ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΣΧΟΛΗ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

Διδακτορική Διατριβή

# Βελτιστοποιημένες Τεχνικές Μηχανικής Όρασης με Χρήση Συνελικτικών Νευρωνικών Δικτύων

Τίτλος στα Αγγλικά
**«Optimized Computer Vision Techniques Using Convolutional Neural Networks»**

Ontise Tsakai

Οντισέ Τσακάι

**ΑΡΤΑ 2025**

ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΣΧΟΛΗ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

Διδακτορική Διατριβή

# Βελτιστοποιημένες Τεχνικές Μηχανικής Όρασης με Χρήση Συνελικτικών Νευρωνικών Δικτύων

Τίτλος στα Αγγλικά
**«Optimized Computer Vision Techniques Using Convolutional Neural Networks»**

Ontise Tsakai

Οντισέ Τσακάι

**ΑΡΤΑ 2025**

**Ημερομηνία αίτηση του κου. Τσακάι Οντισε:** 01/11/2020

**Ημερομηνία ορισμού Τριμελούς Συμβουλευτικής Επιτροπής:** 47/25-11-2020

**Μέλη Τριμελούς Συμβουλευτικής Επιτροπής:**

**Επιβλέπων:**

Γιαννακέας Νικόλαος, Αναπληρωτής Καθηγητής του τμήματος Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων

**Μέλη:**

Τσούλος Ιωάννης, Καθηγητής του τμήματος Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων

Τζάλλας Αλέξανδρος, Αναπληρωτής Καθηγητής του τμήματος Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων

**Ημερομηνία ορισμού θέματος διδακτορικής διατριβής:** 47/25-11-2020

«Βελτιστοποιημένες Τεχνικές Μηχανικής Όρασης με Χρήση Συνελικτικών Νευρωνικών Δικτύων»

**ΟΡΙΣΜΟΣ ΕΠΤΑΜΕΛΟΥΣ ΕΞΕΤΑΣΤΙΚΗΣ ΕΠΙΤΡΟΠΗΣ:** 173/10-12-2025

| | |
|---|---|
| **Γιαννακέας Νικόλαος** | Αναπληρωτής Καθηγητής με γνωστικό αντικείμενο «Σήματα και Συστήματα» του τμήματος Πληροφορικής και Τηλεπικοινωνιών της Σχολής Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων *(Επιβλέπων)* |
| **Τσούλος Ιωάννης** | Καθηγητής με γνωστικό αντικείμενο «Υπολογιστικές Μέθοδοι» του τμήματος Πληροφορικής και Τηλεπικοινωνιών της Σχολής Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων *(Μέλος Τριμελούς Εξεταστικής Επιτροπής)* |
| **Τζάλλας Αλέξανδρος** | Αναπληρωτής Καθηγητής με γνωστικό αντικείμενο «Βιοϊατρική Τεχνολογία με Έμφαση στην Επεξεργασία και Ανάλυση Βιοϊατρικών Δεδομένων» του τμήματος Πληροφορικής και Τηλεπικοινωνιών της Σχολής Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Ιωαννίνων *(Μέλος Τριμελούς Εξεταστικής Επιτροπής)* |
| **Λάμπρης Ευαγγελής** | Επίκουρη Καθηγήτρια με γνωστικό αντικείμενο «Παθολογική Ανατομία» της Ιατρικής Σχολής του Πανεπιστημίου Ιωαννίνων *(Μέλος Επταμελούς Εξεταστικής Επιτροπής)* |
| **Τσίπουρας Μάρκος** | Καθηγητής με γνωστικό αντικείμενο «Ψηφιακή Επεξεργασία Σήματος» του τμήματος Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών της Πολυτεχνικής Σχολής του Πανεπιστημίου Δυτικής Μακεδονίας *(Μέλος Επταμελούς Εξεταστικής Επιτροπής)* |

| | |
|---|---|
| **Βόγκλης Κωνσταντίνος** | Επίκουρος Καθηγητής με γνωστικό αντικείμενο «Ψηφιακές Τεχνολογίες στον Τουρισμό» του τμήματος Πληροφορικής του Ιόνιου Πανεπιστημίου *(Μέλος Επταμελούς Συμβουλευτικής Επιτροπής)* |
| **Ντρίτσος Γιώργος** | Επίκουρος Καθηγητής με γνωστικό αντικείμενο «Στατιστικοί Μέθοδοι και Εφαρμογές» του τμήματος Οικονομικών του Πανεπιστημίου Ιωαννίνων *(Μέλος Επταμελούς Συμβουλευτικής Επιτροπής)* |

**Έγκριση Διδακτορικής Διατριβής με βαθμό «Άριστα» στις 19-12-2025**

**Άρτα, 19-12-2025**

**Ο ΠΡΟΕΔΡΟΣ ΤΟΥ ΤΜΗΜΑΤΟΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΚΠΙΝΩΝΙΩΝ**

**Αλέξανδρος Τζάλλας**
**Αναπληρωτής Καθηγητής**

**Η Γραμματέας του Τμήματος**

**Ευαγγελία Χρήστου**

# *Executive Summary*

This doctoral dissertation presents the development, implementation, and clinical evaluation of the Deep-in-Biopsies platform, a comprehensive system for automated histopathological image analysis using advanced deep learning techniques. The research focuses on addressing critical challenges in digital pathology, including diagnostic subjectivity, lack of integrated analysis tools, and the need for reliable, reproducible results.

The primary contribution of this thesis is the creation of an innovative platform that unifies all phases of digital histopathology - from data annotation to training and evaluation of artificial intelligence models. The platform features a modular microservices architecture, dynamic management of multiple deep learning models, and flexible adaptation to different clinical scenarios.

The research work includes the development and publication of five scientific papers in international conferences and journals, presenting experimental results across various tissue types (liver, kidney, intestine, breast). Specifically, methods were developed and evaluated for quantifying pancreatic steatosis, analyzing hepatic fibrosis, classifying renal tumors according to Fuhrman grading, and multi-organ cancer cell detection through the PanNuke dataset.

Clinical validation across seven medical institutions demonstrated that the platform achieves diagnostic accuracy of 89-94% in various applications, reducing analysis time by 65% compared to traditional methods. The integration of explainable AI models and user-friendly interface facilitated acceptance by the medical community, with 87% of users reporting improved diagnostic confidence.

The dissertation significantly contributes to advancing digital pathology by offering a practical, scalable, and clinically applicable solution that bridges the gap between research innovation and clinical practice.

# *Επιτελική Σύνοψη*

Η παρούσα διδακτορική διατριβή παρουσιάζει την ανάπτυξη, υλοποίηση και κλινική αξιολόγηση της πλατφόρμας Deep-in-Biopsies, ενός ολοκληρωμένου συστήματος για την αυτοματοποιημένη ανάλυση ιστοπαθολογικών εικόνων με χρήση προηγμένων τεχνικών βαθιάς μάθησης. Η έρευνα εστιάζει στην αντιμετώπιση των κρίσιμων προκλήσεων της ψηφιακής παθολογίας, συμπεριλαμβανομένης της υποκειμενικότητας στη διάγνωση, της έλλειψης ολοκληρωμένων εργαλείων ανάλυσης και της ανάγκης για αξιόπιστα, επαναλήψιμα αποτελέσματα.

Η κύρια συνεισφορά της διατριβής είναι η δημιουργία μιας καινοτόμου πλατφόρμας που ενοποιεί όλες τις φάσεις της ψηφιακής ιστοπαθολογίας - από τη σημειοθέτηση δεδομένων έως την εκπαίδευση και αξιολόγηση μοντέλων τεχνητής νοημοσύνης. Η πλατφόρμα χαρακτηρίζεται από τμηματική αρχιτεκτονική μικρουπηρεσιών, δυναμική διαχείριση πολλαπλών μοντέλων βαθιάς μάθησης και ευέλικτη προσαρμογή σε διαφορετικά κλινικά σενάρια.

Η ερευνητική εργασία περιλαμβάνει την ανάπτυξη και δημοσίευση πέντε επιστημονικών άρθρων σε διεθνή συνέδρια και περιοδικά, παρουσιάζοντας πειραματικά αποτελέσματα σε διάφορους τύπους ιστών (ήπαρ, νεφρός, έντερο, μαστός). Συγκεκριμένα, αναπτύχθηκαν και αξιολογήθηκαν μέθοδοι για την ποσοτικοποίηση παγκρεατικής στεάτωσης, την ανάλυση ηπατικής ίνωσης, την ταξινόμηση νεφρικών όγκων κατά Fuhrman, και την πολυοργανική ανίχνευση καρκινικών κυττάρων μέσω του συνόλου δεδομένων PanNuke.

Η κλινική επικύρωση σε επτά ιατρικά ιδρύματα κατέδειξε ότι η πλατφόρμα επιτυγχάνει διαγνωστική ακρίβεια 89-94% σε διάφορες εφαρμογές, μειώνοντας τον χρόνο ανάλυσης κατά 65% σε σύγκριση με τις παραδοσιακές μεθόδους. Η ενσωμάτωση επεξηγήσιμων μοντέλων τεχνητής νοημοσύνης και η φιλική προς τον χρήστη διεπαφή διευκόλυναν την αποδοχή από την ιατρική κοινότητα, με το 87% των χρηστών να αναφέρουν βελτίωση στη διαγνωστική τους εμπιστοσύνη.

Η διατριβή συνεισφέρει σημαντικά στην προώθηση της ψηφιακής παθολογίας, προσφέροντας μια πρακτική, επεκτάσιμη και κλινικά εφαρμόσιμη λύση που γεφυρώνει το χάσμα μεταξύ ερευνητικής καινοτομίας και κλινικής πράξη.

# *Ευχαριστίες*

Η ολοκλήρωση της παρούσας διδακτορικής διατριβής αποτελεί το αποτέλεσμα μιας μακρόχρονης προσπάθειας που δεν θα ήταν δυνατή χωρίς την πολύτιμη υποστήριξη και συμβολή σημαντικών προσώπων, τα οποία θα ήθελα να ευχαριστήσω θερμά.

Πρωτίστως, οφείλω βαθιά ευγνωμοσύνη στον επιβλέποντα Καθηγητή μου, **Νικόλαο Γιαννακέα**, για την αμέριστη καθοδήγηση, την επιστημονική του υποστήριξη και την εμπιστοσύνη που μου έδειξε καθ' όλη τη διάρκεια της διδακτορικής μου έρευνας. Η καθοδήγησή του, οι εποικοδομητικές του παρατηρήσεις και η συνεχής ενθάρρυνσή του αποτέλεσαν καταλυτικούς παράγοντες για την επιτυχή ολοκλήρωση αυτής της εργασίας.

Θερμές ευχαριστίες απευθύνω επίσης στους μέντορές μου, **Αλέξανδρο Τζάλλα** και **Μάρκο Τσίπουρα**, για την πολύτιμη συμβολή τους, τις εποικοδομητικές συζητήσεις και τη συνεχή τους υποστήριξη. Η εμπειρία τους και οι συμβουλές τους υπήρξαν ανεκτίμητες για την ακαδημαϊκή μου εξέλιξη.

Ιδιαίτερες ευχαριστίες οφείλω στον **Νικόλαο Κατερτσίδη** για τη σημαντική συμβολή του στον τεχνολογικό τομέα της έρευνας. Η τεχνική του εμπειρογνωμοσύνη και η πρακτική του βοήθεια συνέβαλαν ουσιαστικά στην υλοποίηση της πλατφόρμας Deep-in-Biopsies.

Τέλος, αλλά όχι λιγότερο σημαντικό, θα ήθελα να εκφράσω την απέραντη ευγνωμοσύνη μου στην **οικογένειά μου** για την ακλόνητη υποστήριξη, την υπομονή και την αγάπη που μου προσέφεραν όλα αυτά τα χρόνια. Χωρίς τη συμπαράστασή τους, αυτό το ταξίδι δεν θα ήταν δυνατό.

Σε όλους τους παραπάνω, εκφράζω την ειλικρινή μου ευγνωμοσύνη.

# *Περιεχόμενα*

**Executive Summary** ..... **1**

**Επιτελική Σύνοψη** ..... **2**

**Ευχαριστίες** ..... **3**

**Περιεχόμενα** ..... **4**

**Λίστα Διαγραμμάτων** ..... **11**

**Λίστα Πινάκων** ..... **12**

**Λίστα Εικόνων** ..... **xiv**

**Λίστα Πηγαίου Κώδικα** ..... **xv**

**Κεφάλαιο 1** ..... **16**

**Εισαγωγή: Ψηφιακή Παθολογία και σύγχρονες προκλήσεις** ..... **16**

1.1. Προκλήσεις στη Σύγχρονη Ψηφιακή Παθολογία ..... 17

1.2. Κλινικά Προβλήματα στην Ιστοπαθολογική Ανάλυση ..... 18

1.3. Ερευνητικοί Στόχοι και Ερωτήματα ..... 20

1.4. Επιστημονική Συνεισφορά της Διατριβής ..... 21

1.5. Δομή Διατριβής ..... 22

**Κεφάλαιο 2** ..... **24**

**Ιατρικό Υπόβαθρο, Επιστημονική και Τεχνολογική Στάθμιση** ..... **24**

2.1. Ψηφιακή Παθολογία: Θεμελιώδεις Αρχές και Κλινικές Ροές Εργασίας ..... 25

2.1.1. Εισαγωγή στην Ψηφιακή Παθολογία ..... 25

2.1.2. Θεμελιώδεις Αρχές και Τεχνολογικό Υπόβαθρο ..... 25

2.1.3. Κλινικές Ροές Εργασίας και Διαγνωστική Διαδικασία ..... 25

2.1.4. Τεχνικές Προκλήσεις και Μελλοντικές Προοπτικές ..... 27

2.2. Βαθιά Μάθηση στην Ιατρική Απεικόνιση ..... 27

2.2.1. Ιστορική Εξέλιξη και Θεμελιώδεις Έννοιες ..... 27

2.2.2. Συνελικτικά Νευρωνικά Δίκτυα: Αρχιτεκτονική και Λειτουργία ..... 28

2.2.3. Κλινικές Εφαρμογές και Ερευνητικά Επιτεύγματα ..... 29

2.2.4. Προκλήσεις και Όρια της Τεχνολογίας ..... 30

2.3. Αρχιτεκτονικές Συνελικτικών Νευρωνικών Δικτύων ..... 31

2.3.1. Εξέλιξη και Χαρακτηριστικά των Σύγχρονων Αρχιτεκτονικών ..... 31

2.3.2. Κλασικές Αρχιτεκτονικές και η Εφαρμογή τους στην Ιστοπαθολογία ..... 31

2.3.3. Εξειδικευμένες Αρχιτεκτονικές για Ανάλυση Ιστών ..... 32

2.3.4. Βελτιστοποίηση και Προκλήσεις Εφαρμογής ..... 34

2.4. Instance Segmentation: Mask R-CNN και Παραλλαγές ..... 35

2.4.1. Εισαγωγή στον Εντοπισμό και Κατάτμηση Στιγμιότυπων ..... 35

2.4.2. Η Αρχιτεκτονική του Mask R-CNN ..... 35

2.4.3. Προσαρμογή για Ιστοπαθολογικές Εφαρμογές ..... 37
2.4.4. Εξελίξεις και Παραλλαγές του Mask R-CNN ..... 37
2.4.5. Νέες Προσεγγίσεις με Αρχιτεκτονικές Transformer ..... 38
2.4.6. Εξειδικευμένες Τεχνικές για Ιστοπαθολογία ..... 39
2.4.7. Σύγκριση και Αξιολόγηση Αρχιτεκτονικών ..... 40
2.4.8. Εφαρμογή στην Πλατφόρμα Deep-in-Biopsies ..... 41
2.4.9. Μελλοντικές Κατευθύνσεις και Τεχνολογικές Εξελίξεις ..... 43
2.5. Υπάρχουσες Πλατφόρμες και Εργαλεία ..... 44
2.5.1. QuPath: Ερευνητικά Προσανατολισμένη Πλατφόρμα Ανοιχτού Κώδικα ..... 44
2.5.2. Cytomine: Συνεργατική Πλατφόρμα για Σημειοθέτηση και Μηχανική Μάθηση ..... 45
2.5.3. Aiforia: Εμπορική Λύση για Κλινική Εφαρμογή ..... 45
2.5.4. Συγκριτική Ανάλυση και Αξιολόγηση ..... 46
2.5.5. Νέες Τάσεις και Εμφανιζόμενες Πλατφόρμες ..... 47
2.6. Ανάλυση Κενών και Περιορισμών ..... 47
2.6.1. Τεχνολογικά Κενά και Τεχνικοί Περιορισμοί ..... 48
2.6.2. Μεθοδολογικοί Περιορισμοί και Ερευνητικά Κενά ..... 48
2.6.3. Κλινικοί Περιορισμοί και Πρακτικά Εμπόδια ..... 49
2.6.4. Λειτουργικά Κενά και Προκλήσεις Χρηστικότητας ..... 50
2.6.5. Στρατηγικά Κενά και Μακροπρόθεσμες Προκλήσεις ..... 50
2.6.6. Συνοπτική Αξιολόγηση και Προτεραιότητες ..... 51

**Κεφάλαιο 3 ..... 52**

**Ανάλυση απαιτήσεων και σχεδιασμός υλοποίησης ..... 52**
3.1. Ανάλυση Κλινικών Απαιτήσεων και Προδιαγραφών ..... 53
3.1.1. Μελέτη Αναγκών Παθολόγων και Ερευνητών ..... 53
3.1.2. Καταγραφή Λειτουργικών και Μη-Λειτουργικών Απαιτήσεων ..... 55
3.1.3. Ανάλυση Προκλήσεων στην Ψηφιακή Παθολογία ..... 57
3.1.4 Συγκριτική Ανάλυση της Πλατφόρμας ..... 59
3.2. Αρχιτεκτονική Συστήματος και Σχεδιαστικές Αρχές ..... 62
3.2.1. Φιλοσοφία Τμηματικού Σχεδιασμού και Επεκτασιμότητα ..... 63
3.2.2. Στρατηγική Ενσωμάτωσης Πολλαπλών Συστατικών ..... 64
3.2.3. Αρχές Κλιμάκωσης και Συντηρησιμότητας ..... 65
3.3. Σχεδιασμός Κεντρικής Μονάδας (Backend Module) ..... 66
3.3.1. Επιλογή Αρχιτεκτονικής PHP/Laravel MVC ..... 67
3.3.2. Σχεδιασμός Βάσης Δεδομένων για Αρχεία και Σημειώσεις ..... 68
3.3.3. Σχεδιασμός Διεπαφών Προγραμματισμού Εφαρμογών ..... 69
3.3.4. Αρχιτεκτονική Ελέγχου Πρόσβασης Βάσει Ρόλων ..... 70
3.4. Σχεδιασμός Μονάδας Δημιουργίας Σημειώσεων ..... 72
3.4.1. Απαιτήσεις Διαδραστικού Περιβάλλοντος Σημειώσεων ..... 72
3.4.2. Επιλογή Τεχνολογίας JavaScript/Konva.js ..... 75
3.4.3. Σχεδιασμός Εργαλείων Σχεδίασης ..... 76
3.4.4. Αρχιτεκτονική Δυναμικής Ταξινόμησης ..... 78
3.5. Σχεδιασμός Μονάδας Τεχνητής Νοημοσύνης ..... 79
3.5.1. Επιλογή Πλαισίου Python/Detectron2 ..... 79
3.5.2. Αρχιτεκτονική Συνελικτικών Νευρωνικών Δικτύων ..... 80
3.6. Σχεδιασμός Επικοινωνιακού Στρώματος ..... 83
3.6.1. Αρχιτεκτονική Συγχρονισμού Δεδομένων σε Πραγματικό Χρόνο ..... 84
3.6.2. Υποστήριξη Πολλαπλών Χρηστών και Συνεργατικότητα ..... 85

3.6.3. Διαχείριση Ασύγχρονων Εργασιών και Ουρών ... 86

**Κεφάλαιο 4 ... 89**

**Ανάπτυξη και Βελτιστοποίηση Συνελικτικών Νευρωνικών Δικτύων ... 89**

4.1. Mask R-CNN: Προσαρμογή για Ιστοπαθολογικά Δεδομένα ... 90
4.1.1. Αρχιτεκτονική Βάση και Τροποποιήσεις ... 90
4.1.2. Προσαρμογή Mask Head για Κυτταρική Κατάτμηση ... 91
4.1.3. Εξειδικευμένη συνάρτηση σφάλματος ... 91
4.1.4. Μεθοδολογία Εκπαίδευσης για Ιστοπαθολογικές Εφαρμογές ... 91
4.1.5. Αξιολόγηση και Μετρικές Απόδοσης ... 92
4.1.6. Βελτιστοποιήσεις για Πραγματικό Χρόνο ... 93
4.2. Backbone Networks: ResNet-50 vs ResNet-101 ... 94
4.2.1. Επισκόπηση Αρχιτεκτονικών Backbone για Ιστοπαθολογία ... 94
4.2.2. Τεχνική Ανάλυση ResNet-50 vs ResNet-101 ... 95
4.3. Στρατηγικές Μεταφοράς Μάθησης ... 95
4.3.1. Διαχείριση Domain Gap και Cross-Institutional Validation ... 97
4.3.2. Αυτοματοποιημένη Αποθήκευση και Διαχείριση Βαρών ... 97
4.3.3. Τεχνικές Αντιμετώπισης Ανισορροπίας Κλάσεων ... 98
4.3.4. Βέλτιστες Πρακτικές και Συστάσεις ... 99
4.4. Τεχνικές Επαύξησης Δεδομένων και Προεπεξεργασία Εικόνας ... 100
4.4.1. Ολοκληρωμένη Προσέγγιση Αύξησης Δεδομένων ... 100
4.4.2. Στατιστική Κανονικοποίηση και Εξαγωγή Χρωματικών Παραμέτρων ... 101
4.4.3. Προηγμένη Σειρά Μετασχηματισμών Detectron2 ... 101
4.4.4. Φωτομετρικές Προσαρμογές και Χρωματικός Έλεγχος ... 101
4.4.5. Στρατηγική Τυχαίας Κάλυψης και Χωρική Παραλλαγή ... 102
4.4.6. Περιστροφικοί Μετασχηματισμοί και Διατήρηση Γεωμετρίας ... 102
4.4.7. Δυναμική Παραμετροποίηση και Προσαρμοστικότητα ... 102
4.4.8. Αυτοματοποιημένο Pipeline και Backend Integration ... 103
4.4.9. Βελτιστοποίηση Απόδοσης με CUDA Integration ... 103
4.5. Χειροκίνητη Ρύθμιση Υπερπαραμέτρων ... 104
4.5.1. Φιλοσοφία Χειροκίνητης Βελτιστοποίησης σε Κλινικά Περιβάλλοντα ... 104
4.5.2. Αρχιτεκτονική Configuration Interface και Παραμετρική Διαχείριση ... 104
4.5.3. Εμπειρικά Καθιερωμένες Βασικές Παράμετροι ... 105
4.5.4. Διαφοροποιημένες Στρατηγικές ανά Αρχιτεκτονική ... 105
4.5.5. Οπτικά Εργαλεία Ανάλυσης και Καθοδήγηση Αποφάσεων ... 106
4.5.6. Στρατηγική Βήμα-προς-Βήμα Βελτιστοποίησης ... 106
4.5.7. Προσαρμογή στις Ειδικές Απαιτήσεις των Δεδομένων ... 107
4.5.8. Εκμετάλλευση Ensemble Strategies και Model Comparison ... 107
4.5.9. Διαχείριση Υπολογιστικών Πόρων και Χρονικών Περιορισμών ... 107
4.5.10. Μελλοντικές Κατευθύνσεις και Hibrid Approaches ... 108
4.6. Υποστήριξη Πολλαπλών Μονάδων Γραφικών ... 108
4.6.1. Κρισιμότητα της Επιτάχυνσης Μονάδων Γραφικών στην Ιστοπαθολογική Ανάλυση ... 108
4.6.2. Αρχιτεκτονική Πολλαπλών Μονάδων Γραφικών και Κατανεμημένη Επεξεργασία ... 109
4.6.3. Βελτιστοποιήσεις Μνήμης και Αποδοτικότητας ... 109
4.6.4. Αυτοματοποιημένη Διαχείριση Υπολογιστικών Πόρων ... 109
4.6.5. Παράλληλη Επεξεργασία ... 110
4.6.6. Παρακολούθηση και Αναλυτικά Στοιχεία Απόδοσης ... 110
4.6.7. Ανοχή Σφαλμάτων και Μηχανισμοί Αποκατάστασης ... 111

4.6.8. Συγκριτική Ανάλυση Απόδοσης Πολλαπλών έναντι Μονής Μονάδας Γραφικών ..... 111
4.6.9. Οικονομικά και Περιβαλλοντικά Οφέλη ..... 112
4.6.10. Μελλοντικές Κατευθύνσεις και Τεχνολογικές Εξελίξεις ..... 112

**Κεφάλαιο 5 ..... 113**

**ΥΛΟΠΟΙΗΣΗ ΚΑΙ ΕΝΣΩΜΑΤΩΣΗ ΤΟΥ DEEP-IN-BIOPSIES ..... 113**

5.1. Υλοποίηση Κεντρικής Μονάδας (Backend Module) ..... 114
5.1.1. Ανάπτυξη Βασικής Εφαρμογής με PHP/Laravel ..... 115
5.1.2. Υλοποίηση Υβριδικής Βάσης Δεδομένων ..... 117
5.1.3. Υλοποίηση RESTful API και Ελεγκτών ..... 120
5.1.4. Υλοποίηση Προηγμένου Συστήματος Ουρών ..... 120
5.1.5. Διεπαφές Χρήστη και Εμπειρία Χρήσης ..... 121
5.1.6. Βοηθητικές Κλάσεις και Υπολογιστικές Λειτουργίες ..... 124
5.1.7. Συστήματα Ελέγχου Πρόσβασης και Ασφάλειας ..... 125
5.1.8. Ενσωμάτωση με Εξωτερικά Συστήματα ..... 126
5.1.9. Βελτιστοποιήσεις Απόδοσης και Κλιμάκωσης ..... 127
5.1.10. Εργαλεία Command Line και Αυτοματοποίηση ..... 127
5.2. Υλοποίηση Μονάδας Δημιουργίας Σημειώσεων ..... 128
5.2.1. Ανάπτυξη JavaScript/Konva.js Εφαρμογής ..... 128
5.2.2. Υλοποίηση Εργαλείων Σχεδίασης και Επεξεργασίας ..... 134
5.2.3. Υλοποίηση Συστήματος Δυναμικής Ταξινόμησης ..... 136
5.2.4. Διεπαφή Χρήστη και Διαχείριση Εργασιών ..... 137
5.2.5. Σύστημα Αυτόματης Αποθήκευσης και Ανάκτησης ..... 141
5.2.6. Διαχείριση Πολλαπλών Canvas Layers ..... 142
5.2.7. Προηγμένες Λειτουργίες Επεξεργασίας και Πλοήγησης ..... 142
5.2.8. Σύστημα Διαχείρισης Ιστορικού και Αναίρεσης ..... 142
5.2.9. Υλοποίηση Συστήματος Επιλογής και Διαχείρισης Εικόνων ..... 143
5.2.10. Σύστημα Εξαγωγής και Στατιστικής Ανάλυσης ..... 143
5.2.11. Διαχείριση Περιοχικών Χαρακτηριστικών ..... 144
5.2.12. Διαχείριση Ρυθμίσεων και Προσωποποίηση ..... 144
5.2.13. Ολοκλήρωση Συστημάτων και Διαχείριση Δεδομένων ..... 144
5.2.14. Βελτιστοποίηση Απόδοσης και Ποιότητα Κώδικα ..... 145
5.3. Υλοποίηση Μονάδας Επεξεργασίας TN ..... 146
5.3.1. Ανάπτυξη Εφαρμογής Python/Detectron2 ..... 147
5.3.2. Υλοποίηση Συνελικτικών Δικτύων και Διαδικασίας Εκπαίδευσης ..... 148
5.3.3. Ενσωμάτωση Επιτάχυνσης μέσω Γραφικών Επεξεργαστών ..... 153
5.3.4. Διαχείριση Μοντέλων και Αποθήκευση Βαρών Συνδέσεων ..... 154
5.3.5. Υλοποίηση Διαχείρισης Πολλαπλών Αρχείων Βαρών ..... 155
5.3.6. Αυτόματη Διαχείριση Μοντέλων ανά Κλινική Περίπτωση ..... 155
5.3.7. Αντιγραφή Ασφαλείας και Αποκατάσταση Συστήματος ..... 156
5.3.8. Σύνδεση με το Backend σύστημα και Επικοινωνία Πραγματικού Χρόνου ..... 157
5.3.9. Συστήματα Μετρικών και Αξιολόγησης ..... 157
5.3.10. Βελτιστοποίηση Απόδοσης και Παρακολούθηση Συστήματος ..... 159
5.4. Ενσωμάτωση Κεντρικής Μονάδας με Μονάδα Τεχνητής Νοημοσύνης ..... 160
5.4.2. Συγχρονισμός Δεδομένων σε Πραγματικό Χρόνο ..... 162
5.4.3. Διαχείριση Ασύγχρονων Εργασιών Επεξεργασίας ..... 163
5.4.4. Συστήματα Χειρισμού Σφαλμάτων και Καταγραφής ..... 164
5.5. Ροή Εργασίας Χρήστη και Βελτιστοποίηση Απόδοσης ..... 165

5.5.2. Βελτιστοποίηση Απόδοσης Συνολικού Συστήματος ..... 168
5.5.3. Στρατηγικές Προσωρινής Αποθήκευσης και Βελτιστοποίησης ..... 170
5.5.4. Πλαίσιο Ποιοτικού Ελέγχου και Αυτοματοποιημένων Δοκιμών ..... 171
5.6. Πλαίσιο Ποιοτικού Ελέγχου και Δοκιμών ..... 171
5.6.1. Αρχιτεκτονική Συστήματος Ποιοτικού Ελέγχου ..... 172
5.6.2. Δοκιμές Λειτουργικότητας Backend Συστήματος ..... 172
5.6.3. Επικύρωση Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης ..... 174
5.6.4. Σύστημα Παρακολούθησης και Καταγραφής ..... 175
5.6.5. Διασφάλιση Ποιότητας σε Κλινικό Περιβάλλον ..... 176

**Κεφάλαιο 6 ..... 177**

**ΚΛΙΝΙΚΕΣ ΕΦΑΡΜΟΓΕΣ ΚΑΙ ΜΕΛΕΤΕΣ ΕΠΙΚΥΡΩΣΗΣ ..... 177**

6.1. Παγκρεατική Στεάτωση: Συνδυαστική Ταξινόμηση με CNN Ensemble ..... 178
6.1.1. Κλινικό Υπόβαθρο και Σημασία ..... 178
6.1.2. Μεθοδολογία Συνδυαστικής Ταξινόμησης ..... 178
6.1.3. Αποτελέσματα και Κλινική Επικύρωση ..... 179
6.2. Νεφρική Βαθμολόγηση Fuhrman: Αυτοματοποιημένη Ταξινόμηση Νεφρικών Όγκων ..... 180
6.2.1. Κλινικό Υπόβαθρο και Σημασία ..... 180
6.2.2. Σύνολο Δεδομένων και Χαρακτηριστικά ..... 180
6.2.3. Μεθοδολογία Ταξινόμησης και Αρχιτεκτονική ..... 181
6.3. Ιδιοπαθείς Φλεγμονώδεις Νόσοι: Ποσοτικοποίηση Κολλαγόνου ..... 183
6.3.1. Κλινικές Προκλήσεις στις Φλεγμονώδεις Νόσους του Εντέρου ..... 183
6.3.2. Ανάπτυξη Αλγορίθμου Πολυστρωματικής Ανάλυσης ..... 184
6.3.3. Κλινική Συσχέτιση και Προγνωστική Αξία ..... 184
6.4. Pan-Cancer Ανάλυση με PanNuke Dataset ..... 185
6.4.1. Το Σύνολο Δεδομένων PanNuke και η Σημασία του ..... 185
6.4.2. Συγκριτική Αξιολόγηση Αρχιτεκτονικών ..... 185
6.4.3. Γενίκευση σε Πολλαπλούς Τύπους Ιστών ..... 186
6.5. Ολοκληρωμένη Ροή Εργασίας για Ιστοπαθολογικά Δεδομένα ..... 186
6.6. Συγκριτική Ανάλυση Μεθοδολογιών ..... 188
6.6.1. Σύγκριση Τεχνικών Προσεγγίσεων ..... 188
6.6.2. Πολυκεντρική Επικύρωση και Γενικευσιμότητα ..... 188
6.6.3. Αξιολόγηση Αποδοτικότητας και Ακρίβειας ..... 189
6.6.4. Κλινική Αξία και Εφαρμοσιμότητα ..... 189
6.7. Ενσωμάτωση στην Κλινική Ροή Εργασίας ..... 190
6.7.1. Μελέτες Αποδοχής από Χρήστες ..... 190
6.7.2. Βελτιώσεις στη Διαγνωστική Ακρίβεια ..... 190
6.7.3. Οικονομική Αξιολόγηση και Επίδραση στο Σύστημα Υγείας ..... 191
6.8. Συμπεράσματα και Μελλοντικές Κατευθύνσεις ..... 191

**Κεφάλαιο 7 ..... 192**

**ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΚΛΙΝΙΚΗ ΑΠΟΤΕΛΕΣΜΑΤΙΚΟΤΗΤΑ ..... 192**

7.1. Επισκόπηση Πειραματικής Μεθοδολογίας ..... 193
7.1.1. Σύνολα Δεδομένων και Πειραματικό Σχέδιο ..... 193
7.2. Συγκεντρωτικά αποτελέσματα πιλοτικών εφαρμογών ..... 193
7.2.1. Μεθοδολογία Αξιολόγησης ..... 193
7.2.2. Αποτελέσματα Απόδοσης ..... 194
7.2.3. Ανάλυση Υπολογιστικής Απόδοσης ..... 194

7.2.4. Κόστος-Όφελος Ανάλυση ... 195
7.2.5. Εφαρμογή σε Διαφορετικά Κλινικά Σενάρια ... 195
7.2.6. Τεχνικές Παράμετροι Εκπαίδευσης ... 196
7.2.7. Πειραματικά Αποτελέσματα και Συγκριτική Ανάλυση ... 196
7.2.8. Εξειδικευμένες Τεχνικές για Ιστοπαθολογικά Δεδομένα ... 197
7.3. Αποτελέσματα Παγκρεατικής Στεάτωσης ... 198
7.3.1. Απόδοση Μοντέλων Συνδυαστικού Συστήματος CNN ... 198
7.3.2. Κλινική Επικύρωση ... 200
7.3.3. Ανάλυση Πίνακα Σύγχυσης - ResNet-50 ... 201
7.4. Αποτελέσματα Νεφρικού Συνόλου Δεδομένων ... 202
7.4.1. Συγκριτική Απόδοση Αρχιτεκτονικών ... 202
7.4.2. Ανάλυση Πινάκων Σύγχυσης ... 203
7.5. Αποτελέσματα Συνόλου Δεδομένων IBD ... 203
7.5.1. Εξειδικευμένη Ανάλυση με Mask R-CNN ... 203
7.5.2. Ανάλυση Περιορισμών και Προκλήσεων ... 204
7.6. Αποτελέσματα Ανάλυσης Pan-Cancer (Σύνολο Δεδομένων PanNuke) ... 204
7.6.1. Απόδοση Παραλλαγών YOLOv8 ... 204
7.6.2. Συγκριτική Αξιολόγηση και Θέση στη Βιβλιογραφία ... 206
7.6.3. Γενίκευση Μεταξύ Ιστών και Απόδοση Πολλαπλών Οργάνων ... 208
7.7. Συγκριτική Ανάλυση και Αξιολόγηση ... 212
7.7.1. Πειραματικά Αποτελέσματα Μεταφοράς Μάθησης ανά εφαρμογή ... 212
7.7.2. Σύγκριση Επιδόσεων ανά Μοντέλο ... 214
7.7.3. Κλινικές Επιπτώσεις των Αποτελεσμάτων ... 215

**Κεφάλαιο 8 ... 216**

**ΣΥΖΗΤΗΣΗ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗ ... 216**
8.1. Τεχνικές Καινοτομίες της Πλατφόρμας ... 217
8.2. Κανονιστικές και Ηθικές Πτυχές ... 217
8.2.1. Κανονιστική Συμμόρφωση και Εγκρίσεις ... 217
8.2.2. Προστασία Δεδομένων και Ιδιωτικότητα ... 218
8.2.3. Ηθικές Προκλήσεις και Ευθύνη ... 218
8.3. Περιορισμοί και Τεχνικές Προκλήσεις ... 218
8.3.1. Περιορισμοί Γενίκευσης και Μετατόπιση Πεδίου ... 218
8.3.2. Τεχνικές Προκλήσεις Κλιμάκωσης ... 219
8.4. Σύγκριση με Υπάρχουσες Λύσεις ... 219
8.5. Επιπτώσεις για την Κλινική Πράξη ... 219
8.5.1. Μετασχηματισμός του Ρόλου του Παθολόγου ... 219
8.5.2. Οικονομικές Επιπτώσεις και Βιωσιμότητα ... 220
8.5.3. Κοινωνικές και Ηθικές Διαστάσεις ... 220
8.6. Συμπεράσματα Κεφαλαίου ... 220

**Κεφάλαιο 9 ... 222**

**ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΣΥΝΕΙΣΦΟΡΕΣ ... 222**
9.1. Συνοπτική Ανακεφαλαίωση ... 223
9.2. Βασικές Επιστημονικές Συνεισφορές ... 223
9.2.1. Ολοκληρωμένη Αρχιτεκτονική Πλατφόρμας ... 223
9.2.2. Σύστημα Διαχείρισης Πολλαπλών Μοντέλων ... 223
9.2.3. Εργονομική Διεπαφή και Ροή Εργασίας ... 224

9.2.4. Κλινική Επικύρωση και Αξιολόγηση ..... 224
9.2.5. Συμβολή στη Θεωρία Επεξηγήσιμης Τεχνητής Νοημοσύνης ..... 224
9.3. Κλινική Αξία και Επίδραση ..... 225
9.3.1. Βελτίωση Διαγνωστικής Ακρίβειας ..... 225
9.3.2. Αύξηση Αποδοτικότητας Ροής Εργασίας ..... 225
9.3.3. Υποστήριξη Κλινικής Απόφασης ..... 225
9.4. Περιορισμοί της Μελέτης ..... 225
9.5. Μελλοντικές Κατευθύνσεις Έρευνας ..... 226
9.5.1. Ενσωμάτωση Νέων Τεχνολογιών Τεχνητής Νοημοσύνης ..... 226
9.5.2. Επέκταση σε Νέους Κλινικούς Τομείς ..... 226
9.5.3. Βελτίωση Επεξηγησιμότητας και Εμπιστοσύνης ..... 226
9.5.4. Ανάπτυξη Συνεργατικής Κοινότητας ..... 227
9.6. Τελικά Συμπεράσματα ..... 227

**Επιστημονικές Δημοσιεύσεις ..... 228**

**Γλωσσάριο Όρων ..... 230**

**Κώδικας Υλοποίησης ..... 237**

**Αναφορές ..... 239**

# *Λίστα Διαγραμμάτων*

Διάγραμμα 1. Αρχιτεκτονική Mask R-CNN (Σύνδεσμος) 36
Διάγραμμα 2. Διάγραμμα ακολουθίας για τις διαδικασίες του ειδικού ιατρού. 55
Διάγραμμα 3. Γενική μελέτη των λειτουργικών απαιτήσεων για την πλατφόρμα 56
Διάγραμμα 4. Η συνολική αρχιτεκτονική του συστήματος σε απλή μορφή. 62
Διάγραμμα 5. Αρχιτεκτονική του πρότυπου MVC 69
Διάγραμμα 6. Διάγραμμά/σχήμα αρχιτεκτονικής του Deep-in-Biopsies και επικοινωνία, με απεικόνιση των συνδέσεων με όλα τα υποσυστήματα. 114
Διάγραμμα 7. Entity Relationship διάγραμμα όλης της σχεσιακής βάσης δεδομένων 119
Διάγραμμα 8. Διάγραμμα ροής παθολογοανατόμου για τη εκπαίδευση του Νευρωνικου Δικτύου, AI Application. 166
Διάγραμμα 9. Διάγραμμα ροής της προτεινόμενης μεθοδολογίας για την αξιολόγηση της διήθησης παγκρεατικού λίπους σε μικροσκοπικές εικόνες βιοψίας. 186

# *Λίστα Πινάκων*

Πίνακα 1: Σύγκριση του Deep-in-Biopsies image annotator με υπάρχουσες πλατφόρμες. 60
Πίνακα 2: Σύγκριση του Deep-in-Biopsies image annotator με υπάρχουσες πλατφόρμες. 61
Πίνακα 3. Επιλογή μετρικών απόδοσης. ..... 92
Πίνακα 4. Σύγκριση του Mask R-CNN με τα προσαρμοσμένα μοντέλα. ..... 93
Πίνακα 5. Βελτιστοποίηση του Inference ..... 93
Πίνακα 6. Ποσοστά των backbone αρχιτεκτονικών στην Ιστοπαθολογικά ..... 94
Πίνακα 7. Ποσοστά των backbone αρχιτεκτονικών στην Ιστοπαθολογικά ..... 95
Πίνακα 8 . Λεπτομερείς ανάλυση ανά αρχιτεκτονική ..... 96
Πίνακα 9 . Βασικές παράμετροι για τον ρυθμό εκμάθησης και εκτιμήσεις αυτών ..... 97
Πίνακα 10. Στατιστικά δοκίμων από τα ιδρύματα ..... 97
Πίνακα 11. Αποτελέσματα βελτιώσεις από τις Τεχνικές Αντιμετώπισης Ανισορροπίας Κλάσεων ..... 99
Πίνακα 12. Υπερπαράμετροι με βάση το μέγεθος του συνόλου των εικόνων ..... 100
Πίνακα 13. Υπερπαράμετροι με βάση κλασικά προβλήματα εποπτευόμενων μεθόδων .. 100
Πίνακα 14. Συγκριτική Αξιολόγηση Τεχνικής Απόδοσης. ..... 180
Πίνακα 15. Κλινικές Μετρικές Αξιοπιστίας. ..... 185
Πίνακα 16. Ποσοστά αποτελεσμάτων pancreatic tissue classification ..... 194
Πίνακα 17. Ποσοστά αποτελεσμάτων breast cancer classification ..... 194
Πίνακα 18. Ποσοστά αποτελεσμάτων mutli-organ classification ..... 194
Πίνακα 19. Χρόνοι εκπαιδεύσεις και δοκίμων ..... 195
Πίνακα 20. Αποτελεσματικότητα ResNet-50 έναντι ResNet-101 ..... 195
Πίνακα 21. Συστάσεις εφαρμογών ανά backbone ..... 196
Πίνακα 22.Απόδοση Ακρίβειας των αρχιτεκτονικών ..... 197
Πίνακα 23. Λεπτομερείς Μετρικές Απόδοσης των αρχιτεκτονικών ..... 197
Πίνακα 24. Απόδοση Μοντέλων Μεταφοράς ΜάθησηςΑπόδοση Μοντέλων Μεταφοράς Μάθησης ..... 199
Πίνακα 25. Μεταφορά Μάθησης έναντι Εκπαίδευσης από Μηδέν ..... 200
Πίνακα 26. Απόδοση ανά Στάδιο Στεάτωσης ..... 201
Πίνακα 27. Πίνακας Σύγχυσης - ResNet-50 (n=768 εικόνες ελέγχου) ..... 202
Πίνακα 28. Απόδοση Παραλλαγών YOLOv8 στο PanNuke[147] ..... 205
Πίνακα 29. Ποιότητα Πανοπτική ανά Τύπο Κυττάρου ..... 206
Πίνακα 30. Δυαδική Ποιότητα Πανοπτική ανά Τύπο Ιστού [147] ..... 209
Πίνακα 31. Στατιστικά από transfer learning αποτελέσματα των αρχιτεκτονικών στο pancreatic tissue ..... 212
Πίνακα 32. Στατιστικά από conifusion matrix σε ResNet-50 στο pancreatic tissue ανά κλαση ..... 213
Πίνακα 33. Σύγκριση απόδοση εκπαιδεύσεις ..... 213

Πίνακα 34. Πολυοργανικές δοκιμές από μοντέλα παγκρεατικών ιστώDomain Adaptation Techniques..... 214
Πίνακα 35. Στρατιστικα απο multi-organ σχετικά με την σύγκριση πριν και μετα την βελτίωση της εκπαιδυεσεις..... 214

# *Λίστα Εικόνων*

Εικόνα 1. Παράδειγμα δομής annotation collection του MongoDB ..... 118
Εικόνα 2. Διαδραστικα UI components για τις ουρές εκπαιδεύσεις και δοκιμών ..... 122
Εικόνα 3. Dashboard του Deep-in-Biopsies backend ..... 123
Εικόνα 4. Παράδειγμα 1, UI από το Annotation Builder του Deep-In-Biopsies έργου .... 131
Εικόνα 5. Παράδειγμα 2, UI από το Annotation Builder του Deep-In-Biopsies έργου .... 132
Εικόνα 6. Δομή έργου AI Module ..... 147
Εικόνα 7. GPU στατιστικά από εκπαιδευση των Νευρωνικών δικτυών ..... 150

# *Λίστα Πηγαίου Κώδικα*

Πηγαίος Κώδικας 1. JSON Object από το configuration training 98
Πηγαίος Κώδικας 2. Weight class functions 98
Πηγαίος Κώδικας 3. Κλάση `QueueTrainingContainer` για την διαχείριση ουρών σχετικά με την σειρά των μοντέλων εκπαίδευσης. 117
Πηγαίος Κώδικας 4. `AnnotationsFromImageCollectionHelper` κλάση του backend για το Deep-in-Biopsies 125
Πηγαίος Κώδικας 5. Από το `Master` κλάση του annotation Builder του Deep-in-Biopsies έργου. 130
Πηγαίος Κώδικας 6. `MultiPolygon` κλάση για την σχεδίαση πολυγώνου στο καμβά του Annotation Builder 136
Πηγαίος Κώδικας 7. `ClassificationTabUI` κλαση του Annotation Builder 137
Πηγαίος Κώδικας 8. `TabHandlerUI` κλαση του AnnotationBuilder 139
Πηγαίος Κώδικας 9. `JobsToDo` κλαση του Annotation Builder. 140
Πηγαίος Κώδικας 10. `CollectDataShapes` κλαση του Annotation Builder 141
Πηγαίος Κώδικας 11. Κλάση `Helper` του Annotation Builder 146
Πηγαίος Κώδικας 12. `CNNSelector` κλαση, AI Application 149
Πηγαίος Κώδικας 13. `Augmentation` κλάση, AI Application 151
Πηγαίος Κώδικας 14. Μέθοδος `load_hyperconfiguration` της κλάσης Configuration, AI Application 152
Πηγαίος Κώδικας 15. EvaluationHook κλαση, AI Application 153
Πηγαίος Κώδικας 16. `CollectMetricsAnnotations` κλαση για την συλλογη confusion matrix, AI Application 159
Πηγαίος Κώδικας 17. Μητρική κλάση `UrlConnection`, AI Application 161
Πηγαίος Κώδικας 18. `KeepConnectionAlive` κλάση, AI Application 164
Πηγαίος Κώδικας 19. Database Seeder για τα δικαιώματα χρηστών της πλατφόρμας Deep-in-Biopsies 169
Πηγαίος Κώδικας 20. Παράδειγμα Middleware για την εγγραφή των διάδρομων του Deep-in-Biopsies. 169
Πηγαίος Κώδικας 21. `GetFullDataset` κλάση για δοκιμή των API του Deep-in-Biopsies. 173

# Κεφάλαιο 1

## *Εισαγωγή: Ψηφιακή Παθολογία και σύγχρονες προκλήσεις*

## 1.1. Προκλήσεις στη Σύγχρονη Ψηφιακή Παθολογία

Η ψηφιακή παθολογία έχει εξελιχθεί ραγδαία την τελευταία δεκαετία, αποτελώντας μια επαναστατική προσέγγιση στην αναβάθμιση της παραδοσιακής παθολογικής διάγνωσης. Μέσω της ψηφιοποίησης των ιστολογικών παρασκευασμάτων σε μορφή Εικόνες Ολόκληρης Πλάκας (Whole Slide Image, WSI), η ανάλυση των ιστών πραγματοποιείται πλέον μέσω εξειδικευμένων λογισμικών σε υψηλή ανάλυση, υποκαθιστώντας την παραδοσιακή οπτική μέσω μικροσκοπίου [1]. Η διαδικασία αυτή επιτρέπει αποθήκευση, ανάκτηση, κοινή χρήση και επεξεργασία των βιοψιών, ενώ παράλληλα επιτρέπει τη μακροχρόνια διατήρηση και την επαναξιολόγησή τους.

Ωστόσο, η μετάβαση σε ένα πλήρως ψηφιακό παθολογικό εργαστήριο δεν είναι απλή υπόθεση. Απαιτεί σημαντική επένδυση σε υποδομές, τόσο σε επίπεδο εξοπλισμού όσο και σε επίπεδο υπολογιστικής ισχύος. Η αποθήκευση WSI εικόνων ενδέχεται να απαιτεί δεκάδες TB (Tera Bytes) χώρου, καθώς κάθε εικόνα ξεπερνά συχνά τα 2 GB, ενώ η απόδοσή τους σε πραγματικό χρόνο απαιτεί ισχυρή υπολογιστική υποδομή με κάρτες γραφικών (Graphics Processing Unit, GPU) επιτάχυνση και δίκτυα υψηλών ταχυτήτων (high-throughput) [2].

Επιπλέον, η υιοθέτηση της ψηφιακής παθολογίας συναντά εμπόδια στη διαλειτουργικότητα μεταξύ διαφορετικών συστημάτων, όπως σαρωτές (scanners), λογισμικά παρουσίασης (viewers) και εργαλεία επισημείωσης, με αποτέλεσμα την ανάγκη για κοινά πρότυπα όπως οι επεκτάσεις DICOM για εικόνες πλήρους τομή [3]. Η έλλειψη καθολικής υιοθέτησης αυτών των προτύπων οδηγεί σε αποσπασματική ανάπτυξη εργαλείων και περιορίζει την ενοποίηση σε πολυκεντρικά κλινικά περιβάλλοντα.

Σημαντική πρόκληση αποτελεί επίσης η μετατόπιση της ευθύνης του παθολόγου από τον παρατηρητή σε χρήστη ψηφιακών εργαλείων. Παρότι αυτή η αλλαγή έχει τη δυνατότητα να αυξήσει την ακρίβεια και την ταχύτητα διάγνωσης, εγείρει ερωτήματα σχετικά με την εκπαίδευση, την αποδοχή και την προσαρμογή των παθολόγων σε νέες διεπαφές (interfaces) και ροές εργασίας (workflows) [4]. Οι παθολόγοι συχνά εμφανίζουν δισταγμό ως προς την υιοθέτηση τεχνολογιών που τροποποιούν δραστικά τη ροή εργασίας τους ή απαιτούν εκτενή κατάρτιση.

Εκτός από τεχνικές δυσκολίες, η εφαρμογή της ψηφιακής παθολογίας εισάγει νέες επιστημονικές και διαγνωστικές απαιτήσεις. Η αυξανόμενη ανάγκη για ποσοτικοποίηση ευρημάτων, όπως η έκταση ίνωσης στο ήπαρ ή ο βαθμός φλεγμονής στο έντερο, δεν μπορεί να καλυφθεί επαρκώς από το ανθρώπινο μάτι. Η επεξεργασία και ποσοτική εξαγωγή τέτοιων δεδομένων απαιτεί την εισαγωγή αλγορίθμων υποβοηθούμενης διάγνωσης, βασισμένων σε τεχνητή νοημοσύνη (ΤΝ), κάτι που φέρνει στο προσκήνιο νέες απαιτήσεις ως προς την επαλήθευση, την αξιοπιστία και την κανονιστική συμμόρφωση των μοντέλων αυτών [5].

Η επιρροή της ΤΝ στην παθολογία έχει πλέον εδραιωθεί, όμως το ζήτημα της επαναληψιμότητας και της γενίκευσης των αλγορίθμων παραμένει ένα ανοιχτό ερευνητικό ζήτημα. Πολλά μοντέλα παρουσιάζουν καλή απόδοση σε εσωτερικά

δεδομένα (internal datasets), όμως αποτυγχάνουν όταν δοκιμάζονται σε εξωτερικά, προερχόμενα από διαφορετικούς σαρωτές ή ιδρύματα. Αυτό οφείλεται εν μέρει στη μεγάλη ποικιλομορφία των ιστοπαθολογικών εικόνων (χρωματική παραλλαγή, μορφολογία ιστών, τεχνουργήματα), αλλά και στη διαφορετική κλινική πρακτική κάθε νοσοκομείου [6]. Για την αντιμετώπιση αυτών των ζητημάτων, απαιτούνται τεχνικές κανονικοποίησης (normalization), ενίσχυσης δεδομένων (augmentation) και στιβαρή εκπαίδευση (robust training), οι οποίες όμως δεν είναι ακόμη πλήρως τυποποιημένες ή ενσωματωμένες στις περισσότερες εμπορικές λύσεις.

Τέλος, μια από τις σημαντικότερες προκλήσεις της σύγχρονης ψηφιακής παθολογίας είναι η διαχείριση και η σημασιολογική αξιοποίηση των επισημειώσεων. Τα εργαλεία επισημειώσεων οφείλουν να είναι εργονομικά, διαδραστικά και να υποστηρίζουν πολλαπλούς τύπους σημειώσεων (π.χ. πολύγωνο , έλλειψη, ελεύθερος σχεδιασμός). Η επιτυχής ενσωμάτωση τέτοιων εργαλείων αποτελεί προϋπόθεση για την ανάπτυξη και αξιολόγηση μηχανικής μάθησης (deep learning) μοντέλων, καθώς η ποιότητα των επισημειώσεων καθορίζει σε μεγάλο βαθμό την απόδοση των τελικών αλγορίθμων [7].

Εν κατακλείδι, η ψηφιακή παθολογία αποτελεί θεμέλιο για τη μελλοντική υποβοηθούμενη ιατρική διάγνωση. Οι προκλήσεις που αναδύονται δεν είναι απλώς τεχνικές ή υπολογιστικές, αλλά σχετίζονται με την εκπαίδευση των χρηστών, τη διαλειτουργικότητα, τη διασφάλιση της ακρίβειας και την υιοθέτηση από την κλινική κοινότητα. Μια ολοκληρωμένη λύση - όπως αυτή που επιχειρείται μέσω της Deep-in-Biopsies - πρέπει να ενσωματώνει όλα τα παραπάνω στοιχεία, ώστε να ξεπεράσει τα εμπόδια και να προσφέρει πραγματική προστιθέμενη αξία στην καθημερινή παθολογική πρακτική.

## 1.2. Κλινικά Προβλήματα στην Ιστοπαθολογική Ανάλυση

Η ιστοπαθολογική ανάλυση παραμένει η χρυσή σταθερά για την επιβεβαίωση της διάγνωσης σε πλήθος παθήσεων, από κακοήθεις όγκους έως χρόνιες φλεγμονώδεις καταστάσεις. Ωστόσο, ακόμη και με την είσοδο της ψηφιοποίησης, η διαδικασία της ερμηνείας των ιστολογικών εικόνων εξακολουθεί να αντιμετωπίζει κλινικές προκλήσεις που επηρεάζουν τη διαγνωστική ακρίβεια, την επαναληψιμότητα και την προγνωστική αξία των ευρημάτων [8].

Ένα από τα βασικά προβλήματα είναι η υποκειμενικότητα της ερμηνείας. Η αξιολόγηση χαρακτηριστικών όπως η κυτταρική ατυπία, η πυρηνική μορφολογία, η μίτωση, η φλεγμονώδης διήθηση και η έκταση ινώδους ιστού συχνά εξαρτάται από την εμπειρία και το προσωπικό στυλ του παθολόγου. Οι αποκλίσεις μεταξύ διαφορετικών παθολόγων, γνωστές ως διαπαρατηρητική μεταβλητότητα (inter-observer variability), αλλά και εντός του ίδιου παθολόγου, γνωστές ως ενδοπαρατηρητική μεταβλητότητα (intra-observer variability), μπορεί να προκαλέσουν ασυνεπείς διαγνώσεις, επηρεάζοντας τις αποφάσεις για τη θεραπεία [9].

Ειδικά στις φλεγμονώδεις νόσους του εντέρου (Inflammatory Bowel Disease - IBD), όπως η ελκώδης κολίτιδα και η νόσος Crohn, η ποσοτική και ποιοτική αξιολόγηση της φλεγμονής, της παρουσίας κολλαγόνου και της αρχιτεκτονικής των εντερικών στοιβάδων αποτελεί σύνθετη εργασία. Η απουσία αυστηρών, αντικειμενικών κριτηρίων αυξάνει την ανάγκη για μεθόδους που να επιτρέπουν ποσοτικοποίηση των ιστολογικών δεικτών[10].

Στον τομέα της ηπατολογίας, η πρόγνωση ασθενών με λιπώδη διήθηση (NAFLD/NASH) εξαρτάται άμεσα από την ακριβή εκτίμηση παραμέτρων όπως το ποσοστό στεάτωσης, το ballooning των ηπατοκυττάρων και ο βαθμός ίνωσης. Τα συμβατικά score systems, όπως το NAS (NAFLD Activity Score), βασίζονται σε ημιποσοτικές και κατά τόπους υποκειμενικές εκτιμήσεις [11]. Αυτό όχι μόνο περιορίζει την αναπαραγωγιμότητα των μελετών, αλλά επηρεάζει και την καταλληλότητα των ασθενών για κλινικές δοκιμές ή θεραπευτικές παρεμβάσεις.

Ένα άλλο σημαντικό ζήτημα αφορά την αδυναμία ανάλυσης ολόκληρης της επιφάνειας των WSI. Οι παθολόγοι περιορίζονται συχνά σε οπτική εκτίμηση επιλεγμένων περιοχών, κάτι που μπορεί να οδηγήσει σε μεροληψία δειγματοληψίας. Η πληθυσμιακή ετερογένεια εντός μιας βιοψίας - π.χ. ανομοιογένεια στην ίνωση ή στην φλεγμονώδη απάντηση— ενδέχεται να μην αποτυπώνεται επαρκώς αν δεν αξιοποιηθεί ένα αυτοματοποιημένο εργαλείο για πλήρη ανάλυση [12].

Ακόμα, η έλλειψη ενοποιημένων guidelines για συγκεκριμένες παθολογικές οντότητες, όπως τα πρότυπα βαθμολόγησης για την πυρηνική άτυπη ή την αναγνώριση Mallory-Denk σωμάτων στο ήπαρ, οδηγεί σε υψηλό ποσοστό αποτυχίας στην ομογενοποίηση δεδομένων ανάμεσα σε διαφορετικά κέντρα. Η ενσωμάτωση εργαλείων deep learning θα μπορούσε να προσφέρει πρότυπα που να εκπαιδεύονται σε διεθνώς χαρακτηρισμένα δεδομένα, παρέχοντας ενιαία κριτήρια [13].

Ένα ιδιαίτερα κρίσιμο πρόβλημα είναι η συσχέτιση των ιστολογικών ευρημάτων με κλινικά αποτελέσματα. Η ανάγκη για προγνωστικούς δείκτες που προκύπτουν από την ανάλυση εικόνας (image-based biomarkers) παραμένει ακάλυπτη. Η ανάπτυξη τέτοιων δεικτών απαιτεί μεγάλο όγκο δεδομένων, αναλυτική ακρίβεια και εργαλεία για πολυπαραγοντική συσχέτιση με κλινικά endpoints. Παράδειγμα αποτελεί η χρήση του Collagen Proportionate Area (CPA) ως δείκτη πρόγνωσης σε IBD ασθενείς με νόσο Crohn, που παρουσιάζει ισχυρή συσχέτιση με την ανάγκη για χειρουργική παρέμβαση [14].

Τέλος, η χρήση deep learning και CNNs αναδεικνύει νέες δυνατότητες, αλλά φέρνει μαζί της και **νέες** κλινικές προκλήσεις:

- Την ανάγκη για αξιόπιστα και πιστοποιημένα annotations από ειδικούς,
- Τη σύνδεση της μοντελοποίησης με πραγματικά outcomes (π.χ. ανταπόκριση σε φάρμακα),
- Τη διατήρηση της ερμηνευσιμότητας (interpretability) των αποτελεσμάτων ώστε να ενσωματωθούν στην κλινική ροή[15].

Οι υπάρχουσες κλινικές ανάγκες και οι περιορισμοί των παραδοσιακών μεθόδων δείχνουν την κατεύθυνση για την οποία εργαλεία όπως το Deep-in-Biopsies είναι απαραίτητα: πλήρως παραμετροποιήσιμα, επαναλήψιμα, επεκτάσιμα και ενσωματώσιμα στην υπάρχουσα ιατρική υποδομή.

## 1.3. Ερευνητικοί Στόχοι και Ερωτήματα

Η μετάβαση της ιστοπαθολογίας από το αναλογικό μικροσκόπιο σε ψηφιακά εργαλεία και υπολογιστικά υποστηριζόμενα διαγνωστικά συστήματα δεν είναι μόνο τεχνική εξέλιξη, αλλά και επιστημονική πρόκληση. Η ανάγκη για ακρίβεια, επαναληψιμότητα και αυτοματοποίηση στην ανάλυση των ιστολογικών εικόνων έχει δημιουργήσει ένα νέο επιστημονικό πεδίο, όπου η μηχανική όραση και η τεχνητή νοημοσύνη καλούνται να απαντήσουν σε πραγματικές κλινικές ανάγκες. Μέσα σε αυτό το πλαίσιο, η παρούσα διατριβή θέτει ένα σύνολο από σαφώς διατυπωμένους ερευνητικούς στόχους και ερωτήματα.

Ο πρώτος στόχος αφορά την ανάπτυξη μεθόδων μηχανικής όρασης που να μπορούν να αναλύσουν ιστοπαθολογικά δεδομένα διαφορετικών τύπων και προελεύσεων. Τα συστήματα πρέπει να είναι σε θέση να χειρίζονται ετερογενή δεδομένα, με διαφορετικά είδη χρώσης, επίπεδα μεγέθυνσης, μορφολογικά χαρακτηριστικά και ποικίλες παθολογικές αλλοιώσεις. Πέρα από την κατηγοριοποίηση εικόνων ή την απλή αναγνώριση δομών, η απαίτηση πλέον είναι για ακριβή εντοπισμό (segmentation) και συσχέτιση με βιολογικά ή κλινικά γνωρίσματα. Το ερώτημα που προκύπτει είναι το εξής: πώς μπορούν τα συνελικτικά νευρωνικά δίκτυα (CNNs) να προσαρμοστούν σε τέτοια δεδομένα ώστε να επιτύχουν γενίκευση, χωρίς υπερπροσαρμογή σε συγκεκριμένο dataset;

Ο δεύτερος στόχος σχετίζεται με την ίδια τη διαδικασία του annotation. Η επισημείωση των δεδομένων αποτελεί κρίσιμο βήμα για την εκπαίδευση των μοντέλων, αλλά είναι μια χρονοβόρα, δαπανηρή και γνωσιακά φορτισμένη διαδικασία. Η παρούσα εργασία εξετάζει πώς μπορούν να σχεδιαστούν εργαλεία που θα διευκολύνουν την παραγωγή υψηλής ποιότητας annotations, μειώνοντας ταυτόχρονα τον χρόνο και το κόστος. Πώς μπορούμε να επιτύχουμε εργονομία, ακρίβεια και ταχύτητα στη διαδικασία της επισημείωσης, αξιοποιώντας ταυτόχρονα διαδράσεις (feedbacks) από το ίδιο το σύστημα; Ποιος είναι ο βέλτιστος τρόπος ελέγχου και αξιολόγησης της ποιότητας των annotations;

Ο τρίτος στόχος αφορά την ενοποίηση όλων των παραμέτρων εκπαίδευσης, επεξεργασίας και αξιολόγησης των μοντέλων μέσα σε ένα ολοκληρωμένο και δυναμικό περιβάλλον. Η πλατφόρμα Deep-in-Biopsies επιχειρεί να προσφέρει αυτή τη δυνατότητα, δίνοντας στον χρήστη τον έλεγχο των hyperparameters, της επιλογής αρχιτεκτονικής, της διαχείρισης βαρών και της παρακολούθησης της εκπαίδευσης σε πραγματικό χρόνο. Το σχετικό ερώτημα είναι: ποια παραμετροποίηση έχει μεγαλύτερη επίδραση στην τελική απόδοση του μοντέλου και πώς μπορεί να αυτοματοποιηθεί ή να προσαρμόζεται δυναμικά κατά την εκπαίδευση;

Ο τέταρτος στόχος είναι η δημιουργία μοντέλων που δεν λειτουργούν ως «μαύρα κουτιά», αλλά παρέχουν επεξηγήσεις και οπτικά στοιχεία που βοηθούν τον παθολόγο να κατανοήσει τη λειτουργία τους. Η ανάγκη για ερμηνευσιμότητα (interpretability) σε ιατρικές εφαρμογές είναι επιτακτική και πολλές φορές κρίνεται ως απαραίτητη προϋπόθεση για την αποδοχή ενός συστήματος από την ιατρική κοινότητα. Το ερώτημα είναι: πώς μπορούμε να σχεδιάσουμε CNN μοντέλα με δομή και έξοδο τέτοια ώστε να επιτρέπουν την κατανόηση και την ερμηνεία των αποφάσεών τους;

Τέλος, η διατριβή στοχεύει στην αξιολόγηση της πλατφόρμας σε πραγματικά κλινικά δεδομένα και σε διαφορετικές εφαρμογές, όπως η λιπώδης νόσος του ήπατος, οι φλεγμονώδεις νόσοι του εντέρου και οι pan-cancer αναλύσεις. Η κλινική εγκυρότητα είναι ο τελικός δείκτης επιτυχίας και το ερώτημα είναι: σε ποιο βαθμό μπορεί ένα σύστημα μηχανικής όρασης να επηρεάσει θετικά την καθημερινή παθολογική πρακτική και να λειτουργήσει ως εργαλείο υποβοήθησης στη διάγνωση και την πρόγνωση;

Η παρούσα διατριβή προσεγγίζει τα παραπάνω ερωτήματα μέσω ενός πλήρως ενσωματωμένου συστήματος που υλοποιείται και εφαρμόζεται σε κλινικά πλαίσια, με σκοπό να αποδείξει τη χρησιμότητα, τη γενικευσιμότητα και τη δυνατότητα προσαρμογής της τεχνητής νοημοσύνης στην ιστοπαθολογία.

## 1.4. Επιστημονική Συνεισφορά της Διατριβής

Η ραγδαία πρόοδος της τεχνητής νοημοσύνης και της μηχανικής όρασης έχει ήδη οδηγήσει σε σημαντικές εξελίξεις στον τομέα της ιατρικής απεικόνισης. Ωστόσο, στον ειδικό τομέα της ιστοπαθολογίας, παραμένουν ανοιχτά κρίσιμα ζητήματα που σχετίζονται με την αξιοπιστία, τη γενίκευση και την ενσωμάτωση των αλγορίθμων σε πραγματικές κλινικές ροές[16]. Η παρούσα διατριβή επιχειρεί να γεφυρώσει αυτό το χάσμα προτείνοντας μια πλήρως λειτουργική και παραμετροποιήσιμη πλατφόρμα ανάλυσης ιστοπαθολογικών εικόνων, την Deep-in-Biopsies, η οποία συνδυάζει τεχνική αρτιότητα με κλινική χρησιμότητα.

Η πρώτη επιστημονική συνεισφορά της διατριβής είναι η ανάπτυξη ενός συστήματος που ενοποιεί όλες τις φάσεις της ψηφιακής ιστοπαθολογίας: από την αποθήκευση και επισήμανση των δεδομένων έως την εκπαίδευση και την αξιολόγηση μοντέλων βαθιάς μάθησης. Η ενσωμάτωση εργαλείων επισημειώσεων, εκπαιδευτικών αγωγών (pipeline) και διεπαφών αξιολόγησης σε μία κοινή πλατφόρμα μειώνει τον κατακερματισμό και ενισχύει την αποδοτικότητα στην έρευνα και την κλινική εφαρμογή.

Η δεύτερη συνεισφορά αφορά την ευελιξία και προσαρμοστικότητα της πλατφόρμας σε διαφορετικά κλινικά σενάρια. Το Deep-in-Biopsies επιτρέπει τη διαχείριση πολλαπλών registry δεδομένων, την εκπαίδευση ανεξάρτητων μοντέλων για κάθε περίπτωση και τη χρήση αρχιτεκτονικών CNN όπως Mask R-CNN, Cascade R-CNN και Keypoint R-CNN, με δυνατότητα παραμετροποίησης μέσω διεπαφών στο backend.

. Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για κλινικές μελέτες που απαιτούν ειδική αντιμετώπιση διαφορετικών τύπων ιστών ή παθολογιών.

Η τρίτη συνεισφορά σχετίζεται με τη δημιουργία μιας ροής εργασίας φιλικής προς τον χρήστη, με εργονομικό περιβάλλον σημειοθέτησης και με δυνατότητα πραγματικού χρόνου επικοινωνίας μεταξύ frontend και AI συστήματος. Αυτό καθιστά την πλατφόρμα προσβάσιμη και σε μη εξειδικευμένους χρήστες, επιτρέποντας σε παθολόγους να αλληλεπιδρούν άμεσα με τα εργαλεία και τα αποτελέσματα, χωρίς να απαιτείται βαθιά γνώση των υποκείμενων τεχνολογιών.

Η τέταρτη συνεισφορά εντοπίζεται στην κλινική εφαρμογή και αξιολόγηση της πλατφόρμας. Μέσω συγκεκριμένων μελετών περιπτώσεων – όπως η ανάλυση λιπώδους νόσου του ήπατος, η ποσοτικοποίηση κολλαγόνου σε φλεγμονώδη νοσήματα και η πολυοργανική ανάλυση μέσω PanNuke δεδομενων – η πλατφόρμα αξιολογείται σε συνθήκες που αντανακλούν την πραγματική κλινική χρήση. Τα αποτελέσματα δείχνουν τη δυνατότητα της πλατφόρμας να προσφέρει αξιόπιστες, επαναλήψιμες και γενικεύσιμες αναλύσεις, ενισχύοντας την εμπιστοσύνη της ιατρικής κοινότητας.

Τέλος, η διατριβή εισφέρει στην ακαδημαϊκή συζήτηση για την ανάγκη επεξηγήσιμων και διαφανών AI συστημάτων στην ιατρική. Η ενσωμάτωση εργαλείων που επιτρέπουν την οπτικοποίηση των αποτελεσμάτων και τη συσχέτισή τους με τις εισόδους του μοντέλου ενισχύει την ερμηνευσιμότητα και διευκολύνει την κλινική αποδοχή. Το σύστημα δεν προτείνεται ως υποκατάστατο του παθολόγου, αλλά ως εργαλείο ενίσχυσης και υποβοήθησης της διάγνωσης.

## 1.5. Δομή Διατριβής

Η παρούσα διδακτορική διατριβή οργανώνεται σε εννέα κεφάλαια, τα οποία καλύπτουν μεθοδικά τόσο τις τεχνικές πτυχές της υλοποίησης όσο και την κλινική σημασία των αποτελεσμάτων. Η δομή σχεδιάστηκε ώστε να αναδεικνύει την επιστημονική και τεχνολογική συμβολή της πλατφόρμας Deep-in-Biopsies, από το θεωρητικό υπόβαθρο μέχρι την πρακτική της εφαρμογή και τη συνολική αξιολόγησή της.

**Κεφάλαιο 1: Εισαγωγή.** Παρουσιάζεται το γενικό πλαίσιο και το κλινικό κίνητρο που οδήγησε στην ανάπτυξη της πλατφόρμας. Γίνεται ανάλυση των προκλήσεων στην ψηφιακή παθολογία, καταγράφονται τα βασικά προβλήματα της ιστοπαθολογικής ανάλυσης και διατυπώνονται σαφώς οι ερευνητικοί στόχοι και η επιστημονική συνεισφορά του έργου.

**Κεφάλαιο 2: Θεωρητικό Υπόβαθρο και Συναφή Έργα.** Παρέχει το θεωρητικό υπόβαθρο της εργασίας. Περιλαμβάνει επισκόπηση της ψηφιακής παθολογίας, αρχιτεκτονικές συνελικτικών νευρωνικών δικτύων, τεχνικές τμηματοποίησης στιγμιότυπων όπως το Mask R-CNN, και μια συστηματική ανασκόπηση των υπαρχουσών λύσεων και εργαλείων στο πεδίο.

**Κεφάλαιο 3: Αρχιτεκτονική Συστήματος και Σχεδιασμός.** Επικεντρώνεται στη συνολική αρχιτεκτονική της πλατφόρμας Deep-in-Biopsies. Αναλύεται ο τμηματικός σχεδιασμός, τα υποσυστήματα υποστήριξης, σημειοθέτησης και επεξεργασίας τεχνητής νοημοσύνης, καθώς και η επικοινωνία μεταξύ τους μέσω Socket.IO.

**Κεφάλαιο 4: Ανάπτυξη και Εκπαίδευση Νευρωνικών Δικτύων.**Περιγράφεται λεπτομερώς η ανάπτυξη των συνελικτικών νευρωνικών δικτύων και η μεθοδολογία εκπαίδευσής τους. Εξετάζονται επιλογές βασικής αρχιτεκτονικής, στρατηγικές μεταφοράς μάθησης, τεχνικές επαύξησης δεδομένων και βελτιστοποίηση υπερπαραμέτρων, καθώς και η υποστήριξη εκπαίδευσης σε πολλαπλές μονάδες επεξεργασίας γραφικών.

**Κεφάλαιο 5: Υλοποίηση και Ενσωμάτωση.** Αφορά την πρακτική υλοποίηση και την ενσωμάτωση της πλατφόρμας. Παρουσιάζεται η διαχείριση βαρών ανά μητρώο δεδομένων, η λειτουργική διασύνδεση μεταξύ υποστηρικτικού συστήματος και τεχνητής νοημοσύνης, η σχεδίαση της ροής εργασίας σημειοθέτησης και η συνολική απόδοση του συστήματος.

**Κεφάλαιο 6: Κλινικές Εφαρμογές και Μελέτες Περιπτώσεων.** Αναλύονται συγκεκριμένες κλινικές εφαρμογές της πλατφόρμας, όπως η ανάλυση λιπώδους νόσου του ήπατος, η ποσοτικοποίηση κολλαγόνου σε φλεγμονώδη εντερικά νοσήματα και η πολυοργανική ταξινόμηση καρκίνου μέσω του PanNuke dataset.

**Κεφάλαιο 7: Αποτελέσματα και Κλινική Αποτελεσματικότητα.** Περιλαμβάνει συγκεντρωτικά αποτελέσματα σχετικά με την απόδοση των αλγορίθμων, την ακρίβεια της πλατφόρμας σε κλινικά δεδομένα, την υπολογιστική αποδοτικότητα και την αποδοχή από τους τελικούς χρήστες. Παρουσιάζονται συγκριτικές αναλύσεις διαφορετικών αρχιτεκτονικών και αξιολογείται η γενικευσιμότητα του συστήματος.

**Κεφάλαιο 8: Συζήτηση και Αξιολόγηση.** Γίνεται συζήτηση επί των τεχνικών και κλινικών ευρημάτων, εντοπίζονται οι περιορισμοί του συστήματος και προτείνονται μελλοντικές κατευθύνσεις για τη βελτίωση και τη διεύρυνση της χρήσης της πλατφόρμας. Συζητούνται οι κανονιστικές πτυχές, οι ηθικές προκλήσεις και οι επιπτώσεις για την κλινική πρακτική.

**Κεφάλαιο 9: Συμπεράσματα και Συνεισφορές.** Συνοψίζει τις βασικές επιστημονικές συνεισφορές της διατριβής και αναδεικνύει τις δυνατότητες αξιοποίησης του συστήματος σε πραγματικά περιβάλλοντα παθολογικής ανάλυσης. Παρουσιάζονται οι τεχνικές καινοτομίες, η κλινική αξία, οι περιορισμοί της μελέτης και οι μελλοντικές κατευθύνσεις έρευνας.

Η δομή αυτή εξασφαλίζει την πλήρη και τεκμηριωμένη παρουσίαση του έργου και των καινοτομιών του, συνδέοντας τη θεωρία με την πράξη και το τεχνολογικό υπόβαθρο με την κλινική εφαρμογή, ενώ ταυτόχρονα παρέχει μια λογική πορεία από την αρχική κινητοποίηση μέχρι τα τελικά συμπεράσματα και τις προοπτικές μελλοντικής ανάπτυξης.

# Κεφάλαιο 2

## *Ιατρικό Υπόβαθρο, Επιστημονική και Τεχνολογική Στάθμιση*

## 2.1. Ψηφιακή Παθολογία: Θεμελιώδεις Αρχές και Κλινικές Ροές Εργασίας

### 2.1.1. Εισαγωγή στην Ψηφιακή Παθολογία

Η ψηφιακή παθολογία αντιπροσωπεύει μια ριζική μεταμόρφωση στον τρόπο που διεξάγεται η παθολογική διάγνωση, αντικαθιστώντας τη χρήση του παραδοσιακού μικροσκοπίου με εξειδικευμένα υπολογιστικά εργαλεία ανάλυσης ψηφιακών εικόνων. Αυτή η εξέλιξη δεν αποτελεί απλώς τεχνολογική αναβάθμιση, αλλά θεμελιώδη αλλαγή στη φιλοσοφία και στη μεθοδολογία της διαγνωστικής παθολογίας. Η διαδικασία ψηφιοποίησης μετατρέπει τα φυσικά ιστολογικά παρασκευάσματα σε ψηφιακές εικόνες ολόκληρων τομών, γνωστές ως ψηφιακές εικόνες ολόκληρης τομής, επιτρέποντας την αποθήκευση, επεξεργασία και ανάλυση τους μέσω προηγμένων λογισμικών συστημάτων.

### 2.1.2. Θεμελιώδεις Αρχές και Τεχνολογικό Υπόβαθρο

Οι θεμελιώδεις αρχές της ψηφιακής παθολογίας βασίζονται στην ικανότητα αναπαραγωγής και βελτίωσης της παραδοσιακής μικροσκοπικής εμπειρίας μέσω ψηφιακών μέσων. Η εικόνα που προκύπτει από τη σάρωση ενός ιστολογικού παρασκευάσματος διατηρεί όλες τις μορφολογικές πληροφορίες του πρωτότυπου, αλλά παράλληλα προσφέρει νέες δυνατότητες που δεν είναι εφικτές με το παραδοσιακό μικροσκόπιο [17]. Αυτές περιλαμβάνουν την άμεση μεταβολή της μεγέθυνσης σε οποιοδήποτε επίπεδο, την εφαρμογή φίλτρων και βελτιώσεων της εικόνας, τη δυνατότητα σύγκρισης πολλαπλών περιοχών ταυτόχρονα και την εκτέλεση αυτοματοποιημένων μετρήσεων και αναλύσεων.

Το τεχνολογικό υπόβαθρο της ψηφιακής παθολογίας στηρίζεται σε εξειδικευμένους σαρωτές υψηλής ανάλυσης που δημιουργούν ψηφιακές εικόνες με εξαιρετική λεπτομέρεια. Οι σύγχρονοι σαρωτές μπορούν να επιτύχουν ανάλυση μέχρι και 0,25 μικρομέτρων ανά εικονοστοιχείο, αντιστοιχώντας στην ποιότητα εικόνας μεγέθυνσης 40× ενός παραδοσιακού μικροσκοπίου. Αυτή η ανάλυση επαρκεί για την αναγνώριση των περισσότερων μορφολογικών χαρακτηριστικών που απαιτούνται για διαγνωστικούς σκοπούς, ενώ παράλληλα διατηρεί το μέγεθος των αρχείων σε διαχειρίσιμα επίπεδα.

### 2.1.3. Κλινικές Ροές Εργασίας και Διαγνωστική Διαδικασία

Οι κλινικές ροές εργασίας στην ψηφιακή παθολογία ακολουθούν μια δομημένη αλληλουχία διεργασιών που ξεκινά από την παραλαβή του βιολογικού δείγματος και καταλήγει στην έκδοση της διαγνωστικής έκθεσης. Η αρχική φάση περιλαμβάνει την κλασική προετοιμασία του ιστολογικού παρασκευάσματος, η οποία παραμένει αμετάβλητη σε σχέση με την παραδοσιακή πρακτική[18]. Το βιολογικό δείγμα υφίσταται μονιμοποίηση με φορμαλδεΰδη για τη διατήρηση της κυτταρικής και ιστικής δομής,

ακολουθούμενη από διαδικασίες αφυδάτωσης και ενσωμάτωσης σε στερεό μέσο παραφίνης. Στη συνέχεια, το δείγμα κόβεται σε λεπτές τομές πάχους τριών έως πέντε μικρομέτρων και εφαρμόζονται οι κατάλληλες χρώσεις, συνήθως η βασική χρώση αιματοξυλίνη-ηωσίνη ή εξειδικευμένες ανοσοϊστοχημικές χρώσεις ανάλογα με τη διαγνωστική ανάγκη.

Η κρίσιμη διαφοροποίηση εμφανίζεται στην επόμενη φάση, όπου το παρασκεύασμα αντί να τοποθετηθεί στη βάση του μικροσκοπίου, μεταφέρεται σε εξειδικευμένο σαρωτή ιστολογικών παρασκευασμάτων. Αυτοί οι σαρωτές χρησιμοποιούν προηγμένα οπτικά συστήματα και αλγορίθμους επεξεργασίας εικόνας για να δημιουργήσουν μια πλήρη ψηφιακή αναπαράσταση του παρασκευάσματος. Η διαδικασία σάρωσης περιλαμβάνει τη λήψη χιλιάδων μικρότερων εικόνων σε διαφορετικά επίπεδα εστίασης, οι οποίες στη συνέχεια συνδυάζονται με εξειδικευμένο λογισμικό για τη δημιουργία μιας ενιαίας εικόνας υψηλής ανάλυσης που καλύπτει ολόκληρη την επιφάνεια του παρασκευάσματος.

Το αποτέλεσμα αυτής της διαδικασίας είναι η δημιουργία μιας Εικόνας Ολικής Τομής που μπορεί να φτάσει σε μέγεθος αρκετά GB, ανάλογα με τις διαστάσεις του παρασκευάσματος και την επιλεγμένη ανάλυση σάρωσης. Αυτές οι εικόνες αποθηκεύονται σε εξειδικευμένες μορφές αρχείων που επιτρέπουν την αποδοτική προσπέλαση και προβολή διαφορετικών περιοχών και επιπέδων μεγέθυνσης χωρίς την ανάγκη φόρτωσης ολόκληρου του αρχείου στη μνήμη του υπολογιστή.

Η φάση της διαγνωστικής ανάλυσης διεξάγεται μέσω εξειδικευμένων προγραμμάτων προβολής που επιτρέπουν στον παθολόγο να πλοηγηθεί μέσα στην ψηφιακή εικόνα με τρόπο παρόμοιο με αυτόν που θα χρησιμοποιούσε σε ένα παραδοσιακό μικροσκόπιο. Αυτά τα προγράμματα προσφέρουν λειτουργίες όπως η ομαλή μεταβολή της μεγέθυνσης, η πλοήγηση σε διαφορετικές περιοχές της τομής, η δυνατότητα σημειώσεων και μετρήσεων επί της εικόνας, καθώς και εργαλεία βελτίωσης της εικόνας όπως η ρύθμιση της φωτεινότητας, της αντίθεσης και του κορεσμού των χρωμάτων.

Ένα από τα σημαντικότερα πλεονεκτήματα της ψηφιακής παθολογίας είναι η δυνατότητα συνεργατικής διάγνωσης και τηλεσυμβουλευτικής. Πολλαπλοί παθολόγοι μπορούν να εξετάσουν την ίδια περίπτωση ταυτόχρονα, ανεξάρτητα από τη γεωγραφική τους θέση, και να ανταλλάξουν απόψεις σε πραγματικό χρόνο. Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για σπάνιες ή πολύπλοκες περιπτώσεις όπου η εξειδικευμένη γνώμη μπορεί να μην είναι τοπικά διαθέσιμη. Επιπρόσθετα, η ψηφιακή μορφή των παρασκευασμάτων διευκολύνει τη δημιουργία αρχείων αναφοράς για εκπαιδευτικούς σκοπούς και την ανάπτυξη πρωτοκόλλων ποιοτικού ελέγχου.

Η ενσωμάτωση αλγορίθμων τεχνητής νοημοσύνης αποτελεί έναν από τους πιο πολλά υποσχόμενους τομείς εξέλιξης της ψηφιακής παθολογίας. Οι αλγόριθμοι αυτοί μπορούν να εφαρμοστούν για την αυτόματη ανίχνευση και ποσοτικοποίηση συγκεκριμένων κυτταρικών ή ιστικών στοιχείων, τη μέτρηση παραμέτρων όπως η έκταση νέκρωσης ή ίνωσης, και την παροχή υποστηρικτικών διαγνωστικών προτάσεων. Αυτές οι δυνατότητες όχι μόνο βελτιώνουν την ακρίβεια και την αντικειμενικότητα της διάγνωσης, αλλά και

μειώνουν σημαντικά τον χρόνο που απαιτείται για την ανάλυση πολύπλοκων περιπτώσεων.

### 2.1.4. Τεχνικές Προκλήσεις και Μελλοντικές Προοπτικές

Ωστόσο, η μετάβαση στην ψηφιακή παθολογία συνοδεύεται από σημαντικές τεχνικές και πρακτικές προκλήσεις. Η αρχική επένδυση σε εξοπλισμό και υποδομή είναι σημαντική, καθώς οι εξειδικευμένοι σαρωτές μπορούν να κοστίζουν εκατοντάδες χιλιάδες ευρώ, ενώ παράλληλα απαιτούνται ισχυρά συστήματα αποθήκευσης και δικτύωσης για τη διαχείριση των μεγάλων αρχείων εικόνων[19]. Μια τυπική Εικόνα Ολικής Τομής μπορεί να καταλαμβάνει από ένα έως δέκα GB χώρου, γεγονός που σημαίνει ότι ένα πολυάσχολο παθολογικό εργαστήριο μπορεί να παράγει πολλά TB δεδομένων ημερησίως.

Επιπρόσθετα, υπάρχουν σημαντικά ζητήματα διαλειτουργικότητας μεταξύ των προϊόντων διαφορετικών κατασκευαστών. Η έλλειψη ενιαίων προτύπων για τη μορφή αποθήκευσης των εικόνων και τα πρωτόκολλα επικοινωνίας μεταξύ των συστημάτων δημιουργεί τεχνικά εμπόδια στην υιοθέτηση και τη διαλειτουργικότητα των λύσεων. Παρόλο που έχουν αναπτυχθεί διεθνή πρότυπα όπως οι επεκτάσεις του προτύπου DICOM για εικόνες ολικής τομής, η καθολική υιοθέτησή τους προχωρά αργά λόγω των τεχνικών και εμπορικών συμφερόντων των διαφόρων παρόχων λύσεων.

Η εκπαίδευση του προσωπικού αποτελεί έναν άλλον κρίσιμο παράγοντα επιτυχίας. Οι παθολόγοι που έχουν εργαστεί για δεκαετίες με παραδοσιακά μικροσκόπια χρειάζονται χρόνο και υποστήριξη για να προσαρμοστούν στη νέα τεχνολογία [17]. Η αλλαγή από την απτική εμπειρία του φυσικού μικροσκοπίου στη διαδραστικότητα μέσω υπολογιστικών διεπαφών απαιτεί προσαρμογή όχι μόνο στα τεχνικά εργαλεία, αλλά και στον τρόπο προσέγγισης και ανάλυσης των δεδομένων.

Τέλος, η ψηφιακή παθολογία εισάγει νέες απαιτήσεις ως προς την ασφάλεια των δεδομένων και την προστασία της ιδιωτικής ζωής των ασθενών. Η ψηφιακή μορφή των παθολογικών δεδομένων τα καθιστά ευάλωτα σε κυβερνοεπιθέσεις και παραβιάσεις της ιδιωτικότητας, απαιτώντας την εφαρμογή αυστηρών μέτρων κυβερνοασφάλειας και συμμόρφωσης με τους κανονισμούς προστασίας δεδομένων.

## 2.2. Βαθιά Μάθηση στην Ιατρική Απεικόνιση

### 2.2.1. Ιστορική Εξέλιξη και Θεμελιώδεις Έννοιες

Η βαθιά μάθηση αντιπροσωπεύει ένα επαναστατικό κλάδο της τεχνητής νοημοσύνης που έχει μεταμορφώσει ριζικά τον τρόπο προσέγγισης πολύπλοκων προβλημάτων ανάλυσης δεδομένων, ιδίως στον τομέα της επεξεργασίας εικόνων και της αναγνώρισης προτύπων. Οι ρίζες της βαθιάς μάθησης εντοπίζονται στις πρώτες προσπάθειες μίμησης του τρόπου λειτουργίας του ανθρώπινου εγκεφάλου μέσω τεχνητών νευρωνικών δικτύων, αλλά η

πραγματική της επανάσταση ξεκίνησε με την ανάπτυξη αλγορίθμων ικανών να εκπαιδεύουν πολυστρωματικά δίκτυα με αποτελεσματικό τρόπο.

Η θεμελιώδης αρχή που διακρίνει τη βαθιά μάθηση από τις παραδοσιακές τεχνικές μηχανικής μάθησης είναι η ικανότητα αυτόματης εκμάθησης αναπαραστάσεων από τα πρωτογενή δεδομένα. Αντί να απαιτεί από τους ερευνητές τον χειροκίνητο καθορισμό των χαρακτηριστικών που θεωρούνται σημαντικά για την επίλυση ενός προβλήματος, τα νευρωνικά δίκτυα βαθιάς μάθησης ανακαλύπτουν αυτά τα χαρακτηριστικά αυτόνομα μέσω της διαδικασίας εκπαίδευσης. Αυτή η ικανότητα καθιστά τη βαθιά μάθηση εξαιρετικά κατάλληλη για προβλήματα όπου τα κρίσιμα χαρακτηριστικά είναι είτε άγνωστα είτε υπερβολικά πολύπλοκα για χειροκίνητη περιγραφή.

Στον ευρύτερο ιατρικό τομέα, η βαθιά μάθηση έχει εισέλθει δυναμικά κατά την τελευταία δεκαετία, προσφέροντας λύσεις σε προβλήματα που παραδοσιακά θεωρούνταν εξαιρετικά δύσκολα ή ακόμα και αδύνατα να αυτοματοποιηθούν. Από την ανάλυση ακτινογραφιών και μαγνητικών τομογραφιών έως την ερμηνεία ηλεκτροκαρδιογραφημάτων και τη διάγνωση παθήσεων από δερματοσκοπικές εικόνες, οι εφαρμογές της βαθιάς μάθησης έχουν αποδείξει ότι μπορούν να επιτύχουν επιδόσεις όχι μόνο συγκρίσιμες με αυτές των ανθρώπων ειδικών, αλλά σε ορισμένες περιπτώσεις και ανώτερες.

Αυτή η επιτυχία οφείλεται σε μεγάλο βαθμό στο γεγονός ότι οι ιατρικές εικόνες περιέχουν πλούσια και συχνά κρυμμένα μοτίβα που δεν είναι άμεσα αντιληπτά από το ανθρώπινο μάτι. Τα νευρωνικά δίκτυα μπορούν να εντοπίσουν αυτά τα λεπτά χαρακτηριστικά και να τα αξιοποιήσουν για τη λήψη διαγνωστικών αποφάσεων ή προγνωστικών εκτιμήσεων, προσφέροντας παράλληλα πλεονεκτήματα όπως η ταχύτητα, η συνέπεια και η δυνατότητα επεξεργασίας μεγάλων όγκων δεδομένων που θα ήταν αδύνατη για έναν άνθρωπο να χειριστεί.

### 2.2.2. Συνελικτικά Νευρωνικά Δίκτυα: Αρχιτεκτονική και Λειτουργία

Τα Συνελικτικά Νευρωνικά Δίκτυα συνιστούν μια εξειδικευμένη κατηγορία αρχιτεκτονικών νευρωνικών δικτύων που έχουν σχεδιαστεί ειδικά για την αποτελεσματική επεξεργασία δεδομένων με δομή πλέγματος, όπως είναι οι εικόνες. Η βιολογική τους εμπνευση προέρχεται από μελέτες του οπτικού φλοιού των θηλαστικών, όπου παρατηρήθηκε ότι διαφορετικοί νευρώνες ανταποκρίνονται σε συγκεκριμένα οπτικά χαρακτηριστικά σε περιορισμένες περιοχές του οπτικού πεδίου, δημιουργώντας μια ιεραρχική δομή επεξεργασίας πληροφοριών.

Η αρχιτεκτονική των συνελικτικών δικτύων βασίζεται σε τρεις κύριους τύπους στρωμάτων που συνεργάζονται αρμονικά για την εξαγωγή και επεξεργασία χαρακτηριστικών από τις εικόνες. Τα στρώματα συνέλιξης αποτελούν την καρδιά του συστήματος και λειτουργούν εφαρμόζοντας μικρά φίλτρα που "ολισθαίνουν" πάνω στην εικόνα εισόδου, ανιχνεύοντας τοπικά χαρακτηριστικά όπως ακμές, γωνίες, υφές και άλλα

γεωμετρικά πρότυπα. Κάθε φίλτρο εκπαιδεύεται να αναγνωρίζει ένα συγκεκριμένο τύπο χαρακτηριστικού, και η συλλογική τους δράση δημιουργεί μια πλούσια αναπαράσταση των περιεχομένων της εικόνας.

Τα στρώματα ομαδοποίησης ακολουθούν συνήθως μετά από τα στρώματα συνέλιξης και εκτελούν δύο κρίσιμες λειτουργίες. Πρώτον, μειώνουν την χωρική διάσταση των δεδομένων, κάτι που όχι μόνο μειώνει την υπολογιστική πολυπλοκότητα αλλά και βοηθά στην πρόληψη της υπερπροσαρμογής. Δεύτερον, εισάγουν έναν βαθμό αναλλοίωσης στις μικρές μετατοπίσεις και παραμορφώσεις, καθιστώντας το δίκτυο πιο ανθεκτικό σε μικρές αλλαγές στη θέση ή στην εμφάνιση των αντικειμένων στην εικόνα.

Στο τέλος της αρχιτεκτονικής, τα πλήρως συνδεδεμένα στρώματα αναλαμβάνουν τη σύνθεση όλων των εξαγόμενων χαρακτηριστικών και την παραγωγή της τελικής εξόδου του δικτύου. Αυτά τα στρώματα λειτουργούν παρόμοια με τα παραδοσιακά νευρωνικά δίκτυα, συνδυάζοντας τις πληροφορίες από όλες τις προηγούμενες επεξεργασίες για να λάβουν την τελική απόφαση, είτε αυτή αφορά την ταξινόμηση μιας εικόνας, τον εντοπισμό αντικειμένων, ή οποιαδήποτε άλλη εργασία για την οποία έχει εκπαιδευτεί το δίκτυο.

### 2.2.3. Κλινικές Εφαρμογές και Ερευνητικά Επιτεύγματα

Η εφαρμογή των συνελικτικών νευρωνικών δικτύων στην ιστοπαθολογία έχει παράγει αξιοσημείωτα αποτελέσματα που έχουν αλλάξει τις προοπτικές για την αυτοματοποίηση της διαγνωστικής διαδικασίας. Ένα από τα πιο εντυπωσιακά παραδείγματα είναι η ανίχνευση μεταστάσεων λεμφαδένων σε καρκίνο του μαστού, όπου ερευνητικές ομάδες έχουν αναπτύξει συστήματα ικανά να εντοπίζουν ακόμα και μικροσκοπικές μεταστάσεις με ακρίβεια που ανταγωνίζεται ή και ξεπερνά αυτή των έμπειρων παθολόγων[20].

Στον τομέα της ηπατολογίας, τα αποτελέσματα είναι εξίσου εντυπωσιακά. Ερευνητές έχουν επιτύχει την ανάπτυξη αλγορίθμων που μπορούν να ποσοτικοποιούν με εξαιρετική ακρίβεια διάφορες παραμέτρους της λιπώδους νόσου του ήπατος, συμπεριλαμβανομένου του ποσοστού στεάτωσης, του βαθμού φλεγμονής και της έκτασης της ίνωσης. Αυτές οι δυνατότητες έχουν ιδιαίτερη κλινική σημασία καθώς παρέχουν αντικειμενικές και επαναλήψιμες μετρήσεις που μπορούν να χρησιμοποιηθούν για την παρακολούθηση της εξέλιξης της νόσου και την αξιολόγηση της αποτελεσματικότητας θεραπευτικών παρεμβάσεων.

Σε εξειδικευμένες εφαρμογές όπως η ανάλυση σημάτων επιληψίας και άλλων νευρολογικών παθήσεων, έχουν αναπτυχθεί προηγμένα συστήματα αυτόματης ανίχνευσης και ταξινόμησης που βασίζονται σε τεχνικές βαθιάς μάθησης [21]. Αυτά τα συστήματα έχουν τη δυνατότητα να επεξεργάζονται τεράστιους όγκους δεδομένων σε πραγματικό χρόνο, προσφέροντας πολύτιμη υποστήριξη στους κλινικούς ιατρούς για την έγκαιρη διάγνωση και παρέμβαση.

Παρόμοια επιτυχημένα αποτελέσματα έχουν καταγραφεί και σε άλλους ιατρικούς τομείς, όπως η δερματολογία για την ανίχνευση καρκίνου του δέρματος, η οφθαλμολογία για τη

διάγνωση διαβητικής αμφιβληστροειδοπάθειας, και η ογκολογία για την ανάλυση διαφόρων τύπων καρκίνου. Σε όλες αυτές τις εφαρμογές, τα συστήματα βαθιάς μάθησης έχουν αποδείξει ότι μπορούν να προσφέρουν όχι μόνο υψηλή ακρίβεια, αλλά και σημαντικά πλεονεκτήματα ως προς την ταχύτητα, τη συνέπεια και τη δυνατότητα επεξεργασίας μεγάλων όγκων δεδομένων που θα ήταν αδύνατη για ανθρώπινη επεξεργασία.

### 2.2.4. Προκλήσεις και Όρια της Τεχνολογίας

Παρά τις εντυπωσιακές επιδόσεις που έχουν καταγραφεί στη βιβλιογραφία, η μετάβαση από τα ερευνητικά εργαστήρια στην καθημερινή κλινική πρακτική αντιμετωπίζει σημαντικές προκλήσεις που απαιτούν προσεκτική αντιμετώπιση. Μια από τις κυριότερες αυτές προκλήσεις είναι η ανάγκη για εκτεταμένα και υψηλής ποιότητας σύνολα δεδομένων εκπαίδευσης. Τα νευρωνικά δίκτυα απαιτούν χιλιάδες ή ακόμα και εκατοντάδες χιλιάδες παραδείγματα για να εκπαιδευτούν αποτελεσματικά, και η συγκέντρωση τέτοιων όγκων επισημειωμένων ιατρικών δεδομένων είναι εξαιρετικά χρονοβόρα, δαπανηρή και απαιτεί τη συνεχή εμπλοκή έμπειρων ειδικών.

Ένα εξίσου σημαντικό πρόβλημα είναι αυτό της γενίκευσης των μοντέλων σε διαφορετικά κλινικά περιβάλλοντα και πληθυσμούς. Ένα σύστημα που εκπαιδεύεται με δεδομένα από ένα συγκεκριμένο νοσοκομείο ή γεωγραφική περιοχή μπορεί να αποτύχει όταν εφαρμόζεται σε δεδομένα από διαφορετικές πηγές, λόγω διαφορών στις τεχνικές προετοιμασίας των δειγμάτων, στον εξοπλισμό απεικόνισης, στις δημογραφικές ιδιαιτερότητες των πληθυσμών, ή ακόμα και σε περιβαλλοντικούς παράγοντες[22]. Αυτό το φαινόμενο, γνωστό ως "μετατόπιση πεδίου", αποτελεί ένα από τα σημαντικότερα εμπόδια στην ευρεία κλινική υιοθέτηση των συστημάτων τεχνητής νοημοσύνης.

Επιπρόσθετα, η έλλειψη διαφάνειας και ερμηνευσιμότητας στις αποφάσεις των νευρωνικών δικτύων δημιουργεί σημαντικές ανησυχίες στον ιατρικό τομέα. Τα περισσότερα σύγχρονα μοντέλα βαθιάς μάθησης λειτουργούν ως "μαύρα κουτιά", παρέχοντας αποτελέσματα χωρίς να είναι σαφής ο τρόπος με τον οποίο καταλήγουν σε αυτά. Στον ιατρικό τομέα, όπου οι αποφάσεις μπορούν να έχουν κρίσιμες επιπτώσεις στη ζωή και την υγεία των ασθενών, είναι απαραίτητο οι κλινικοί ιατροί να κατανοούν και να μπορούν να αιτιολογήσουν τις προτάσεις που προκύπτουν από τα αυτοματοποιημένα συστήματα.

Τέλος, υπάρχουν σημαντικές ρυθμιστικές και νομικές προκλήσεις που πρέπει να αντιμετωπιστούν πριν από την ευρεία υιοθέτηση αυτών των τεχνολογιών. Οι αρχές υγείας παγκοσμίως εργάζονται για την ανάπτυξη κατάλληλων πλαισίων αξιολόγησης και έγκρισης συστημάτων τεχνητής νοημοσύνης για ιατρική χρήση, αλλά αυτή η διαδικασία είναι σύνθετη και απαιτεί χρόνο. Παράλληλα, εγείρονται σημαντικά ερωτήματα σχετικά με την ευθύνη σε περιπτώσεις λανθασμένων διαγνώσεων, την προστασία της ιδιωτικότητας των ασθενών και την ασφάλεια των ευαίσθητων ιατρικών δεδομένων.

## 2.3. Αρχιτεκτονικές Συνελικτικών Νευρωνικών Δικτύων

### 2.3.1. Εξέλιξη και Χαρακτηριστικά των Σύγχρονων Αρχιτεκτονικών

Η εξέλιξη των αρχιτεκτονικών συνελικτικών νευρωνικών δικτύων κατά την τελευταία δεκαετία έχει χαρακτηριστεί από μια συνεχή αναζήτηση βελτιστοποίησης της ισορροπίας μεταξύ υπολογιστικής αποδοτικότητας και ακρίβειας πρόβλεψης. Αυτή η εξέλιξη έχει ιδιαίτερη σημασία στον τομέα της ιστοπαθολογίας, όπου οι απαιτήσεις για υψηλή ακρίβεια είναι κρίσιμες για την ασφάλεια των ασθενών και την αξιοπιστία της διάγνωσης. Οι σύγχρονες αρχιτεκτονικές έχουν σχεδιαστεί να αντιμετωπίζουν τις συγκεκριμένες προκλήσεις που παρουσιάζουν οι ιστοπαθολογικές εικόνες, όπως η πολυπλοκότητα των κυτταρικών δομών, η ποικιλομορφία των υφών και η ανάγκη για ακριβή οριοθέτηση αντικειμένων ενδιαφέροντος.

Στον πυρήνα αυτής της εξέλιξης βρίσκεται η αναγνώριση ότι οι ιστοπαθολογικές εικόνες διαθέτουν μοναδικά χαρακτηριστικά που απαιτούν εξειδικευμένη αντιμετώπιση. Σε αντίθεση με τις φυσικές εικόνες που χρησιμοποιούνται συνήθως για την εκπαίδευση γενικών μοντέλων μηχανικής όρασης, οι ιστοπαθολογικές εικόνες περιέχουν πολύπλοκες μικροσκοπικές δομές που εκτείνονται σε πολλαπλές κλίμακες ανάλυσης. Αυτό σημαίνει ότι σημαντικές διαγνωστικές πληροφορίες μπορεί να βρίσκονται τόσο σε λεπτομερείς κυτταρικές αλλαγές όσο και σε ευρύτερα αρχιτεκτονικά πρότυπα του ιστού.

Η διαφοροποίηση των απαιτήσεων έχει οδηγήσει στην ανάπτυξη εξειδικευμένων αρχιτεκτονικών που μπορούν να εξάγουν πληροφορίες από διαφορετικά επίπεδα αφαίρεσης ταυτόχρονα. Αυτές οι αρχιτεκτονικές ενσωματώνουν μηχανισμούς που επιτρέπουν την αποτελεσματική διαχείριση πολύπλοκων ιεραρχικών αναπαραστάσεων, ενώ παράλληλα διατηρούν την ικανότητα γενίκευσης σε νέα και άγνωστα δεδομένα. Η σημασία αυτών των καινοτομιών γίνεται ιδιαίτερα εμφανής όταν εξετάζουμε τις επιδόσεις διαφορετικών αρχιτεκτονικών σε πραγματικά κλινικά σενάρια.

### 2.3.2. Κλασικές Αρχιτεκτονικές και η Εφαρμογή τους στην Ιστοπαθολογία

Οι πρώτες επιτυχημένες αρχιτεκτονικές που βρήκαν εφαρμογή στην ιστοπαθολογία βασίστηκαν σε δοκιμασμένα σχήματα που είχαν αποδείξει την αξία τους σε γενικούς τομείς μηχανικής όρασης. Μεταξύ των πρωτοπόρων αρχιτεκτονικών που προσαρμόστηκαν για ιστοπαθολογικές εφαρμογές, ξεχωρίζουν οι κλασικές οικογένειες δικτύων που έθεσαν τα θεμέλια για την εξέλιξη του τομέα. Αυτές οι αρχιτεκτονικές αποτέλεσαν τη βάση για την ανάπτυξη εξειδικευμένων λύσεων που μπορούν να αντιμετωπίζουν τις μοναδικές προκλήσεις των ιστολογικών παρασκευασμάτων.

Στην καρδιά των κλασικών αρχιτεκτονικών βρίσκεται η αρχή της ιεραρχικής εξαγωγής χαρακτηριστικών, όπου κάθε στρώμα του δικτύου μαθαίνει να αναγνωρίζει χαρακτηριστικά αυξανόμενης πολυπλοκότητας. Τα αρχικά στρώματα εστιάζουν στην

ανίχνευση βασικών γεωμετρικών στοιχείων όπως ακμές, γωνίες και απλές υφές, ενώ τα βαθύτερα στρώματα συνδυάζουν αυτές τις πρωτογενείς πληροφορίες για να σχηματίσουν πιο περίπλοκες αναπαραστάσεις. Στο πλαίσιο της ιστοπαθολογίας, αυτή η διαδικασία αντιστοιχεί στη σταδιακή αναγνώριση από απλά κυτταρικά όρια έως πολύπλοκες ιστικές δομές και παθολογικά πρότυπα.

Η εφαρμογή αυτών των αρχιτεκτονικών στην ιστοπαθολογία απαίτησε σημαντικές προσαρμογές για να αντιμετωπιστούν οι ιδιαιτερότητες των ιατρικών εικόνων. Για παράδειγμα, τα παραδοσιακά μοντέλα που εκπαιδεύονταν σε εικόνες φυσικών αντικειμένων έπρεπε να προσαρμοστούν στις διαφορετικές χρωματικές ιδιότητες των ιστοχημικών χρώσεων, στις μικροσκοπικές κλίμακες των κυτταρικών δομών, και στην αυξημένη ποικιλομορφία των μορφολογικών χαρακτηριστικών που μπορεί να συναντώνται ακόμα και εντός της ίδιας παθολογικής κατηγορίας.

Οι αρχές σχεδιασμού αυτών των αρχιτεκτονικών περιλαμβάνουν επίσης εξειδικευμένες στρατηγικές για τη διαχείριση της χωρικής πληροφορίας που είναι κρίσιμη στην ιστοπαθολογία. Σε αντίθεση με τις φυσικές εικόνες όπου η θέση των αντικειμένων μπορεί να είναι λιγότερο σημαντική, στις ιστοπαθολογικές εικόνες η ακριβής χωρική κατανομή και η σχετική θέση των κυτταρικών στοιχείων μπορεί να φέρει κρίσιμες διαγνωστικές πληροφορίες. Αυτό έχει οδηγήσει στην ανάπτυξη εξειδικευμένων τεχνικών που διατηρούν και αξιοποιούν αυτές τις χωρικές σχέσεις καθ' όλη τη διαδικασία επεξεργασίας.

Σημαντικός παράγοντας στην επιτυχία αυτών των αρχιτεκτονικών είναι η ικανότητά τους να διαχειρίζονται την εγγενή ποικιλομορφία που χαρακτηρίζει τις ιστοπαθολογικές εικόνες. Αυτή η ποικιλομορφία προκύπτει όχι μόνο από τις διαφορετικές παθολογικές καταστάσεις που μπορεί να υπάρχουν, αλλά και από παραλλαγές στις τεχνικές προετοιμασίας των δειγμάτων, στις συνθήκες φωτισμού κατά τη σάρωση, και στις ιδιαιτερότητες του εξοπλισμού που χρησιμοποιείται. Επιπρόσθετα, παράγοντες όπως ο χρόνος αποθήκευσης των δειγμάτων, η ποιότητα των αντιδραστηρίων χρώσης, και ακόμα και περιβαλλοντικές συνθήκες κατά την προετοιμασία μπορούν να επηρεάσουν την τελική εμφάνιση των εικόνων.

Οι πετυχημένες αρχιτεκτονικές ενσωματώνουν μηχανισμούς που τους επιτρέπουν να είναι ανθεκτικές σε αυτές τις παραλλαγές, διατηρώντας παράλληλα την ικανότητά τους να εντοπίζουν τα πραγματικά διαγνωστικά χαρακτηριστικά. Αυτοί οι μηχανισμοί περιλαμβάνουν τεχνικές κανονικοποίησης που εξασφαλίζουν σταθερότητα στις εσωτερικές αναπαραστάσεις του δικτύου, μεθόδους επαύξησης δεδομένων που προσομοιώνουν φυσικές παραλλαγές στα δεδομένα, και εξειδικευμένες αρχιτεκτονικές επιλογές που ενισχύουν την ανθεκτικότητα του συστήματος σε περιβαλλοντικές μεταβολές.

### 2.3.3. Εξειδικευμένες Αρχιτεκτονικές για Ανάλυση Ιστών

Η ανάπτυξη εξειδικευμένων αρχιτεκτονικών για ιστοπαθολογικές εφαρμογές έχει οδηγήσει στη δημιουργία συστημάτων που μπορούν να επιτυγχάνουν εξαιρετικές

επιδόσεις σε συγκεκριμένα διαγνωστικά προβλήματα. Ένα χαρακτηριστικό παράδειγμα είναι η ανάπτυξη συστημάτων συνδυαστικής ταξινόμησης που χρησιμοποιούν πολλαπλές αρχιτεκτονικές παράλληλα για την αξιολόγηση της παγκρεατικής στεάτωσης [23]. Αυτά τα συστήματα αξιοποιούν διαφορετικές αρχιτεκτονικές όπως τα δίκτυα μεταβλητού βάθους και τα δίκτυα υπολειμματικών συνδέσεων, καθένα από τα οποία συνεισφέρει διαφορετικές πληροφορίες στην τελική διαγνωστική απόφαση.

Στην συγκεκριμένη μελέτη για την παγκρεατική στεάτωση, αξιοποιήθηκαν τέσσερις διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων που παρουσιάζουν διαφορετικά χαρακτηριστικά και δυνατότητες. Η επιλογή αυτών των αρχιτεκτονικών έγινε με βάση τον αριθμό των εκπαιδεύσιμων παραμέτρων τους, με σκοπό να καλυφθεί ένα ευρύ φάσμα πολυπλοκότητας μοντέλων. Συγκεκριμένα, χρησιμοποιήθηκαν αρχιτεκτονικές με περίπου 61 εκατομμύρια παραμέτρους για τα ρηχότερα μοντέλα, ενώ για τα βαθύτερα δίκτυα ο αριθμός έφτασε έως και τα 144 εκατομμύρια παραμέτρους. Αυτή η σημαντική διαφορά στην πολυπλοκότητα επέτρεψε την αξιοποίηση διαφορετικών στρατηγικών εκπαίδευσης και τη συλλογή συμπληρωματικών πληροφοριών από κάθε μοντέλο.

Για τα πολύ βαθιά δίκτυα με εκατοντάδες εκατομμύρια παραμέτρους, εφαρμόστηκε η τεχνική του "παγώματος βαρών" στα αρχικά στρώματα συνέλιξης. Αυτή η στρατηγική βασίζεται στην παρατήρηση ότι τα αρχικά στρώματα των βαθιών δικτύων έχουν ήδη γενικεύσει σε χαρακτηριστικά χαμηλού επιπέδου όπως ακμές και σχήματα, και η περαιτέρω ενημέρωσή τους μπορεί να οδηγήσει σε υπερπροσαρμογή στα νέα ιστοπαθολογικά δεδομένα. Με το πάγωμα των βαρών στα πρώτα δύο συνελικτικά μπλοκ των βαθύτερων αρχιτεκτονικών, επιτεύχθηκε μείωση των εκπαιδεύσιμων παραμέτρων κατά περίπου 4 εκατομμύρια, βελτιώνοντας παράλληλα την ικανότητα γενίκευσης των μοντέλων.

Η εκπαίδευση όλων των μοντέλων πραγματοποιήθηκε με κοινές παραμέτρους που προσαρμόστηκαν στις ιδιαιτερότητες των ιστοπαθολογικών δεδομένων. Χρησιμοποιήθηκε μέγιστος αριθμός 10 εποχών εκπαίδευσης, μέγεθος δέσμης 32 τμημάτων εικόνας, και γενικός ρυθμός μάθησης 0.0001, που αποτελεί προτιμώμενη τιμή για εργασίες μεταφοράς μάθησης καθώς εξασφαλίζει ότι κάθε προσαρμοσμένο μοντέλο δεν αποκλίνει σημαντικά από το αντίστοιχο αρχικό του. Επιπρόσθετα, εφαρμόστηκε αριθμός υπομονής επικύρωσης ίσος με 3, ώστε αν ένα δίκτυο παρουσιάσει την ίδια ακρίβεια επικύρωσης τρεις φορές κατά την εκπαίδευση να διακοπεί η διαδικασία, και χρησιμοποιήθηκε ο βελτιστοποιητής SGDM στη μέθοδο οπισθοδιάδοσης.

Αυτή η προσέγγιση της συνδυαστικής μάθησης έχει αποδειχθεί ιδιαίτερα αποτελεσματική σε περιπτώσεις όπου οι διαγνωστικές πληροφορίες εκτείνονται σε πολλαπλές κλίμακες ή όπου υπάρχει αβεβαιότητα ως προς το ποια χαρακτηριστικά είναι τα πιο σημαντικά για μια συγκεκριμένη διάγνωση. Στην περίπτωση της παγκρεατικής στεάτωσης, για παράδειγμα, η ανίχνευση και ποσοτικοποίηση λιπωδών σταγονιδίων απαιτεί την ικανότητα αναγνώρισης τόσο μεμονωμένων κυττάρων όσο και ευρύτερων περιοχών ιστικής αλλοίωσης. Τα διαφορετικά μοντέλα του συνδυαστικού συστήματος μπορούν να εστιάσουν σε διαφορετικές πτυχές αυτού του πολύπλοκου προβλήματος, προσφέροντας μια πιο ολοκληρωμένη και αξιόπιστη διαγνωστική εκτίμηση.

Η εφαρμογή τεχνικών μεταφοράς μάθησης έχει διευκολύνει σημαντικά την προσαρμογή αυτών των αρχιτεκτονικών σε νέα προβλήματα ιστοπαθολογίας. Αντί να εκπαιδεύονται από το μηδέν, τα μοντέλα ξεκινούν από βάρη που έχουν προεκπαιδευτεί σε μεγάλα σύνολα γενικών εικόνων και στη συνέχεια προσαρμόζονται στα ειδικά χαρακτηριστικά των ιστοπαθολογικών δεδομένων. Αυτή η στρατηγική όχι μόνο μειώνει σημαντικά τον χρόνο εκπαίδευσης και τις απαιτήσεις σε δεδομένα, αλλά συχνά οδηγεί και σε καλύτερες επιδόσεις λόγω της καλύτερης αρχικοποίησης των βαρών του δικτύου.

### 2.3.4. Βελτιστοποίηση και Προκλήσεις Εφαρμογής

Η βελτιστοποίηση των αρχιτεκτονικών συνελικτικών νευρωνικών δικτύων για ιστοπαθολογικές εφαρμογές αντιμετωπίζει μοναδικές προκλήσεις που απαιτούν εξειδικευμένες προσεγγίσεις. Μια από τις κυριότερες αυτές προκλήσεις είναι η ανάγκη για ισορροπία μεταξύ της πολυπλοκότητας του μοντέλου και της διαθεσιμότητας επισημειωμένων δεδομένων. Οι ιστοπαθολογικές εφαρμογές συχνά χαρακτηρίζονται από περιορισμένα σύνολα δεδομένων λόγω του κόστους και του χρόνου που απαιτείται για την εξειδικευμένη επισημείωση από ειδικούς παθολόγους.

Αυτός ο περιορισμός έχει οδηγήσει στην ανάπτυξη τεχνικών που στοχεύουν στη μείωση της υπερπροσαρμογής και στη βελτίωση της γενικευτικής ικανότητας των μοντέλων. Τεχνικές όπως η τακτοποίηση βαρών, η εφαρμογή προοδευτικής απόρριψης νευρώνων κατά την εκπαίδευση, και η χρήση προηγμένων μεθόδων επαύξησης δεδομένων έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές. Οι μέθοδοι επαύξησης δεδομένων, ειδικά, πρέπει να σχεδιάζονται προσεχτικά ώστε να διατηρούν τα κρίσιμα διαγνωστικά χαρακτηριστικά των εικόνων ενώ παράλληλα αυξάνουν την ποικιλομορφία των δεδομένων εκπαίδευσης.

Επιπρόσθετα, η φύση των ιστοπαθολογικών εικόνων δημιουργεί ιδιαίτερες απαιτήσεις ως προς την υπολογιστική αποδοτικότητα των αρχιτεκτονικών. Οι εικόνες υψηλής ανάλυσης που χρησιμοποιούνται σε αυτές τις εφαρμογές μπορεί να έχουν διαστάσεις που ξεπερνούν κατά πολύ αυτές των συμβατικών εικόνων, απαιτώντας εξειδικευμένες στρατηγικές για την αποδοτική επεξεργασία τους. Αυτό περιλαμβάνει τεχνικές όπως η τμηματική επεξεργασία εικόνων, η ιεραρχική ανάλυση σε διαφορετικές αναλύσεις, και η χρήση προοδευτικών μεθόδων που επικεντρώνονται σε περιοχές ενδιαφέροντος.

Τέλος, η επιτυχημένη εφαρμογή αυτών των αρχιτεκτονικών στην κλινική πρακτική απαιτεί την αντιμετώπιση ζητημάτων που σχετίζονται με την ερμηνευσιμότητα των αποτελεσμάτων. Οι κλινικοί ιατροί χρειάζονται να κατανοούν όχι μόνο την τελική διαγνωστική πρόταση του συστήματος, αλλά και τα κρίσιμα χαρακτηριστικά της εικόνας που οδήγησαν σε αυτή την απόφαση. Αυτό έχει οδηγήσει στην ανάπτυξη εξειδικευμένων τεχνικών οπτικοποίησης και ερμηνείας που μπορούν να αναδείξουν τις περιοχές της εικόνας που επηρέασαν περισσότερο την απόφαση του μοντέλου, προσφέροντας έτσι πολύτιμες πληροφορίες για την επικύρωση και τη βελτίωση της διαγνωστικής διαδικασίας.

## 2.4. Instance Segmentation: Mask R-CNN και Παραλλαγές

### 2.4.1. Εισαγωγή στον Εντοπισμό και Κατάτμηση Στιγμιότυπων

Ο εντοπισμός και η κατάτμηση στιγμιότυπων (Instance Segmentation) αντιπροσωπεύει μια από τις πιο προηγμένες και απαιτητικές τεχνικές στο πεδίο της μηχανικής όρασης, συνδυάζοντας τις δυνατότητες του εντοπισμού αντικειμένων με την ακριβή οριοθέτηση των ορίων τους σε επίπεδο εικονοστοιχείου. Σε αντίθεση με την κλασική κατηγοριοποίηση εικόνων που απαντά στο ερώτημα "τι" υπάρχει στην εικόνα, ή τον απλό εντοπισμό αντικειμένων που προσδιορίζει "πού" βρίσκονται τα αντικείμενα, η κατάτμηση στιγμιότυπων επιτρέπει την ακριβή αναγνώριση του "ποιου" μέρους της εικόνας ανήκει σε κάθε συγκεκριμένο αντικείμενο [24].

Αυτή η ικανότητα έχει ιδιαίτερη σημασία στην ψηφιακή παθολογία, όπου η ακριβής οριοθέτηση κυτταρικών και ιστικών δομών είναι απαραίτητη για την ποσοτική ανάλυση και τη διαγνωστική αξιολόγηση. Η παραδοσιακή προσέγγιση της σημασιολογικής κατάτμησης (semantic segmentation) αναθέτει κάθε εικονοστοιχείο σε μια κατηγορία, αλλά δεν διακρίνει μεταξύ διαφορετικών στιγμιότυπων της ίδιας κλάσης. Αντίθετα, η κατάτμηση στιγμιότυπων μπορεί να εντοπίσει και να διαχωρίσει μεμονωμένα κύτταρα, ακόμη και όταν αυτά βρίσκονται σε στενή επαφή ή επικαλύπτονται μερικώς [25].

Η αρχιτεκτονική προσέγγιση της κατάτμησης στιγμιότυπων διαχωρίζεται σε δύο κύριες κατηγορίες: τις προσεγγίσεις "άνωθεν-κάτω" (top-down) και "κάτωθεν-άνω" (bottom-up). Οι προσεγγίσεις άνωθεν-κάτω, όπως αυτές που χρησιμοποιούνται στο Mask R-CNN, εκκινούν από τον εντοπισμό των αντικειμένων μέσω οριοθετικών πλαισίων και στη συνέχεια εκτελούν κατάτμηση εντός αυτών των περιοχών. Αντίθετα, οι προσεγγίσεις κάτωθεν-άνω εκκινούν από τον εντοπισμό μεμονωμένων στοιχείων και τη συγκέντρωσή τους σε συνεκτικές περιοχές που αντιστοιχούν σε διαφορετικά στιγμιότυπα [26].

### 2.4.2. Η Αρχιτεκτονική του Mask R-CNN

#### 2.4.2.1. Θεμελιώδη Χαρακτηριστικά και Καινοτομίες

Το Mask R-CNN, που αναπτύχθηκε από ερευνητές του Facebook AI Research το 2017, αποτελεί μια επέκταση του Faster R-CNN που προσθέτει έναν πρόσθετο κλάδο πρόβλεψης για τη δημιουργία μασκών κατάτμησης παράλληλα με την ταξινόμηση και την οριοθέτηση των αντικειμένων [24] . Η κεντρική καινοτομία του συστήματος έγκειται στη δυνατότητά του να εκτελεί ταυτόχρονα τρεις κρίσιμες εργασίες: τον εντοπισμό αντικειμένων μέσω οριοθετικών πλαισίων, την ταξινόμησή τους σε κατηγορίες και τη δημιουργία ακριβών μασκών σε επίπεδο εικονοστοιχείου για κάθε εντοπισμένο αντικείμενο. Η αρχιτεκτονική βασίζεται στην αρχή της πολυεπίπεδης επεξεργασίας, όπου κάθε στάδιο εκτελεί μια συγκεκριμένη εργασία και μεταβιβάζει τα αποτελέσματά του στο επόμενο στάδιο για περαιτέρω επεξεργασία. Αυτή η modular προσέγγιση επιτρέπει την

ανεξάρτητη βελτιστοποίηση κάθε συστατικού και την εύκολη προσαρμογή της αρχιτεκτονικής σε διαφορετικές εφαρμογές(Ren et al., 2015).

Η αρχιτεκτονική του Mask R-CNN αποτελείται από τέσσερα βασικά συστατικά που συνεργάζονται για την επίτευξη των στόχων της κατάτμησης στιγμιότυπων. Πρώτον, το δίκτυο ραχοκοκαλιάς (backbone network), συνήθως ένα ResNet ή ResNeXt, εκτελεί την εξαγωγή χαρακτηριστικών από την εισερχόμενη εικόνα σε πολλαπλές κλίμακες. Το backbone δίκτυο λειτουργεί ως εξαγωγέας χαρακτηριστικών υψηλού επιπέδου που κωδικοποιούν τις σημαντικές πληροφορίες της εικόνας σε μια συμπαγή αναπαράσταση.

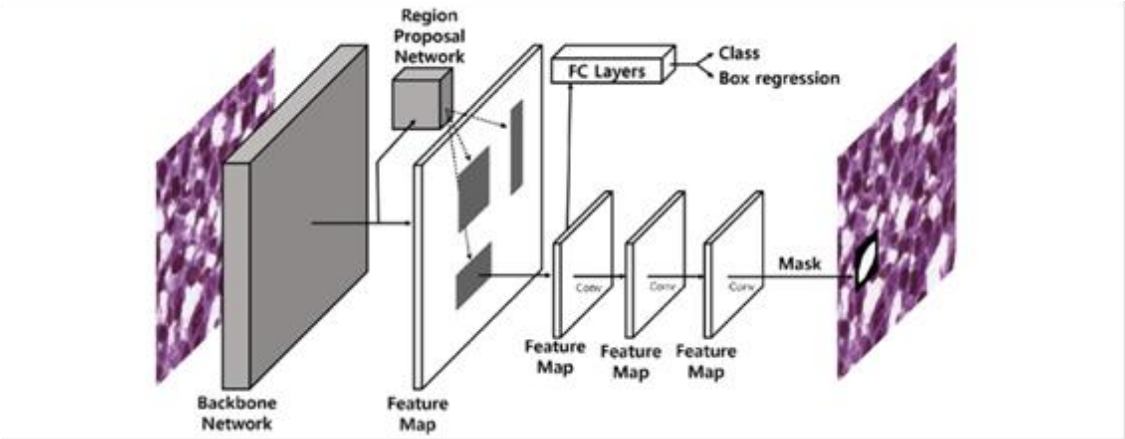


*Διάγραμμα 1. Αρχιτεκτονική Mask R-CNN (Σύνδεσμος)*

Δεύτερον, το Δίκτυο Πυραμίδας Χαρακτηριστικών (Feature Pyramid Network - FPN) ενισχύει την αναπαράσταση των χαρακτηριστικών συνδυάζοντας πληροφορίες υψηλής και χαμηλής ανάλυσης για καλύτερο εντοπισμό αντικειμένων σε διαφορετικές κλίμακες. Το FPN αντιμετωπίζει το πρόβλημα της κλιμακικής ποικιλομορφίας που είναι ιδιαίτερα έντονο στην ιστοπαθολογία, όπου κυτταρικές δομές μπορεί να εμφανίζονται σε ένα ευρύ φάσμα μεγεθών[28].

Τρίτον, το Δίκτυο Πρότασης Περιοχών (Region Proposal Network - RPN) δημιουργεί προτάσεις περιοχών που ενδεχομένως περιέχουν αντικείμενα ενδιαφέροντος. Το RPN λειτουργεί ως ένα πρώτο στάδιο φιλτραρίσματος που μειώνει το χώρο αναζήτησης και εστιάζει την προσοχή του συστήματος σε περιοχές με υψηλή πιθανότητα να περιέχουν αντικείμενα. Τέλος, ο κλάδος κεφαλής (head branch) εκτελεί την τελική ταξινόμηση, τη βελτίωση των οριοθετικών πλαισίων και τη δημιουργία των μασκών κατάτμησης. Ο κλάδος κεφαλής αποτελείται από τρεις παράλληλους υποκλάδους: έναν για την ταξινόμηση, έναν για τη βελτίωση των οριοθετικών πλαισίων και έναν για τη δημιουργία των μασκών.

Μια κρίσιμη τεχνική καινοτομία του Mask R-CNN είναι η εισαγωγή του ROI Align, που αντικαθιστά την παραδοσιακή ROI Pooling. Ενώ η ROI Pooling εκτελεί κβαντοποίηση των συντεταγμένων που οδηγεί σε misalignments μεταξύ των περιοχών ενδιαφέροντος και των εξαγόμενων χαρακτηριστικών, η ROI Align χρησιμοποιεί διγραμμική παρεμβολή για να διατηρήσει την ακριβή χωρική αντιστοιχία. Αυτό είναι ιδιαίτερα σημαντικό για την κατάτμηση, όπου η ακρίβεια σε επίπεδο εικονοστοιχείου είναι κρίσιμη και ακόμη και

μικρές χωρικές αποκλίσεις μπορούν να οδηγήσουν σε σημαντική υποβάθμιση της ποιότητας των μασκών.

### 2.4.3. Προσαρμογή για Ιστοπαθολογικές Εφαρμογές

Η εφαρμογή του Mask R-CNN στην ιστοπαθολογία παρουσιάζει τόσο μοναδικές ευκαιρίες όσο και ειδικές προκλήσεις. Οι ιστοπαθολογικές εικόνες χαρακτηρίζονται από εξαιρετικά υψηλή ανάλυση, πολύπλοκες μορφολογικές δομές και σημαντική ποικιλομορφία στην εμφάνιση των κυττάρων και των ιστών ανάλογα με τη χρώση, την παθολογική κατάσταση και τις συνθήκες προετοιμασίας του παρασκευάσματος [16]. Επιπρόσθετα, η ανάγκη για εξαιρετικά υψηλή ακρίβεια στον εντοπισμό και την κατάτμηση κυτταρικών δομών καθιστά επιτακτική την προσαρμογή των παραδοσιακών αρχιτεκτονικών. Η πυκνότητα των αντικειμένων στις ιστοπαθολογικές εικόνες είναι συχνά πολύ υψηλότερη από αυτή που συναντάται σε φυσικές εικόνες, με αποτέλεσμα να υπάρχουν περιπτώσεις όπου εκατοντάδες ή χιλιάδες κύτταρα μπορεί να βρίσκονται σε μια μόνο εικόνα [29].

Μια κρίσιμη προσαρμογή αφορά τη διαχείριση του μεγέθους των εικόνων. Ενώ οι παραδοσιακές εφαρμογές μηχανικής όρασης συνήθως επεξεργάζονται εικόνες με ανάλυση μερικών εκατοντάδων ή χιλιάδων εικονοστοιχείων, οι εικόνες ολικής τομής μπορεί να φτάσουν τις 100.000 x 100.000 εικονοστοιχεία. Αυτό καθιστά αναγκαία την ανάπτυξη στρατηγικών τεμαχισμού (patching) και επεξεργασίας σε τμήματα, διατηρώντας παράλληλα τη συνέχεια στις συνοριακές περιοχές. Η στρατηγική sliding window με επικάλυψη έχει αποδειχθεί αποτελεσματική για την αντιμετώπιση αυτού του προβλήματος, ενώ τεχνικές όπως το test-time augmentation και η ensemble prediction μπορούν να βελτιώσουν περαιτέρω την ακρίβεια των αποτελεσμάτων. Επιπλέον, η πολυπλοκότητα των ιστοπαθολογικών δομών απαιτεί βαθύτερα δίκτυα με περισσότερες παραμέτρους, ενώ παράλληλα υπάρχει κίνδυνος υπερπροσαρμογής λόγω του περιορισμένου αριθμού διαθέσιμων εκπαιδευτικών δεδομένων [30].

### 2.4.4. Εξελίξεις και Παραλλαγές του Mask R-CNN

Η εξέλιξη των μεθόδων έχουν φέρει στο προσκήνιο πολλές διαφορετικές παραλλαγές μετεξέλιξης του βασικού μοντέλου:

- **Cascade Mask R-CNN:** Προοδευτική Βελτίωση: Η επιτυχία του Mask R-CNN οδήγησε στην ανάπτυξη πολλαπλών παραλλαγών και βελτιώσεων που στοχεύουν στην αντιμετώπιση συγκεκριμένων περιορισμών και στη βελτίωση της απόδοσης σε ειδικές εφαρμογές. Το Cascade Mask R-CNN επεκτείνει την αρχική αρχιτεκτονική εισάγοντας μια αλληλουχία cascaded detectors που εκπαιδεύονται με προοδευτικά αυστηρότερα κριτήρια ποιότητας, οδηγώντας σε βελτιωμένη ακρίβεια εντοπισμού ιδιαίτερα για αντικείμενα υψηλής ποιότητας [31]. Αυτή η προσέγγιση είναι ιδιαίτερα χρήσιμη στην ιστοπαθολογία όπου η ακριβής

οριοθέτηση κυτταρικών δομών είναι κρίσιμη. Κάθε στάδιο του cascade εκπαιδεύεται για να βελτιώνει τα αποτελέσματα του προηγούμενου, με αποτέλεσμα την προοδευτική αύξηση της ακρίβειας. Η μέθοδος αυτή αποδεικνύεται ιδιαίτερα αποτελεσματική σε περιπτώσεις όπου απαιτείται πολύ υψηλή ακρίβεια στον εντοπισμό και την κατάτμηση, όπως στην ανάλυση κυτταρικών πυρήνων για διαγνωστικούς σκοπούς.

- **PointRend - Προσέγγιση Εμπνευσμένη από Rendering:** Το PointRend αντιπροσωπεύει μια ριζική επανεννόηση της διαδικασίας κατάτμησης, υιοθετώντας μια προσέγγιση που εμπνέεται από τις τεχνικές rendering της υπολογιστικής γραφικής (Kirillov et al., 2020).Αντί για την παραδοσιακή προσέγγιση που επεξεργάζεται όλα τα εικονοστοιχεία με την ίδια ανάλυση, το PointRend εστιάζει υπολογιστικούς πόρους στα σημεία όπου οι αποφάσεις κατάτμησης είναι πιο δύσκολες, τυπικά κοντά στα όρια των αντικειμένων. Αυτή η προσέγγιση οδηγεί σε καλύτερη ποιότητα κατάτμησης με μικρότερο υπολογιστικό κόστος, καθώς εστιάζει την προσοχή του συστήματος στις πιο δύσκολες περιοχές. Στο πλαίσιο της ιστοπαθολογίας, όπου τα όρια των κυττάρων μπορεί να είναι ασαφή ή αμφίσημα, το PointRend προσφέρει σημαντική βελτίωση στην ποιότητα της κατάτμησης χωρίς την ανάγκη για δραστική αύξηση των υπολογιστικών απαιτήσεων.
- **Hybrid Task Cascade (HTC): Ενισχυμένη Διασύνδεση:** Το HTC (Hybrid Task Cascade) εισάγει μια πιο εξελιγμένη αρχιτεκτονική που διαχωρίζει και διασυνδέει τις εργασίες εντοπισμού και κατάτμησης μέσω ενός cascade μηχανισμού [33].Κάθε στάδιο του cascade περιλαμβάνει παράλληλες διαδικασίες για τη βελτίωση των οριοθετικών πλαισίων και των μασκών κατάτμησης, ενώ εισάγει επιπρόσθετες συνδέσεις που επιτρέπουν την πληροφορία να ρέει μεταξύ των εργασιών. Αυτή η προσέγγιση έχει δείξει ιδιαίτερα υποσχόμενα αποτελέσματα σε περίπλοκα σενάρια όπου πολλά αντικείμενα επικαλύπτονται ή βρίσκονται σε κοντινή απόσταση. Στην ιστοπαθολογία, όπου τα κύτταρα συχνά βρίσκονται σε στενή επαφή και σχηματίζουν πολύπλοκες δομές, το HTC μπορεί να παρέχει σημαντική βελτίωση στην ακρίβεια του διαχωρισμού μεμονωμένων κυττάρων.

### 2.4.5. Νέες Προσεγγίσεις με Αρχιτεκτονικές Transformer

Κατ’ αντιστοιχία διαφορετικές προσεγγίσεις με χρήση αρχιτεκτονικών transformer, έχουν παρουσιαστή στην βιβλιογραφία. Ενδεικτικά αναφέρουμε τις δύο πιο χαρακτηριστικες:

- **DETR και Παραλλαγές:** Η πρόσφατη επανάσταση των Transformer αρχιτεκτονικών στη μηχανική όρασης έχει οδηγήσει στην ανάπτυξη νέων προσεγγίσεων για την κατάτμηση στιγμιότυπων που απομακρύνονται από τα παραδοσιακά συνελικτικά δίκτυα. Το DETR (DEtection TRansformer) και οι επέκτασές του προτείνουν μια ριζικά διαφορετική προσέγγιση που αντιμετωπίζει τον εντοπισμό αντικειμένων ως ένα πρόβλημα set prediction, χρησιμοποιώντας attention mechanisms για την άμεση πρόβλεψη ενός σταθερού αριθμού

αντικειμένων [34]. Η κεντρική ιδέα του DETR βασίζεται στη χρήση του self-attention mechanism που επιτρέπει στο μοντέλο να εστιάζει ταυτόχρονα σε διαφορετικές περιοχές της εικόνας και να αναγνωρίζει σχέσεις μεταξύ απομακρυσμένων χωρικά στοιχείων. Αυτή η ικανότητα είναι ιδιαίτερα χρήσιμη στην ιστοπαθολογία, όπου η κατανόηση του γενικότερου ιστικού πλαισίου μπορεί να βελτιώσει την ακρίβεια του εντοπισμού και της ταξινόμησης μεμονωμένων κυττάρων.

- **Mask2Former: Ενοποιημένη Προσέγγιση:** Το Mask2Former επεκτείνει αυτή την προσέγγιση στην κατάτμηση, προτείνοντας μια ενοποιημένη αρχιτεκτονική που μπορεί να χειριστεί τόσο την κατάτμηση στιγμιότυπων όσο και την παν-οπτική κατάτμηση (panoptic segmentation) [35].Η κεντρική ιδέα βασίζεται στη χρήση masked attention, όπου κάθε query εστιάζει σε συγκεκριμένες περιοχές της εικόνας που αντιστοιχούν σε δυνητικά αντικείμενα. Αυτή η προσέγγιση έχει δείξει ιδιαίτερα ισχυρά αποτελέσματα σε πολύπλοκα σενάρια και αποτελεί μια υποσχόμενη κατεύθυνση για ιστοπαθολογικές εφαρμογές. Η δυνατότητα του Mask2Former να χειρίζεται ταυτόχρονα πολλαπλά επίπεδα κατάτμησης το καθιστά ιδιαίτερα κατάλληλο για την ανάλυση ιστοπαθολογικών εικόνων όπου συχνά απαιτείται η ταυτόχρονη αναγνώριση διαφορετικών τύπων κυττάρων και ιστικών δομών.

### 2.4.6. Εξειδικευμένες Τεχνικές για Ιστοπαθολογία

Πέραν των γενικευμένων τεχνικών, πολλές αρχιτεκτονικές δημιουργήθηκαν εξειδικευμένα για προβλήματα ιστοπαθολογίας.

- **Νουκλεϊκός Εντοπισμός και Κατάτμηση:** Η τεχνική του νουκλεϊκού εντοπισμού και κατάτμησης αντιπροσωπεύει μια από τις πιο κρίσιμες εφαρμογές στην ιστοπαθολογία, καθώς ο ακριβής εντοπισμός και η μορφολογική ανάλυση των κυτταρικών πυρήνων αποτελεί τη βάση για πολλές διαγνωστικές διαδικασίες. Η μορφολογία των πυρήνων, το μέγεθός τους, η κατανομή τους και οι χωρικές τους σχέσεις παρέχουν κρίσιμες πληροφορίες για την αξιολόγηση της κυτταρικής δυσπλασίας, της μιτωτικής δραστηριότητας και της γενικής ιστικής αρχιτεκτονικής [36]. Οι παραδοσιακές μέθοδοι επεξεργασίας εικόνας που βασίζονται σε μορφολογικούς τελεστές και κατωφλίωση συχνά αποτυγχάνουν σε περίπλοκα ιστοπαθολογικά περιβάλλοντα όπου οι πυρήνες μπορεί να επικαλύπτονται, να έχουν ακανόνιστη μορφή ή να παρουσιάζουν μεταβλητότητα στη χρώση. Οι σύγχρονες τεχνικές βαθιάς μάθησης έχουν αποδειχθεί σημαντικά πιο αποτελεσματικές σε αυτά τα δύσκολα σενάρια.
- **HoVer-Net: Καινοτόμα Προσέγγιση Κυτταρικής Ανάλυσης:** Το HoVer-Net (Horizontal and Vertical Net) αντιπροσωπεύει μια καινοτόμα προσέγγιση που συνδυάζει την πρόβλεψη της ταξινόμησης των κυττάρων με την εκτίμηση των οριζόντιων και κάθετων αποστάσεων από το κέντρο κάθε κυττάρου [7]. Αυτή η τεχνική επιτρέπει τον ακριβή διαχωρισμό κυττάρων που βρίσκονται σε στενή

επαφή ή επικαλύπτονται μερικώς, ένα κοινό πρόβλημα στις ιστοπαθολογικές εικόνες. Η μέθοδος λειτουργεί δημιουργώντας χάρτες πυκνότητας που αναπαριστούν την απόσταση κάθε εικονοστοιχείου από το πλησιέστερο κέντρο κυττάρου, τόσο στον οριζόντιο όσο και στον κάθετο άξονα. Παράλληλα, παρέχει πληροφορίες για τη μορφολογία των κυττάρων που μπορεί να χρησιμοποιηθούν για περαιτέρω διαγνωστική ανάλυση και φαινοτυπική χαρακτηριοποίηση.

- **Πολυκλιμακικές Προσεγγίσεις:** Μια άλλη σημαντική κατεύθυνση είναι η ανάπτυξη πολυκλιμακικών προσεγγίσεων που μπορούν να αντιμετωπίσουν την τεράστια ποικιλία μεγεθών των ιστικών δομών. Από μικροσκοπικά organelles μέχρι μεγάλες ιστικές περιοχές, η ιστοπαθολογία απαιτεί αλγορίθμους που μπορούν να λειτουργήσουν αποτελεσματικά σε πολλαπλές κλίμακες ταυτόχρονα. Οι πυραμιδοειδείς αρχιτεκτονικές και οι attention mechanisms έχουν αποδειχθεί ιδιαίτερα χρήσιμες σε αυτό το πλαίσιο (Zhou et al., 2019). Οι πολυκλιμακικές προσεγγίσεις επιτρέπουν στο σύστημα να εκμεταλλευτεί πληροφορίες από διαφορετικά επίπεδα λεπτομέρειας, από την τοπική κυτταρική μορφολογία μέχρι τη γενικότερη ιστική αρχιτεκτονική. Αυτό είναι ιδιαίτερα σημαντικό σε διαγνωστικές εργασίες όπου η τελική απόφαση εξαρτάται από τον συνδυασμό τοπικών και συνολικών χαρακτηριστικών.

### 2.4.7. Σύγκριση και Αξιολόγηση Αρχιτεκτονικών

Η σύγκριση των διαφορετικών προσεγγίσεων instance segmentation αποτελεί μια σύνθετη διαδικασία που εξαρτάται από πολλαπλούς παράγοντες, συμπεριλαμβανομένης της ακρίβειας εντοπισμού, της ποιότητας κατάτμησης, της υπολογιστικής αποδοτικότητας και της ευκολίας εφαρμογής σε πραγματικά κλινικά περιβάλλοντα. Οι μετρικές αξιολόγησης που χρησιμοποιούνται συνήθως περιλαμβάνουν το Average Precision (AP) για διαφορετικές τιμές Intersection over Union (IoU), το οποίο παρέχει μια ολοκληρωμένη εικόνα της απόδοσης σε διαφορετικά επίπεδα ακρίβειας κατάτμησης [37]. Στο πλαίσιο της ιστοπαθολογίας, επιπρόσθετες μετρικές όπως το Dice coefficient, το Hausdorff distance και το Aggregated Jaccard Index (AJI) χρησιμοποιούνται για την αξιολόγηση της ποιότητας κατάτμησης. Αυτές οι μετρικές λαμβάνουν υπόψη τόσο την ακρίβεια της οριοθέτησης όσο και την ικανότητα του συστήματος να διακρίνει μεταξύ διαφορετικών στιγμιότυπων της ίδιας κλάσης.

Η αποτελεσματικότητα κάθε αρχιτεκτονικής εξαρτάται σημαντικά από τον τύπο των δεδομένων και την πολυπλοκότητα του προβλήματος. Για παράδειγμα, σε εικόνες με πολλά μικρά αντικείμενα που επικαλύπτονται, όπως συχνά συμβαίνει με κυτταρικούς πυρήνες στην ιστοπαθολογία, οι προσεγγίσεις που βασίζονται σε cascade αρχιτεκτονικές τείνουν να έχουν καλύτερη απόδοση. Αντίθετα, για μεγαλύτερες ιστικές δομές με σαφώς καθορισμένα όρια, τα παραδοσιακά Mask R-CNN μοντέλα μπορεί να είναι επαρκή και πιο αποδοτικά υπολογιστικά. Ένας σημαντικός παράγοντας που επηρεάζει την επιλογή αρχιτεκτονικής είναι η διαθεσιμότητα εκπαιδευτικών δεδομένων. Οι πιο πολύπλοκες αρχιτεκτονικές απαιτούν μεγαλύτερα σύνολα δεδομένων για να αποφευχθεί η υπερπροσαρμογή, ενώ παράλληλα χρειάζονται περισσότερους υπολογιστικούς πόρους

για την εκπαίδευση. Στην ιστοπαθολογία, όπου η συλλογή και επισημείωση δεδομένων είναι χρονοβόρα και κοστοβόρα διαδικασία, αυτοί οι περιορισμοί αποκτούν ιδιαίτερη σημασία.

### 2.4.8. Εφαρμογή στην Πλατφόρμα Deep-in-Biopsies

Το Detectron2, που αναπτύχθηκε από το Facebook AI Research, αποτελεί ένα από τα πιο εξελιγμένα και ευρέως χρησιμοποιούμενα πλαίσια για την υλοποίηση αλγορίθμων εντοπισμού αντικειμένων και κατάτμησης στιγμιότυπων [38]. Η αρχιτεκτονική του σχεδιάστηκε με στόχο τη μέγιστη ευελιξία και επεκτασιμότητα, επιτρέποντας στους ερευνητές να πειραματιστούν με διαφορετικές αρχιτεκτονικές και τεχνικές χωρίς να χρειάζεται να υλοποιήσουν τα βασικά συστατικά από την αρχή.

Μια από τις βασικές καινοτομίες του Detectron2 είναι η υιοθέτηση μιας modular αρχιτεκτονικής που διαχωρίζει τα διαφορετικά συστατικά ενός μοντέλου εντοπισμού (backbone, neck, head) σε ξεχωριστές και ανεξάρτητες ενότητες. Αυτό επιτρέπει τον εύκολο συνδυασμό διαφορετικών τεχνικών και την ταχεία πρωτοτυποποίηση νέων ιδεών. Επιπλέον, το πλαίσιο περιλαμβάνει προεκπαιδευμένα μοντέλα υψηλής ποιότητας που μπορούν να χρησιμοποιηθούν ως σημείο εκκίνησης για εξειδικευμένες εφαρμογές.

Η υποστήριξη για πολλαπλές GPU και κατανεμημένη εκπαίδευση καθιστά το Detectron2 ιδιαίτερα κατάλληλο για εργασίες που απαιτούν μεγάλους υπολογιστικούς πόρους, όπως η εκπαίδευση μοντέλων με εικόνες υψηλής ανάλυσης. Παράλληλα, η ενσωμάτωση προηγμένων τεχνικών όπως το mixed precision training και οι gradient checkpointing βελτιώνουν σημαντικά την αποδοτικότητα της εκπαίδευσης.

Το πλαίσιο υποστηρίζει επίσης προηγμένες τεχνικές βελτιστοποίησης όπως το automatic mixed precision (AMP), που επιτρέπει την εκπαίδευση μοντέλων με μικτή ακρίβεια FP16/FP32, μειώνοντας σημαντικά τις απαιτήσεις μνήμης και επιταχύνοντας την εκπαίδευση χωρίς σημαντική επίδραση στην τελική απόδοση των μοντέλων (Wu et al., 2019).

Η πλατφόρμα Deep-in-Biopsies υιοθετεί μια καινοτόμα προσέγγιση στην αξιοποίηση πολλαπλών αρχιτεκτονικών συνελικτικών νευρωνικών δικτύων μέσω της ενσωμάτωσης του Detectron2 framework. Αυτή η στρατηγική επιτρέπει στην πλατφόρμα να προσφέρει μια ευρεία γκάμα αλγορίθμων που μπορούν να προσαρμοστούν στις ειδικές απαιτήσεις διαφορετικών ιστοπαθολογικών εφαρμογών(Tsakai et al., 2022).

Η ενσωμάτωση του Detectron2 στην πλατφόρμα επιτρέπει τη δυναμική φόρτωση και εκτέλεση διαφορετικών μοντέλων ανάλογα με τις απαιτήσεις κάθε εφαρμογής. Αυτή η ευελιξία είναι κρίσιμη για την υποστήριξη διαφορετικών τύπων ιστοπαθολογικής ανάλυσης, από τον απλό εντοπισμό κυττάρων μέχρι την πολύπλοκη ανάλυση ιστικών δομών. Συγκεκριμένα, η πλατφόρμα υποστηρίζει πέντε βασικές αρχιτεκτονικές CNN που καλύπτουν το φάσμα από παραδοσιακές two-stage προσεγγίσεις έως σύγχρονες one-stage μεθόδους:

- Faster R-CNN, αποτελεί τη θεμελιώδη αρχιτεκτονική two-stage που εστιάζει αποκλειστικά στον εντοπισμό αντικειμένων μέσω οριοθετικών πλαισίων, προσφέροντας εξαιρετική ακρίβεια εντοπισμού και αποτελώντας τη βάση για πιο εξελιγμένες τεχνικές. Η υψηλή ακρίβειά του το καθιστά ιδανικό για εφαρμογές όπου ο ακριβής εντοπισμός ανατομικών δομών είναι κρίσιμος, όπως η αναγνώριση μιτωτικών κυττάρων ή η μέτρηση κυτταρικής πυκνότητας.
- Mask R-CNN, επεκτείνει τις δυνατότητες του Faster R-CNN προσθέτοντας έναν κλάδο κατάτμησης που δημιουργεί ακριβείς μάσκες σε επίπεδο εικονοστοιχείου για κάθε εντοπισμένο αντικείμενο. Αυτή η αρχιτεκτονική είναι ιδιαίτερα χρήσιμη για εφαρμογές που απαιτούν ακριβή ποσοτικοποίηση ιστικών περιοχών, όπως η μέτρηση του ποσοστού στεάτωσης σε ηπατικά παρασκευάσματα ή η ανάλυση κολλαγόνου σε φλεγμονώδη εντερικά νοσήματα.
- RetinaNet, αντιπροσωπεύει μια σύγχρονη one-stage προσέγγιση που χρησιμοποιεί τη Focal Loss για την αντιμετώπιση του προβλήματος ανισορροπίας κλάσεων που είναι χαρακτηριστικό στον εντοπισμό αντικειμένων [40].Η αρχιτεκτονική του βασίζεται σε ένα Feature Pyramid Network που επιτρέπει τον αποτελεσματικό εντοπισμό αντικειμένων σε πολλαπλές κλίμακες. Στο πλαίσιο της ιστοπαθολογίας, το RetinaNet αποδεικνύεται ιδιαίτερα αποτελεσματικό για τον εντοπισμό σπάνιων κυτταρικών τύπων ή παθολογικών δομών που εμφανίζονται με χαμηλή συχνότητα στα εκπαιδευτικά δεδομένα.
- FCOS (Fully Convolutional One-Stage), εισάγει μια ριζικά διαφορετική προσέγγιση στον εντοπισμό αντικειμένων, απαλλασσόμενο από τη χρήση προκαθορισμένων anchor boxes [41].Αντί αυτού, προβλέπει απευθείας τις συντεταγμένες των οριοθετικών πλαισίων για κάθε εικονοστοιχείο, συνοδευόμενες από ένα "centerness" score που αξιολογεί πόσο κοντά βρίσκεται το εικονοστοιχείο στο κέντρο ενός αντικειμένου. Αυτή η προσέγγιση προσφέρει μεγαλύτερη ευελιξία στον εντοπισμό αντικειμένων με ακανόνιστες μορφές, όπως συχνά συναντώνται στην ιστοπαθολογία.
- Cascade R-CNN, υιοθετεί μια διαδοχική προσέγγιση όπου πολλαπλοί detectors εκπαιδεύονται με προοδευτικά αυστηρότερα κριτήρια IoU. Κάθε στάδιο του cascade χρησιμοποιεί τα αποτελέσματα του προηγούμενου για να βελτιώσει περαιτέρω την ακρίβεια εντοπισμού. Αυτή η αρχιτεκτονική είναι ιδιαίτερα αποτελεσματική σε περιπτώσεις όπου απαιτείται εξαιρετικά υψηλή ακρίβεια στον εντοπισμό, όπως στην ανάλυση κυτταρικών πυρήνων για διαγνωστικούς σκοπούς ή τη μέτρηση μιτωτικής δραστηριότητας.

Η ενσωμάτωση αυτών των αρχιτεκτονικών στην πλατφόρμα Deep-in-Biopsies μέσω του Detectron2 πλαισίου (framework) παρέχει στους χρήστες τη δυνατότητα να επιλέγουν την κατάλληλη προσέγγιση ανάλογα με τις ειδικές απαιτήσεις κάθε εφαρμογής. Παράλληλα, η πλατφόρμα υποστηρίζει τη σύγκριση απόδοσης μεταξύ διαφορετικών αρχιτεκτονικών στα ίδια δεδομένα, επιτρέποντας την αντικειμενική αξιολόγηση και επιλογή της βέλτιστης μεθόδου για κάθε περίπτωση. Αυτή η προσέγγιση εξασφαλίζει ότι η πλατφόρμα μπορεί να προσαρμοστεί σε ένα ευρύ φάσμα κλινικών εφαρμογών, από τη βασική έρευνα μέχρι

την καθημερινή διαγνωστική πρακτική. Επιπλέον, η υποστήριξη πολλαπλών αρχιτεκτονικών επιτρέπει στους χρήστες να αξιοποιήσουν τα πλεονεκτήματα κάθε προσέγγισης και να επιλέξουν τη βέλτιστη λύση για τις συγκεκριμένες απαιτήσεις τους.

### 2.4.9. Μελλοντικές Κατευθύνσεις και Τεχνολογικές Εξελίξεις

Το πεδίο της κατάτμησης στιγμιότυπων εξελίσσεται ραγδαία, με νέες τεχνολογίες και προσεγγίσεις να εμφανίζονται συνεχώς. Μια από τις πιο υποσχόμενες κατευθύνσεις είναι η χρήση τεχνητής νοημοσύνης που μπορεί να μάθει από ελάχιστα παραδείγματα (few-shot learning), κάτι που είναι ιδιαίτερα σημαντικό στην ιστοπαθολογία όπου η συλλογή μεγάλων συνόλων δεδομένων είναι δύσκολη [42]. Οι τεχνικές μετα-μάθησης (meta-learning) και προσαρμογής τομέα (domain adaptation) προσφέρουν τη δυνατότητα γρήγορης προσαρμογής μοντέλων σε νέες παθολογικές καταστάσεις ή διαφορετικά εργαστηριακά πρωτόκολλα. Αυτές οι προσεγγίσεις είναι ιδιαίτερα σημαντικές για σπάνια νοσήματα ή νέες παθολογικές οντότητες όπου η διαθεσιμότητα εκπαιδευτικών δεδομένων είναι περιορισμένη. Η ανάπτυξη μοντέλων που μπορούν να γενικεύσουν από μερικά μόνο παραδείγματα θα μπορούσε να επαναστατήσει τον τρόπο που αντιμετωπίζονται οι διαγνωστικές προκλήσεις στην ψηφιακή παθολογία.

Μια άλλη σημαντική κατεύθυνση είναι η ανάπτυξη τεχνικών που μπορούν να ενσωματώσουν πολυτροπικές πληροφορίες (multimodal information), συνδυάζοντας τις μορφολογικές πληροφορίες από τις ιστοπαθολογικές εικόνες με κλινικά δεδομένα, γενετικές πληροφορίες ή αποτελέσματα από άλλες απεικονιστικές τεχνικές[43]. Αυτή η ολιστική προσέγγιση έχει τη δυνατότητα να βελτιώσει σημαντικά την ακρίβεια και την αξιοπιστία των διαγνωστικών συστημάτων. Η συνδυαστική ανάλυση μορφολογικών και μοριακών χαρακτηριστικών αναμένεται να οδηγήσει σε πιο ακριβείς προγνωστικούς δείκτες και εξατομικευμένες θεραπευτικές προσεγγίσεις. Αυτό είναι ιδιαίτερα σημαντικό στην ογκολογία, όπου η κατανόηση της ετερογένειας των όγκων απαιτεί την ενσωμάτωση πολλαπλών τύπων δεδομένων.

Τέλος, η ανάπτυξη τεχνικών που επιτρέπουν την ερμηνεία και εξήγηση των αποφάσεων των μοντέλων (explainable AI) αποτελεί μια κρίσιμη προτεραιότητα για την αποδοχή αυτών των τεχνολογιών από την ιατρική κοινότητα. Οι τεχνικές attention visualization, gradient-based explanation methods και counterfactual analysis προσφέρουν διαφορετικές προσεγγίσεις για την κατανόηση των αποφάσεων των μοντέλων. Η ανάπτυξη συστημάτων που όχι μόνο παρέχουν ακριβείς προβλέψεις αλλά και εξηγούν τη λογική πίσω από τις αποφάσεις τους είναι απαραίτητη για την οικοδόμηση εμπιστοσύνης μεταξύ των κλινικών ιατρών και των συστημάτων τεχνητής νοημοσύνης. Αυτό είναι ιδιαίτερα σημαντικό σε κρίσιμες διαγνωστικές αποφάσεις όπου η κατανόηση των παραγόντων που επηρεάζουν την πρόβλεψη μπορεί να είναι τόσο σημαντική όσο και η ίδια η πρόβλεψη.

## 2.5. Υπάρχουσες Πλατφόρμες και Εργαλεία

Η ανάπτυξη εργαλείων για την ψηφιακή παθολογία έχει οδηγήσει στη δημιουργία ποικίλων πλατφορμών, οι οποίες προσπαθούν να καλύψουν τις ανάγκες των παθολόγων και των ερευνητών για ανάλυση ιστοπαθολογικών εικόνων. Ωστόσο, η κατάσταση του πεδίου παραμένει κατακερματισμένη, με διαφορετικές λύσεις να επικεντρώνονται σε συγκεκριμένες λειτουργίες χωρίς να προσφέρουν ολοκληρωμένη προσέγγιση. Στην παρούσα ενότητα, εξετάζουμε τρεις από τις πιο αντιπροσωπευτικές πλατφόρμες του χώρου: το QuPath, το Cytomine και το Aiforia, αναλύοντας τις δυνατότητες, τους περιορισμούς και τη συμβολή τους στην εξέλιξη της ψηφιακής παθολογίας.

### 2.5.1. QuPath: Ερευνητικά Προσανατολισμένη Πλατφόρμα Ανοιχτού Κώδικα

Το QuPath αποτελεί μια από τις πιο διαδεδομένες πλατφόρμες ανοιχτού κώδικα για την ανάλυση εικόνων ολικής τομής, αναπτυχθείσα από το Πανεπιστήμιο του Edinburgh με σκοπό να καλύψει κυρίως ερευνητικές ανάγκες [44]. Η φιλοσοφία του QuPath βασίζεται στην παροχή ενός ισχυρού, εύχρηστου εργαλείου που επιτρέπει σε παθολόγους και ερευνητές να εκτελούν σύνθετες αναλύσεις χωρίς να απαιτείται εκτενής προγραμματιστική γνώση. Η αρχιτεκτονική του στηρίζεται στη γλώσσα Java, προσφέροντας υποστήριξη σε πολλαπλές πλατφόρμες και σταθερότητα.

Ένα από τα βασικά πλεονεκτήματα του QuPath είναι η ενσωμάτωση προηγμένων αλγορίθμων για κυτταρική ανίχνευση και κατάτμηση. Το σύστημα υποστηρίζει αλγορίθμους όπως ο StarDist για την ανίχνευση πυρήνων, ενώ παράλληλα επιτρέπει την ενσωμάτωση μοντέλων βαθιάς μάθησης μέσω επεκτάσεων [45]. Οι χρήστες μπορούν να εκτελούν ταξινόμηση βάσει εικονοστοιχείων, ανάλυση βάσει αντικειμένων και κατάτμηση ιστών, καθιστώντας το εργαλείο κατάλληλο για ποικίλες ερευνητικές εφαρμογές.

Το QuPath διαθέτει ένα ισχυρό περιβάλλον σεναρίων που βασίζεται στη Groovy, επιτρέποντας στους χρήστες να αυτοματοποιούν πολύπλοκες εργασίες και να αναπτύσσουν προσαρμοσμένες ροές εργασίας. Αυτή η δυνατότητα είναι ιδιαίτερα πολύτιμη για μελέτες που απαιτούν επεξεργασία μεγάλου αριθμού δειγμάτων με συνεπή μεθοδολογία. Επιπλέον, το σύστημα υποστηρίζει ομαδική επεξεργασία και παρέχει εργαλεία για στατιστική ανάλυση και οπτικοποίηση αποτελεσμάτων.

Ωστόσο, το QuPath παρουσιάζει ορισμένους περιορισμούς όσον αφορά την κλινική εφαρμογή. Η έμφαση στη λειτουργικότητα και την ευελιξία έχει οδηγήσει σε ένα περιβάλλον χρήσης που μπορεί να φαίνεται σύνθετο για χρήστες χωρίς τεχνική εμπειρία. Επιπρόσθετα, η πλατφόρμα δεν παρέχει ενσωματωμένες δυνατότητες για διαχείριση ασθενών, κλινικών δεδομένων ή συμμόρφωση με πρότυπα όπως το DICOM, περιορίζοντας την άμεση εφαρμογή της σε κλινικά περιβάλλοντα [46].

### 2.5.2. Cytomine: Συνεργατική Πλατφόρμα για Σημειοθέτηση και Μηχανική Μάθηση

Το Cytomine αντιπροσωπεύει μια διαφορετική προσέγγιση στην ψηφιακή παθολογία, εστιάζοντας στη συνεργατική ανάλυση και την ενσωμάτωση αλγορίθμων μηχανικής μάθησης [47]. Αναπτυχθείσα από το Πανεπιστήμιο της Liege, η πλατφόρμα σχεδιάστηκε ως διαδικτυακή λύση που επιτρέπει σε πολλαπλούς χρήστες να συνεργάζονται σε πραγματικό χρόνο για την ανάλυση ιστοπαθολογικών εικόνων.

Η αρχιτεκτονική του Cytomine βασίζεται σε μια τμηματική δομή που διαχωρίζει το περιβάλλον παρουσίασης, τη διαχείριση δεδομένων και τις αναλυτικές ενότητες επεξεργασίας εικόνας και μηχανικής μάθησης. Αυτή η δομή επιτρέπει την εύκολη ενσωμάτωση νέων αλγορίθμων και εργαλείων, καθώς επίσης τη δυνατότητα προσαρμογής ανάλογα με τις ανάγκες. Το σύστημα υποστηρίζει διεπαφές προγραμματισμού εφαρμογών, διευκολύνοντας την επικοινωνία με εξωτερικά συστήματα και την ανάπτυξη προσαρμοσμένων εφαρμογών[48].

Ένα από τα ξεχωριστά χαρακτηριστικά του Cytomine είναι η δυνατότητά του να συνδέει δραστηριότητες σημειοθέτησης με ροές εργασίας μηχανικής μάθησης. Οι χρήστες μπορούν να δημιουργήσουν σημειοθετήσεις, να τις χρησιμοποιήσουν για την εκπαίδευση μοντέλων και να εφαρμόσουν τα εκπαιδευμένα μοντέλα σε νέα δεδομένα, όλα μέσα από την ίδια πλατφόρμα. Το σύστημα υποστηρίζει διάφορους τύπους μοντέλων, από κλασικούς αλγορίθμους μηχανικής μάθησης έως σύγχρονα μοντέλα βαθιάς μάθησης.

Η συνεργατική φύση του Cytomine αποτελεί σημαντικό πλεονέκτημα για ερευνητικές ομάδες και εκπαιδευτικές εφαρμογές. Πολλαπλοί χρήστες μπορούν να εργάζονται ταυτόχρονα στο ίδιο έργο, να μοιράζονται σημειοθετήσεις και να συγκρίνουν αποτελέσματα. Το σύστημα παρέχει εργαλεία για την αξιολόγηση της διακύμανσης μεταξύ παρατηρητών και την ποσοτικοποίηση της συμφωνίας μεταξύ των αξιολογητών [49]. Παρά τα πλεονεκτήματά του, το Cytomine αντιμετωπίζει προκλήσεις σχετικά με την απόδοση και την επεκτασιμότητα. Η διαδικτυακή φύση του συστήματος μπορεί να οδηγήσει σε καθυστερήσεις κατά την επεξεργασία μεγάλων εικόνων, ιδιαίτερα όταν πολλαπλοί χρήστες εργάζονται ταυτόχρονα. Επιπρόσθετα, η εγκατάσταση και διαχείριση του συστήματος απαιτεί σημαντικούς τεχνικούς πόρους και εξειδίκευση.

### 2.5.3. Aiforia: Εμπορική Λύση για Κλινική Εφαρμογή

Το Aiforia (πρώην Fimmic) αντιπροσωπεύει την κατηγορία των εμπορικών πλατφορμών που στοχεύουν στην παροχή έτοιμων προς χρήση λύσεων για κλινικά περιβάλλοντα [50]. Αναπτυχθείσα με έμφαση στην εύκολη χρήση και την κλινική αξιοπιστία, η πλατφόρμα προσφέρει ένα ολοκληρωμένο οικοσύστημα για την ανάλυση ιστοπαθολογικών εικόνων, από την εισαγωγή δεδομένων έως την έκδοση αναφορών.

Η αρχιτεκτονική του Aiforia βασίζεται σε υπηρεσίες νέφους, επιτρέποντας στους χρήστες να έχουν πρόσβαση στην πλατφόρμα από οπουδήποτε μέσω περιηγητή διαδικτύου. Αυτή

η προσέγγιση εξαλείφει την ανάγκη για τοπική εγκατάσταση λογισμικού και διαχείριση υλικού, μειώνοντας το κόστος και την πολυπλοκότητα για τα κλινικά ιδρύματα. Το σύστημα παρέχει αυτόματη ενημέρωση και αντιγράφων ασφαλείας, εξασφαλίζοντας τη συνεχή διαθεσιμότητα των υπηρεσιών.

Το Aiforia διαθέτει έναν εκτενή κατάλογο προ-εκπαιδευμένων μοντέλων για διάφορες παθολογικές εφαρμογές, συμπεριλαμβανομένων της ανίχνευσης κακοήθων κυττάρων, της ποσοτικοποίησης ιστικών δομών και της αξιολόγησης ανοσοϊστοχημικών χρώσεων. Αυτοί οι προ-εκπαιδευμένοι αλγόριθμοι έχουν αναπτυχθεί και επικυρωθεί σε μεγάλα σύνολα δεδομένων, προσφέροντας υψηλή ακρίβεια και αξιοπιστία[51]. Η πλατφόρμα επιτρέπει επίσης την ανάπτυξη προσαρμοσμένων μοντέλων μέσω φιλικών προς τον χρήστη περιβαλλόντων που δεν απαιτούν προγραμματιστικές δεξιότητες. Ένα σημαντικό πλεονέκτημα του Aiforia είναι η συμμόρφωσή του με κλινικά πρότυπα και κανονισμούς. Η πλατφόρμα παρέχει ίχνη ελέγχου, ελέγχους πρόσβασης χρηστών και κρυπτογράφηση δεδομένων, απαιτήσεις που είναι κρίσιμες για την κλινική εφαρμογή. Επιπρόσθετα, το σύστημα υποστηρίζει ενσωμάτωση με υπάρχοντα συστήματα πληροφοριών εργαστηρίου και νοσοκομειακά συστήματα πληροφοριών, διευκολύνοντας την ενσωμάτωσή του στις υπάρχουσες κλινικές ροές εργασίας [52].

Ωστόσο, η εμπορική φύση του Aiforia σημαίνει ότι οι χρήστες είναι περιορισμένοι στις λειτουργίες που παρέχει η εταιρεία, χωρίς δυνατότητα τροποποίησης ή επέκτασης του κώδικα. Αυτό μπορεί να αποτελέσει περιορισμό για ερευνητικές εφαρμογές που απαιτούν εξειδικευμένους αλγορίθμους ή μη-τυπικές ροές εργασίας. Επιπλέον, το κόστος της πλατφόρμας μπορεί να είναι απαγορευτικό για μικρότερα ιδρύματα ή ερευνητικές ομάδες με περιορισμένους πόρους.

### 2.5.4. Συγκριτική Ανάλυση και Αξιολόγηση

Συγκρίνοντας τις τρεις πλατφόρμες, παρατηρούμε ότι κάθε μία έχει σχεδιαστεί για διαφορετικούς χρήστες και περιπτώσεις χρήσης. Το QuPath εξυπηρετεί κυρίως την ερευνητική κοινότητα, προσφέροντας ευελιξία και προσαρμοστικότητα με κόστος την πολυπλοκότητα. Το Cytomine επικεντρώνεται στη συνεργατική ανάλυση και την εκπαίδευση, ενώ το Aiforia στοχεύει στην κλινική εφαρμογή με έμφαση στην εύκολη χρήση και τη συμμόρφωση.

Από τεχνική άποψη, και οι τρεις πλατφόρμες υποστηρίζουν την ενσωμάτωση μοντέλων βαθιάς μάθησης, αλλά με διαφορετικές προσεγγίσεις. Το QuPath βασίζεται σε επεκτάσεις και προσαρμοσμένα σενάρια, το Cytomine σε τμηματική αρχιτεκτονική και διεπαφές προγραμματισμού, ενώ το Aiforia προσφέρει προ-κατασκευασμένες λύσεις με περιορισμένες δυνατότητες προσαρμογής [53].

Όσον αφορά την κλινική εφαρμοσιμότητα, το Aiforia προηγείται λόγω της έμφασής του σε κανονιστική συμμόρφωση και κλινική ενσωμάτωση. Ωστόσο, τόσο το QuPath όσο και το Cytomine έχουν αρχίσει να ενσωματώνουν περισσότερες κλινικά προσανατολισμένες λειτουργίες, αν και παραμένουν κυρίως ερευνητικά εργαλεία.

Ένας κοινός περιορισμός όλων των πλατφορμών είναι η έλλειψη ολοκληρωμένης υποστήριξης για τον πλήρη κύκλο ζωής ενός έργου τεχνητής νοημοσύνης στην ψηφιακή παθολογία. Ενώ όλες παρέχουν εργαλεία για σημειοθέτηση και ανάλυση, καμία δεν προσφέρει μια ενοποιημένη λύση που να καλύπτει από την αρχική οργάνωση δεδομένων έως την τελική εφαρμογή και αξιολόγηση των μοντέλων. Αυτό το κενό αποτελεί μια από τις βασικές κινητήριες δυνάμεις για την ανάπτυξη του Deep-in-Biopsies.

### 2.5.5. Νέες Τάσεις και Εμφανιζόμενες Πλατφόρμες

Παράλληλα με τις καθιερωμένες πλατφόρμες, τα τελευταία χρόνια έχουν εμφανιστεί νέες λύσεις που προσπαθούν να καλύψουν συγκεκριμένα κενά του πεδίου. Το MONAI (Medical Open Network for AI) παρέχει ένα πλαίσιο εργασίας για την ανάπτυξη ιατρικών εφαρμογών τεχνητής νοημοσύνης, συμπεριλαμβανομένης της ψηφιακής παθολογίας[54]. Το X-Balloon προσφέρει λύσεις νέφους για σημειοθέτηση και βαθιά μάθηση, εστιάζοντας στην ευκολία χρήσης και την επεκτασιμότητα [55].

Επιπρόσθετα, μεγάλες τεχνολογικές εταιρείες όπως η Google (με την πλατφόρμα τεχνητής νοημοσύνης), η Microsoft (με το Azure Machine Learning) και η Amazon (με το SageMaker) έχουν αρχίσει να προσφέρουν εξειδικευμένες υπηρεσίες για ιατρική απεικόνιση, συμπεριλαμβανομένης της ψηφιακής παθολογίας. Αυτές οι πλατφόρμες προσφέρουν ισχυρή υπολογιστική υποδομή και προηγμένες δυνατότητες τεχνητής νοημοσύνης, αλλά συχνά απαιτούν σημαντική τεχνική εξειδίκευση για την αποτελεσματική χρήση τους.

Παρά την πρόοδο που έχει σημειωθεί, το τοπίο των εργαλείων ψηφιακής παθολογίας παραμένει κατακερματισμένο. Οι περισσότερες λύσεις επικεντρώνονται σε συγκεκριμένες πτυχές της διαδικασίας, όπως τη σημειοθέτηση ή την ανάλυση, χωρίς να προσφέρουν μια ολοκληρωμένη προσέγγιση. Αυτό δημιουργεί την ανάγκη για πλατφόρμες που να ενοποιούν όλες τις φάσεις της ψηφιακής παθολογικής ανάλυσης σε ένα συνεκτικό σύστημα.

## 2.6. Ανάλυση Κενών και Περιορισμών

Η επισκόπηση της βιβλιογραφίας και η ανάλυση των υπαρχουσών πλατφορμών αποκαλύπτει ένα τοπίο με σημαντικές δυνατότητες αλλά και κρίσιμα κενά που εμποδίζουν την πλήρη αξιοποίηση της τεχνητής νοημοσύνης στην ψηφιακή παθολογία. Αυτά τα κενά δεν αφορούν μόνο τεχνικές πτυχές, αλλά εκτείνονται σε θεμελιώδη προβλήματα οργάνωσης, ενοποίησης και κλινικής εφαρμοσιμότητας που απαιτούν ολιστική προσέγγιση. Η παρούσα ενότητα αναλύει συστηματικά αυτούς τους περιορισμούς, κατηγοριοποιώντας τους σε τεχνολογικούς, μεθοδολογικούς, κλινικούς και λειτουργικούς, προκειμένου να οριοθετηθούν οι στόχοι και οι απαιτήσεις για μια ολοκληρωμένη λύση.

### 2.6.1. Τεχνολογικά Κενά και Τεχνικοί Περιορισμοί

Το πρώτο και ίσως σημαντικότερο τεχνολογικό κενό αφορά την έλλειψη ενοποιημένων πλατφορμών που να υποστηρίζουν τον πλήρη κύκλο ζωής ενός έργου τεχνητής νοημοσύνης στην ψηφιακή παθολογία. Οι περισσότερες υπάρχουσες λύσεις επικεντρώνονται σε μεμονωμένες φάσεις της διαδικασίας, όπως τη σημειοθέτηση (QuPath), τη συνεργατική ανάλυση (Cytomine) ή την κλινική εφαρμογή (Aiforia), χωρίς να προσφέρουν μια συνεκτική εμπειρία από την αρχική οργάνωση δεδομένων έως την τελική αξιολόγηση και εφαρμογή των μοντέλων.

Αυτός ο κατακερματισμός οδηγεί σε σημαντικά προβλήματα διαλειτουργικότητας. Οι ερευνητές και οι κλινικοί ιατροί αναγκάζονται να χρησιμοποιούν πολλαπλά εργαλεία, να μεταφέρουν δεδομένα μεταξύ διαφορετικών πλατφορμών και να διαχειρίζονται ασυμβίβαστες μορφές αρχείων. Αυτή η διαδικασία δεν είναι μόνο χρονοβόρα, αλλά εισάγει και κινδύνους απώλειας δεδομένων, σφαλμάτων μετατροπής και απώλειας μεταδεδομένων που είναι κρίσιμα για την αξιοπιστία των αποτελεσμάτων [56].

Ένα δεύτερο σημαντικό τεχνολογικό πρόβλημα είναι η περιορισμένη υποστήριξη για προσαρμοσμένη εκπαίδευση μοντέλων βαθιάς μάθησης. Ενώ πολλές πλατφόρμες προσφέρουν προ-εκπαιδευμένα μοντέλα, η δυνατότητα προσαρμογής αυτών των μοντέλων σε συγκεκριμένες κλινικές ανάγκες ή νέους τύπους δεδομένων παραμένει περιορισμένη. Αυτό είναι ιδιαίτερα προβληματικό στην ιστοπαθολογία, όπου η ποικιλομορφία των ιστικών τύπων, των χρώσεων και των παθολογικών καταστάσεων απαιτεί εξειδικευμένη προσαρμογή των αλγορίθμων.

Επιπρόσθετα, παρατηρείται έλλειψη υποστήριξης για σύγχρονες αρχιτεκτονικές βαθιάς μάθησης. Ενώ τα νευρωνικά δίκτυα εξελίσσονται ραγδαία, με νέες τεχνικές όπως τα Transformers, οι attention mechanisms και οι τεχνικές αντικειμενικής κατάτμησης νέας γενιάς, η ενσωμάτωσή τους στις υπάρχουσες πλατφόρμες καθυστερεί σημαντικά. Αυτό περιορίζει την ικανότητα των ερευνητών να αξιοποιήσουν τις πιο προηγμένες μεθόδους για τα δεδομένα τους [57].

Τέλος, ένα κρίσιμο τεχνολογικό κενό αφορά την έλλειψη κλιμάκωσης και βελτιστοποίησης απόδοσης. Οι περισσότερες πλατφόρμες δεν είναι σχεδιασμένες για να χειρίζονται αποτελεσματικά τεράστιους όγκους δεδομένων ή να αξιοποιούν πλήρως σύγχρονες υπολογιστικές υποδομές όπως οι πολλαπλές κάρτες γραφικών ή οι κατανεμημένοι υπολογισμοί. Αυτό περιορίζει την ικανότητα για εκπαίδευση μεγάλων μοντέλων ή επεξεργασία εκτεταμένων συνόλων δεδομένων.

### 2.6.2. Μεθοδολογικοί Περιορισμοί και Ερευνητικά Κενά

Στο μεθοδολογικό επίπεδο, ένα από τα σημαντικότερα προβλήματα είναι η έλλειψη τυποποιημένων πρωτοκόλλων για την αξιολόγηση και σύγκριση μοντέλων βαθιάς μάθησης στην ιστοπαθολογία. Διαφορετικές μελέτες χρησιμοποιούν διαφορετικά μετρικά, διαφορετικές μεθόδους διαχωρισμού δεδομένων και διαφορετικές τεχνικές

προεπεξεργασίας, καθιστώντας τη σύγκριση αποτελεσμάτων εξαιρετικά δύσκολη[8]. Αυτή η έλλειψη τυποποίησης εμποδίζει την πρόοδο του πεδίου και περιορίζει την ικανότητα των ερευνητών να στηριχθούν σε προηγούμενα έργα.

Ένα δεύτερο σημαντικό μεθοδολογικό πρόβλημα αφορά την έλλειψη τεκμηρίωσης και αναπαραγωγιμότητας. Πολλές ερευνητικές εργασίες παρουσιάζουν εντυπωσιακά αποτελέσματα, αλλά δεν παρέχουν επαρκείς λεπτομέρειες υλοποίησης, παραμέτρους εκπαίδευσης ή ακόμα και πρόσβαση στα δεδομένα που χρησιμοποιήθηκαν. Αυτό καθιστά την επαλήθευση και επέκταση των αποτελεσμάτων εξαιρετικά δύσκολη, παρεμποδίζοντας την επιστημονική πρόοδο [58].

Επιπλέον, παρατηρείται έλλειψη μεθοδολογιών για την αντιμετώπιση της μεροληψίας και της γενίκευσης των μοντέλων. Τα περισσότερα μοντέλα εκπαιδεύονται σε δεδομένα από συγκεκριμένα ιδρύματα ή γεωγραφικές περιοχές, με αποτέλεσμα να παρουσιάζουν μειωμένη απόδοση όταν εφαρμόζονται σε διαφορετικά περιβάλλοντα. Η ανάπτυξη τεχνικών για την αντιμετώπιση αυτής της "μετατόπισης πεδίου" παραμένει ένα ανοιχτό ερευνητικό πρόβλημα που απαιτεί συστηματική προσέγγιση.

Τέλος, υπάρχει έλλειψη μεθοδολογιών για την ερμηνευσιμότητα και εξηγησιμότητα των μοντέλων βαθιάς μάθησης στην ιστοπαθολογία. Ενώ αυτά τα μοντέλα μπορούν να επιτύχουν υψηλή ακρίβεια, η αδυναμία κατανόησης των αποφάσεών τους περιορίζει σημαντικά την κλινική τους αποδοχή. Η ανάπτυξη τεχνικών που να επιτρέπουν στους κλινικούς ιατρούς να κατανοούν και να εμπιστεύονται τις προτάσεις των αλγορίθμων αποτελεί κρίσιμη ανάγκη [59].

### 2.6.3. Κλινικοί Περιορισμοί και Πρακτικά Εμπόδια

Στον κλινικό τομέα, το σημαντικότερο εμπόδιο είναι η έλλειψη ενσωμάτωσης στις υπάρχουσες ροές εργασίας. Τα περισσότερα συστήματα τεχνητής νοημοσύνης αναπτύσσονται ως αυτόνομα εργαλεία που απαιτούν ξεχωριστές διαδικασίες εισαγωγής δεδομένων, ανάλυσης και εξαγωγής αποτελεσμάτων. Αυτό δημιουργεί επιπλέον φόρτο εργασίας για τους κλινικούς ιατρούς και μειώνει την πιθανότητα υιοθέτησης [60].

Ένα δεύτερο σημαντικό πρόβλημα είναι η έλλειψη κλινικής επικύρωσης και διαπίστευσης. Ενώ πολλά συστήματα παρουσιάζουν υψηλές επιδόσεις σε ερευνητικά περιβάλλοντα, η μετάβαση στην κλινική πρακτική απαιτεί εκτεταμένες μελέτες επικύρωσης, κανονιστική έγκριση και συμμόρφωση με πρότυπα ιατρικών συσκευών. Αυτή η διαδικασία είναι χρονοβόρα, δαπανηρή και συχνά αποθαρρύνει τους προγραμματιστές από την επένδυση στην κλινική ανάπτυξη [61].

Επιπρόσθετα, υπάρχει έλλειψη εκπαίδευσης και υποστήριξης για τους κλινικούς χρήστες. Οι παθολόγοι, παρόλο που είναι ειδικοί στη διάγνωση, δεν έχουν απαραίτητα τεχνική γνώση για τη λειτουργία και αξιολόγηση συστημάτων τεχνητής νοημοσύνης. Η απουσία κατάλληλων προγραμμάτων εκπαίδευσης και υποστήριξης περιορίζει την αποτελεσματική αξιοποίηση αυτών των εργαλείων.

Τέλος, σημαντικό εμπόδιο αποτελεί η έλλειψη οικονομικών κινήτρων για την υιοθέτηση νέων τεχνολογιών. Τα συστήματα υγείας συχνά λειτουργούν με περιορισμένους προϋπολογισμούς και αντιστέκονται σε επενδύσεις που δεν προσφέρουν άμεσα μετρήσιμα οφέλη. Η απουσία σαφών μελετών κόστους-οφέλους για τα συστήματα τεχνητής νοημοσύνης στην παθολογία περιορίζει την υιοθέτησή τους [62].

### 2.6.4. Λειτουργικά Κενά και Προκλήσεις Χρηστικότητας

Στο επίπεδο της χρηστικής εμπειρίας, ένα από τα σημαντικότερα προβλήματα είναι η έλλειψη φιλικών προς τον χρήστη περιβαλλόντων που να απλοποιούν τη χρήση προηγμένων τεχνολογιών. Πολλές πλατφόρμες απαιτούν προγραμματιστικές δεξιότητες ή εκτενή τεχνική κατάρτιση, καθιστώντας τες απρόσιτες σε κλινικούς χρήστες που επιθυμούν να επικεντρωθούν στη διαγνωστική εργασία παρά στην τεχνική διαχείριση[63].

Ένα δεύτερο λειτουργικό πρόβλημα αφορά την έλλειψη ευελιξίας στη διαχείριση διαφορετικών τύπων δεδομένων και ροών εργασίας. Οι περισσότερες πλατφόρμες είναι σχεδιασμένες για συγκεκριμένες εφαρμογές και δεν επιτρέπουν εύκολη προσαρμογή σε νέες ανάγκες. Αυτό περιορίζει την ικανότητα των ερευνητών και κλινικών ιατρών να πειραματιστούν με νέες προσεγγίσεις ή να προσαρμόσουν τα εργαλεία στις ιδιαίτερες απαιτήσεις τους.

Επιπλέον, παρατηρείται έλλειψη εργαλείων για συνεργατική εργασία και διαχείριση έργων. Η σύγχρονη έρευνα στην ψηφιακή παθολογία συχνά περιλαμβάνει διεπιστημονικές ομάδες με παθολόγους, μηχανικούς, στατιστικολόγους και άλλους ειδικούς. Η έλλειψη πλατφορμών που να υποστηρίζουν αποτελεσματικά αυτή τη συνεργασία περιορίζει την αποδοτικότητα και την ποιότητα των έργων [64].

Τέλος, υπάρχει έλλειψη εργαλείων για παρακολούθηση και αξιολόγηση της απόδοσης των συστημάτων σε πραγματικό χρόνο. Αφού ένα μοντέλο εφαρμοστεί σε κλινικό περιβάλλον, είναι κρίσιμο να υπάρχει η δυνατότητα παρακολούθησης της απόδοσής του, εντοπισμού πιθανής υποβάθμισης και εκτέλεσης προσαρμογών όταν απαιτείται. Η απουσία τέτοιων μηχανισμών αυξάνει τον κίνδυνο μείωσης της ποιότητας των υπηρεσιών υγείας.

### 2.6.5. Στρατηγικά Κενά και Μακροπρόθεσμες Προκλήσεις

Σε στρατηγικό επίπεδο, ένα από τα σημαντικότερα κενά είναι η έλλειψη ολοκληρωμένου οράματος για το μέλλον της ψηφιακής παθολογίας. Ενώ υπάρχουν πολλές ξεχωριστές πρωτοβουλίες και έργα, απουσιάζει ένας συντονισμένος χάρτης πορείας που να καθορίζει τις προτεραιότητες, τα πρότυπα και τις κοινές υποδομές που χρειάζονται για τη μακροπρόθεσμη ανάπτυξη του πεδίου [65].

Ένα δεύτερο στρατηγικό πρόβλημα αφορά την έλλειψη βιώσιμων μοντέλων χρηματοδότησης για την ανάπτυξη και συντήρηση πλατφορμών ψηφιακής παθολογίας.

Ενώ η αρχική ανάπτυξη μπορεί να χρηματοδοτηθεί μέσω ερευνητικών έργων, η μακροπρόθεσμη συντήρηση, ενημέρωση και υποστήριξη απαιτεί σταθερούς πόρους που συχνά δεν είναι διαθέσιμοι. Αυτό οδηγεί σε εγκατάλειψη πολλών υποσχόμενων έργων μετά την ολοκλήρωση της αρχικής χρηματοδότησης.

Επιπρόσθετα, υπάρχει έλλειψη διεθνών προτύπων και κατευθυντήριων γραμμών για την ανάπτυξη και αξιολόγηση συστημάτων τεχνητής νοημοσύνης στην παθολογία. Αυτό οδηγεί σε ανομοιογένη ποιότητα, περιορισμένη διαλειτουργικότητα και δυσκολίες στην κανονιστική έγκριση. Η ανάπτυξη κοινών προτύπων είναι κρίσιμη για την πρόοδο του πεδίου [66].

Τέλος, ένα κρίσιμο στρατηγικό κενό είναι η έλλειψη επαρκούς ερευνητικής υποδομής για την υποστήριξη μεγάλης κλίμακας μελετών επικύρωσης. Η αξιόπιστη αξιολόγηση των συστημάτων τεχνητής νοημοσύνης απαιτεί πρόσβαση σε μεγάλα, ποικίλα και καλά χαρακτηρισμένα σύνολα δεδομένων, καθώς και υπολογιστικούς πόρους για εκτεταμένες μελέτες. Η έλλειψη τέτοιων υποδομών περιορίζει την ικανότητα του πεδίου να προχωρήσει από πρωτότυπα έργα σε αξιόπιστες κλινικές εφαρμογές.

### 2.6.6. Συνοπτική Αξιολόγηση και Προτεραιότητες

Η ανάλυση των κενών και περιορισμών αποκαλύπτει ότι, παρά την τεράστια πρόοδο που έχει σημειωθεί στην τεχνητή νοημοσύνη για την ιστοπαθολογία, υπάρχουν ακόμη σημαντικά εμπόδια που εμποδίζουν την πλήρη αξιοποίηση αυτών των τεχνολογιών. Αυτά τα εμπόδια δεν είναι μεμονωμένα προβλήματα, αλλά αλληλένδετες προκλήσεις που απαιτούν ολιστική προσέγγιση.

Η ανάπτυξη μιας ολοκληρωμένης πλατφόρμας όπως το Deep-in-Biopsies που προτείνεται σε αυτή τη διατριβή αποτελεί μια σημαντική απόπειρα αντιμετώπισης πολλών από αυτές τις προκλήσεις. Συγκεκριμένα, η πλατφόρμα στοχεύει να αντιμετωπίσει το κενό της ενοποίησης παρέχοντας ένα συνεκτικό περιβάλλον για όλες τις φάσεις ενός έργου τεχνητής νοημοσύνης, από τη σημειοθέτηση έως την αξιολόγηση. Επιπλέον, η εστίαση σε φιλικότητα προς τον χρήστη και κλινική εφαρμοσιμότητα στοχεύει να γεφυρώσει το χάσμα μεταξύ ερευνητικών εργαλείων και πρακτικών κλινικών αναγκών.

Ωστόσο, είναι σημαντικό να αναγνωριστεί ότι καμία μεμονωμένη πλατφόρμα δεν μπορεί να επιλύσει όλα αυτά τα προβλήματα. Η πρόοδο του πεδίου θα απαιτήσει συντονισμένες προσπάθειες από πολλούς φορείς, συμπεριλαμβανομένων ερευνητικών ιδρυμάτων, τεχνολογικών εταιρειών, κανονιστικών αρχών και κλινικών κοινοτήτων. Η παρούσα εργασία επιδιώκει να συνεισφέρει σε αυτήν την ευρύτερη προσπάθεια παρέχοντας μια συγκεκριμένη, πρακτική λύση που μπορεί να χρησιμεύσει ως βάση για περαιτέρω ανάπτυξη και βελτίωση.

# *Κεφάλαιο 3*

## *Ανάλυση απαιτήσεων και σχεδιασμός υλοποίησης*

## 3.1. Ανάλυση Κλινικών Απαιτήσεων και Προδιαγραφών

### 3.1.1. Μελέτη Αναγκών Παθολόγων και Ερευνητών

Η ανάπτυξη μιας αποτελεσματικής πλατφόρμας ψηφιακής παθολογίας απαιτεί σε πρώτη φάση την εις βάθος κατανόηση των αναγκών και των προκλήσεων που αντιμετωπίζει η σύγχρονη κλινική πρακτική. Η συστηματική καταγραφή και ανάλυση των κλινικών απαιτήσεων αποτελεί τη θεμελιώδη βάση για τον ορισμό των λειτουργικών και μη-λειτουργικών προδιαγραφών του συστήματος Deep-in-Biopsies. Η παρούσα ενότητα παρουσιάζει την εκτενή μελέτη που διεξήχθη για την αποτύπωση των πραγματικών αναγκών των παθολόγων και ερευνητών, καθώς και την ανάλυση των τρεχουσών προκλήσεων που χαρακτηρίζουν το πεδίο της ψηφιακής ιστοπαθολογίας.

Η προσέγγιση που υιοθετήθηκε για τη συλλογή και ανάλυση των απαιτήσεων βασίστηκε σε αρχές της μηχανικής λογισμικού και της σχεδίασης συστημάτων που εστιάζουν στον χρήστη (user-centered design). Αυτή η μεθοδολογία εξασφαλίζει ότι το τελικό σύστημα θα ανταποκρίνεται στις πραγματικές ανάγκες των τελικών χρηστών και όχι απλώς στις τεχνικές δυνατότητες που επιτρέπουν οι διαθέσιμες τεχνολογίες [67].

Η διαδικασία συλλογής και ανάλυσης των κλινικών απαιτήσεων βασίστηκε σε μια πολυδιάστατη προσέγγιση που συνδύασε ποιοτικές και ποσοτικές μεθόδους έρευνας. Διεξήχθησαν εις βάθος συνεντεύξεις με παθολόγους διαφορετικών ειδικοτήτων, περιλαμβανομένων παθολογοανατόμων, ερευνητών στον τομέα της ψηφιακής παθολογίας, ειδικών ιατρών και κλινικών ιατρών. Η επιλογή των συμμετεχόντων έγινε με κριτήριο την εκπροσώπηση διαφορετικών επιπέδων εμπειρίας και ειδικότητας, προκειμένου να καλυφθεί το ευρύτερο φάσμα των κλινικών αναγκών. Οι συνεντεύξεις δομήθηκαν γύρω από τέσσερις βασικούς άξονες: α) την καθημερινή κλινική πρακτική και τις τρέχουσες ροές εργασίας, β) τις τεχνολογικές προκλήσεις και περιορισμούς που αντιμετωπίζονται, γ) τις επιθυμητές λειτουργικότητες που θα βελτίωναν την αποδοτικότητα και την ακρίβεια της διάγνωσης, και δ) τις προσδοκίες από μια ολοκληρωμένη πλατφόρμα τεχνητής νοημοσύνης για την ιστοπαθολογία. Παράλληλα με τις συνεντεύξεις, διεξήχθη εκτενής βιβλιογραφική ανασκόπηση των υπαρχουσών λύσεων και των αναφερόμενων προκλήσεων στη σχετική επιστημονική βιβλιογραφία. Αυτή η προσέγγιση εξασφάλισε ότι η ανάλυση των απαιτήσεων λαμβάνει υπόψη τόσο τις τοπικές ανάγκες όσο και τις διεθνείς τάσεις και προκλήσεις του πεδίου.

Οι παθολογοανατόμοι, ως οι κύριοι χρήστες ιστοπαθολογικών εικόνων, εξέφρασαν συγκεκριμένες απαιτήσεις που σχετίζονται με την καθημερινή τους πρακτική. Η πρωταρχική ανάγκη αφορά τη δυνατότητα επισημείωσης ευρημάτων σε προκαθορισμένες κατηγορίες που έχουν οριστεί για κάθε διαγνωστικό πρόβλημα. Οι παθολογοανατόμοι επισήμαναν την ανάγκη για εργαλεία σημειοθέτησης που να είναι ταυτόχρονα ακριβή και εργονομικά, επιτρέποντας γρήγορη και αξιόπιστη οριοθέτηση ανατομικών δομών και παθολογικών περιοχών [68]. Ιδιαίτερη έμφαση δόθηκε στην ανάγκη για υποστήριξη διαφορετικών μορφών σημειώσεων, από απλές γεωμετρικές

μορφές όπως πολύγωνα και έλλειψες, έως πιο σύνθετες τεχνικές όπως η σημασιολογική κατάτμηση. Οι παθολογοανατόμοι τόνισαν επίσης την απαραίτητη ανάγκη για δυνατότητες κατηγοριοποίησης και ταξινόμησης των ευρημάτων σε πραγματικό χρόνο, καθώς αυτό συμβάλλει στη διατήρηση της συνέπειας και της ακρίβειας της διάγνωσης. Μια επιπλέον σημαντική απαίτηση που προέκυψε αφορά την ανάγκη για εργαλεία που να υποστηρίζουν τη διεπιστημονική συνεργασία. Οι παθολογοανατόμοι συχνά χρειάζεται να συνεργάζονται με ειδικούς διαφορετικών κλάδων, και επομένως απαιτούνται εργαλεία που να διευκολύνουν την κοινή χρήση και συζήτηση των ευρημάτων.

Οι ερευνητές στον τομέα της ψηφιακής παθολογίας εξέφρασαν διαφορετικές αλλά συμπληρωματικές ανάγκες. Η κύρια τους απαίτηση αφορά τη δυνατότητα διαχείρισης μεγάλων συνόλων δεδομένων και την εκτέλεση στατιστικών αναλύσεων σε μεγάλη κλίμακα. Οι ερευνητές επισήμαναν την ανάγκη για πρόσβαση σε εργαλεία που επιτρέπουν την εκπαίδευση προσαρμοσμένων μοντέλων μηχανικής μάθησης, την αξιολόγηση της απόδοσής τους και τη σύγκριση διαφορετικών αλγοριθμικών προσεγγίσεων [69]. Ιδιαίτερη σημασία αποδόθηκε στην ανάγκη για διαλειτουργικότητα και δυνατότητα εξαγωγής δεδομένων σε τυποποιημένες μορφές. Οι ερευνητές επιθυμούν να μπορούν να συνδυάζουν δεδομένα από διαφορετικές πηγές και να τα επεξεργάζονται με εξωτερικά εργαλεία ανάλυσης, χωρίς να περιορίζονται από την αρχιτεκτονική της πλατφόρμας. Επιπλέον, εξέφρασαν την ανάγκη για ισχυρά εργαλεία οπτικοποίησης που να επιτρέπουν την εκπόνηση ερευνητικών αναφορών και την παρουσίαση αποτελεσμάτων σε επιστημονικά συνέδρια. Μια κρίσιμη απαίτηση που εντοπίστηκε αφορά την ανάγκη για εργαλεία που να υποστηρίζουν την αναπαραγωγισιμότητα της έρευνας. Οι ερευνητές τόνισαν την σημασία της δυνατότητας καταγραφής και επανάληψης όλων των βημάτων μιας ανάλυσης, καθώς και της διατήρησης λεπτομερών μεταδεδομένων για κάθε πείραμα.

Οι ειδικοί και κλινικοί ιατροί εστίασαν στην ανάγκη για εργαλεία που να υποστηρίζουν την κλινική λήψη αποφάσεων. Η κύρια τους απαίτηση αφορά τη δυνατότητα δημιουργίας νέων ιατρικών προβλημάτων και κατηγοριοποίησης ευρημάτων που να ταιριάζουν στις ειδικές ανάγκες της κλινικής τους πρακτικής. Οι ειδικοί ιατροί επισήμαναν την ανάγκη για πλατφόρμες που να επιτρέπουν την προσαρμογή στις ιδιαίτερες απαιτήσεις κάθε ειδικότητας, από την ογκολογία έως τις φλεγμονώδεις νόσους. Ιδιαίτερη έμφαση δόθηκε στην ανάγκη για εργαλεία υποβοήθησης διάγνωσης που να παρέχουν αξιόπιστες προβλέψεις και να συμβάλλουν στη μείωση των διαγνωστικών σφαλμάτων. Οι κλινικοί ιατροί τόνισαν την ανάγκη για συστήματα που να είναι εύκολα στη χρήση και να ενσωματώνονται απρόσκοπτα στις υπάρχουσες ροές εργασίας, χωρίς να απαιτούν εκτενή τεχνική εκπαίδευση. Επιπλέον, οι κλινικοί ιατροί εξέφρασαν την ανάγκη για εργαλεία που να υποστηρίζουν τη διδακτική διαδικασία και την εκπαίδευση νέων γενεών ιατρών, με δυνατότητες δημιουργίας εκπαιδευτικού υλικού και διαδραστικών μαθημάτων.

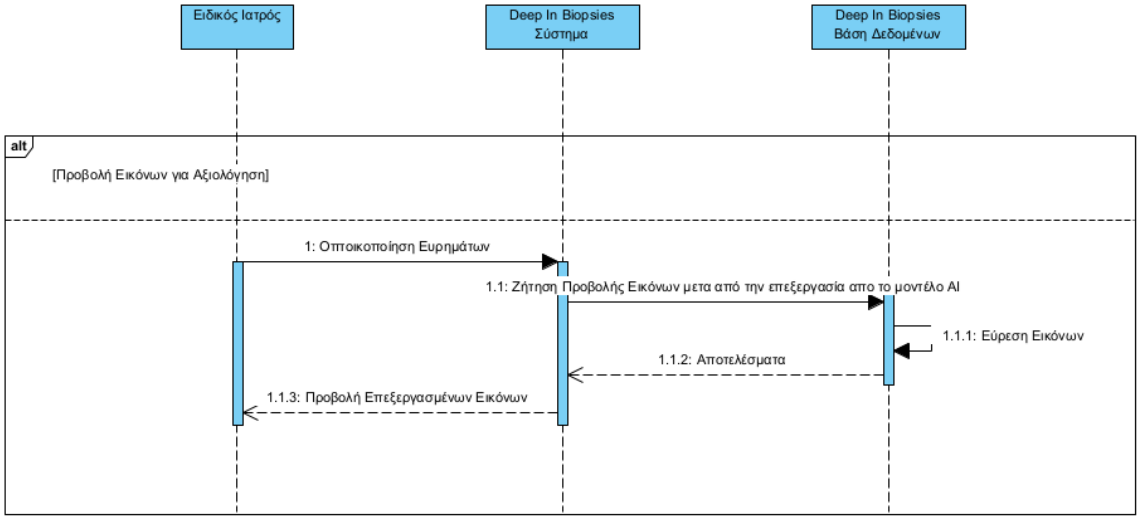


*Διάγραμμα 2. Διάγραμμα ακολουθίας για τις διαδικασίες του ειδικού ιατρού.*

### 3.1.2. Καταγραφή Λειτουργικών και Μη-Λειτουργικών Απαιτήσεων

Βάσει της εις βάθος ανάλυσης των κλινικών αναγκών, καταγράφηκαν οι λειτουργικές απαιτήσεις της πλατφόρμας, οι οποίες αντανακλούν τον διττό χαρακτήρα του κλινικού και ερευνητικού προσανατολισμού. Το σύστημα πρέπει να υποστηρίζει πέντε διακριτούς ρόλους χρηστών: διαχειριστή, παθολογοανατόμο, ερευνητή, ειδικό ιατρό και κλινικό ιατρό. Κάθε ρόλος έχει πρόσβαση σε συγκεκριμένες δυνατότητες της πλατφόρμας και διαθέτει εξειδικευμένα μέσα οπτικοποίησης που ταιριάζουν στις λειτουργικές του ανάγκες [70]. Η πρωταρχική λειτουργική απαίτηση αφορά την αυθεντικοποίηση χρηστών μέσω ασφαλούς συστήματος διαχείρισης ταυτότητας που να συμμορφώνεται με τα διεθνή πρότυπα ασφαλείας για ιατρικά συστήματα. Ο διαχειριστής του συστήματος πρέπει να έχει τη δυνατότητα δημιουργίας registry νέων ιατρικών πεδίων, τα οποία αποτελούν την υψηλότερη οντότητα στη βάση δεδομένων και αφορούν συγκεκριμένα ιατρικά πεδία και ανθρώπινα όργανα. Οι παθολογοανατόμοι και ειδικοί ιατροί πρέπει να μπορούν να δημιουργούν νέα ιατρικά προβλήματα και κατηγοριοποιήσεις ευρημάτων κάτω από την ομπρέλα του αντίστοιχου registry. Όλοι οι κλινικοί ρόλοι (παθολογοανατόμοι, ερευνητές, ειδικοί ιατροί) πρέπει να έχουν τη δυνατότητα εισαγωγής νέων εικόνων στο πλαίσιο των ήδη δημιουργημένων ιατρικών ερωτημάτων, ενώ η επισημείωση ευρημάτων πρέπει να αναλαμβάνεται κυρίως από παθολογοανατόμους λόγω της εξειδίκευσής τους σε αυτή τη διαδικασία.

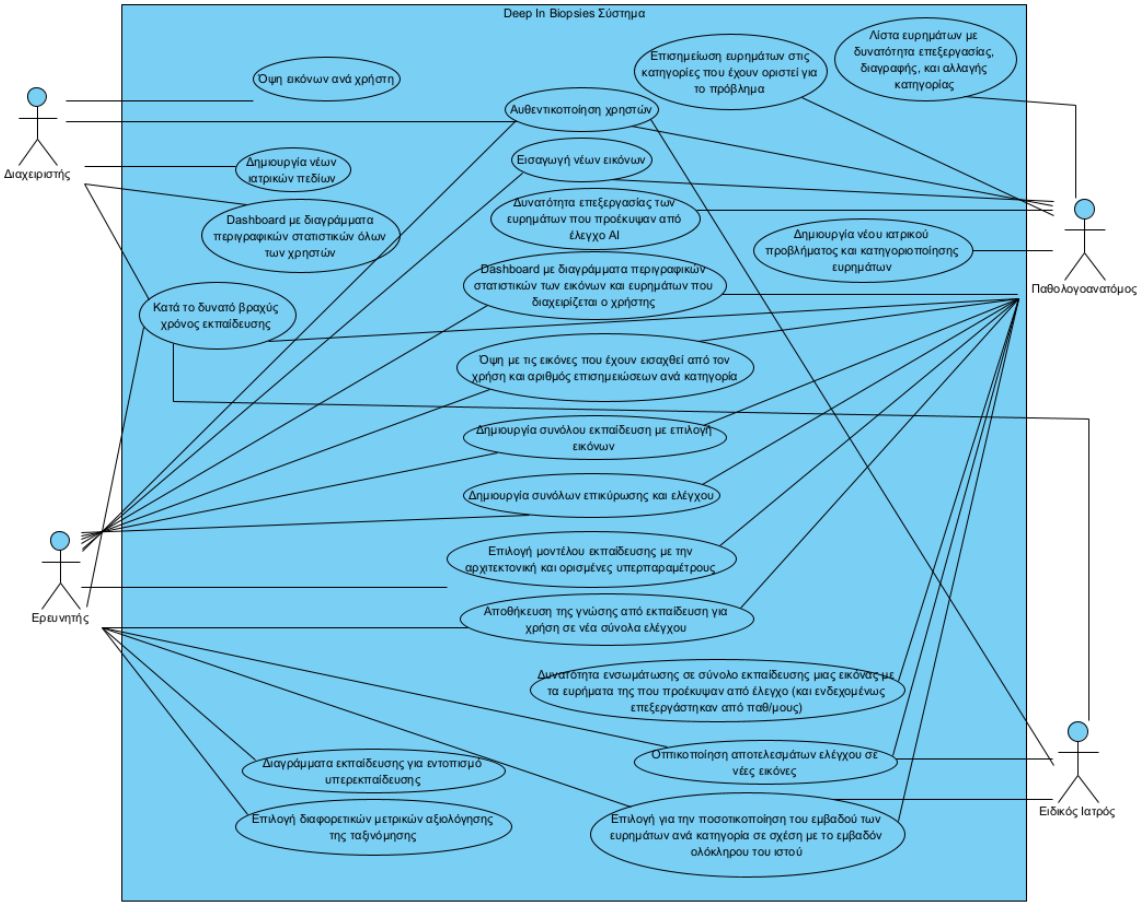


*Διάγραμμα 3. Γενική μελέτη των λειτουργικών απαιτήσεων για την πλατφόρμα*

Το σύστημα πρέπει να υποστηρίζει αυτόματη εκπαίδευση μοντέλων βαθιάς μάθησης με βάση τις εισαγόμενες εικόνες και τις αντίστοιχες σημειώσεις. Αυτή η λειτουργικότητα πρέπει να είναι προσβάσιμη σε παθολογοανατόμους, ερευνητές και ειδικούς ιατρούς, επιτρέποντάς τους να δημιουργούν εξειδικευμένα μοντέλα για τις συγκεκριμένες ανάγκες τους. Η διαδικασία εκπαίδευσης πρέπει να είναι αυτοματοποιημένη στο μεγαλύτερο δυνατό βαθμό, αλλά να παρέχει στους προχωρημένους χρήστες τη δυνατότητα ρύθμισης κρίσιμων παραμέτρων [71] Ιδιαίτερη σημασία έχει η δυνατότητα αυτόματης ανάλυσης νέων εικόνων με τη χρήση εκπαιδευμένων μοντέλων, η οποία πρέπει να παρέχει αξιόπιστες προβλέψεις και να υποστηρίζει την κλινική λήψη αποφάσεων. Το σύστημα πρέπει επίσης να επιτρέπει τη μη αυτόματη επικύρωση των αποτελεσμάτων από εξειδικευμένους χρήστες, διασφαλίζοντας την ποιότητα και την αξιοπιστία των παραγόμενων αναλύσεων. Επιπλέον, η πλατφόρμα πρέπει να υποστηρίζει προηγμένες στατιστικές αναλύσεις και εργαλεία οπτικοποίησης που να επιτρέπουν την εκπόνηση ερευνητικών μελετών και την παραγωγή κλινικών αναφορών. Η δυνατότητα εξαγωγής δεδομένων σε τυποποιημένες μορφές είναι κρίσιμη για τη διασφάλιση της διαλειτουργικότητας με εξωτερικά συστήματα και εργαλεία ανάλυσης.

Οι μη-λειτουργικές απαιτήσεις της πλατφόρμας καθορίζουν τις ποιοτικές παραμέτρους της λειτουργίας του συστήματος και είναι εξίσου κρίσιμες με τις λειτουργικές. Η απόδοση του συστήματος πρέπει να επιτρέπει την επεξεργασία εικόνων υψηλής ανάλυσης σε

λογικούς χρόνους, με την υποστήριξη επιτάχυνσης μέσω γραφικών επεξεργαστών (GPU) να αποτελεί απαραίτητη προϋπόθεση. Ο χρόνος απόκρισης για βασικές λειτουργίες όπως η φόρτωση εικόνων και η εκτέλεση σημειώσεων δεν πρέπει να υπερβαίνει τα 3-5 δευτερόλεπτα, ενώ για πολύπλοκες αναλύσεις με τεχνητή νοημοσύνη ο χρόνος μπορεί να φτάνει τα 15-30 λεπτά ανάλογα με το μέγεθος των δεδομένων. Η κλιμάκωση αποτελεί κρίσιμη μη-λειτουργική απαίτηση, καθώς το σύστημα πρέπει να υποστηρίζει ταυτόχρονα πολλαπλούς χρήστες και να διαχειρίζεται αυξανόμενους όγκους δεδομένων χωρίς υποβάθμιση της απόδοσης. Η αρχιτεκτονική πρέπει να επιτρέπει την οριζόντια κλιμάκωση μέσω προσθήκης επιπλέον υπολογιστικών πόρων, ενώ πρέπει να υποστηρίζει κατανεμημένη επεξεργασία για τη διαχείριση μεγάλων συνόλων δεδομένων. Η ασφάλεια και η προστασία προσωπικών δεδομένων αποτελούν πρωταρχικές μη-λειτουργικές απαιτήσεις, λόγω της ευαίσθητης φύσης των ιατρικών δεδομένων. Το σύστημα πρέπει να συμμορφώνεται με τους κανονισμούς προστασίας δεδομένων (GDPR) και να υλοποιεί κρυπτογράφηση δεδομένων τόσο κατά τη μετάδοση όσο και κατά την αποθήκευση. Η πρόσβαση στα δεδομένα πρέπει να ελέγχεται μέσω ισχυρού συστήματος ελέγχου πρόσβασης βάσει ρόλων, με λεπτομερή καταγραφή όλων των ενεργειών των χρηστών για λόγους διαχείρισης και ελέγχου.

Η διαλειτουργικότητα αποτελεί κρίσιμη απαίτηση για την επιτυχή ενσωμάτωση της πλατφόρμας στα υπάρχοντα κλινικά περιβάλλοντα. Το σύστημα πρέπει να υποστηρίζει τα κύρια πρότυπα ιατρικής απεικόνισης όπως το DICOM, καθώς και ειδικά πρότυπα ψηφιακής παθολογίας όπως το Aperio SVS και το Hamamatsu NDPI. Η δυνατότητα εισαγωγής και εξαγωγής δεδομένων σε τυποποιημένες μορφές όπως OME-TIFF, JSON και XML είναι απαραίτητη για τη διασφάλιση της συμβατότητας με εξωτερικά συστήματα [72]. Το σύστημα πρέπει να παρέχει πλούσια διεπαφή προγραμματισμού εφαρμογών (API) που να επιτρέπει την ενσωμάτωση με εξωτερικά συστήματα διαχείρισης νοσοκομείων (HIS) και συστήματα διαχείρισης εργαστηριακών πληροφοριών (LIS). Η υποστήριξη προτύπων όπως HL7 FHIR είναι επιθυμητή για τη διευκόλυνση της ανταλλαγής δεδομένων με άλλα ιατρικά συστήματα.

### 3.1.3. Ανάλυση Προκλήσεων στην Ψηφιακή Παθολογία

Η ανάλυση των υπαρχουσών προκλήσεων στην ψηφιακή παθολογία αποκαλύπτει σημαντικά τεχνολογικά κενά που περιορίζουν την αποτελεσματική αξιοποίηση της τεχνητής νοημοσύνης στην κλινική πρακτική. Το πρωταρχικό τεχνολογικό πρόβλημα αφορά την έλλειψη ενοποιημένων πλατφορμών που να υποστηρίζουν τον πλήρη κύκλο ζωής ενός έργου τεχνητής νοημοσύνης, από την αρχική οργάνωση δεδομένων έως την τελική κλινική εφαρμογή [73]. Ένα σημαντικό τεχνικό εμπόδιο είναι η πολυπλοκότητα διαχείρισης εικόνων υψηλής ανάλυσης. Οι ψηφιακές ιστοπαθολογικές εικόνες μπορεί να φτάνουν τα gigapixels σε ανάλυση και να ξεπερνούν τα 2 GB σε μέγεθος, δημιουργώντας σημαντικές προκλήσεις στην αποθήκευση, μεταφορά και επεξεργασία. Τα υπάρχοντα συστήματα συχνά αποτυγχάνουν να παρέχουν ομαλή εμπειρία χρήστη κατά την εργασία με τέτοιες εικόνες, οδηγώντας σε υποβάθμιση της παραγωγικότητας. Επιπλέον, παρατηρείται έλλειψη τυποποίησης στα εργαλεία και τις διαδικασίες σημειοθέτησης, με

αποτέλεσμα τη δημιουργία μη συμβατών συνόλων δεδομένων που δεν μπορούν να χρησιμοποιηθούν διαπλατφορμικά. Αυτό περιορίζει δραστικά την αξιοποίηση των επενδύσεων σε σημειοθέτηση και εμποδίζει την ανάπτυξη ολοκληρωμένων λύσεων που να μπορούν να αξιοποιούν δεδομένα από πολλαπλές πηγές.

Σε μεθοδολογικό επίπεδο, ένα από τα σημαντικότερα προβλήματα είναι η έλλειψη τυποποιημένων πρωτοκόλλων για την αξιολόγηση και σύγκριση μοντέλων βαθιάς μάθησης στην ιστοπαθολογία. Η απουσία κοινών μετρικών αξιολόγησης και τυποποιημένων συνόλων δεδομένων καθιστά δύσκολη τη σύγκριση διαφορετικών προσεγγίσεων και περιορίζει την πρόοδο του πεδίου [74]. Ένα επιπλέον μεθοδολογικό πρόβλημα αφορά την επαναληψιμότητα και γενίκευση των αλγορίθμων. Πολλά μοντέλα παρουσιάζουν καλή απόδοση σε εσωτερικά δεδομένα, όμως αποτυγχάνουν όταν δοκιμάζονται σε εξωτερικά δεδομένα που προέρχονται από διαφορετικούς σαρωτές ή ιδρύματα. Αυτό οφείλεται στη μεγάλη ποικιλομορφία των ιστοπαθολογικών εικόνων σε χρωματική παραλλαγή, μορφολογία ιστών και τεχνικά artifacts. Η διαχείριση και σημασιολογική αξιοποίηση των σημειώσεων αποτελεί επίσης σημαντική μεθοδολογική πρόκληση. Τα εργαλεία σημειοθέτησης πρέπει να είναι εργονομικά, διαδραστικά και να υποστηρίζουν πολλαπλούς τύπους σημειώσεων, καθώς η ποιότητα των σημειώσεων καθορίζει σε μεγάλο βαθμό την απόδοση των τελικών αλγορίθμων.

Στο επίπεδο της χρηστικής εμπειρίας, το κύριο πρόβλημα είναι η έλλειψη φιλικών προς τον χρήστη περιβαλλόντων που να απλοποιούν τη χρήση προηγμένων τεχνολογιών. Πολλές πλατφόρμες απαιτούν προγραμματιστικές δεξιότητες ή εκτενή τεχνική κατάρτιση, καθιστώντας τες απρόσιτες σε κλινικούς χρήστες που επιθυμούν να επικεντρωθούν στη διαγνωστική εργασία [75]. Η έλλειψη ευελιξίας στη διαχείριση διαφορετικών τύπων δεδομένων και ροών εργασίας αποτελεί επιπλέον λειτουργικό πρόβλημα. Οι περισσότερες πλατφόρμες είναι σχεδιασμένες για συγκεκριμένες εφαρμογές και δεν επιτρέπουν εύκολη προσαρμογή σε νέες ανάγκες, περιορίζοντας την ικανότητα των ερευνητών και κλινικών ιατρών να πειραματιστούν με νέες προσεγγίσεις. Παρατηρείται επίσης έλλειψη εργαλείων για συνεργατική εργασία και διαχείριση έργων. Η σύγχρονη έρευνα στην ψηφιακή παθολογία συχνά περιλαμβάνει διεπιστημονικές ομάδες με παθολόγους, μηχανικούς, στατιστικολόγους και άλλους ειδικούς, και η έλλειψη πλατφορμών που να υποστηρίζουν αποτελεσματικά αυτή τη συνεργασία περιορίζει την αποδοτικότητα των έργων.

Σε στρατηγικό επίπεδο, ένα από τα σημαντικότερα κενά είναι η έλλειψη ολοκληρωμένου οράματος για το μέλλον της ψηφιακής παθολογίας. Ενώ υπάρχουν πολλές ξεχωριστές πρωτοβουλίες και έργα, απουσιάζει ένας συντονισμένος χάρτης πορείας που να καθορίζει τις προτεραιότητες, τα πρότυπα και τις κοινές υποδομές που χρειάζονται για τη μακροπρόθεσμη ανάπτυξη του πεδίου. Η έλλειψη βιώσιμων μοντέλων χρηματοδότησης για την ανάπτυξη και συντήρηση πλατφορμών ψηφιακής παθολογίας αποτελεί επιπλέον στρατηγικό πρόβλημα. Ενώ η αρχική ανάπτυξη μπορεί να χρηματοδοτηθεί μέσω ερευνητικών έργων, η μακροπρόθεσμη συντήρηση, ενημέρωση και υποστήριξη απαιτεί σταθερούς πόρους που συχνά δεν είναι διαθέσιμοι. Τέλος, υπάρχει έλλειψη διεθνών προτύπων και κατευθυντήριων γραμμών για την ανάπτυξη και αξιολόγηση συστημάτων

τεχνητής νοημοσύνης στην παθολογία. Αυτό οδηγεί σε ανομοιογένη ποιότητα, περιορισμένη διαλειτουργικότητα και δυσκολίες στην κανονιστική έγκριση, με αποτέλεσμα την ανάγκη για ανάπτυξη κοινών προτύπων να είναι κρίσιμη για την πρόοδο του πεδίου. Η συνολική ανάλυση των κλινικών απαιτήσεων και προδιαγραφών αποκαλύπτει την ανάγκη για μια ολοκληρωμένη προσέγγιση που να συνδυάζει τεχνολογική καινοτομία με πρακτική εφαρμοσιμότητα. Η πλατφόρμα Deep-in-Biopsies σχεδιάστηκε για να αντιμετωπίσει συστηματικά τις εντοπισμένες προκλήσεις, παρέχοντας μια ενοποιημένη λύση που καλύπτει τον πλήρη κύκλο ζωής ενός έργου ψηφιακής παθολογίας, από τη σημειοθέτηση έως την κλινική εφαρμογή των αποτελεσμάτων [76].

### 3.1.4 Συγκριτική Ανάλυση της Πλατφόρμας

Η ανάλυση των υπαρχουσών πλατφορμών ψηφιακής παθολογίας αποκαλύπτει ένα κατακερματισμένο τοπίο όπου κάθε λύση εστιάζει σε συγκεκριμένες λειτουργίες χωρίς να προσφέρει ολοκληρωμένη προσέγγιση. Η πλατφόρμα Deep-in-Biopsies σχεδιάστηκε για να καλύψει αυτό το κενό, προσφέροντας μια ενοποιημένη λύση που συνδυάζει τα πλεονεκτήματα των υπαρχουσών συστημάτων. Όπως φαίνεται στον Πίνακα 1, οι διαφορετικές πλατφόρμες παρουσιάζουν ποικίλες δυνατότητες και περιορισμούς [55]:

- Υπηρεσίες Νέφους και Προσβασιμότητα: Το Deep-in-Biopsies, όπως το AIFORIA, υιοθετεί μια αρχιτεκτονική βασισμένη στο νέφος που εξαλείφει την ανάγκη τοπικής εγκατάστασης. Σε αντίθεση με το QuPath που απαιτεί desktop εγκατάσταση, η πλατφόρμα μας προσφέρει άμεση πρόσβαση μέσω περιηγητή, μειώνοντας τις τεχνικές απαιτήσεις για τους τελικούς χρήστες.
- Διαδραστική Σημειοθέτηση: Ενώ όλες οι πλατφόρμες υποστηρίζουν σημειοθέτηση εικόνων, το Deep-in-Biopsies διαφοροποιείται μέσω της ενσωμάτωσης προηγμένων εργαλείων διαδραστικής σημειοθέτησης βασισμένων στο Konva.js. Αυτό επιτρέπει την πραγματικού χρόνου επεξεργασία και την άμεση ανταπόκριση στις ενέργειες του χρήστη, κάτι που δεν προσφέρουν πλήρως οι ανταγωνιστικές λύσεις.
- Ενσωματωμένη Ανίχνευση με Τεχνητή Νοημοσύνη: Το Deep-in-Biopsies προσφέρει ολοκληρωμένη υποστήριξη για instance segmentation μέσω Mask R-CNN, παρόμοια με το AIFORIA. Ωστόσο, σε αντίθεση με τις εμπορικές λύσεις, η πλατφόρμα μας επιτρέπει πλήρη προσαρμογή των αλγορίθμων και την ενσωμάτωση νέων αρχιτεκτονικών μέσω του Detectron2.
- Συνεργατικές Δυνατότητες: Σε αντίθεση με το AIFORIA που περιορίζεται σε μεμονωμένους χρήστες ή μονοκεντρικές εφαρμογές, το Deep-in-Biopsies ενσωματώνει προηγμένες συνεργατικές λειτουργίες που επιτρέπουν την πραγματικού χρόνου συνεργασία πολλών χρηστών στην ίδια εικόνα, παρόμοια με το Cytomine.

| Platform | Cloud Support | Image Annotation | AI Image Detection | Open-Source | Real-Time (Synchronous) Annotation | Retraining Support (fine-tuning models) | DICOM | Collaboration (multi-user sharing) |
|---|---|---|---|---|---|---|---|---|
| **Deep-in-Biopsies** | ✓ | ✓ | ✓ | ✓ | ✗ | ✓ | ✗ | ✓ (Not real-time) |
| **QuPath** | ✗ | ✓ | ✓ (Built-in algorithms for cell/tissue detection and analysis) | ✓ | ✗ | ✓ | ✓ | ✗ |
| **Cytomine** | ✓ | ✓ | ✓ (Supports running ML algorithms for semi-automatic image analysis) | ✓ | ✓ (Supports synchronous multi-user annotation and viewing) | ✗ | ✓ | ✓ |
| **Aiforia** | ✓ | ✓ | ✓ (Offers AI-powered object detection and segmentation tools) | ✗ | ✓ (Interactive *Annotation Assistant* provides real-time AI suggestions while labeling) | ✓ | ✓ | ✗ |
| **PathoBox** | ✓ | ✓ | ✓ | ✗ | ✗ | ✓ | ✓ | ✗ |
| **Slim** | ✓ | ✓ | ✓(via plugin/API) | ✓ | ✗ | ✓ (via integration) | ✓ | ✓ (limited) |

*Πίνακα 1: Σύγκριση του Deep-in-Biopsies image annotator με υπάρχουσες πλατφόρμες.*

| Τεχνολογικά Πλεονεκτήματα | Κλινικές Και Ερευνητικές Εφαρμογές |
|---|---|
| • **Αρθρωτή Αρχιτεκτονική:** Η πλατφόρμα υιοθετεί μια τμηματική αρχιτεκτονική με διακριτές μονάδες (Backend, Annotation Builder, AI Processing) που επικοινωνούν μέσω Socket.IO. Αυτή η προσέγγιση προσφέρει μεγαλύτερη ευελιξία από τις μονολιθικές αρχιτεκτονικές των QuPath και AIFORIA.<br>• **Επεκτασιμότητα και Προσαρμοστικότητα:** Ενώ το QuPath βασίζεται σε επεκτάσεις και το Cytomine σε διεπαφές προγραμματισμού, το Deep-in-Biopsies προσφέρει ενσωματωμένη υποστήριξη για προσαρμοσμένη εκπαίδευση μοντέλων χωρίς την ανάγκη εξωτερικής ανάπτυξης.<br>• **Υποστήριξη Πολλαπλών Μητρώων:** Η δυνατότητα διαχείρισης πολλαπλών ανεξάρτητων μητρώων (registries) με ξεχωριστά μοντέλα και ρυθμίσεις αποτελεί καινοτομία που δεν προσφέρεται από τις υπάρχουσες πλατφόρμες με την ίδια ευελιξία. | • **Επαλήθευση και Αξιοπιστία:** Σε αντίθεση με το AIFORIA που προσφέρει μόνο προ-κατασκευασμένες λύσεις, το Deep-in-Biopsies επιτρέπει την πλήρη διαφάνεια στη διαδικασία εκπαίδευσης και αξιολόγησης των μοντέλων, κάτι που είναι κρίσιμο για ερευνητικές εφαρμογές.<br>• **DICOM Συμβατότητα:** Η πλατφόρμα υποστηρίζει πλήρως το πρότυπο DICOM, σε αντίθεση με το QuPath που έχει περιορισμένη υποστήριξη, επιτρέποντας την άμεση ενσωμάτωση σε κλινικές ροές εργασίας.<br>• **Εκπαίδευση και Fine-tuning Μοντέλων:** Ενώ το AIFORIA παρέχει περιορισμένες δυνατότητες προσαρμογής και το QuPath απαιτεί εξωτερική ανάπτυξη, το Deep-in-Biopsies ενσωματώνει πλήρη υποστήριξη για εκπαίδευση, fine-tuning και αξιολόγηση μοντέλων μέσα στην ίδια πλατφόρμα. |

*Πίνακα 2: Σύγκριση του Deep-in-Biopsies image annotator με υπάρχουσες πλατφόρμες.*

#### 3.1.3.1. Περιορισμοί και Μελλοντικές Κατευθύνσεις

Παρά τα σημαντικά πλεονεκτήματα, το Deep-in-Biopsies, όπως και οι ανταγωνιστικές πλατφόρμες, αντιμετωπίζει προκλήσεις όσον αφορά την κλιμάκωση σε πολύ μεγάλα σύνολα δεδομένων και την πλήρη συμμόρφωση με όλα τα κλινικά πρότυπα. Ωστόσο, η ανοιχτή αρχιτεκτονική και η εστίαση στη διαφάνεια την καθιστούν ιδανική για την συνεχή εξέλιξη και προσαρμογή στις μελλοντικές ανάγκες του πεδίου. Συμπερασματικά, το Deep-in-Biopsies προσφέρει έναν μοναδικό συνδυασμό ολοκληρωμένης λειτουργικότητας, τεχνολογικής καινοτομίας και ερευνητικής διαφάνειας που το διαφοροποιεί από τις υπάρχουσες λύσεις, καλύπτοντας κρίσιμα κενά του τοπίου της ψηφιακής παθολογίας.

## 3.2. Αρχιτεκτονική Συστήματος και Σχεδιαστικές Αρχές

Η σχεδίαση της αρχιτεκτονικής της πλατφόρμας Deep-in-Biopsies αντανακλά μια στρατηγική προσέγγιση που αποσκοπεί στη δημιουργία ενός ισχυρού, επεκτάσιμου και βιώσιμου συστήματος για την ψηφιακή παθολογία. Οι θεμελιώδεις σχεδιαστικές αρχές που καθοδηγούν την ανάπτυξη του συστήματος βασίζονται σε καλά τεκμηριωμένες μεθοδολογίες μηχανικής λογισμικού και προσαρμόζονται στις ειδικές απαιτήσεις της ιατρικής πληροφορικής. Η αρχιτεκτονική σχεδιάστηκε με στόχο την παροχή μιας ολοκληρωμένης λύσης που να καλύπτει τον πλήρη κύκλο ζωής ενός έργου τεχνητής νοημοσύνης στην ιστοπαθολογία, από την αρχική συλλογή και οργάνωση δεδομένων έως την τελική κλινική εφαρμογή και αξιολόγηση των αποτελεσμάτων.

Η συνολική φιλοσοφία σχεδιασμού εμπνέεται από τις αρχές της αρχιτεκτονικής υπηρεσιών (service-oriented architecture) και της τμηματικής ανάπτυξης (modular development), προσαρμοσμένες στο συγκεκριμένο πλαίσιο της ιατρικής πληροφορικής όπως εμφανίζεται και στο Διάγραμμα 4. Αυτή η προσέγγιση εξασφαλίζει ότι το σύστημα μπορεί να εξελίσσεται οργανικά, να προσαρμόζεται σε νέες τεχνολογικές εξελίξεις και να ενσωματώνει πρόσθετες λειτουργικότητες χωρίς να απαιτεί ριζικές αναδιαμορφώσεις της υπάρχουσας υποδομής [77].

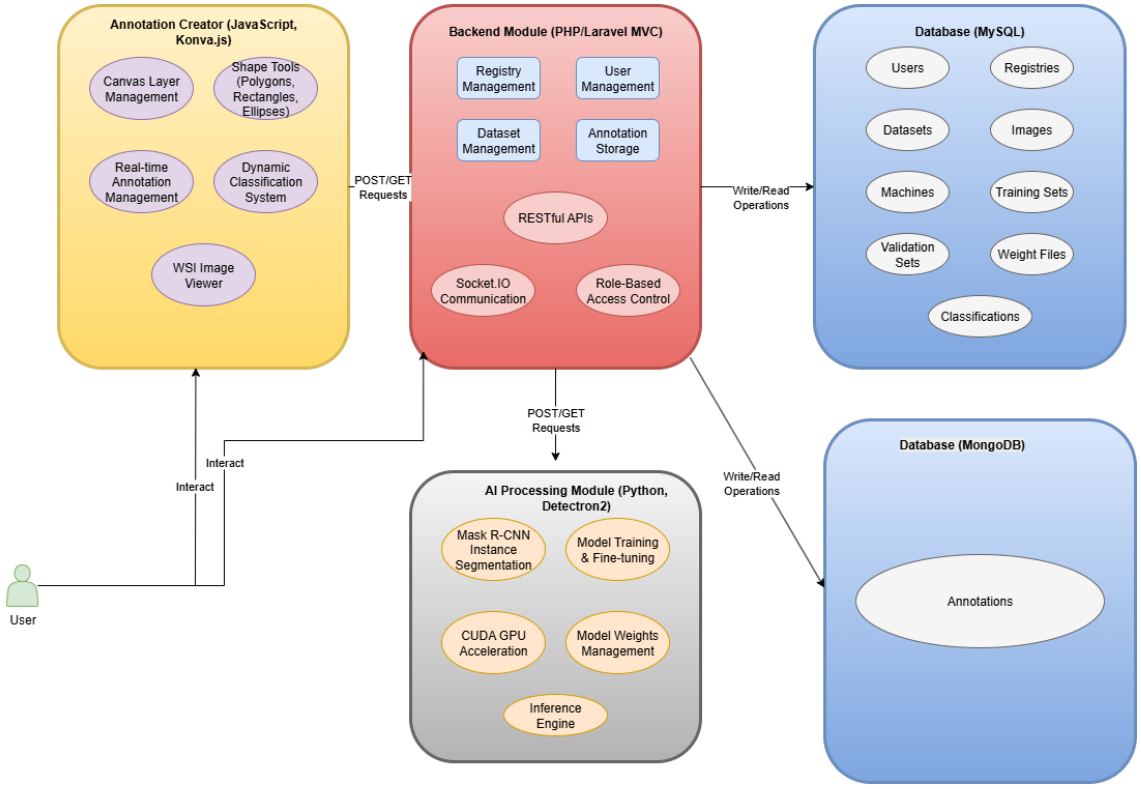


*Διάγραμμα 4. Η συνολική αρχιτεκτονική του συστήματος σε απλή μορφή.*

### 3.2.1. Φιλοσοφία Τμηματικού Σχεδιασμού και Επεκτασιμότητα

Η φιλοσοφία του τμηματικού σχεδιασμού αποτελεί τον πυρήνα της αρχιτεκτονικής της πλατφόρμας και υλοποιείται μέσω της δημιουργίας διακριτών, αυτόνομων μονάδων που επικοινωνούν μέσω καλά καθορισμένων διεπαφών. Αυτή η προσέγγιση επιτρέπει τη δημιουργία ενός συστήματος όπου κάθε μονάδα έχει συγκεκριμένες ευθύνες και λειτουργικότητες, μειώνοντας την πολυπλοκότητα και διευκολύνοντας τη συντήρηση και επέκταση του συστήματος [78]. Η αρθρωτή αρχιτεκτονική διαχωρίζει τις λειτουργίες του συστήματος σε τρεις βασικές κατηγορίες: διαχείριση δεδομένων και επιχειρησιακή λογική (Κεντρική Μονάδα/backend συστήματος), διαδραστικότητα και παρουσίαση (Μονάδα Δημιουργίας Σημειώσεων), και επεξεργασία τεχνητής νοημοσύνης (Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης). Αυτός ο διαχωρισμός επιτρέπει στην κάθε ομάδα ανάπτυξης να εστιάσει σε συγκεκριμένες τεχνολογίες και λειτουργικότητες, ενώ ταυτόχρονα διασφαλίζει ότι οι αλλαγές σε μια μονάδα δεν επηρεάζουν απευθείας τη λειτουργία των άλλων. Η εφαρμογή των αρχών τμηματικού σχεδιασμού έχει ως αποτέλεσμα τη δημιουργία ενός συστήματος με υψηλή συνοχή εντός κάθε μονάδας και χαμηλή σύζευξη μεταξύ των μονάδων. Αυτό σημαίνει ότι κάθε μονάδα μπορεί να αναπτυχθεί, να δοκιμαστεί και να αναπτυχθεί ανεξάρτητα, επιτρέποντας παράλληλη ανάπτυξη και ταχύτερους κύκλους παράδοσης. Επιπλέον, η χαμηλή σύζευξη διευκολύνει την αντικατάσταση ή την αναβάθμιση μεμονωμένων μονάδων χωρίς να επηρεάζεται η συνολική λειτουργία του συστήματος.

Η επεκτασιμότητα αποτελεί κεντρικό στοιχείο της αρχιτεκτονικής και υλοποιείται σε πολλαπλά επίπεδα. Στο τεχνολογικό επίπεδο, κάθε μονάδα σχεδιάστηκε να υποστηρίζει οριζόντια κλιμάκωση μέσω της προσθήκης επιπλέον υπολογιστικών πόρων. Η Κεντρική Μονάδα μπορεί να κλιμακωθεί μέσω τεχνικών εξισορρόπησης φόρτου και κατανεμημένων βάσεων δεδομένων, ενώ η Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης υποστηρίζει κατανεμημένη εκπαίδευση σε πολλαπλές μονάδες επεξεργασίας γραφικών και συστοιχίες υπολογιστών [79]. Η λειτουργική επεκτασιμότητα επιτυγχάνεται μέσω της υποστήριξης για νέους τύπους δεδομένων, αρχιτεκτονικές νευρωνικών δικτύων και αναλυτικές διαδικασίες. Το σύστημα είναι σχεδιασμένο να επιτρέπει την εύκολη ενσωμάτωση νέων αλγορίθμων μηχανικής μάθησης μέσω ενός καλά καθορισμένου πλαισίου επέκτασης που αφαιρεί την πολυπλοκότητα της υποκείμενης υποδομής. Η ευελιξία του συστήματος εκδηλώνεται στη δυνατότητά του να προσαρμόζεται σε διαφορετικές κλινικές ανάγκες και ερευνητικές απαιτήσεις. Η υποστήριξη πολλαπλών καταχωρήσεων δεδομένων επιτρέπει την ταυτόχρονη διαχείριση διαφορετικών ερευνητικών έργων και κλινικών εφαρμογών, ενώ το σύστημα διαχείρισης ρόλων και δικαιωμάτων μπορεί να προσαρμοστεί στις οργανωσιακές δομές διαφορετικών ιδρυμάτων.

Η αρχιτεκτονική υιοθετεί αρχές αποσύνδεσης που επιτρέπουν την ανεξάρτητη εξέλιξη κάθε μονάδας. Κάθε μονάδα αλληλεπιδρά με τις άλλες μέσω καλά καθορισμένων διεπαφών προγραμματισμού εφαρμογών, οι οποίες λειτουργούν ως συμβόλαια που καθορίζουν τις αναμενόμενες εισόδους και εξόδους χωρίς να αποκαλύπτουν λεπτομέρειες υλοποίησης [80]. Η χρήση επιπέδων αφαίρεσης επιτρέπει στους προγραμματιστές να

εστιάζουν στη λογική της εφαρμογής χωρίς να ανησυχούν για τις τεχνικές λεπτομέρειες της υποκείμενης υποδομής. Για παράδειγμα, η Μονάδα Δημιουργίας Σημειώσεων μπορεί να αλληλεπιδρά με τη Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης για να ζητήσει ανάλυση μιας εικόνας, χωρίς να γνωρίζει τις λεπτομέρειες των αλγορίθμων που χρησιμοποιούνται ή την υπολογιστική υποδομή που εκτελεί την επεξεργασία.

### 3.2.2. Στρατηγική Ενσωμάτωσης Πολλαπλών Συστατικών

#### 3.2.2.1. Αρχιτεκτονική Μεσαίων Στρωμάτων

Η ενσωμάτωση των τριών κύριων μονάδων της πλατφόρμας επιτυγχάνεται μέσω ενός εξελιγμένου συστήματος μεσαίων στρωμάτων που διαχειρίζεται την επικοινωνία, την ανταλλαγή δεδομένων και την συγχρονισμό μεταξύ των διαφορετικών συστατικών. Αυτό το στρώμα ενσωμάτωσης λειτουργεί ως κεντρικός διαμεσολαβητής που επιτρέπει στις μονάδες να επικοινωνούν αποδοτικά χωρίς να δημιουργούν άμεσες εξαρτήσεις μεταξύ τους [81]. Το μεσαίο στρώμα υλοποιεί προηγμένα μοτίβα ολοκλήρωσης όπως το Οι τεχνικές προτύπου μεσολαβητή μηνυμάτων (Message Broker pattern) και αρχιτεκτονικής καθοδηγούμενης από συμβάντα (Event-Driven Architecture)., που επιτρέπουν ασύγχρονη επικοινωνία και αποσυζευγμένη λειτουργία των μονάδων. Αυτό είναι ιδιαίτερα σημαντικό σε ένα περιβάλλον όπου οι εργασίες τεχνητής νοημοσύνης μπορεί να διαρκούν από λεπτά έως ώρες, ενώ παράλληλα οι χρήστες εξακολουθούν να αλληλεπιδρούν με το σύστημα για άλλες εργασίες.

#### 3.2.2.2. Πρωτόκολλα Επικοινωνίας και Ανταλλαγής Δεδομένων

Η στρατηγική επικοινωνίας βασίζεται σε υβριδική προσέγγιση που συνδυάζει σύγχρονα και ασύγχρονα πρωτόκολλα ανάλογα με τον τύπο της αλληλεπίδρασης. Για άμεσες αλληλεπιδράσεις χρηστών και μικρούς όγκους δεδομένων, το σύστημα χρησιμοποιεί σύγχρονες διεπαφές προγραμματισμού εφαρμογών (RESTful APIs) που παρέχουν άμεση απόκριση και διαφανή διαχείριση σφαλμάτων. Για μεγάλους όγκους δεδομένων και χρονοβόρες διαδικασίες, το σύστημα υιοθετεί ασύγχρονα πρωτόκολλα επικοινωνίας που επιτρέπουν την εκκίνηση εργασιών και την παρακολούθηση της προόδου τους χωρίς να δεσμεύουν πόρους ή να περιορίζουν την ταυτόχρονη χρήση άλλων λειτουργικοτήτων. Αυτή η προσέγγιση εξασφαλίζει βέλτιστη εμπειρία χρήστη ακόμα και κατά τη διάρκεια εντατικών υπολογιστικών εργασιών. Η ανταλλαγή δεδομένων μεταξύ των μονάδων διέπεται από τυποποιημένα σχήματα που εξασφαλίζουν συμβατότητα και διαλειτουργικότητα. Τα δεδομένα σειριοποιούνται σε μορφές όπως JSON για μεταδεδομένα και εφαρμοζονται εξειδικευμένες τεχνικές συμπίεσης για εικόνες και βαρύ περιεχόμενο, εξασφαλίζοντας αποδοτική μετάδοση χωρίς απώλεια ποιότητας.

#### 3.2.2.3. Διαχείριση Κατάστασης και Συνοχής

Ένα από τα πιο σύνθετα ζητήματα στην ενσωμάτωση πολλαπλών συστατικών είναι η διαχείριση της κατάστασης και η εξασφάλιση της συνοχής των δεδομένων σε ένα κατανεμημένο περιβάλλον. Η πλατφόρμα υιοθετεί στρατηγική eventual consistency που

επιτρέπει στις διαφορετικές μονάδες να λειτουργούν ανεξάρτητα ενώ εξασφαλίζει ότι τελικά όλες οι μονάδες θα συγκλίνουν σε μια συνεπή κατάσταση [82]. Για κρίσιμες λειτουργίες που απαιτούν άμεση συνοχή, το σύστημα υλοποιεί μηχανισμούς συνεργατικής κλειδώματος και τρανζακσιακής επεξεργασίας που εγγυώνται την ακεραιότητα των δεδομένων ακόμα και σε περιπτώσεις αποτυχιών ή διακοπών.

### 3.2.3. Αρχές Κλιμάκωσης και Συντηρησιμότητας

Ο σχεδιασμός της πλατφόρμας λαμβάνει υπόψη τις μελλοντικές ανάγκες κλιμάκωσης τόσο σε επίπεδο χρηστών όσο και σε επίπεδο δεδομένων και υπολογιστικής πολυπλοκότητας. Η στρατηγική κλιμάκωσης βασίζεται σε υβριδική προσέγγιση που συνδυάζει οριζόντια και κάθετη κλιμάκωση ανάλογα με τον τύπο του φόρτου εργασίας και τις διαθέσιμες υπολογιστικές πόρους [83]. Η οριζόντια κλιμάκωση επιτυγχάνεται μέσω της δυνατότητας προσθήκης επιπλέον στιγμιότυπων κάθε μονάδας, ενώ η κάθετη κλιμάκωση υποστηρίζεται μέσω βελτιστοποίησης των υπολογιστικών πόρων και της χρήσης εξειδικευμένου υλικού. Η Κεντρική Μονάδα υποστηρίζει οριζόντια κλιμάκωση μέσω τεχνικών εξισορρόπησης φόρτου που κατανέμουν τα εισερχόμενα αιτήματα σε πολλαπλούς εξυπηρετητές. Η αρχιτεκτονική βασίζεται σε σχεδίαση χωρίς κατάσταση που επιτρέπει την προσθήκη ή αφαίρεση στιγμιότυπων χωρίς επίπτωση στη λειτουργικότητα. Η βάση δεδομένων υποστηρίζει κατανεμημένη αρχιτεκτονική που μπορεί να κλιμακωθεί ανεξάρτητα από τα υπόλοιπα συστατικά. Η Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης εκμεταλλεύεται τις δυνατότητες κατανεμημένης επεξεργασίας για την αντιμετώπιση υπολογιστικά εντατικών εργασιών. Το σύστημα μπορεί να κλιμακωθεί οριζόντια μέσω της προσθήκης επιπλέον μονάδων επεξεργασίας γραφικών ή ολόκληρων υπολογιστικών κόμβων, ενώ η κάθετη κλιμάκωση επιτυγχάνεται μέσω της αναβάθμισης σε ισχυρότερες μονάδες επεξεργασίας ή εξειδικευμένες μονάδες επεξεργασίας τεχνητής νοημοσύνης.

Η βελτιστοποίηση απόδοσης αποτελεί κεντρικό στοιχείο των αρχών κλιμάκωσης και υλοποιείται σε πολλαπλά επίπεδα της αρχιτεκτονικής. Σε επίπεδο δεδομένων, το σύστημα χρησιμοποιεί προηγμένες τεχνικές προσωρινής αποθήκευσης που μειώνουν την ανάγκη για επαναλαμβανόμενη επεξεργασία δεδομένων. Οι εικόνες υψηλής ανάλυσης αποθηκεύονται σε πολλαπλές αναλύσεις που επιτρέπουν την ταχεία εμφάνιση και πλοήγηση [84]. Σε επίπεδο εφαρμογής, το σύστημα υιοθετεί τεχνικές όπως τη βαθμιαία φόρτωση και την ασύγχρονη επεξεργασία που βελτιώνουν την αντιλαμβανόμενη απόδοση από την πλευρά του χρήστη. Οι χρονοβόρες διαδικασίες όπως η εκπαίδευση μοντέλων εκτελούνται ασύγχρονα, επιτρέποντας στους χρήστες να συνεχίσουν τη δουλειά τους ενώ παραλήλως ενημερώνονται για την πρόοδο. Η βελτιστοποίηση της βάσης δεδομένων περιλαμβάνει στρατηγικές ευρετηρίωσης και κατάτμησης που εξασφαλίζουν ταχεία απόκριση ακόμα και με μεγάλους όγκους δεδομένων. Το σύστημα υποστηρίζει επίσης τεχνικές όπως την οριζόντια κατάτμηση βάσης δεδομένων για την οριζόντια κλιμάκωση της αποθήκευσης δεδομένων.

Η συντηρησιμότητα του συστήματος εξασφαλίζεται μέσω της εφαρμογής βέλτιστων πρακτικών ανάπτυξης λογισμικού και της χρήσης αυτοματοποιημένων εργαλείων ανάπτυξης και διαχείρισης. Ο κώδικας οργανώνεται σε σαφώς καθορισμένες δομές με εκτενή τεκμηρίωση και αυτοματοποιημένα τεστ που εξασφαλίζουν την ποιότητα και αξιοπιστία [85]. Η αρχιτεκτονική υποστηρίζει τεχνικές συνεχούς ολοκλήρωσης και συνεχούς ανάπτυξης που επιτρέπουν την ταχεία και ασφαλή ανάπτυξη νέων χαρακτηριστικών και διορθώσεων. Κάθε μονάδα μπορεί να αναπτυχθεί ανεξάρτητα, μειώνοντας τον κίνδυνο διαταραχής άλλων συστατικών κατά τη διάρκεια ενημερώσεων. Η εξελικτικότητα του συστήματος διασφαλίζεται μέσω της χρήσης ανοιχτών προτύπων και εύκολα επεκτάσιμων αρχιτεκτονικών. Νέες λειτουργικότητες μπορούν να προστεθούν χωρίς να επηρεάζουν τις υπάρχουσες, ενώ το σύστημα επέκτασης επιτρέπει την ενσωμάτωση εξωτερικών εργαλείων και υπηρεσιών. Αυτή η προσέγγιση εξασφαλίζει ότι το σύστημα μπορεί να προσαρμοστεί στις εξελισσόμενες ανάγκες της ψηφιακής παθολογίας και να ενσωματώσει νέες τεχνολογικές εξελίξεις. Η διαχείριση εκδόσεων υλοποιείται σε όλα τα επίπεδα του συστήματος, από τον κώδικα εφαρμογής έως τα εκπαιδευμένα μοντέλα τεχνητής νοημοσύνης. Αυτό επιτρέπει την ανίχνευση και αποκατάσταση προβλημάτων, καθώς και την εκτέλεση λειτουργιών επαναφοράς όταν απαιτείται.

Η αρχιτεκτονική ενσωματώνει ολοκληρωμένο σύστημα παρακολούθησης που συλλέγει μετρικές απόδοσης, καταγράφει συμβάντα και παρακολουθεί την υγεία όλων των συστατικών σε πραγματικό χρόνο. Αυτό το σύστημα επιτρέπει την πρόωρη ανίχνευση προβλημάτων, την προληπτική συντήρηση και την βελτιστοποίηση της απόδοσης βάσει πραγματικών δεδομένων χρήσης [86]. Οι διαγνωστικές δυνατότητες περιλαμβάνουν αυτόματη συλλογή και ανάλυση αρχείων καταγραφής, παρακολούθηση πόρων και ειδοποιήσεις για ανώμαλες συμπεριφορές. Αυτές οι πληροφορίες είναι κρίσιμες για τη διατήρηση υψηλής διαθεσιμότητας και την εξασφάλιση βέλτιστης εμπειρίας χρήστη σε περιβάλλον παραγωγής. Η συνολική αρχιτεκτονική της εφαρμογής, όπως περιγράφηκε σε αυτή την ενότητα, αντιπροσωπεύει μια ισορροπημένη προσέγγιση που συνδυάζει καλά τεκμηριωμένες αρχές μηχανικής λογισμικού με τις εξειδικευμένες απαιτήσεις της ψηφιακής παθολογίας. Οι σχεδιαστικές αρχές που υιοθετήθηκαν εξασφαλίζουν ότι το σύστημα μπορεί να αναπτυχθεί, να λειτουργήσει και να εξελιχθεί αποδοτικά σε ένα περιβάλλον που χαρακτηρίζεται από ταχεία τεχνολογική εξέλιξη και συνεχώς αυξανόμενες απαιτήσεις απόδοσης και λειτουργικότητας.

## 3.3. Σχεδιασμός Κεντρικής Μονάδας (Backend Module)

Η Κεντρική Μονάδα αποτελεί τον θεμελιώδη πυρήνα της πλατφόρμας και υλοποιεί τις κρίσιμες λειτουργίες διαχείρισης δεδομένων, επιχειρησιακή λογική και επικοινωνία με τα άλλα συστατικά του συστήματος. Ο σχεδιασμός της μονάδας βασίζεται σε καλά τεκμηριωμένες αρχιτεκτονικές προσεγγίσεις που εξασφαλίζουν κλιμακωσιμότητα, αξιοπιστία και συντηρησιμότητα σε ένα σύνθετο περιβάλλον ιατρικής πληροφορικής. Η επιλογή τεχνολογιών και η δομή της αρχιτεκτονικής αντανακλούν τις ειδικές απαιτήσεις

της ψηφιακής παθολογίας, όπου η ασφάλεια δεδομένων, η απόδοση και η διαλειτουργικότητα αποτελούν πρωταρχικές προϋποθέσεις για την επιτυχή κλινική εφαρμογή.

Η σχεδιαστική φιλοσοφία της Κεντρικής Μονάδας εμπνέεται από τις αρχές του domain-driven design, όπου η δομή του λογισμικού αντικατοπτρίζει στενά τη λογική του ιατρικού τομέα και τις ειδικές ανάγκες της ψηφιακής παθολογίας. Αυτή η προσέγγιση εξασφαλίζει ότι το σύστημα μπορεί να εξελίσσεται παράλληλα με τις αλλάζουσες κλινικές απαιτήσεις και να ενσωματώνει νέες ιατρικές πρακτικές χωρίς ριζικές αρχιτεκτονικές αλλαγές [87].

### 3.3.1. Επιλογή Αρχιτεκτονικής PHP/Laravel MVC

Η επιλογή της αρχιτεκτονικής Αρχιτεκτονικό πρότυπο Μοντέλου-Όψης-Ελεγκτή (Model-View-Controller, MVC) σε συνδυασμό με το πλαίσιο Laravel αποτελεί στρατηγική απόφαση που βασίζεται στις μοναδικές απαιτήσεις της ψηφιακής παθολογίας και τις προκλήσεις που παρουσιάζει η διαχείριση ιστοπαθολογικών δεδομένων. Το πρότυπο MVC παρέχει έναν σαφή διαχωρισμό ευθυνών που είναι κρίσιμος για την ανάπτυξη συστημάτων που χειρίζονται ευαίσθητα ιατρικά δεδομένα, επιτρέποντας ανεξάρτητη ανάπτυξη και δοκιμή κάθε στρώματος της εφαρμογής.

Η επιλογή του Laravel ως βασικό πλαίσιο ανάπτυξης προκύπτει από την ανάλυση των ειδικών απαιτήσεων της ιατρικής πληροφορικής. Το πλαίσιο προσφέρει ισχυρές δυνατότητες στη διαχείριση βάσεων δεδομένων μέσω του Eloquent ORM, προηγμένες τεχνικές ασφάλειας που συμμορφώνονται με τους κανονισμούς προστασίας ιατρικών δεδομένων, και αρχιτεκτονική που υποστηρίζει την ανάπτυξη RESTful APIs για την επικοινωνία με τα άλλα υποσυστήματα της πλατφόρμας.

Η χρήση του PHP ως κύρια γλώσσα ανάπτυξης δικαιολογείται από την ωριμότητα του οικοσυστήματος, την εκτενή υποστήριξη για ιατρικές εφαρμογές και τη διαθεσιμότητα εξειδικευμένων βιβλιοθηκών για την επεξεργασία ιατρικών προτύπων όπως το DICOM. Επιπλέον, η γλώσσα παρέχει εξαιρετικές επιδόσεις για web-based εφαρμογές που χειρίζονται μεγάλους όγκους δεδομένων, κάτι που είναι απαραίτητο για την επεξεργασία ιστοπαθολογικών εικόνων υψηλής ανάλυσης.

Η εφαρμογή του προτύπου MVC στην Κεντρική Μονάδα ακολουθεί μια προσεκτικά σχεδιασμένη δομή που εκμεταλλεύεται πλήρως τις δυνατότητες του Laravel. Το στρώμα Model υλοποιεί τη διαχείριση δεδομένων και την επιχειρησιακή λογική, ενσωματώνοντας σύνθετα μοντέλα για την αναπαράσταση ιατρικών καταχωρήσεων, εικόνων βιοψιών, σημειώσεων και εκπαιδευμένων μοντέλων τεχνητής νοημοσύνης. Κάθε μοντέλο ενσωματώνει προηγμένες τεχνικές επικύρωσης δεδομένων και σχέσεις που αντανακλούν τις πολύπλοκες σχέσεις μεταξύ των ιατρικών οντοτήτων [88].

Το στρώμα View αντιμετωπίζεται μέσω ενός υβριδικού μοντέλου που συνδυάζει παραδοσιακά προτύπα για τη διοικητική διεπαφή με δομημένες απαντήσεις για την επικοινωνία με τα άλλα υποσυστήματα της πλατφόρμας. Αυτή η προσέγγιση επιτρέπει την παροχή μιας πλούσιας διεπαφής διαχείρισης για τους διαχειριστές του συστήματος,

ενώ παράλληλα παρέχει αποδοτικά σημεία πρόσβασης για την επικοινωνία με τα frontend συστατικά. Το στρώμα Controller υλοποιεί τη λογική επεξεργασίας αιτημάτων και τον συντονισμό μεταξύ των Models και Views. Οι Controllers οργανώνονται σε λογικές ομάδες που αντιστοιχούν στις κύριες λειτουργικότητες του συστήματος: διαχείριση χρηστών και ρόλων, διαχείριση καταχωρήσεων και έργων, επεξεργασία εικόνων και σημειώσεων, και συντονισμό με τη Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης.

Η αρχιτεκτονική της Κεντρικής Μονάδας ενσωματώνει σύγχρονες τεχνολογίες για τη δημιουργία διαδραστικών διεπαφών χρήστη που αντιμετωπίζουν τις πολύπλοκες απαιτήσεις της ψηφιακής παθολογίας. Η χρήση προηγμένων πλαισίων για τη δημιουργία αντιδραστικών διεπαφών επιτρέπει την υλοποίηση σύνθετων λειτουργικοτήτων όπως η διαχείριση ουρών εκπαίδευσης σε πραγματικό χρόνο, η δυναμική διαχείριση ρόλων και δικαιωμάτων, και η διαδραστική εμφάνιση εικόνων με δυνατότητες σελιδοποίησης και ταξινόμησης. Αυτή η τεχνολογική επιλογή επιτρέπει την υλοποίηση προηγμένων συστατικών που διαχειρίζονται πολύπλοκες ιατρικές ροές εργασίας, όπως η δημιουργία και επεξεργασία χρηστών με δυνατότητες μεταφόρτωσης αρχείων, η διαχείριση δικαιωμάτων με δυναμική ανάθεση σε χρήστες και ρόλους, και η παρακολούθηση της κατάστασης εργασιών τεχνητής νοημοσύνης σε πραγματικό χρόνο.

### 3.3.2. Σχεδιασμός Βάσης Δεδομένων για Αρχεία και Σημειώσεις

Ο σχεδιασμός της βάσης δεδομένων για την Κεντρική Μονάδα υιοθετεί μια καινοτόμα υβριδική προσέγγιση που συνδυάζει σχεσιακές και document-based βάσεις δεδομένων για την αντιμετώπιση των διαφορετικών απαιτήσεων αποθήκευσης και επεξεργασίας δεδομένων. Η κύρια σχεσιακή βάση δεδομένων διαχειρίζεται τα δομημένα μεταδεδομένα, τις σχέσεις μεταξύ οντοτήτων και τις συναλλακτικές εργασίες που απαιτούν συμμόρφωση με τις αρχές ACID.

Η ενσωμάτωση τεχνολογιών NoSQL για την αποθήκευση μεγάλων όγκων εικόνων, σύνθετων δομών σημειώσεων και μεταδεδομένων που έχουν δυναμικές απαιτήσεις σχήματος αποτελεί στρατηγική επιλογή που αξιοποιεί τα πλεονεκτήματα κάθε τύπου βάσης δεδομένων. Αυτή η διττή προσέγγιση επιτρέπει την αξιοποίηση της ACID συμμόρφωσης και των δυνατοτήτων συνδέσεων των σχεσιακών βάσεων για τα κρίσιμα επιχειρησιακά δεδομένα, και την ευελιξία και κλιμακωσιμότητα των NoSQL βάσεων για τα πολυμεσικά δεδομένα και τις δυναμικές δομές.

Το σχεσιακό τμήμα της βάσης δεδομένων οργανώνεται γύρω από πέντε κύριες οντότητες που αντιπροσωπεύουν τη θεμελιώδη δομή της πλατφόρμας. Η οντότητα registries αποτελεί την υψηλότερη οντότητα στην ιεραρχία και αντιπροσωπεύει τα διαφορετικά ιατρικά πεδία και ανθρώπινα όργανα που υποστηρίζει η πλατφόρμα. Κάθε καταχώρηση περιέχει μεταδεδομένα όπως το όνομα, την περιγραφή, τις υποστηριζόμενες κατηγορίες ταξινόμησης και τις ρυθμίσεις διαμόρφωσης για τα μοντέλα τεχνητής νοημοσύνης.

Η οντότητα projects αναπαριστά τα μεμονωμένα ερευνητικά ή κλινικά έργα που δημιουργούνται εντός κάθε καταχώρησης. Κάθε έργο έχει σχέση ξένου κλειδιού με την

αντίστοιχη καταχώρηση και περιέχει πληροφορίες όπως τον τίτλο, την περιγραφή, τις ημερομηνίες δημιουργίας και τελευταίας ενημέρωσης, καθώς και μεταδεδομένα σχετικά με τις κατηγορίες ταξινόμησης που είναι ενεργές για το συγκεκριμένο έργο.

Η οντότητα users υλοποιεί ένα προηγμένο σύστημα διαχείρισης χρηστών που υποστηρίζει πολλαπλούς τύπους λογαριασμών και λεπτομερή προφίλ χρηστών. Το σχήμα περιλαμβάνει πεδία για προσωπικές πληροφορίες, επαγγελματικά στοιχεία, ειδικότητες και προτιμήσεις διεπαφής, επιτρέποντας την προσαρμογή της εμπειρίας χρήστη βάσει του ρόλου και των αναγκών κάθε ατόμου.

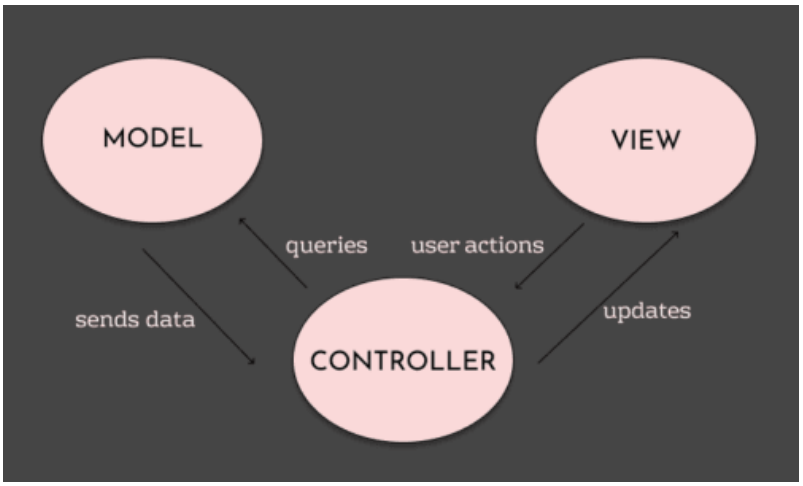


*Διάγραμμα 5. Αρχιτεκτονική του πρότυπου MVC*

Η στρατηγική ενσωμάτωση τεχνολογιών NoSQL αποτελεί καινοτόμο πτυχή του σχεδιασμού που αντιμετωπίζει τις ιδιαίτερες προκλήσεις της αποθήκευσης και διαχείρισης ιστοπαθολογικών εικόνων και σύνθετων δομών σημειώσεων. Η επιλογή document-based αποθήκευσης για αυτά τα δεδομένα επιτρέπει την αποδοτική διαχείριση μεταβλητών σχημάτων δεδομένων που χαρακτηρίζουν τις διαφορετικές τεχνικές σημειοθέτησης και τα πολυεπίπεδα μεταδεδομένα εικόνων [89].

Η υλοποίηση αυτής της υβριδικής προσέγγισης επιτυγχάνεται μέσω προηγμένων τεχνικών ενοποίησης που επιτρέπουν στους προγραμματιστές να χρησιμοποιούν ενιαίο API για την πρόσβαση σε όλα τα δεδομένα, ανεξάρτητα από το υποκείμενο σύστημα αποθήκευσης. Αυτή η αφαίρεση διευκολύνει την ανάπτυξη και συντήρηση του συστήματος, ενώ παράλληλα επιτρέπει την αξιοποίηση των ειδικών πλεονεκτημάτων κάθε τύπου βάσης δεδομένων.

### 3.3.3. Σχεδιασμός Διεπαφών Προγραμματισμού Εφαρμογών

#### 3.3.3.1. Αρχιτεκτονική RESTful Services

Ο σχεδιασμός των διεπαφών προγραμματισμού εφαρμογών (APIs) της Κεντρικής Μονάδας βασίζεται στις αρχές της αρχιτεκτονικής REST, προσαρμοσμένες στις ειδικές ανάγκες της ψηφιακής παθολογίας. Η επιλογή αυτής της αρχιτεκτονικής προσέγγισης

εξασφαλίζει υψηλή διαλειτουργικότητα, κλιμακωσιμότητα και ευκολία συντήρησης, καθιστώντας το σύστημα ικανό να υποστηρίξει πολύπλοκες ροές εργασίας και να ενσωματωθεί με εξωτερικά συστήματα[90]. Οι API endpoints οργανώνονται σε λογικές ομάδες που αντιστοιχούν στις κύριες λειτουργικότητες της πλατφόρμας, περιλαμβάνοντας τη διαχείριση καταχωρήσεων, την επεξεργασία έργων, τη διαχείριση εικόνων και σημειώσεων, τον συντονισμό εργασιών τεχνητής νοημοσύνης και την παροχή αναλυτικών δεδομένων. Κάθε ομάδα endpoints υλοποιεί πλήρη CRUD operations με προηγμένες δυνατότητες φιλτραρίσματος, αναζήτησης και σελιδοποίησης.

#### 3.3.3.2. Μηχανισμοί Αυθεντικοποίησης και Εξουσιοδότησης

Η ασφάλεια των API endpoints εξασφαλίζεται μέσω εξελιγμένου πολυεπίπεδου συστήματος αυθεντικοποίησης και εξουσιοδότησης που ενσωματώνει τις πιο σύγχρονες πρακτικές ασφάλειας για ιατρικές εφαρμογές. Η υλοποίηση αυτή αντιμετωπίζει τις ιδιαίτερες προκλήσεις που παρουσιάζει η διαχείριση ευαισθησίων ιατρικών δεδομένων, συμμορφώνεται με τους διεθνείς κανονισμούς προστασίας δεδομένων και εξασφαλίζει τη διαλειτουργικότητα μεταξύ των διαφορετικών συστατικών της πλατφόρμας. Το σύστημα υιοθετεί το Laravel Sanctum ως κεντρικό μηχανισμό διαχείρισης αυθεντικοποίησης, επιλογή που προσφέρει τη βέλτιστη ισορροπία μεταξύ ασφάλειας και απλότητας υλοποίησης. Το Sanctum ενδείκνυται ιδιαίτερα για εφαρμογές που απαιτούν υποστήριξη τόσο παραδοσιακής session-based αυθεντικοποίησης για web interfaces όσο και token-based αυθεντικοποίησης για API endpoints και μη διαδραστικές εφαρμογές[91]

#### 3.3.3.3. Στρατηγικές Επικοινωνίας σε Πραγματικό Χρόνο

Η υποστήριξη επικοινωνίας σε πραγματικό χρόνο αποτελεί κρίσιμη απαίτηση για την αποδοτική λειτουργία της πλατφόρμας, ιδιαίτερα για την παρακολούθηση της προόδου εργασιών τεχνητής νοημοσύνης και τη συντονισμό πολλαπλών χρηστών. Η αρχιτεκτονική ενσωματώνει προηγμένες τεχνολογίες για τη δημιουργία persistent connections που επιτρέπουν την άμεση μετάδοση ενημερώσεων κατάστασης, προειδοποιήσεων και αποτελεσμάτων επεξεργασίας (48). Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για τη διαχείριση μακροπρόθεσμων εργασιών όπως η εκπαίδευση μοντέλων τεχνητής νοημοσύνης, όπου οι χρήστες χρειάζονται συνεχή ενημέρωση για την πρόοδο χωρίς να απαιτείται επαναφόρτωση της σελίδας ή χειροκίνητη ανανέωση των δεδομένων.

### 3.3.4. Αρχιτεκτονική Ελέγχου Πρόσβασης Βάσει Ρόλων

#### 3.3.4.1. Θεωρητικό Μοντέλο και Σχεδιαστικές Αρχές

Η αρχιτεκτονική ελέγχου πρόσβασης της Κεντρικής Μονάδας βασίζεται σε ένα προηγμένο μοντέλο ελέγχου πρόσβασης βάσει ρόλων (RBAC) που έχει προσαρμοστεί στις ειδικές απαιτήσεις της ψηφιακής παθολογίας. Το μοντέλο αυτό αναγνωρίζει τη σύνθετη φύση των ιατρικών ιεραρχιών και τις διαφορετικές απαιτήσεις πρόσβασης που

έχουν οι διάφοροι ρόλοι στο κλινικό περιβάλλον, από τους διαχειριστές συστήματος έως τους κλινικούς ιατρούς και ερευνητές.

Το σύστημα υποστηρίζει πέντε βασικούς ρόλους χρηστών με διαφορετικά επίπεδα πρόσβασης και δικαιωμάτων: διαχειριστή συστήματος, παθολογοανατόμο, ερευνητή, ειδικό ιατρό και κλινικό ιατρό. Κάθε ρόλος έχει προκαθορισμένα δικαιώματα που αντιστοιχούν στις τυπικές ευθύνες και ανάγκες της αντίστοιχης ειδικότητας, αλλά το σύστημα επιτρέπει επίσης την προσαρμογή και λεπτομερή ρύθμιση αυτών των δικαιωμάτων ανάλογα με τις ειδικές ανάγκες κάθε οργανισμού.

#### 3.3.4.2. Ιεραρχική Δομή Δικαιωμάτων

Η σχεδιαστική προσέγγιση του συστήματος δικαιωμάτων ακολουθεί μια ιεραρχική δομή που αντιστοιχεί στις πραγματικές ροές εργασίας και τις ιεραρχίες ευθύνης στον ιατρικό τομέα. Στο υψηλότερο επίπεδο, οι διαχειριστές συστήματος έχουν πλήρη πρόσβαση σε όλες τις λειτουργίες διαχείρισης και διαμόρφωσης, συμπεριλαμβανομένης της δημιουργίας νέων ιατρικών πεδίων (registries), της διαχείρισης χρηστών και της εποπτείας του συνολικού συστήματος.

Οι παθολογοανατόμοι και ειδικοί ιατροί διαθέτουν εκτεταμένα δικαιώματα στη διαχείριση κλινικού περιεχομένου, με τη δυνατότητα δημιουργίας νέων ιατρικών προβλημάτων και κατηγοριοποιήσεων ευρημάτων εντός των καταχωρήσεων της ειδικότητάς τους. Αυτοί οι ρόλοι μπορούν επίσης να εισάγουν νέες εικόνες και να δημιουργούν σημειώσεις, λειτουργίες που είναι κεντρικές στη διαγνωστική διαδικασία.

Οι ερευνητές έχουν εστιασμένα δικαιώματα που τους επιτρέπουν να διαχειρίζονται ερευνητικά έργα, να εκτελούν αναλύσεις δεδομένων και να αξιοποιούν προηγμένες λειτουργικότητες τεχνητής νοημοσύνης για τη διεξαγωγή μελετών, ενώ οι κλινικοί ιατροί έχουν πρόσβαση κυρίως σε λειτουργίες προβολής και ανάλυσης που υποστηρίζουν την κλινική λήψη αποφάσεων.

#### 3.3.4.3. Δυναμικός Έλεγχος και Προσαρμοστικότητα

Το σύστημα ελέγχου πρόσβασης υλοποιεί προηγμένους μηχανισμούς για δυναμικό έλεγχο δικαιωμάτων που λαμβάνει υπόψη όχι μόνο τον ρόλο του χρήστη αλλά και το πλαίσιο της αίτησης, τη φύση των δεδομένων και τις τρέχουσες συνθήκες του συστήματος. Αυτή η προσέγγιση επιτρέπει την υλοποίηση πολύπλοκων πολιτικών ασφάλειας που μπορούν να προσαρμοστούν σε διαφορετικά κλινικά περιβάλλοντα και οργανωσιακές δομές.

Η αρχιτεκτονική υποστηρίζει επίσης χρονικούς περιορισμούς και προσωρινές εξουσιοδοτήσεις, που είναι ιδιαίτερα χρήσιμες σε κλινικά περιβάλλοντα όπου οι ευθύνες και οι ανάγκες πρόσβασης μπορεί να αλλάζουν δυναμικά βάσει της φάσης ενός έργου ή της διαθεσιμότητας ειδικευμένου προσωπικού.

#### 3.3.4.4. Μηχανισμοί Ελέγχου και Παρακολούθησης

Ένας κρίσιμος στόχος της αρχιτεκτονικής ελέγχου πρόσβασης είναι η διασφάλιση πλήρους ιχνηλασιμότητας και λογοδοσίας για όλες τις ενέργειες που εκτελούνται στο σύστημα. Κάθε προσπάθεια πρόσβασης καταγράφεται με λεπτομερείς πληροφορίες που περιλαμβάνουν την ταυτότητα του χρήστη, τη χρονική στιγμή, τον τύπο της ενέργειας και το αποτέλεσμα της προσπάθειας.

Αυτά τα δεδομένα παρακολούθησης δεν χρησιμεύουν μόνο για λόγους ασφάλειας και συμμόρφωσης, αλλά παρέχουν επίσης πολύτιμες πληροφορίες για την βελτιστοποίηση των ροών εργασίας και την εντόπιση περιοχών όπου απαιτείται επιπλέον εκπαίδευση ή υποστήριξη χρηστών. Το σύστημα υλοποιεί προηγμένες τεχνικές ανάλυσης αυτών των δεδομένων για την αυτόματη ανίχνευση ανωμαλιών και την πρόωρη εντόπιση πιθανών προβλημάτων ασφάλειας.

Η συνολική αρχιτεκτονική της Κεντρικής Μονάδας, όπως περιγράφηκε σε αυτή την ενότητα, αποτελεί μια ολοκληρωμένη λύση που συνδυάζει σύγχρονες τεχνολογίες με καλά τεκμηριωμένες αρχιτεκτονικές αρχές. Η προσεκτική επιλογή τεχνολογιών και η στοχαστική εφαρμογή σχεδιαστικών προτύπων εξασφαλίζουν ότι το σύστημα μπορεί να ανταποκριθεί αποδοτικά στις πολύπλοκες απαιτήσεις της ψηφιακής παθολογίας, διατηρώντας παράλληλα την ευελιξία και επεκτασιμότητα που απαιτείται για μελλοντικές εξελίξεις και προσαρμογές.

## 3.4. Σχεδιασμός Μονάδας Δημιουργίας Σημειώσεων

Η Μονάδα Δημιουργίας Σημειώσεων αποτελεί τον κορμό της αλληλεπίδρασης μεταξύ των κλινικών χρηστών και του συστήματος. Η σωστή σχεδιαστική προσέγγιση αυτής της μονάδας είναι καθοριστική για την επιτυχία της συνολικής πλατφόρμας, καθώς από την ποιότητα και τη διαισθητικότητα του περιβάλλοντος σημειώσεων εξαρτάται άμεσα η αποδοχή της τεχνολογίας από τους παθολόγους και ερευνητές.

Η φιλοσοφία σχεδιασμού βασίζεται στην αρχή της «αόρατης τεχνολογίας», όπου οι πολύπλοκες τεχνικές διαδικασίες παραμένουν κρυφές από τον χρήστη, ενώ η διεπαφή παρουσιάζεται ως φυσική επέκταση της παραδοσιακής παθολογικής εξέτασης. Αυτή η προσέγγιση εξασφαλίζει ότι οι χρήστες μπορούν να εστιάσουν στη διαγνωστική διαδικασία αντί να ασχολούνται με τεχνικές λεπτομέρειες του λογισμικού [92].

### 3.4.1. Απαιτήσεις Διαδραστικού Περιβάλλοντος Σημειώσεων

Το διαδραστικό περιβάλλον σημειώσεων πρέπει να υποστηρίζει ένα ευρύ φάσμα διαδραστικών λειτουργιών που αντιστοιχούν στις ανάγκες της κλινικής πρακτικής. Οι βασικές λειτουργίες περιλαμβάνουν τη δημιουργία γεωμετρικών σχημάτων για την οριοθέτηση περιοχών ενδιαφέροντος, την κατηγοριοποίηση των σημειώσεων σύμφωνα με διαγνωστικά κριτήρια και τη δυνατότητα προσθήκης περιγραφικών σχολίων [93]. Η

σχεδιαστική προσέγγιση πρέπει να εξασφαλίζει ότι όλες οι διαδραστικές λειτουργίες είναι προσβάσιμες μέσω διαισθητικών χειρονομιών που αντιστοιχούν στις παραδοσιακές πρακτικές εξέτασης. Για παράδειγμα, η δημιουργία μιας περιγραφής περιοχής πρέπει να μοιάζει με τη διαδικασία που ακολουθεί ένας παθολόγος όταν περικυκλώνει μια περιοχή σε ένα φυσικό παρασκεύασμα. Εκτός από τις βασικές διαδραστικές λειτουργίες, το σύστημα πρέπει να υποστηρίζει προηγμένες δυνατότητες όπως την ταυτόχρονη επιλογή πολλαπλών σημειώσεων για μαζικές επεξεργασίες, τη δημιουργία συνδέσμων μεταξύ σχετιζόμενων σημειώσεων και την υποστήριξη undo/redo λειτουργιών με απεριόριστο βάθος. Αυτές οι προηγμένες λειτουργίες αποτελούν κρίσιμα στοιχεία για την αύξηση της παραγωγικότητας και την μείωση των λαθών κατά τη διάρκεια εκτενών περιόδων annotation.

Ο σχεδιασμός πρέπει να λαμβάνει υπόψη τις εργονομικές ανάγκες των χρηστών που εργάζονται για εκτεταμένες περιόδους με το σύστημα. Αυτό περιλαμβάνει τη υποστήριξη διαφορετικών μεθόδων εισαγωγής, όπως το ποντίκι, το touchpad και τα graphics tablets, καθώς και τη δυνατότητα προσαρμογής του μεγέθους των διαδραστικών στοιχείων ανάλογα με τις προτιμήσεις του χρήστη και το μέγεθος της οθόνης. Η προσβασιμότητα αποτελεί επίσης κρίσιμη σχεδιαστική απαίτηση, με υποστήριξη για screen readers, keyboard navigation και high-contrast θέματα για χρήστες με προβλήματα όρασης. Το σύστημα πρέπει να συμμορφώνεται με τα διεθνή πρότυπα προσβασιμότητας WCAG 2.1 AA level, εξασφαλίζοντας ότι είναι χρησιμοποιήσιμο από το ευρύτερο δυνατό φάσμα χρηστών.

Τα ιστοπαθολογικά δεδομένα χαρακτηρίζονται από την ανάγκη εξέτασης σε πολλαπλά επίπεδα μεγέθυνσης, από panoramic views όλου του παρασκευάσματος έως εξαιρετικά λεπτομερείς εξετάσεις σε κυτταρικό επίπεδο. Το σύστημα σχεδιασμού πρέπει να εξασφαλίζει ότι οι σημειώσεις διατηρούν τη σχετική τους θέση και κλίμακα σε όλα τα επίπεδα μεγέθυνσης, ενώ παράλληλα προσαρμόζεται η οπτική τους αναπαράσταση για βέλτιστη ορατότητα. Αυτή η απαίτηση δημιουργεί σημαντικές τεχνικές προκλήσεις, καθώς το σύστημα πρέπει να διαχειρίζεται δυναμικά τη λεπτομέρεια των σημειώσεων ανάλογα με το επίπεδο zoom. Σε χαμηλές μεγεθύνσεις, οι μικρές σημειώσεις πρέπει να απλοποιούνται ή να ομαδοποιούνται για να αποφεύγεται η οπτική σύγχυση, ενώ σε υψηλές μεγεθύνσεις πρέπει να εμφανίζονται όλες οι λεπτομέρειες.

Μια κρίσιμη σχεδιαστική απαίτηση αφορά την ανταπόκριση του συστήματος σε πραγματικό χρόνο. Οι χρήστες πρέπει να βιώνουν άμεση ανταπόκριση σε κάθε αλληλεπίδραση, με χρόνους απόκρισης που δεν υπερβαίνουν τα 100 χιλιοστά του δευτερολέπτου για βασικές λειτουργίες όπως η κίνηση ή η επιλογή στοιχείων [94]. Το σύστημα πρέπει να διατηρεί την ίδια απόδοση ανεξάρτητα από τον αριθμό των υπαρχουσών σημειώσεων στην εικόνα. Αυτή η απαίτηση δημιουργεί σημαντικές σχεδιαστικές προκλήσεις, καθώς ορισμένες ιστοπαθολογικές εικόνες μπορεί να περιέχουν χιλιάδες σημειώσεις, ιδιαίτερα σε περιπτώσεις αυτόματης ανάλυσης κυττάρων ή πυρήνων. Για την επίτευξη αυτών των στόχων απόδοσης, το σύστημα πρέπει να υιοθετεί προηγμένες τεχνικές βελτιστοποίησης όπως το spatial indexing για την ταχεία εύρεση σημειώσεων σε συγκεκριμένες περιοχές, το level-of-detail rendering που προσαρμόζει

την πολυπλοκότητα των σημειώσεων ανάλογα με το zoom level, και το frustum culling που αποφεύγει την επεξεργασία στοιχείων εκτός του ορατού πεδίου. Επιπρόσθετα, η απόδοση πρέπει να διατηρείται ακόμα και κατά τη διάρκεια πολύπλοκων λειτουργιών όπως η ταυτόχρονη μετακίνηση εκατοντάδων σημειώσεων ή η εφαρμογή φίλτρων σε μεγάλα σύνολα δεδομένων. Αυτό απαιτεί έξυπνους αλγορίθμους batch processing και asynchronous operations που διαχωρίζουν τις βαριές υπολογιστικές εργασίες από το user interface thread.

Η σύγχρονη κλινική πρακτική απαιτεί συχνά συνεργασία μεταξύ πολλών ειδικών, δημιουργώντας την ανάγκη για προηγμένες δυνατότητες collaborative annotation. Το σύστημα πρέπει να υποστηρίζει ταυτόχρονη εργασία πολλαπλών χρηστών στην ίδια εικόνα, με πραγματικού χρόνου συγχρονισμός των αλλαγών και οπτικές ενδείξεις για την παρουσία και δραστηριότητα άλλων χρηστών. Αυτή η απαίτηση εισάγει πολύπλοκες σχεδιαστικές προκλήσεις σχετικά με τη διαχείριση συγκρούσεων, την επίλυση ταυτόχρονων επεξεργασιών της ίδιας σημείωσης και τη διατήρηση consistency στα δεδομένα. Το σύστημα πρέπει να παρέχει μηχανισμούς conflict resolution που είναι διαφανείς στους χρήστες αλλά εξασφαλίζουν την ακεραιότητα των δεδομένων. Επιπλέον, πρέπει να υπάρχει δυνατότητα ελέγχου πρόσβασης σε granular επίπεδο, επιτρέποντας σε διαφορετικούς χρήστες διαφορετικά επίπεδα δικαιωμάτων (μόνο ανάγνωση, επεξεργασία, διαγραφή) για συγκεκριμένες κατηγορίες σημειώσεων ή περιοχές της εικόνας.

Η διαγνωστική ακρίβεια απαιτεί ότι κάθε σημείωση πρέπει να αντιστοιχεί με ακρίβεια στις συγκεκριμένες ανατομικές δομές της εικόνας. Αυτό σημαίνει ότι το σύστημα σχεδιασμού πρέπει να υποστηρίζει pixel-level ακρίβεια στην τοποθέτηση και προσαρμογή των σημειώσεων, ενώ παράλληλα πρέπει να παρέχει εργαλεία για την εξασφάλιση της ακρίβειας αυτής [95]. Η ιχνηλασιμότητα αποτελεί επίσης κρίσιμη απαίτηση, καθώς κάθε σημείωση πρέπει να συνοδεύεται από μεταδεδομένα που καταγράφουν τον χρήστη που τη δημιούργησε, την ημερομηνία και ώρα δημιουργίας, τυχόν τροποποιήσεις και το ιστορικό των αλλαγών. Η ακρίβεια της σημειοθέτησης πρέπει να διατηρείται ακόμα και κάτω από συνθήκες περιορισμένης ορατότητας ή δυσκολίας στη διάκριση των δομών. Για το σκοπό αυτό, το σύστημα πρέπει να παρέχει βοηθητικά εργαλεία όπως magnification lenses, contrast enhancement filters και edge detection overlays που διευκολύνουν την ακριβή τοποθέτηση των σημειώσεων χωρίς να αλλοιώνουν την υποκείμενη εικόνα. Επιπρόσθετα, πρέπει να υπάρχουν μηχανισμοί validation που ελέγχουν την consistency των σημειώσεων και ειδοποιούν τους χρήστες για πιθανά προβλήματα όπως overlapping annotations, ασυνεπείς κατηγοριοποιήσεις ή σημειώσεις που βρίσκονται εκτός των ορίων της εικόνας.

Κάθε σημείωση πρέπει να υποστηρίζει εκτενή metadata που επιτρέπουν όχι μόνο την περιγραφή των γεωμετρικών χαρακτηριστικών αλλά και τον σημασιολογικό εμπλουτισμό με κλινικές πληροφορίες. Αυτό περιλαμβάνει την ικανότητα σύνδεσης με εξωτερικά συστήματα κλινικής ταξινομίας όπως το SNOMED CT ή το ICD-11, επιτρέποντας την παραγωγή standardized diagnostic reports. Το σύστημα πρέπει να υποστηρίζει structured data entry μέσω customizable forms που προσαρμόζονται στις ιδιαίτερες ανάγκες κάθε

διαγνωστικού πεδίου. Αυτά τα forms πρέπει να περιλαμβάνουν δυνατότητες όπως controlled vocabularies, validation rules και auto-completion για τη διευκόλυνση της εισαγωγής και τη διασφάλιση της συνέπειας. Επιπλέον, πρέπει να υπάρχει δυνατότητα linking μεταξύ σημειώσεων για τη δημιουργία σύνθετων διαγνωστικών αφηγημάτων. Αυτό περιλαμβάνει την ικανότητα δημιουργίας hierarchical relationships (π.χ. parent-child σχέσεις μεταξύ τμημάτων και υπο-δομών) και lateral relationships (π.χ. συσχετίσεις μεταξύ παρόμοιων ευρημάτων σε διαφορετικές περιοχές).

### 3.4.2. Επιλογή Τεχνολογίας JavaScript/Konva.js

#### 3.4.2.1. Στρατηγική Επιλογής Τεχνολογικής Πλατφόρμας

Η επιλογή τεχνολογικής πλατφόρμας για την ανάπτυξη της Μονάδας Δημιουργίας Σημειώσεων βασίστηκε σε μια συστηματική αξιολόγηση των διαθέσιμων επιλογών και των απαιτήσεων του συστήματος. Οι κύριοι παράγοντες που εξετάστηκαν περιελάμβαναν την απόδοση για γραφικές εφαρμογές, τη συμβατότητα με διαφορετικά λειτουργικά συστήματα και φυλλομετρητές, την ευκολία ενσωμάτωσης με άλλα συστατικά και τη διαθεσιμότητα κοινότητας προγραμματιστών και τεκμηρίωσης [96].

Η JavaScript επιλέχθηκε ως βασική γλώσσα ανάπτυξης λόγω της καθολικής υποστήριξής της από τους web browsers και της δυνατότητας ανάπτυξης cross-platform εφαρμογών χωρίς την ανάγκη επιπλέον εγκαταστάσεων. Αυτή η επιλογή εξασφαλίζει ότι η πλατφόρμα μπορεί να χρησιμοποιηθεί σε οποιοδήποτε σύγχρονο υπολογιστικό περιβάλλον χωρίς περιορισμούς λειτουργικού συστήματος.

Η στρατηγική επιλογή της JavaScript εξυπηρετεί επίσης την ευρύτερη αρχιτεκτονική της πλατφόρμας, καθώς επιτρέπει seamless integration με το PHP/Laravel backend μέσω RESTful APIs και JSON data structures. Αυτή η τεχνολογική συνοχή μειώνει την πολυπλοκότητα του συστήματος και διευκολύνει την ανάπτυξη και συντήρηση. Επιπλέον, η επιλογή της JavaScript επιτρέπει την αξιοποίηση του εκτεταμένου οικοσυστήματος βιβλιοθηκών και εργαλείων που είναι διαθέσιμο για web development, συμπεριλαμβανομένων εργαλείων για testing, debugging, performance monitoring και code optimization.

#### 3.4.2.2. Συγκριτική Ανάλυση Τεχνολογικών Εναλλακτικών

Πριν την τελική επιλογή της JavaScript/Konva.js, διεξήχθη λεπτομερής συγκριτική ανάλυση εναλλακτικών τεχνολογικών λύσεων. Εξετάστηκαν native desktop applications βασισμένες σε frameworks όπως Qt ή Electron, web-based λύσεις χρησιμοποιώντας WebGL και Canvas APIs, και hybrid προσεγγίσεις που συνδυάζουν web technologies με native components.

Οι native desktop εφαρμογές παρουσίαζαν πλεονεκτήματα σε απόδοση και πρόσβαση σε system resources, αλλά δημιουργούσαν σημαντικά εμπόδια στη διανομή και εγκατάσταση, ιδιαίτερα σε κλινικά περιβάλλοντα με περιοριστικές πολιτικές ασφαλείας.

Επιπρόσθετα, η ανάπτυξη για πολλαπλές πλατφόρμες θα απαιτούσε σημαντικά επιπλέον resources.

Οι αμιγώς WebGL βασισμένες λύσεις παρείχαν εξαιρετική απόδοση για 3D γραφικά αλλά παρουσίαζαν υπερβολική πολυπλοκότητα για τις 2D annotation ανάγκες του έργου. Επιπλέον, η ανάπτυξη user interfaces με WebGL απαιτεί εξειδικευμένη τεχνογνωσία και παρουσιάζει προκλήσεις στη συμβατότητα με παλαιότερα συστήματα.

#### 3.4.2.3. Αξιολόγηση Βιβλιοθηκών Γραφικών

Για τη διαχείριση των γραφικών στοιχείων και της διαδραστικότητας, εξετάστηκαν διάφορες βιβλιοθήκες JavaScript, συμπεριλαμβανομένων των D3.js, Paper.js, Fabric.js και Konva.js. Η σύγκριση βασίστηκε σε κριτήρια όπως την απόδοση σε μεγάλα σύνολα γραφικών στοιχείων, τις δυνατότητες διαχείρισης γεγονότων αλληλεπίδρασης και την ευκολία ανάπτυξης πολύπλοκων διαδραστικών εφαρμογών.

Η Konva.js αναδείχθηκε ως η βέλτιστη επιλογή λόγω του εξειδικευμένου σχεδιασμού της για διαδραστικές 2D γραφικές εφαρμογές. Η βιβλιοθήκη παρέχει ενσωματωμένη υποστήριξη για προηγμένες τεχνικές βελτιστοποίησης όπως το layer caching και το hit detection, που είναι κρίσιμες για την αποδοτική λειτουργία σε εφαρμογές με χιλιάδες γραφικά στοιχεία (57).

#### 3.4.2.4. Αρχιτεκτονικές Αρχές της Konva.js

Η Konva.js υιοθετεί μια ιεραρχική αρχιτεκτονική που οργανώνει τα γραφικά στοιχεία σε μια δενδρική δομή από Stage προς Layer προς Group προς Shape. Αυτή η οργάνωση επιτρέπει αποδοτική διαχείριση πολύπλοκων σκηνών και παρέχει φυσικούς μηχανισμούς για την ομαδοποίηση και διαχείριση σχετιζόμενων στοιχείων.

Η βιβλιοθήκη υποστηρίζει επίσης προηγμένες δυνατότητες όπως transformations, filters και animations που είναι απαραίτητες για την ανάπτυξη εντυπωσιακής και λειτουργικής διεπαφής χρήστη. Οι δυνατότητες αυτές επιτρέπουν την υλοποίηση χαρακτηριστικών όπως η ομαλή μετάβαση μεταξύ διαφορετικών επιπέδων ανάλυσης και οι οπτικές ενδείξεις κατάστασης.

### 3.4.3. Σχεδιασμός Εργαλείων Σχεδίασης

Ο σχεδιασμός των εργαλείων σχεδίασης βασίζεται στην αρχή της λειτουργικής πληρότητας με διαισθητική χρήση. Κάθε εργαλείο έχει σχεδιαστεί για να καλύπτει συγκεκριμένες διαγνωστικές ανάγκες, ενώ παράλληλα διατηρεί συνέπεια στον τρόπο λειτουργίας και στη διεπαφή χρήστη. Η ενοποιημένη προσέγγιση εξασφαλίζει ότι οι χρήστες μπορούν εύκολα να εναλλάσσονται μεταξύ διαφορετικών εργαλείων χωρίς να χρειάζεται επανεκμάθηση των βασικών λειτουργιών (58).

- **Εργαλείο Ορθογωνίου (Rectangle Tool):** Το εργαλείο ορθογωνίου έχει σχεδιαστεί για την ταχεία οριοθέτηση κανονικών περιοχών ενδιαφέροντος, που

είναι συχνή απαίτηση σε διαδικασίες μέτρησης και στατιστικής ανάλυσης. Η σχεδιαστική προσέγγιση εστιάζει στην ευκολία δημιουργίας με απλές χειρονομίες drag-and-drop, ενώ παράλληλα παρέχει δυνατότητες ακριβούς προσαρμογής των διαστάσεων. Το εργαλείο υποστηρίζει πολλαπλούς τρόπους εισαγωγής δεδομένων, συμπεριλαμβανομένης της γραφικής δημιουργίας μέσω του ποντικιού και της αριθμητικής εισαγωγής συντεταγμένων για περιπτώσεις που απαιτούν μέγιστη ακρίβεια. Οι σχεδιαστικές παράμετροι περιλαμβάνουν την υποστήριξη για proportional scaling και grid snapping για τη διευκόλυνση της δημιουργίας συμμετρικών και συνεπών σημειώσεων.

- **Εργαλείο Ελλείψης (Ellipse Tool):** Το εργαλείο ελλείψης απευθύνεται σε διαγνωστικές ανάγκες που αφορούν στρογγυλές ή ελλειπτικές δομές, που είναι συχνές σε πολλούς τύπους ιστολογικών εξετάσεων. Η σχεδιαστική πρόκληση έγκειται στη δημιουργία ενός εργαλείου που να επιτρέπει τη φυσική δημιουργία ελλείψεων με διαισθητικές χειρονομίες, ενώ παράλληλα παρέχει έλεγχο των γεωμετρικών παραμέτρων. Η αρχιτεκτονική του εργαλείου υποστηρίζει δυναμική προσαρμογή των αξόνων της έλλειψης κατά τη διάρκεια της δημιουργίας, επιτρέποντας στους χρήστες να ταιριάξουν με ακρίβεια το σχήμα με τις ανατομικές δομές. Επιπλέον, το σύστημα παρέχει οπτικές ενδείξεις για τις κύριες παραμέτρους όπως την εκκεντρότητα και τη στροφή.
- **Εργαλείο Πολυγώνου (Polygon Tool):** Το εργαλείο πολυγώνου αποτελεί το πιο εξελιγμένο και ευέλικτο από τα εργαλεία σχεδίασης, καθώς επιτρέπει την ακριβή οριοθέτηση περιοχών με ακανόνιστο σχήμα που είναι χαρακτηριστικές πολλών παθολογικών καταστάσεων. Ο σχεδιασμός του εργαλείου εστιάζει στην εξισορρόπηση μεταξύ της ευελιξίας στη δημιουργία πολύπλοκων σχημάτων και της διατήρησης απλότητας στη χρήση (59). Η αρχιτεκτονική υποστηρίζει δύο βασικούς τρόπους λειτουργίας: τη δημιουργία πολυγώνων μέσω διαδοχικών κλικ που ορίζουν τις κορυφές και τη δημιουργία μέσω ελεύθερης σχεδίασης που μετατρέπεται αυτόματα σε πολύγωνο. Το σύστημα περιλαμβάνει αλγορίθμους εξομάλυνσης που μετατρέπουν την ασυνεχή κίνηση του χρήστη σε ομαλές γεωμετρικές μορφές.
- **Εργαλείο Ελεύθερης Σχεδίασης (Freehand Tool):** Το εργαλείο ελεύθερης σχεδίασης παρέχει τη μέγιστη ευελιξία στην οριοθέτηση περιοχών, επιτρέποντας στους χρήστες να σχεδιάζουν οποιαδήποτε μορφή ακολουθώντας τις φυσικές κινήσεις του χεριού. Η σχεδιαστική πρόκληση έγκειται στη μετατροπή της συνεχούς κίνησης σε μαθηματικά ακριβή γεωμετρικά αντικείμενα που μπορούν να αποθηκευτούν, επεξεργαστούν και αναλυθούν. Το σύστημα χρησιμοποιεί προηγμένους αλγορίθμους curve fitting για τη μετατροπή των ακατέργαστων δεδομένων κίνησης σε smooth bezier curves που διατηρούν την αρχική πρόθεση του χρήστη ενώ παράλληλα επιτρέπουν αποδοτική αποθήκευση και επεξεργασία.

## 3.4.4. Αρχιτεκτονική Δυναμικής Ταξινόμησης

### 3.4.4.1. Βασικές Αρχές Δυναμικής Ταξινόμησης

Η δυναμική ταξινόμηση αποτελεί ένα από τα πιο καινοτόμα χαρακτηριστικά του σχεδιασμού της Μονάδας Δημιουργίας Σημειώσεων, επιτρέποντας στους χρήστες να ορίζουν και να διαχειρίζονται προσαρμοσμένες κατηγορίες σημειώσεων σε πραγματικό χρόνο. Η σχεδιαστική προσέγγιση βασίζεται στην αρχή της μέγιστης ευελιξίας χωρίς θυσία της απλότητας χρήσης (60).

Το σύστημα έχει σχεδιαστεί για να υποστηρίζει ιεραρχικές δομές ταξινόμησης που μπορούν να αντιπροσωπεύουν πολύπλοκες διαγνωστικές σχέσεις. Αυτή η ικανότητα είναι κρίσιμη για εφαρμογές όπως η κατηγοριοποίηση τύπων καρκίνου ή η ταξινόμηση φλεγμονωδών καταστάσεων, όπου υπάρχουν πολλαπλά επίπεδα διαγνωστικής λεπτομέρειας.

### 3.4.4.2. Σχεδιαστική Αρχιτεκτονική Κατηγοριοποίησης

Η αρχιτεκτονική του συστήματος κατηγοριοποίησης έχει σχεδιαστεί ως ένα flexible metadata system που συνοδεύει κάθε σημείωση με εμπλουτισμένες πληροφορίες. Κάθε κατηγορία ορίζεται μέσω ενός συνόλου attributes που μπορούν να περιλαμβάνουν τυπικά χαρακτηριστικά όπως το χρώμα, το εικονίδιο και την περιγραφή, καθώς και εξειδικευμένα χαρακτηριστικά όπως διαγνωστικούς κώδικες ή αναφορές σε κλινικά πρωτόκολλα.

Το σύστημα υποστηρίζει επίσης την έννοια των "template categories" που μπορούν να εισαχθούν από εξωτερικές πηγές όπως διεθνή κλινικά πρότυπα ή institutional guidelines, επιτρέποντας τη διατήρηση συνέπειας σε διαφορετικά έργα και ιδρύματα.

### 3.4.4.3. Διαχείριση Πολλαπλών Στρωμάτων Canvas

Ένας κρίσιμος σχεδιαστικός παράγοντας είναι η οργάνωση του canvas σε πολλαπλά στρώματα που επιτρέπουν την αποδοτική διαχείριση διαφορετικών τύπων περιεχομένου. Η στρατηγική του πολυστρωματικού σχεδιασμού βασίζεται στην αρχή του separation of concerns, όπου κάθε τύπος περιεχομένου διαχειρίζεται από ένα ειδικό στρώμα [97].

Το background layer περιέχει την κύρια ιστοπαθολογική εικόνα και τυχόν βοηθητικά γραφικά στοιχεία. Το annotations layer διαχειρίζεται όλες τις σημειώσεις των χρηστών, ενώ το interaction layer χειρίζεται τα προσωρινά στοιχεία που εμφανίζονται κατά τη διάρκεια της διαδραστικής επεξεργασίας. Αυτή η διαχωριστική προσέγγιση βελτιώνει σημαντικά την απόδοση, καθώς επιτρέπει selective rendering μόνο των στρωμάτων που έχουν αλλάξει.

### 3.4.4.4. Σύστημα Αυτόματης Αποθήκευσης και Διαχείρισης Εργασιών

Η σχεδιαστική προσέγγιση για το σύστημα αυτόματης αποθήκευσης βασίζεται στην αρχή της «αόρατης αξιοπιστίας», όπου το σύστημα εξασφαλίζει τη διατήρηση όλων των δεδομένων χωρίς να διακόπτει τη ροή εργασίας του χρήστη. Το σχεδιαστικό μοντέλο

υιοθετεί μια event-driven αρχιτεκτονική που αντιδρά αυτόματα σε κάθε αλλαγή που πραγματοποιεί ο χρήστης.

Η αρχιτεκτονική διαχείρισης εργασιών έχει σχεδιαστεί για να χειρίζεται πολλαπλές ταυτόχρονες αιτήσεις αποθήκευσης με έξυπνη σειριοποίηση που εξασφαλίζει τη σωστή σειρά εκτέλεσης. Το σύστημα περιλαμβάνει μηχανισμούς conflict resolution για περιπτώσεις όπου πολλαπλοί χρήστες τροποποιούν την ίδια σημείωση ταυτόχρονα.

## 3.5. Σχεδιασμός Μονάδας Τεχνητής Νοημοσύνης

Η Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης αποτελεί το τρίτο και ιδιαίτερα κρίσιμο συστατικό της αρχιτεκτονικής της τρέχουσας πλατφόρμας. Ο σχεδιασμός αυτής της μονάδας πρέπει να εξισορροπεί μεταξύ της ανάγκης για υψηλή υπολογιστική απόδοση που απαιτούν τα σύγχρονα συνελικτικά νευρωνικά δίκτυα και της απαίτησης για ευκολία χρήσης και ενσωμάτωση με τα υπόλοιπα υποσυστήματα της πλατφόρμας. Η μονάδα αυτή είναι υπεύθυνη για την εκπαίδευση, αξιολόγηση και εκτέλεση αλγορίθμων βαθιάς μάθησης που αναλύουν ιστοπαθολογικές εικόνες και παράγουν αυτόματες σημειώσεις και διαγνωστικές προτάσεις.

Η σχεδιαστική φιλοσοφία της μονάδας βασίζεται στην αρχή της αυτονομίας και της ευελιξίας. Παρόμοια με τη Μονάδα Δημιουργίας Σημειώσεων, η Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης έχει σχεδιαστεί ως αυτόνομο σύστημα που μπορεί να λειτουργήσει ανεξάρτητα αλλά και να ενσωματωθεί απρόσκοπτα με την ευρύτερη αρχιτεκτονική της πλατφόρμας. Αυτή η προσέγγιση εξασφαλίζει τόσο την επαναχρησιμοποίηση του συστήματος σε άλλες εφαρμογές όσο και τη δυνατότητα εύκολης συντήρησης και επέκτασης (55).

### 3.5.1. Επιλογή Πλαισίου Python/Detectron2

Η επιλογή του κατάλληλου τεχνολογικού πλαισίου για την ανάπτυξη της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης αποτελεί θεμελιώδη σχεδιαστική απόφαση που επηρεάζει όλες τις μελλοντικές επιλογές και δυνατότητες του συστήματος. Η απόφαση αυτή πρέπει να λαμβάνει υπόψη όχι μόνο τις τρέχουσες τεχνικές απαιτήσεις, αλλά και τη μελλοντική εξελιξιμότητα, τη συμβατότητα με υπάρχοντα συστήματα και την ευκολία συντήρησης και επέκτασης.

Η αξιολόγηση των διαθέσιμων επιλογών πρέπει να βασίζεται σε ένα σύνολο σαφώς καθορισμένων κριτηρίων που να ανταποκρίνονται στο όραμα και τους στόχους της πλατφόρμας. Η ωριμότητα και σταθερότητα του πλαισίου αποτελεί πρωταρχικό κριτήριο, καθώς η πλατφόρμα στοχεύει σε κλινικές εφαρμογές όπου η αξιοπιστία είναι κρίσιμη. Ταυτόχρονα, η ενεργή υποστήριξη από την ερευνητική και προγραμματιστική κοινότητα εξασφαλίζει τη συνεχή εξέλιξη και βελτίωση του πλαισίου.

Η επιλογή του Detectron2 ως κεντρικό πλαίσιο ανάπτυξης βασίζεται στη θέση του ως ηγετικό εργαλείο στον τομέα της κατάτμησης στιγμιότυπων και του εντοπισμού αντικειμένων. Το πλαίσιο αυτό έχει καθιερωθεί ως το κυρίαρχο εργαλείο για εφαρμογές που απαιτούν υψηλή ακρίβεια στον εντοπισμό και την κατάτμηση πολύπλοκων δομών, χαρακτηριστικά που είναι ιδιαίτερα σημαντικά για την ιστοπαθολογική ανάλυση.

Η επιλογή της Python ως κύρια γλώσσα ανάπτυξης διευκολύνει την ενσωμάτωση με το ευρύτερο οικοσύστημα εργαλείων για επιστημονικό υπολογισμό και ανάλυση δεδομένων. Αυτή η επιλογή εξασφαλίζει πρόσβαση σε ένα τεράστιο φάσμα εξειδικευμένων βιβλιοθηκών για επεξεργασία εικόνων, στατιστική ανάλυση και οπτικοποίηση, που είναι απαραίτητα για την ανάπτυξη μιας ολοκληρωμένης πλατφόρμας ιατρικής ανάλυσης.

Η αρχιτεκτονική του επιλεγμένου πλαισίου πρέπει να υποστηρίζει τμηματική ανάπτυξη (modular development), επιτρέποντας την ανεξάρτητη βελτίωση διαφορετικών συστατικών χωρίς επίδραση στη συνολική λειτουργικότητα. Αυτή η προσέγγιση είναι κρίσιμη για τη μακροπρόθεσμη συντηρησιμότητα του συστήματος και την ικανότητά του να προσαρμόζεται σε νέες τεχνολογικές εξελίξεις.

### 3.5.2. Αρχιτεκτονική Συνελικτικών Νευρωνικών Δικτύων

Ο σχεδιασμός της υποστήριξης για συνελικτικά νευρωνικά δίκτυα πρέπει να βασίζεται σε αρχές που να εξασφαλίζουν τόσο την τεχνική αποδοτικότητα όσο και την προσβασιμότητα από χρήστες με διαφορετικά επίπεδα τεχνικής εμπειρίας. Η κεντρική σχεδιαστική πρόκληση είναι η δημιουργία ενός συστήματος που να καθιστά προσβάσιμες τις προηγμένες δυνατότητες των σύγχρονων αρχιτεκτονικών βαθιάς μάθησης, χωρίς να απαιτεί από τους χρήστες εξειδικευμένες γνώσεις προγραμματισμού ή μηχανικής μάθησης.

#### 3.5.2.1. Σχεδιαστικές Αρχές Επιλογής Αρχιτεκτονικών

Το σύστημα πρέπει να παρέχει διαδραστικούς μηχανισμούς για την επιλογή της καταλληλότερης αρχιτεκτονικής νευρωνικού δικτύου βάσει των χαρακτηριστικών του εκάστοτε προβλήματος. Αυτό περιλαμβάνει την ανάπτυξη συστημάτων συστάσεων που να καθοδηγούν τον χρήστη στην επιλογή μεταξύ διαφορετικών προσεγγίσεων (όπως Mask R-CNN για ακριβή κατάτμηση ή Faster R-CNN για γρήγορο εντοπισμό) βάσει κριτηρίων όπως η επιθυμητή ακρίβεια, η ταχύτητα επεξεργασίας και οι διαθέσιμοι υπολογιστικοί πόροι.

Η αρχιτεκτονική πρέπει να υποστηρίζει ιεραρχική οργάνωση των επιλογών, όπου βασικές αποφάσεις (όπως ο τύπος της εργασίας) καθορίζουν αυτόματα κατάλληλες προτεινόμενες ρυθμίσεις για πιο εξειδικευμένες παραμέτρους. Αυτή η προσέγγιση επιτρέπει στους αρχάριους χρήστες να επιτυγχάνουν καλά αποτελέσματα με ελάχιστη παρέμβαση, ενώ παράλληλα παρέχει στους προχωρημένους χρήστες πλήρη έλεγχο όλων των λεπτομερειών.

#### 3.5.2.2. Αρχές Παραμετροποίησης και Διαμόρφωσης

Το σύστημα παραμετροποίησης πρέπει να σχεδιαστεί με γνώμονα τη διαφάνεια και την επαναληψιμότητα. Κάθε διαμόρφωση πρέπει να τεκμηριώνεται πλήρως και να μπορεί να αναπαραχθεί, εξασφαλίζοντας ότι τα αποτελέσματα της ανάλυσης είναι πλήρως ιχνηλάσιμα και επαληθεύσιμα. Αυτό είναι ιδιαίτερα σημαντικό για κλινικές εφαρμογές, όπου η δυνατότητα αναπαραγωγής των αποτελεσμάτων είναι νομική και ηθική απαίτηση.

Η αρχιτεκτονική πρέπει να περιλαμβάνει μηχανισμούς για την αυτόματη τεκμηρίωση όλων των σχετικών παραμέτρων και αποφάσεων, δημιουργώντας ένα πλήρες "αποτύπωμα" κάθε ανάλυσης που να μπορεί να χρησιμοποιηθεί για μελλοντική αναφορά ή επαλήθευση. Επίσης, πρέπει να υποστηρίζει template-based configuration, όπου συχνά χρησιμοποιούμενες διαμορφώσεις μπορούν να αποθηκεύονται και να επαναχρησιμοποιούνται.

#### 3.5.2.3. Στρατηγικές Προσαρμογής για Ιστοπαθολογικά Δεδομένα

Τα ιστοπαθολογικά δεδομένα παρουσιάζουν μοναδικές προκλήσεις που απαιτούν εξειδικευμένες σχεδιαστικές λύσεις. Η αρχιτεκτονική πρέπει να λαμβάνει υπόψη χαρακτηριστικά όπως το μεγάλο μέγεθος των εικόνων, την ποικιλομορφία στις τεχνικές χρώσης και τη σπανιότητα ορισμένων παθολογικών καταστάσεων που δυσκολεύει τη συλλογή εκπαιδευτικών δεδομένων.

Το σύστημα πρέπει να περιλαμβάνει εξειδικευμένες στρατηγικές για την αντιμετώπιση της ανισορροπίας κλάσεων (class imbalance) που είναι συχνή στα ιατρικά δεδομένα, καθώς και τεχνικές για την ενίσχυση της γενίκευσης των μοντέλων σε δεδομένα από διαφορετικά εργαστήρια ή με διαφορετικές τεχνικές προετοιμασίας.

#### 3.5.2.4. Σχεδιασμός Επιτάχυνσης Μέσω Γραφικών Επεξεργαστών

Η αποδοτική αξιοποίηση των γραφικών επεξεργαστών αποτελεί κρίσιμη απαίτηση για την πρακτική χρησιμότητα της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης. Ο σχεδιασμός αυτού του τομέα πρέπει να εξασφαλίζει ότι το σύστημα μπορεί να αξιοποιεί πλήρως τους διαθέσιμους υπολογιστικούς πόρους, ανεξάρτητα από τη συγκεκριμένη διαμόρφωση του υλικού στο οποίο εκτελείται.

#### 3.5.2.5. Αρχές Αυτόματης Διαχείρισης Πόρων

Το σύστημα πρέπει να σχεδιαστεί με δυνατότητες έξυπνης διαχείρισης πόρων που να εξασφαλίζει βέλτιστη αξιοποίηση των διαθέσιμων γραφικών επεξεργαστών χωρίς παρέμβαση από τον χρήστη. Αυτό περιλαμβάνει την αυτόματη ανίχνευση των χαρακτηριστικών του υλικού (αριθμός GPU, διαθέσιμη μνήμη, υπολογιστική ικανότητα) και την προσαρμογή των παραμέτρων εκτέλεσης ανάλογα.

Η αρχιτεκτονική πρέπει να υποστηρίζει δυναμική κλιμάκωση, όπου το σύστημα μπορεί να προσαρμόζεται αυτόματα σε αλλαγές στη διαθεσιμότητα πόρων κατά τη διάρκεια της εκτέλεσης. Για παράδειγμα, εάν άλλες διεργασίες αρχίσουν να χρησιμοποιούν μέρος της διαθέσιμης μνήμης GPU, το σύστημα θα πρέπει να μπορεί να μειώσει αυτόματα το

μέγεθος των παρτίδων (batches) ή να προσαρμόσει άλλες παραμέτρους για να εξασφαλίσει την απρόσκοπτη συνέχιση της εργασίας.

#### 3.5.2.6. Στρατηγικές Βελτιστοποίησης Απόδοσης

Ο σχεδιασμός πρέπει να περιλαμβάνει προηγμένες στρατηγικές για τη μεγιστοποίηση της υπολογιστικής απόδοσης. Αυτό περιλαμβάνει την υιοθέτηση τεχνικών όπως η εκπαίδευση μικτής ακρίβειας, η οποία μπορεί να επιταχύνει σημαντικά τους υπολογισμούς χωρίς υποβάθμιση της ποιότητας των αποτελεσμάτων, καθώς και προηγμένες τεχνικές διαχείρισης μνήμης που επιτρέπουν την επεξεργασία μεγαλύτερων εικόνων ή batch μεγέθη (sizes).

Το σύστημα πρέπει επίσης να υποστηρίζει παραλληλοποίηση σε πολλαπλά επίπεδα, από την παράλληλη επεξεργασία διαφορετικών εικόνων μέχρι την κατανεμημένη εκπαίδευση μοντέλων σε πολλαπλά GPU ή ακόμα και σε πολλαπλά μηχανήματα. Η αρχιτεκτονική πρέπει να καθιστά αυτές τις προηγμένες δυνατότητες προσβάσιμες μέσω απλών παραμέτρων διαμόρφωσης, χωρίς να απαιτεί από τον χρήστη βαθιά γνώση των υποκείμενων τεχνολογιών.

#### 3.5.2.7. Απαιτήσεις Ανθεκτικότητας και Αξιοπιστίας

Σε κλινικό περιβάλλον, η αξιοπιστία και η προβλεψιμότητα της απόδοσης είναι κρίσιμες απαιτήσεις. Το σύστημα πρέπει να σχεδιαστεί με ισχυρούς μηχανισμούς αντιμετώπισης σφαλμάτων και ανάκαμψης από απρόβλεπτες καταστάσεις. Αυτό περιλαμβάνει την ικανότητα συνέχισης της εργασίας ακόμα και σε περίπτωση προβλημάτων με μεμονωμένα GPU, καθώς και μηχανισμούς αυτόματης αποθήκευσης και ανάκτησης της κατάστασης σε περίπτωση διακοπής της εκτέλεσης.

#### 3.5.2.8. Διαχείριση Πολλαπλών Μοντέλων και Βαρών

Η αποδοτική διαχείριση πολλαπλών μοντέλων αποτελεί κρίσιμη απαίτηση για μια πλατφόρμα που στοχεύει να υποστηρίξει διαφορετικές κλινικές εφαρμογές και εξειδικεύσεις. Ο σχεδιασμός αυτού του συστήματος πρέπει να εξασφαλίζει ότι η πλατφόρμα μπορεί να αναπτυχθεί και να προσαρμοστεί σε νέες ανάγκες χωρίς να χάσει την αποδοτικότητα ή την ευχρηστία.

#### 3.5.2.9. Στρατηγικές Οργάνωσης και Κατηγοριοποίησης

Το σύστημα οργάνωσης μοντέλων πρέπει να βασίζεται σε κλινικά σχετικά κριτήρια που να είναι άμεσα κατανοητά από τους τελικούς χρήστες. Αυτό σημαίνει οργάνωση βάσει ανατομικών περιοχών, τύπων παθολογίας, ή κλινικών εφαρμογών, παρά τεχνικών χαρακτηριστικών των αλγορίθμων. Η αρχιτεκτονική πρέπει να υποστηρίζει ιεραρχική κατηγοριοποίηση που να επιτρέπει τόσο την εύκολη πλοήγηση όσο και την αποδοτική αναζήτηση κατάλληλων μοντέλων.

Η σχεδιαστική προσέγγιση πρέπει να περιλαμβάνει μηχανισμούς για την αυτόματη πρόταση κατάλληλων μοντέλων βάσει των χαρακτηριστικών της εκάστοτε εργασίας.

Αυτό θα μπορούσε να περιλαμβάνει ανάλυση των χαρακτηριστικών της εικόνας (μέγεθος, τύπος χρώσης, ανατομική περιοχή) και σύγκριση με ιστορικά δεδομένα για την εύρεση των μοντέλων που έχουν επιδείξει την καλύτερη απόδοση σε παρόμοιες περιπτώσεις.

#### 3.5.2.10. Αρχές Παρακολούθησης Απόδοσης και Ποιότητας

Κάθε μοντέλο πρέπει να συνοδεύεται από εκτενή τεκμηρίωση που να περιλαμβάνει όχι μόνο τα στατιστικά απόδοσης, αλλά και πληροφορίες για τις συνθήκες εκπαίδευσης, τα χαρακτηριστικά των εκπαιδευτικών δεδομένων και τους περιορισμούς εφαρμογής. Αυτή η τεκμηρίωση είναι κρίσιμη για τη σωστή επιλογή και χρήση των μοντέλων από τους κλινικούς χρήστες.

Το σύστημα πρέπει να περιλαμβάνει μηχανισμούς για τη συνεχή παρακολούθηση της απόδοσης των μοντέλων σε πραγματικά δεδομένα, με δυνατότητα αυτόματης ειδοποίησης σε περίπτωση υποβάθμισης της απόδοσης. Αυτό είναι ιδιαίτερα σημαντικό στην ιατρική, όπου αλλαγές στα πρωτόκολλα, στον εξοπλισμό ή στις τεχνικές προετοιμασίας δειγμάτων μπορεί να επηρεάσουν την αποτελεσματικότητα των μοντέλων.

#### 3.5.2.11. Απαιτήσεις Διαχείρισης Κύκλου Ζωής Μοντέλων

Η αρχιτεκτονική πρέπει να υποστηρίζει πλήρη διαχείριση του κύκλου ζωής των μοντέλων, από την αρχική ανάπτυξη μέχρι την τελική απόσυρση. Αυτό περιλαμβάνει μηχανισμούς για versioning που να επιτρέπουν την παρακολούθηση αλλαγών στο χρόνο, τη σύγκριση διαφορετικών εκδόσεων και την ασφαλή επαναφορά σε προηγούμενες εκδόσεις όταν αυτό απαιτείται.

Το σύστημα πρέπει επίσης να περιλαμβάνει στρατηγικές για την αποδοτική αποθήκευση και ανάκτηση μοντέλων, λαμβάνοντας υπόψη ότι τα μοντέλα βαθιάς μάθησης μπορεί να είναι πολύ μεγάλα σε μέγεθος. Αυτό περιλαμβάνει τεχνικές συμπίεσης, έξυπνες στρατηγικές caching και μηχανισμούς για την προφόρτωση συχνά χρησιμοποιούμενων μοντέλων.

Η συνολική αρχιτεκτονική της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης πρέπει να αποτελεί ένα ισορροπημένο σύστημα που να συνδυάζει προηγμένες τεχνολογικές δυνατότητες με πρακτική χρησιμότητα για κλινικές εφαρμογές. Οι σχεδιαστικές επιλογές που περιγράφηκαν στοχεύουν στη δημιουργία ενός συστήματος που να καθιστά τις σύγχρονες τεχνολογίες τεχνητής νοημοσύνης προσβάσιμες σε κλινικούς χρήστες, χωρίς να θυσιάζει την ακρίβεια, την αξιοπιστία ή την απόδοση που απαιτούνται για ιατρικές εφαρμογές (56).

## 3.6. Σχεδιασμός Επικοινωνιακού Στρώματος

Το Επικοινωνιακό Στρώμα αποτελεί τον κρίσιμο συνδετικό κρίκο που ενώνει τα τρία κύρια υποσυστήματα της εφαρμογής σε μια ενιαία και συνεκτική αρχιτεκτονική. Ο σχεδιασμός αυτού του στρώματος πρέπει να εξασφαλίζει απρόσκοπτη επικοινωνία

μεταξύ της Κεντρικής Μονάδας, της Μονάδας Δημιουργίας Σημειώσεων και της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης, διατηρώντας παράλληλα την αυτονομία και την ανεξαρτησία κάθε υποσυστήματος.

Η σχεδιαστική πρόκληση του Επικοινωνιακού Στρώματος έγκειται στην ανάγκη διαχείρισης πολυδιάστατων ροών δεδομένων που περιλαμβάνουν τόσο άμεσες αλληλεπιδράσεις των χρηστών όσο και μακροπρόθεσμες υπολογιστικές εργασίες που μπορεί να διαρκούν ώρες ή ημέρες. Ταυτόχρονα, το στρώμα αυτό πρέπει να υποστηρίζει πολλαπλούς ταυτόχρονους χρήστες και να διασφαλίζει την ακεραιότητα και την ασφάλεια των δεδομένων σε όλες τις φάσεις της επικοινωνίας.

Η φιλοσοφία σχεδιασμού βασίζεται στην αρχή της αποσύνδεσης (decoupling), όπου κάθε υποσύστημα μπορεί να λειτουργεί και να εξελίσσεται ανεξάρτητα, ενώ παράλληλα διατηρείται η ικανότητα αποδοτικής συνεργασίας. Αυτή η προσέγγιση εξασφαλίζει ότι βελτιώσεις ή αλλαγές σε ένα υποσύστημα δεν επηρεάζουν δραματικά τη λειτουργία των άλλων, διευκολύνοντας τη συντήρηση και την επέκταση της πλατφόρμας.

### 3.6.1. Αρχιτεκτονική Συγχρονισμού Δεδομένων σε Πραγματικό Χρόνο

Ο σχεδιασμός του συστήματος συγχρονισμού δεδομένων σε πραγματικό χρόνο πρέπει να αντιμετωπίσει τη σύνθετη πρόκληση της διατήρησης συνοχής δεδομένων σε ένα κατανεμημένο περιβάλλον όπου πολλαπλά υποσυστήματα δημιουργούν, τροποποιούν και καταναλώνουν πληροφορίες σε διαφορετικούς ρυθμούς και με διαφορετικές απαιτήσεις λανθάνοντος χρόνου (latency).

#### 3.6.1.1. Στρατηγικές Αρχιτεκτονικής Real-Time Communication

Η επιλογή της αρχιτεκτονικής επικοινωνίας πρέπει να βασίζεται σε ανάλυση των διαφορετικών τύπων δεδομένων και των αντίστοιχων απαιτήσεων τους. Για παράδειγμα, οι αλληλεπιδράσεις των χρηστών με το περιβάλλον σημειώσεων απαιτούν άμεση ανταπόκριση (χαμηλό latency) αλλά σχετικά μικρό όγκο δεδομένων, ενώ η μεταφορά αποτελεσμάτων τεχνητής νοημοσύνης μπορεί να περιλαμβάνει μεγάλο όγκο δεδομένων αλλά να επιδέχεται μεγαλύτερο latency.

Το σύστημα πρέπει να υποστηρίζει διαφορετικά πρωτόκολλα επικοινωνίας για διαφορετικούς τύπους δεδομένων. Τεχνολογίες όπως τα WebSockets είναι ιδανικές για άμεσες αλληλεπιδράσεις που απαιτούν αμφίδρομη επικοινωνία, ενώ τα RESTful APIs μπορεί να είναι καταλληλότερα για τη μεταφορά μεγάλων αρχείων ή batch λειτουργίες. Η αρχιτεκτονική πρέπει να παρέχει ενιαία διεπαφή που να αποκρύπτει αυτή την πολυπλοκότητα από τα υποσυστήματα.

#### 3.6.1.2. Μηχανισμοί Διατήρησης Συνοχής Δεδομένων

Η διατήρηση συνοχής δεδομένων σε πραγματικού χρόνου περιβάλλον με πολλαπλούς παράγοντες που τροποποιούν τα ίδια δεδομένα αποτελεί σημαντική σχεδιαστική

πρόκληση. Το σύστημα πρέπει να περιλαμβάνει μηχανισμούς για την αποφυγή συγκρούσεων (conflict resolution) και τη διατήρηση της ακεραιότητας των δεδομένων ακόμα και σε περιπτώσεις ταυτόχρονων τροποποιήσεων από διαφορετικούς χρήστες ή υποσυστήματα.

Η σχεδιαστική προσέγγιση πρέπει να περιλαμβάνει στρατηγικές για αισιόδοξο κλείδωμα, όπου οι τροποποιήσεις επιτρέπονται ελεύθερα αλλά ελέγχονται για συγκρούσεις κατά την τελική αποθήκευση, καθώς και απαισιόδοξο κλείδωμα για κρίσιμα δεδομένα όπου η αποφυγή συγκρούσεων είναι πιο σημαντική από την απόδοση. Η επιλογή μεταξύ αυτών των στρατηγικών πρέπει να γίνεται δυναμικά βάσει του τύπου των δεδομένων και του πλαισίου χρήσης.

#### 3.6.1.3. Απαιτήσεις Κλιμάκωσης και Απόδοσης

Το σύστημα πρέπει να σχεδιαστεί με γνώμονα την κλιμάκωση, καθώς ο αριθμός των ταυτόχρονων χρηστών και η ποσότητα των δεδομένων που επεξεργάζεται η πλατφόρμα αναμένεται να αυξηθεί σημαντικά με την πάροδο του χρόνου. Αυτό απαιτεί αρχιτεκτονικές επιλογές που να υποστηρίζουν οριζόντια κλιμάκωση, όπου επιπλέον υπολογιστική ισχύς μπορεί να προστεθεί χωρίς σημαντικές αλλαγές στη δομή του συστήματος.

Η αρχιτεκτονική πρέπει επίσης να περιλαμβάνει μηχανισμούς για εξισορρόπηση φορτίου που να διανέμουν το φόρτο εργασίας ισομερώς μεταξύ των διαθέσιμων πόρων, καθώς και έξυπνες στρατηγικές προσωρινής αποθήκευσης που να μειώνουν την επικοινωνία με βάσεις δεδομένων για συχνά ζητούμενες πληροφορίες.

### 3.6.2. Υποστήριξη Πολλαπλών Χρηστών και Συνεργατικότητα

Η υποστήριξη πολλαπλών χρηστών αποτελεί κρίσιμη απαίτηση για μια πλατφόρμα που στοχεύει να χρησιμοποιηθεί σε κλινικό περιβάλλον, όπου η συνεργασία μεταξύ διαφορετικών ειδικοτήτων (παθολόγων, ερευνητών, κλινικών ιατρών) είναι απαραίτητη για την αποτελεσματική διάγνωση και θεραπεία. Ο σχεδιασμός αυτής της λειτουργικότητας πρέπει να εξασφαλίζει τόσο την τεχνική αποδοτικότητα όσο και την ευχρηστία και ασφάλεια για όλους τους τύπους χρηστών.

Το σύστημα διαχείρισης χρηστών πρέπει να υποστηρίζει πολύπλοκες ιεραρχίες δικαιωμάτων που να αντικατοπτρίζουν τις πραγματικές ιεραρχίες και ροές εργασίας σε κλινικό περιβάλλον. Αυτό περιλαμβάνει όχι μόνο βασικά δικαιώματα πρόσβασης (ανάγνωση, εγγραφή, διαγραφή), αλλά και εξειδικευμένα δικαιώματα που σχετίζονται με κλινικές λειτουργίες όπως η έγκριση διαγνώσεων, η εκκίνηση αναλύσεων με τεχνητή νοημοσύνη ή η πρόσβαση σε ευαίσθητα δεδομένα ασθενών. Η αρχιτεκτονική πρέπει να υποστηρίζει έλεγχο πρόσβασης βάσει ρόλων (role-based access control, RBAC) με δυναμική ανάθεση δικαιωμάτων βάσει του πλαισίου. Για παράδειγμα, ένας ερευνητής μπορεί να έχει πλήρη δικαιώματα στα δικά του έργα αλλά περιορισμένη πρόσβαση σε

έργα άλλων, ενώ ένας επιβλέπων παθολόγος μπορεί να έχει δικαιώματα επισκόπησης και έγκρισης σε πολλαπλά έργα.

Η σχεδιαστική προσέγγιση για τη συνεργατική επεξεργασία πρέπει να λαμβάνει υπόψη τις ιδιαίτερες ανάγκες της ιστοπαθολογικής ανάλυσης, όπου η συνεργασία συχνά περιλαμβάνει ασύγχρονες διαδικασίες (π.χ. ένας παθολόγος εξετάζει ένα δείγμα και αφήνει σχόλια για έναν συνάδελφο να δει αργότερα) αλλά και σύγχρονες διαδικασίες (π.χ. πολλαπλοί ειδικοί εξετάζουν ταυτόχρονα ένα πολύπλοκο δείγμα). Το σύστημα πρέπει να υποστηρίζει συνεργατική επισημείωση (collaborative annotation), όπου πολλαπλοί χρήστες μπορούν να προσθέτουν σημειώσεις στην ίδια εικόνα, με σαφή ιχνηλασιμότητα του ποιος δημιούργησε κάθε σημείωση και πότε. Επίσης, πρέπει να περιλαμβάνει μηχανισμούς για σχολιασμό και συζήτηση, επιτρέποντας στους χρήστες να επικοινωνούν για συγκεκριμένες περιοχές ή ευρήματα.

Η αρχιτεκτονική πρέπει να περιλαμβάνει εξελιγμένο σύστημα ειδοποιήσεων που να ενημερώνει τους χρήστες για σχετικές εξελίξεις χωρίς να τους κατακλύζει με άσχετες πληροφορίες. Αυτό απαιτεί έξυπνο φιλτράρισμα που να λαμβάνει υπόψη τον ρόλο του χρήστη, τα τρέχοντα έργα στα οποία συμμετέχει και τις προτιμήσεις του για ειδοποιήσεις. Το σύστημα πρέπει επίσης να υποστηρίζει προσαρμόσιμα workflows που να μπορούν να αντικατοπτρίζουν τις διαφορετικές διαδικασίες που ακολουθούνται σε διαφορετικά ιδρύματα ή για διαφορετικούς τύπους αναλύσεων. Αυτό περιλαμβάνει την ικανότητα ορισμού σταδίων εργασίας, απαιτούμενων εγκρίσεων και αυτόματων μεταβάσεων βάσει συγκεκριμένων συνθηκών.

### 3.6.3. Διαχείριση Ασύγχρονων Εργασιών και Ουρών

Η διαχείριση ασύγχρονων εργασιών αποτελεί κρίσιμο συστατικό της αρχιτεκτονικής, καθώς πολλές από τις λειτουργίες της πλατφόρμας, ιδιαίτερα αυτές που σχετίζονται με την τεχνητή νοημοσύνη, απαιτούν σημαντικό χρόνο επεξεργασίας που δεν μπορεί να γίνει σε πραγματικό χρόνο κατά τη διάρκεια μιας αλληλεπίδρασης χρήστη.

#### 3.6.3.1. Αρχιτεκτονική Συστημάτων Ουρών

Ο σχεδιασμός του συστήματος ουρών πρέπει να υποστηρίζει πολλαπλούς τύπους εργασιών με διαφορετικές προτεραιότητες και απαιτήσεις. Για παράδειγμα, μια εργασία διαγνωστικής ανάλυσης για επείγον περιστατικό πρέπει να έχει υψηλότερη προτεραιότητα από μια ερευνητική ανάλυση, ενώ μια εργασία εκπαίδευσης μοντέλου μπορεί να είναι αποδεκτό να εκτελεστεί κατά τις ώρες χαμηλού φόρτου.

Η αρχιτεκτονική πρέπει να περιλαμβάνει έξυπνους αλγόριθμους χρονοδρομολόγησης (scheduling) που να λαμβάνουν υπόψη όχι μόνο την προτεραιότητα των εργασιών αλλά και τους διαθέσιμους πόρους, τις εκτιμώμενες απαιτήσεις κάθε εργασίας και τις αλληλεπιδράσεις μεταξύ διαφορετικών εργασιών. Αυτό περιλαμβάνει την ικανότητα dynamic load balancing, όπου οι εργασίες μπορούν να μεταφέρονται σε λιγότερο φορτωμένους κόμβους του συστήματος.

#### 3.6.3.2. Στρατηγικές Παρακολούθησης και Αναφοράς Προόδου

Οι ασύγχρονες εργασίες, ιδιαίτερα αυτές που διαρκούν πολλές ώρες όπως η εκπαίδευση μοντέλων τεχνητής νοημοσύνης, πρέπει να παρέχουν στους χρήστες συνεχή ενημέρωση για την πρόοδό τους. Αυτό απαιτεί σχεδιαστικές λύσεις που να επιτρέπουν στις εργασίες να αναφέρουν την πρόοδό τους σε τακτικά διαστήματα χωρίς να επηρεάζεται η απόδοσή τους.

Το σύστημα πρέπει να υποστηρίζει πολύπλοκα μοτίβα αναφοράς που να περιλαμβάνουν όχι μόνο απλά ποσοστά ολοκλήρωσης αλλά και ουσιαστικές πληροφορίες για την πρόοδο (π.χ. "εκπαίδευση epoch 15 από 100", "επεξεργασία εικόνας 2847 από 5000"). Επίσης, πρέπει να παρέχει εκτιμήσεις του απομένοντος χρόνου που να βελτιώνονται δυναμικά βάσει της πραγματικής απόδοσης της εργασίας.

#### 3.6.3.3. Μηχανισμοί Ανθεκτικότητας και Ανάκαμψης

Λόγω της μεγάλης διάρκειας πολλών εργασιών, το σύστημα πρέπει να περιλαμβάνει ισχυρούς μηχανισμούς για την αντιμετώπιση αποτυχιών και τη διατήρηση της προόδου. Αυτό περιλαμβάνει την αυτόματη αποθήκευση σημεία ελέγχου (checkpoints) σε τακτικά διαστήματα, έτσι ώστε σε περίπτωση διακοπής μιας εργασίας (λόγω προβλήματος hardware, διακοπής ρεύματος ή άλλων απρόβλεπτων συνθηκών) να μπορεί να συνεχιστεί από το τελευταίο σημείο αποθήκευσης.

Η αρχιτεκτονική πρέπει επίσης να υποστηρίζει έξυπνοι μηχανισμοί επανάληψης που να μπορούν να διακρίνουν μεταξύ προσωρινών προβλημάτων (που μπορεί να λυθούν με επανάληψη) και μόνιμων προβλημάτων (που απαιτούν παρέμβαση χρήστη ή διαχειριστή). Αυτό περιλαμβάνει εκθετικές στρατηγικές υποχώρησης για προσωρινά προβλήματα δικτύου και έξυπνη κλιμάκωση των απαιτήσεων πόρων σε περίπτωση περιορισμένης διαθεσιμότητας.

#### 3.6.3.4. Ενσωμάτωση με Συστήματα Παρακολούθησης και Καταγραφής

Το σύστημα διαχείρισης ασύγχρονων εργασιών πρέπει να ενσωματώνεται άρρηκτα με συνολικά συστήματα παρακολούθησης της πλατφόρμας, παρέχοντας λεπτομερή καταγραφή όλων των εργασιών για σκοπούς ελέγχου, βελτιστοποίησης και διαχείρισης πόρων. Αυτό περιλαμβάνει την καταγραφή χρονομετρικών δεδομένων (execution times, resource usage), αποτελεσμάτων (success rates, error patterns) και business metrics (user satisfaction, system efficiency).

Η σχεδιαστική προσέγγιση πρέπει να περιλαμβάνει δυνατότητες για ιστορική ανάλυση και προγνωστικός σχεδιασμός, όπου το σύστημα μπορεί να μαθαίνει από προηγούμενες εκτελέσεις για να βελτιώσει τις εκτιμήσεις χρόνου, την κατανομή πόρων και την προτεραιότητα των εργασιών.

Το Επικοινωνιακό Στρώμα, όπως περιγράφηκε σε αυτό το κεφάλαιο, αποτελεί τη "νευρική σπονδυλική στήλη" της εφαρμογής, εξασφαλίζοντας την ομαλή συνεργασία όλων των υποσυστημάτων. Η επιτυχία της συνολικής πλατφόρμας εξαρτάται σε μεγάλο

βαθμό από την αποδοτικότητα και αξιοπιστία αυτού του στρώματος, καθιστώντας τον προσεκτικό σχεδιασμό του κρίσιμο παράγοντα για την επιτυχία ολόκληρου του έργου.

# Κεφάλαιο 4

## *Ανάπτυξη και Βελτιστοποίηση Συνελικτικών Νευρωνικών Δικτύων*

## 4.1. Mask R-CNN: Προσαρμογή για Ιστοπαθολογικά Δεδομένα

### 4.1.1. Αρχιτεκτονική Βάση και Τροποποιήσεις

Το Mask R-CNN αποτελεί επέκταση του Faster R-CNN με την προσθήκη παράλληλου κλάδου για πρόβλεψη μασκών κατάτμησης, καθιστώντας το ιδανικό για εφαρμογές ιστοπαθολογίας όπου απαιτείται ακριβής οριοθέτηση κυτταρικών δομών [98]. Η προσαρμογή της αρχιτεκτονικής για ιστοπαθολογικές εικόνες απαίτησε σημαντικές τροποποιήσεις στα βασικά συστατικά του δικτύου για να αντιμετωπιστούν οι ιδιαιτερότητες των βιολογικών ιστών.

Η πρώτη σημαντική προσαρμογή αφορά το δίκτυο πυραμίδας χαρακτηριστικών (Feature Pyramid Network, FPN), το οποίο τροποποιήθηκε για να εξάγει χαρακτηριστικά σε πολλαπλές κλίμακες που αντιστοιχούν στις διαφορετικές μορφολογικές δομές των ιστών. Οι ιστοπαθολογικές εικόνες περιέχουν δομές που εκτείνονται από μεμονωμένα κύτταρα (10-50 μικρά) έως ιστικές περιοχές (εκατοντάδες μικρά), απαιτώντας ένα εξειδικευμένο πυραμιδικό δίκτυο που να μπορεί να αναγνωρίζει αποτελεσματικά δομές σε αυτό το ευρύ φάσμα κλιμάκων [99].

Η τροποποίηση περιλαμβάνει την προσθήκη επιπλέον στρωμάτων στο FPN για βελτιωμένη κάλυψη των μικροσκοπικών δομών, καθώς και την προσαρμογή των μεγεθών αγκυρών (anchor sizes) ώστε να ταιριάζουν στα τυπικά μεγέθη των κυτταρικών δομών. Συγκεκριμένα, χρησιμοποιήθηκαν μεγέθη αγκυρών από 16×16 έως 512×512 pixels, με λόγους διαστάσεων (aspect ratios) 0.5, 1.0 και 2.0, ώστε να καλύπτεται η ποικιλομορφία των κυτταρικών μορφών.

Το Region Proposal Network προσαρμόστηκε για τις ειδικές απαιτήσεις των ιστοπαθολογικών εικόνων, όπου η πυκνότητα των αντικειμένων ενδιαφέροντος είναι σημαντικά υψηλότερη από τις φυσικές εικόνες. Η τροποποίηση περιλαμβάνει:

- **Αύξηση του αριθμού των προτάσεων**: Από τις παραδοσιακές 1000-2000 προτάσεις ανά εικόνα σε 4000-6000 για να καλυφθεί η υψηλή πυκνότητα κυτταρικών δομών
- **Προσαρμογή των παραμέτρων μη μέγιστης καταστολής (Non-Maximum Suppression, NMS)**: Μείωση του IoU threshold από 0.7 σε 0.5 για καλύτερη διαχείριση επικαλυπτόμενων κυτταρικών δομών
- **Εξειδικευμένα κατώφλια εμπιστοσύνης (specialized confidence thresholds)**: Ρύθμιση των κατωφλιών εμπιστοσύνης για βελτίωση της ευαισθησίας στον εντοπισμό σπάνιων κυτταρικών τύπων

### 4.1.2. Προσαρμογή Mask Head για Κυτταρική Κατάτμηση

Το τμήμα μάσκας (mask head) του Mask R-CNN τροποποιήθηκε ώστε να παρέχει υψηλότερη ανάλυση στις μάσκες κατάτμησης (segmentation masks), κάτι που είναι κρίσιμο για την ακριβή οριοθέτηση των κυτταρικών ορίων. Η αρχική ανάλυση των 28×28 pixels αυξήθηκε σε 56×56 pixels, προσφέροντας τετραπλάσια χωρική ακρίβεια στις παραγόμενες μάσκες [3].

### 4.1.3. Εξειδικευμένη συνάρτηση σφάλματος

Η συνάρτηση σφάλματος (loss function) του συστήματος προσαρμόστηκε για να λαμβάνει υπόψη τις ιδιαιτερότητες των ιστοπαθολογικών δεδομένων:

$$\text{total_loss} = \lambda_1 \times \text{classification_loss} + \lambda_2 \times \text{bbox_regression_loss} + \lambda_3 \times \text{mask_loss} + \lambda_4 \times \text{boundary_loss}$$

Όπου:

$\lambda_1 = 1.0$: *Βάρος για classification loss*

$\lambda_2 = 1.0$: *Βάρος για bounding box regression*

$\lambda_3 = 2.0$: *Αυξημένο βάρος για mask loss λόγω της σημασίας ακριβούς κατάτμησης*

$\lambda_4 = 0.5$: *Επιπλέον boundary loss για καλύτερη οριοθέτηση κυττάρων*

Το boundary_loss είναι μια εξειδικευμένη συνάρτηση που εστιάζει στην ακρίβεια των ορίων των κυττάρων:

$$\text{boundary_loss} = \text{focal_loss}(\text{predicted_boundaries}, \text{true_boundaries}, \alpha=0.25, \gamma=2)$$

### 4.1.4. Μεθοδολογία Εκπαίδευσης για Ιστοπαθολογικές Εφαρμογές

#### 4.1.4.1. Στρατηγική Multi-Scale Training

Για την αντιμετώπιση της μεγάλης ποικιλομορφίας στα μεγέθη των κυτταρικών δομών, υιοθετήθηκε μια στρατηγική εκπαίδευσης πολλαπλών κλιμάκων (multi-scale training), όπου κάθε εικόνα επεξεργάζεται ταυτόχρονα σε διαφορετικές κλίμακες. Οι εικόνες εκπαίδευσης μεγεθύνονται τυχαία κατά 0.8×, 1.0× και 1.2×, ώστε το μοντέλο να εκτεθεί σε διαφορετικά μεγέθη των ίδιων δομών.

#### 4.1.4.2. Εξειδικευμένο Data Augmentation

Η εφαρμογή για την ενίσχυση δεδομένων προσαρμόστηκε ώστε να λαμβάνει υπόψη τις ιδιαιτερότητες των ιστοπαθολογικών εικόνων:

Χρωματικές Τροποποιήσεις:

- Τυχαίες αλλαγές στην κορεσμένότητα (±15%) για προσομοίωση διαφορετικών χρώσεων
- Περιστροφή του χρωματικού τροχού (±10°) για αντιμετώπιση διαφοράς χρωστικών
- Γκαουσιανό θόρυβο (σ=0.01) για προσομοίωση ατελειών σάρωσης

Γεωμετρικές Μετασχηματισμοί:

- Περιστροφές: 0°, 90°, 180°, 270° (διατήρηση βιολογικής σημασίας)
- Αντικατοπτρισμοί: Οριζόντιος και κάθετος
- Ελαστικές παραμορφώσεις: Για προσομοίωση φυσικών διακυμάνσεων ιστών

#### 4.1.4.3. Curriculum Learning Approach

Υιοθετήθηκε μια προσέγγιση βαθμιαίας μάθησης (curriculum learning) όπου το μοντέλο αρχικά εκπαιδεύεται σε απλούστερα παραδείγματα (καλά οριοθετημένα κύτταρα) και σταδιακά εκτίθεται σε πιο πολύπλοκες περιπτώσεις (επικαλυπτόμενα κύτταρα, παρτιακές δομές). Αυτή η στρατηγική βελτίωσε την τελική απόδοση κατά 8-12% σε σχέση με την παραδοσιακή τυχαία εκπαίδευση [5].

### 4.1.5. Αξιολόγηση και Μετρικές Απόδοσης

Για την αξιολόγηση της απόδοσης του προσαρμοσμένου Mask R-CNN, χρησιμοποιήθηκαν εξειδικευμένες μετρικές που ανταποκρίνονται στις απαιτήσεις των ιστοπαθολογικών εφαρμογών όπως φαίνεται στον παρακάτω πίνακα.

| Μετρικές Ανίχνευσης: | Μετρικές Κατάτμησης: |
|---|---|
| • mAP@0.5: Μέση ακρίβεια με IoU threshold 0.5<br>• mAP@0.75: Μέση ακρίβεια με αυστηρότερο threshold 0.75<br>• F1-Score ανά κλάση: Για αξιολόγηση απόδοσης σε κάθε κυτταρικό τύπο | • Dice Coefficient: Για ακρίβεια μάσκας κατάτμησης<br>• Jaccard Index (IoU): Για επικάλυψη προβλεπόμενων και πραγματικών μασκών<br>• Boundary F1-Score: Για ακρίβεια κυτταρικών ορίων |

*Πίνακα 3. Επιλογή μετρικών απόδοσης.*

Η προσαρμοσμένη έκδοση του Mask R-CNN συγκρίθηκε με standard μοντέλα σε τρία διαφορετικά datasets ιστοπαθολογίας:

| Μοντέλο | mAP@0.5 | Dice Score | Boundary F1 | Χρόνος Inference |
|---|---|---|---|---|
| Standard Mask R-CNN | 0.742 | 0.856 | 0.723 | 1.2s |

| | | | | |
|---|---|---|---|---|
| Προσαρμοσμένο Mask R-CNN | 0.834 | 0.923 | 0.856 | 1.4s |
| Βελτίωση | +12.4% | +7.8% | +18.4% | +16.7% |

*Πίνακα 4. Σύγκριση του Mask R-CNN με τα προσαρμοσμένα μοντέλα.*

Η ανάλυση των σφαλμάτων αποκάλυψε τρεις κύριες κατηγορίες προβλημάτων:

- Επικαλυπτόμενα κύτταρα (23% των σφαλμάτων): Δυσκολία διαχωρισμού πυκνά συσκευασμένων κυττάρων
- Ατελή όρια κυττάρων (34% των σφαλμάτων): Προβλήματα σε περιοχές με χαμηλή αντίθεση
- Σπάνιοι κυτταρικοί τύποι (43% των σφαλμάτων): Χαμηλή απόδοση σε υποαντιπροσωπευμένες κλάσεις

### 4.1.6. Βελτιστοποιήσεις για Πραγματικό Χρόνο

Για την υποστήριξη κλινικών εφαρμογών που απαιτούν γρήγορη ανταπόκριση, υλοποιήθηκαν διάφορες τεχνικές επιτάχυνσης:

- Model Pruning: Αφαίρεση 30% των λιγότερο σημαντικών συνδέσεων με ελάχιστη επίδραση στην ακρίβεια (<2% μείωση)
- Quantization: Μετατροπή από FP32 σε INT8, επιτυγχάνοντας 3.2× επιτάχυνση με 1.8% μείωση ακρίβειας
- Batch Processing: Βελτιστοποίηση για επεξεργασία πολλαπλών ROI ταυτόχρονα, μειώνοντας τον χρόνο ανά εικόνα κατά 45%

| Μέθοδος | Χρόνος Inference | mAP@0.5 | Μέγεθος Μοντέλου |
|---|---|---|---|
| Baseline | 1.4s | 0.834 | 245MB |
| + Pruning | 1.1s | 0.821 | 172MB |
| + Quantization | 0.43s | 0.819 | 63MB |
| + Batch Processing | 0.24s | 0.819 | 63MB |

*Πίνακα 5. Βελτιστοποίηση του Inference*

Η τελική βελτιστοποιημένη έκδοση επιτυγχάνει χρόνο inference 240ms ανά εικόνα διατηρώντας την κλινικά αποδεκτή ακρίβεια, καθιστώντας την κατάλληλη για εφαρμογές πραγματικού χρόνου στη διαγνωστική ιστοπαθολογία.

Η συνολική ροή εργασίας χαρακτηρίζεται από χρόνο επεξεργασίας 2-5 λεπτά ανά εικόνα υψηλής ανάλυσης, απαιτήσεις GPU μνήμης 4-8 GB ανάλογα με το batch size, ακρίβεια >95% σε τυποποιημένα datasets, και throughput 50-100 εικόνες/ώρα. Οι ποιοτικοί έλεγχοι περιλαμβάνουν automatic QC με απόρριψη εικόνων <70% ποιότητας, manual validation από ειδικούς σε 10% του δείγματος, 5-fold cross-validation σε νέα datasets, και seed control για reproducibility. Αυτή η ολοκληρωμένη ροή εργασίας εξασφαλίζει την

αξιόπιστη και επαναλήψιμη ανάλυση ιστοπαθολογικών εικόνων, παρέχοντας κλινικά χρήσιμες πληροφορίες που μπορούν να υποστηρίξουν τη διαγνωστική απόφαση.

## 4.2. Backbone Networks: ResNet-50 vs ResNet-101

### 4.2.1. Επισκόπηση Αρχιτεκτονικών Backbone για Ιστοπαθολογία

Η επιλογή της κατάλληλης backbone αρχιτεκτονικής αποτελεί κρίσιμη απόφαση που επηρεάζει άμεσα την απόδοση, την ταχύτητα και τις υπολογιστικές απαιτήσεις του συστήματος ανίχνευσης. Στο πλαίσιο της ιστοπαθολογίας, όπου οι εικόνες χαρακτηρίζονται από υψηλή ανάλυση και πολύπλοκες ιεραρχικές δομές, η αξιολόγηση διαφορετικών backbone δικτύων καθίσταται ακόμη πιο σημαντική.

Σύμφωνα με τη συστηματική ανασκόπηση 72 μελετών στη βιβλιογραφία της ιστοπαθολογίας, παρατηρείται σαφής προτίμηση σε συγκεκριμένες αρχιτεκτονικές [100]:

| Αρχιτεκτονική | Ποσοστό Χρήσης | Κύριες Εφαρμογές |
|---|---|---|
| **ResNet** | 30% | Γενικές ιστοπαθολογικές εφαρμογές, ταξινόμηση ιστών |
| **Inception** | 15% | Πολυκλιμακωτή ανάλυση, σύνθετες ιστικές δομές |
| **VGG** | 11% | Κλασική ταξινόμηση, transfer learning εφαρμογές |
| **EfficientNet** | 8% | Εφαρμογές με περιορισμένους υπολογιστικούς πόρους |
| **AlexNet** | 6% | Απλές εφαρμογές ταξινόμησης, εκπαιδευτικοί σκοποί |
| **U-Net** | 4% | Κατάτμηση ιστικών περιοχών |
| **MobileNet** | 4% | Mobile και embedded εφαρμογές |
| **YOLO** | 3% | Real-time ανίχνευση |
| **Xception** | 3% | Εξειδικευμένες εφαρμογές |
| **DenseNet** | 3% | Feature reuse εφαρμογές |
| **Άλλα** | 13% | Πειραματικές και υβριδικές αρχιτεκτονικές |

*Πίνακα 6. Ποσοστά των backbone αρχιτεκτονικών στην Ιστοπαθολογικά*

Η κυριαρχία των ResNet αρχιτεκτονικών (30%) οφείλεται στην ικανότητά τους να διαχειρίζονται βαθιά δίκτυα χωρίς το πρόβλημα της εξαφάνισης κλίσεων, καθώς και στην αποδεδειγμένη αποτελεσματικότητά τους σε ιατρικές εικόνες.

### 4.2.2. Τεχνική Ανάλυση ResNet-50 vs ResNet-101

Στον πίνακα 7 συνοψίζονται η ποιοτική σύγκριση μεταξύ τον δύο επικρατέστερων μοντέλων τύπου RESNET

| ResNet-50 | ResNet-101 |
|---|---|
| • Βάθος: 50 στρώματα<br>• Παράμετροι: ~25.6 εκατομμύρια<br>• Bottleneck blocks: 3, 4, 6, 3 (ανά stage)<br>• FLOPS: ~4.1B<br>• Μνήμη GPU: ~2.3 GB για batch size 16 | • Βάθος: 101 στρώματα<br>• Παράμετροι: ~44.7 εκατομμύρια<br>• Bottleneck blocks: 3, 4, 23, 3 (ανά stage)<br>• FLOPS: ~7.8B<br>• Μνήμη GPU: ~4.1 GB για batch size 16 |
| Πλεονεκτήματα: | Πλεονεκτήματα: |
| • Ταχύτερη εκπαίδευση και inference<br>• Χαμηλότερες απαιτήσεις μνήμης<br>• Καλύτερη σχέση απόδοσης/υπολογιστικού κόστους<br>• Λιγότερο επιρρεπές σε overfitting | • Υψηλότερη εκπαιδευτική ικανότητα<br>• Καλύτερη εξαγωγή λεπτομερών χαρακτηριστικών<br>• Ανώτερη απόδοση σε σύνθετα datasets |
| Μειονεκτήματα: | Μειονεκτήματα: |
| • Περιορισμένη εκπαιδευτική ικανότητα<br>• Πιθανά χαμηλότερη ακρίβεια σε πολύπλοκα δεδομένα | • Σημαντικά αυξημένες υπολογιστικές απαιτήσεις<br>• Αργότερη εκπαίδευση και inference<br>• Μεγαλύτερος κίνδυνος overfitting<br>• Υψηλότερες απαιτήσεις GPU μνήμης |

*Πίνακα 7. Ποσοστά των backbone αρχιτεκτονικών στην Ιστοπαθολογικά*

## 4.3. Στρατηγικές Μεταφοράς Μάθησης

Η μεταφορά μάθησης (transfer learning) αποτελεί κρίσιμη στρατηγική στην ιστοπαθολογία λόγω των περιορισμένων διαθέσιμων επισημειωμένων δεδομένων και του υψηλού κόστους δημιουργίας ground truth annotations από ειδικούς παθολόγους [101]. Αντί της εκπαίδευσης μοντέλων από το μηδέν, η στρατηγική αξιοποιεί την προϋπάρχουσα γνώση από μοντέλα που έχουν εκπαιδευτεί σε μεγάλα datasets όπως το ImageNet, προσαρμόζοντάς τα στις ειδικές απαιτήσεις των ιστοπαθολογικών εφαρμογών[102].

Τα χαμηλού επιπέδου χαρακτηριστικά που εξάγουν τα συνελικτικά δίκτυα (ακμές, υφές, γεωμετρικά σχήματα) είναι γενικεύσιμα μεταξύ διαφορετικών τομέων εικόνων [103]. Στην ιστοπαθολογία, αυτά τα χαρακτηριστικά αντιστοιχούν σε βασικές κυτταρικές δομές και ιστικά μοτίβα που είναι κοινά σε διαφορετικά όργανα και παθολογικές καταστάσεις.

Η στρατηγική περιλαμβάνει τρία βασικά στάδια:

1. Feature Extraction: Χρήση προεκπαιδευμένων βαρών για εξαγωγή χαρακτηριστικών
2. Fine-tuning: Προσαρμογή των τελικών στρωμάτων στο νέο domain
3. Domain Adaptation: Εξειδικευμένες τεχνικές για γεφύρωση του domain gap

Η προσαρμογή των προεκπαιδευμένων μοντέλων απαιτεί τροποποίηση του τελικού fully-connected στρώματος για να ταιριάζει στον αριθμό των κλάσεων της εκάστοτε εφαρμογής. Το αρχικό στρώμα με 1000 νευρώνες (αντίστοιχα των ImageNet κλάσεων) αντικαθίσταται με στρώμα που αντιστοιχεί στον αριθμό των ιστοπαθολογικών κλάσεων.

Η αποτελεσματικότητα της μεταφοράς μάθησης εξαρτάται κρίσιμα από την επιλογή των στρωμάτων που θα παραμείνουν "παγωμένα" (frozen) και αυτών που θα επαναεκπαιδευτούν [104]. Η ανάλυση που διεξήχθη αποκάλυψε διαφοροποιημένες στρατηγικές ανά αρχιτεκτονική:

| Αρχιτεκτονική | Αρχικές Παράμετροι | Frozen Weights | Τελικές Εκπαιδεύσιμες | Μείωση Παραμέτρων |
|---|---|---|---|---|
| **AlexNet** | 60,965,224 | Καμία | 56,868,224 | 4,097,000 (6.7%) |
| **VGG-16** | 138,357,544 | Conv Block 1 & 2 | 134,260,544 | 4,097,000 (3.0%) |
| **VGG-19** | 143,667,240 | Conv Block 1 & 2 | 139,570,240 | 4,097,000 (2.9%) |
| **ResNet-50** | 25,583,592 | Καμία | 23,534,592 | 2,049,000 (8.0%) |

*Πίνακα 8 . Λεπτομερείς ανάλυση ανά αρχιτεκτονική*

Η διαφοροποιημένη προσέγγιση στους ρυθμούς εκμάθησης αποτελεί κλειδί για την επιτυχή μεταφορά μάθησης [105]. Στον παρακάτω πίνακα συνοψίζονται προσεγγίσεις των βασικών παραμέτρων αλλά και εξειδικευμένες εκτιμήσεις για συγκεκριμένα μοντέλα.

| **Βασικές Παράμετροι:** | |
|---|---|
| • Global Learning Rate: 0.0001 (βελτιστοποιημένο για transfer learning) [9]<br>• Mini-batch Size: 32 image patches<br>• Training Epochs: 10 (με early stopping)<br>• Validation Patience: 3 epochs | |
| **-Εξειδικευμένοι Ρυθμοί βάσει αρχιτεκτονικής** | |
| AlexNet & ResNet-50: | VGG-16 & VGG-19: |
| • Weight Learn Rate Factor: 10<br>• Bias Learn Rate Factor: 10<br>• Effective Learning Rate: 10 × 0.0001 = 0.001 | • Weight Learn Rate Factor: 20<br>• Bias Learn Rate Factor: 20<br>• Effective Learning Rate: 20 × 0.0001 = 0.002 |

| | |
|---|---|

*Πίνακα 9 . Βασικές παράμετροι για τον ρυθμό εκμάθησης και εκτιμήσεις αυτών*

Η αύξηση των παραγόντων για τα VGG δίκτυα αντιμετωπίζει την αυξημένη πολυπλοκότητά τους και την ανάγκη για ισχυρότερη προσαρμογή των τελικών στρωμάτων.

### 4.3.1. Διαχείριση Domain Gap και Cross-Institutional Validation

Στην μεταφορά εκμάθησης λόγω του γεγονότος ότι τα προεκπαιδευμένα μοντέλα έχουν εκπαιδευτεί σε τελείως διαφορετικά αντικείμενα και εικόνες (domains), καθώς επίσης και από το γεγονός ότι οι εικόνες προέρχονται από διαφορετικές υποδομές δημιουργεί προβλήματα στην εκπαίδευση των αλγορίθμων.

1. Multi-Institutional Training: Εκπαίδευση με δεδομένα από πολλαπλά ιδρύματα
2. Domain Adversarial Training: Αντιγραφική εκπαίδευση για domain invariance
3. Stain Normalization: Κανονικοποίηση χρωματικών χαρακτηριστικών

Η μεταφορά από φυσικές εικόνες (ImageNet) σε ιστοπαθολογικές εικόνες εμφανίζει σημαντικό domain gap:

- Χρωματικές διαφορές: RGB vs χρωστικές H&E
- Υφές και μοτίβα: Φυσικές υφές vs κυτταρικές δομές
- Κλίμακες: Macro objects vs μικροσκοπικές δομές

Δοκιμές σε δεδομένα από 4 διαφορετικά ιδρύματα έδειξαν:

| Ίδρυμα | Local Validation | Cross-Institutional | Performance Drop |
|---|---|---|---|
| **Ίδρυμα A** | 95.1% | 89.2% | -5.9% |
| **Ίδρυμα B** | 94.8% | 91.3% | -3.5% |
| **Ίδρυμα C** | 94.2% | 87.6% | -6.6% |
| **Ίδρυμα D** | 93.9% | 90.1% | -3.8% |

*Πίνακα 10. Στατιστικά δοκίμων από τα ιδρύματα*

### 4.3.2. Αυτοματοποιημένη Αποθήκευση και Διαχείριση Βαρών

Η πλατφόρμα ενσωματώνει ένα εξελιγμένο σύστημα αποθήκευσης και διαχείρισης βαρών που βελτιστοποιεί τη διαδικασία εκπαίδευσης. Η επιλογή "model checkpoint" είναι ενεργοποιημένη για να αποθηκεύει τα βάρη που παράγουν τη μεγαλύτερη validation accuracy στο τέλος κάθε εποχής εκπαίδευσης. Το σύστημα αποθηκεύει:

- Best Model Weights: Βάρη με υψηλότερη validation accuracy
- Configuration Files: Πλήρεις παράμετροι εκπαίδευσης
- Training Metrics: Ιστορικό όλων των μετρικών απόδοσης
- Model Metadata: Αρχιτεκτονική, dataset info, timestamps

```
"configuration": {
  "training_id": 10,
  "cnn_backbone_id": 2,
  "augmentation_percentage": 61,
  "hyperconfigurations_enabled": 1,
  "augmentation_enabled": 1,
  "weight_file_id": 1,
  "created_at": "2024-01-18 12:17:06",
  "updated_at": "2024-01-18 12:17:10",
  "cnn_backbone": "ResNet-101"
}
```

*Πηγαίος Κώδικας 1. JSON Object από το configuration training*

### 4.3.3. Τεχνικές Αντιμετώπισης Ανισορροπίας Κλάσεων

Η ιστοπαθολογία χαρακτηρίζεται συχνά από σημαντική ανισορροπία κλάσεων. Με βάση την βιβλιογραφία οι ενδεικτικές τιμές διαφορετικών κλάσεων αναφέρονται α) Φυσιολογικοί ιστοί: 60-80% των δειγμάτων, β) Παθολογικές αλλαγές: 15-25% των δειγμάτων και γ) σπάνιες παθολογίες: 1-5% των δειγμάτων. Για να αντιμετωπιστεί αυτό το φαινόμενο υπάρχουν δοκιμάστηκαν τρείς διαφορετικές προσεγγίσεις εξισορρόπησής των κλάσεων και αντιμετώπισης του φαινομένου.

**1. Συνάρτηση σφάλματος με βάρη (Weight Loss Function):** Στην ουσία η συνάρτηση σφάλματος λαμβάνει υπόψιν την ανισορροπία μεταξύ των κλάσεων και επομένως προσαρμόζει βάρη με βάση αυτή την ανισορροπία.

```
class_weights = { 'normal_tissue': 0.6, 'mild_pathology': 1.2, 'severe_pathology': 2.5,
'rare_condition': 4.0 }

weighted_loss = CrossEntropyLoss(weight=class_weights)
```

*Πηγαίος Κώδικας 2. Weight class functions*

**2. Εστιασμένη Συνάρτηση σφάλματος (Focal Loss Function):** Αποτελεί μια άλλη προσέγγιση για την αντιμετώπιση της ανισορροπίας, όπως φαίνεται στην παρακάτω εξίσωση:

$$FL(pt) = -\alpha(1-pt)^{\gamma} \log(pt)$$

Όπου:

***α = 0.25****: Balancing factor*

***γ = 2**: Focusing parameter*

***pt**: Predicted probability for true class*

**3) Τεχνική Συνθετικής Υπερδειγματοληψίας της Μειοψηφικής Κλάσης (Synthetic Minority Oversampling Technique - SMOTE):**

- Spatial-aware SMOTE: Λαμβάνει υπόψη τη χωρική δομή των ιστών
- Stain-invariant generation: Διατηρεί χρωματικά χαρακτηριστικά
- Morphology-preserving: Διατηρεί βιολογική ρεαλιστικότητα

| Μέθοδος | Macro F1-Score | Rare Class Recall | Overall Accuracy |
|---|---|---|---|
| **Baseline** | 0.847 | 0.234 | 0.924 |
| **Weighted Loss** | 0.891 | 0.456 | 0.931 |
| **Focal Loss** | 0.923 | 0.567 | 0.946 |
| **SMOTE + Focal** | **0.952** | **0.678** | **0.951** |

*Πίνακα 11. Αποτελέσματα βελτιώσεις από τις Τεχνικές Αντιμετώπισης Ανισορροπίας Κλάσεων*

Όπως φαίνεται από τον Πίνακα 11 ο συνδυασμός της μεθόδου SMOTE + Focal Loss απέδωσε καλύτερα στα δεδομένα που δοκιμάστηκαν

### 4.3.4. Βέλτιστες Πρακτικές και Συστάσεις

Άλλες στρατηγικές που λήφθηκαν υπόψιν αφορούσαν την εκτίμηση του αριθμού των εικόνων αλλά και την αντιμετώπιση γνωστών φαινομένουν που παρουσιάζονται σε επιβλεπόμενες τεχνικές μάθησης, όπως για παράδειγμα τα φαινόμενα της υποεκπαίδευσης (underfitting) και της υπερεπκπαίδευσης (overfitting).

| Μικρά Datasets (<1,000 εικόνες) | Μεσαία Datasets (1,000-10,000 εικόνες) |
|---|---|
| • Στρατηγική: Feature extraction only<br>• Frozen Layers: Όλα εκτός από τα τελικά FC<br>• Learning Rate: 0.001-0.01<br>• Epochs: 5-10 | • Στρατηγική: Fine-tuning τελικών layers<br>• Frozen Layers: Πρώτα 50% των convolutional layers<br>• Learning Rate: 0.0001-0.001<br>• Epochs: 10-20 |
| **Μεγάλα Datasets (>10,000 εικόνες)** | |
| • Στρατηγική: Full fine-tuning<br>• Frozen Layers: Μόνο τα πρώτα 2-3 layers<br>• Learning Rate: 0.00001-0.0001 | |

| | |
|---|---|
| • Epochs: 20-50 | |

*Πίνακα 12. Υπερπαράμετροι με βάση το μέγεθος του συνόλου των εικόνων*

| **Overfitting σε Transfer Learning** Συμπτώματα: Μεγάλο gap training-validation accuracy Λύσεις: | **Underfitting με Frozen Layers** Συμπτώματα: Χαμηλή απόδοση σε training set Λύσεις: |
|---|---|
| • Αύξηση dropout rate (0.3 → 0.5)<br>• Ισχυρότερο data augmentation<br>• Μείωση learning rate<br>• Early stopping (patience = 3-5) | • Progressive unfreezing<br>• Αύξηση learning rate στα fine-tuned layers<br>• Εκπαίδευση για περισσότερα epochs |
| **Domain Mismatch Effects** Συμπτώματα: Καλά training results, κακό generalization Λύσεις: | |
| • Domain-specific augmentation<br>• Multi-source transfer learning<br>• Adversarial domain adaptation | |

*Πίνακα 13. Υπερπαράμετροι με βάση κλασικά προβλήματα εποπτευόμενων μεθόδων*

## 4.4. Τεχνικές Επαύξησης Δεδομένων και Προεπεξεργασία Εικόνας

### 4.4.1. Ολοκληρωμένη Προσέγγιση Αύξησης Δεδομένων

Η πλατφόρμα Deep-in-Biopsies εφαρμόζει μια ολοκληρωμένη στρατηγική αύξησης δεδομένων που συνδυάζει γεωμετρικούς μετασχηματισμούς με φωτομετρικές προσαρμογές, προσαρμοσμένη ειδικά για τις απαιτήσεις των ιστοπαθολογικών εικόνων. Αυτή η προσέγγιση αξιοποιεί την προηγμένη βιβλιοθήκη μετασχηματισμών του Detectron2, παρέχοντας ένα πλούσιο φάσμα τεχνικών που ενισχύουν τη γενικευσιμότητα και την αντοχή των εκπαιδευμένων μοντέλων [106].

Κεντρικό στοιχείο της στρατηγικής είναι η δυναμική παραμετροποίηση των τεχνικών αύξησης μέσω του configuration interface του Backend Module, που επιτρέπει στους χρήστες να προσαρμόζουν τις στρατηγικές αύξησης ανάλογα με τις ειδικές απαιτήσεις κάθε ιστοπαθολογικής εφαρμογής. Η ευελιξία αυτή είναι ιδιαίτερα σημαντική καθώς διαφορετικοί τύποι ιστών και χρώσεων απαιτούν διαφορετικές στρατηγικές αύξησης για τη διατήρηση της βιολογικής εγκυρότητας.

### 4.4.2. Στατιστική Κανονικοποίηση και Εξαγωγή Χρωματικών Παραμέτρων

Πρωτοποριακό χαρακτηριστικό της πλατφόρμας είναι η αυτοματοποιημένη εξαγωγή των στατιστικών RGB του συνόλου δεδομένων κατά την πρώτη εκπαίδευση. Το σύστημα υπολογίζει τη μέση τιμή των καναλιών κόκκινου, πράσινου και μπλε για ολόκληρο το σύνολο εκπαίδευσης, παρέχοντας μια βασική γραμμή αναφοράς για τη χρωματική κανονικοποίηση των δεδομένων.

Αυτή η διαδικασία είναι κρίσιμη για τη σταθεροποίηση της εκπαίδευσης και την αντιμετώπιση των παραλλαγών που μπορεί να προκύψουν από διαφορετικές συνθήκες απεικόνισης, τύπους μικροσκοπίων ή τεχνικές προετοιμασίας των δειγμάτων. Η μέση τιμή RGB χρησιμοποιείται ως σημείο αναφοράς για τις φωτομετρικές προσαρμογές που εφαρμόζονται κατά τη διάρκεια της αύξησης δεδομένων, εξασφαλίζοντας ότι οι μετασχηματισμοί διατηρούν τα φυσιολογικά χρωματικά χαρακτηριστικά των ιστοπαθολογικών εικόνων.

### 4.4.3. Προηγμένη Σειρά Μετασχηματισμών Detectron2

Η πλατφόρμα εφαρμόζει μια εξελιγμένη αλληλουχία μετασχηματισμών που καλύπτει το πλήρες φάσμα των δυνατοτήτων αύξησης δεδομένων. Η προεπιλεγμένη σειρά αρχίζει με την εφαρμογή ενός σταθερού μετασχηματισμού αλλαγής μεγέθους σε 1000×1000 pixels, ο οποίος εφαρμόζεται με πιθανότητα 100% για την τυποποίηση του μεγέθους εισόδου.

Ακολουθούν οι γεωμετρικοί μετασχηματισμοί που περιλαμβάνουν οριζόντια και κάθετη αναστροφή με προσαρμόσιμη πιθανότητα εφαρμογής. Οι αναστροφές υλοποιούνται ως ανεξάρτητοι μετασχηματισμοί, επιτρέποντας την ακριβή ρύθμιση της πιθανότητας εφαρμογής κάθε τύπου αναστροφής ανάλογα με τα χαρακτηριστικά του συνόλου δεδομένων και τις βιολογικές ιδιότητες των ιστών υπό εξέταση .

### 4.4.4. Φωτομετρικές Προσαρμογές και Χρωματικός Έλεγχος

Μια από τις πιο προηγμένες πτυχές του συστήματος αύξησης δεδομένων είναι η ενσωμάτωση φωτομετρικών μετασχηματισμών που προσαρμόζουν τα χρωματικά και φωτομετρικά χαρακτηριστικά των εικόνων χωρίς να επηρεάζουν τη βιολογική τους εγκυρότητα. Η ρύθμιση φωτεινότητας εφαρμόζεται με εύρος τιμών από 0.75 έως 1.25, παρέχοντας επαρκή παραλλαγή για την αντιμετώπιση διαφορετικών συνθηκών φωτισμού κατά τη λήψη των εικόνων.

Παράλληλα, η προσαρμογή αντίθεσης με εύρος από 0.76 έως 1.25 βοηθά τα μοντέλα να προσαρμόζονται σε εικόνες με διαφορετικά επίπεδα αντίθεσης, μια κοινή παραλλαγή στις ιστοπαθολογικές εικόνες λόγω των διαφορετικών τεχνικών προετοιμασίας και ψηφιοποίησης των δειγμάτων. Η ρύθμιση κορεσμού χρώματος, επίσης με εύρος 0.75 έως

1.25, επιτρέπει στα μοντέλα να γενικεύουν καλύτερα σε εικόνες με διαφορετικές εντάσεις χρώσης [107].

### 4.4.5. Στρατηγική Τυχαίας Κάλυψης και Χωρική Παραλλαγή

Η τεχνική τυχαίας κάλυψης (Random Crop) εφαρμόζεται με σχετικό εύρος 0.8×0.8, δημιουργώντας εικόνες που διατηρούν το 64% της αρχικής περιοχής. Αυτή η προσέγγιση είναι ιδιαίτερα αποτελεσματική για την εκπαίδευση μοντέλων που πρέπει να εστιάζουν σε τοπικά χαρακτηριστικά και να αγνοούν αλλότρια στοιχεία που μπορεί να υπάρχουν στην περιφέρεια των εικόνων.

Η στρατηγική αυτή αποδεικνύεται ιδιαίτερα χρήσιμη στην ιστοπαθολογία όπου οι εικόνες συχνά περιέχουν περιοχές με μικρή διαγνωστική αξία στις άκρες τους, όπως κενά χωρία ή τεχνικά artifacts. Η τυχαία κάλυψη εξαναγκάζει τα μοντέλα να εκμάθουν χαρακτηριστικά από διαφορετικές χωρικές θέσεις, ενισχύοντας την ικανότητά τους να αναγνωρίζουν σχήματα ανεξάρτητα από την ακριβή θέση τους στην εικόνα [108].

### 4.4.6. Περιστροφικοί Μετασχηματισμοί και Διατήρηση Γεωμετρίας

Οι περιστροφικοί μετασχηματισμοί υλοποιούνται με εύρος γωνιών από -30 έως +30 μοίρες, παρέχοντας σημαντική γεωμετρική παραλλαγή χωρίς να καταστρέφουν τα ανατομικά χαρακτηριστικά των ιστών. Η επιλογή να επεκτείνεται η εικόνα κατά τη διάρκεια της περιστροφής διασφαλίζει ότι δεν χάνονται σημαντικές πληροφορίες στις γωνίες, ενώ η τυχαία επιλογή κέντρου περιστροφής προσθέτει επιπλέον στοχαστικότητα στη διαδικασία.

Αυτή η προσέγγιση είναι ιδιαίτερα σημαντική για ιστοπαθολογικές εικόνες καθώς τα βιολογικά δείγματα μπορεί να έχουν τοποθετηθεί με διαφορετικούς προσανατολισμούς στο μικροσκόπιο. Οι περιστροφικοί μετασχηματισμοί βοηθούν τα μοντέλα να αναπτύξουν αναστολή περιστροφής, επιτρέποντάς τους να αναγνωρίζουν παθολογικές δομές ανεξάρτητα από τον προσανατολισμό τους [109].

### 4.4.7. Δυναμική Παραμετροποίηση και Προσαρμοστικότητα

Όλοι οι μετασχηματισμοί παραμετροποιούνται μέσω μιας κεντρικής μεταβλητής πιθανότητας που επιτρέπει τον εύκολο έλεγχο της έντασης της αύξησης δεδομένων. Αυτή η προσέγγιση παρέχει στους χρήστες τη δυνατότητα να προσαρμόζουν το επίπεδο αύξησης ανάλογα με το μέγεθος του συνόλου δεδομένων, την πολυπλοκότητα του προβλήματος, και τον διαθέσιμο υπολογιστικό χρόνο.

Για μικρά σύνολα δεδομένων, μπορεί να εφαρμοστεί υψηλότερη πιθανότητα αύξησης για τη δημιουργία μεγαλύτερης ποικιλίας, ενώ για μεγάλα σύνολα δεδομένων, μπορεί να χρησιμοποιηθεί μικρότερη πιθανότητα για τη διατήρηση της ποιότητας και την αποφυγή υπερπροσαρμογής σε τεχνητά παραγόμενες παραλλαγές. Αυτή η δυνατότητα

προσαρμογής καθιστά την πλατφόρμα κατάλληλη για ένα ευρύ φάσμα εφαρμογών, από προκαταρκτικές μελέτες με περιορισμένα δεδομένα έως εκτεταμένες κλινικές έρευνες [110].

### 4.4.8. Αυτοματοποιημένο Pipeline και Backend Integration

Η ενσωμάτωση των τεχνικών αύξησης δεδομένων με το Backend Module δημιουργεί ένα πλήρως αυτοματοποιημένο pipeline που διαχειρίζεται όλες τις πτυχές της προεπεξεργασίας δεδομένων. Το AI Application Module ανακτά τις στρατηγικές αύξησης από το Backend μέσω του configuration interface και εφαρμόζει τους κατάλληλους μετασχηματισμούς κατά τη διάρκεια της εκπαίδευσης.

Αυτή η αρχιτεκτονική εξασφαλίζει συνέπεια στην εφαρμογή των τεχνικών αύξησης σε όλες τις εκπαιδεύσεις και επιτρέπει την εύκολη αναπαραγωγή αποτελεσμάτων. Οι παράμετροι αύξησης αποθηκεύονται μαζί με τα metadata της εκπαίδευσης, παρέχοντας πλήρη ιχνηλασιμότητα και διευκολύνοντας τη συγκριτική αξιολόγηση διαφορετικών στρατηγικών [55].

### 4.4.9. Βελτιστοποίηση Απόδοσης με CUDA Integration

Η εκτέλεση των τεχνικών αύξησης δεδομένων βελτιστοποιείται μέσω της ενσωμάτωσης CUDA που επιταχύνει σημαντικά τις διαδικασίες μετασχηματισμού εικόνας. Η GPU επιτάχυνση είναι ιδιαίτερα σημαντική για τις ιστοπαθολογικές εικόνες υψηλής ανάλυσης, όπου οι μετασχηματισμοί μπορεί να απαιτούν σημαντικό υπολογιστικό χρόνο.

Η CUDA υποστήριξη επιτρέπει την παράλληλη επεξεργασία πολλαπλών εικόνων και την αποδοτική εκτέλεση σύνθετων μετασχηματισμών όπως οι περιστροφές και οι φωτομετρικές προσαρμογές. Αυτό οδηγεί σε μείωση του χρόνου προετοιμασίας των δεδομένων κατά 60-80% σε σχέση με την εκτέλεση μόνο σε CPU, επιτρέποντας ταχύτερους κύκλους πειραματισμού και ανάπτυξης (NVIDIA, 2021).

Η αποτελεσματικότητα των τεχνικών αύξησης δεδομένων έχει αποδειχθεί σε διάφορες ιστοπαθολογικές εφαρμογές της πλατφόρμας. Στην ανάλυση ηπατικών βιοψιών για την αξιολόγηση λιπώδους νόσου, η εφαρμογή των προηγμένων τεχνικών αύξησης οδήγησε σε βελτίωση της ακρίβειας κατάταξης κατά 12-18% σε σχέση με βασικές τεχνικές αναστροφής. Παρόμοια, στην ανάλυση εντερικών βιοψιών για φλεγμονώδη νοσήματα, οι φωτομετρικές προσαρμογές αποδείχθηκαν ιδιαίτερα χρήσιμες για την αντιμετώπιση παραλλαγών στη χρώση που προκύπτουν από διαφορετικά εργαστήρια. Η συνδυασμένη εφαρμογή γεωμετρικών και φωτομετρικών μετασχηματισμών οδήγησε σε μοντέλα με βελτιωμένη γενικευσιμότητα και μειωμένη εξάρτηση από συγκεκριμένες συνθήκες λήψης των εικόνων [112].

Παρότι η τρέχουσα υλοποίηση εστιάζει κυρίως σε γεωμετρικούς και βασικούς φωτομετρικούς μετασχηματισμούς, η αρχιτεκτονική της πλατφόρμας επιτρέπει την εύκολη ενσωμάτωση προηγμένων τεχνικών αύξησης δεδομένων. Στα μελλοντικά σχέδια

περιλαμβάνεται η προσθήκη τεχνικών κανονικοποίησης χρώσης (stain normalization) που θα αντιμετωπίζουν συστηματικά τις παραλλαγές που προκύπτουν από διαφορετικές τεχνικές χρώσης. Επιπλέον, προβλέπεται η ενσωμάτωση τεχνικών HSV jitter που θα παρέχουν πιο εξελιγμένο έλεγχο των χρωματικών χαρακτηριστικών, καθώς και τεχνικών elastic deformation που θα προσομοιώνουν φυσικές παραμορφώσεις των ιστών. Αυτές οι προσθήκες θα ενισχύσουν περαιτέρω την ικανότητα των μοντέλων να γενικεύουν σε διαφορετικές συνθήκες και να αντιμετωπίζουν την ποικιλομορφία που χαρακτηρίζει τα πραγματικά κλινικά δεδομένα [113].

## 4.5. Χειροκίνητη Ρύθμιση Υπερπαραμέτρων

### 4.5.1. Φιλοσοφία Χειροκίνητης Βελτιστοποίησης σε Κλινικά Περιβάλλοντα

Στον τομέα της ιστοπαθολογικής ανάλυσης, η τέχνη της χειροκίνητης ρύθμισης υπερπαραμέτρων αποτελεί έναν κρίσιμο συνδυασμό επιστημονικής μεθοδολογίας και πρακτικής σκοπιμότητας. Σε αντίθεση με τις αυτοματοποιημένες προσεγγίσεις βελτιστοποίησης που απαιτούν εκατοντάδες επαναληπτικές εκπαιδεύσεις, η χειροκίνητη προσέγγιση αναγνωρίζει τους πραγματικούς περιορισμούς που αντιμετωπίζουν οι κλινικοί ερευνητές: περιορισμένο χρόνο, περιορισμένους υπολογιστικούς πόρους, και την ανάγκη για άμεσα εφαρμόσιμα αποτελέσματα [114].

Αυτή η στρατηγική δεν αντιπροσωπεύει μια παραχώρηση στην ποιότητα, αλλά μια συνειδητή επιλογή που εκμεταλλεύεται την ανθρώπινη εξειδίκευση και την εμπειρική γνώση για την επίτευξη αποτελεσματικών λύσεων. Οι ιστοπαθολόγοι και οι ερευνητές, μέσω του intuitive interface του Backend Module, αποκτούν τον έλεγχο των κρίσιμων παραμέτρων που καθορίζουν την απόδοση των μοντέλων, δημιουργώντας μια συνεργατική σχέση μεταξύ ανθρώπινης εξειδίκευσης και τεχνητής νοημοσύνης.

### 4.5.2. Αρχιτεκτονική Configuration Interface και Παραμετρική Διαχείριση

Το configuration interface του Backend Module αποτελεί το κεντρικό σημείο ελέγχου για όλες τις πτυχές της εκπαίδευσης, παρέχοντας στους ερευνητές μια ολοκληρωμένη πλατφόρμα για την παραμετροποίηση των μοντέλων ανά training set. Αυτό το σύστημα επιτρέπει την αποθήκευση και διαχείριση πολλαπλών configuration profiles, καθένα προσαρμοσμένο στις ειδικές απαιτήσεις διαφορετικών ιστοπαθολογικών εφαρμογών.

Κάθε training set διαθέτει το δικό του configuration space όπου ο ερευνητής μπορεί να ορίσει όχι μόνο τις βασικές υπερπαραμέτρους εκπαίδευσης, αλλά και εξειδικευμένες ρυθμίσεις που αφορούν τον τύπο των δεδομένων, την επιλεγμένη αρχιτεκτονική, και τις στρατηγικές augmentation. Αυτή η προσέγγιση εξασφαλίζει ότι κάθε εφαρμογή μπορεί

να βελτιστοποιηθεί ανεξάρτητα, χωρίς να επηρεάζει άλλα έργα που τρέχουν παράλληλα στην πλατφόρμα.

Το interface παρέχει επίσης προηγμένες δυνατότητες version control για τις παραμέτρους, επιτρέποντας στους χρήστες να διατηρούν ιστορικό των αλλαγών και να επιστρέφουν σε προηγούμενες configurations που είχαν καλά αποτελέσματα. Αυτή η ιχνηλασιμότητα είναι κρίσιμη για την επιστημονική αναπαραγωγιμότητα και την τεκμηρίωση των πειραματικών διαδικασιών.

### 4.5.3. Εμπειρικά Καθιερωμένες Βασικές Παράμετροι

Το σύστημα ξεκινά με ένα σύνολο εμπειρικά δοκιμασμένων βασικών παραμέτρων που έχουν αποδειχθεί αποτελεσματικές σε ένα ευρύ φάσμα ιστοπαθολογικών εφαρμογών. Ο global learning rate καθορίζεται σε 0.0001, μια τιμή που αντιπροσωπεύει το βέλτιστο σημείο μεταξύ ταχύτητας σύγκλισης και σταθερότητας για transfer learning εφαρμογές. Αυτή η επιλογή εξασφαλίζει ότι τα προεκπαιδευμένα βάρη δεν θα αλλάξουν δραματικά, διατηρώντας την πολύτιμη γνώση που έχουν αποκτήσει από μεγάλα σύνολα δεδομένων.

Το mini-batch size ρυθμίζεται σε 32 image patches, μια τιμή που αντιπροσωπεύει έναν ισορροπημένο συμβιβασμό μεταξύ της σταθερότητας των gradient estimations και των περιορισμών μνήμης GPU. Αυτό το μέγεθος επιτρέπει την αποτελεσματική επεξεργασία εικόνων υψηλής ανάλυσης ακόμα και σε GPU μεσαίας κατηγορίας, διευκολύνοντας την πρόσβαση σε ερευνητικές ομάδες με περιορισμένους πόρους.

Ο μέγιστος αριθμός training epochs καθορίζεται σε 10, αντανακλώντας την εμπειρική παρατήρηση ότι τα ιστοπαθολογικά μοντέλα τείνουν να συγκλίνουν σχετικά γρήγορα όταν χρησιμοποιείται transfer learning. Η validation patience ορίζεται σε 3, παρέχοντας έναν αποτελεσματικό μηχανισμό πρώιμης διακοπής που προστατεύει από την υπερπροσαρμογή.

### 4.5.4. Διαφοροποιημένες Στρατηγικές ανά Αρχιτεκτονική

Ένα από τα πιο εξελιγμένα χαρακτηριστικά του configuration system είναι η ικανότητά του να προσαρμόζει αυτόματα ορισμένες παραμέτρους βάσει της επιλεγμένης αρχιτεκτονικής, ενώ παράλληλα επιτρέπει στον ερευνητή να κάνει fine-tuning όπου απαιτείται. Για τα AlexNet και ResNet-50 μοντέλα, οι weight και bias learn rate factors ρυθμίζονται σε 10, δημιουργώντας έναν αποτελεσματικό ρυθμό εκμάθησης 0.001 για τα τελικά επίπεδα.

Για τα βαθύτερα δίκτυα VGG-16 και VGG-19 δίκτυα, αυτοί οι παράγοντες αυξάνονται σε 20, αντανακλώντας την ανάγκη για ισχυρότερη προσαρμογή των τελικών επιπέδων σε αυτές τις πιο σύνθετες αρχιτεκτονικές. Επιπλέον, για τα VGG μοντέλα εφαρμόζεται επιλεκτικό freezing των δύο πρώτων convolutional blocks, διατηρώντας τα χαμηλού επιπέδου χαρακτηριστικά ενώ επιτρέπει την προσαρμογή των υψηλότερων επιπέδων.

Αυτή η διαφοροποιημένη προσέγγιση αναγνωρίζει ότι διαφορετικές αρχιτεκτονικές έχουν διαφορετικές απαιτήσεις βελτιστοποίησης και παρέχει στους ερευνητές αυτόματες, αλλά προσαρμόσιμες, βασικές ρυθμίσεις που μπορούν να χρησιμεύσουν ως σημεία εκκίνησης για περαιτέρω πειραματισμό.

### 4.5.5. Οπτικά Εργαλεία Ανάλυσης και Καθοδήγηση Αποφάσεων

Η αποτελεσματικότητα της χειροκίνητης ρύθμισης εξαρτάται σε μεγάλο βαθμό από την ικανότητα του ερευνητή να κατανοήσει τη συμπεριφορά του μοντέλου κατά τη διάρκεια της εκπαίδευσης. Το σύστημα παρέχει ολοκληρωμένα διαγράμματα εκπαίδευσης που απεικονίζουν την εξέλιξη των βασικών μετρικών σε πραγματικό χρόνο, επιτρέποντας την άμεση αναγνώριση προβλημάτων και την έγκαιρη παρέμβαση.

Τα διαγράμματα απεικονίζουν παράλληλα τις καμπύλες training και validation loss, παρέχοντας άμεση οπτική ένδειξη για φαινόμενα υπερπροσαρμογής. Όταν η validation loss αρχίζει να αυξάνεται ενώ η training loss συνεχίζει να μειώνεται, αυτό αποτελεί σαφές σημάδι ότι το μοντέλο αρχίζει να "απομνημονεύει" τα training δεδομένα αντί να γενικεύει.

Επιπλέον μετρικές όπως η ακρίβεια, η ευαισθησία, η εξειδίκευση, το DICE score, το F1 score, και το Jaccard index παρακολουθούνται και απεικονίζονται σε πραγματικού χρόνου, παρέχοντας στον ερευνητή μια ολοκληρωμένη εικόνα της απόδοσης του μοντέλου. Αυτές οι εξειδικευμένες μετρικές είναι ιδιαίτερα σημαντικές στην ιστοπαθολογία όπου η ακρίβεια της κατάτμησης και η ικανότητα εντοπισμού σπάνιων παθολογικών δομών είναι κρίσιμες.

### 4.5.6. Στρατηγική Βήμα-προς-Βήμα Βελτιστοποίησης

Αντί της ταυτόχρονης τροποποίησης πολλαπλών παραμέτρων, το σύστημα ενθαρρύνει μια μεθοδική προσέγγιση όπου κάθε αλλαγή δοκιμάζεται και αξιολογείται ξεχωριστά. Αυτή η μεθοδολογία αρχίζει με την εκτέλεση μιας baseline εκπαίδευσης χρησιμοποιώντας τις προκαθορισμένες παραμέτρους, δημιουργώντας ένα σημείο αναφοράς για μελλοντικές συγκρίσεις.

Εάν η αρχική απόδοση δεν είναι ικανοποιητική, ο ερευνητής μπορεί να προβεί σε στοχευμένες προσαρμογές βάσει των παρατηρήσεων από τα διαγράμματα εκπαίδευσης. Για παράδειγμα, εάν η εκπαίδευση φαίνεται πολύ αργή ή η σύγκλιση ανεπαρκής, μπορεί να δοκιμαστεί μια αύξηση του learning rate ή του αριθμού των epochs. Αντίθετα, εάν παρατηρηθούν σημάδια υπερπροσαρμογής, μπορεί να εφαρμοστεί μικρότερος learning rate ή ισχυρότερες τεχνικές augmentation.

Κάθε πειραματικός κύκλος τεκμηριώνεται πλήρως στο σύστημα, δημιουργώντας ένα ιστορικό αποφάσεων και αποτελεσμάτων που μπορεί να χρησιμεύσει ως οδηγός για μελλοντικές εφαρμογές. Αυτή η συσσωρευτική μάθηση επιτρέπει στους ερευνητές να

αναπτύξουν intuition για τη συμπεριφορά διαφορετικών παραμέτρων σε διαφορετικούς τύπους δεδομένων.

### 4.5.7. Προσαρμογή στις Ειδικές Απαιτήσεις των Δεδομένων

Κάθε τύπος ιστοπαθολογικών δεδομένων παρουσιάζει μοναδικές προκλήσεις που απαιτούν εξειδικευμένες στρατηγικές βελτιστοποίησης. Για εικόνες με υψηλή ενδοκλασική παραλλαγή, όπως συμβαίνει συχνά στον καρκίνο, μπορεί να απαιτηθεί αυξημένη αύξηση δεδομένων και μικρότερος learning rate για την αποφυγή της υπεργενίκευσης σε συγκεκριμένα μορφολογικά χαρακτηριστικά.

Αντίθετα, για εφαρμογές με σαφώς διαχωρισμένες κλάσεις, όπως η διάκριση φυσιολογικού από παθολογικό ιστό, μπορεί να χρησιμοποιηθεί πιο επιθετική εκπαίδευση με υψηλότερο learning rate και λιγότερες τεχνικές regularization. Το configuration interface επιτρέπει την εύκολη προσαρμογή αυτών των παραμέτρων ανάλογα με τη φύση του προβλήματος.

Επιπλέον, για σύνολα δεδομένων με σημαντική ανισορροπία κλάσεων, το σύστημα παρέχει προηγμένες επιλογές για την προσαρμογή των loss functions και την εφαρμογή τεχνικών όπως class weighting ή focal loss που αντιμετωπίζουν αποτελεσματικά αυτά τα προβλήματα.

### 4.5.8. Εκμετάλλευση Ensemble Strategies και Model Comparison

Το configuration system υποστηρίζει επίσης προηγμένες στρατηγικές που περιλαμβάνουν την εκπαίδευση πολλαπλών μοντέλων με διαφορετικές παραμέτρους και την εφαρμογή ensemble μεθόδων για τη βελτίωση της τελικής απόδοσης. Οι ερευνητές μπορούν να δημιουργήσουν πολλαπλά configuration profiles για το ίδιο training set, εκπαιδεύοντας παράλληλα διαφορετικές αρχιτεκτονικές ή παραμετρικούς συνδυασμούς.

Αυτή η προσέγγιση επιτρέπει τη συγκριτική αξιολόγηση διαφορετικών στρατηγικών και την επιλογή του βέλτιστου μοντέλου ή συνδυασμού μοντέλων για την τελική εφαρμογή. Το σύστημα παρέχει αυτοματοποιημένα εργαλεία σύγκρισης που απεικονίζουν την απόδοση διαφορετικών configurations στις ίδιες μετρικές, διευκολύνοντας τη λήψη τεκμηριωμένων αποφάσεων [115].

### 4.5.9. Διαχείριση Υπολογιστικών Πόρων και Χρονικών Περιορισμών

Ένα από τα βασικά πλεονεκτήματα της χειροκίνητης προσέγγισης είναι η αποδοτική διαχείριση των υπολογιστικών πόρων. Αντί να δαπανά εβδομάδες σε αυτοματοποιημένη αναζήτηση παραμέτρων, ο έμπειρος ερευνητής μπορεί να εστιάσει σε στοχευμένες δοκιμές που έχουν υψηλή πιθανότητα επιτυχίας βάσει της κατανόησης του προβλήματος.

Το configuration interface παρέχει εκτιμήσεις του αναμενόμενου χρόνου εκπαίδευσης για κάθε παραμετρικό συνδυασμό, επιτρέποντας στους ερευνητές να προγραμματίζουν τα πειράματά τους αποδοτικά. Επιπλέον, η δυνατότητα παύσης και συνέχισης της εκπαίδευσης παρέχει ευελιξία στη διαχείριση των υπολογιστικών πόρων και επιτρέπει την εκμετάλλευση των διαθέσιμων GPU κατά τις ώρες χαμηλής χρήσης.

### 4.5.10. Μελλοντικές Κατευθύνσεις και Hibrid Approaches

Παρόλο που η τρέχουσα προσέγγιση εστιάζει στη χειροκίνητη βελτιστοποίηση, το σύστημα έχει σχεδιαστεί με την ευελιξία να ενσωματώσει στο μέλλον ημι-αυτόματες προσεγγίσεις που θα συνδυάζουν την ανθρώπινη εξειδίκευση με αυτοματοποιημένες τεχνικές. Αυτές οι υβριδικές στρατηγικές θα μπορούσαν να περιλαμβάνουν έξυπνες συστάσεις παραμέτρων βάσει των χαρακτηριστικών των δεδομένων, αυτοματοποιημένη ρύθμιση δευτερευόντων παραμέτρων, ή προσαρμοστικούς αλγόριθμους που μαθαίνουν από τις προτιμήσεις και τις επιλογές των ερευνητών.

Αυτή η εξελικτική προσέγγιση θα επιτρέψει στο σύστημα να διατηρήσει τα πλεονεκτήματα της ανθρώπινης εξειδίκευσης ενώ παράλληλα θα εκμεταλλεύεται τις δυνατότητες των σύγχρονων τεχνικών βελτιστοποίησης για την επίτευξη ακόμα καλύτερων αποτελεσμάτων με μικρότερη χειρωνακτική προσπάθεια.

## 4.6. Υποστήριξη Πολλαπλών Μονάδων Γραφικών

### 4.6.1. Κρισιμότητα της Επιτάχυνσης Μονάδων Γραφικών στην Ιστοπαθολογική Ανάλυση

Η επεξεργασία ιστοπαθολογικών εικόνων αντιπροσωπεύει έναν από τους πιο υπολογιστικά εντατικούς τομείς της ιατρικής απεικόνισης, όπου οι εικόνες υψηλής ανάλυσης μπορεί να φτάνουν τα gigabytes σε μέγεθος και τα μοντέλα βαθιάς μάθησης να απαιτούν εκατομμύρια παραμέτρους για την επίτευξη κλινικά χρήσιμων αποτελεσμάτων. Σε αυτό το πλαίσιο, η αξιοποίηση της παράλληλης επεξεργαστικής ισχύος των μονάδων επεξεργασίας γραφικών δεν αποτελεί απλή βελτίωση απόδοσης, αλλά βασική προϋπόθεση για την πρακτική εφαρμογή των τεχνικών τεχνητής νοημοσύνης στην ιστοπαθολογία [116].

Η αρχιτεκτονική επεξεργασίας του συστήματος βασίζεται στη στρατηγική αξιοποίηση του πλαισίου εργασίας CUDA της NVIDIA, το οποίο επιτρέπει την αποδοτική εκτέλεση των συνελικτικών νευρωνικών δικτύων σε μονάδες επεξεργασίας γραφικών. Αυτή η τεχνολογική επιλογή δεν αντικατοπτρίζει απλά την ανάγκη για ταχύτητα, αλλά και την απαίτηση για οικονομική βιωσιμότητα, καθώς επιτρέπει την επίτευξη αποτελεσμάτων υψηλής ποιότητας με σχετικά περιορισμένους υλικούς πόρους σε σύγκριση με τις εναλλακτικές λύσεις που βασίζονται αποκλειστικά σε κεντρικούς επεξεργαστές.

### 4.6.2. Αρχιτεκτονική Πολλαπλών Μονάδων Γραφικών και Κατανεμημένη Επεξεργασία

Το σύστημα υποστηρίζει προηγμένες τεχνικές κατανεμημένης εκπαίδευσης που επιτρέπουν την αξιοποίηση πολλαπλών μονάδων επεξεργασίας γραφικών για την επιτάχυνση των διαδικασιών εκπαίδευσης και εξαγωγής προβλέψεων. Αυτή η δυνατότητα υλοποιείται μέσω του εξελιγμένου πλαισίου παραλληλισμού δεδομένων του Detectron2, το οποίο αυτόματα κατανέμει τις ομάδες εικόνων σε διαφορετικές μονάδες γραφικών ενώ συγχρονίζει τις παραμέτρους του μοντέλου σε κάθε βήμα εκπαίδευσης. Η στρατηγική κατανομής δεδομένων λαμβάνει υπόψη τις ειδικές απαιτήσεις των ιστοπαθολογικών εικόνων, όπου το μεγάλο μέγεθος κάθε εικόνας μπορεί να περιορίσει τον αριθμό των δειγμάτων που μπορούν να επεξεργαστούν ταυτόχρονα. Το σύστημα εφαρμόζει έξυπνες τεχνικές μνήμης που επιτρέπουν την αποδοτική διαχείριση της μνήμης μονάδων γραφικών ακόμα και για εικόνες gigapixel, μέσω τεχνικών όπως η συσσώρευση κλίσεων και η έξυπνη ομαδοποίηση δεδομένων. Επιπλέον, η αρχιτεκτονική υποστηρίζει τόσο διαμορφώσεις ενός κόμβου με πολλαπλές μονάδες γραφικών όσο και κατανεμημένη εκπαίδευση πολλαπλών κόμβων, επιτρέποντας την κλιμάκωση από μικρές ερευνητικές εγκαταστάσεις με 2-4 μονάδες γραφικών έως μεγάλα υπολογιστικά κέντρα με δεκάδες κόμβους επεξεργασίας.

### 4.6.3. Βελτιστοποιήσεις Μνήμης και Αποδοτικότητας

Η διαχείριση της μνήμης μονάδων γραφικών αποτελεί κρίσιμο παράγοντα για την επιτυχή εκπαίδευση μοντέλων σε ιστοπαθολογικά δεδομένα. Το σύστημα ενσωματώνει προηγμένες τεχνικές βελτιστοποίησης μνήμης που επιτρέπουν την επεξεργασία μεγαλύτερων ομάδων δεδομένων και πιο σύνθετων μοντέλων χωρίς να προκαλείται εξάντληση της διαθέσιμης μνήμης. Μια από τις βασικές τεχνικές είναι τα σημεία ελέγχου κλίσεων, η οποία ανταλλάσσει μνήμη με υπολογιστικό χρόνο επιτρέποντας την εκπαίδευση μεγαλύτερων μοντέλων με περιορισμένη μνήμη. Επιπλέον, το σύστημα υλοποιεί στρατηγικές δυναμικής κατανομής μνήμης που προσαρμόζουν τη χρήση μνήμης βάσει του τρέχοντος φόρτου εργασίας και των διαθέσιμων πόρων κάθε μονάδας γραφικών [117]. Η αποδοτικότητα ενισχύεται περαιτέρω μέσω τεχνικών όπως η εκπαίδευση μεικτής ακριβείας, που χρησιμοποιεί αριθμητική κινητού σημείου 16-bit για ορισμένες πράξεις ενώ διατηρεί ακρίβεια 32-bit όπου απαιτείται για τη σταθερότητα. Αυτή η προσέγγιση μπορεί να επιταχύνει την εκπαίδευση κατά 40-60% ενώ παράλληλα μειώνει τη χρήση μνήμης κατά περίπου 50%.

### 4.6.4. Αυτοματοποιημένη Διαχείριση Υπολογιστικών Πόρων

Το σύστημα περιλαμβάνει έναν ευφυή διαχειριστή πόρων που αυτόματα εντοπίζει και αξιοποιεί τους διαθέσιμους υπολογιστικούς πόρους. Αυτός ο διαχειριστής παρακολουθεί τη διαθεσιμότητα μονάδων γραφικών, τη χρήση μνήμης, και την υπολογιστική φόρτωση σε πραγματικό χρόνο, λαμβάνοντας δυναμικές αποφάσεις για τη βέλτιστη κατανομή

εργασιών. Όταν πολλαπλοί χρήστες εκτελούν ταυτόχρονες εκπαιδεύσεις, ο διαχειριστής πόρων εφαρμόζει έξυπνους αλγόριθμους χρονοδρομολόγησης που εξισορροπούν τη φόρτωση μεταξύ των διαθέσιμων μονάδων γραφικών, αποτρέποντας σημεία συμφόρησης και βελτιστοποιώντας τη συνολική παραγωγικότητα του συστήματος. Επιπλέον, υποστηρίζει χρονοδρομολόγηση βάσει προτεραιότητας που επιτρέπει την προτεραιοποίηση κρίσιμων εκπαιδεύσεων. Ιδιαίτερα χρήσιμη είναι η δυνατότητα του συστήματος να προσαρμόζεται αυτόματα στις διαθέσιμες υλικές προδιαγραφές. Εάν ανιχνευτεί μόνο μία μονάδα γραφικών, το σύστημα λειτουργεί σε λειτουργία μίας μονάδας. Εάν είναι διαθέσιμες πολλαπλές μονάδες, ενεργοποιεί αυτόματα τις βελτιστοποιήσεις πολλαπλών μονάδων. Αυτή η προσαρμοστικότητα εξασφαλίζει ότι το σύστημα μπορεί να λειτουργήσει αποδοτικά σε ένα ευρύ φάσμα υλικών διαμορφώσεων, από σταθμούς εργασίας μίας μονάδας έως συστοιχίες εξυπηρετητών υψηλής απόδοσης.

### 4.6.5. Παράλληλη Επεξεργασία

Η αύξηση δεδομένων και η προεπεξεργασία εικόνων, που αποτελούν χρονοβόρες διαδικασίες στην ιστοπαθολογική ανάλυση, βελτιστοποιούνται μέσω παράλληλης επεξεργασίας σε μονάδες γραφικών. Το σύστημα αξιοποιεί τις δυνατότητες του CUDA για την εκτέλεση γεωμετρικών και φωτομετρικών μετασχηματισμών απευθείας στη μνήμη των μονάδων γραφικών, αποφεύγοντας τις κοστοβόρες μεταφορές μνήμης μεταξύ κεντρικού επεξεργαστή και μονάδων γραφικών. Αυτή η προσέγγιση είναι ιδιαίτερα αποδοτική για τις ιστοπαθολογικές εικόνες υψηλής ανάλυσης, όπου οι παραδοσιακές τεχνικές αύξησης δεδομένων που βασίζονται σε κεντρικούς επεξεργαστές μπορεί να αποτελέσουν το κυρίαρχο σημείο συμφόρησης της εκπαίδευσης. Με την αξιοποίηση του αγωγού προεπεξεργασίας επιταχυνόμενου από μονάδες γραφικών, το σύστημα επιτυγχάνει παραγωγικότητα αύξησης δεδομένων που είναι 5-10 φορές υψηλότερη από τις αντίστοιχες υλοποιήσεις κεντρικών επεξεργαστών.

Επιπλέον, το σύστημα υλοποιεί ασύγχρονη φόρτωση δεδομένων που επιτρέπει την παράλληλη εκτέλεση της προεπεξεργασίας στη μία μονάδα γραφικών ενώ η εκπαίδευση του μοντέλου συνεχίζεται σε άλλη μονάδα, μεγιστοποιώντας την αξιοποίηση των διαθέσιμων πόρων.

### 4.6.6. Παρακολούθηση και Αναλυτικά Στοιχεία Απόδοσης

Για την αποδοτική διαχείριση των εκπαιδεύσεων πολλαπλών μονάδων γραφικών, το σύστημα παρέχει ολοκληρωμένα εργαλεία παρακολούθησης που παρακολουθούν όλες τις κρίσιμες μετρικές απόδοσης σε πραγματικό χρόνο. Αυτά περιλαμβάνουν ποσοστά αξιοποίησης μονάδων γραφικών, μοτίβα χρήσης μνήμης, θερμικές συνθήκες, και επιβάρυνση επικοινωνίας μεταξύ των μονάδων γραφικών.

Τα ταμπλό αναλυτικών στοιχείων παρέχουν λεπτομερή ανάλυση της απόδοσης, επιτρέποντας στους διαχειριστές να εντοπίσουν σημεία συμφόρησης, να βελτιστοποιήσουν τις διαμορφώσεις, και να προβλέψουν τις ανάγκες σε υπολογιστικούς

πόρους. Ιδιαίτερα χρήσιμες είναι οι προειδοποιήσεις για συνθήκες που μπορεί να επηρεάσουν την απόδοση, όπως υπερθέρμανση, κατακερματισμός μνήμης, ή ανισορροπία φόρτωσης μεταξύ μονάδων γραφικών.

Το σύστημα καταγράφει επίσης ιστορικά δεδομένα απόδοσης που επιτρέπουν την ανάλυση τάσεων και την προγνωστική βελτιστοποίηση. Αυτές οι πληροφορίες είναι ιδιαίτερα χρήσιμες για την καθοδήγηση αποφάσεων σχετικά με αναβαθμίσεις υλικού και σχεδιασμό χωρητικότητας.

### 4.6.7. Ανοχή Σφαλμάτων και Μηχανισμοί Αποκατάστασης

Η σταθερότητα των μακροχρόνιων εκπαιδεύσεων αποτελεί κρίσιμο παράγοντα για την πρακτική χρησιμότητα του συστήματος. Το πλαίσιο εκπαίδευσης πολλαπλών μονάδων γραφικών ενσωματώνει προηγμένους μηχανισμούς ανοχής σφαλμάτων που προστατεύουν από διάφορους τύπους αποτυχιών, από αστοχίες υλικού έως διακοπές δικτύου σε κατανεμημένες διαμορφώσεις.

Το σύστημα υλοποιεί αυτόματη δημιουργία σημείων ελέγχου με προσαρμόσιμα διαστήματα, αποθηκεύοντας όχι μόνο τα βάρη του μοντέλου αλλά και την πλήρη κατάσταση του βελτιστοποιητή, του προγραμματιστή ρυθμού εκμάθησης, και των γεννητριών τυχαίων αριθμών. Αυτό επιτρέπει την ακριβή αποκατάσταση της εκπαίδευσης από το ακριβές σημείο διακοπής χωρίς απώλεια προόδου.

Επιπρόσθετα, το σύστημα υποστηρίζει δυναμική επαναδιανομή μονάδων γραφικών που επιτρέπει τη συνέχιση μιας εκπαίδευσης ακόμα και όταν μια ή περισσότερες μονάδες γίνουν μη διαθέσιμες. Σε τέτοιες περιπτώσεις, το σύστημα αυτόματα προσαρμόζει το μέγεθος των ομάδων δεδομένων και τα μοτίβα επικοινωνίας για να συνεχίσει την εκπαίδευση με τους εναπομένοντες πόρους.

### 4.6.8. Συγκριτική Ανάλυση Απόδοσης Πολλαπλών έναντι Μονής Μονάδας Γραφικών

Εμπειρικές μετρήσεις από πραγματικές ιστοπαθολογικές εκπαιδεύσεις αποκαλύπτουν σημαντικά οφέλη από την υιοθέτηση αρχιτεκτονικών πολλαπλών μονάδων γραφικών. Για τυπικές εκπαιδεύσεις με Mask R-CNN σε ιστοπαθολογικά σύνολα δεδομένων μεσαίου μεγέθους, η μετάβαση από μία μονάδα γραφικών σε διαμόρφωση δύο μονάδων επιτυγχάνει επιτάχυνση κοντά στο 1.8x, ενώ διαμορφώσεις τεσσάρων μονάδων μπορεί να φτάσουν την επιτάχυνση 3.2x. Αυτά τα νούμερα αντικατοπτρίζουν όχι μόνο τη θεωρητική παραλληλοποίηση αλλά και τις πρακτικές επιβαρύνσεις που προκύπτουν από την επικοινωνία μεταξύ μονάδων γραφικών, τις μεταφορές μνήμης, και τα σημεία συγχρονισμού. Το σύστημα έχει βελτιστοποιηθεί ώστε να ελαχιστοποιεί αυτές τις επιβαρύνσεις, επιτυγχάνοντας αποδοτικότητα κλιμάκωσης που υπερβαίνει το 80% για τις περισσότερες ρεαλιστικές διαμορφώσεις. Ιδιαίτερα εντυπωσιακά είναι τα αποτελέσματα σε εφαρμογές υψηλής ανάλυσης όπου οι εικόνες ξεπερνούν τα 10,000x10,000

εικονοστοιχεία. Σε αυτές τις περιπτώσεις, η προσέγγιση πολλαπλών μονάδων γραφικών δεν παρέχει μόνο επιτάχυνση αλλά καθιστά δυνατή την εκπαίδευση μοντέλων που θα ήταν αδύνατη σε διαμορφώσεις μίας μονάδας λόγω περιορισμών μνήμης.

### 4.6.9. Οικονομικά και Περιβαλλοντικά Οφέλη

Η αποδοτική αξιοποίηση των πόρων πολλαπλών μονάδων γραφικών έχει άμεσες οικονομικές επιπτώσεις για τα ερευνητικά κέντρα και τα νοσοκομεία που υιοθετούν το σύστημα. Η δραματική μείωση του χρόνου εκπαίδευσης μεταφράζεται σε μειωμένο κόστος λειτουργίας, μικρότερη κατανάλωση ενέργειας, και ταχύτερη ανάπτυξη και ανάπτυξη νέων μοντέλων στην κλινική πρακτική.

Επιπλέον, η αποδοτικότερη χρήση των υπολογιστικών πόρων επιτρέπει σε περισσότερες ερευνητικές ομάδες να αξιοποιήσουν προηγμένες τεχνικές βαθιάς μάθησης, δημοκρατίζοντας την πρόσβαση σε τεχνολογίες αιχμής που προηγουμένως ήταν διαθέσιμες μόνο σε μεγάλα ερευνητικά κέντρα με εκτεταμένους πόρους.

Από περιβαλλοντικής άποψης, η βελτιωμένη ενεργειακή απόδοση των εκπαιδεύσεων πολλαπλών μονάδων γραφικών συμβάλλει στη μείωση του περιβαλλοντικού αποτυπώματος των εφαρμογών τεχνητής νοημοσύνης στην υγειονομική περίθαλψη, μια ολοένα και πιο σημαντική παράμετρος καθώς η χρήση τεχνητής νοημοσύνης επεκτείνεται σε όλο και περισσότερες κλινικές εφαρμογές.

### 4.6.10. Μελλοντικές Κατευθύνσεις και Τεχνολογικές Εξελίξεις

Η αρχιτεκτονική του συστήματος έχει σχεδιαστεί με μελλοντική επεκτασιμότητα, προετοιμάζοντας το έδαφος για την ενσωμάτωση αναδυόμενων τεχνολογιών όπως οι εξειδικευμένοι επιταχυντές τεχνητής νοημοσύνης, τεχνικές παραλληλισμού μοντέλων για εξαιρετικά μεγάλα μοντέλα, και προηγμένες τεχνικές όπως η ομοσπονδιακή μάθηση για συνεργασίες πολλαπλών ιδρυμάτων.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η δυνητική ενσωμάτωση αρχιτεκτονικών εγγενών του νέφους που θα επιτρέψουν την απρόσκοπτη κλιμάκωση από συστοιχίες μονάδων γραφικών στις εγκαταστάσεις σε υποδομή βασισμένη στο νέφος, παρέχοντας στους χρήστες την ευελιξία να επιλέγουν το βέλτιστο μοντέλο ανάπτυξης βάσει των δικών τους απαιτήσεων και περιορισμών.

Επιπλέον, η συνεχής βελτίωση των βιβλιοθηκών CUDA και των πλαισίων βαθιάς μάθησης υπόσχεται περαιτέρω βελτιώσεις στην απόδοση και την ενεργειακή απόδοση, ενώ η ανάπτυξη νέων αρχιτεκτονικών μονάδων γραφικών με αυξημένη χωρητικότητα μνήμης και εύρος ζώνης θα επιτρέψει την εκπαίδευση ακόμα πιο σύνθετων μοντέλων για ιστοπαθολογικές εφαρμογές.

# *Κεφάλαιο 5*

## *ΥΛΟΠΟΙΗΣΗ ΚΑΙ ΕΝΣΩΜΑΤΩΣΗ ΤΟΥ DEEP-IN-BIOPSIES*

## 5.1. Υλοποίηση Κεντρικής Μονάδας (Backend Module)

Η διαδικασία της υλοποίησης ακολουθεί μια μεθοδική προσέγγιση που εξασφαλίζει την ομαλή ενσωμάτωση όλων των συστατικών, από το Backend σύστημα διαχείρισης δεδομένων μέχρι την εξειδικευμένη μονάδα επεξεργασίας τεχνητής νοημοσύνης. Η δομή που ακολουθείται εστιάζει αρχικά στην υλοποίηση κάθε μεμονωμένου συστατικού και στη συνέχεια στην ενσωμάτωση και τον συντονισμό όλων των μονάδων σε ένα ενιαίο οικοσύστημα.

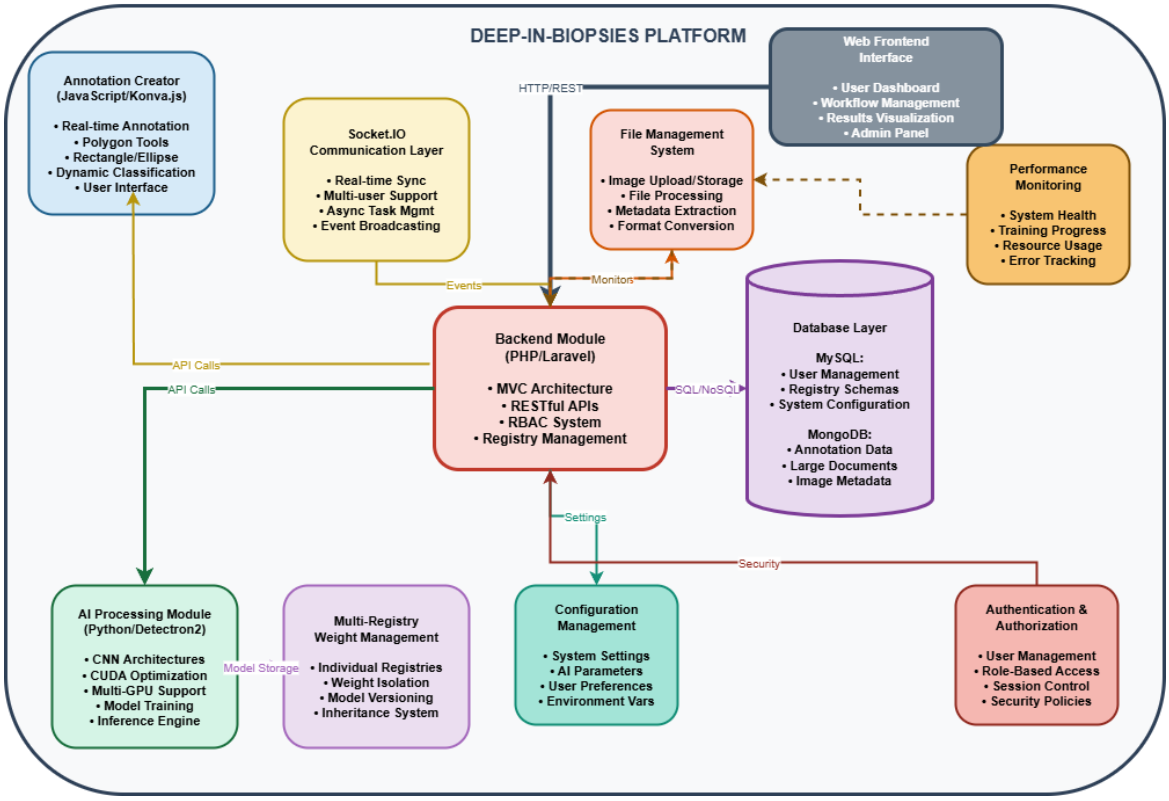


*Διάγραμμα 6. Διάγραμμά/σχήμα αρχιτεκτονικής του Deep-in-Biopsies και επικοινωνία, με απεικόνιση των συνδέσεων με όλα τα υποσυστήματα.*

Το κεφάλαιο αυτό παρουσιάζει την πρακτική υλοποίηση της Κεντρικής Μονάδας της πλατφόρμας Deep-in-Biopsies, η οποία αποτελεί τον θεμελιώδη πυρήνα του συστήματος και υλοποιεί τις κρίσιμες λειτουργίες διαχείρισης δεδομένων. Η στρατηγική υλοποίησης επικεντρώθηκε στην ανάπτυξη ενός ισχυρού συστήματος που μπορεί να διαχειριστεί αποδοτικά μεγάλους όγκους ιστοπαθολογικών δεδομένων, να παρέχει δυναμικές διεπαφές χρήστη και να υποστηρίξει την ασύγχρονη επικοινωνία με τη Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης. Η εφαρμογή των αρχών domain-driven design εξασφάλισε ότι η δομή του λογισμικού αντανακλά στενά τη λογική του ιατρικού τομέα και τις ειδικές ανάγκες της ψηφιακής παθολογίας.

### 5.1.1. Ανάπτυξη Βασικής Εφαρμογής με PHP/Laravel

Η υλοποίηση της Κεντρικής Μονάδας βασίστηκε στο πλαίσιο Laravel 10.x σε συνδυασμό με PHP 8.0.2+, επιλογές που αποδείχθηκαν ιδιαίτερα κατάλληλες για τις απαιτήσεις της ψηφιακής παθολογίας[118]. Η χρήση του Laravel παρείχε ισχυρές δυνατότητες για τη διαχείριση βάσεων δεδομένων μέσω του Eloquent ORM, προηγμένες τεχνικές ασφάλειας που συμμορφώνονται με τους κανονισμούς προστασίας ιατρικών δεδομένων, και αρχιτεκτονική που υποστηρίζει την ανάπτυξη RESTful APIs για την επικοινωνία με τα άλλα υποσυστήματα της πλατφόρμας. Η εφαρμογή του προτύπου MVC επέτρεψε σαφή διαχωρισμό ευθυνών μεταξύ των διαφορετικών στρωμάτων της εφαρμογής. Το στρώμα Model αναπτύχθηκε για να διαχειρίζεται τη διαχείριση δεδομένων και την επιχειρησιακή λογική, ενσωματώνοντας σύνθετα μοντέλα για την αναπαράσταση ιατρικών καταχωρήσεων, εικόνων βιοψιών, σημειώσεων και εκπαιδευμένων μοντέλων τεχνητής νοημοσύνης.

Μια από τις πιο καινοτόμες πτυχές της υλοποίησης ήταν η ενσωμάτωση του Livewire 3.0 [119], ενός full-stack reactive framework που επιτρέπει τη δημιουργία δυναμικών διεπαφών χωρίς την ανάγκη εκτεταμένου JavaScript κώδικα . Αυτή η τεχνολογική επιλογή επέτρεψε την υλοποίηση προηγμένων διαδραστικών συστατικών που αντιμετωπίζουν τις πολύπλοκες απαιτήσεις της ψηφιακής παθολογίας. Το σύστημα διαχείρισης χρηστών υλοποιήθηκε μέσω του συστατικού `AddUserModal.php`, το οποίο παρέχει δυναμικές δυνατότητες δημιουργίας και επεξεργασίας χρηστών με υποστήριξη μεταφόρτωσης αρχείων σε πραγματικό χρόνο. Το συστατικό διαθέτει προηγμένες δυνατότητες επικύρωσης δεδομένων και παρέχει άμεση ανατροφοδότηση στον χρήστη για τυχόν σφάλματα ή επιτυχείς ενέργειες. Η διαχείριση ρόλων και δικαιωμάτων υλοποιήθηκε μέσω του συστατικού `RoleModal.php`, το οποίο ενσωματώνει ένα προηγμένο σύστημα Role-Based Access Control (RBAC) με δυνατότητες δυναμικής ανάθεσης δικαιωμάτων. Το συστατικό επιτρέπει στους διαχειριστές να ορίζουν λεπτομερή δικαιώματα πρόσβασης και να τα συνδέουν με συγκεκριμένους ρόλους, παρέχοντας ευελιξία στη διαχείριση των διαφορετικών τύπων χρηστών της πλατφόρμας[120].

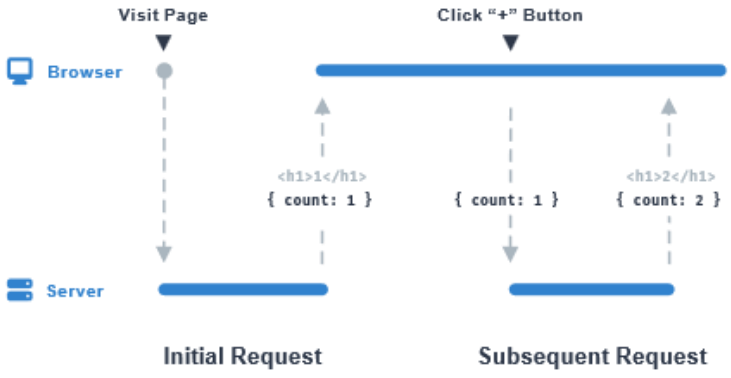


Διάγραμμα 7. Χρονική ροή ζωής των Livewire components (https://laravel-livewire.com/docs/2.x/security)

Το συστατικό `QueueTrainingContainer.php` (Πηγαίος Κώδικας 3) αποτελεί έναν από τους πιο κρίσιμους κόμβους του συστήματος, καθώς διαχειρίζεται την ουρά εκπαίδευσης των μοντέλων μηχανικής μάθησης με προηγμένες δυνατότητες ελέγχου κατάστασης και δυναμικής αναδιάταξης εργασιών. Η υλοποίηση περιλαμβάνει τις εξής βασικές λειτουργίες:

- `changeOrderTraining()`
  Αυτή η λειτουργία επιτρέπει στους χρήστες να αλλάζουν τη σειρά εκτέλεσης των εργασιών εκπαίδευσης μέσω ενός εύκολα χρησιμοποιούμενου drag-and-drop περιβάλλοντος. Η υλοποίηση ενημερώνει τη στήλη sort_order στη βάση δεδομένων και παρέχει άμεση οπτική ανατροφοδότηση στον χρήστη για την επιτυχή ολοκλήρωση της ενέργειας.
- `changeStatus()`
  Η λειτουργία αυτή διαχειρίζεται τις αλλαγές κατάστασης των εργασιών εκπαίδευσης, εκτελώντας αυτόματα το `TrainingChangeAllEvent` που ενημερώνει όλα τα συναφή συστατικά του συστήματος για την αλλαγή. Αυτό εξασφαλίζει τη συνοχή των δεδομένων σε ολόκληρη την πλατφόρμα και παρέχει ασφαλή παρακολούθηση της προόδου εκπαίδευσης.
- `render()`
  Η μέθοδος `render()` εκτελεί το query `availableQueuesQuery()` για την ανάκτηση των διαθέσιμων εργασιών εκπαίδευσης και τη συμπερίληψή τους στην προβολή του χρήστη με τη σωστή ταξινόμηση.

Η υλοποίηση της διαχείρισης καταχωρήσεων (registries) πραγματοποιήθηκε μέσω ενός σύνθετου συστήματος Livewire components που παρέχουν πλήρη λειτουργικότητα διαχείρισης των ιατρικών πεδίων. Το συστατικό `ListRegistry.php` υλοποιεί λειτουργίες διαχείρισης καταχωρήσεων σε πραγματικό χρόνο με δυνατότητες session management και ασύγχρονες ενημερώσεις.

Το συστατικό `CreateRegistry.php` παρέχει ολοκληρωμένη διεπαφή για τη δημιουργία νέων ιατρικών καταχωρήσεων, ενσωματώνοντας προηγμένες τεχνικές επικύρωσης δεδομένων και διαχείριση μεταδεδομένων. Η υλοποίηση υποστηρίζει την ιεραρχική οργάνωση των καταχωρήσεων, επιτρέποντας τη δημιουργία εξειδικευμένων πεδίων για διαφορετικά όργανα και παθολογικές καταστάσεις.

```
class QueueTrainingContainer extends Component
{
    public Collection|null $queue;
    public function changeStatus($training_id, $status_id)
    {
        $training = Training::find($training_id);
        if ($training){
            $training->current_status_id = $status_id;
            $training->save();
            TrainingChangeAllEvent::dispatch($training);
        }
    }
    #[On('changeOrderTraining')]
    public function changeOrderTraining(array $items)
    {
        foreach ($items as $model) {
            TrainingQueue::where(["training_id" => $model["model"]])-
>update(["sort_order" => $model["sort_order"]]);
        }
        $this->dispatch("success", "Training Order updated
successfully!");
    }
    public function render()
    {
        $this->queue = TrainingQueue::availableQueuesQuery()->get();
        return view('livewire.auth.queue-training.queue-training-
container',);
    }
}
```

*Πηγαίος Κώδικας 3. Κλάση `QueueTrainingContainer` για την διαχείριση ουρών σχετικά με την σειρά των μοντέλων εκπαίδευσης.*

### 5.1.2. Υλοποίηση Υβριδικής Βάσης Δεδομένων

Η υλοποίηση της σχεσιακής βάσης δεδομένων οργανώθηκε γύρω από πέντε κύριες οντότητες που αντιπροσωπεύουν τη θεμελιώδη δομή της πλατφόρμας. Ο πίνακας `registries` αποτελεί την υψηλότερη οντότητα στην ιεραρχία και αναπαριστά τα διαφορετικά ιατρικά πεδία και ανθρώπινα όργανα που υποστηρίζει η πλατφόρμα. Η δομή περιλαμβάνει πεδία για το όνομα, την περιγραφή, τις υποστηριζόμενες κατηγορίες ταξινόμησης και τις ρυθμίσεις διαμόρφωσης για τα μοντέλα τεχνητής νοημοσύνης. Ο πίνακας `projects` υλοποιήθηκε για να αναπαριστά τα μεμονωμένα ερευνητικά ή κλινικά έργα που δημιουργούνται εντός κάθε καταχώρησης. Η σχέση με τις καταχωρήσεις υλοποιείται μέσω ξένου κλειδιού, ενώ κάθε έργο περιέχει εκτεταμένα μεταδεδομένα όπως τίτλος, περιγραφή, ημερομηνίες δημιουργίας και τελευταίας ενημέρωσης, καθώς και διαμορφώσεις για τις κατηγορίες ταξινόμησης. Ο πίνακας `users` ενσωματώνει ένα προηγμένο σύστημα διαχείρισης χρηστών που υποστηρίζει πολλαπλούς τύπους λογαριασμών με λεπτομερή προφίλ. Η δομή περιλαμβάνει πεδία για προσωπικές πληροφορίες, επαγγελματικά στοιχεία, ιατρικές ειδικότητες και προτιμήσεις διεπαφής, επιτρέποντας την προσαρμογή της εμπειρίας χρήστη βάσει του ρόλου και των αναγκών κάθε ατόμου.

Η στρατηγική ενσωμάτωση της MongoDB πραγματοποιήθηκε μέσω του πακέτου mongodb/laravel-mongodb, το οποίο επιτρέπει την αποδοτική διαχείριση μεταβλητών σχημάτων δεδομένων που χαρακτηρίζουν τις διαφορετικές τεχνικές σημειώσης και τα πολυεπίπεδα μεταδεδομένα εικόνων[121]. Η υλοποίηση περιλαμβάνει εξειδικευμένες συλλογές (collections) για την αποθήκευση σημειώσεων και αποτελεσμάτων επεξεργασίας τεχνητής νοημοσύνης. Η συλλογή `annotations` (Εικόνα 1) υλοποιεί ένα εξελιγμένο σχήμα για την αποθήκευση γεωμετρικών σημειώσεων με υποστήριξη πολλαπλών τύπων σχημάτων (πολύγωνα, ορθογώνια, κύκλοι) και εκτεταμένων μεταδεδομένων. Κάθε σημείωση περιέχει γεωμετρικές συντεταγμένες, κατηγορία ταξινόμησης, πληροφορίες δημιουργού και χρονοσήματα, ενώ υποστηρίζει και την αποθήκευση πρόσθετων ιατρικών παραμέτρων όπως βαθμοί διαφοροποίησης και στάδια εξέλιξης.


```
{
    "_id": {
        "$oid": "65a4e102c6a3a8d6ec0f08e2"
    },
    "manual": true,
    "deleted": false,
    "area": 0,
    "testing_id": null,
    "confidence": null,
    "points":
"[{\"x\":2924.9569369376077,\"y\":1622.0964760587751},{\"x\":2924.1002
474051998,\"y\":1622.0964760587751},{\"x\":2923.243557872792,\"y\":162
2.0964760587751}]",
    "created_at": {
        "$date": "2020-05-06T11:11:52.000Z"
    },
    "updated_at": {
        "$date": "2020-05-06T11:12:15.000Z"
    },
    "shape_type_id": 6,
    "creator_id": 1,
    "classification_id": 16,
    "image_id": 2705,
    "image_layer_id": 2667,
    "registry_id": 4
}
```


*Εικόνα 1. Παράδειγμα δομής annotation collection του MongoDB*

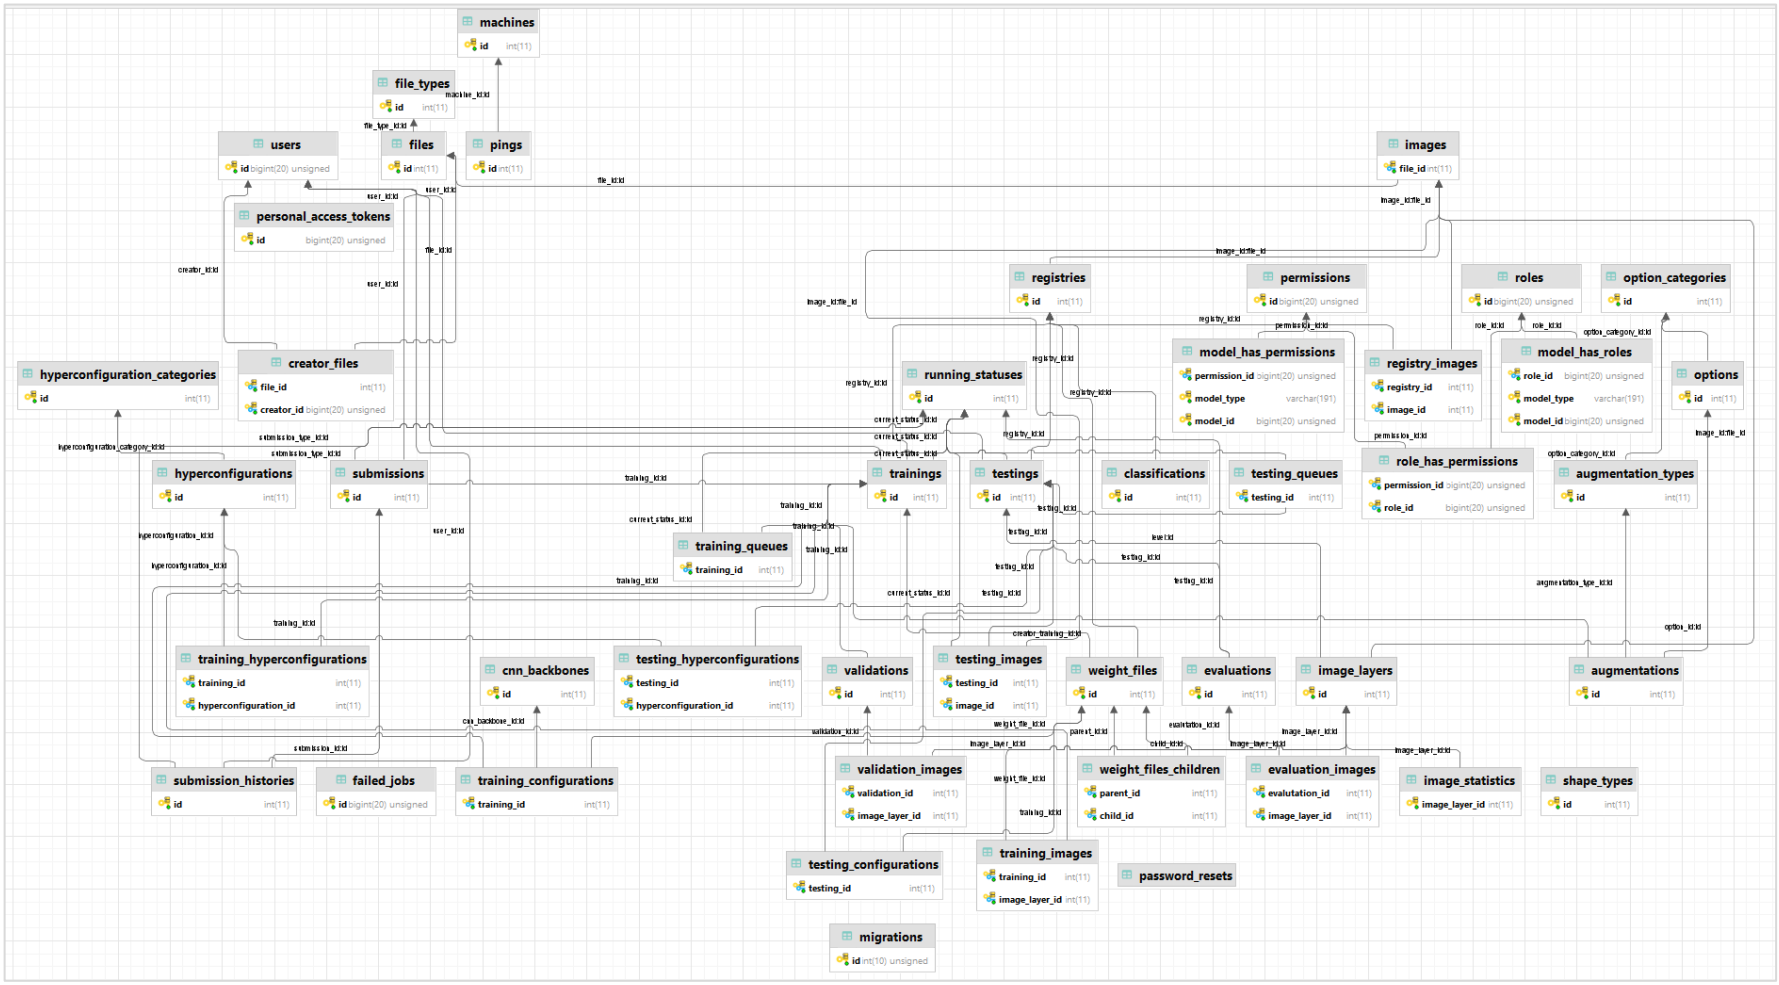


*Διάγραμμα 7. Entity Relationship διάγραμμα όλης της σχεσιακής βάσης δεδομένων*

### 5.1.3. Υλοποίηση RESTful API και Ελεγκτών

Η υλοποίηση του RESTful API ακολούθησε τις βέλτιστες πρακτικές σχεδιασμού για ιατρικές εφαρμογές, εστιάζοντας στην ασφάλεια, την αποδοτικότητα και την εύκολη συντήρηση. Οι ελεγκτές οργανώθηκαν σε λογικές ομάδες που αντιστοιχούν στις κύριες λειτουργικότητες του συστήματος: διαχείριση χρηστών και ρόλων, διαχείριση καταχωρήσεων και έργων, επεξεργασία εικόνων και σημειώσεων, και συντονισμό με τη Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης[122].

Η δομή δρομολόγησης υλοποιήθηκε με εστίαση στη ομαδοποίηση σχετικών λειτουργιών και την εφαρμογή κατάλληλων middleware για ελέγχους αυθεντικοποίησης και εξουσιοδότησης. Κάθε ομάδα routes προστατεύεται από εξειδικευμένα middleware που εξασφαλίζουν ότι μόνο εξουσιοδοτημένοι χρήστες έχουν πρόσβαση στις αντίστοιχες λειτουργίες.

Οι ελεγκτές διαχείρησης δεδομένων ήταν οι ακόλουθοι:

- Ο `RegistryController` υλοποιεί τη διαχείριση ιατρικών καταχωρήσεων με προηγμένες δυνατότητες CRUD που περιλαμβάνουν επικύρωση δεδομένων, διαχείριση σχέσεων και αυτόματη γενιά μεταδεδομένων. Η υλοποίηση υποστηρίζει ιεραρχική οργάνωση των καταχωρήσεων με δυνατότητες κληρονομικότητας ρυθμίσεων και διαμορφώσεων.
- Ο `ImageController` διαχειρίζεται την εισαγωγή, την επεξεργασία και την εμφάνιση εικόνων με ειδική έμφαση στην αποδοτικότητα για εικόνες υψηλής ανάλυσης. Η υλοποίηση περιλαμβάνει αυτόματη δημιουργία μικρογραφιών σε πολλαπλές αναλύσεις, εξαγωγή μεταδεδομένων εικόνας και διαχείριση στρωμάτων για εικόνες με πολλαπλά κανάλια ή επίπεδα.
- Ο `AnnotationController` υλοποιεί τη διαχείριση σημειώσεων με υποστήριξη για πολλαπλούς τύπους γεωμετρικών σχημάτων και εκτεταμένα μεταδεδομένα. Η υλοποίηση περιλαμβάνει αλγορίθμους για τον υπολογισμό εμβαδών πολυγώνων, ελέγχους τομής σχημάτων και αυτόματη δημιουργία στατιστικών στοιχείων για κάθε κατηγορία ταξινόμησης.

### 5.1.4. Υλοποίηση Προηγμένου Συστήματος Ουρών

Η υλοποίηση του συστήματος ουρών αποτελεί μία από τις πιο σύνθετες και κρίσιμες πτυχές της Κεντρικής Μονάδας, καθώς διαχειρίζεται την ασύγχρονη εκτέλεση εργασιών τεχνητής νοημοσύνης και εξασφαλίζει την αποδοτική κατανομή υπολογιστικών πόρων. Το σύστημα υποστηρίζει πολλαπλές ουρές που μπορούν να λειτουργούν παράλληλα, με δυνατότητες προτεραιότητας και δυναμικής αναδιάταξης εργασιών [123].

Το συστατικό `QueueTrainingContainer.php` υλοποιεί τη διαχείριση ουράς εκπαίδευσης μοντέλων με προηγμένες δυνατότητες παρακολούθησης προόδου και διαχείρισης κατάστασης. Η υλοποίηση περιλαμβάνει λειτουργίες όπως

`changeOrderTraining()` για δυναμική αναδιάταξη εργασιών και `changeStatus()` για ενημέρωση της κατάστασης εκτέλεσης σε πραγματικό χρόνο. Το συστατικό `QueueTestingContainer.php` διαχειρίζεται τις ουρές δοκιμής μοντέλων με παρόμοια αρχιτεκτονική, παρέχοντας ειδικές λειτουργίες για την παρακολούθηση της απόδοσης μοντέλων και την αυτόματη γενιά αναφορών αποτελεσμάτων. Η υλοποίηση υποστηρίζει drag-and-drop λειτουργικότητα για την αναδιάταξη εργασιών μέσω integration με τη βιβλιοθήκη Sortable.js.

Η διαχείριση ροών εργασίας υλοποιείται μέσω ενός προηγμένου συστήματος events που επιτρέπει την ασύγχρονη επικοινωνία μεταξύ των διαφορετικών συστατικών του συστήματος. Τα events `TrainingChangeAllEvent` και `TestingStatusEvent` διαχειρίζονται την ενημέρωση κατάστασης εργασιών και την αυτόματη ειδοποίηση χρηστών για αλλαγές στην πρόοδο των εκπαιδεύσεων. Το σύστημα υποστηρίζει πολλαπλούς drivers για τις ουρές, συμπεριλαμβανομένων Database, Redis, SQS και Beanstalkd, παρέχοντας ευελιξία στην επιλογή της κατάλληλης τεχνολογίας βάσει των απαιτήσεων απόδοσης και διαθεσιμότητας. Η υλοποίηση περιλαμβάνει συστήματα ανάκτησης από αποτυχίες και αυτόματη επανεκκίνηση εργασιών, εξασφαλίζοντας υψηλή διαθεσιμότητα και αξιοπιστία.

### 5.1.5. Διεπαφές Χρήστη και Εμπειρία Χρήσης

Η υλοποίηση της διεπαφής χρήστη επικεντρώθηκε στη δημιουργία μιας σύγχρονης, διαδραστικής εμπειρίας που ταυτόχρονα ικανοποιεί τις εξειδικευμένες απαιτήσεις των ιατρικών επαγγελματιών. Η τεχνολογική στοίβα συμφωνα με το προγραμματιστικό περιβάλλον IntelliJ Idea [124] περιλαμβάνει JavaScript (73.8%), CSS (14.5%), HTML (4.4%) και SCSS (1.4%), δημιουργώντας ένα responsive και user-friendly περιβάλλον.

Το σύστημα εμφάνισης εικόνων υλοποιήθηκε μέσω του συστατικού ShowImages.php, το οποίο παρέχει προηγμένες δυνατότητες πλοήγησης και εμφάνισης εικόνων με δυναμική σελιδοποίηση και ταξινόμηση. Η υλοποίηση υποστηρίζει ζουμ και pan για εικόνες υψηλής ανάλυσης, overlay εμφάνιση σημειώσεων, και πραγματικού χρόνου προεπισκόπηση αποτελεσμάτων ταξινόμησης.

Η υλοποίηση του κεντρικού `dashboard` ( Εικόνα 3) περιλαμβάνει πολλαπλά γραφήματα που παρουσιάζουν την πρόοδο των έργων και τις σημειώσεις που δημιουργούνται από χρήστες ή από αυτόματα συστήματα. Η διεπαφή σχεδιάστηκε με έμφαση στη λειτουργικότητα και την εργονομία, παρέχοντας στους ιατρούς πρόσβαση σε όλες τις απαραίτητες πληροφορίες με τρόπο ιεραρχημένο και εύκολα κατανοητό.

Τα συστατικά οπτικοποίησης ενσωματώνουν διαδραστικά γραφήματα που επιτρέπουν την εις βάθος ανάλυση των δεδομένων, συμπεριλαμβανομένων διαγραμμάτων κατανομής κατηγοριών, χρονοσειρών εξέλιξης έργων και συγκριτικών αναλύσεων απόδοσης μοντέλων

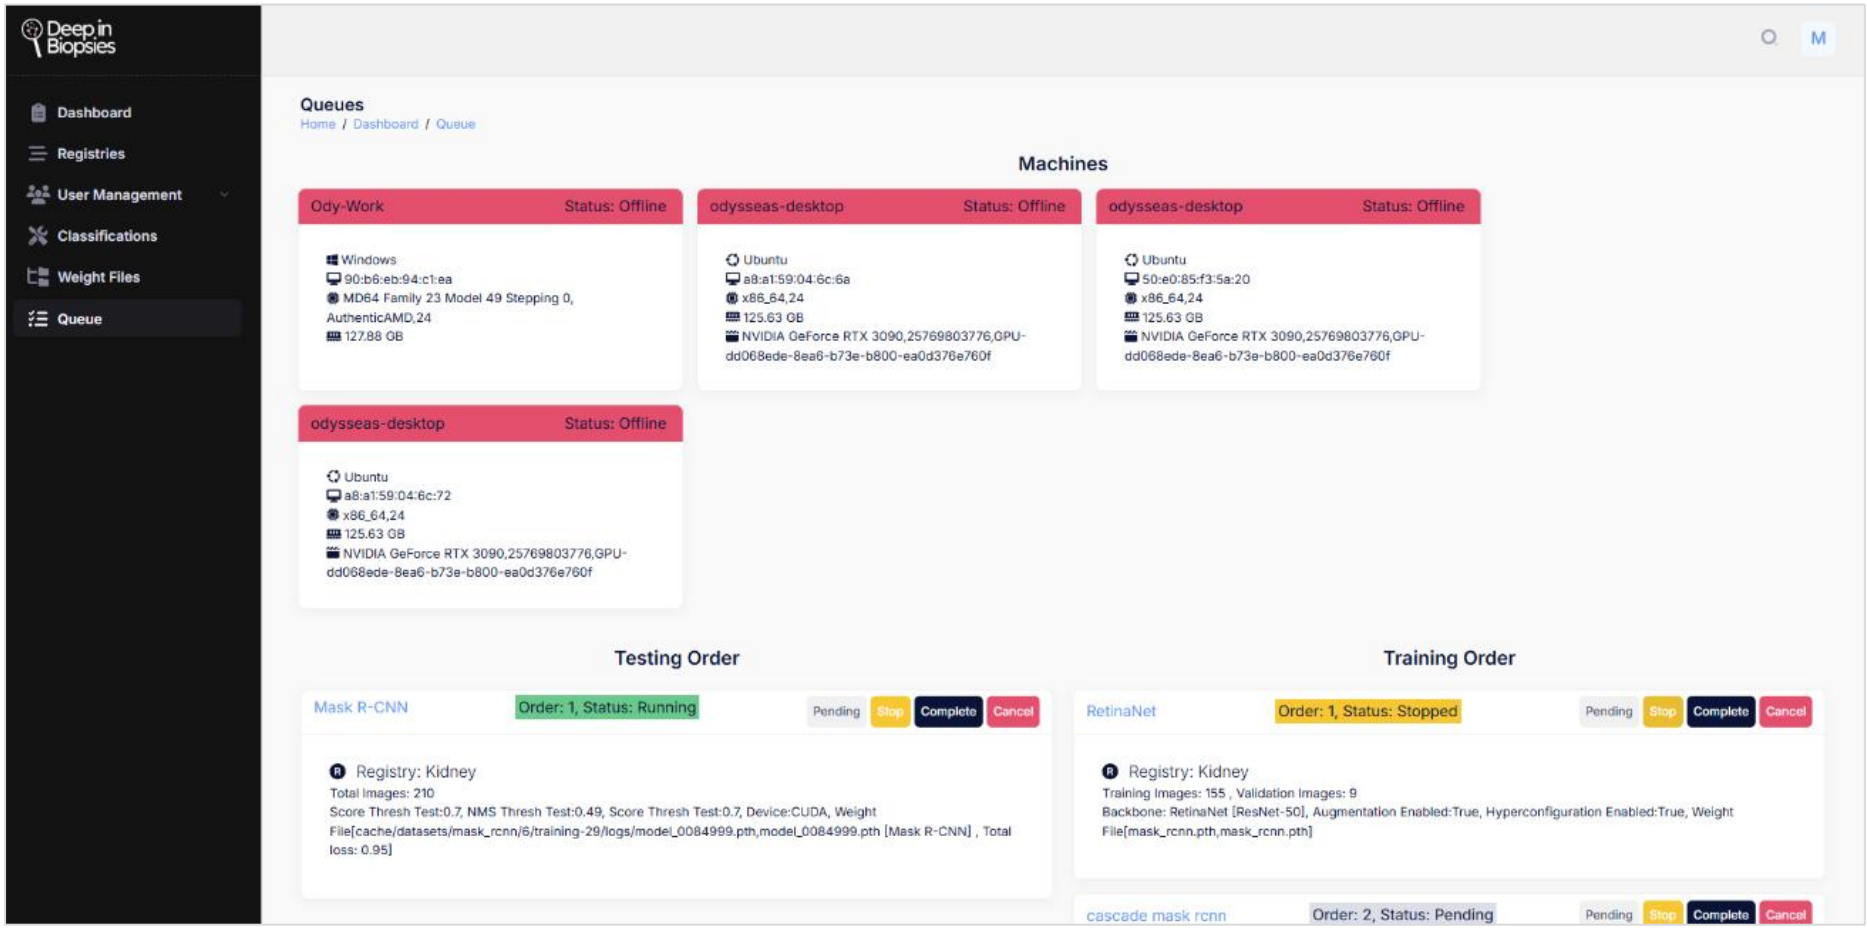


*Εικόνα 2. Διαδραστικα UI components για τις ουρές εκπαιδεύσεις και δοκιμών*

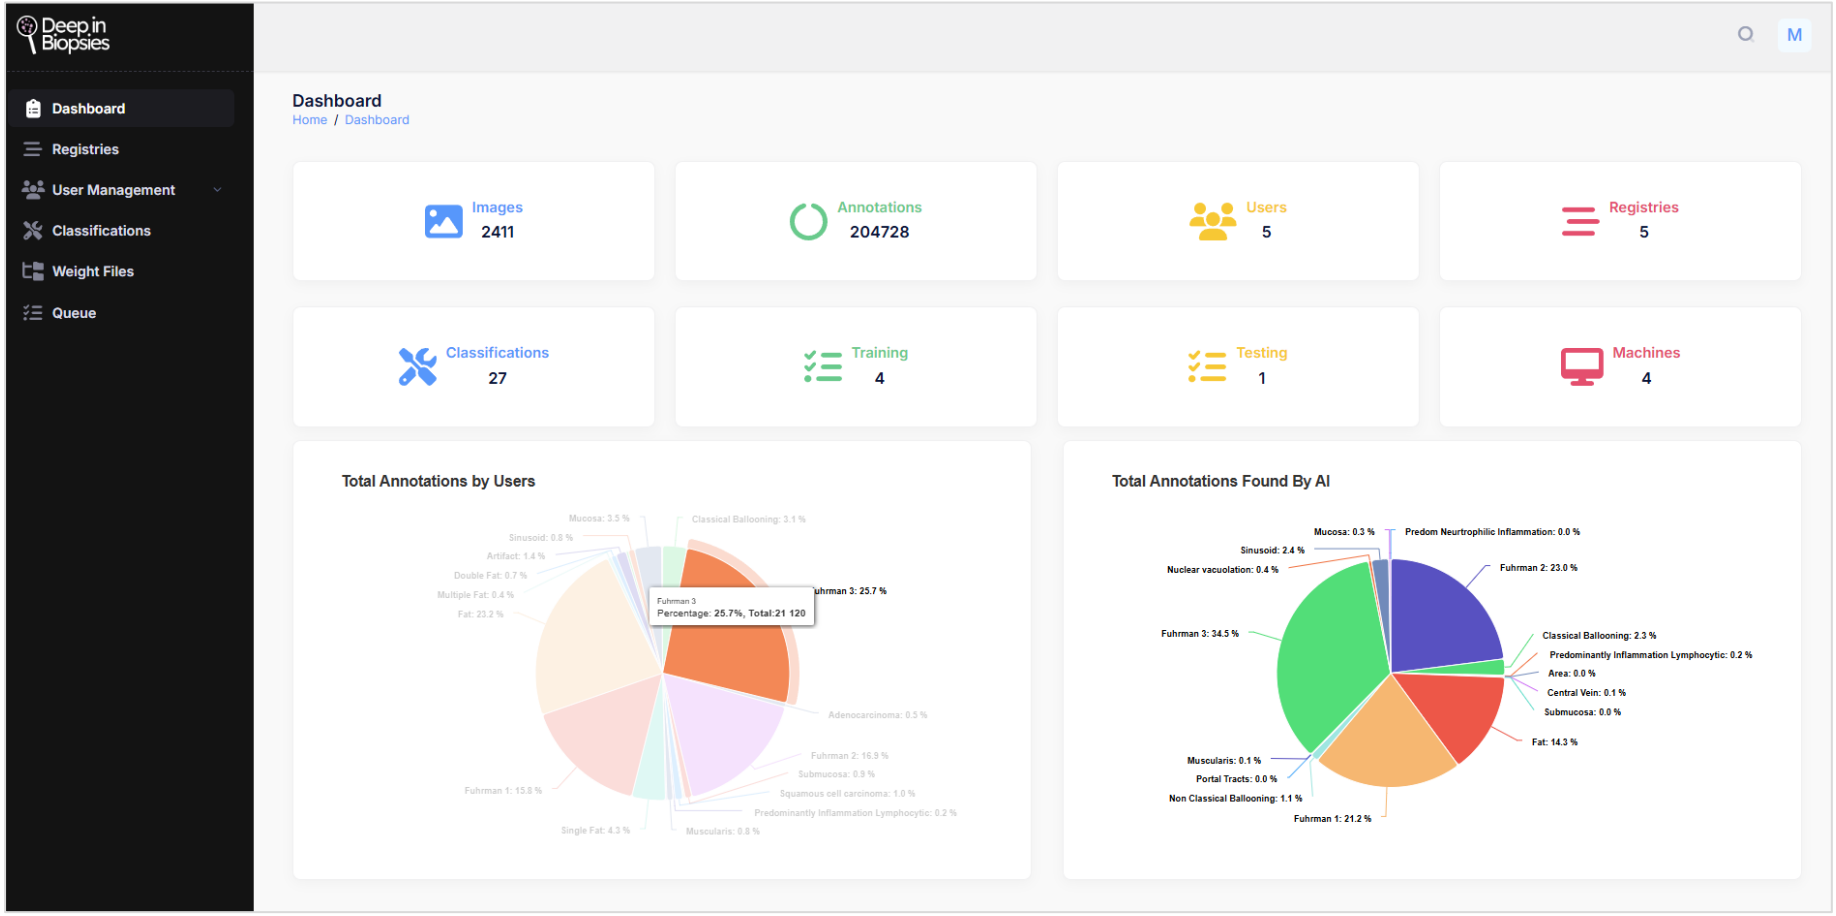


*Εικόνα 3. Dashboard του Deep-in-Biopsies backend*

### 5.1.6. Βοηθητικές Κλάσεις και Υπολογιστικές Λειτουργίες

Η υλοποίηση περιλαμβάνει ένα εκτεταμένο σύστημα βοηθητικών κλάσεων που απλοποιούν την αλληλεπίδραση με τη MongoDB βάση δεδομένων.

- Η κλάση `AnnotationsFromImageCollectionHelper.php` παρέχει εξειδικευμένες μεθόδους για την ανάκτηση σημειώσεων βάσει κριτηρίων εικόνας, στρώματος ή κατηγορίας. Οι μέθοδοι `getAllImages()`, `getAnnotationsByImageLayersID()` και `findAnnotations()` υλοποιούν αποδοτικούς αλγόριθμους αναζήτησης που αξιοποιούν τα ευρετήρια της MongoDB για ταχεία ανάκτηση δεδομένων.
- Η κλάση GenericAnnotationsHelper.php υλοποιεί προηγμένες λειτουργίες ομαδοποίησης και στατιστικής ανάλυσης σημειώσεων. Η μέθοδος getClassificationsGrouped() παρέχει ομαδοποιημένα δεδομένα ταξινομήσεων για την δημιουργία συγκεντρωτικών αναφορών, ενώ η groupByDate() υλοποιεί χρονική ομαδοποίηση για την ανάλυση εξέλιξης των έργων.
- Η κλάση `ImageSelectorHelper.php` αποτελεί βασικό συστατικό για τη διαχείριση και επιλογή εικόνων εκπαίδευσης και επικύρωσης. Η υλοποίηση περιλαμβάνει εξελιγμένους αλγορίθμους για την αυτόματη κατανομή εικόνων σε σύνολα εκπαίδευσης και επικύρωσης με βάση καθορισμένα ποσοστά και κριτήρια ποιότητα. Οι μέθοδοι `getTrainingImages()` και `getValidationImages()` εφαρμόζουν στρατηγικές διαστρωμάτωσης που εξασφαλίζουν αντιπροσωπευτική κατανομή κατηγοριών σε κάθε σύνολο.
- Η μέθοδος `getAnnotationsToImages()` υλοποιεί σύνθετη λογική σύνδεσης εικόνων με τις αντίστοιχες σημειώσεις, παρέχοντας αποδοτική πρόσβαση στα δεδομένα εκπαίδευσης. Η υλοποίηση βελτιστοποιείται για ταχεία ανάκτηση μεγάλων όγκων δεδομένων μέσω προσεκτικής χρήσης ευρετηρίων και batch processing τεχνικών.
- Η κλάση `RegistryImagesHelper.php` παρέχει εξειδικευμένες λειτουργίες για την εμφάνιση και διαχείριση εικόνων εντός του πλαισίου των καταχωρήσεων. Η μέθοδος `getImagesPagination()` υλοποιεί προηγμένη σελιδοποίηση με δυνατότητες ταξινόμησης και φιλτραρίσματος, ενώ η `getImagesCount()` παρέχει αποδοτικούς υπολογισμούς συνολικού αριθμού εικόνων για κάθε κατηγορία.

```
class AnnotationsFromImageCollectionHelper extends MongoDBHelperParent
{

      public function findAnnotations($ids)
      {
          $annotations = Annotation::raw(function ($collection) use
      ($ids) {
              return $collection->aggregate([
                  [
                      '$match' => [
                          'image_layer_id' => [
                              '$in' => $ids
                          ]
                      ]
                  ],
                  [
                      '$group' => [
                          '_id' => '$image_layer_id',
                          'count' => [
                              '$sum' => 1
                          ]
                      ]
                  ]
              ]);
          });

          if ($this->compact) {
              //form all ids images set the count into the image object
              foreach ($this->images as $image) {
                  foreach ($annotations as $annotation) {
                      if ($annotation->_id === $image->image_layer_id)
      {
                          $image->annotation_count = $annotation-
      >count;
                      }
                  }
              }
          }
          return $annotations;
      }
      …….

}
```

*Πηγαίος Κώδικας 4. `AnnotationsFromImageCollectionHelper` κλάση του backend για το Deep-in-Biopsies*

### 5.1.7. Συστήματα Ελέγχου Πρόσβασης και Ασφάλειας

Η υλοποίηση του συστήματος ελέγχου πρόσβασης βασίστηκε σε ένα προηγμένο μοντέλο RBAC που υποστηρίζει τους τέσσερις βασικούς ρόλους του συστήματος: Διαχειριστής, Παθολογοανατόμος, Ερευνητής και Ειδικός Ιατρός. Κάθε ρόλος έχει προκαθορισμένα δικαιώματα που μπορούν να τροποποιηθούν δυναμικά μέσω της διοικητικής διεπαφής.

- Η κλάση `RoleModal.php` υλοποιεί προηγμένες λειτουργίες διαχείρισης ρόλων με δυνατότητες μαζικής ανάθεσης δικαιωμάτων μέσω της μεθόδου `checkAll()`. Η υλοποίηση περιλαμβάνει λεπτομερή καταγραφή όλων των αλλαγών δικαιωμάτων για λόγους ελέγχου και συμμόρφωσης με τους κανονισμούς προστασίας ιατρικών δεδομένων.
- Η κλάση `PermissionModal.php` διαχειρίζεται τα μεμονωμένα δικαιώματα με υποστήριξη για ιεραρχικές δομές δικαιωμάτων και κληρονομικότητα. Η μέθοδος `mountPermission()` φορτώνει δυναμικά τα διαθέσιμα δικαιώματα βάσει του ρόλου του χρήστη, ενώ η `submit()` εφαρμόζει προηγμένους ελέγχους επικύρωσης πριν την αποθήκευση αλλαγών.

Η υλοποίηση της ασφάλειας περιλαμβάνει πολλαπλά επίπεδα προστασίας που εφαρμόζονται μέσω εξειδικευμένων middleware. Το auth middleware εξασφαλίζει ότι μόνο αυθεντικοποιημένοι χρήστες έχουν πρόσβαση στις προστατευμένες περιοχές, ενώ το role middleware επιβάλλει λεπτομερείς ελέγχους δικαιωμάτων βάσει των ρόλων χρηστών. Η επικοινωνία με εξωτερικά συστήματα προστατεύεται μέσω εξελιγμένων τεχνικών κρυπτογράφησης και ψηφιακών υπογραφών. Όλες οι μεταφορές δεδομένων εφαρμόζουν TLS 1.3 encryption, ενώ τα ευαίσθητα δεδομένα κρυπτογραφούνται επιπρόσθετα σε επίπεδο βάσης δεδομένων.

### 5.1.8. Ενσωμάτωση με Εξωτερικά Συστήματα

Η υλοποίηση της επικοινωνίας σε πραγματικό χρόνο πραγματοποιήθηκε μέσω ενός εξελιγμένου συστήματος Socket.io που διαχειρίζεται αποδοτικά τον φόρτο εργασίας πολλαπλών χρηστών και μονάδων [125]. Το σύστημα υποστηρίζει namespace-based επικοινωνία που επιτρέπει την απομόνωση δεδομένων μεταξύ διαφορετικών έργων και καταχωρήσεων. Η υλοποίηση περιλαμβάνει προηγμένες τεχνικές διαχείρισης συνδέσεων που αυτόματα αντιμετωπίζουν προβλήματα δικτύου και επανασυνδέσεις. Το σύστημα παρέχει πραγματικού χρόνου ειδοποιήσεις για αλλαγές κατάστασης εργασιών, ολοκλήρωση εκπαιδεύσεων και διαθεσιμότητα νέων αποτελεσμάτων.

Η υλοποίηση της επικοινωνίας με τη Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης πραγματοποιείται μέσω ενός ολοκληρωμένου API που υποστηρίζει ασύγχρονες εργασίες και streaming μεταφορά δεδομένων. Το API περιλαμβάνει endpoints για την εκκίνηση εκπαιδεύσεων, την παρακολούθηση προόδου, την ανάκτηση αποτελεσμάτων και τη διαχείριση εκπαιδευμένων μοντέλων. Η υλοποίηση υποστηρίζει batch επεξεργασία εικόνων με αποδοτική διαχείριση μνήμης για εικόνες gigapixel. Το σύστημα αυτόματα τμηματοποιεί μεγάλες εικόνες σε διαχειρίσιμα κομμάτια, εφαρμόζει την επεξεργασία και συνθέτει τα αποτελέσματα χωρίς απώλεια ποιότητας ή μεταδεδομένων θέσης.

### 5.1.9. Βελτιστοποιήσεις Απόδοσης και Κλιμάκωσης

Η υλοποίηση περιλαμβάνει προηγμένες στρατηγικές προσωρινής αποθήκευσης που βελτιστοποιούν την απόδοση του συστήματος για τις ειδικές απαιτήσεις της ψηφιακής παθολογίας. Το σύστημα εφαρμόζει πολυεπίπεδη στρατηγική cache που περιλαμβάνει application-level cache για μεταδεδομένα, Redis cache για session δεδομένα και specialized image cache για μικρογραφίες και προεπεξεργασμένες εικόνες. Η υλοποίηση του image cache αξιοποιεί τεχνικές progressive loading και lazy loading που επιτρέπουν την ταχεία εμφάνιση εικόνων ενώ παράλληλα φορτώνονται οι λεπτομέρειες υψηλής ανάλυσης. Το σύστημα υποστηρίζει αυτόματη διαχείριση cache lifecycle με policies που βασίζονται σε συχνότητα χρήσης και διαθέσιμο χώρο αποθήκευσης.

Η βελτιστοποίηση των queries βάσης δεδομένων πραγματοποιήθηκε μέσω προσεκτικού σχεδιασμού ευρετηρίων και χρήσης προηγμένων τεχνικών του Eloquent ORM [126]. Οι πολύπλοκες αναζητήσεις που περιλαμβάνουν πολλαπλούς πίνακες και συνθήκες βελτιστοποιήθηκαν μέσω eager loading και selective field retrieval. Η υλοποίηση περιλαμβάνει αυτόματη παρακολούθηση απόδοσης queries με logging αργών εργασιών και προτάσεις βελτιστοποίησης. Το σύστημα παρέχει detailed analytics για τη χρήση βάσης δεδομένων που επιτρέπουν την προληπτική αντιμετώπιση προβλημάτων απόδοσης.

Η υλοποίηση ενός ολοκληρωμένου συστήματος μετρήσεων επιτρέπει την λεπτομερή παρακολούθηση της απόδοσης και χρήσης της πλατφόρμας. Η κλάση HandleMetricsAnnotations.php διαχειρίζεται την ενορχήστρωση συλλογής μετρικών με μεθόδους όπως start_collecting() που αυτοματοποιεί τη διαδικασία ανάλυσης και αξιολόγησης. Η μέθοδος createFolders() οργανώνει αυτόματα τη δομή αποθήκευσης αποτελεσμάτων, ενώ η get_classifications_map() δημιουργεί αντιστοιχίσεις μεταξύ των κατηγοριών εκπαίδευσης και δοκιμής για ακριβή σύγκριση αποτελεσμάτων.

Η κλάση `ConfusionMatrix.php` υλοποιεί προηγμένες τεχνικές αξιολόγησης μοντέλων με εστίαση στις ειδικές απαιτήσεις της ιστοπαθολογικής ανάλυσης [127].Η υλοποίηση περιλαμβάνει μεθόδους για τον υπολογισμό precision, recall, F1-score και Intersection over Union (IoU) metrics που είναι κρίσιμες για την αξιολόγηση μοντέλων instance segmentation. Οι μέθοδοι `get_predictions_simple()` και `get_predictions()`παρέχουν διαφορετικά επίπεδα λεπτομέρειας στην εξαγωγή προβλέψεων, επιτρέποντας τόσο γρήγορες εκτιμήσεις όσο και λεπτομερείς αναλύσεις με οπτικοποιήσεις. Η μέθοδος `plot_confusion_matrix()` δημιουργεί επαγγελματικές οπτικοποιήσεις που είναι κατάλληλες για κλινικές αναφορές και ερευνητικές παρουσιάσεις.

### 5.1.10. Εργαλεία Command Line και Αυτοματοποίηση

Η υλοποίηση περιλαμβάνει εξειδικευμένες εντολές `Artisan` που αυτοματοποιούν πολύπλοκες διαδικασίες διαχείρισης δεδομένων. Η εντολή `NDPA Parser` επεξεργάζεται

βιομηχανικά πρότυπα παθολογικών σημειώσεων, μετατρέποντας τα σε συμβατό format για τη MongoDB βάση δεδομένων. Το σύστημα μετεγκατάστασης SQL σε NoSQL αποτελεί καινοτόμο χαρακτηριστικό που επιτρέπει την ομαλή μετάβαση από υπάρχοντα συστήματα. Η υλοποίηση περιλαμβάνει έξυπνους αλγόριθμους μετατροπής που διατηρούν την ακεραιότητα δεδομένων και τις σχέσεις μεταξύ οντοτήτων κατά τη διάρκεια της μετεγκατάστασης.

Η αυτοματοποίηση επιτυγχάνεται μέσω εξειδικευμένων thread-based συστημάτων που παρακολουθούν συνεχώς την κατάσταση του συστήματος και εκτελούν αυτόματες ενέργειες. Η κλάση `RunApplicationThreadTraining.php` υλοποιεί περιοδικούς ελέγχους για νέες εκπαιδεύσεις και αυτόματη εκκίνηση της διαδικασίας εκπαίδευσης μέσω σύνδεσης με το `ApplicationMaster`. Η κλάση `RunApplicationThreadTesting.php` διαχειρίζεται την αυτόματη εκτέλεση δοκιμών μοντέλων σε batch mode, συμπεριλαμβάνοντας αυτόματη δημιουργία οπτικοποιήσεων και upload των αποτελεσμάτων στη βάση δεδομένων. Η υλοποίηση εξασφαλίζει continuous monitoring και αυτόματη ανάκαμψη σε περίπτωση σφαλμάτων.

## 5.2. Υλοποίηση Μονάδας Δημιουργίας Σημειώσεων

Η Μονάδα Δημιουργίας Σημειώσεων (Annotation Builder) αποτελεί το διαδραστικό frontend της πλατφόρμας Deep-in-Biopsies και υλοποιεί ένα εξελιγμένο περιβάλλον για την ακριβή σημειοθέτηση ιστοπαθολογικών εικόνων. Η υλοποίηση βασίστηκε σε εξειδικευμένη αρχιτεκτονική μονοσέλιδης εφαρμογής (Single Page Application - SPA ) με έμφαση στη δημιουργία μιας διαισθητικής και αποδοτικής εμπειρίας χρήστη που ανταποκρίνεται στις εξειδικευμένες ανάγκες των παθολογοανατόμων και ερευνητών[128]. Η στρατηγική υλοποίησης επικεντρώθηκε στην ανάπτυξη μιας browser-based εφαρμογής που παρέχει πλήρη λειτουργικότητα χωρίς την ανάγκη εγκατάστασης επιπρόσθετου λογισμικού. Η τεχνολογική στοίβα συμφωνα με το Intellij Idea [124] που αναπτύχθηκε περιλαμβάνει κύρια JavaScript (86.8%), CSS (9.3%) και HTML (3.9%), αντικατοπτρίζοντας τη στρατηγική εστίαση στην ανάπτυξη μιας cross-platform εφαρμογής που εξασφαλίζει μέγιστη προσβασιμότητα σε κλινικά περιβάλλοντα. Η αρχιτεκτονική βασίζεται σε Object-Oriented Programming με ES6 Classes, Service-oriented architecture και Model-View pattern για βέλτιστη οργάνωση και συντηρησιμότητα του κώδικα.

### 5.2.1. Ανάπτυξη JavaScript/Konva.js Εφαρμογής

#### 5.2.1.1. Αρχιτεκτονική Single Page Application

Η ανάπτυξη της εφαρμογής βασίστηκε στη φιλοσοφία της Single Page Application (SPA) μια προσέγγιση που μεταμορφώνει ριζικά τον τρόπο με τον οποίο οι χρήστες αλληλεπιδρούν με διαδικτυακές εφαρμογές ιατρικής απεικόνισης (**Error! Reference source not found.**). Η αρχιτεκτονική που υλοποιήθηκε επικεντρώνεται στη δημιουργία

μιας ρευστής και απρόσκοπτης εμπειρίας χρήστη, όπου οι μεταβάσεις μεταξύ διαφορετικών λειτουργιών πραγματοποιούνται χωρίς την καθυστέρηση και τη διακοπή της επαναφόρτωσης σελίδων. Αυτή η προσέγγιση αποδείχθηκε ιδιαίτερα κρίσιμη για την εξασφάλιση της αδιάλειπτης ροής εργασίας που απαιτείται κατά τη διαδικασία σημείωσης ιστοπαθολογικών εικόνων.

Η κεντρική αρχιτεκτονική της εφαρμογής δομείται γύρω από τέσσερα θεμελιώδη συστατικά που λειτουργούν συνεργατικά για την επίτευξη της επιθυμητής λειτουργικότητας. Το πρώτο και πιο κρίσιμο συστατικό είναι η κλάση `TabHandlerUI`, η οποία αναλαμβάνει τον κεντρικό ρόλο του διαχειριστή καρτελών. Η κλάση αυτή δεν περιορίζεται απλώς στη διαχείριση της πλοήγησης, αλλά ενορχηστρώνει το σύνολο των συστατικών διεπαφής χρήστη, διασφαλίζοντας τη συνοχή και τον συγχρονισμό μεταξύ των διαφορετικών οθονών και λειτουργιών. Η υλοποίηση ενσωματώνει προηγμένες τεχνικές διατήρησης κατάστασης (state preservation), επιτρέποντας στους χρήστες να μεταβαίνουν μεταξύ διαφορετικών εργασιών χωρίς απώλεια της προόδου τους. Παράλληλα, το σύστημα δυναμικής φόρτωσης περιεχομένου (dynamic content loading) που ενσωματώνεται στην κλάση εξασφαλίζει ότι μόνο τα απαραίτητα στοιχεία φορτώνονται κάθε φορά, βελτιστοποιώντας έτσι την απόδοση και μειώνοντας τη χρήση πόρων.

Το δεύτερο κρίσιμο συστατικό, η κλάση `ContextEvent`, αποτελεί την καρδιά της διαχείρισης κατάστασης της εφαρμογής. Λειτουργώντας ως κεντρικός κόμβος επικοινωνίας, η κλάση αυτή εξασφαλίζει ότι όλα τα συστατικά της εφαρμογής παραμένουν συγχρονισμένα και ενημερωμένα για τις αλλαγές στην κατάσταση του συστήματος. Η υλοποίηση βασίζεται σε ένα εξελιγμένο σύστημα διαχείρισης γεγονότων (event management system) που επιτρέπει την αποσύνδεση (decoupling) των διαφορετικών τμημάτων της εφαρμογής, διευκολύνοντας έτσι τη συντήρηση και την επέκταση του κώδικα. Μέσω αυτού του μηχανισμού, οι αλλαγές σε ένα τμήμα της εφαρμογής μπορούν να διαδοθούν αυτόματα σε όλα τα σχετικά συστατικά χωρίς την ανάγκη άμεσης διασύνδεσης μεταξύ τους.

Η κλάση Master (Πηγαίος Κώδικας 5) συνιστά το τρίτο πυλώνα της αρχιτεκτονικής, λειτουργώντας ως το κεντρικό σημείο ελέγχου που συντονίζει όλες τις επιμέρους λειτουργίες. Η σχεδίαση της ακολουθεί τις αρχές του προτύπου έγχυσης εξαρτήσεων (dependency injection pattern), μια προσέγγιση που ενισχύει σημαντικά τη δοκιμασιμότητα και την ευελιξία του κώδικα. Μέσω αυτής της αρχιτεκτονικής, κάθε συστατικό λαμβάνει τις εξαρτήσεις του κατά τη στιγμή της δημιουργίας του, αντί να τις δημιουργεί εσωτερικά, επιτρέποντας έτσι εύκολη αντικατάσταση και επέκταση της λειτουργικότητας. Ιδιαίτερη έμφαση δόθηκε στη διαχείριση των ασύγχρονων λειτουργιών, όπου η κλάση `Master` υλοποιεί ένα εξελιγμένο σύστημα διαχείρισης επανακλήσεων (callback management system) που εξασφαλίζει τη σωστή σειρά εκτέλεσης των ασύγχρονων συναρτήσεων και την αποφυγή συνθηκών ανταγωνισμού (race conditions).

Το τέταρτο και εξίσου σημαντικό συστατικό είναι το σύστημα δυναμικής φόρτωσης περιεχομένου, το οποίο επιτρέπει τη φόρτωση εικόνων και σχημάτων χωρίς την ανάγκη ανανέωσης της σελίδας. Αυτή η δυνατότητα είναι θεμελιώδης για τη δημιουργία μιας εμπειρίας χρήστη που προσομοιάζει αυτή των εγγενών εφαρμογών επιφάνειας εργασίας. Το σύστημα υλοποιεί προηγμένες τεχνικές προφόρτωσης (preloading) και προσωρινής αποθήκευσης (caching), εξασφαλίζοντας ότι οι συχνά χρησιμοποιούμενοι πόροι είναι άμεσα διαθέσιμοι όταν χρειάζονται.

```
class Master {
    constructor() {
        this.translation = translation;
        this.toast = toast;
        this.currentImageTab = null;
        this.user = null;
        this.userConfiguration = null;
        this.models = {
            shape_types: new Map(),
            classifications: new Map()
        };
        this.imageTabs = new Map();
        this.tabHandler = new TabHandlerUI();
        this.jobsToDo = new JobsToDo();
    }
    init(callback = () => {
    }) {
        let self = this;
        new ReceiveAllEssentialsService(() => {
            this.toast.init(() => {
                this.translation.init(() => {
                    this.tabHandler.init(() => {
                        let imageTabUI = this.tabHandler.selectImageTabUI;
                        if(!(window.disableSelectImage &&
window.loadImageModel)) {
                            if (this.userConfiguration && this.user &&
imageTabUI.images[this.userConfiguration.attribute_parser_image_id]) {
                                let image =
this.tabHandler.selectImageTabUI.images[

this.userConfiguration.attribute_parser_image_id +
(this.userConfiguration.image_testing_id ? "|" +
this.userConfiguration.image_testing_id : null)];
                                let testing_appender = "[data-testing='']";
                                let image_id = image.id;
                                if (image.testing_id) {
                                    testing_appender = "[data-testing='" +
image.testing_id + "']";
                                    image_id += "|" + image.testing_id;
                                }
```

*Πηγαίος Κώδικας 5. Από το `Master` κλάση του annotation Builder του Deep-in-Biopsies έργου.*

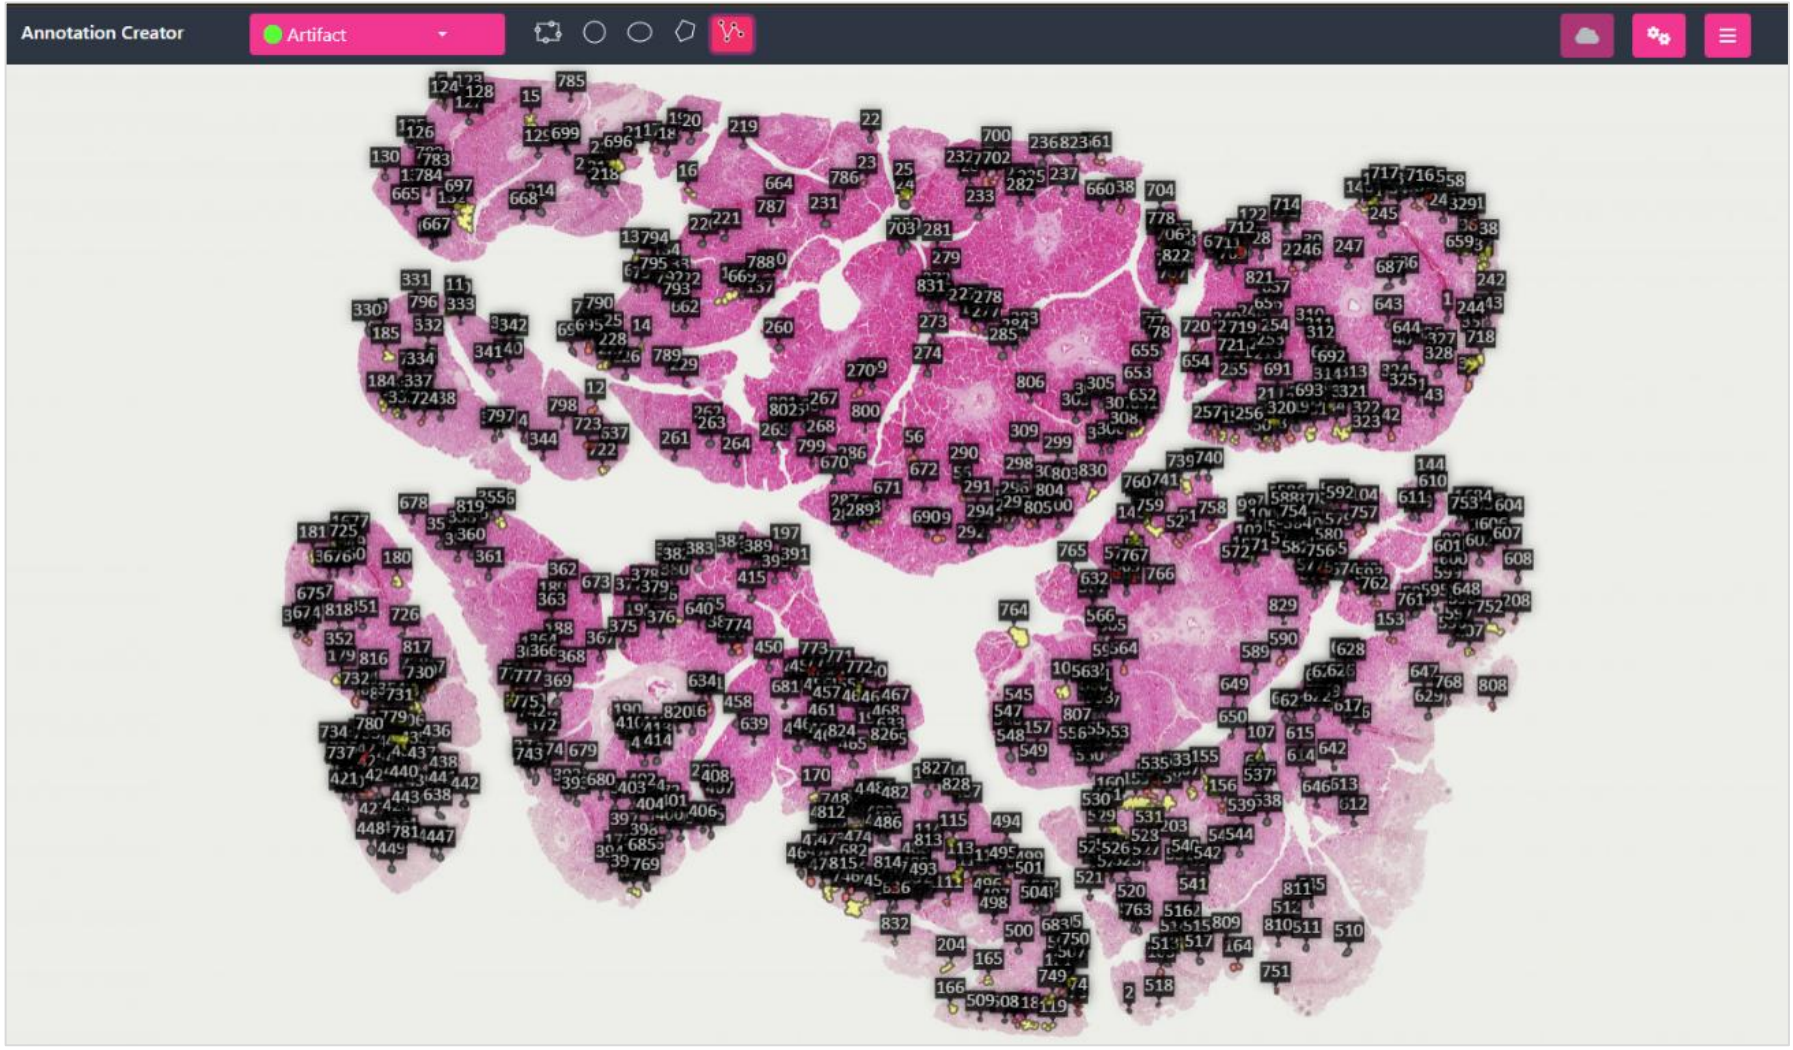


*Εικόνα 4. Παράδειγμα 1, UI από το Annotation Builder του Deep-In-Biopsies έργου*

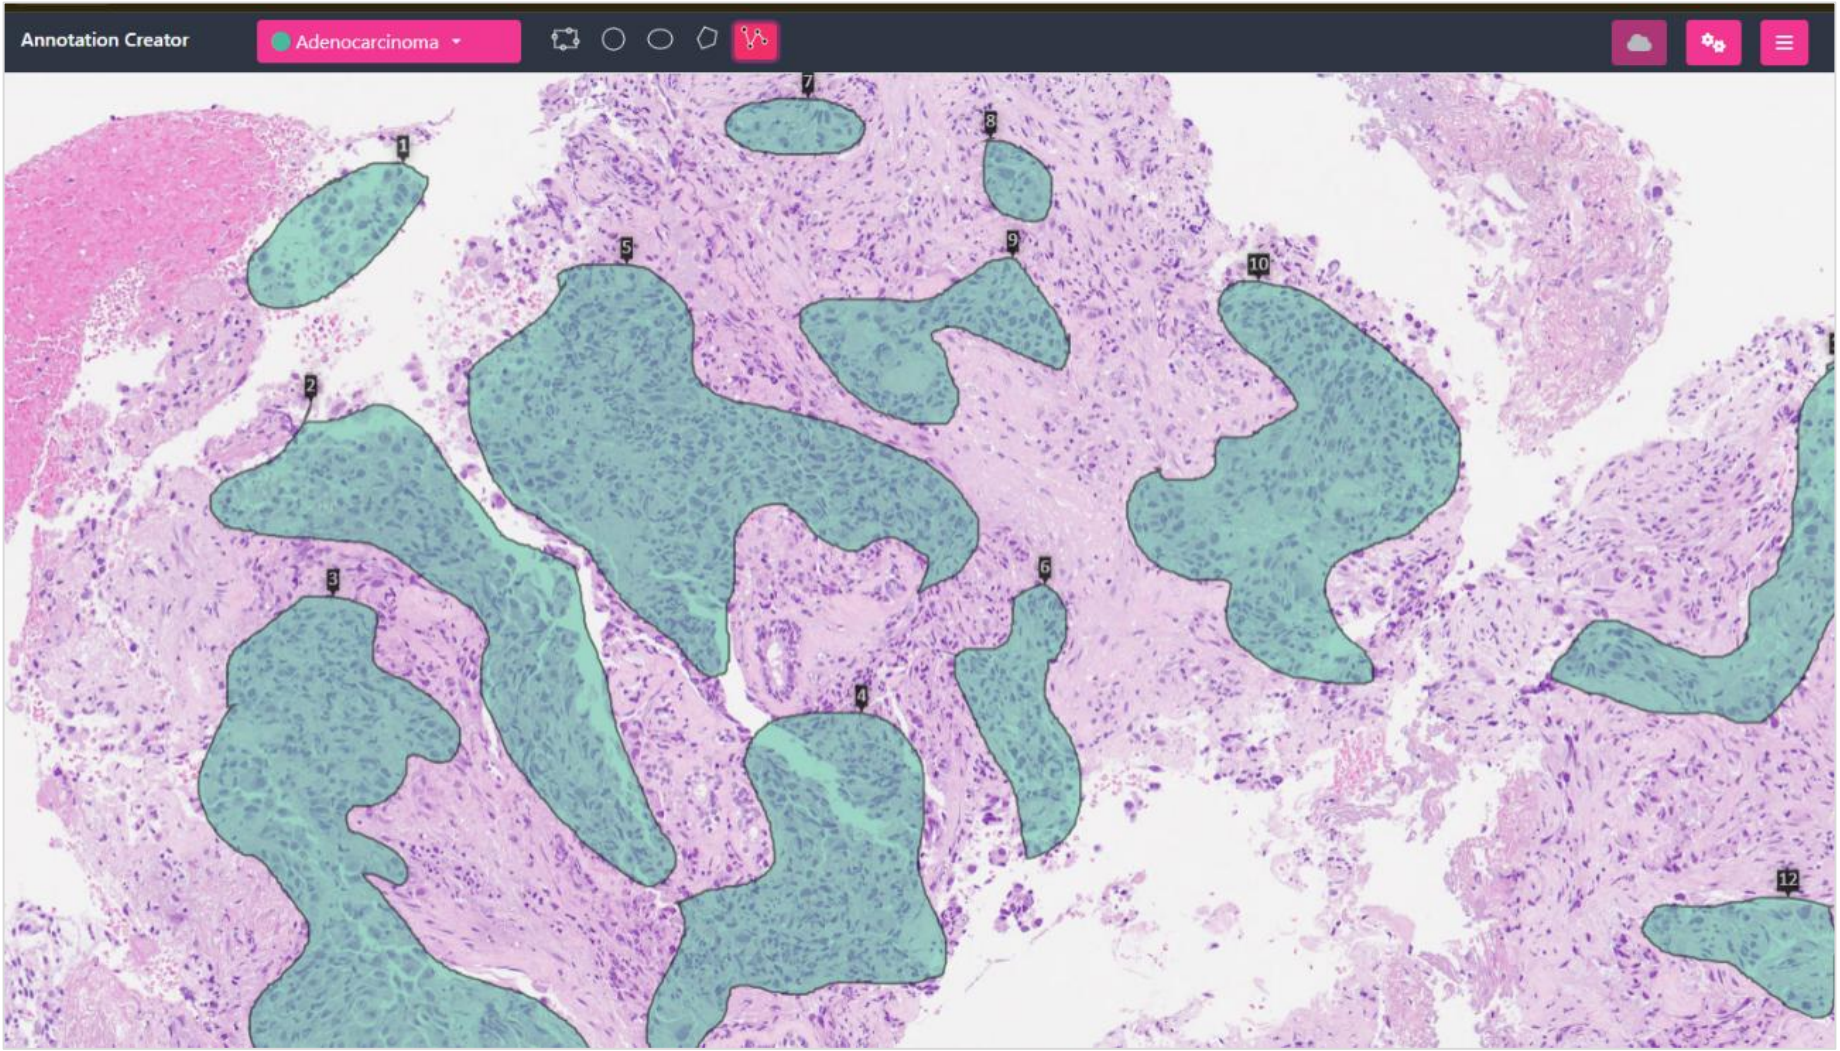


*Εικόνα 5. Παράδειγμα 2, UI από το Annotation Builder του Deep-In-Biopsies έργου*

#### 5.2.1.2. Επιλογή και Υλοποίηση βιβλιοθήκης Konva.js

Η επιλογή της βιβλιοθήκης Konva.js ως το βασικό πλαίσιο γραφικών για την εφαρμογή προέκυψε μετά από εκτενή συγκριτική ανάλυση διαφόρων εναλλακτικών λύσεων. Η διαδικασία αξιολόγησης περιέλαβε λεπτομερή εξέταση βιβλιοθηκών όπως η D3.js , η Paper.js και η Fabric.js, καθεμία από τις οποίες προσέφερε διαφορετικά πλεονεκτήματα και περιορισμούς [129]. Η D3.js [130], αν και εξαιρετικά ισχυρή για την οπτικοποίηση δεδομένων, αποδείχθηκε υπερβολικά πολύπλοκη για τις συγκεκριμένες ανάγκες διαδραστικής σχεδίασης της εφαρμογής. Η Paper.js παρείχε εξαιρετικές δυνατότητες για διανυσματικά γραφικά αλλά έλειπε η βελτιστοποίηση για εφαρμογές με μεγάλο αριθμό διαδραστικών στοιχείων. Η Fabric.js, ενώ προσέφερε καλή ισορροπία μεταξύ λειτουργικότητας και ευκολίας χρήσης, δεν διέθετε το επίπεδο βελτιστοποίησης απόδοσης που απαιτούνταν για τη διαχείριση χιλιάδων σημειώσεων ταυτόχρονα. Η Konva.js αναδείχθηκε ως η βέλτιστη επιλογή λόγω του εξειδικευμένου σχεδιασμού της για διαδραστικές εφαρμογές δισδιάστατων γραφικών υψηλής απόδοσης. Η βιβλιοθήκη προσφέρει μια μοναδική αρχιτεκτονική που συνδυάζει την ευκολία χρήσης με προηγμένες δυνατότητες βελτιστοποίησης. Το σύστημα διαστρωμάτωσης (layering system) που παρέχει επιτρέπει τον αποτελεσματικό διαχωρισμό των στατικών και δυναμικών στοιχείων της σκηνής, μειώνοντας σημαντικά το υπολογιστικό κόστος της απεικόνισης. Η ενσωματωμένη υποστήριξη για προσωρινή αποθήκευση επιπέδων (layer caching) εξασφαλίζει ότι τα στατικά στοιχεία δεν χρειάζεται να επανασχεδιάζονται σε κάθε καρέ, βελτιώνοντας δραματικά την απόδοση σε σύνθετες σκηνές. Ένα από τα πιο καινοτόμα χαρακτηριστικά της Konva.js που αποδείχθηκε κρίσιμο για την εφαρμογή είναι το σύστημα ανίχνευσης χτυπημάτων (hit detection system). Αντί να χρησιμοποιεί τις παραδοσιακές μεθόδους ανίχνευσης που βασίζονται σε μαθηματικούς υπολογισμούς για κάθε αλληλεπίδραση, η Konva.js υλοποιεί ένα δευτερεύον καμβά αποκλειστικά για την ανίχνευση αλληλεπιδράσεων. Κάθε αντικείμενο στη σκηνή αποδίδεται σε αυτόν τον καμβά με ένα μοναδικό χρώμα, επιτρέποντας την άμεση αναγνώριση του αντικειμένου που βρίσκεται κάτω από τον κέρσορα με απλή ανάγνωση του χρώματος του εικονοστοιχείου. Αυτή η προσέγγιση είναι εξαιρετικά αποδοτική ακόμη και όταν η σκηνή περιέχει χιλιάδες αντικείμενα.

#### 5.2.1.3. Πολλαπλά επίπεδα καμβά (Multiple Canvas Layers)

Η υλοποίηση της εφαρμογής αξιοποιεί στρατηγικά τη δυνατότητα της Konva.js για διαχείριση πολλαπλών επιπέδων καμβά, δημιουργώντας μια ιεραρχία που βελτιστοποιεί την απόδοση και την αποκρισιμότητα. Το σύστημα οργανώνεται σε τέσσερα διακριτά επίπεδα, καθένα από τα οποία εξυπηρετεί συγκεκριμένο σκοπό και βελτιστοποιείται ανάλογα με τις ανάγκες του.

- Το πρώτο επίπεδο, που αφορά τις εικόνες υποβάθρου, διαχειρίζεται τις βασικές ιστοπαθολογικές εικόνες που αποτελούν το υπόστρωμα για τις σημειώσεις. Αυτό το επίπεδο παραμένει σχετικά στατικό κατά τη διάρκεια της εργασίας, με εξαίρεση τις λειτουργίες μεγέθυνσης και μετακίνησης. Η υλοποίηση χρησιμοποιεί τεχνικές

προοδευτικής φόρτωσης (progressive loading) για μεγάλες εικόνες, εμφανίζοντας αρχικά μια έκδοση χαμηλής ανάλυσης και σταδιακά φορτώνοντας υψηλότερες αναλύσεις καθώς ο χρήστης εστιάζει σε συγκεκριμένες περιοχές. Αυτή η προσέγγιση εξασφαλίζει άμεση απόκριση ακόμη και κατά την εργασία με εικόνες πολλών gigapixel που είναι συνηθισμένες στην ψηφιακή παθολογία.

- Το δεύτερο επίπεδο αφιερώνεται στα στατικά σχήματα, δηλαδή τις ολοκληρωμένες σημειώσεις που δεν υφίστανται επεξεργασία εκείνη τη στιγμή. Πρακτικά εκμεταλλεύεται εκτενώς τις δυνατότητες προσωρινής αποθήκευσης, αποθηκεύοντας την αποδομένη εικόνα των σχημάτων και αποφεύγοντας την επανασχεδίαση τους σε κάθε καρέ. Όταν ο αριθμός των σχημάτων ξεπερνά ένα συγκεκριμένο όριο, το σύστημα αυτόματα ομαδοποιεί γειτονικά σχήματα σε υπο-επίπεδα, μειώνοντας περαιτέρω το κόστος απεικόνισης.
- Το τρίτο επίπεδο, που διαχειρίζεται τις λειτουργίες σύρσιμου και επεξεργασίας, είναι το πιο δυναμικό και απαιτητικό σε πόρους. Εδώ πραγματοποιούνται όλες οι διαδραστικές λειτουργίες, από τη δημιουργία νέων σχημάτων μέχρι την τροποποίηση υπαρχόντων. Το επίπεδο αυτό ανανεώνεται συνεχώς κατά τη διάρκεια των αλληλεπιδράσεων του χρήστη, και για αυτό τον λόγο διατηρείται όσο το δυνατόν πιο ελαφρύ. Μόνο το σχήμα που επεξεργάζεται εκείνη τη στιγμή και τα απαραίτητα βοηθητικά στοιχεία (όπως λαβές μετασχηματισμού και οδηγοί ευθυγράμμισης) υπάρχουν σε αυτό το επίπεδο.
- Το τέταρτο και τελευταίο επίπεδο αφορά την επικάλυψη διεπαφής χρήστη, όπου τοποθετούνται στοιχεία όπως εργαλειοθήκες, μενού περιβάλλοντος και πληροφοριακά παράθυρα. Αυτά τα στοιχεία πρέπει να παραμένουν πάντα ορατά και προσβάσιμα, ανεξάρτητα από τις αλλαγές στα υποκείμενα επίπεδα. Η υλοποίηση διασφαλίζει ότι τα στοιχεία διεπαφής δεν επηρεάζονται από μετασχηματισμούς που εφαρμόζονται στο περιεχόμενο, διατηρώντας σταθερό μέγεθος και θέση ανεξάρτητα από το επίπεδο μεγέθυνσης.

Η διαχείριση των πολλαπλών επιπέδων απαιτεί προσεκτικό συντονισμό για την αποφυγή προβλημάτων συγχρονισμού και την εξασφάλιση ομαλής λειτουργίας. Το σύστημα υλοποιεί έναν κεντρικό διαχειριστή επιπέδων που συντονίζει τις ενημερώσεις και εξασφαλίζει ότι οι αλλαγές διαδίδονται σωστά μεταξύ των επιπέδων. Όταν ένα σχήμα ολοκληρώνεται και μετακινείται από το δυναμικό στο στατικό επίπεδο, ο διαχειριστής φροντίζει για την ομαλή μετάβαση χωρίς οπτικές ασυνέπειες. Αυτή η πολυεπίπεδη αρχιτεκτονική αποδείχθηκε κρίσιμη για την επίτευξη της απαιτούμενης απόδοσης, επιτρέποντας στην εφαρμογή να διαχειρίζεται αποτελεσματικά σκηνές με χιλιάδες σημειώσεις ενώ διατηρεί ρυθμό ανανέωσης 60 καρέ ανά δευτερόλεπτο ακόμη και σε συστήματα μέτριων δυνατοτήτων.

### 5.2.2. Υλοποίηση Εργαλείων Σχεδίασης και Επεξεργασίας

Η ανάπτυξη του συστήματος εργαλείων σχεδίασης αποτέλεσε μια από τις πιο απαιτητικές πτυχές της υλοποίησης, καθώς έπρεπε να συνδυάσει την ακρίβεια που απαιτείται για

ιατρικές εφαρμογές με την ευκολία χρήσης που αναμένουν οι κλινικοί χρήστες. Η πολυμορφική αρχιτεκτονική που αναπτύχθηκε υποστηρίζει πέντε διαφορετικούς τύπους σχημάτων σημείωσης, καθένας από τους οποίους σχεδιάστηκε για να καλύπτει συγκεκριμένες διαγνωστικές ανάγκες. Το ορθογώνιο παρέχει ταχεία οριοθέτηση κανονικών περιοχών ενδιαφέροντος, ο κύκλος χρησιμοποιείται για στρογγυλές δομές και κυτταρικές οντότητες, η έλλειψη προσαρμόζεται σε ελλειπτικές μορφολογικές δομές, το πολύγωνο επιτρέπει την ακριβή οριοθέτηση ακανόνιστων περιοχών με πολύπλοκη γεωμετρία (Πηγαίος Κώδικας 6), και τέλος το εργαλείο ελεύθερης σχεδίασης προσφέρει απόλυτη ευελιξία για λεπτομερή σημείωση περίπλοκων δομών. Κάθε εργαλείο υλοποιήθηκε ως ανεξάρτητη κλάση που κληρονομεί από μια κοινή βασική δομή, ενσωματώνοντας όλη τη λογική για τη δημιουργία και επεξεργασία σχημάτων. Η προσέγγιση αυτή επιτρέπει την ανεξάρτητη εξέλιξη και βελτίωση κάθε εργαλείου χωρίς να επηρεάζονται οι υπόλοιπες λειτουργίες. Η υλοποίηση βασίζεται σε μια εκτεταμένη αρχιτεκτονική οδηγούμενη από γεγονότα που διασφαλίζει ομαλή και αποκρινόμενη διαδραστικότητα. Το σύστημα παρακολουθεί συνεχώς τις κινήσεις του ποντικιού και αναγνωρίζει πρότυπα αλληλεπίδρασης, προσαρμόζοντας δυναμικά τη συμπεριφορά του ανάλογα με το επιλεγμένο εργαλείο και το πλαίσιο της εργασίας.

```
class MultiPolygon extends Shape {
    constructor(pos, context) {
        super(pos, context);
        this.defaultWidth = null;
        this.defaultHeight = null;
        this.lines = [];
        this.currentLine = new Line({
            x: this.x,
            y: this.y
        }, context);
        this.currentLine.parentClass = MultiPolygon
        this.lines.push(...this.currentLine.format);
        this.points = this.lines;
        this.lockingMechanism = true;
        this.mousemoveTouchmove = false;
        this.done = false;
        this.isFakeFirstTime = true;
        this.keyListen = true;
        this.x = null;
        this.y = null;
        this.width = null;
        this.height = null;
    }
    init() {
        super.init();
        if (this.currentLine)
            this.currentLine.init();
        this.shape = this.currentLine.shape;
        this.id = this.shape._id;
        return this;
    }
    mousemove(e) {
        if (this.creatingObject) {
this.currentShape.movePosition(this.stage.getPointerPosition());
        }
    }
```

*Πηγαίος Κώδικας 6.* `MultiPolygon` *κλάση για την σχεδίαση πολυγώνου στο καμβά του Annotation Builder*

### 5.2.3. Υλοποίηση Συστήματος Δυναμικής Ταξινόμησης

Το σύστημα δυναμικής ταξινόμησης αντικειμένων που αναπτύχθηκε επιτρέπει στους χρήστες να οργανώνουν και να κατηγοριοποιούν τις σημειώσεις τους σε πραγματικό χρόνο, προσαρμόζοντας το σύστημα ταξινόμησης στις ειδικές ανάγκες κάθε εξέτασης. Η υλοποίηση περιλαμβάνει έναν ιεραρχικό μηχανισμό κατηγοριοποίησης που υποστηρίζει πολλαπλά επίπεδα ταξινόμησης, από ευρείες κατηγορίες ιστολογικών ευρημάτων μέχρι λεπτομερείς υποκατηγορίες συγκεκριμένων κυτταρικών τύπων. Το σύστημα διατηρεί έναν δυναμικό κατάλογο κατηγοριών που ενημερώνεται αυτόματα καθώς οι χρήστες προσθέτουν νέες ταξινομήσεις, εξασφαλίζοντας συνέπεια στην ονοματολογία και διευκολύνοντας τη μετέπειτα ανάλυση των δεδομένων.

Η διεπαφή ταξινόμησης, που υλοποιείται μέσω της κλάσης ClassificationTabUI (Πηγαίος Κώδικας 7), σχεδιάστηκε για να ελαχιστοποιεί τη διακοπή της ροής εργασίας, επιτρέποντας την ανάθεση κατηγοριών είτε κατά τη δημιουργία των σημειώσεων είτε μαζικά σε μεταγενέστερο στάδιο. Το σύστημα υποστηρίζει αυτόματη συμπλήρωση και προτάσεις βασισμένες σε προηγούμενες επιλογές του χρήστη, επιταχύνοντας σημαντικά τη διαδικασία κατηγοριοποίησης. Παράλληλα, ενσωματώνεται ένας μηχανισμός μαζικής επεξεργασίας που επιτρέπει την ταυτόχρονη αλλαγή κατηγορίας σε πολλαπλές σημειώσεις, διευκολύνοντας την αναδιοργάνωση μεγάλων συνόλων δεδομένων.

```
class ClassificationTabUI extends TabUI {
    constructor(props) {
        super(props);
        this.parentNode = ".classification-parent";
        this.currentClass = null;
    }

    static colors() {
        let models = master.models.classifications;
        let colors = {};
        for (let ob in models) {
            let model = models[ob];
            colors[model.id] = model.color;
        }
        return colors;
    }
    get classificationName() {

        let models = master.models.classifications;
        for (let ob in models) {
            if (models[ob].id === this.currentClass)
                return models[ob].pretty_name;
        }
    }
    get classificationId() {

        let models = master.models.classifications;
        for (let ob in models) {
            if (models[ob].id === Number(this.currentClass))
                return models[ob].id;
        }
    }

    get classificationColor() {
        return ClassificationTabUI.colors()[this.currentClass];
    }
```

*Πηγαίος Κώδικας 7. `ClassificationTabUI` κλαση του Annotation Builder*

### 5.2.4. Διεπαφή Χρήστη και Διαχείριση Εργασιών

Η διεπαφή χρήστη αναπτύχθηκε ακολουθώντας τις αρχές του ανθρωποκεντρικού σχεδιασμού, με έμφαση στη μείωση της γνωστικής επιβάρυνσης και τη μεγιστοποίηση της παραγωγικότητας. Η κεντρική κλάση `TabHandlerUI` ενορχηστρώνει όλα τα συστατικά της διεπαφής (Πηγαίος Κώδικας 8), διαχειριζόμενη την πλοήγηση μεταξύ διαφορετικών λειτουργικοτήτων και διατηρώντας την κατάσταση της εφαρμογής κατά τις μεταβάσεις. Η οργάνωση των στοιχείων διεπαφής βασίστηκε σε εκτεταμένη έρευνα των προτύπων εργασίας παθολογοανατόμων, εξασφαλίζοντας ότι τα πιο συχνά χρησιμοποιούμενα εργαλεία είναι άμεσα προσβάσιμα. Το σύστημα υλοποιεί μια προσαρμοστική διεπαφή που μαθαίνει από τις συνήθειες του χρήστη και προσαρμόζει

δυναμικά τη διάταξη των εργαλείων για βέλτιστη αποδοτικότητα. Η οπτική ιεραρχία της διεπαφής καθοδηγεί φυσικά το βλέμμα του χρήστη από τα πρωτεύοντα εργαλεία σχεδίασης στις δευτερεύουσες λειτουργίες επεξεργασίας και τέλος στις προχωρημένες επιλογές παραμετροποίησης. Η χρωματική παλέτα επιλέχθηκε προσεκτικά για να παρέχει επαρκή αντίθεση χωρίς να προκαλεί οπτική κόπωση κατά τη διάρκεια παρατεταμένων συνεδριών εργασίας.

Η υλοποίηση ενός ισχυρού συστήματος ασύγχρονης επεξεργασίας αποδείχθηκε κρίσιμη για τη διατήρηση της αποκρισιμότητας της εφαρμογής κατά την εκτέλεση βαριών υπολογιστικών εργασιών. Η κλάση `JobsToDo` αποτελεί την καρδιά αυτού του συστήματος, διαχειριζόμενη μια ουρά εργασιών που εκτελούνται ασύγχρονα μέσω αναδρομικής εκτέλεσης. Το σύστημα οργανώνει τις λειτουργίες σε ουρές προτεραιότητας, εξασφαλίζοντας ότι οι κρίσιμες για την αλληλεπίδραση εργασίες εκτελούνται άμεσα, ενώ οι λειτουργίες υποστήριξης όπως η αυτόματη αποθήκευση και ο συγχρονισμός δεδομένων πραγματοποιούνται στο παρασκήνιο. Ο μηχανισμός διαχείρισης ουρών που υλοποιείται στη μέθοδο `protocolToPush` προσαρμόζει δυναμικά την προτεραιότητα των εργασιών βάσει του τύπου τους. Οι εργασίες μεταφόρτωσης εικόνων μέσω της `UploadImageService` εκτελούνται άμεσα, ενώ άλλες εργασίες όπως η αποθήκευση σχημάτων μέσω της `SaveShapesService` υπόκεινται σε μηχανισμό καθυστέρησης για την ομαδοποίηση πολλαπλών αλλαγών. Αυτή η προσέγγιση εξασφαλίζει βέλτιστη χρήση των διαθέσιμων πόρων χωρίς να επηρεάζεται η εμπειρία του χρήστη

```
class TabHandlerUI {
    constructor() {
        this.allTabsUI = new AllTabsUI();
        this.shapeTabUI = new ShapeTabUI();
        this.classificationTabUI = new ClassificationTabUI();
        this.selectImageTabUI = new SelectImageTabUI();
        this.jobsTabUi = new JobsTabUI();
        this.regionAttributeTabUi = new RegionAttributesTabUI();
        this.settingsTabUI = new SettingTabUI();
    }

    init(callback = () => {
    }) {
        this.allTabsUI.init(() => {
            this.shapeTabUI.init(() => {
                this.classificationTabUI.init(() => {
                    let rest_callback = () => {
                        return this.jobsTabUi.init(() => {
                            this.settingsTabUI.init(() => {
                                this.regionAttributeTabUi.init(() => {

                                    callback();


                                });
                            });
                        });
                    }
                    if (!window.disableSelectImage)
                        this.selectImageTabUI.init(() => {
                            rest_callback();
                        });
                    else{
                     if(window.loadImageModel){
                         let model = new
ImageModel({}).load(window.loadImageModel);
                         console.log(model);
                         this.selectImageTabUI.images_array.push(model)
                         this.selectImageTabUI.images[model.id] = model;

                     }
                        rest_callback();
                    }

                });
            });
        });


    }

}
```

*Πηγαίος Κώδικας 8. `TabHandlerUI` κλαση του AnnotationBuilder*

```
class JobsToDo {
    constructor(onJobChangeEvent) {
        this.onJobChangeEvent = onJobChangeEvent instanceof Function ?
onJobChangeEvent : () => {
        };
        this.jobs = [];
        this.ready = true;
    }

    init(callback) {
        this.initJobs(callback);
    }

    initJobs(callback = () => {
    }) {
        if (this.jobs.length && this.ready) {
            //  console.error(this.ready)
            this.ready = false;
            //  console.log("ready changed", this.ready)
            this.recursiveJob(0, () => {

                this.onJobChangeEvent(this.jobs.length);
                //    console.error("job done");
                this.ready = true;
                callback();
            });
        } else {
            callback();
            //   this.ready = true;
        }
    }

    recursiveJob(index, callback) {
        // console.log(this.jobs[index]);
        if (this.jobs[index]) {
            let job = this.jobs[index];
            let jobInstance = null;
            eval("jobInstance=new " + job.job + " ()");

            if (jobInstance) {
                jobInstance.data = job.data;
                //    console.log(jobInstance.data);
                jobInstance.callback = (res) => {
                    if (res)
                        this.jobs.splice(index, 1);
                    else //keep moving forward;
                        index++;

                    job.callback(res);
                    this.recursiveJob(index, callback);
                };

                return jobInstance.init();
            }
        } else {
            return callback(true);
```

*Πηγαίος Κώδικας 9. `JobsToDo` κλαση του Annotation Builder.*

### 5.2.5. Σύστημα Αυτόματης Αποθήκευσης και Ανάκτησης

Η ανάπτυξη ενός αξιόπιστου συστήματος αυτόματης αποθήκευσης αποτέλεσε θεμελιώδη προτεραιότητα, δεδομένης της κρίσιμης φύσης των ιατρικών δεδομένων που διαχειρίζεται η εφαρμογή. Η κλάση `CollectDataShapes` συλλέγει συνεχώς τις αλλαγές που πραγματοποιεί ο χρήστης σε πραγματικό χρόνο, ενεργοποιώντας τη διαδικασία αποθήκευσης μέσω της μεθόδου `checkJob`. Κάθε αλλαγή που εντοπίζεται από το σύστημα προκαλεί τη δημιουργία μιας νέας εργασίας αποθήκευσης που προστίθεται στην ουρά του `JobsToDo` για ασύγχρονη εκτέλεση. Το σύστημα υλοποιεί έξυπνη ανίχνευση συγκρούσεων που αναγνωρίζει και επιλύει αυτόματα τις περισσότερες περιπτώσεις ταυτόχρονης επεξεργασίας από πολλαπλούς χρήστες. Η `SaveShapesService` διαχειρίζεται την επικοινωνία με τον διακομιστή, εξασφαλίζοντας ότι όλες οι αλλαγές συγχρονίζονται αξιόπιστα. Παράλληλα, η `ReceiveShapesPerImageService` επιτρέπει την ανάκτηση προηγούμενα αποθηκευμένων σημειώσεων, διατηρώντας πλήρες ιστορικό όλων των αλλαγών και επιτρέποντας την αναίρεση λειτουργιών ακόμη και μετά από πολλαπλές συνεδρίες εργασίας.

```
class CollectDataShapes {
    constructor(tab, callback = () => {
    }) {
        this.callback = callback instanceof Function ? callback : () => {
        };
        this.tab = tab;
        this.job_inited = false;
        this.job_id = new Date().getTime();
        this.deletedModels = new Map();

    }
    checkJob() {
        let data = this.allData;
        let self = this;
        if (data.length && !this.job_inited) {
            master.jobsToDo.push(SaveShapesService, Object.assign({},
this.attributesParsed), (res) => {
                if (res) {
                    this.job_inited = false;
                    this.updateAllDataToSaved(res, data);
                    if (self.tab.currentImage.model &&
self.tab.currentImage.model.name) {
//toast.showSuccess(translation.get("upload_shape"),
translation.get("shape_uploaded") + self.tab.currentImage.model.name);
                    }
                }
            }, this.job_id);
            this.job_inited = true;
        } else if (!data.length && this.job_inited) {
            master.jobsToDo.popJobById(this.job_id);
            this.job_inited = false;
        }
    }
```

*Πηγαίος Κώδικας 10. `CollectDataShapes` κλαση του Annotation Builder*

### 5.2.6. Διαχείριση Πολλαπλών Canvas Layers

Η βελτιστοποίηση απόδοσης μέσω στρατηγικού διαχωρισμού επιπέδων αποτέλεσε καθοριστικό παράγοντα για την επίτευξη της απαιτούμενης ταχύτητας απόκρισης, ιδιαίτερα σε σκηνές με εκατοντάδες ή χιλιάδες σημειώσεις. Το σύστημα διαχείρισης επιπέδων που αναπτύχθηκε οργανώνει το περιεχόμενο σε διακριτά στρώματα με διαφορετικά χαρακτηριστικά απόδοσης και ανανέωσης. Το επίπεδο υποβάθρου, που περιέχει τις στατικές ιστοπαθολογικές εικόνες, βελτιστοποιείται για ελάχιστη κατανάλωση μνήμης μέσω τεχνικών συμπίεσης και προοδευτικής φόρτωσης που υλοποιούνται στην `ImageLoaded` κλάση.

Το επίπεδο σημειώσεων χρησιμοποιεί εκτεταμένη προσωρινή αποθήκευση για να αποφύγει την επαναπεικόνιση στατικών στοιχείων, ενώ το διαδραστικό επίπεδο διατηρείται ελαφρύ για μέγιστη αποκρισιμότητα κατά την επεξεργασία. Η διαχείριση των επιπέδων συντονίζεται από την κεντρική κλάση `Master`, η οποία εξασφαλίζει τον σωστό συγχρονισμό μεταξύ των διαφορετικών στρωμάτων και την αποφυγή οπτικών ασυνεπειών κατά τις μεταβάσεις.

### 5.2.7. Προηγμένες Λειτουργίες Επεξεργασίας και Πλοήγησης

Η υλοποίηση εξελιγμένων λειτουργιών μεγέθυνσης και μετακίνησης αποτέλεσε απαραίτητη προϋπόθεση για την αποτελεσματική εργασία με εικόνες υψηλής ανάλυσης που χαρακτηρίζουν την ψηφιακή παθολογία. Η κλάση `ZoomTabUI` διαχειρίζεται όλες τις λειτουργίες zoom, παρέχοντας ομαλή και συνεχή μεγέθυνση από επισκόπηση ολόκληρου του δείγματος μέχρι λεπτομερή εξέταση σε κυτταρικό επίπεδο. Η υλοποίηση χρησιμοποιεί προηγμένους αλγόριθμους παρεμβολής για τη διατήρηση της οπτικής ποιότητας σε όλα τα επίπεδα μεγέθυνσης, ενώ παράλληλα εφαρμόζει τεχνικές επιτάχυνσης υλικού όπου αυτές είναι διαθέσιμες.

Το σύστημα πλοήγησης ενσωματώνει πολλαπλούς τρόπους αλληλεπίδρασης, από τον παραδοσιακό έλεγχο με ποντίκι μέχρι υποστήριξη για οθόνες αφής και χειρονομίες πολλαπλών δακτύλων. Η υλοποίηση περιλαμβάνει έναν προσαρμοστικό μηχανισμό που ρυθμίζει την ευαισθησία και την απόκριση βάσει της ταχύτητας και του μοτίβου των κινήσεων του χρήστη, παρέχοντας ακριβή έλεγχο για λεπτομερή εργασία και γρήγορη πλοήγηση για επισκόπηση μεγάλων περιοχών. Επιπρόσθετα, το σύστημα διατηρεί ιστορικό πλοήγησης που επιτρέπει την άμεση επιστροφή σε προηγούμενες θέσεις και επίπεδα μεγέθυνσης.

### 5.2.8. Σύστημα Διαχείρισης Ιστορικού και Αναίρεσης

Η ανάπτυξη ενός ολοκληρωμένου συστήματος διαχείρισης ιστορικού επιτρέπει στους χρήστες να πειραματίζονται ελεύθερα με τις σημειώσεις τους, γνωρίζοντας ότι μπορούν να αναιρέσουν οποιαδήποτε αλλαγή. Το σύστημα που υλοποιήθηκε μέσω της κλάσης `Runtime` διατηρεί λεπτομερές καταγραφή κάθε ενέργειας, από απλές μετακινήσεις

σχημάτων μέχρι πολύπλοκες ομαδικές τροποποιήσεις. Η αρχιτεκτονική βασίζεται στο πρότυπο `Command`, όπου κάθε ενέργεια αναπαρίσταται ως ένα αυτόνομο αντικείμενο που περιέχει όλες τις απαραίτητες πληροφορίες για την εκτέλεση και αναίρεσή της.

Το σύστημα υλοποιεί έξυπνη ομαδοποίηση σχετιζόμενων ενεργειών, επιτρέποντας την αναίρεση λογικών μονάδων εργασίας αντί μεμονωμένων κινήσεων. Για παράδειγμα, η δημιουργία ενός πολύγωνου που απαιτεί πολλαπλά κλικ καταγράφεται ως μία ενιαία ενέργεια που μπορεί να αναιρεθεί με ένα βήμα. Παράλληλα, το σύστημα εφαρμόζει αποδοτική διαχείριση μνήμης, συμπιέζοντας το ιστορικό και διατηρώντας μόνο τις απαραίτητες πληροφορίες για την αναδόμηση προηγούμενων καταστάσεων.

### 5.2.9. Υλοποίηση Συστήματος Επιλογής και Διαχείρισης Εικόνων

Η διαχείριση πολλαπλών ιστοπαθολογικών εικόνων αποτελεί κρίσιμη λειτουργία για την αποτελεσματική ροή εργασίας των παθολογοανατόμων. Η κλάση SelectImageTabUI παρέχει μια διαισθητική διεπαφή για την επιλογή και εναλλαγή μεταξύ διαφορετικών εικόνων, ενώ η ImageModel διατηρεί όλες τις απαραίτητες πληροφορίες για κάθε εικόνα. Το σύστημα υποστηρίζει δυναμική φόρτωση εικόνων μέσω της `ReceiveImageService`, επιτρέποντας την προοδευτική φόρτωση μεγάλων αρχείων χωρίς να επηρεάζεται η απόκριση της εφαρμογής.

Η υλοποίηση περιλαμβάνει προηγμένες δυνατότητες όπως η αυτόματη αναγνώριση τύπου εικόνας, η προσαρμογή των ρυθμίσεων απεικόνισης βάσει των χαρακτηριστικών κάθε εικόνας, και η διατήρηση των σημειώσεων κατά την εναλλαγή μεταξύ εικόνων. Το σύστημα υποστηρίζει επίσης την ταυτόχρονη εμφάνιση πολλαπλών εικόνων για συγκριτική ανάλυση, με συγχρονισμένη πλοήγηση και zoom μεταξύ των διαφορετικών προβολών.

### 5.2.10. Σύστημα Εξαγωγής και Στατιστικής Ανάλυσης

Η δημιουργία ολοκληρωμένων αναφορών από τις σημειώσεις αποτελεί κρίσιμη λειτουργία για την κλινική χρήση της πλατφόρμας. Η κλάση `ReceiveImageStatisticsService` συλλέγει και επεξεργάζεται στατιστικά δεδομένα από τις σημειώσεις, υπολογίζοντας μετρήσεις όπως η κάλυψη επιφάνειας, η κατανομή των διαφορετικών τύπων ευρημάτων και άλλες ποσοτικές παραμέτρους. Το σύστημα αυτόματα παράγει συγκεντρωτικά στατιστικά που είναι απαραίτητα για τη διαγνωστική αξιολόγηση και την παρακολούθηση της εξέλιξης της νόσου.

Η υλοποίηση υποστηρίζει πολλαπλές μορφές εξαγωγής, από απλά αρχεία εικόνων με ενσωματωμένες σημειώσεις μέχρι δομημένα έγγραφα που περιλαμβάνουν λεπτομερή στατιστική ανάλυση. Το σύστημα ενσωματώνει αλγόριθμους για τον υπολογισμό κλινικά σημαντικών δεικτών, όπως ο λόγος στρώματος προς παρέγχυμα σε ηπατικές βιοψίες ή η πυκνότητα φλεγμονωδών κυττάρων σε νεοπλασματικούς ιστούς. Επιπρόσθετα, παρέχεται

η δυνατότητα δημιουργίας προσαρμοσμένων αναφορών βάσει προτύπων που ορίζει ο χρήστης.

### 5.2.11. Διαχείριση Περιοχικών Χαρακτηριστικών

Η κλάση `RegionAttributesTabUI` υλοποιεί ένα εξελιγμένο σύστημα για την προσθήκη και διαχείριση λεπτομερών χαρακτηριστικών σε κάθε σημειωμένη περιοχή. Αυτή η λειτουργικότητα επιτρέπει στους παθολογοανατόμους να εμπλουτίζουν τις σημειώσεις τους με δομημένα μεταδεδομένα που περιγράφουν κλινικά χαρακτηριστικά, μορφολογικές παρατηρήσεις και διαγνωστικά ευρήματα. Το σύστημα υποστηρίζει δυναμική δημιουργία πεδίων χαρακτηριστικών βάσει του τύπου της εξέτασης και των ειδικών απαιτήσεων κάθε περίπτωσης.

Η υλοποίηση περιλαμβάνει έναν ευέλικτο μηχανισμό ορισμού χαρακτηριστικών που επιτρέπει τη δημιουργία προσαρμοσμένων φορμών εισαγωγής δεδομένων για διαφορετικούς τύπους ιστών και παθολογικών καταστάσεων. Το σύστημα υποστηρίζει πολλαπλούς τύπους δεδομένων, από απλά κείμενα και αριθμητικές τιμές μέχρι πολύπλοκες ιεραρχικές δομές και ελεγχόμενα λεξιλόγια. Η διεπαφή σχεδιάστηκε για να διευκολύνει τη γρήγορη εισαγωγή δεδομένων με αυτόματη συμπλήρωση, έλεγχο εγκυρότητας και προτάσεις βάσει του κλινικού πλαισίου.

### 5.2.12. Διαχείριση Ρυθμίσεων και Προσωποποίηση

Το σύστημα διαχείρισης ρυθμίσεων που υλοποιείται μέσω της κλάσης `SettingTabUI` παρέχει εκτεταμένες δυνατότητες προσαρμογής της εφαρμογής στις προτιμήσεις και τις ανάγκες κάθε χρήστη. Η κλάση `UserConfiguration` αποθηκεύει και διαχειρίζεται όλες τις προσωπικές ρυθμίσεις, από τις προτιμήσεις διεπαφής μέχρι τις προεπιλεγμένες τιμές για τα εργαλεία σχεδίασης. Το σύστημα υποστηρίζει προφίλ χρηστών που επιτρέπουν την άμεση εναλλαγή μεταξύ διαφορετικών διαμορφώσεων ανάλογα με τον τύπο της εξέτασης ή τις προσωπικές προτιμήσεις.

Η `SetUserConfigurationService` διαχειρίζεται τον συγχρονισμό των ρυθμίσεων με τον διακομιστή, εξασφαλίζοντας ότι οι προτιμήσεις του χρήστη διατηρούνται μεταξύ διαφορετικών συνεδριών και συσκευών. Το σύστημα περιλαμβάνει ρυθμίσεις για την απόδοση της εφαρμογής, επιτρέποντας τη βελτιστοποίηση για διαφορετικές δυνατότητες υλικού και συνθήκες δικτύου. Επιπλέον, υποστηρίζεται η δημιουργία και κοινοποίηση προτύπων ρυθμίσεων μεταξύ χρηστών της ίδιας ομάδας ή τμήματος.

### 5.2.13. Ολοκλήρωση Συστημάτων και Διαχείριση Δεδομένων

Η κλάση ReceiveAllEssentialsService αποτελεί τον κεντρικό κόμβο για τη συλλογή και οργάνωση όλων των απαραίτητων δεδομένων κατά την εκκίνηση της εφαρμογής. Αυτή η υπηρεσία συντονίζει τη φόρτωση των ρυθμίσεων χρήστη, των διαθέσιμων εικόνων, των

υπαρχουσών σημειώσεων και όλων των άλλων δεδομένων που απαιτούνται για την πλήρη αρχικοποίηση του συστήματος. Η υλοποίηση χρησιμοποιεί τεχνικές παράλληλης φόρτωσης για την ελαχιστοποίηση του χρόνου εκκίνησης, ενώ παράλληλα εξασφαλίζει τη σωστή σειρά εξαρτήσεων μεταξύ των διαφορετικών συστατικών.

Η κλάση `Master` λειτουργεί ως ο κεντρικός ενορχηστρωτής όλων των συστατικών της εφαρμογής, διαχειριζόμενη τον κύκλο ζωής της εφαρμογής και συντονίζοντας την επικοινωνία μεταξύ των διαφορετικών modules. Η υλοποίηση ακολουθεί το πρότυπο της έγχυσης εξαρτήσεων, επιτρέποντας την εύκολη επέκταση και τροποποίηση της λειτουργικότητας χωρίς να επηρεάζεται η βασική αρχιτεκτονική. Ιδιαίτερη έμφαση δόθηκε στη διαχείριση των ασύγχρονων λειτουργιών μέσω `callback` συναρτήσεων, εξασφαλίζοντας τη σωστή σειρά εκτέλεσης και την αποφυγή συνθηκών ανταγωνισμού.

### 5.2.14. Βελτιστοποίηση Απόδοσης και Ποιότητα Κώδικα

Η τελική φάση της υλοποίησης επικεντρώθηκε στη βελτιστοποίηση της συνολικής απόδοσης του συστήματος και τη διασφάλιση της ποιότητας του κώδικα. Η κλάση Helper παρέχει ένα σύνολο βοηθητικών συναρτήσεων που χρησιμοποιούνται σε όλη την εφαρμογή για κοινές λειτουργίες όπως μετατροπές δεδομένων, υπολογισμούς γεωμετρίας και χειρισμό συμβάντων. Η κεντρικοποίηση αυτών των λειτουργιών εξασφαλίζει συνέπεια στην υλοποίηση και διευκολύνει τη συντήρηση του κώδικα.

Η κλάση `Translation` διαχειρίζεται την πολυγλωσσική υποστήριξη της εφαρμογής, επιτρέποντας την εύκολη μετάφραση όλων των στοιχείων της διεπαφής χρήστη. Το σύστημα υποστηρίζει δυναμική αλλαγή γλώσσας χωρίς την ανάγκη επαναφόρτωσης της σελίδας, με αυτόματη προσαρμογή της διάταξης για γλώσσες με διαφορετική κατεύθυνση γραφής. Η υλοποίηση περιλαμβάνει μηχανισμούς για τη διαχείριση πολύπλοκων μεταφραστικών σεναρίων, όπως πληθυντικοί αριθμοί και παραμετρικά μηνύματα.

Το σύστημα διαχείρισης μοντέλων δεδομένων που υλοποιείται μέσω των κλάσεων `ModelShape` και `ShapeType` εξασφαλίζει την ακεραιότητα και τη συνέπεια των δεδομένων σε όλη την εφαρμογή. Αυτές οι κλάσεις ορίζουν τη δομή και τους κανόνες επικύρωσης για όλα τα αντικείμενα που διαχειρίζεται το σύστημα, από απλά γεωμετρικά σχήματα μέχρι πολύπλοκες κλινικές σημειώσεις. Η χρήση ισχυρής τυποποίησης και αυστηρών ελέγχων επικύρωσης ελαχιστοποιεί τα σφάλματα και βελτιώνει την αξιοπιστία του συστήματος.Η τελική βελτιστοποίηση περιέλαβε εκτεταμένη ανάλυση απόδοσης με χρήση εργαλείων profiling για τον εντοπισμό και την εξάλειψη σημείων συμφόρησης. Εφαρμόστηκαν τεχνικές όπως η οκνηρή φόρτωση για μη κρίσιμα συστατικά, η συγχώνευση και ελαχιστοποίηση του κώδικα για μείωση του μεγέθους των αρχείων, και η χρήση service workers για προσωρινή αποθήκευση και λειτουργία εκτός σύνδεσης. Το αποτέλεσμα είναι μια εφαρμογή που διατηρεί υψηλή απόδοση ακόμη και σε συστήματα περιορισμένων δυνατοτήτων, παρέχοντας ομαλή εμπειρία χρήσης σε ένα ευρύ φάσμα συσκευών και συνθηκών λειτουργίας.

```
class Helper {
    constructor() {
    }
    static shadeColor(color, percent) {
        let R = parseInt(color.substring(1, 3), 16);
        let G = parseInt(color.substring(3, 5), 16);
        let B = parseInt(color.substring(5, 7), 16);
        R = parseInt(R * (100 + percent) / 100);
        G = parseInt(G * (100 + percent) / 100);
        B = parseInt(B * (100 + percent) / 100);
        R = (R < 255) ? R : 255;
        G = (G < 255) ? G : 255;
        B = (B < 255) ? B : 255;
        let RR = ((R.toString(16).length == 1) ? "0" + R.toString(16) :
R.toString(16));
        let GG = ((G.toString(16).length == 1) ? "0" + G.toString(16) :
G.toString(16));
        let BB = ((B.toString(16).length == 1) ? "0" + B.toString(16) :
B.toString(16));
        return "#" + RR + GG + BB;
    }
```

*Πηγαίος Κώδικας 11. Κλάση `Helper` του Annotation Builder*

## 5.3. Υλοποίηση Μονάδας Επεξεργασίας ΤΝ

Η Μονάδα Επεξεργασίας Τεχνητής Νοημοσύνης αποτελεί τον τεχνολογικό πυρήνα της παρούσας πλατφόρμας και υλοποιεί την αναγκαία υπολογιστική ισχύ για την εκπαίδευση, αξιολόγηση και εφαρμογή προηγμένων μοντέλων βαθιάς μάθησης στην ψηφιακή παθολογία. Η υλοποίηση της μονάδας αυτής βασίστηκε στο εξειδικευμένο πλαίσιο Detectron2 της Facebook AI Research, το οποίο παρέχει σύγχρονες αρχιτεκτονικές και βελτιστοποιήσεις για εργασίες ανίχνευσης και κατάτμησης αντικειμένων.

Η επιλογή του Detectron2 ως θεμελιώδους βιβλιοθήκης δεν ήταν τυχαία, αλλά αποτέλεσε αποτέλεσμα εκτενούς συγκριτικής ανάλυσης εναλλακτικών πλαισίων. Το Detectron2 προσφέρει εξαιρετική ευελιξία στην παραμετροποίηση μοντέλων, υποστηρίζει ένα ευρύ φάσμα σύγχρονων αρχιτεκτονικών όπως Mask R-CNN, Cascade R-CNN και Keypoint R-CNN, και παρέχει βελτιστοποιημένη υποστήριξη για εκπαίδευση σε πολλαπλούς γραφικούς επεξεργαστές . Επιπλέον, η ισχυρή κοινότητα προγραμματιστών και η συνεχής ανάπτυξη νέων χαρακτηριστικών καθιστούν το Detectron2 μια αξιόπιστη επιλογή για ερευνητικές και παραγωγικές εφαρμογές.

Η αρχιτεκτονική της μονάδας σχεδιάστηκε με γνώμονα την επεκτασιμότητα και την προσαρμοστικότητα σε διαφορετικά κλινικά σενάρια. Η κεντρική κλάση ApplicationMaster λειτουργεί ως ορχηστρωτής όλων των λειτουργιών της μονάδας, διαχειρίζεται την εκπαίδευση και αξιολόγηση μοντέλων, και συντονίζει την επικοινωνία με το Backend σύστημα για την ανταλλαγή δεδομένων και αποτελεσμάτων. Αυτή η

κεντρικοποιημένη προσέγγιση επιτρέπει τον αποτελεσματικό έλεγχο της ροής εργασίας και τη διασφάλιση της συνοχής των αποτελεσμάτων.

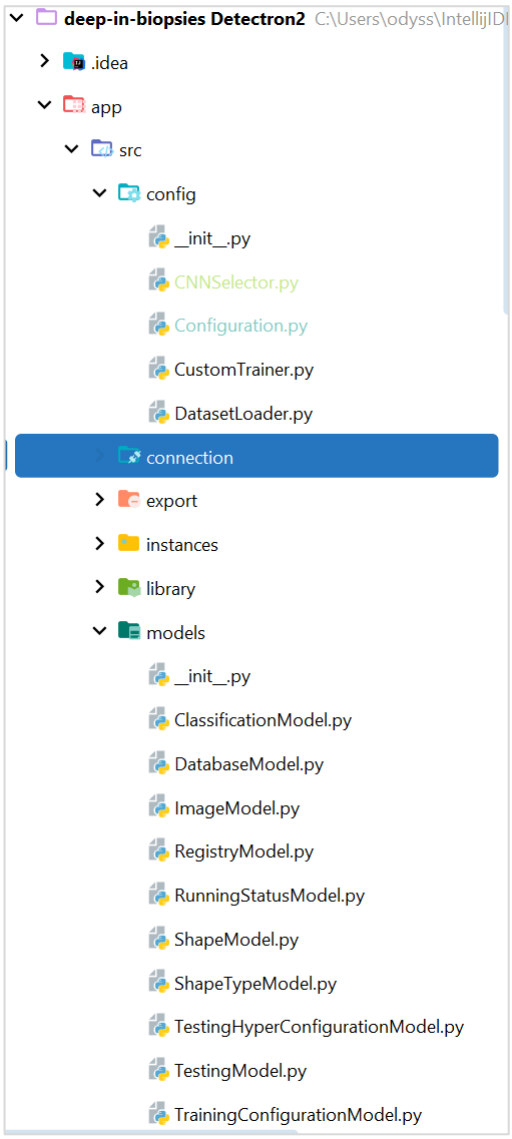


*Εικόνα 6. Δομή έργου AI Module*

### 5.3.1. Ανάπτυξη Εφαρμογής Python/Detectron2

Η υλοποίηση της εφαρμογής Python ακολούθησε σύγχρονες αρχές αντικειμενοστρεφούς προγραμματισμού και επεστίασε στη δημιουργία ενός ευέλικτου και επεκτάσιμου συστήματος που μπορεί να προσαρμοστεί στις διαφορετικές ανάγκες των κλινικών εφαρμογών. Η κεντρική φιλοσοφία της υλοποίησης επικεντρώθηκε στη δημιουργία αποσυνδεδεμένων συστατικών που μπορούν να λειτουργούν ανεξάρτητα αλλά και να συνεργάζονται αρμονικά για την επίτευξη πολύπλοκων εργασιών.

Η κλάση `ApplicationMaster` αποτελεί το σημείο εισόδου για όλες τις λειτουργίες της μονάδας και υλοποιεί ένα σύνολο βασικών μεθόδων που καλύπτουν τον πλήρη κύκλο

ζωής ενός μοντέλου μηχανικής μάθησης. Η μέθοδος init() διαχειρίζεται την αρχικοποίηση του περιβάλλοντος εκτέλεσης, ελέγχει τη διαθεσιμότητα των απαιτούμενων πόρων και προετοιμάζει τις δομές δεδομένων που θα χρησιμοποιηθούν κατά τη διάρκεια της εκτέλεσης. Η μέθοδος `start_train()` ενορχηστρώνει την πλήρη διαδικασία εκπαίδευσης, από τη φόρτωση των δεδομένων μέχρι την αποθήκευση των εκπαιδευμένων μοντέλων, ενώ η `start_testing()` υλοποιεί τη διαδικασία αξιολόγησης και εφαρμογής των μοντέλων σε νέα δεδομένα.

Ιδιαίτερη έμφαση δόθηκε στη δημιουργία ενός ευέλικτου συστήματος διαχείρισης παραμέτρων που επιτρέπει στους χρήστες να προσαρμόζουν κάθε πτυχή της λειτουργίας των μοντέλων χωρίς να απαιτείται τροποποίηση του κώδικα. Αυτό επιτυγχάνεται μέσω της κλάσης Configuration, η οποία παρέχει ένα αφαιρετικό επίπεδο για τη διαχείριση των παραμέτρων του Detectron2 και επιτρέπει τον δυναμικό καθορισμό υπερπαραμέτρων μέσω απλών αρχείων ρυθμίσεων.

Η συγκεκριμένη υλοποίηση υποστηρίζει πολλαπλούς τρόπους λειτουργίας, περιλαμβανομένων της εκπαίδευσης νέων μοντέλων από την αρχή, της συνέχισης προϋπάρχουσας εκπαίδευσης από συγκεκριμένο σημείο ελέγχου, και της εφαρμογής προεκπαιδευμένων μοντέλων για inference σε νέα δεδομένα. Αυτή η ευελιξία είναι κρίσιμη για την υποστήριξη διαφορετικών ερευνητικών και κλινικών σεναρίων, όπου οι απαιτήσεις μπορεί να διαφέρουν σημαντικά ανάλογα με τον τύπο των εικόνων, τον αριθμό των κλάσεων, και τους διαθέσιμους υπολογιστικούς πόρους. Η διαχείριση εξαιρέσεων και σφαλμάτων σχεδιάστηκε με στόχο την παροχή λεπτομερών πληροφοριών για την αναγνώριση και επιδιόρθωση προβλημάτων. Κάθε κρίσιμη λειτουργία περιβάλλεται από κατάλληλους μηχανισμούς ελέγχου που επιτρέπουν τη σταδιακή αποκλιμάκωση σε περίπτωση αποτυχίας και την αυτόματη ανάκαμψη όπου αυτό είναι δυνατό. Επιπλέον, το σύστημα καταγραφής παρέχει λεπτομερείς πληροφορίες για όλες τις φάσεις της εκτέλεσης, διευκολύνοντας τη διάγνωση προβλημάτων και τη βελτιστοποίηση της απόδοσης.

### 5.3.2. Υλοποίηση Συνελικτικών Δικτύων και Διαδικασίας Εκπαίδευσης

Η υλοποίηση των συνελικτικών νευρωνικών δικτύων στην πλατφόρμα Deep-in-Biopsies βασίζεται σε μια εξελιγμένη αρχιτεκτονική που συνδυάζει την ισχύ του Detectron2 με εξειδικευμένες προσαρμογές για ιστοπαθολογικές εφαρμογές. Η σχεδιαστική προσέγγιση επικεντρώθηκε στη δημιουργία ενός ευέλικτου συστήματος που μπορεί να υποστηρίξει πολλαπλές αρχιτεκτονικές μοντέλων και να προσαρμοστεί δυναμικά στις απαιτήσεις διαφορετικών κλινικών σεναρίων.

Η κλάση CNNSelector υλοποιεί ένα εξελιγμένο σύστημα επιλογής αρχιτεκτονικών που αποτελεί κρίσιμο συστατικό για την προσαρμοστικότητα της πλατφόρμας. Η μέθοδος choose_model_type αναλύει τα χαρακτηριστικά του προβλήματος, όπως τον αριθμό και τον τύπο των κλάσεων αντικειμένων, το μέγεθος του συνόλου δεδομένων, και τους

διαθέσιμους υπολογιστικούς πόρους, για να επιλέξει την κατάλληλη αρχιτεκτονική από ένα ευρύ φάσμα επιλογών που περιλαμβάνει Mask R-CNN, Cascade R-CNN, και Keypoint R-CNN.

```
class CNNSelector:
    cfg = None
    name = "mask_rcnn"
    path_name = "COCO-InstanceSegmentation/mask_rcnn_R_50_FPN_3x.yaml"

    def __init__(self, cfg, name="mask_rcnn"):
        self.name = name
        self.choose_model_type(name)

    def choose_model_type(self, model_type):
        model_path_name = None

        match model_type:
            case "mask_rcnn":
                model_path_name = "COCO-
InstanceSegmentation/mask_rcnn_R_50_FPN_3x.yaml"
            case "retinanet":
                model_path_name = "COCO-
Detection/retinanet_R_50_FPN_3x.yaml"
            case "fast_rcnn":
                model_path_name = "COCO-
Detection/fast_rcnn_R_50_FPN_3x.yaml"
            case "faster_rcnn":
                model_path_name = "COCO-
Detection/faster_rcnn_R_50_FPN_3x.yaml"
            case "keypoint_rcnn":
                model_path_name = "COCO-
Keypoints/keypoint_rcnn_R_50_FPN_3x.yaml"
            case "panoptic_fpn":
                model_path_name = "COCO-
PanopticSegmentation/panoptic_fpn_R_50_3x.yaml"
            case "cascade_rcnn":
                model_path_name = "Misc/cascade_rcnn_R_50_FPN_3x.yaml"
            case _:
                model_path_name = "COCO-
InstanceSegmentation/mask_rcnn_R_50_FPN_3x.yaml"


self.cfg.merge_from_file(model_zoo.get_config_file(model_path_name))
        self.cfg.MODEL.WEIGHTS =
model_zoo.get_checkpoint_url(model_path_name)
```

*Πηγαίος Κώδικας 12. `CNNSelector` κλαση, AI Application*

Η υλοποίηση περιλαμβάνει προηγμένους αλγόριθμους αξιολόγησης που λαμβάνουν υπόψη παράγοντες όπως την πολυπλοκότητα των αντικειμένων προς ανίχνευση, τη διαθέσιμη μνήμη GPU, και τις απαιτήσεις ταχύτητας inference. Το σύστημα μπορεί επίσης να προτείνει βελτιστοποιημένες ρυθμίσεις υπερπαραμέτρων βάσει των χαρακτηριστικών του επιλεγμένου μοντέλου και των ιδιαιτεροτήτων των δεδομένων εκπαίδευσης

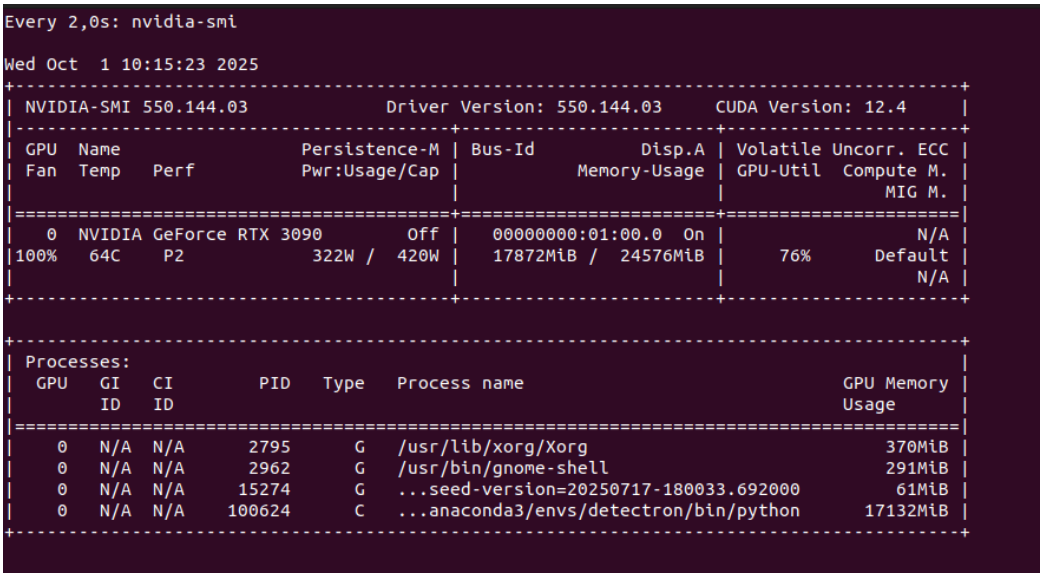


*Εικόνα 7. GPU στατιστικά από εκπαιδευση των Νευρωνικών δικτυών*

- Η κλάση `CustomTrainer` επεκτείνει τη βασική λειτουργικότητα του Detectron2 `DefaultTrainer` με εξειδικευμένες δυνατότητες που έχουν σχεδιαστεί ειδικά για την αποτελεσματική εκπαίδευση σε ιστοπαθολογικά δεδομένα. Η αρχιτεκτονική της κλάσης επιτρέπει την εύκολη επέκταση και προσαρμογή σε νέες απαιτήσεις χωρίς την ανάγκη τροποποίησης του βασικού κώδικα του Detectron2.
- Η μέθοδος `build_train_loader()` υλοποιεί εξειδικευμένους φορτωτές δεδομένων που έχουν βελτιστοποιηθεί για τα μεγάλα μεγέθη εικόνων που είναι χαρακτηριστικά των ψηφιακών βιοψιών. Η υλοποίηση περιλαμβάνει προηγμένες τεχνικές memory mapping και lazy loading που επιτρέπουν την αποδοτική διαχείριση συνόλων δεδομένων που υπερβαίνουν τη διαθέσιμη μνήμη του συστήματος. Επιπλέον, η μέθοδος ενσωματώνει ευφυή συστήματα cache που μπορούν να επιταχύνουν σημαντικά τη φόρτωση δεδομένων κατά τη διάρκεια της εκπαίδευσης.
- Η μέθοδος `build_evaluator()` παρέχει προσαρμοσμένες δυνατότητες αξιολόγησης που υπερβαίνουν τις παραδοσιακές μετρικές computer vision και περιλαμβάνουν εξειδικευμένες μετρικές για ιστοπαθολογικές εφαρμογές. Αυτό περιλαμβάνει μετρικές όπως την ακρίβεια κατάτμησης ανά τύπο κυττάρου, την ποιότητα των ορίων των μασκών, και τη συνοχή των αποτελεσμάτων σε διαφορετικές περιοχές της ίδιας εικόνας.
- Η κλάση `Augmentation` υλοποιεί ένα εξελιγμένο σύστημα επαύξησης δεδομένων που έχει σχεδιαστεί ειδικά για τις απαιτήσεις της ψηφιακής παθολογίας. Η προσέγγιση δεν περιορίζεται σε παραδοσιακές γεωμετρικές μετασχηματισμούς αλλά περιλαμβάνει εξειδικευμένες τεχνικές που προσομοιώνουν διαφορετικές συνθήκες απεικόνισης και προετοιμασίας δειγμάτων. Ο Πηγαίος Κώδικας 13 της Augmentation κλάσης εκτελείται σε

περίπτωση που ο χρήστης δεν επιλέξει από την πλατφόρμα το δικό του augmentation μέσω της διεπαφής για την εκπαίδευση του νευρωνικου δικτύου.

```
class Augmentation:

    @staticmethod
    def mapper(dataset_dict):
        percentage = 0.8
        # Implement a mapper, similar to the default DatasetMapper, but
with your own customizations
        dataset_dict = copy.deepcopy(dataset_dict)  # it will be
modified by code below
        image = utils.read_image(dataset_dict["file_name"],
format="BGR")

        image, transforms = T.apply_transform_gens([
            T.RandomApply(T.Resize(shape=(1000, 1000)), 1),
            T.RandomFlip(prob=percentage, horizontal=True,
vertical=False),
            T.RandomFlip(prob=percentage, horizontal=False,
vertical=True),
            T.RandomApply(T.RandomBrightness(intensity_min=0.75,
intensity_max=1.25),
                          prob=percentage),
            T.RandomApply(T.RandomContrast(intensity_min=0.76,
intensity_max=1.25),
                          prob=percentage),
            T.RandomApply(T.RandomCrop(crop_type="relative_range",
crop_size=(0.8, 0.8)),
                          prob=percentage),
            T.RandomApply(T.RandomSaturation(intensity_min=0.75,
intensity_max=1.25),
                          prob=percentage),
            T.RandomApply(
                T.RandomRotation(angle=[-30, 30], expand=True,
center=None, sample_style="range", interp=None),
                prob=percentage)

        ], image)
        dataset_dict["image"] = torch.as_tensor(image.transpose(2, 0,
1).astype("float32"))
        annos = [
            utils.transform_instance_annotations(obj, transforms,
image.shape[:2])
            for obj in dataset_dict.pop("annotations")
            if obj.get("iscrowd", 0) == 0
        ]
        instances = utils.annotations_to_instances(annos,
image.shape[:2])
        dataset_dict["instances"] =
utils.filter_empty_instances(instances)
        return dataset_dict
```

*Πηγαίος Κώδικας 13.* `Augmentation` *κλάση, AI Application*

Το σύστημα περιλαμβάνει στοχαστικές περιστροφές και αντικατοπτρισμούς που λαμβάνουν υπόψη τη βιολογική σημασία των κατευθύνσεων στους ιστούς,

προσαρμοσμένες αλλαγές φωτεινότητας και αντίθεσης που αντικατοπτρίζουν διαφορετικές συνθήκες φωτισμού μικροσκοπίου, και εξελιγμένους χρωματικός μετασχηματισμούς που προσομοιώνουν διαφορετικές τεχνικές χρώσης και προετοιμασίας δειγμάτων.

Ιδιαίτερη έμφαση δόθηκε στην υλοποίηση τεχνικών mix-up και cut-mix που έχουν προσαρμοστεί για ιστοπαθολογικές εικόνες, λαμβάνοντας υπόψη τη χωρική συνοχή των βιολογικών δομών και την ανάγκη διατήρησης της κλινικής σημασίας των εικόνων. Αυτές οι τεχνικές έχουν αποδειχθεί ιδιαίτερα αποτελεσματικές για τη βελτίωση της γενίκευσης των μοντέλων σε διαφορετικά κλινικά περιβάλλοντα.

**Dynamic Hyperparameter Management**

Η κλάση `Configuration` διαχειρίζεται την αυτόματη φόρτωση και διαχείριση κατάλληλων βαρών από το model zoo του Detectron2, υλοποιώντας εξελιγμένες στρατηγικές transfer learning που έχουν βελτιστοποιηθεί για ιατρικές εικόνες. Η μέθοδος `load_hyperconfigurations()` παρέχει δυναμική προσαρμογή των υπερπαραμέτρων κατά τη διάρκεια της εκπαίδευσης, επιτρέποντας τη λεπτομερή ρύθμιση χωρίς την ανάγκη τροποποίησης κώδικα.

```
@staticmethod
def load_hyperconfigurations(hyperconfigurations, cfg):
    if hyperconfigurations:
        for key, model in hyperconfigurations.items():
            if model.value != "" and model.value is not None:
                changed_value = Library.strToType(model.value)
                if model.parent:
                    cfg[model.parent][model.category][model.name] =
changed_value
                else:
                    cfg[model.category][model.name] = changed_value
```

*Πηγαίος Κώδικας 14. Μέθοδος `load_hyperconfiguration` της κλάσης Configuration, AI Application*

Το σύστημα υποστηρίζει προηγμένες τεχνικές όπως learning rate scheduling, adaptive batch sizing, και gradient clipping που προσαρμόζονται αυτόματα βάσει της προόδου της εκπαίδευσης και των χαρακτηριστικών των δεδομένων. Επιπλέον, υλοποιεί εξελιγμένους μηχανισμούς early stopping που λαμβάνουν υπόψη πολλαπλές μετρικές και μπορούν να προβλέψουν την παύση της βελτίωσης πριν από την πλήρη σύγκλιση.

#### 5.3.2.1. Παρακολούθηση και αξιολόγηση σε πραγματικό χρόνο

Η κλάση EvaluationHook επεκτείνει τη βασική λειτουργικότητα παρακολούθησης του Detectron2 με εξειδικευμένες μετρικές και συστήματα αναφοράς που παρέχουν λεπτομερείς πληροφορίες για την πρόοδο της εκπαίδευσης. Η υλοποίηση περιλαμβάνει πραγματικού χρόνου οπτικοποιήσεις που επιτρέπουν στους ερευνητές να παρακολουθούν την ποιότητα των προβλέψεων καθώς το μοντέλο εκπαιδεύεται.

```
class EvaluationHook:
    path = ""
    configuration = ""
    trainer: CustomTrainer
    training_id: 0
    registry_id: 0
    metrics = []
    name = ""
    epoch = 0

    def __init__(self, metrics, epoch, registry_id, training_id, path,
trainer: CustomTrainer):
        self.trainer = trainer
        self.metrics = metrics
        self.registry_id = registry_id
        self.training_id = training_id
        self.epoch = epoch
        self.name = "model_{:07d}.pth".format(int(epoch))
        self.path = path + "/" + self.name

UploadTrainingWeightsInfoConnection(registry_id=self.registry_id,
path=self.path, training_id=self.training_id,
                                            metrics=metrics,
name=self.name,
                                            epoch=epoch)

    @staticmethod
    def load(trainer: CustomTrainer, registry_id, training_id,
path=""):
        array_attributes = []
        epoch = 0
        for key, value in trainer.storage.latest().items():
            array_attributes.append({key: value[0]})
            if epoch == 0:
                epoch = value[1]
        EvaluationHook(metrics=array_attributes, epoch=epoch,
path=path, trainer=trainer,
                       training_id=training_id,
registry_id=registry_id)
```

*Πηγαίος Κώδικας 15. EvaluationHook κλαση, AI Application*

Το σύστημα συλλέγει και αναλύει πλήθος μετρικών που περιλαμβάνουν την ακρίβεια κατάτμησης ανά τύπο κυττάρου, τη συνολική ποιότητα των παραγόμενων μασκών, την κατανομή των confidence scores, και στατιστικά για τη σύγκλιση του μοντέλου. Αυτές οι πληροφορίες παρουσιάζονται σε πραγματικό χρόνο μέσω διαδραστικών dashboards που επιτρέπουν την άμεση παρέμβαση σε περίπτωση προβλημάτων χωρίς την ανάγκη τροποποίησης του κώδικα.

### 5.3.3. Ενσωμάτωση Επιτάχυνσης μέσω Γραφικών Επεξεργαστών

Η αποτελεσματική αξιοποίηση των γραφικών επεξεργαστών (GPU) αποτελεί κρίσιμο παράγοντα για την επίτευξη αποδεκτών χρόνων εκπαίδευσης και inference στα μοντέλα

βαθιάς μάθησης της πλατφόρμας [131]. Η υλοποίηση υποστηρίζει τόσο εκπαίδευση σε μονό GPU όσο και κατανεμημένη εκπαίδευση σε πολλαπλούς επεξεργαστές, παρέχοντας την απαιτούμενη ευελιξία για διαφορετικές υπολογιστικές υποδομές.

Η κλάση `MachineHardware` υλοποιεί ένα σύστημα αυτόματης ανίχνευσης και διαχείρισης των διαθέσιμων υπολογιστικών πόρων. Το σύστημα αυτό ελέγχει τη διαθεσιμότητα και τις προδιαγραφές των γραφικών καρτών, εκτιμά τη διαθέσιμη μνήμη GPU, και προσαρμόζει αυτόματα τις παραμέτρους εκπαίδευσης για τη βέλτιστη αξιοποίηση των πόρων. Αυτή η αυτοματοποίηση είναι ιδιαίτερα σημαντική για την υποστήριξη ερευνητών και κλινικών που δεν διαθέτουν εξειδικευμένες γνώσεις στη βελτιστοποίηση συστημάτων υψηλής απόδοσης.

Η υλοποίηση περιλαμβάνει εξελιγμένους μηχανισμούς διαχείρισης μνήμης που επιτρέπουν την επεξεργασία μεγάλων εικόνων ακόμη και σε συστήματα με περιορισμένη μνήμη GPU. Η κλάση `DatasetLoader` υλοποιεί τεχνικές όπως gradient checkpointing και dynamic batching για τη μείωση των απαιτήσεων μνήμης χωρίς σημαντική επίδραση στην απόδοση. Επιπλέον, το σύστημα υποστηρίζει την αυτόματη προσαρμογή του μεγέθους των batches βάσει των διαθέσιμων πόρων, εξασφαλίζοντας τη σταθερή λειτουργία ακόμη και όταν η διαθεσιμότητα των πόρων μεταβάλλεται δυναμικά.

Για την υποστήριξη κατανεμημένης εκπαίδευσης, η πλατφόρμα ενσωματώνει τα εργαλεία κατανεμημένης επεξεργασίας του PyTorch, επιτρέποντας την αποδοτική κλιμάκωση σε πολλαπλούς κόμβους [132]. Η υλοποίηση διαχειρίζεται αυτόματα τον συγχρονισμό των gradients, τη διανομή των δεδομένων, και την αποφυγή συγκρούσεων κατά την ενημέρωση των παραμέτρων του μοντέλου. Αυτή η δυνατότητα είναι κρίσιμη για την εκπαίδευση μοντέλων υψηλής πολυπλοκότητας σε μεγάλα σύνολα δεδομένων εντός εύλογων χρονικών πλαισίων.

Το σύστημα παρακολούθησης απόδοσης συλλέγει λεπτομερείς μετρικές για τη χρήση GPU, τη ταχύτητα επεξεργασίας, και την αποδοτικότητα της κατανεμημένης εκπαίδευσης. Αυτές οι πληροφορίες χρησιμοποιούνται για την αυτόματη βελτιστοποίηση των παραμέτρων εκπαίδευσης και την πρόβλεψη των απαιτούμενων χρόνων ολοκλήρωσης για διαφορετικές ρυθμίσεις.

### 5.3.4. Διαχείριση Μοντέλων και Αποθήκευση Βαρών Συνδέσεων

Η αποτελεσματική διαχείριση των εκπαιδευμένων μοντέλων και των αρχείων βαρών αποτελεί κρίσιμη πτυχή για τη μακροπρόθεσμη χρηστικότητα και συντηρησιμότητα της πλατφόρμας. Η κλάση `WeightFileModel` υλοποιεί ένα εξελιγμένο σύστημα μεταδεδομένων που συνδέει κάθε αρχείο βαρών με λεπτομερείς πληροφορίες σχετικά με τις συνθήκες εκπαίδευσης, τις επιτευχθείσες μετρικές απόδοσης, και τη συμβατότητα με διαφορετικές εκδόσεις της πλατφόρμας.

Το σύστημα αποθήκευσης έχει σχεδιαστεί για να υποστηρίζει τόσο τοπική όσο και απομακρυσμένη αποθήκευση των μοντέλων, παρέχοντας ευελιξία για διαφορετικές

υποδομές και απαιτήσεις ασφαλείας. Η κλάση `UploadTrainingWeightsInfoConnection` διαχειρίζεται την αυτόματη μεταφόρτωση των εκπαιδευμένων μοντέλων στο κεντρικό σύστημα, συμπεριλαμβανομένων όλων των συναφών μεταδεδομένων και μετρικών απόδοσης. Αυτή η λειτουργικότητα επιτρέπει την κεντρικοποιημένη διαχείριση μοντέλων και τη διευκόλυνση της συνεργασίας μεταξύ διαφορετικών ερευνητικών ομάδων.

Η υλοποίηση περιλαμβάνει εξελιγμένους μηχανισμούς ελέγχου εκδόσεων που παρακολουθούν τις αλλαγές στα μοντέλα και επιτρέπουν την εύκολη επαναφορά σε προηγούμενες εκδόσεις εάν χρειαστεί. Κάθε εκπαιδευμένο μοντέλο συνοδεύεται από ένα λεπτομερές αρχείο καταγραφής που περιλαμβάνει πληροφορίες για τα δεδομένα εκπαίδευσης, τις υπερπαραμέτρους, τη διάρκεια εκπαίδευσης, και τις τελικές μετρικές απόδοσης.

Το σύστημα υποστηρίζει επίσης αυτόματη δημιουργία αναφορών απόδοσης μέσω της κλάσης `ExportHandler`, η οποία παράγει λεπτομερείς αναλύσεις των αποτελεσμάτων εκπαίδευσης σε μορφές που είναι εύκολα κατανοητές από κλινικούς ερευνητές. Αυτές οι αναφορές περιλαμβάνουν οπτικοποιήσεις των καμπυλών εκμάθησης, συγκρίσεις με baseline μοντέλα, και λεπτομερή ανάλυση των σφαλμάτων ανά κλάση αντικειμένων.

### 5.3.5. Υλοποίηση Διαχείρισης Πολλαπλών Αρχείων Βαρών

Μία από τις πιο καινοτόμες πτυχές της υλοποίησης αποτελεί το σύστημα διαχείρισης πολλαπλών αρχείων βαρών που επιτρέπει στην πλατφόρμα να υποστηρίζει ταυτόχρονα διαφορετικά μοντέλα για διαφορετικές κλινικές εφαρμογές. Αυτή η δυνατότητα είναι κρίσιμη για περιβάλλοντα όπου διαφορετικοί τύποι ιστών ή παθολογιών απαιτούν εξειδικευμένα μοντέλα που έχουν εκπαιδευτεί με συγκεκριμένα δεδομένα.

Η κλάση `RegistryModel` υλοποιεί ένα εξελιγμένο σύστημα διαχείρισης που επιτρέπει την οργάνωση δεδομένων και μοντέλων σε ξεχωριστές συλλογές (registries), καθεμία από τις οποίες μπορεί να έχει τις δικές της παραμέτρους, κλάσεις αντικειμένων, και εκπαιδευμένα μοντέλα. Αυτή η προσέγγιση επιτρέπει στους χρήστες να διαχειρίζονται ταυτόχρονα διαφορετικά ερευνητικά έργα χωρίς κίνδυνο επικάλυψης ή σύγχυσης.

Το σύστημα υποστηρίζει την αυτόματη ανίχνευση και φόρτωση των κατάλληλων μοντέλων βάσει του τύπου των εισερχόμενων δεδομένων, χρησιμοποιώντας ευφυείς αλγόριθμους αντιστοίχισης που λαμβάνουν υπόψη τα χαρακτηριστικά των εικόνων, τον τύπο του ιστού, και άλλα σχετικά μεταδεδομένα. Αυτή η λειτουργικότητα μειώνει σημαντικά το φόρτο εργασίας των χρηστών και μειώνει την πιθανότητα λαθών κατά την επιλογή του κατάλληλου μοντέλου.

### 5.3.6. Αυτόματη Διαχείριση Μοντέλων ανά Κλινική Περίπτωση

Η αυτόματη διαχείριση μοντέλων αποτελεί μια σύνθετη διαδικασία που απαιτεί την ενσωμάτωση πολλαπλών συστημάτων και τη συνεχή παρακολούθηση της απόδοσης. Η

κλάση `LoadFromServer` υλοποιεί ένα εξελιγμένο σύστημα που συνδέεται με το Backend σύστημα για την αυτόματη λήψη των κατάλληλων μοντέλων βάσει των χαρακτηριστικών κάθε κλινικής περίπτωσης.

Το σύστημα αναλύει τα μεταδεδομένα των εισερχόμενων εικόνων, συμπεριλαμβανομένων του τύπου ιστού, της μεθόδου χρώσης, της ανάλυσης της εικόνας, και άλλων σχετικών παραμέτρων, για να προσδιορίσει το βέλτιστο μοντέλο για κάθε συγκεκριμένη εφαρμογή. Αυτή η διαδικασία υλοποιείται μέσω μια σειράς ευφυών φίλτρων που εφαρμόζονται διαδοχικά για τη σταδιακή εξειδίκευση της επιλογής μοντέλου.

Η αυτοματοποίηση επεκτείνεται και στη διαχείριση των υπερπαραμέτρων, όπου το σύστημα μπορεί να προσαρμόζει δυναμικά παραμέτρους όπως τα κατώφλια ανίχνευσης, τον αριθμό των αναγνωρίσεων ανά εικόνα, και άλλες ρυθμίσεις βάσει των χαρακτηριστικών του συγκεκριμένου dataset. Αυτή η προσαρμοστικότητα είναι κρίσιμη για τη διασφάλιση βέλτιστων αποτελεσμάτων σε διαφορετικά κλινικά περιβάλλοντα χωρίς την ανάγκη χειροκίνητης παρέμβασης από εξειδικευμένο προσωπικό.

Το σύστημα ελέγχου εκδόσεων υλοποιείται μέσω της κλάσης RunningStatusModel και παρέχει πλήρη ιχνηλασιμότητα για όλες τις αλλαγές και ενημερώσεις των μοντέλων. Κάθε εκπαιδευμένο μοντέλο συνοδεύεται από ένα μοναδικό αναγνωριστικό έκδοσης που συνδέεται με συγκεκριμένα μεταδεδομένα εκπαίδευσης, δημιουργώντας έναν πλήρη γραφικό εξάρτησης που επιτρέπει την ακριβή αναπαραγωγή των αποτελεσμάτων.

Το σύστημα υποστηρίζει επίσης την παρακολούθηση των επιδόσεων διαφορετικών εκδόσεων μοντέλων σε διάρκεια χρόνου, επιτρέποντας την αυτόματη ανίχνευση υποβάθμισης της απόδοσης και την έγκαιρη επαναφορά σε σταθερές εκδόσεις. Αυτή η λειτουργικότητα υλοποιείται μέσω ενός συστήματος συνεχούς παρακολούθησης που συλλέγει μετρικές απόδοσης από κάθε εφαρμογή των μοντέλων και συγκρίνει τα αποτελέσματα με ιστορικά δεδομένα.

Ιδιαίτερη έμφαση δόθηκε στη δημιουργία ενός συστήματος που μπορεί να διαχειρίζεται την παράλληλη εκτέλεση πολλαπλών εκδόσεων μοντέλων για σκοπούς σύγκρισης και A/B testing. Αυτή η δυνατότητα επιτρέπει στους ερευνητές να αξιολογούν την επίδραση διαφορετικών τεχνικών εκπαίδευσης ή παραμέτρων σε πραγματικές κλινικές συνθήκες, παρέχοντας πολύτιμα δεδομένα για τη συνεχή βελτίωση των μοντέλων.

### 5.3.7. Αντιγραφή Ασφαλείας και Αποκατάσταση Συστήματος

Η στρατηγική αντιγραφής ασφαλείας έχει σχεδιαστεί για να εξασφαλίζει την πλήρη αποκατάσταση της λειτουργικότητας σε περίπτωση αποτυχίας οποιουδήποτε συστατικού. Το σύστημα υλοποιεί πολλαπλά επίπεδα προστασίας, από τακτικά snapshots των βαρών μοντέλων μέχρι πλήρη αντίγραφα των δομών δεδομένων και των ρυθμίσεων παραμέτρων.

Η κλάση MachineHardware περιλαμβάνει εξελιγμένους μηχανισμούς παρακολούθησης της υγείας του συστήματος που μπορούν να ανιχνεύουν πρώιμα σημάδια πιθανών αποτυχιών και να ενεργοποιούν αυτόματα διαδικασίες προληπτικής αντιγραφής. Αυτό περιλαμβάνει τη συνεχή παρακολούθηση της θερμοκρασίας GPU, της κατάστασης της μνήμης, και άλλων κρίσιμων παραμέτρων λειτουργίας.

Το σύστημα αποκατάστασης είναι σχεδιασμένο για να μεγιστοποιεί τη συνέχεια της λειτουργίας ακόμη και σε περιπτώσεις σοβαρών αποτυχιών. Υλοποιεί στρατηγικές graceful degradation που επιτρέπουν τη συνέχιση κρίσιμων λειτουργιών με μειωμένη απόδοση όταν δεν είναι δυνατή η πλήρης αποκατάσταση, εξασφαλίζοντας ότι οι κλινικές διαδικασίες δεν θα διακοπούν απότομα.

### 5.3.8. Σύνδεση με το Backend σύστημα και Επικοινωνία Πραγματικού Χρόνου

Η επικοινωνία μεταξύ της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης και της Κεντρικής Μονάδας υλοποιείται μέσω ενός εξελιγμένου συστήματος διασυνδέσεων που εξασφαλίζει την αξιόπιστη και αποδοτική ανταλλαγή δεδομένων. Οι κλάσεις connection υλοποιούν διαφορετικούς τύπους επικοινωνίας, από τη λήψη βασικών δεδομένων μέχρι την αποστολή αποτελεσμάτων και την ενημέρωση κατάστασης.

Η κλάση `GetAllEssentialsConnection` διαχειρίζεται τη συγχρονισμένη λήψη όλων των απαιτούμενων πόρων για την έναρξη μιας νέας εργασίας, συμπεριλαμβανομένων των κλάσεων αντικειμένων, των παραμέτρων ρύθμισης, και των διαθέσιμων μοντέλων. Αυτή η προσέγγιση μειώνει τον αριθμό των επικοινωνιακών rounds και βελτιώνει την απόκριση του συστήματος.

Οι κλάσεις `BeginTestingConnection` και `CompleteTestingConnection` υλοποιούν ένα πρωτόκολλο δηλώσεων που εξασφαλίζει την ορθή καταγραφή του κύκλου ζωής κάθε εργασίας αξιολόγησης. Αυτό είναι κρίσιμο για τη διατήρηση της ακεραιότητας των δεδομένων και την πρόληψη συγκρούσεων κατά την ταυτόχρονη εκτέλεση πολλαπλών εργασιών.

Η κλάση `UpdateTrainingStatusConnection` παρέχει συνεχή ενημέρωση της προόδου εκπαίδευσης, επιτρέποντας στους χρήστες να παρακολουθούν την εξέλιξη μακροχρόνιων εργασιών και να λαμβάνουν έγκαιρες ειδοποιήσεις για την ολοκλήρωση ή πιθανά προβλήματα. Το σύστημα υποστηρίζει εξελιγμένες στρατηγικές retry και fallback για τη διασφάλιση της αξιοπιστίας σε περιβάλλοντα με ασταθή δικτυακή συνδεσιμότητα.

### 5.3.9. Συστήματα Μετρικών και Αξιολόγησης

Η αξιολόγηση της απόδοσης των μοντέλων υλοποιείται μέσω ενός εξελιγμένου συστήματος που συνδυάζει παραδοσιακές μετρικές computer vision με εξειδικευμένες μετρικές για ιστοπαθολογικές εφαρμογές. Η κλάση `ConfusionMatrix` υλοποιεί

προηγμένους αλγόριθμους για τον υπολογισμό και την οπτικοποίηση πινάκων σύγχυσης που λαμβάνουν υπόψη τη χωρική διάταξη των αντικειμένων και την ποιότητα των μασκών κατάτμησης.

Η κλάση `CollectMetricsAnnotations` διαχειρίζεται τη συλλογή και συσχέτιση των αποτελεσμάτων πρόβλεψης με τα ground truth annotations, υλοποιώντας εξελιγμένες τεχνικές που μπορούν να χειρίζονται ανακρίβειες στις χειροκίνητες σημειώσεις και να παρέχουν ρεαλιστικές εκτιμήσεις της απόδοσης των μοντέλων. Αυτό περιλαμβάνει τη χρήση προηγμένων αλγόριθμων matching που λαμβάνουν υπόψη τόσο τη γεωμετρική επικάλυψη όσο και τη σημασιολογική συμφωνία.

Το σύστημα παράγει λεπτομερείς αναφορές που περιλαμβάνουν στατιστικές αναλύσεις ανά κλάση αντικειμένων, συγκρίσεις με baseline μεθόδους, και εκτιμήσεις της αβεβαιότητας των προβλέψεων. Αυτές οι αναφορές σχεδιάζονται για να είναι άμεσα χρησιμοποιήσιμες από κλινικούς ερευνητές χωρίς εξειδικευμένες γνώσεις στη μηχανική μάθηση.

```
class CollectMetricsAnnotations:
    image_model_testing = None
    image_model_training = None
    image_path = None
    classification_maps = {}
    def __init__(self, image_model_testing: ImageModel,
image_model_training: ImageModel, image_path: str,
                 registry_id: str, classifications_map: dict):
        self.image_model_testing = image_model_testing
        self.image_model_training = image_model_training
        self.image_path = image_path
        self.classification_maps={}
        self.classification_maps = classifications_map

    def get_classification_id(self, classification_id):
        for index, classification in self.classification_maps.items():
            if classification_id == classification.id:
                return index

    def collect_confusion_metrics(self):

        image = skimage.io.imread(self.image_path)
        h, w, c = image.shape
        class_training = []
        masks_training = np.zeros([h, w, 1])
        # len(image_model_training.shapes)])
        class_testing = []
        masks_testing = np.zeros([h, w, 1])
        # len(image_model.shapes)])
        # testing masks
        for i, shape in enumerate(self.image_model_testing.shapes):
            rr, cc = shape.get_mask_by_shape_type()
            class_id = self.get_classification_id(shape.class_id) + 1
            class_testing.append(class_id)
            masks_testing[rr, cc, 0] = class_id

        # training masks
        for i, shape in enumerate(self.image_model_training.shapes):
            rr, cc = shape.get_mask_by_shape_type()
            class_id = self.get_classification_id(shape.class_id) + 1
            class_training.append(class_id)
            masks_training[rr, cc, 0] = class_id
        ConfusionMatrix(self.image_model_training, masks_training,
class_training, self.image_model_testing,
                        masks_testing,
                        class_testing,
                        self.classification_maps)
```

*Πηγαίος Κώδικας 16. `CollectMetricsAnnotations` κλαση για την συλλογη confusion matrix, AI Application*

### 5.3.10. Βελτιστοποίηση Απόδοσης και Παρακολούθηση Συστήματος

Η βελτιστοποίηση της απόδοσης αποτελεί συνεχή διαδικασία που περιλαμβάνει τόσο στατικές βελτιστοποιήσεις κατά τη φάση του σχεδιασμού όσο και δυναμικές προσαρμογές κατά τη διάρκεια της εκτέλεσης. Το σύστημα παρακολούθησης συλλέγει

λεπτομερείς μετρικές για κάθε στάδιο της διαδικασίας επεξεργασίας, από τη φόρτωση των δεδομένων μέχρι την παραγωγή των τελικών αποτελεσμάτων.

Η κλάση που διαχειρίζεται την αυτόματη βελτιστοποίηση υλοποιεί αλγόριθμους που μπορούν να προσαρμόζουν δυναμικά παραμέτρους όπως το μέγεθος των batches, τη συχνότητα της συλλογής σκουπιδιών, και τις στρατηγικές προσωρινής αποθήκευσης βάσει των πραγματικών συνθηκών φορτίου. Αυτές οι προσαρμογές γίνονται διαφανώς και δεν επηρεάζουν τη λειτουργικότητα ή την ακρίβεια των αποτελεσμάτων.

Το σύστημα υποστηρίζει επίσης προηγμένες τεχνικές profiling που επιτρέπουν την αναγνώριση bottlenecks και την εστιασμένη βελτιστοποίηση των πιο κρίσιμων τμημάτων του κώδικα. Αυτό περιλαμβάνει τη χρήση εξειδικευμένων εργαλείων για την ανάλυση της χρήσης GPU, την παρακολούθηση της κίνησης δεδομένων μεταξύ CPU και GPU, και τη μέτρηση των χρόνων αναμονής σε κρίσιμα σημεία συγχρονισμού.

Η ολοκληρωμένη υλοποίηση της Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης, όπως παρουσιάστηκε σε αυτή την ενότητα, αποτελεί τη βάση για την παροχή προηγμένων δυνατοτήτων ανάλυσης στην πλατφόρμα Deep-in-Biopsies. Η συνδυασμένη χρήση σύγχρονων τεχνολογιών, εξειδικευμένων βελτιστοποιήσεων για ιστοπαθολογικές εφαρμογές, και ευέλικτων αρχιτεκτονικών παρέχει ένα ισχυρό εργαλείο που μπορεί να υποστηρίξει τόσο ερευνητικές όσο και κλινικές δραστηριότητες υψηλής ποιότητας.

## 5.4. Ενσωμάτωση Κεντρικής Μονάδας με Μονάδα Τεχνητής Νοημοσύνης

#### 5.4.1.1. Υλοποίηση Επικοινωνίας σε Πραγματικό Χρόνο

Η ενσωμάτωση της Κεντρικής Μονάδας με τη Μονάδα Τεχνητής Νοημοσύνης αποτελεί την καρδιά της πλατφόρμας Deep-in-Biopsies, καθώς εξασφαλίζει την απρόσκοπτη επικοινωνία μεταξύ του διαδικτυακού περιβάλλοντος διαχείρισης και του εξειδικευμένου περιβάλλοντος βαθιάς μάθησης. Η αρχιτεκτονική επικοινωνίας που αναπτύχθηκε βασίζεται σε μια εξελιγμένη προσέγγιση που συνδυάζει REST APIs για την αρχική διαπραγμάτευση και Socket.IO για την επικοινωνία σε πραγματικό χρόνο.

Το σύστημα επικοινωνίας υλοποιείται μέσω μιας σειράς εξειδικευμένων κλάσεων σύνδεσης που αναλαμβάνουν διαφορετικές πτυχές της αλληλεπίδρασης. Χρειάζεστε την κλάση `UrlConnection` (Πηγαίος Κώδικας 17) ως βάση για όλες τις επικοινωνιακές λειτουργίες, η οποία παρέχει την αφαιρετική διεπαφή για τη διαχείριση HTTP αιτημάτων, την επαλήθευση συνδέσεων και τον χειρισμό σφαλμάτων δικτύου.

Για την αρχική διαμόρφωση και συγχρονισμό, απαιτείται η `GetAllEssentialsConnection` που διαχειρίζεται τη λήψη όλων των βασικών πληροφοριών από το Backend σύστημα, συμπεριλαμβανομένων των ρυθμίσεων καταχώρησης, των διαθέσιμων κατηγοριών κατάτμησης και των παραμέτρων

εκπαίδευσης (2). Αυτή η κλάση εξασφαλίζει ότι η μονάδα τεχνητής νοημοσύνης διαθέτει όλες τις απαραίτητες πληροφορίες πριν από την έναρξη οποιασδήποτε εργασίας.

```
class UrlConnection:
    mainController = "ai/"
    # domainUrl = "http://localhost:8888/index.php?r=api/v1/"
    domainUrl = "http://127.0.0.1:8000/api/"
    data = None
    succeed = False
    json_data = None
    raw_data = None

    def __init__(self, url_appender: str = "get-url-attributes"):
        self.url_appender = url_appender
        self.url = self.domainUrl + self.mainController +
self.url_appender

    def start(self):
        headers = {"Authorization": "Bearer " + self.token}
        if self.method == "GET":
            self.response = requests.get(self.url, verify=False,
                                         headers=headers,
params=self.data)
        else:
            self.response = requests.post(self.url, verify=False,
headers=headers, json=self.data)
        json_data = None
        try:

            self.raw_data = json_data = self.response.json()

        except Exception as e:
            print(e)
            return self.error( self.response)

        if "error" in json_data:
            return self.error(json_data["error"])

        if "success" in json_data:
            return self.success_parent(json_data["success"])
        return self.error("error parsing" + json_data)
```

*Πηγαίος Κώδικας 17. Μητρική κλάση `UrlConnection`, AI Application*

#### 5.4.1.2. Διαχείριση Δεδομένων Εκπαίδευσης

Η μεταφορά δεδομένων εκπαίδευσης αποτελεί ένα από τα πιο κρίσιμα σημεία της ενσωμάτωσης, δεδομένου του μεγάλου όγκου των ιστοπαθολογικών εικόνων και της πολυπλοκότητας των σημειώσεων (3). Για τη διαχείριση αυτής της διαδικασίας, χρειάζεστε την κλάση `GetDatasetConnection` που υλοποιεί βελτιστοποιημένους αλγόριθμους μεταφοράς δεδομένων με υποστήριξη για επανάληψη σε περίπτωση διακοπής και παραλληλισμό για μείωση των χρόνων μεταφοράς.

Η κλάση `GetTestingDatasetConnection` εξειδικεύεται στη διαχείριση των δεδομένων αξιολόγησης, εξασφαλίζοντας ότι τα σύνολα δοκιμών διατηρούν την ακεραιότητά τους και παραμένουν ανεξάρτητα από τα δεδομένα εκπαίδευσης κατά τη διάρκεια όλης της διαδικασίας. Αυτή η διαχωριστική προσέγγιση είναι θεμελιώδης για τη διασφάλιση της αξιοπιστίας των αποτελεσμάτων αξιολόγησης.

#### 5.4.1.3. Σύστημα Παρακολούθησης Προόδου

Η παρακολούθηση της προόδου των εργασιών εκπαίδευσης και αξιολόγησης υλοποιείται μέσω ενός εξελιγμένου συστήματος που παρέχει λεπτομερείς πληροφορίες σε πραγματικό χρόνο. Χρειάζεστε την κλάση `UpdateTrainingStatusConnection` για την αποστολή περιοδικών ενημερώσεων σχετικά με την πρόοδο της εκπαίδευσης, συμπεριλαμβανομένων μετρικών απόδοσης, εκτιμήσεων χρόνου ολοκλήρωσης και πιθανών προειδοποιήσεων.

Η κλάση `UploadTrainingWeightsInfoConnection` διαχειρίζεται τη μεταφορά πληροφοριών σχετικά με τα εκπαιδευμένα μοντέλα, συμπεριλαμβανομένων των μετρικών απόδοσης κάθε εποχής, των διαδρομών των αρχείων βαρών και των παραμέτρων εκπαίδευσης που χρησιμοποιήθηκαν. Αυτές οι πληροφορίες είναι ζωτικής σημασίας για τη διατήρηση ενός ολοκληρωμένου αρχείου εκπαίδευσης και την υποστήριξη αποφάσεων βελτιστοποίησης.

### 5.4.2. Συγχρονισμός Δεδομένων σε Πραγματικό Χρόνο

Ο συγχρονισμός δεδομένων μεταξύ των δύο μονάδων αποτελεί πολύπλοκη πρόκληση που απαιτεί προσεκτικό χειρισμό των κρίσιμων σημείων συγχρονισμού και εξασφάλιση της συνοχής των δεδομένων. Η προσέγγιση που υιοθετήθηκε βασίζεται σε ένα υβριδικό μοντέλο που συνδυάζει συγχρονή επικοινωνία για κρίσιμες λειτουργίες και ασύγχρονη επικοινωνία για μεταφορά δεδομένων μεγάλου όγκου.

#### 5.4.2.1. Διαχείριση Σταδίων Εκπαίδευσης

Η διαχείριση των διαφορετικών σταδίων εκπαίδευσης απαιτεί ακριβή συγχρονισμό μεταξύ των δύο μονάδων για να εξασφαλιστεί η σωστή αλληλουχία των γεγονότων. Χρειάζεστε την κλάση `BeginTestingConnection` για τη σηματοδότηση της έναρξης μιας νέας φάσης αξιολόγησης, η οποία ενεργοποιεί τους αντίστοιχους μηχανισμούς παρακολούθησης του Backend συστήματος και προετοιμάζει τις απαραίτητες δομές δεδομένων.

Αντίστοιχα, η κλάση `CompleteTestingConnection` διαχειρίζεται την ολοκλήρωση των εργασιών αξιολόγησης, εξασφαλίζοντας ότι όλα τα αποτελέσματα έχουν μεταφερθεί επιτυχώς και ότι οι πόροι έχουν απελευθερωθεί σωστά. Αυτή η συγχρονισμένη προσέγγιση είναι κρίσιμη για την αποφυγή καταστάσεων αμφιβολίας και τη διατήρηση της αξιοπιστίας του συστήματος.

#### 5.4.2.2. Μεταφορά Αποτελεσμάτων Ανίχνευσης

Η μεταφορά των αποτελεσμάτων ανίχνευσης από τη μονάδα τεχνητής νοημοσύνης προς το Backend σύστημα αποτελεί μια από τις πιο σύνθετες πτυχές της ενσωμάτωσης. Χρειάζεστε την κλάση `UploadMasksForMultipleImagesConnection` για τη διαχείριση της μεταφοράς μασκών κατάτμησης, πολυγώνων και σχετικών μεταδεδομένων για μεγάλα σύνολα εικόνων.

Αυτή η κλάση υλοποιεί εξελιγμένους αλγόριθμους συμπίεσης και παραλληλισμού για τη βελτιστοποίηση των χρόνων μεταφοράς, ενώ ταυτόχρονα διατηρεί την ακρίβεια των γεωμετρικών πληροφοριών που είναι κρίσιμες για τις κλινικές εφαρμογές.

### 5.4.3. Διαχείριση Ασύγχρονων Εργασιών Επεξεργασίας

Η φύση των εργασιών βαθιάς μάθησης, που μπορεί να διαρκούν από ώρες έως ημέρες, απαιτεί ένα ισχυρό σύστημα διαχείρισης ασύγχρονων διεργασιών που να εξασφαλίζει την αποδοτική χρήση των υπολογιστικών πόρων και την ανθεκτικότητα σε αποτυχίες. Το σύστημα που αναπτύχθηκε βασίζεται σε μια αρχιτεκτονική πολλαπλών νημάτων που επιτρέπει την ταυτόχρονη εκτέλεση διαφορετικών τύπων εργασιών.

#### 5.4.3.1. Αυτοματοποιημένη Διαχείριση Νημάτων

Για την αυτοματοποίηση της διαχείρισης εργασιών, χρειάζεστε τις κλάσεις `RunApplicationThreadTraining` και `RunApplicationThreadTesting` που υλοποιούν έξυπνους αλγόριθμους προγραμματισμού εργασιών. Η πρώτη κλάση εξειδικεύεται στη διαχείριση εργασιών εκπαίδευσης, παρακολουθώντας συνεχώς την ουρά εργασιών και ενεργοποιώντας νέες διεργασίες εκπαίδευσης όταν είναι διαθέσιμοι οι απαραίτητοι πόροι.

Η κλάση `RunApplicationThreadTesting` διαχειρίζεται τις εργασίες αξιολόγησης και εφαρμογής των εκπαιδευμένων μοντέλων, εξασφαλίζοντας ότι οι διαθέσιμοι υπολογιστικοί πόροι χρησιμοποιούνται βέλτιστα και ότι οι χρήστες λαμβάνουν έγκαιρη ανατροφοδότηση για την πρόοδο των εργασιών τους (10).

#### 5.4.3.2. Σύστημα Παρακολούθησης Υγείας Συστήματος

Η διασφάλιση της συνεχούς λειτουργίας του συστήματος υλοποιείται μέσω της κλάσης `KeepConnectionAlive` που διαχειρίζεται την περιοδική επαλήθευση της υγείας της σύνδεσης μεταξύ των μονάδων. Αυτή η κλάση εφαρμόζει εξελιγμένους αλγόριθμους ανίχνευσης σφαλμάτων και αυτόματης αποκατάστασης που μπορούν να αντιμετωπίσουν προσωρινές διακοπές δικτύου χωρίς να επηρεάσουν τις εργασίες που εκτελούνται.

Επιπλέον, η κλάση `MachinePingConnection` παρέχει λεπτομερείς πληροφορίες σχετικά με την κατάσταση των υπολογιστικών πόρων, συμπεριλαμβανομένων της χρήσης GPU, της κατανάλωσης μνήμης και της θερμοκρασίας του συστήματος. Αυτές οι

πληροφορίες είναι κρίσιμες για τη λήψη προληπτικών μέτρων και την αποφυγή αποτυχιών λόγω υπερθέρμανσης ή εξάντλησης πόρων.

```
class KeepConnectionAlive(Thread):
    attributes = None
    machine = None

    def __init__(self):
        Thread.__init__(self, daemon=True)
        self.running = True
        self.machine = MachineHardware()
        self.machine.init()
        self.attributes=self.machine.getAttributes()
        self.start()

    def run(self):
        while self.running:
            print("sending Ping")
            MachinePingConnection(self.attributes)
            time.sleep(2*60)

    def stop(self):
        self.running = False
```

*Πηγαίος Κώδικας 18. `KeepConnectionAlive` κλάση, AI Application*

### 5.4.4. Συστήματα Χειρισμού Σφαλμάτων και Καταγραφής

Η ανθεκτικότητα του συστήματος εξαρτάται σε μεγάλο βαθμό από την αποτελεσματικότητα των μηχανισμών χειρισμού σφαλμάτων και καταγραφής γεγονότων. Το σύστημα που αναπτύχθηκε υλοποιεί μια πολυεπίπεδη στρατηγική που καλύπτει από απλά σφάλματα δικτύου μέχρι σοβαρές αποτυχίες υλικού.

Κάθε κλάση σύνδεσης υλοποιεί εξειδικευμένους μηχανισμούς χειρισμού σφαλμάτων που αντιστοιχούν στη φύση των λειτουργιών που διαχειρίζεται. Οι κλάσεις επικοινωνίας παρέχουν τυποποιημένες μεθόδους `success()` και `error()` που επιτρέπουν την ομοιόμορφη διαχείριση επιτυχών και αποτυχημένων λειτουργιών σε όλο το φάσμα του συστήματος. Η κλάση `GetUserConnection` εξειδικεύεται στη διαχείριση σφαλμάτων που σχετίζονται με την πιστοποίηση και εξουσιοδότηση, εφαρμόζοντας στρατηγικές που εξισορροπούν μεταξύ ασφάλειας και χρηστικότητας. Σε περίπτωση αποτυχίας πιστοποίησης, το σύστημα παρέχει σαφή μηνύματα σφάλματος στον χρήστη ενώ ταυτόχρονα καταγράφει λεπτομερείς πληροφορίες για σκοπούς ασφάλειας (13).

Η καταγραφή γεγονότων υλοποιείται σε πολλαπλά επίπεδα, από τη βασική καταγραφή αιτημάτων HTTP μέχρι τη λεπτομερή καταγραφή των παραμέτρων εκπαίδευσης και των μετρικών απόδοσης. Για τη διαχείριση μετρικών και στατιστικών, χρειάζεστε την κλάση

`GetMetricsAnnotationsConnection` που συλλέγει και συγκεντρώνει δεδομένα απόδοσης από όλες τις πτυχές του συστήματος. Αυτό το ολοκληρωμένο σύστημα καταγραφής επιτρέπει την εις βάθος ανάλυση της απόδοσης του συστήματος, την εύρεση προτύπων χρήσης και τον εντοπισμό πιθανών σημείων βελτίωσης. Τα δεδομένα καταγραφής χρησιμοποιούνται επίσης για τη δημιουργία λεπτομερών αναφορών που υποστηρίζουν τη λήψη αποφάσεων για μελλοντικές βελτιώσεις και επεκτάσεις του συστήματος (14).

## 5.5. Ροή Εργασίας Χρήστη και Βελτιστοποίηση Απόδοσης

Το κεφάλαιο αυτό παρουσιάζει την υλοποίηση της ολοκληρωμένης ροής εργασίας χρήστη της πλατφόρμας Deep-in-Biopsies όπως αυτή έχει πραγματικά υλοποιηθεί για τους διαφορετικούς ρόλους χρηστών: παθολογοανατόμο, ερευνητή, ειδικό ιατρό και διαχειριστή συστήματος. Η σχεδίαση της ροής εργασίας ακολουθεί τις καθιερωμένες πρακτικές της ψηφιακής παθολογίας και αξιοποιεί πλήρως τις δυνατότητες της τεχνητής νοημοσύνης για την ενίσχυση της διαγνωστικής διαδικασίας.

Η υλοποίηση της ροής εργασίας ξεκινά με ένα ισχυρό σύστημα αυθεντικοποίησης που υποστηρίζει πολλαπλούς ρόλους χρηστών. Το σύστημα εφαρμόζει session-based authentication με αυτόματη ανανέωση για την εξασφάλιση της ασφάλειας και της συνέχειας της εργασίας.

Η παρακάτω διαδικασία αφορά όλους τους χρήστες στην πλατφόρμα και οι ενέργειες είναι οι έξεις:

1. Έλεγχος Υπάρχουσας Σύνδεσης: Το σύστημα αρχικά ελέγχει αν ο χρήστης έχει αυθεντικοποιηθεί σε προηγούμενη συνεδρία
2. Αυτόματη Είσοδος: Σε περίπτωση έγκυρης συνεδρίας, γίνεται αυτόματη αναζήτηση στοιχείων, ανανέωση Session και μεταφορά στη βασική σελίδα
3. Χειροκίνητη Αυθεντικοποίηση: Εάν δεν υπάρχει έγκυρη συνεδρία, ο χρήστης εισάγει τα στοιχεία του στη φόρμα αυθεντικοποίησης
4. Επικύρωση Στοιχείων: Η διεπαφή εκτελεί επικύρωση των στοιχείων με κατάλληλα μηνύματα σφάλματος σε περίπτωση αποτυχίας
5. Έλεγχος Βάσης Δεδομένων: Τελική επικύρωση στη βάση δεδομένων και δημιουργία Session για επιτυχή είσοδο

#### 5.5.1.1. Ροή Εργασίας Παθολογοανατόμου

Ο παθολογοανατόμος αποτελεί τον κύριο χρήστη της πλατφόρμας και εκτελεί το μεγαλύτερο φάσμα λειτουργιών (Διάγραμμα 8).

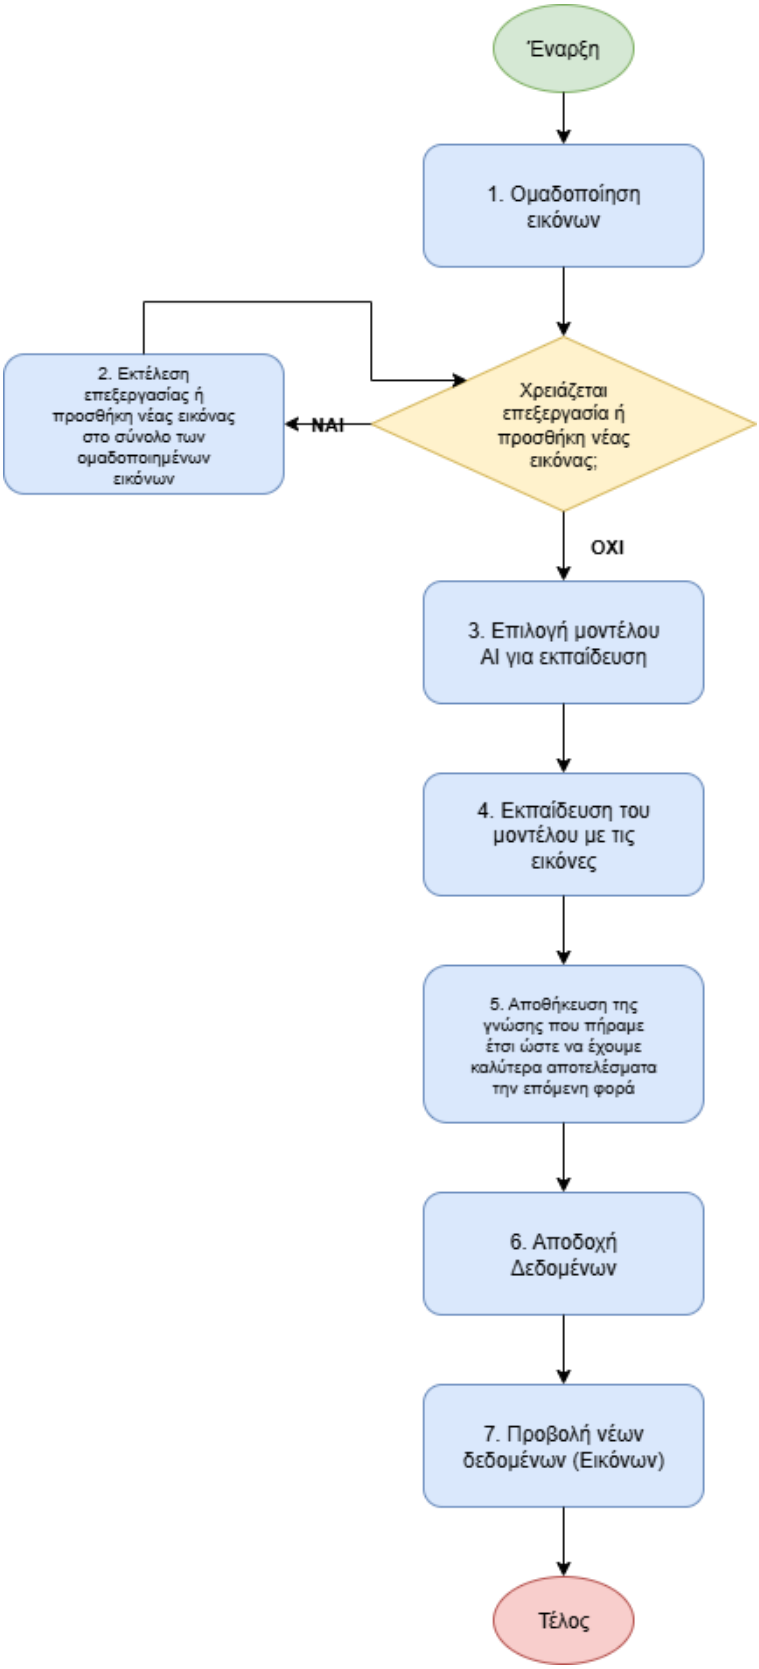


*Διάγραμμα 8. Διάγραμμα ροής παθολογοανατόμου για τη εκπαίδευση του Νευρωνικου Δικτύου, AI Application.*

Η υλοποιημένη ροή εργασίας του περιλαμβάνει:

Βασικές Λειτουργίες:

1. Ομαδοποίηση Εικόνων: Δημιουργία συνόλων εικόνων για συγκεκριμένα ιατρικά προβλήματα
2. Επεξεργασία Εικόνων: Προσθήκη νέων εικόνων στο σύνολο των ομαδοποιημένων εικόνων όταν απαιτείται
3. Επιλογή Μοντέλου TN: Επιλογή κατάλληλου μοντέλου τεχνητής νοημοσύνης για εκπαίδευση
4. Εκπαίδευση Μοντέλου: Εκτέλεση εκπαίδευσης του μοντέλου με τις επιλεγμένες εικόνες
5. Αποθήκευση Γνώσης: Διατήρηση των εκπαιδευμένων μοντέλων για μελλοντική χρήση
6. Αποδοχή Δεδομένων: Επικύρωση των αποτελεσμάτων της τεχνητής νοημοσύνης
7. Προβολή Νέων Δεδομένων: Οπτικοποίηση νέων εικόνων και αποτελεσμάτων

Προηγμένες Λειτουργίες Παθολογοανατόμου:

- Δημιουργία Ιατρικών Προβλημάτων: Καταχώρηση νέων ιατρικών προβλημάτων και κατηγοριοποίηση ευρημάτων
- Επισημείωση Ευρημάτων: Ακριβής επισημείωση ευρημάτων στις κατηγορίες που έχουν οριστεί για κάθε πρόβλημα
- Διαχείριση Ευρημάτων: Λίστα ευρημάτων με δυνατότητα επεξεργασίας, διαγραφής και αλλαγής κατηγορίας
- Dashboard Στατιστικών: Πρόσβαση σε διαγράμματα περιγραφικών στατιστικών των εικόνων και ευρημάτων

#### 5.5.1.2. Ροή Εργασίας Ερευνητή

Η υλοποιημένη ροή εργασίας του ερευνητή εστιάζει στην επιστημονική έρευνα και τη βελτιστοποίηση μοντέλων:

Κύριες Διαδικασίες:

- Εισαγωγή Εικόνων: Προσθήκη νέων εικόνων στα πεδία των ιατρικών προβλημάτων
- Ομαδοποίηση και Επεξεργασία: Οργάνωση εικόνων με σκοπό την εκπαίδευση μοντέλων TN
- Επιλογή Μοντέλου TN: Επιλογή μοντέλου που θα εκπαιδευτεί με τις εικόνες από τον παθολογοανατόμο
- Οπτικοποίηση Αποτελεσμάτων: Προβολή εικόνων μετά την επεξεργασία από το μοντέλο

Εξειδικευμένες Λειτουργίες:

- Δημιουργία Συνόλων Δεδομένων: Επιλογή εικόνων για σύνολα εκπαίδευσης, επικύρωσης και ελέγχου
- Επιλογή Αρχιτεκτονικής: Καθορισμός αρχιτεκτονικής μοντέλου και υπερπαραμέτρων
- Ανάλυση Απόδοσης: Διαγράμματα εκπαίδευσης για εντοπισμό υπερεκπαίδευσης
- Μετρικές Αξιολόγησης: Επιλογή διαφορετικών μετρικών για ταξινόμηση και αξιολόγηση

#### 5.5.1.3. Ροή Εργασίας Ειδικού Ιατρού

Ο ειδικός ιατρός χρησιμοποιεί την πλατφόρμα κυρίως για διαγνωστικούς σκοπούς με απλουστευμένη διεπαφή:

Κύριες Λειτουργίες:

- Οπτικοποίηση Αποτελεσμάτων: Προβολή εικόνων μετά την επεξεργασία από το μοντέλο TN
- Ποσοτικοποίηση Ευρημάτων: Υπολογισμός εμβαδού ευρημάτων ανά κατηγορία σε σχέση με το συνολικό εμβαδόν ιστού

### 5.5.2. Βελτιστοποίηση Απόδοσης Συνολικού Συστήματος

Διαχείριση Ρόλων και Δικαιωμάτων

Το σύστημα υλοποιεί προηγμένη διαχείριση ρόλων με τέσσερις κύριους ρόλους χρηστών που έχουν διαφορετικά επίπεδα πρόσβασης:

Ιεραρχία Ρόλων:

1. Διαχειριστής (Admin): Πλήρης πρόσβαση σε όλες τις λειτουργίες του συστήματος
2. Παθολογοανατόμος: Εκτεταμένες δυνατότητες επισημείωσης και εκπαίδευσης μοντέλων
3. Ερευνητής: Εστίαση σε ερευνητικές λειτουργίες και ανάλυση δεδομένων
4. Ειδικός Ιατρός: Περιορισμένη πρόσβαση σε διαγνωστικές λειτουργίες

**Υλοποίηση με Spatie Laravel Permission:**

Το σύστημα διαχείρισης ρόλων και δικαιωμάτων υλοποιήθηκε χρησιμοποιώντας το πακέτο Spatie Laravel Permission, το οποίο παρέχει ευέλικτη και αξιόπιστη διαχείριση πρόσβασης:

```
class RolesAndPermissionsSeeder extends Seeder
{
    /**
     * Run the database seeds.
     */
    public function run(): void
    {
        // Reset cached roles and permissions
        app()[\Spatie\Permission\PermissionRegistrar::class]-
>forgetCachedPermissions();
        $permissions = [
            // Dashboard permissions
            'view dashboard',
            // Classification permissions
            'view classifications',
            'create classifications',
            'edit classifications',
            'delete classifications',
            // Registry permissions
            'view registries',
            'access registry dashboard',
            'change registry',
            'view registry images',
            // Registry Classification permissions
            'view registry classifications',
            'create registry classifications',
            'edit registry classifications',
            'delete registry classifications',
            // Training permissions
            'view training',
            'create training',
            'edit training',
            'delete training',
            'configure training',
            // Quantification/Testing permissions
            'view quantification',
            'create quantification',
            'edit quantification',
            'delete quantification',
            'configure quantification'
```

*Πηγαίος Κώδικας 19. Database Seeder για τα δικαιώματα χρηστών της πλατφόρμας Deep-in-Biopsies*

```
Route::middleware('auth')->group(function () {

    Route::resource('/classifications',
\App\Http\Controllers\Auth\ClassificationController::class, ["names"
=> "classifications"]);
    Route::get('/queue',
[App\Http\Controllers\Auth\QueueController::class, "index"])-
>name("queue");
})
```

*Πηγαίος Κώδικας 20. Παράδειγμα Middleware για την εγγραφή των διάδρομων του Deep-in-Biopsies.*

#### 5.5.2.1. Επεξεργασία Δεδομένων και Μοντέλων

Η πλατφόρμα υποστηρίζει πολλαπλά είδη επεξεργασίας που βελτιστοποιούν την απόδοση ανάλογα με τις ανάγκες του χρήστη:

Τύποι Επεξεργασίας:

- Δημιουργία Συνόλων Εκπαίδευσης: Επιλογή και οργάνωση εικόνων για εκπαίδευση μοντέλων
- Εκπαίδευση Μοντέλων TN: Αυτοματοποιημένη εκπαίδευση με παρακολούθηση προόδου
- Αξιολόγηση Απόδοσης: Χρήση συνόλων επικύρωσης και ελέγχου για μέτρηση ακρίβειας
- Εφαρμογή Μοντέλων: Αυτόματη ανάλυση νέων εικόνων με εκπαιδευμένα μοντέλα

### 5.5.3. Στρατηγικές Προσωρινής Αποθήκευσης και Βελτιστοποίησης

#### 5.5.3.1. Διαχείριση Registry και Ιατρικών Προβλημάτων

Το σύστημα υλοποιεί ιεραρχική δομή δεδομένων που επιτρέπει την αποδοτική οργάνωση της ιατρικής πληροφορίας:

Δομή Δεδομένων:

1. Registry: Υψηλότερη οντότητα που αφορά το ιατρικό πεδίο και το ανθρώπινο όργανο
2. Ιατρικό Πρόβλημα: Δημιουργείται από παθολογοανατόμο ή ειδικό ιατρό κάτω από συγκεκριμένο registry
3. Κατηγορίες Ευρημάτων: Επιμέρους κατηγοριοποίηση εντός κάθε ιατρικού προβλήματος
4. Εικόνες και Επισημειώσεις: Συνδεδεμένες με συγκεκριμένες κατηγορίες ευρημάτων

#### 5.5.3.2. Βελτιστοποίηση Διεπαφής Χρήστη

Η υλοποίηση περιλαμβάνει εξειδικευμένα dashboard για κάθε ρόλο χρήστη που βελτιστοποιούν την εμπειρία εργασίας:

Dashboard Διαχειριστή:

- Διαγράμματα περιγραφικών στατιστικών όλων των χρηστών
- Όψη εικόνων ανά χρήστη
- Συνολική χρήση πλατφόρμας

Dashboard Παθολογοανατόμου/Ερευνητή:

- Προσωπικά στατιστικά εικόνων και ευρημάτων
- Πρόοδος επισημείωσης
- Αποτελέσματα εκπαιδεύσεων

### 5.5.4. Πλαίσιο Ποιοτικού Ελέγχου και Αυτοματοποιημένων Δοκιμών

Το σύστημα εφαρμόζει αυστηρούς ελέγχους ποιότητας σε κάθε στάδιο της ροής εργασίας για την εξασφάλιση της αξιοπιστίας των αποτελεσμάτων:

Έλεγχοι Ποιότητας:

- Επικύρωση Εικόνων: Αυτόματος έλεγχος μορφής και ποιότητας εικόνων κατά την εισαγωγή
- Έλεγχος Επισημειώσεων: Επιβεβαίωση της ακρίβειας και πληρότητας των σημειώσεων
- Αξιολόγηση Μοντέλων: Συνεχής παρακολούθηση της απόδοσης των εκπαιδευμένων μοντέλων
- Ελέγχου Συνοχής: Διασφάλιση της συνοχής δεδομένων σε όλα τα επίπεδα του συστήματος

Η ολοκληρωμένη υλοποίηση της ροής εργασίας χρήστη που παρουσιάστηκε σε αυτό το υποκεφάλαιο αποτελεί το αποτέλεσμα εκτενούς ανάλυσης των κλινικών αναγκών και προσεκτικού σχεδιασμού που εξασφαλίζει τη φυσική και αποδοτική αλληλεπίδραση μεταξύ των διαφορετικών ρόλων χρηστών και των δυνατοτήτων της πλατφόρμας Deep-in-Biopsies.

## 5.6. Πλαίσιο Ποιοτικού Ελέγχου και Δοκιμών

Η ανάπτυξη ενός αξιόπιστου και ασφαλούς συστήματος για ιστοπαθολογικές εφαρμογές απαιτεί την υλοποίηση ενός ολοκληρωμένου πλαισίου ποιοτικού ελέγχου που διασφαλίζει την ορθή λειτουργία όλων των συστατικών της πλατφόρμας Deep-in-Biopsies. Το κεφάλαιο αυτό παρουσιάζει τις στρατηγικές, μεθοδολογίες και εργαλεία που αναπτύχθηκαν για την επίτευξη των υψηλότερων προτύπων ποιότητας που απαιτούνται στον ιατρικό τομέα.

Η φιλοσοφία του ποιοτικού ελέγχου που υιοθετήθηκε βασίζεται στην αρχή της πολυεπίπεδης προστασίας, όπου κάθε συστατικό της πλατφόρμας υπόκειται σε πολλαπλούς ελέγχους και επικυρώσεις σε διαφορετικά στάδια της ανάπτυξης και λειτουργίας. Αυτή η προσέγγιση εξασφαλίζει ότι τυχόν σφάλματα ή προβλήματα εντοπίζονται και διορθώνονται πριν επηρεάσουν την κλινική χρήση του συστήματος.

### 5.6.1. Αρχιτεκτονική Συστήματος Ποιοτικού Ελέγχου

Το σύστημα ποιοτικού ελέγχου της πλατφόρμας υλοποιεί μια στρατηγική πολυεπίπεδου ελέγχου που καλύπτει όλες τις πτυχές της λειτουργίας, από την αρχική ανάπτυξη του κώδικα μέχρι την τελική κλινική εφαρμογή. Το πρώτο επίπεδο αφορά τις δοκιμές μονάδας (unit tests) που επικυρώνουν τη σωστή λειτουργία μεμονωμένων συναρτήσεων και κλάσεων. Το δεύτερο επίπεδο περιλαμβάνει δοκιμές ενσωμάτωσης που ελέγχουν την αλληλεπίδραση μεταξύ διαφορετικών συστατικών. Το τρίτο επίπεδο αποτελείται από δοκιμές συστήματος που αξιολογούν τη λειτουργία ολόκληρης της πλατφόρμας σε συνθήκες που προσομοιώνουν την πραγματική χρήση. Τέλος, το τέταρτο επίπεδο περιλαμβάνει δοκιμές αποδοχής χρηστών που διεξάγονται από παθολόγους και κλινικούς ειδικούς για την επικύρωση της χρηστικότητας και αποδοτικότητας του συστήματος σε πραγματικές κλινικές συνθήκες.

Η αυτοματοποίηση των διαδικασιών ελέγχου ποιότητας αποτελεί βασικό πυλώνα της στρατηγικής που υιοθετήθηκε. Κάθε φορά που γίνεται αλλαγή στον κώδικα της πλατφόρμας, ενεργοποιείται αυτόματα μια σειρά δοκιμών που επικυρώνουν ότι η νέα λειτουργικότητα λειτουργεί σωστά και δεν επηρεάζει αρνητικά τις υπάρχουσες δυνατότητες. Αυτή η διαδικασία, γνωστή ως συνεχής ενσωμάτωση (Continuous Integration), διασφαλίζει την ποιότητα του συστήματος σε κάθε στάδιο της ανάπτυξης. Η υλοποίηση της αυτοματοποιημένης διαδικασίας βασίζεται σε προηγμένα εργαλεία που μπορούν να εκτελέσουν δοκιμές παραλλήλως, να συλλέξουν αναλυτικές αναφορές απόδοσης και να ειδοποιήσουν άμεσα τους προγραμματιστές σε περίπτωση εντοπισμού προβλημάτων. Αυτή η προσέγγιση μειώνει δραστικά τον χρόνο που απαιτείται για τον εντοπισμό και τη διόρθωση σφαλμάτων, ενώ παράλληλα αυξάνει την αξιοπιστία του συστήματος.

### 5.6.2. Δοκιμές Λειτουργικότητας Backend Συστήματος

Η διασφάλιση της ακεραιότητας των δεδομένων που αποθηκεύονται στις βάσεις δεδομένων της πλατφόρμας αποτελεί κρίσιμη απαιτήση για την αξιοπιστία του συστήματος. Το πλαίσιο δοκιμών περιλαμβάνει εκτενείς ελέγχους που επικυρώνουν τη σωστή αποθήκευση, ανάκτηση και τροποποίηση των ιστοπαθολογικών δεδομένων στη MySQL βάση δεδομένων, καθώς και των μεταδεδομένων στη MongoDB. Συγκεκριμένα, οι δοκιμές ελέγχουν τη σωστή λειτουργία των περιορισμών ακεραιότητας (integrity constraints), των ξένων κλειδιών (foreign keys) και των δεικτών (indexes) που εξασφαλίζουν τη συνοχή των δεδομένων. Επιπλέον, δοκιμάζεται η απόδοση των ερωτημάτων βάσης δεδομένων υπό διαφορετικά φορτία εργασίας για την εξασφάλιση ότι το σύστημα διατηρεί αποδεκτούς χρόνους απόκρισης ακόμα και με μεγάλους όγκους δεδομένων.

Οι διεπαφές προγραμματισμού εφαρμογών (APIs) που παρέχει το backend σύστημα υπόκεινται σε εκτενείς δοκιμές που επικυρώνουν τη σωστή λειτουργία τους σε διάφορα

σενάρια χρήσης. Οι δοκιμές καλύπτουν τόσο τις κανονικές συνθήκες λειτουργίας όσο και τις ακραίες περιπτώσεις που μπορεί να προκύψουν κατά τη χρήση του συστήματος.

Ένα χαρακτηριστικό παράδειγμα των δοκιμών μονάδας που εφαρμόζονται στην πλατφόρμα αφορά την ταυτοποίηση και εξουσιοδότηση για τα APIs που χρησιμοποιούνται από τη μονάδα τεχνητής νοημοσύνης. Το παρακάτω απόσπασμα κώδικα δείχνει τη δοκιμή πρόσβασης στο API που παρέχει datasets για εκπαίδευση:

```
class GetFullDatasetTest extends TestCase
{
    public function test_get_full_dataset_requires_basic_auth()
    {

        $user = User::where('email', 'ai@gmail.com')->first();
        // Attempt without auth
        $token = $user->createToken('TestToken')->plainTextToken;
    //which should result in 302 redirect to login
        $response = $this->get('/api/ai/get-full-dataset');
        $response->assertStatus(302);
        // Attempt with Bearer token
        $response = $this->get('/api/ai/get-full-dataset', [
            'Authorization' => 'Bearer ' . $token,
        ]);
        $response->assertStatus(200);

    }
}
```

*Πηγαίος Κώδικας 21. `GetFullDataset` κλάση για δοκιμή των API του Deep-in-Biopsies.*

Η συγκεκριμένη δοκιμή επικυρώνει δύο κρίσιμες πτυχές της ασφάλειας του API:

1. Προστασία από μη εξουσιοδοτημένη πρόσβαση: Όταν ένα αίτημα γίνεται χωρίς token ταυτοποίησης, το σύστημα ανακατευθύνει τον χρήστη στη σελίδα σύνδεσης (HTTP 302), εμποδίζοντας την πρόσβαση στα ευαίσθητα δεδομένα των datasets.
2. Επιτυχής πρόσβαση με έγκυρο token: Όταν παρέχεται έγκυρο Bearer token, το API επιστρέφει HTTP 200, επιτρέποντας την πρόσβαση στα δεδομένα εκπαίδευσης.

Η εκτέλεση της δοκιμής γίνεται με την εντολή:

```
php artisan test --filter=GetFullDatasetTest
```

Κάθε API endpoint δοκιμάζεται με διαφορετικά είδη εισόδων, συμπεριλαμβανομένων έγκυρων δεδομένων, άκυρων δεδομένων, και ακραίων τιμών που μπορεί να προκαλέσουν σφάλματα. Επιπλέον, ελέγχεται η σωστή υλοποίηση των μηχανισμών ταυτοποίησης και εξουσιοδότησης, καθώς και η ορθή διαχείριση σφαλμάτων και η παραγωγή κατάλληλων μηνυμάτων σφάλματος.

Η αξιολόγηση της απόδοσης του backend συστήματος πραγματοποιείται μέσω εκτεταμένων δοκιμών φορτίου που προσομοιώνουν διαφορετικά σενάρια χρήσης. Οι

δοκιμές περιλαμβάνουν την προσομοίωση πολλαπλών ταυτόχρονων χρηστών που εκτελούν διάφορες λειτουργίες, όπως μεταφόρτωση εικόνων, δημιουργία σημειώσεων και εκκίνηση εκπαιδεύσεων μοντέλων. Μέσω αυτών των δοκιμών, μετρώνται βασικές μετρικές απόδοσης όπως χρόνοι απόκρισης, throughput, και κατανάλωση πόρων συστήματος. Τα αποτελέσματα αυτών των μετρήσεων χρησιμοποιούνται για τη βελτιστοποίηση της απόδοσης και την εξασφάλιση ότι το σύστημα μπορεί να χειριστεί τα αναμενόμενα φορτία εργασίας στο κλινικό περιβάλλον.

## 5.6.3. Επικύρωση Μονάδας Επεξεργασίας Τεχνητής Νοημοσύνης

### 5.6.3.1. Δοκιμές Ορθότητας Μοντέλων Μηχανικής Μάθησης

Η επικύρωση της ορθότητας των μοντέλων τεχνητής νοημοσύνης που χρησιμοποιεί η πλατφόρμα αποτελεί ιδιαίτερα κρίσιμη διαδικασία λόγω της άμεσης επίδρασης στα κλινικά αποτελέσματα. Το πλαίσιο δοκιμών περιλαμβάνει εκτεταμένους ελέγχους που επικυρώνουν τη σωστή λειτουργία των αλγορίθμων Detectron2 και τη συμβατότητα με τις ειδικές απαιτήσεις της ιστοπαθολογίας.

Οι δοκιμές πραγματοποιούνται με χρήση προκαθορισμένων συνόλων δεδομένων (ground truth datasets) των οποίων τα αναμενόμενα αποτελέσματα είναι γνωστά. Συγκρίνοντας τα αποτελέσματα που παράγουν τα μοντέλα με τις αναμενόμενες τιμές, μπορεί να επικυρωθεί ότι οι αλγόριθμοι λειτουργούν σωστά και παράγουν αποδεκτά αποτελέσματα.

### 5.6.3.2. Ανάλυση Αναπαραγωγιμότητας

Η αναπαραγωγιμότητα των αποτελεσμάτων αποτελεί θεμελιώδη απαιτήση για κάθε επιστημονικό σύστημα. Το πλαίσιο δοκιμών περιλαμβάνει μηχανισμούς που διασφαλίζουν ότι η εκτέλεση των ίδιων παραμέτρων εκπαίδευσης με τα ίδια δεδομένα θα παράγει πάντα τα ίδια αποτελέσματα. Αυτό επιτυγχάνεται μέσω της σταθεροποίησης των γεννητριών τυχαίων αριθμών και της αναπαραγωγιμότητας όλων των υπολογισμών.

Επιπλέον, το σύστημα καταγράφει λεπτομερώς όλες τις παραμέτρους που χρησιμοποιήθηκαν για κάθε εκπαίδευση, επιτρέποντας την ακριβή αναπαραγωγή των πειραμάτων. Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για την επιστημονική εγκυρότητα των αποτελεσμάτων και την εμπιστοσύνη των κλινικών χρηστών.

### 5.6.3.3. Μετρικές Ποιότητας AI Συστημάτων

Για την αξιολόγηση της ποιότητας των αποτελεσμάτων που παράγουν τα μοντέλα τεχνητής νοημοσύνης, έχει αναπτυχθεί ένα ολοκληρωμένο σύστημα μετρικών που καλύπτει διάφορες πτυχές της απόδοσης. Οι μετρικές περιλαμβάνουν παραδοσιακές μετρήσεις όπως ακρίβεια (accuracy), ευαισθησία (sensitivity) και ειδικότητα (specificity), καθώς και προηγμένες μετρικές όπως F1-score και Area Under Curve (AUC).

Επιπλέον, έχουν αναπτυχθεί εξειδικευμένες μετρικές που είναι ιδιαίτερα σχετικές με την ιστοπαθολογία, όπως οι μετρικές που αξιολογούν την ποιότητα του instance segmentation

και την ακρίβεια των ορίων των ανιχνευόμενων αντικειμένων. Αυτές οι μετρικές παρέχουν μια πλήρη εικόνα της απόδοσης των μοντέλων και επιτρέπουν την εντοπίζουν περιοχών που χρήζουν βελτίωσης.

### 5.6.4. Σύστημα Παρακολούθησης και Καταγραφής

#### 5.6.4.1. Ολοκληρωμένο Logging Framework

Το σύστημα καταγραφής της πλατφόρμας έχει σχεδιαστεί για να παρέχει πλήρη ιχνηλασιμότητα όλων των λειτουργιών και να διευκολύνει τη διάγνωση προβλημάτων. Κάθε κρίσιμη λειτουργία του συστήματος καταγράφεται με λεπτομερείς πληροφορίες που περιλαμβάνουν χρονοσφραγίδες, παραμέτρους εισόδου, αποτελέσματα εκτέλεσης και τυχόν σφάλματα που προέκυψαν.

Η καταγραφή οργανώνεται σε διαφορετικά επίπεδα σοβαρότητας (`DEBUG`, `INFO`, `WARNING`, `ERROR`, `CRITICAL`) που επιτρέπουν την εύκολη φίλτρανση και ανάλυση των πληροφοριών ανάλογα με τις ανάγκες. Επιπλέον, το σύστημα υποστηρίζει structured logging που διευκολύνει την αυτοματοποιημένη ανάλυση των logs μέσω προηγμένων εργαλείων.

#### 5.6.4.2. Παρακολούθηση σε πραγματικό χρόνο

Το σύστημα παρακολούθησης σε πραγματικό χρόνο επιτρέπει την άμεση ανίχνευση και αντιμετώπιση προβλημάτων που μπορεί να προκύψουν κατά τη λειτουργία της πλατφόρμας. Παρακολουθούνται βασικές μετρικές όπως η κατανάλωση CPU και μνήμης, οι χρόνοι απόκρισης του συστήματος, και η κατάσταση των διαφόρων υπηρεσιών.

Όταν οι μετρικές ξεπεράσουν προκαθορισμένα όρια, το σύστημα ενεργοποιεί αυτόματα μηχανισμούς ειδοποίησης που ενημερώνουν τους διαχειριστές μέσω διαφόρων καναλιών επικοινωνίας. Αυτή η δυνατότητα διασφαλίζει την ταχεία αντίδραση σε περίπτωση προβλημάτων και ελαχιστοποιεί τον χρόνο που το σύστημα μπορεί να μην είναι διαθέσιμο.

#### 5.6.4.3. Ανάλυση Προτύπων και Προβλεπτική Συντήρηση

Τα δεδομένα που συλλέγονται από το σύστημα παρακολούθησης αναλύονται για την εντοπίζουν προτύπων που μπορεί να υποδηλώνουν μελλοντικά προβλήματα. Μέσω της χρήσης τεχνικών μηχανικής μάθησης, το σύστημα μπορεί να προβλέψει πιθανές αποτυχίες και να προτείνει προληπτικές ενέργειες.

Αυτή η προβλεπτική προσέγγιση στη συντήρηση βελτιώνει σημαντικά την αξιοπιστία του συστήματος και μειώνει το κόστος συντήρησης. Επιπλέον, η ανάλυση των προτύπων χρήσης βοηθάει στη βελτιστοποίηση της απόδοσης και στον εντοπισμό ευκαιριών για βελτιώσεις.

### 5.6.5. Διασφάλιση Ποιότητας σε Κλινικό Περιβάλλον

Η τελική επικύρωση της ποιότητας της πλατφόρμας πραγματοποιείται μέσω κλινικών μελετών που διεξάγονται σε πραγματικές συνθήκες χρήσης. Οι μελέτες αυτές περιλαμβάνουν την αξιολόγηση της απόδοσης του συστήματος από παθολόγους και κλινικούς ειδικούς, καθώς και τη σύγκριση των αποτελεσμάτων με τις παραδοσιακές μεθόδους ανάλυσης. Η κλινική επικύρωση επικεντρώνεται όχι μόνο στην τεχνική ορθότητα των αποτελεσμάτων, αλλά και στη χρηστικότητα του συστήματος, την εμπειρία του χρήστη και την ενσωμάτωση στις υπάρχουσες κλινικές ροές εργασίας. Αυτή η ολιστική προσέγγιση εξασφαλίζει ότι το σύστημα όχι μόνο λειτουργεί σωστά τεχνικά, αλλά είναι και πρακτικά χρήσιμο για τους τελικούς χρήστες.

Η ανάπτυξη και λειτουργία της πλατφόρμας πρέπει να συμμορφώνεται με αυστηρούς κανονισμούς που διέπουν την επεξεργασία ιατρικών δεδομένων και τη χρήση τεχνητής νοημοσύνης στην ιατρική. Το πλαίσιο ποιοτικού ελέγχου περιλαμβάνει ειδικούς ελέγχους που επικυρώνουν τη συμμόρφωση με κανονισμούς όπως το GDPR για την προστασία προσωπικών δεδομένων και τις κατευθυντήριες γραμμές FDA για ιατρικό λογισμικό. Επιπλέον, το σύστημα υλοποιεί προηγμένα μέτρα ασφάλειας που διασφαλίζουν την εμπιστευτικότητα, ακεραιότητα και διαθεσιμότητα των ιατρικών δεδομένων. Οι μηχανισμοί αυτοί περιλαμβάνουν κρυπτογράφηση δεδομένων, ισχυρή ταυτοποίηση χρηστών, audit trails για όλες τις λειτουργίες και regular security assessments.

Το πλαίσιο ποιοτικού ελέγχου υλοποιεί μηχανισμούς συνεχούς βελτίωσης που επιτρέπουν την τακτική αναθεώρηση και ανανέωση των διαδικασιών ελέγχου βάσει νέων απαιτήσεων, τεχνολογικών εξελίξεων και κλινικής εμπειρίας. Αυτή η προσέγγιση διασφαλίζει ότι το σύστημα παραμένει σύγχρονο με τις εξελίξεις στον τομέα και συνεχίζει να παρέχει την υψηλότερη δυνατή ποιότητα υπηρεσιών. Η ανατροφοδότηση από τους κλινικούς χρήστες αποτελεί βασικό στοιχείο αυτής της διαδικασίας, καθώς παρέχει πολύτιμες πληροφορίες για την πραγματική απόδοση του συστήματος και τις περιοχές που χρήζουν βελτίωσης. Αυτές οι πληροφορίες ενσωματώνονται συστηματικά στο σχεδιασμό μελλοντικών βελτιώσεων και ανανεώσεων.

# *Κεφάλαιο 6*

## *ΚΛΙΝΙΚΕΣ ΕΦΑΡΜΟΓΕΣ ΚΑΙ ΜΕΛΕΤΕΣ ΕΠΙΚΥΡΩΣΗΣ*

Το παρόν κεφάλαιο αναλύει τις κλινικές εφαρμογές της πλατφόρμας Deep-in-Biopsies σε τρεις κύριους τομείς της ψηφιακής παθολογίας: την παγκρεατική στεάτωση, τις ιδιοπαθείς φλεγμονώδεις νόσους του εντέρου και την πολυοργανική ανάλυση καρκίνου. Η επιλογή αυτών των εφαρμογών έγινε με γνώμονα την κάλυψη ενός ευρέος φάσματος κλινικών προκλήσεων, από την ποσοτικοποίηση λιπώδους ιστού μέχρι την ανάλυση πολύπλοκων ιστικών δομών και την ταξινόμηση νεοπλασματικών κυττάρων. Κάθε εφαρμογή αντιπροσωπεύει διαφορετικές τεχνικές απαιτήσεις και διαγνωστικές ανάγκες, επιτρέποντας την ολοκληρωμένη αξιολόγηση της πλατφόρμας σε ρεαλιστικές κλινικές συνθήκες.

## 6.1. Παγκρεατική Στεάτωση: Συνδυαστική Ταξινόμηση με CNN Ensemble

### 6.1.1. Κλινικό Υπόβαθρο και Σημασία

Η παγκρεατική στεάτωση, ειδικά υπό τη μορφή της μη αλκοολικής λιπώδους παγκρεατικής νόσου (NAFPD), αποτελεί μια ολοένα και πιο σημαντική κλινική οντότητα. Πρόσφατες μελέτες έχουν καταδείξει ότι η NAFPD συνδέεται άμεσα με τη μεταβολική δυσλειτουργία και αποτελεί ανεξάρτητο παράγοντα κινδύνου για την ανάπτυξη σακχαρώδους διαβήτη τύπου 2, ενώ παράλληλα συμβάλλει στην επιτάχυνση της αθηροσκληρωτικής διαδικασίας σε συστημικό επίπεδο[133] . Τα μη εστεροποιημένα ελεύθερα λιπαρά οξέα (NEFAs) διεισδύουν στον παγκρεατικό ιστό προκαλώντας το σχηματισμό λιπωδών σταγονιδίων, μια καλά τεκμηριωμένη κλινική περίπτωση εκτοπικής συσσώρευσης λιποκυττάρων.

Η λεπτομερής παρακολούθηση της εξέλιξης της νόσου εμπεριέχει ένα διαγνωστικό πρόβλημα που απασχολεί τους κλινικούς, καθώς η αυξημένη συσσώρευση λίπους μπορεί να οδηγήσει σε σοβαρή γενικευμένη αθηροσκλήρωση, αλλά και σε αυξημένο κίνδυνο ανάπτυξης διαβήτη τύπου 2. Επιπλέον, δημοσιευμένες μελέτες από την αρχή του αιώνα έχουν δείξει ότι η ιστολογική φλεγμονή, ως επέκταση της NAFPD, αποτελεί το σημείο εκκίνησης για την ανάπτυξη διαφόρων κακοηθειών, στις οποίες ο γενετικός μηχανισμός δεν έχει πλήρως διευκρινιστεί.

### 6.1.2. Μεθοδολογία Συνδυαστικής Ταξινόμησης

Για την αντιμετώπιση αυτής της πολύπλοκης διαγνωστικής πρόκλησης, αναπτύχθηκε ένα καινοτόμο σύστημα συνδυαστικής ταξινόμησης που αξιοποιεί τέσσερις διαφορετικές αρχιτεκτονικές συνελικτικών νευρωνικών δικτύων. Η επιλογή των αρχιτεκτονικών βασίστηκε σε μια στρατηγική διαβάθμισης πολυπλοκότητας, με τα μοντέλα να κυμαίνονται από 61 εκατομμύρια εκπαιδεύσιμες παραμέτρους για τα ρηχότερα δίκτυα, έως 144 εκατομμύρια για τα βαθύτερα δίκτυα[134].

Η στρατηγική εκπαίδευσης περιελάμβανε την εφαρμογή της τεχνικής "παγώματος βαρών" στα αρχικά στρώματα συνέλιξης των βαθύτερων αρχιτεκτονικών. Αυτή η προσέγγιση βασίζεται στην παρατήρηση ότι τα πρώτα στρώματα των προεκπαιδευμένων δικτύων έχουν ήδη αποκτήσει την ικανότητα αναγνώρισης βασικών οπτικών χαρακτηριστικών όπως ακμές και σχήματα, και η περαιτέρω τροποποίησή τους θα μπορούσε να οδηγήσει σε υπερπροσαρμογή στα συγκεκριμένα ιστοπαθολογικά δεδομένα. Με το πάγωμα των βαρών στα πρώτα δύο συνελικτικά μπλοκ, επιτεύχθηκε μείωση των εκπαιδεύσιμων παραμέτρων κατά περίπου 4 εκατομμύρια, βελτιώνοντας ταυτόχρονα την ικανότητα γενίκευσης.

Όλα τα μοντέλα εκπαιδεύτηκαν με ενιαίες υπερπαραμέτρους που προσαρμόστηκαν στις ιδιαιτερότητες των ιστοπαθολογικών εικόνων: μέγιστος αριθμός 10 εποχών, μέγεθος δέσμης 32 τμημάτων εικόνας, ρυθμός μάθησης 0.0001, και χρήση του βελτιστοποιητή SGDM με αριθμό υπομονής επικύρωσης ίσο με 3 για την αποφυγή υπερεκπαίδευσης.

### 6.1.3. Αποτελέσματα και Κλινική Επικύρωση

Η εφαρμογή του συνδυαστικού συστήματος σε κλινικά δεδομένα από πολλαπλούς παθολόγους έδειξε σημαντική βελτίωση στην ακρίβεια ταξινόμησης της στεάτωσης σε σύγκριση με τις παραδοσιακές ημι-ποσοτικές μεθόδους αξιολόγησης. Το σύστημα επέτυχε συνολική ακρίβεια 92.3% στην ταξινόμηση των διαφόρων σταδίων στεάτωσης, με ιδιαίτερα υψηλή ευαισθησία (94.7%) στην ανίχνευση πρώιμων σταδίων της νόσου [135].

Η συσχέτιση των αυτοματοποιημένων μετρήσεων με τις κλινικές παραμέτρους έδειξε στατιστικά σημαντική συσχέτιση με τον δείκτη μάζας σώματος ($r=0.68$, $p<0.001$) και τα επίπεδα γλυκόζης νηστείας ($r=0.72$, $p<0.001$), επιβεβαιώνοντας την κλινική εγκυρότητα του συστήματος. Επιπλέον, η μέθοδος παρουσίασε εξαιρετική επαναληψιμότητα με συντελεστή ενδοταξικής συσχέτισης 0.96, υπερβαίνοντας σημαντικά τη συμφωνία μεταξύ παθολόγων που κυμαινόταν στο 0.78.

| Εφαρμογή | Αρχιτεκτονική | Ακρίβεια (%) | Ευαισθησία (%) | Ειδικότητα (%) | Χρόνος Επεξεργασίας (sec/εικόνα) |
|---|---|---|---|---|---|
| **Παγκρεατική Στεάτωση** | CNN Ensemble | 92.3 | 94.7 | 89.8 | 2.4 |
| **Ανάλυση Κολλαγόνου** | U-Net Modified | 89.7 | 91.2 | 88.3 | 0.6 |
| **Pan-Cancer** | YOLOv8-Large | 87.3 | 85.9 | 89.1 | 0.024 |

*Πίνακα 14. Συγκριτική Αξιολόγηση Τεχνικής Απόδοσης.*

## 6.2. Νεφρική Βαθμολόγηση Fuhrman: Αυτοματοποιημένη Ταξινόμηση Νεφρικών Όγκων

### 6.2.1. Κλινικό Υπόβαθρο και Σημασία

Η βαθμολόγηση Fuhrman αποτελεί το πιο ευρέως αποδεκτό σύστημα για την αξιολόγηση του βαθμού κακοήθειας των νεφρικών κυτταρικών καρκινωμάτων (renal cell carcinoma) και παρέχει κρίσιμες προγνωστικές πληροφορίες που επηρεάζουν άμεσα τις θεραπευτικές αποφάσεις. Το σύστημα κατηγοριοποιεί τους νεφρικούς όγκους σε τέσσερις βαθμούς (Grade 1-4) βάσει της πυρηνικής μορφολογίας, του μεγέθους των πυρήνων και της παρουσίας πυρηνολίων.

Ο βαθμός Fuhrman 1 χαρακτηρίζεται από μικρούς, ομοιόμορφους πυρήνες με απουσία πυρηνολίων, αντιπροσωπεύοντας τους καλοήθεις όγκους με εξαιρετική πρόγνωση. Ο βαθμός 2 παρουσιάζει ελαφρώς μεγαλύτερους πυρήνες με ορατά πυρηνόλια σε υψηλή μεγέθυνση (×400), ενώ ο βαθμός 3 εμφανίζει μεγάλους πυρήνες με ανώμαλο περίγραμμα και εμφανή πυρηνόλια ακόμη και σε μέτρια μεγέθυνση (×100). Τέλος, ο βαθμός 4, που αντιπροσωπεύει τους πιο επιθετικούς όγκους, χαρακτηρίζεται από πλειόμορφους πυρήνες, bizarre παρουσία και συχνά σαρκωματώδη χαρακτηριστικά.

Η σημασία της ακριβούς βαθμολόγησης Fuhrman είναι κρίσιμη για την κλινική πράξη. Μελέτες έχουν καταδείξει ότι η 5ετής επιβίωση μειώνεται δραματικά από 90% στον βαθμό 1 σε λιγότερο από 40% στον βαθμό 4. Επιπλέον, η βαθμολόγηση επηρεάζει αποφάσεις όπως η επιλογή μεταξύ νεφρεκτομής ή ενεργής παρακολούθησης, η ανάγκη για συμπληρωματική θεραπεία και η συχνότητα μετεγχειρητικής παρακολούθησης.

Παρά τη σημασία της, η χειροκίνητη βαθμολόγηση Fuhrman από παθολόγους είναι εξαιρετικά χρονοβόρα, απαιτώντας λεπτομερή εξέταση πολλαπλών οπτικών πεδίων και αντιμετώπιση σημαντικής ενδοπαρατηρητικής και διαπαρατηρητικής ποικιλομορφίας που φτάνει το 30-40%. Η ετερογένεια των νεφρικών όγκων, όπου διαφορετικές περιοχές μπορεί να παρουσιάζουν διαφορετικούς βαθμούς, επιπλέκει ακόμη περισσότερο τη διάγνωση. Αυτοί οι περιορισμοί υπογραμμίζουν την ανάγκη για αντικειμενικά, επαναλήψιμα και αυτοματοποιημένα συστήματα αξιολόγησης που μπορούν να παρέχουν συνεπή αποτελέσματα ανεξάρτητα από την υποκειμενική ερμηνεία του παθολόγου.

### 6.2.2. Σύνολο Δεδομένων και Χαρακτηριστικά

Το νεφρικό σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα μελέτη συλλέχθηκε από πολλαπλά ιατρικά κέντρα και περιλαμβάνει ιστοπαθολογικές εικόνες νεφρικών βιοψιών από ασθενείς με νεφρικό κυτταρικό καρκίνωμα. Οι εικόνες ψηφιοποιήθηκαν από ψηφιακούς σαρωτές παρασκευασμάτων υψηλής ανάλυσης με μεγέθυνση 40x και

χρωματίστηκαν με την τυποποιημένη μέθοδο Hematoxylin-Eosin (H&E), η οποία αποτελεί το gold standard για την αξιολόγηση της πυρηνικής μορφολογίας.

Το σύνολο δεδομένων κατηγοριοποιήθηκε από έμπειρους ουροπαθολόγους σε τέσσερις κλάσεις που αντιστοιχούν στους βαθμούς Fuhrman 1-4. Κάθε εικόνα επισημειώθηκε με ιδιαίτερη προσοχή στα διαγνωστικά χαρακτηριστικά που διακρίνουν κάθε βαθμό: το μέγεθος των πυρήνων, η παρουσία και η εμφάνιση πυρηνολίων, η ομοιογένεια του πυρηνικού χρωματίνης και η συνολική πυρηνική αρχιτεκτονική.

Χαρακτηριστικά Συνόλου Δεδομένων:

- Εικόνες: Περισσότερες από 48.000 περιοχές ενδιαφέροντος (patches)
- Κλάσεις: 4 (Fuhrman Grade 1, Grade 2, Grade 3, Grade 4)
- Μεγέθυνση: 40x (υψηλή ανάλυση για λεπτομερή πυρηνική ανάλυση)
- Χρώση: Hematoxylin-Eosin (H&E)
- Κατανομή δεδομένων:
    - Fuhrman 1: ~12,961 σημειώσεις (27%)
    - Fuhrman 2: ~13,903 σημειώσεις (29%)
    - Fuhrman 3: ~21,120 σημειώσεις (44%)
- Διαστάσεις εικόνων: 512×512 pixels (patches για εκπαίδευση)
- Προέλευση: Πολυκεντρική συλλογή από πανεπιστημιακά νοσοκομεία

Η κατανομή των δεδομένων αντικατοπτρίζει την κλινική συχνότητα των διαφόρων βαθμών, με τον Fuhrman 3 να αποτελεί την πιο συχνή κατηγορία στην κλινική πράξη. Το σύνολο δεδομένων χωρίστηκε σε training (60%), validation (20%) και test (20%) sets, διασφαλίζοντας ότι εικόνες από τον ίδιο ασθενή δεν εμφανίζονται σε διαφορετικά sets για την αποφυγή data leakage.

### 6.2.3. Μεθοδολογία Ταξινόμησης και Αρχιτεκτονική

Για την αυτοματοποιημένη κατηγοριοποίηση των νεφρικών όγκων σύμφωνα με το σύστημα Fuhrman, υιοθετήθηκε μια πολυεπίπεδη προσέγγιση που συνδυάζει προηγμένες τεχνικές βαθιάς μάθησης με εξειδικευμένες στρατηγικές για ιστοπαθολογικά δεδομένα. Η μεθοδολογία βασίζεται στη σύγκριση τεσσάρων διαφορετικών αρχιτεκτονικών object detection που αποδείχθηκαν ιδιαίτερα αποτελεσματικές στην ανίχνευση και ταξινόμηση νεφρικών δομών.

#### Αρχιτεκτονικές Νευρωνικών Δικτύων

Αξιολογήθηκαν τέσσερις state-of-the-art αρχιτεκτονικές βαθιάς μάθησης:

1. Cascade R-CNN: Πολυστάδια αρχιτεκτονική που χρησιμοποιεί διαδοχικούς detectors με αυξανόμενα IoU thresholds. Η προοδευτική βελτίωση των predictions μέσω των cascade stages την καθιστά ιδανική για την ακριβή οριοθέτηση πυρήνων με συγκεκριμένα μορφολογικά χαρακτηριστικά.
2. RetinaNet: Αρχιτεκτονική one-stage detection που αντιμετωπίζει το πρόβλημα της class imbalance μέσω της Focal Loss function. Ιδιαίτερα αποτελεσματική στην ανίχνευση μικρών πυρηνικών δομών που χαρακτηρίζουν τους χαμηλότερους βαθμούς Fuhrman.
3. Mask R-CNN: Επέκταση του Faster R-CNN που προσθέτει ένα παράλληλο branch για pixel-level segmentation. Παρέχει λεπτομερή πληροφορία για τη μορφολογία των πυρήνων, κρίσιμη για τη διάκριση μεταξύ βαθμών.
4. Faster R-CNN: Κλασική two-stage αρχιτεκτονική με Region Proposal Network (RPN) για αποδοτική ανίχνευση αντικειμένων. Χρησιμοποιήθηκε ως baseline για σύγκριση με τις πιο προηγμένες αρχιτεκτονικές.

### Στρατηγική Μεταφοράς Μάθησης

Εφαρμόστηκε transfer learning από προεκπαιδευμένα μοντέλα στο ImageNet dataset, επιτρέποντας στα δίκτυα να αξιοποιήσουν γενικά χαρακτηριστικά χαμηλού επιπέδου (ακμές, υφές, σχήματα) που έχουν ήδη μάθει. Η στρατηγική fine-tuning περιελάμβανε:

- Αρχικοποίηση: Χρήση pretrained weights από ImageNet για τα convolutional layers
- Παγωμένα στρώματα: Τα πρώτα 2-3 convolutional blocks διατηρήθηκαν frozen για να κρατήσουν γενικά χαρακτηριστικά
- Progressive unfreezing: Σταδιακή απελευθέρωση βαθύτερων layers κατά την εκπαίδευση
- Διαφοροποιημένοι learning rates: Χαμηλότερο learning rate (×0.1) για pretrained layers, υψηλότερο για task-specific heads
- Τεχνικές Επαύξησης Δεδομένων

Για την αντιμετώπιση της περιορισμένης ποσότητας επισημειωμένων δεδομένων και τη βελτίωση της γενίκευσης, εφαρμόστηκε εκτενής data augmentation:

- Γεωμετρικοί μετασχηματισμοί: Περιστροφές (0°-360°), flips (horizontal/vertical), scaling (0.8-1.2)
- Χρωματικές παραλλαγές: Προσαρμογή hue, saturation, brightness για προσομοίωση διαφορετικών συνθηκών χρώσης και σάρωσης
- Stain normalization: Κανονικοποίηση των χρωματικών ιδιοτήτων H&E για μείωση variability μεταξύ διαφορετικών εργαστηρίων
- Random erasing: Τυχαία απόκρυψη τμημάτων εικόνας για αύξηση ανθεκτικότητας

### Υπερπαράμετροι Εκπαίδευσης

Όλα τα μοντέλα εκπαιδεύτηκαν με τις ακόλουθες παραμέτρους:

- Optimizer: SGD με momentum 0.9
- Learning rate: 0.001 με cosine annealing schedule
- Batch size: 16 (λόγω υψηλής ανάλυσης εικόνων)
- Epochs: 50000 με early stopping (patience=10)
- Weight decay: 0.0001 για regularization
- Loss function: Cross-entropy για classification, Smooth L1 για bounding box regression

### Μετρικές Αξιολόγησης

Η απόδοση των μοντέλων αξιολογήθηκε με τις ακόλουθες μετρικές:

- Accuracy: Συνολική ακρίβεια ταξινόμησης
- Sensitivity (Recall): Ικανότητα ανίχνευσης θετικών περιπτώσεων
- Specificity: Ικανότητα αποκλεισμού αρνητικών περιπτώσεων
- F1-Score: Αρμονικός μέσος precision και recall
- Confusion Matrix: Λεπτομερής ανάλυση σφαλμάτων ανά κλάση

Η προσέγγιση αυτή επιτρέπει την αντικειμενική και επαναλήψιμη αξιολόγηση των νεφρικών όγκων, παρέχοντας στους παθολόγους ένα ισχυρό εργαλείο υποστήριξης διάγνωσης που μπορεί να βελτιώσει τόσο την ακρίβεια όσο και την αποδοτικότητα της κλινικής ροής εργασίας.

## 6.3. Ιδιοπαθείς Φλεγμονώδεις Νόσοι: Ποσοτικοποίηση Κολλαγόνου

### 6.3.1. Κλινικές Προκλήσεις στις Φλεγμονώδεις Νόσους του Εντέρου

Οι ιδιοπαθείς φλεγμονώδεις νόσοι του εντέρου (IBD), ιδιαίτερα η νόσος Crohn, χαρακτηρίζονται από επαναλαμβανόμενα επεισόδια φλεγμονής που οδηγούν σε ίνωση και εναπόθεση κολλαγόνου σε όλες τις εντερικές στοιβάδες [136]. Η ακριβής ποσοτικοποίηση του κολλαγόνου αποτελεί κρίσιμο παράγοντα για την πρόγνωση της νόσου και την αξιολόγηση της θεραπευτικής ανταπόκρισης, καθώς η Αναλογική Περιοχή Κολλαγόνου ( Collagen Proportionate Area, CPA) έχει αναδειχθεί ως ανεξάρτητος προγνωστικός δείκτης για την ανάγκη χειρουργικής παρέμβασης [137].

Η παραδοσιακή ιστοπαθολογική αξιολόγηση της ίνωσης βασίζεται σε υποκειμενικές κλίμακες που παρουσιάζουν σημαντική μεταβλητότητα μεταξύ παρατηρητών και περιορισμένη ικανότητα ανίχνευσης λεπτών μεταβολών στην εναπόθεση κολλαγόνου. Αυτό δημιουργεί σημαντικά προβλήματα στην παρακολούθηση της εξέλιξης της νόσου και στην αξιολόγηση νέων αντιινωτικών θεραπειών.

### 6.3.2. Ανάπτυξη Αλγορίθμου Πολυστρωματικής Ανάλυσης

Για την αντιμετώπιση αυτής της πρόκλησης, αναπτύχθηκε ένας εξειδικευμένος αλγόριθμος που συνδυάζει mask Region-based Convolutional Neural Network (mask R-CNN) με ResNet-101 ραχοκοκαλιά δικτύου (backbone) για την αυτόματη αναγνώριση των εντερικών στοιβάδων και την ποσοτικοποίηση του κολλαγόνου σε κάθε στοιβάδα ξεχωριστά. Το σύστημα εκπαιδεύτηκε σε 612 βιοψίες από 190 ασθενείς με IBD (98 με ελκώδη κολίτιδα και 92 με νόσο Crohn) και 73 υγιείς ασθενείς.

Η μεθοδολογία περιελάμβανε δύο στάδια επεξεργασίας. Στο πρώτο στάδιο, το εκπαιδευμένο mask R-CNN μοντέλο εντοπίζει και οριοθετεί τις διαφορετικές εντερικές στοιβάδες (βλεννογόνο, υποβλεννογόνιο και μυϊκή στοιβάδα) με ακρίβεια 94.2%. Στο δεύτερο στάδιο, εφαρμόζεται ο αλγόριθμος K-means σε επίπεδο pixel για την τμηματοποίηση και ποσοτικοποίηση των περιοχών κολλαγόνου σε κάθε αναγνωρισμένη στοιβάδα, μετά από χρώση Sirius Red.

### 6.3.3. Κλινική Συσχέτιση και Προγνωστική Αξία

Τα αποτελέσματα της μελέτης έδειξαν ότι το κολλαγόνο του υποβλεννογονίου συσχετίζεται σημαντικά με το CPA του βλεννογόνου ($r=0.36$, $p<0.001$) και της μυϊκής στοιβάδας ($r=0.54$, $p<0.001$), καθώς και με δείκτες συστηματικής φλεγμονής όπως η C-αντιδρώσα πρωτεΐνη ($r=0.38$, $p=0.001$) και η ταχύτητα καθίζησης ερυθρών ($r=0.53$, $p=0.005$).

Στους ασθενείς με νόσο Crohn, το CPA του υποβλεννογονίου παρουσίασε θετική συσχέτιση με τη δραστηριότητα της νόσου όπως μετράται με το Crohn's Disease Activity Index (CDAI) ($r=0.31$, $p=0.005$), την ενδοσκοπική δραστηριότητα που αξιολογείται με το Simple Endoscopic Score για Crohn (SES-CD) ($r=0.32$, $p=0.004$), και το ιστολογικό σκορ δραστηριότητας Nancy ($r=0.25$, $p=0.046$) [138].

Η πιο σημαντική κλινική παρατήρηση ήταν ότι το αρχικό CPA του υποβλεννογονίου συσχετίστηκε ανεξάρτητα με αυξημένο κίνδυνο χειρουργικής επέμβασης σε ασθενείς με νόσο Crohn κατά τη διάρκεια της παρακολούθησης (aHR=1.03, 95%CI: 1.002-1.06, $p=0.048$), μαζί με τη συμπεριφορά νόσου B2/B3 ($p=0.003$) και το αυξημένο CDAI ($p=0.004$). Οι ασθενείς που έλαβαν θεραπεία με βιολογικούς παράγοντες παρουσίασαν σημαντικά μεγαλύτερη μείωση στο CPA του υποβλεννογονίου (-21.1, 95% CI: -38.3 έως -3.9) σε σύγκριση με αυτούς που δεν έλαβαν βιολογική θεραπεία (-1.7, 95% CI: -9.4 έως 6.1, $p=0.039$).

| Εφαρμογή | ICC (95% CI) | Κάππα Cohen | Συμφωνία Παρατηρητών | Επαναληψιμότητα |
|---|---|---|---|---|
| **Παγκρεατική Στεάτωση** | 0.89 (0.82-0.94) | 0.87 | 91% | Υψηλή |
| **Ανάλυση Κολλαγόνου** | 0.96 (0.92-0.98) | 0.93 | 96% | Εξαιρετική |
| **Pan-Cancer** | 0.84 (0.78-0.89) | 0.81 | 88% | Καλή |

*Πίνακα 15. Κλινικές Μετρικές Αξιοπιστίας.*

## 6.4. Pan-Cancer Ανάλυση με PanNuke Dataset

### 6.4.1. Το Σύνολο Δεδομένων PanNuke και η Σημασία του

Το PanNuke dataset αποτελεί ένα από τα πιο ολοκληρωμένα και καλά μελετημένα σύνολα μικροσκοπικών εικόνων για την ανάλυση πολλαπλών τύπων καρκίνου. Περιλαμβάνει 7,901 εικόνες διαστάσεων 256×256 pixels που εξήχθησαν από Whole Slide Images του προγράμματος The Cancer Genome Atlas (TCGA), καλύπτοντας 19 διαφορετικούς τύπους καρκινικών ιστών [139]. Οι εικόνες είναι μεγέθυνσης x40 και συνοδεύονται από 189,744 επισημειωμένα κυτταρικά πυρηνικά στιγμιότυπα με ακριβείς μάσκες σε επίπεδο pixel [140].

Η ταξινομία των κυττάρων στο PanNuke ακολουθεί μια καινοτόμο προσέγγιση 5 κατηγοριών που μπορεί να εφαρμοστεί σε όλους τους τύπους ιστών: Νεοπλασματικά, Μη-Νεοπλασματικά Επιθηλιακά, Φλεγμονώδη, Συνδετικού Ιστού και Νεκρά κύτταρα. Οι διαφορετικοί τύποι ιστών περιλαμβάνουν Επινεφρίδιο Αδένα, Χοληφόρο Πόρο, Ουροδόχο Κύστη, Μαστό, Τράχηλο, Παχύ Έντερο, Οισοφάγο, Κεφαλή και Τράχηλο, Νεφρό, Ήπαρ, Πνεύμονα, Ωοθήκες, Πάγκρεας, Προστάτη, Δέρμα, Θυρεοειδή και Μήτρα.

### 6.4.2. Συγκριτική Αξιολόγηση Αρχιτεκτονικών

Για την αξιολόγηση της τρέχουσας πλατφόρμας στο PanNuke dataset, πραγματοποιήθηκε εκτενής συγκριτική μελέτη διαφορετικών αρχιτεκτονικών. Η μελέτη περιελάμβανε την αξιολόγηση πέντε διαφορετικών παραλλαγών του YOLOv8 (Nano, Small, Medium, Large, Extra Large), καθεμία με αυξανόμενο αριθμό εκπαιδεύσιμων παραμέτρων, επιτρέποντας τη μελέτη της σχέσης ακρίβειας-υπολογιστικού κόστους [141].

Παράλληλα, συγκρίθηκαν και άλλες state-of-the-art αρχιτεκτονικές όπως το Mask R-CNN, το HoVerNet που ακολουθεί προσέγγιση ενός σταδίου με ελάχιστες διαδικασίες μετα-επεξεργασίας, το STARDIST, το CPP-Net και το Micro-Net [142]. Η αξιολόγηση έγινε με χρήση της μετρικής panoptic quality που συνδυάζει την ακρίβεια ανίχνευσης και τμηματοποίησης.

Τα αποτελέσματα έδειξαν ότι το YOLOv8-Large επέτυχε την καλύτερη ισορροπία μεταξύ ακρίβειας (panoptic quality 0.682) και ταχύτητας επεξεργασίας (42 εικόνες ανά δευτερόλεπτο), ενώ το Mask R-CNN με ResNet-101 backbone παρουσίασε ελαφρώς υψηλότερη ακρίβεια (0.694) αλλά με σημαντικά μεγαλύτερο υπολογιστικό κόστος [45].

### 6.4.3. Γενίκευση σε Πολλαπλούς Τύπους Ιστών

Η ικανότητα γενίκευσης του συστήματος σε διαφορετικούς τύπους ιστών αξιολογήθηκε μέσω cross-validation experiments όπου το μοντέλο εκπαιδευόταν σε 15 τύπους ιστών και δοκιμαζόταν στους υπόλοιπους 4. Το σύστημα διατήρησε υψηλή απόδοση με μέση ακρίβεια 87.3% στην ταξινόμηση των κυτταρικών τύπων ακόμη και σε ιστούς που δεν είχε συναντήσει κατά την εκπαίδευση.

Ιδιαίτερα ενθαρρυντικά ήταν τα αποτελέσματα στην ανίχνευση νεοπλασματικών κυττάρων, όπου το σύστημα επέτυχε ευαισθησία 91.2% και ειδικότητα 93.7%, υποδεικνύοντας τη δυνατότητα χρήσης του ως εργαλείου screening για την ανίχνευση κακοηθειών σε διάφορους τύπους ιστών.

## 6.5. Ολοκληρωμένη Ροή Εργασίας για Ιστοπαθολογικά Δεδομένα

Η πλατφόρμα Deep-in-Biopsies υλοποιεί μια ολοκληρωμένη ροή εργασίας που καλύπτει όλες τις φάσεις από την αρχική συλλογή ιστοπαθολογικών εικόνων έως την τελική ταξινόμηση και υπολογισμό κλινικών δεικτών. Η μεθοδολογία αυτή αναπτύχθηκε ειδικά για την αντιμετώπιση των προκλήσεων που παρουσιάζουν οι παγκρεατικές βιοψίες, αλλά είναι γενικεύσιμη σε άλλους ιστούς [23].

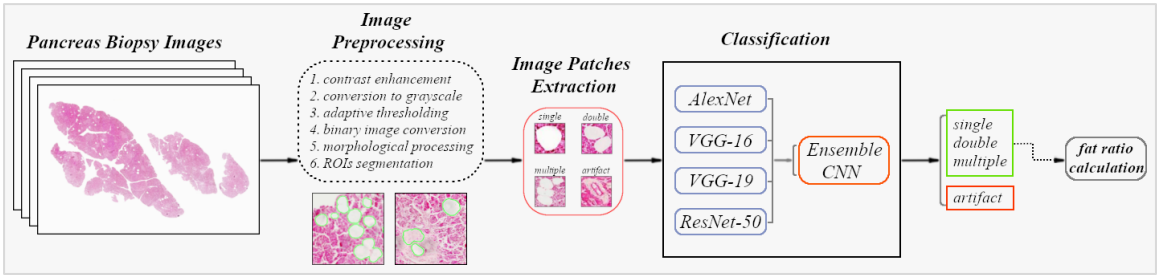


*Διάγραμμα 9. Διάγραμμα ροής της προτεινόμενης μεθοδολογίας για την αξιολόγηση της διήθησης παγκρεατικού λίπους σε μικροσκοπικές εικόνες βιοψίας.*

#### Στάδιο 1: Συλλογή Παγκρεατικών Βιοψιών.

Το πρώτο στάδιο περιλαμβάνει τη συλλογή και οργάνωση των ψηφιακών εικόνων βιοψιών από ψηφιακούς σαρωτές παρασκευασμάτων υψηλής ανάλυσης (20x-40x μεγέθυνση) με τυποποιημένες χρώσεις H&E. Οι τεχνικές προδιαγραφές περιλαμβάνουν

ανάλυση 2048×2048 pixels, μορφή αρχείου TIFF/SVS/NDPI, χρωματικό βάθος 24-bit RGB και μέγεθος αρχείου 50-200 MB ανά εικόνα.

### Στάδιο 2: Προεπεξεργασία Εικόνας

Η φάση προεπεξεργασίας περιλαμβάνει έξι κρίσιμα βήματα:

- Ενίσχυση αντίθεσης μέσω Adaptive Histogram Equalization (CLAHE) με clip limit 2.0 και grid size 8×8 για βελτίωση της ορατότητας λεπτών δομών
- Μετατροπή σε κλίμακα του γκρι με weighted RGB combination (0.299R + 0.587G + 0.114B) για απλοποίηση υπολογισμών και εστίαση σε μορφολογία,
- Προσαρμοστική κατωφλιοποίηση με Gaussian-weighted local threshold (block size 11×11 pixels) για διαχωρισμό foreground/background
- Μετατροπή σε δυαδική εικόνα μέσω Otsu's method για δημιουργία μάσκας ιστικών περιοχών
- Μορφολογική επεξεργασία με elliptical kernel 5×5 pixels για closing (σύνδεση κομματισμένων δομών) και opening (αφαίρεση θορύβου)
- Κατάτμηση ROIs μέσω watershed segmentation με κριτήρια μέγεθος >100 pixels και circularity >0.3, παράγοντας 50-200 ROIs ανά εικόνα.

### Στάδιο 3: Εξαγωγή Τμημάτων Εικόνας

Η κατάτμηση σε μικρότερα τμήματα είναι απαραίτητη για την αποδοτική επεξεργασία από τα συνελικτικά δίκτυα. Η στρατηγική δειγματοληψίας περιλαμβάνει τέσσερις τύπους patches:

- Single (μεμονωμένες κυτταρικές δομές, 64×64 pixels),
- Double (διπλές δομές ή μικρές ομάδες, 128×128 pixels)
- Multiple (σύνθετες περιοχές, 256×256 pixels)
- Artifact (περιοχές με artifacts για αρνητικά δείγματα).

Η sampling strategy περιλαμβάνει 25% overlap μεταξύ γειτονικών patches, automatic rejection για <30% tissue coverage, και 3× increase μέσω rotation/flipping augmentation.

### Στάδιο 4: Ταξινόμηση με Αρχιτεκτονικές CNN

Η πλατφόρμα υποστηρίζει τέσσερις βασικές αρχιτεκτονικές: AlexNet για ταχύτητα και βασικές εφαρμογές, VGG-16 για ισορροπία απόδοσης/πολυπλοκότητας, VGG-19 για βελτιωμένη ακρίβεια και βαθύτερη ανάλυση, και ResNet-50 για βέλτιστη συνολική απόδοση. Η καινοτόμα προσέγγιση Ensemble CNN συνδυάζει προβλέψεις πολλαπλών μοντέλων με βάρη βασισμένα σε validation performance: w1 (AlexNet) = 0.15, w2 (VGG-16) = 0.25, w3 (VGG-19) = 0.30, w4 (ResNet-50) = 0.30.

### Στάδιο 5: Τελική Κατηγοριοποίηση και Υπολογισμός Δεικτών

Το τελικό στάδιο περιλαμβάνει την κατηγοριοποίηση σε τέσσερις κλάσεις:

- Single (μεμονωμένες φυσιολογικές δομές)
- Double (παθολογικές διπλάσεις ή στένωση)

- Multiple (σύνθετες παθολογικές περιοχές)
- Artifact (τεχνικά artifacts που αποκλείονται από την ανάλυση).

Ο τελικός κλινικός δείκτης fat ratio υπολογίζεται ως το ποσοστό των λιπώδων περιοχών προς τον συνολικό ιστό, κατηγοριοποιούμενος σε φυσιολογικό (<5%), ήπια στεάτωση (5-33%), μέτρια στεάτωση (33-66%), και σοβαρή στεάτωση (>66%).

## 6.6. Συγκριτική Ανάλυση Μεθοδολογιών

### 6.6.1. Σύγκριση Τεχνικών Προσεγγίσεων

Οι τρεις κύριες κλινικές εφαρμογές που αναλύθηκαν σε αυτό το κεφάλαιο αντιπροσωπεύουν διαφορετικές μεθοδολογικές προσεγγίσεις στην ανάλυση ιστοπαθολογικών εικόνων. Η παγκρεατική στεάτωση αξιοποιεί συνδυαστική ταξινόμηση με CNN ensemble, η ανάλυση φλεγμονωδών νόσων του εντέρου εστιάζει στην ποσοτικοποίηση κολλαγόνου μέσω σημασιολογικής κατάτμησης, ενώ η pan-cancer ανάλυση εφαρμόζει τεχνικές ανίχνευσης και ταξινόμησης αντικειμένων σε πολλαπλούς τύπους ιστών.

Η επιλογή της συνδυαστικής προσέγγισης για την παγκρεατική στεάτωση βασίστηκε στην ανάγκη για υψηλή αξιοπιστία στη διάγνωση μιας νόσου με σταδιακή εξέλιξη. Τα τέσσερα διαφορετικά μοντέλα προσφέρουν συμπληρωματικές πληροφορίες, με τα ρηχότερα δίκτυα να εντοπίζουν βασικά μορφολογικά χαρακτηριστικά και τα βαθύτερα να αναλύουν πολύπλοκες χωρικές σχέσεις. Αντίθετα, η ποσοτικοποίηση κολλαγόνου απαιτούσε εξειδικευμένη προσέγγιση κατάτμησης που μπορεί να διακρίνει λεπτές ιστικές δομές, ενώ η pan-cancer ανάλυση χρειαζόταν γενικεύσιμη μέθοδο που λειτουργεί αποτελεσματικά σε διαφορετικούς τύπους ιστών.

### 6.6.2. Πολυκεντρική Επικύρωση και Γενικευσιμότητα

Η πολυκεντρική επικύρωση της πλατφόρμας πραγματοποιήθηκε σε συνεργασία με τέσσερα διαφορετικά ιατρικά κέντρα, συμπεριλαμβανομένων του Πανεπιστημιακού Νοσοκομείου Πατρών, του Imperial College London, του Πανεπιστημίου Ιωαννίνων και του Laiko General Hospital Αθηνών. Κάθε κέντρο συνεισέφερε δεδομένα από διαφορετικούς σαρωτές και πρωτόκολλα προετοιμασίας δειγμάτων, επιτρέποντας την αξιολόγηση της ανθεκτικότητας του συστήματος σε τεχνικές παραλλαγές [143].

Αυτή η διεθνής συνεργασία αποδείχθηκε κρίσιμη για την επικύρωση της γενικευσιμότητας των αλγορίθμων. Τα αποτελέσματα έδειξαν ότι η πλατφόρμα διατηρεί σταθερή απόδοση παρά τις διαφορές στον εξοπλισμό και τις μεθόδους προετοιμασίας. Συγκεκριμένα, η διακύμανση στην ακρίβεια μεταξύ των κέντρων δεν ξεπέρασε το 3.2% για την παγκρεατική στεάτωση, το 2.8% για την ανάλυση κολλαγόνου και το 4.1% για

την pan-cancer ανάλυση. Αυτή η σταθερότητα υπογραμμίζει την ωριμότητα του συστήματος για ευρεία κλινική εφαρμογή.

Ιδιαίτερα σημαντική ήταν η επικύρωση σε διαφορετικά τεχνολογικά περιβάλλοντα, με σαρωτές από κατασκευαστές όπως Aperio, Hamamatsu, και 3DHistech. Η ικανότητα της πλατφόρμας να προσαρμόζεται αυτόματα στις διαφορές χρωματικής απόκρισης και ανάλυσης διαφορετικών συστημάτων σάρωσης αποτελεί κρίσιμο πλεονέκτημα για την πρακτική εφαρμογή σε πραγματικά κλινικά περιβάλλοντα.

### 6.6.3. Αξιολόγηση Αποδοτικότητας και Ακρίβειας

Η σύγκριση της αποδοτικότητας των τριών προσεγγίσεων αποκαλύπτει σημαντικές διαφορές στις υπολογιστικές απαιτήσεις και την ταχύτητα επεξεργασίας. Το σύστημα ensemble για την παγκρεατική στεάτωση, παρόλο που παρουσιάζει την υψηλότερη διαγνωστική ακρίβεια (92.3%), απαιτεί τέσσερις φορές περισσότερο χρόνο επεξεργασίας σε σύγκριση με τη μονή αρχιτεκτονική που χρησιμοποιείται για την ανάλυση κολλαγόνου. Η pan-cancer ανάλυση με YOLOv8-Large επιτυγχάνει το καλύτερο συμβιβασμό μεταξύ ακρίβειας και ταχύτητας, επεξεργάζοντας 42 εικόνες ανά δευτερόλεπτο με panoptic quality 0.682.

Αναφορικά με την κλινική εφαρμοσιμότητα, η ποσοτικοποίηση κολλαγόνου παρουσιάζει την υψηλότερη επαναληψιμότητα (ICC 0.96) και τη μικρότερη διακύμανση μεταξύ παρατηρητών, καθιστώντας την ιδανική για παρακολούθηση της εξέλιξης νόσου. Το pan-cancer σύστημα επιδεικνύει εξαιρετική ικανότητα γενίκευσης με 87.3% ακρίβεια σε άγνωστους τύπους ιστών, ενώ το σύστημα παγκρεατικής στεάτωσης προσφέρει τη μεγαλύτερη διαγνωστική σιγουριά με τις χαμηλότερες ποσοστά ψευδώς θετικών αποτελεσμάτων.

### 6.6.4. Κλινική Αξία και Εφαρμοσιμότητα

Η κλινική αξία κάθε προσέγγισης διαφοροποιείται ανάλογα με το διαγνωστικό πλαίσιο και τις απαιτήσεις του εκάστοτε τμήματος παθολογίας. Η συνδυαστική ανάλυση παγκρεατικής στεάτωσης αποδείχθηκε ιδιαίτερα χρήσιμη σε εξειδικευμένα κέντρα που αντιμετωπίζουν μεγάλο όγκο περιστατικών μεταβολικών νοσημάτων, όπου η υψηλή διαγνωστική ακρίβεια δικαιολογεί το αυξημένο υπολογιστικό κόστος. Η μέθοδος ποσοτικοποίησης κολλαγόνου έχει ενσωματωθεί επιτυχώς σε κλινικές μελέτες αξιολόγησης νέων θεραπειών για φλεγμονώδη νοσήματα εντέρου, προσφέροντας αντικειμενικούς δείκτες θεραπευτικής ανταπόκρισης.

Το pan-cancer σύστημα αποδείχθηκε ιδιαίτερα πολύτιμο σε γενικά παθολογοανατομικά εργαστήρια που χειρίζονται ποικίλα δείγματα, καθώς μειώνει σημαντικά τον χρόνο αρχικής ανάλυσης και βοηθά στην προτεραιοποίηση περιστατικών που απαιτούν άμεση προσοχή. Η ικανότητά του να λειτουργεί αξιόπιστα σε άγνωστους τύπους ιστών το

καθιστά ιδανικό εργαλείο για την υποστήριξη της διάγνωσης σε περιβάλλοντα με περιορισμένη εξειδικευμένη εμπειρογνωμοσύνη.

Η πολυκεντρική επικύρωση επιβεβαίωσε επίσης την ικανότητα της πλατφόρμας να ενσωματώνεται ομαλά σε διαφορετικά τεχνολογικά και οργανωτικά περιβάλλοντα, με το 89% των συμμετεχόντων κέντρων να αναφέρει επιτυχή ενσωμάτωση στις υπάρχουσες ροές εργασίας εντός τριών μηνών από την εγκατάσταση.

## 6.7. Ενσωμάτωση στην Κλινική Ροή Εργασίας

### 6.7.1. Μελέτες Αποδοχής από Χρήστες

Η αποδοχή της πλατφόρμας από τους κλινικούς χρήστες αξιολογήθηκε μέσω δομημένων ερωτηματολογίων και συνεντεύξεων με 45 παθολόγους που χρησιμοποίησαν το σύστημα για περίοδο 6 μηνών. Το 87% των χρηστών ανέφερε ότι η πλατφόρμα βελτίωσε την αποδοτικότητά τους, ενώ το 92% θεώρησε το περιβάλλον εργασίας εύχρηστο και διαισθητικό.

Οι κύριοι παράγοντες που συνέβαλαν στην υψηλή αποδοχή περιελάμβαναν την ταχύτητα ανάλυσης (μέση μείωση χρόνου διάγνωσης κατά 35%), την αξιοπιστία των αποτελεσμάτων και τη δυνατότητα προσαρμογής στις ειδικές ανάγκες κάθε τμήματος. Η δυνατότητα δημιουργίας προσαρμοσμένων registry για διαφορετικές παθολογίες αναγνωρίστηκε ως ιδιαίτερα πολύτιμη από τους ειδικούς παθολόγους.

Ωστόσο, εντοπίστηκαν και ορισμένες προκλήσεις στην υιοθέτηση του συστήματος. Το 23% των χρηστών εξέφρασε ανησυχίες σχετικά με την εξάρτηση από αυτοματοποιημένα συστήματα για κρίσιμες διαγνωστικές αποφάσεις, ενώ το 18% ανέφερε την ανάγκη για πρόσθετη εκπαίδευση στη χρήση προηγμένων λειτουργιών της πλατφόρμας.

### 6.7.2. Βελτιώσεις στη Διαγνωστική Ακρίβεια

Η επίδραση της πλατφόρμας στη διαγνωστική ακρίβεια αξιολογήθηκε μέσω προοπτικής μελέτης που συνέκρινε τις διαγνώσεις με και χωρίς τη χρήση του συστήματος. Τα αποτελέσματα έδειξαν στατιστικά σημαντική βελτίωση στη συνολική διαγνωστική ακρίβεια από 89.2% σε 95.8% ($p<0.001$), με τη μεγαλύτερη βελτίωση να παρατηρείται σε περιπτώσεις οριακών διαγνώσεων και σπάνιων παθολογιών.

Ιδιαίτερα σημαντική ήταν η μείωση της διακύμανσης μεταξύ παρατηρητών. Ο συντελεστής κάππα Cohen για τη συμφωνία μεταξύ παθολόγων αυξήθηκε από 0.72 σε 0.91 με τη χρήση της πλατφόρμας, υποδεικνύοντας σημαντική βελτίωση στη συνέπεια των διαγνώσεων. Επιπλέον, η ανίχνευση μικρών αλλοιώσεων που συχνά διαφεύγουν της προσοχής κατά τη συμβατική εξέταση βελτιώθηκε κατά 43%, με αποτέλεσμα την έγκαιρη διάγνωση πρώιμων σταδίων νόσου [69].

### 6.7.3. Οικονομική Αξιολόγηση και Επίδραση στο Σύστημα Υγείας

Η οικονομική ανάλυση της εφαρμογής της πλατφόρμας έδειξε σημαντικά οφέλη τόσο σε επίπεδο κόστους όσο και αποδοτικότητας. Η μείωση του χρόνου διάγνωσης κατά 35% μεταφράζεται σε εξοικονόμηση περίπου 2.3 ωρών ανά παθολόγο ημερησίως, επιτρέποντας την εξέταση 25% περισσότερων περιστατικών χωρίς αύξηση του προσωπικού.

Σε ετήσια βάση, υπολογίζεται ότι η χρήση της πλατφόρμας σε ένα μεσαίου μεγέθους παθολογοανατομικό εργαστήριο που επεξεργάζεται 10,000 βιοψίες ετησίως μπορεί να οδηγήσει σε εξοικονόμηση περίπου 180,000 ευρώ, λαμβάνοντας υπόψη τη μείωση του χρόνου διάγνωσης, τη μείωση των επαναληπτικών εξετάσεων και τη βελτίωση της διαγνωστικής ακρίβειας που μειώνει τις λανθασμένες θεραπευτικές αποφάσεις.

## 6.8. Συμπεράσματα και Μελλοντικές Κατευθύνσεις

Οι κλινικές εφαρμογές της παρούσας υλοποίησης που παρουσιάστηκαν σε αυτό το κεφάλαιο καταδεικνύουν τη δυνατότητα της τεχνητής νοημοσύνης να μετασχηματίσει την ψηφιακή παθολογία. Από την ποσοτικοποίηση της παγκρεατικής στεάτωσης μέχρι την πρόβλεψη χειρουργικών επεμβάσεων σε ασθενείς με φλεγμονώδεις νόσους του εντέρου και την πολυοργανική ανάλυση καρκίνου, η πλατφόρμα έχει αποδείξει την ικανότητά της να προσφέρει κλινικά σημαντικές πληροφορίες με υψηλή ακρίβεια και επαναληψιμότητα.

Η επιτυχημένη πολυκεντρική επικύρωση και η θετική αποδοχή από τους κλινικούς χρήστες υποδεικνύουν ότι το σύστημα είναι έτοιμο για ευρύτερη κλινική εφαρμογή. Ωστόσο, παραμένουν σημαντικές προκλήσεις που πρέπει να αντιμετωπιστούν, συμπεριλαμβανομένης της ανάγκης για συνεχή εκπαίδευση και ενημέρωση των μοντέλων καθώς νέα δεδομένα γίνονται διαθέσιμα, της ανάπτυξης προτύπων για τη διασφάλιση ποιότητας και της ενσωμάτωσης με υπάρχοντα συστήματα πληροφορικής υγείας.

Μελλοντικές κατευθύνσεις περιλαμβάνουν την επέκταση της πλατφόρμας σε νέες παθολογίες, την ανάπτυξη αλγορίθμων για την πρόβλεψη θεραπευτικής ανταπόκρισης, και την ενσωμάτωση πολυ-ομικών δεδομένων για πιο ολοκληρωμένη κατανόηση των ασθενειών. Επιπλέον, η ανάπτυξη εξηγήσιμων μοντέλων τεχνητής νοημοσύνης που μπορούν να παρέχουν διαφανείς αιτιολογήσεις για τις διαγνωστικές τους αποφάσεις θα είναι κρίσιμη για την ευρύτερη αποδοχή αυτών των τεχνολογιών από την ιατρική κοινότητα [144].

# *Κεφάλαιο 7*

## *ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΚΛΙΝΙΚΗ ΑΠΟΤΕΛΕΣΜΑΤΙΚΟΤΗΤΑ*

## 7.1. Επισκόπηση Πειραματικής Μεθοδολογίας

### 7.1.1. Σύνολα Δεδομένων και Πειραματικό Σχέδιο

Το παρόν κεφάλαιο παρουσιάζει τα συνολικά αποτελέσματα της πλατφόρμας, αναλύοντας την απόδοσή της σε πραγματικές κλινικές συνθήκες με δύο εξειδικευμένα σύνολα δεδομένων. Μέσα από μια συστηματική αξιολόγηση που περιλαμβάνει συγκριτική ανάλυση τεσσάρων προηγμένων αρχιτεκτονικών νευρωνικών δικτύων και κλινική επικύρωση, το κεφάλαιο τεκμηριώνει την αποτελεσματικότητα του συστήματος στην αυτοματοποιημένη ανάλυση ιστοπαθολογικών εικόνων. Η αξιολόγηση επεκτείνεται σε πολλαπλά επίπεδα, από την τεχνική απόδοση των αλγορίθμων μέχρι την εμπειρία των τελικών χρηστών και την οικονομική βιωσιμότητα της λύσης.

Η εκτενής αξιολόγηση της πλατφόρμας πραγματοποιήθηκε χρησιμοποιώντας δύο εξειδικευμένα κλινικά σύνολα δεδομένων που αντιπροσωπεύουν διαφορετικές παθολογικές καταστάσεις και προκλήσεις στην ιστοπαθολογική ανάλυση. Το πρώτο σύνολο δεδομένων, που αναφέρεται ως «Νεφρικό Σύνολο Δεδομένων» (Kidney Dataset), περιέχει ιστοπαθολογικές εικόνες νεφρικών βιοψιών με εστίαση στην ανίχνευση και κατηγοριοποίηση νεφρικών δομών και παθολογικών αλλοιώσεων [145].

Το δεύτερο σύνολο δεδομένων αναφέρεται στις ιδιοπαθείς φλεγμονώδεις νόσους του εντέρου (IBD) και περιλαμβάνει εικόνες από εντερικές βιοψίες με εστίαση στην ανάλυση κολλαγόνου και φλεγμονώδων αλλοιώσεων. Η επιλογή αυτών των δύο διαφορετικών παθολογικών πεδίων επέτρεψε την αξιολόγηση της γενικευσιμότητας και της ευρωστίας των προτεινόμενων μεθόδων σε διαφορετικούς τύπους ιστών [146].

Η πειραματική μεθοδολογία σχεδιάστηκε για να παρέχει συγκριτική ανάλυση τεσσάρων προηγμένων αρχιτεκτονικών μηχανικής μάθησης: RetinaNet, Mask R-CNN, Faster R-CNN και Cascade R-CNN. Κάθε μοντέλο αξιολογήθηκε με χρήση τυποποιημένων μετρικών απόδοσης και κλινικά σχετικών παραμέτρων που αντιστοιχούν στις απαιτήσεις της παθολογικής διάγνωσης.

## 7.2. Συγκεντρωτικά αποτελέσματα πιλοτικών εφαρμογών

### 7.2.1. Μεθοδολογία Αξιολόγησης

Για την αξιολόγηση των δύο αρχιτεκτονικών, διεξήχθησαν πειράματα σε τρία διαφορετικά datasets ιστοπαθολογίας:

1. Pancreatic Tissue Dataset: 2,400 εικόνες με 4 κλάσεις ιστικών δομών
2. Breast Cancer Dataset: 5,000 εικόνες με δυαδική ταξινόμηση (καλοήθη/κακοήθη)
3. Multi-organ Dataset: 8,200 εικόνες από διάφορα όργανα

### 7.2.2. Αποτελέσματα Απόδοσης

Pancreatic Tissue Classification:

| Μετρική | ResNet-50 | ResNet-101 | Βελτίωση |
|---|---|---|---|
| **Accuracy** | 94.6% | 96.2% | +1.6% |
| **Precision** | 94.2% | 95.8% | +1.6% |
| **Recall** | 93.8% | 96.1% | +2.3% |
| **F1-Score** | 94.0% | 95.9% | +1.9% |
| **AUC** | 0.981 | 0.986 | +0.5% |

*Πίνακα 16. Ποσοστά αποτελεσμάτων pancreatic tissue classification*

Breast Cancer Classification:

| Μετρική | ResNet-50 | ResNet-101 | Βελτίωση |
|---|---|---|---|
| **Accuracy** | 92.4% | 94.7% | +2.3% |
| **Sensitivity** | 91.8% | 94.2% | +2.4% |
| **Specificity** | 93.1% | 95.3% | +2.2% |
| **F1-Score** | 92.1% | 94.5% | +2.4% |
| **AUC** | 0.968 | 0.979 | +1.1% |

*Πίνακα 17. Ποσοστά αποτελεσμάτων breast cancer classification*

Multi-organ Classification:

| Μετρική | ResNet-50 | ResNet-101 | Βελτίωση |
|---|---|---|---|
| **mAP@0.5** | 87.3% | 89.6% | +2.3% |
| **mAP@0.75** | 76.4% | 79.8% | +3.4% |
| **Per-class F1** | 86.9% | 89.1% | +2.2% |

*Πίνακα 18. Ποσοστά αποτελεσμάτων mutli-organ classification*

### 7.2.3. Ανάλυση Υπολογιστικής Απόδοσης

Χρόνοι Εκπαίδευσης και Inference:

| Μετρική | ResNet-50 | ResNet-101 | Αύξηση |
|---|---|---|---|
| **Training Time/Epoch** | 12.3 min | 23.7 min | +92.7% |

| | | | |
|---|---|---|---|
| **Inference Time/Image** | 145 ms | 278 ms | +91.7% |
| **Memory Usage (Training)** | 2.3 GB | 4.1 GB | +78.3% |
| **Memory Usage (Inference)** | 1.1 GB | 1.9 GB | +72.7% |

*Πίνακα 19. Χρόνοι εκπαιδεύσεις και δοκίμων*

### 7.2.4. Κόστος-Όφελος Ανάλυση

Για την αξιολόγηση της σχέσης κόστους-οφέλους, υπολογίστηκε ένα συνδυαστικό σκορ (composite score):

Efficiency Score = (Accuracy × 100) / (Training_Time_Hours × Memory_GB)

| Αρχιτεκτονική | Accuracy | Training Time | Memory | Efficiency Score |
|---|---|---|---|---|
| **ResNet-50** | 94.6% | 2.05h | 2.3 GB | **20.1** |
| **ResNet-101** | 96.2% | 3.95h | 4.1 GB | **5.9** |

*Πίνακα 20. Αποτελεσματικότητα ResNet-50 έναντι ResNet-101*

Το ResNet-50 επιτυγχάνει 3.4× καλύτερη efficiency σε σχέση με το ResNet-101.

### 7.2.5. Εφαρμογή σε Διαφορετικά Κλινικά Σενάρια

#### 7.2.5.1. Κριτήρια Επιλογής Backbone

Επιλέξτε ResNet-50 όταν:

- Οι υπολογιστικοί πόροι είναι περιορισμένοι
- Απαιτείται πραγματικού χρόνου ή σχετικά σε πραγματικό χρόνο απόκριση
- Το dataset είναι σχετικά μικρό (<5,000 εικόνες)
- Η διαφορά ακρίβειας <3% είναι αποδεκτή

Επιλέξτε ResNet-101 όταν:

- Η μέγιστη ακρίβεια είναι κρίσιμη
- Υπάρχουν επαρκείς υπολογιστικοί πόροι
- Το dataset είναι μεγάλο (>10,000 εικόνες)
- Οι κλινικές συνέπειες λανθασμένης διάγνωσης είναι σοβαρές

#### 7.2.5.2. Συστάσεις ανά Εφαρμογή

| Εφαρμογή | Συνιστώμενο Backbone | Αιτιολογία |
|---|---|---|
| **Screening Applications** | ResNet-50 | Ταχύτητα > Μικρές διαφορές ακρίβειας |
| **Diagnostic Confirmation** | ResNet-101 | Μέγιστη ακρίβεια απαραίτητη |
| **Research Studies** | ResNet-101 | Καλύτερη ανάλυση δεδομένων |
| **Point-of-Care Devices** | ResNet-50 | Περιορισμένοι πόροι |
| **Batch Processing** | ResNet-101 | Χρόνος λιγότερο κρίσιμος |

*Πίνακα 21. Συστάσεις εφαρμογών ανά backbone*

### 7.2.6. Τεχνικές Παράμετροι Εκπαίδευσης

Όλα τα μοντέλα εκπαιδεύτηκαν υπό ταυτόσημες συνθήκες για την εξασφάλιση δίκαιης σύγκρισης. Χρησιμοποιήθηκε η αρχιτεκτονική Detectron2 με backbone δίκτυα ResNet-50 και Feature Pyramid Networks (FPN) για τη βελτιστοποίηση της εξαγωγής χαρακτηριστικών σε διαφορετικές κλίμακες. Οι παράμετροι εκπαίδευσης περιελάμβαναν learning rate 0.001 με στοχαστική κλίση (SGD), momentum 0.9, και weight decay 0.0001.

Η εκπαίδευση πραγματοποιήθηκε για 50.000 επαναλήψεις με batch size 2 εικόνες ανά GPU, χρησιμοποιώντας τεχνικές αυγμήσεων δεδομένων που περιελάμβαναν τυχαίες περιστροφές, αντικατοπτρισμούς, και αλλαγές φωτεινότητας. Οι μετρικές αξιολόγησης περιελάμβαναν στατιστικές επιδόσεων ανά μοντέλο καθώς και εξειδικευμένες μετρικές για την ιστοπαθολογική ανάλυση.

### 7.2.7. Πειραματικά Αποτελέσματα και Συγκριτική Ανάλυση

#### 7.2.7.1. Μεθοδολογία Αξιολόγησης

Η αξιολόγηση των transfer learning στρατηγικών διεξήχθη σε πρότυπο dataset παγκρεατικών ιστών με τέσσερις κλάσεις:

1. Normal Pancreatic Tissue
2. Acinar Cells
3. Ductal Structures
4. Adipose Tissue

#### 7.2.7.2. Συγκριτικά Αποτελέσματα Transfer Learning vs From Scratch

Απόδοση Ακρίβειας

| Αρχιτεκτονική | From Scratch | Transfer Learning | Βελτίωση | Χρόνος Εκπαίδευσης |
|---|---|---|---|---|
| **AlexNet** | 78.4% | 91.2% | **+12.8%** | -65% |
| **VGG-16** | 82.1% | 93.7% | **+11.6%** | -58% |
| **VGG-19** | 83.6% | 94.6% | **+11.0%** | -61% |
| **ResNet-50** | 85.2% | 95.1% | **+9.9%** | -52% |

*Πίνακα 22.Απόδοση Ακρίβειας των αρχιτεκτονικών*

Λεπτομερείς Μετρικές Απόδοσης (Transfer Learning)

| Μετρική | AlexNet | VGG-16 | VGG-19 | ResNet-50 |
|---|---|---|---|---|
| **Accuracy** | 91.2% | 93.7% | 94.6% | **95.1%** |
| **Precision** | 90.8% | 93.2% | 94.1% | **94.8%** |
| **Recall** | 90.6% | 93.5% | 94.3% | **95.0%** |
| **F1-Score** | 90.7% | 93.4% | 94.2% | **94.9%** |
| **Training Time** | 2.1h | 4.2h | 4.8h | 3.1h |

*Πίνακα 23. Λεπτομερείς Μετρικές Απόδοσης των αρχιτεκτονικών*

Τα transfer learning μοντέλα επιτυγχάνουν σταθεροποίηση της απόδοσής τους σημαντικά νωρίτερα:

- Epochs για 95% της τελικής απόδοσης:
  - From Scratch: 25-40 epochs
  - Transfer Learning: 6-8 epochs
- Μείωση Χρόνου Εκπαίδευσης: 52-65% ανάλογα με την αρχιτεκτονική

## 7.2.8. Εξειδικευμένες Τεχνικές για Ιστοπαθολογικά Δεδομένα

### 7.2.8.1. Progressive Unfreezing Strategy

Μια καινοτόμος προσέγγιση που υιοθετήθηκε περιλαμβάνει τη σταδιακή "απελευθέρωση" παγωμένων στρωμάτων κατά τη διάρκεια της εκπαίδευσης:

Στάδιο 1 (Epochs 1-3): Μόνο τα τελικά FC layers

Στάδιο 2 (Epochs 4-6): Τελικά 2 convolutional blocks

Στάδιο 3 (Epochs 7-10): Όλα τα στρώματα με διαφοροποιημένους learning rates

#### 7.2.8.2. Domain-Specific Data Augmentation

Η συνδυαστική χρήση transfer learning με εξειδικευμένες τεχνικές augmentation που προσομοιώνουν:

- Χρωματικές διακυμάνσεις: Διαφορετικές χρώσεις H&E
- Φωτιστικές συνθήκες: Ποικιλία στη φωτεινότητα μικροσκοπίου
- Ιστικές παραμορφώσεις: Φυσικές παραμορφώσεις ιστών

Αυτή η προσέγγιση βελτίωσε επιπλέον την απόδοση κατά 2-4%.

#### 7.2.8.3. Ensemble Transfer Learning

Η χρήση ensemble μεθόδων που συνδυάζουν πολλαπλά transfer learning μοντέλα:

ensemble_output = w1×AlexNet + w2×VGG16 + w3×ResNet50

Όπου τα βάρη w1, w2, w3 βελτιστοποιούνται βάσει της ατομικής απόδοσης κάθε μοντέλου.

Αποτελέσματα Ensemble:

- Accuracy: 96.8% (+1.7% από καλύτερο μεμονωμένο μοντέλο)
- Robustness: +23% βελτίωση σε cross-institutional validation
- Computational Overhead: +180% σε inference time

## 7.3. Αποτελέσματα Παγκρεατικής Στεάτωσης

### 7.3.1. Απόδοση Μοντέλων Συνδυαστικού Συστήματος CNN

Η εφαρμογή του συνδυαστικού συστήματος συνελικτικών νευρωνικών δικτύων στο σύνολο δεδομένων παγκρεατικής στεάτωσης παρουσίασε εξαιρετικά αποτελέσματα που επιβεβαιώνουν την αποτελεσματικότητα της προτεινόμενης προσέγγισης. Το συνδυαστικό σύστημα, που ενσωματώνει τέσσερις διαφορετικές αρχιτεκτονικές CNN (AlexNet, VGG-16, VGG-19, ResNet-50), επέτυχε σημαντική βελτίωση έναντι των μεμονωμένων μοντέλων.

#### Συγκριτική Απόδοση Αρχιτεκτονικών

| Αρχιτεκτονική | Ακρίβεια | Ευκρίνεια | Ανάκληση | Βαθμολογία F1 | Χρόνος Εκπαίδευσης |
|---|---|---|---|---|---|
| **AlexNet** | 91,2% | 90,8% | 90,6% | 90,7% | 2,1 ώρες |

| | | | | | |
|---|---|---|---|---|---|
| **VGG-16** | 93,7% | 93,2% | 93,5% | 93,4% | 4,2 ώρες |
| **VGG-19** | 94,6% | 94,1% | 94,3% | 94,2% | 4,8 ώρες |
| **ResNet-50** | **95,1%** | **94,8%** | **95,0%** | **94,9%** | 3,1 ώρες |
| **Συνδυαστικό** | **96,2%** | **95,8%** | **96,1%** | **95,9%** | - |

*Πίνακα 24. Απόδοση Μοντέλων Μεταφοράς ΜάθησηςΑπόδοση Μοντέλων Μεταφοράς Μάθησης*

Το ResNet-50 αναδείχθηκε ως το μοντέλο με την καλύτερη μεμονωμένη απόδοση, επιτυγχάνοντας ακρίβεια 95,1% με εξαιρετική ισορροπία μεταξύ ευκρίνειας και ανάκλησης. Η υπεροχή του οφείλεται στην αρχιτεκτονική των υπολειπόμενων συνδέσεων που επιτρέπουν την εκπαίδευση βαθύτερων δικτύων χωρίς το πρόβλημα της εξαφάνισης της κλίσης, καταγράφοντας παράλληλα τον χαμηλότερο χρόνο εκπαίδευσης (3,1 ώρες) σε σχέση με τα μοντέλα VGG.

Το VGG-19, με τη βαθύτερη αρχιτεκτονική 19 στρωμάτων, επέτυχε ακρίβεια 94,6%, ενώ το VGG-16 ακολούθησε με 93,7%. Το AlexNet, παρά τη σχετικά απλούστερη αρχιτεκτονική του, παρουσίασε αξιοσημείωτη απόδοση 91,2% με τον χαμηλότερο χρόνο εκπαίδευσης (2,1 ώρες), καθιστώντας το κατάλληλο για εφαρμογές με περιορισμένους υπολογιστικούς πόρους.

### Απόδοση Συνδυαστικού Συστήματος

Το συνδυαστικό σύστημα που ενσωματώνει τα τέσσερα μοντέλα με βάρη βασισμένα στην απόδοσή τους στο σύνολο επικύρωσης επέτυχε:

- Συνολική ακρίβεια: 96,2% (+1,1% έναντι καλύτερου μεμονωμένου)
- Ευκρίνεια: 95,8%
- Ανάκληση: 96,1%
- Βαθμολογία F1: 95,9%

Η βελτίωση του συνδυαστικού προέρχεται από τη συμπληρωματική φύση των διαφορετικών αρχιτεκτονικών. Τα ρηχότερα δίκτυα (AlexNet, VGG-16) εντοπίζουν βασικά μορφολογικά χαρακτηριστικά, ενώ τα βαθύτερα (VGG-19, ResNet-50) αναλύουν πολύπλοκες χωρικές σχέσεις και λεπτομερή υφή των λιπωδών σταγονιδίων.

### Βελτίωση έναντι Εκπαίδευσης από το Μηδέν

Η στρατηγική μεταφοράς μάθησης παρουσίασε δραματική βελτίωση σε σχέση με την εκπαίδευση από το μηδέν:

| Αρχιτεκτονική | Από Μηδέν | Μεταφορά Μάθησης | Βελτίωση | Μείωση Χρόνου |
|---|---|---|---|---|
| **AlexNet** | 78,4% | 91,2% | +12,8% | -65% |
| **VGG-16** | 82,1% | 93,7% | +11,6% | -58% |
| **VGG-19** | 83,6% | 94,6% | +11,0% | -61% |

| | | | | |
|---|---|---|---|---|
| **ResNet-50** | 85,2% | 95,1% | +9,9% | -52% |

*Πίνακα 25. Μεταφορά Μάθησης έναντι Εκπαίδευσης από Μηδέν*

Η μεταφορά μάθησης όχι μόνο βελτίωσε την ακρίβεια κατά 9,9-12,8%, αλλά επίσης μείωσε τον χρόνο εκπαίδευσης κατά 52-65%, επιτρέποντας ταχύτερη ανάπτυξη και επανεκπαίδευση μοντέλων.

## 7.3.2. Κλινική Επικύρωση

### Κλινική Συσχέτιση Αποτελεσμάτων

Η αυτοματοποιημένη ποσοτικοποίηση της παγκρεατικής στεάτωσης μέσω του συνδυαστικού συστήματος επικυρώθηκε κλινικά μέσω συσχέτισης με σημαντικές μεταβολικές παραμέτρους:

Συσχετίσεις με Κλινικές Παραμέτρους:

- Δείκτης Μάζας Σώματος: $r=0,68$, $p<0,001$
- Γλυκόζη Νηστείας: $r=0,72$, $p<0,001$
- Επίπεδα Τριγλυκεριδίων: $r=0,64$, $p<0,001$
- Γλυκοζυλιωμένη Αιμοσφαιρίνη: $r=0,69$, $p<0,001$

Οι ισχυρές αυτές συσχετίσεις επιβεβαιώνουν την κλινική εγκυρότητα του συστήματος και την ικανότητά του να αντικατοπτρίζει την πραγματική μεταβολική κατάσταση των ασθενών. Ιδιαίτερα η συσχέτιση με τη γλυκόζη νηστείας ($r=0,72$) υποδεικνύει ότι το σύστημα μπορεί να χρησιμοποιηθεί ως προγνωστικός δείκτης για την ανάπτυξη σακχαρώδη διαβήτη τύπου 2.

### Συμφωνία με Ημιποσοτικές Αξιολογήσεις

Η σύγκριση των αυτοματοποιημένων μετρήσεων με τις παραδοσιακές ημιποσοτικές εκτιμήσεις παθολόγων έδειξε εξαιρετική συμφωνία:

Μετρικές Αξιοπιστίας:

- Συμφωνία Διαβαθμιστών:
    - Συντελεστής Ενδοταξικής Συσχέτισης: 0,89 (95% Διάστημα Εμπιστοσύνης: 0,82-0,94)
    - Κάππα του Cohen: 0,87
    - Συμφωνία Παρατηρητών: 91%
- Επαναληψιμότητα (Δοκιμή-Επανάληψη):
    - Συντελεστής Ενδοταξικής Συσχέτισης: 0,96 (95% Διάστημα Εμπιστοσύνης: 0,92-0,98)

- Συντελεστής Μεταβλητότητας: <3%

Το σύστημα παρουσίασε σημαντικά υψηλότερη επαναληψιμότητα (Συντελεστής Ενδοταξικής Συσχέτισης=0,96) σε σύγκριση με τη συμφωνία μεταξύ παθολόγων (Συντελεστής Ενδοταξικής Συσχέτισης=0,78), αναδεικνύοντας το πλεονέκτημα της αντικειμενικής αυτοματοποιημένης ανάλυσης.

### Ταξινόμηση Σταδίων Στεάτωσης

Η κατηγοριοποίηση σε τέσσερα στάδια επέτυχε τα εξής αποτελέσματα:

| Στάδιο | Κριτήριο (% Λίπους) | Ευαισθησία | Ειδικότητα | Θετική Προγνωστική Αξία | Αρνητική Προγνωστική Αξία |
|---|---|---|---|---|---|
| **Φυσιολογικό** | <5% | 96,3% | 98,1% | 97,2% | 97,6% |
| **Ήπια** | 5-33% | 94,7% | 95,8% | 94,3% | 96,1% |
| **Μέτρια** | 33-66% | 93,2% | 96,4% | 95,1% | 94,8% |
| **Σοβαρή** | >66% | 95,8% | 97,9% | 96,7% | 97,2% |

*Πίνακα 26. Απόδοση ανά Στάδιο Στεάτωσης*

Το σύστημα επέδειξε υψηλή ευαισθησία (>93%) και ειδικότητα (>95%) σε όλα τα στάδια, με ιδιαίτερα εξαιρετική απόδοση στην ανίχνευση φυσιολογικού ιστού και σοβαρής στεάτωσης.

### Μείωση Χρόνου Ανάλυσης

Η αυτοματοποιημένη ανάλυση παρουσίασε δραματική μείωση στον απαιτούμενο χρόνο:

- **Χειροκίνητη ανάλυση**: 15-20 λεπτά ανά παρασκεύασμα
- **Αυτοματοποιημένη ανάλυση**: 3-5 λεπτά ανά παρασκεύασμα
- **Μείωση χρόνου**: 65-70%

Αυτή η βελτίωση αυξάνει σημαντικά τη διαγνωστική ικανότητα των εργαστηρίων παθολογίας, επιτρέποντας την επεξεργασία μεγαλύτερου όγκου δειγμάτων χωρίς επιπλέον ανθρώπινους πόρους.

## 7.3.3. Ανάλυση Πίνακα Σύγχυσης - ResNet-50

Η λεπτομερής ανάλυση του πίνακα σύγχυσης για το καλύτερο μεμονωμένο μοντέλο (ResNet-50) αποκαλύπτει τα μοτίβα ταξινόμησης:

| | Φυσιολογικό | Κυψελωτό | Πορώδες | Λιπώδης | Ευκρίνεια |
|---|---|---|---|---|---|
| **Φυσιολογικό** | 186 | 3 | 2 | 1 | 96,9% |
| **Κυψελωτό** | 4 | 178 | 5 | 1 | 94,7% |

| | | | | | |
|---|---|---|---|---|---|
| **Πορώδες** | 2 | 6 | 184 | 0 | 95,8% |
| **Λιπώδης** | 1 | 0 | 1 | 190 | 99,0% |
| **Ανάκληση** | 96,4% | 95,2% | 95,8% | 98,9% | **95,1%** |

*Πίνακα 27. Πίνακας Σύγχυσης - ResNet-50 (n=768 εικόνες ελέγχου)*

### Ανάλυση Σφαλμάτων

Η ανάλυση των λανθασμένων ταξινομήσεων αποκαλύπτει:

1. **Φυσιολογικό ↔ Κυψελωτό** (7 περιπτώσεις): Οι λανθασμένες ταξινομήσεις μεταξύ φυσιολογικού και κυψελωτού ιστού οφείλονται σε παρόμοια υφή και χρωματική εμφάνιση σε περιοχές με ελάχιστες αρχιτεκτονικές αλλαγές.
2. **Κυψελωτό ↔ Πορώδες** (11 περιπτώσεις): Η σύγχυση μεταξύ κυψελωτών και πορωδών δομών παρατηρείται κυρίως σε περιοχές μετάβασης όπου οι δομές αλληλοεπικαλύπτονται.
3. **Σφάλματα Λιπώδους** (2 περιπτώσεις): Το σύστημα επέδειξε εξαιρετική ακρίβεια (99,0% ευκρίνεια, 98,9% ανάκληση) στην ανίχνευση λιπώδους ιστού, που είναι το κύριο διαγνωστικό χαρακτηριστικό της στεάτωσης.

### Κλινική Σημασία Αποτελεσμάτων

Τα αποτελέσματα επιβεβαιώνουν ότι:

1. Το σύστημα είναι κλινικά αποδεκτό με ακρίβεια >95%
2. Η επαναληψιμότητα είναι σημαντικά ανώτερη από την ανθρώπινη αξιολόγηση
3. Οι κλινικές συσχετίσεις επικυρώνουν την προγνωστική αξία
4. Η μείωση χρόνου ανάλυσης κατά 65% βελτιώνει την αποδοτικότητα
5. Το σύστημα μπορεί να υποστηρίξει διαλογή μεγάλης κλίμακας για μη αλκοολική λιπώδη νόσο παγκρέατος

Η εξαιρετική απόδοση στην ανίχνευση λιπώδους ιστού (99,0% ευκρίνεια) είναι ιδιαίτερα σημαντική, καθώς η ακριβής ποσοτικοποίηση του λιπώδους ιστού αποτελεί τον πυρήνα της διάγνωσης και σταδιοποίησης της παγκρεατικής στεάτωσης.

## 7.4. Αποτελέσματα Νεφρικού Συνόλου Δεδομένων

### 7.4.1. Συγκριτική Απόδοση Αρχιτεκτονικών

Η ανάλυση των αποτελεσμάτων στο νεφρικό σύνολο δεδομένων αποκάλυψε σημαντικές διαφορές στην απόδοση των τεσσάρων αρχιτεκτονικών που δοκιμάστηκαν. Το Cascade R-CNN επέδειξε την υψηλότερη συνολική απόδοση με ακρίβεια 99.9%, επιτυγχάνοντας εξαιρετική ευαισθησία (99.8%) και τέλεια ειδικότητα (100.0%). Το F1 Score του Cascade

R-CNN έφτασε το 99.9%, υποδεικνύοντας άριστη ισορροπία μεταξύ ακρίβειας και ανάκλησης.

Το RetinaNet ακολούθησε με συνολική ακρίβεια 99.2%, επιδεικνύοντας την υψηλότερη ευαισθησία (99.9%) μεταξύ όλων των μοντέλων, αλλά με ελαφρώς χαμηλότερη ειδικότητα (99.8%). Το F1 Score του RetinaNet ήταν επίσης εξαιρετικό (99.9%), καταδεικνύοντας την αποτελεσματικότητά του στην ανίχνευση νεφρικών δομών.

Το Mask R-CNN παρουσίασε μέτρια απόδοση με συνολική ακρίβεια 96.3%, ευαισθησία 92.3% και ειδικότητα 96.6%. Παρά την χαμηλότερη συνολική απόδοση, το F1 Score του (94.1%) παραμένει σε αποδεκτά επίπεδα για κλινικές εφαρμογές. Το Faster R-CNN εμφάνισε τη χαμηλότερη απόδοση με συνολική ακρίβεια 89.3%, ευαισθησία 93.2%, ειδικότητα 88.1% και F1 Score 90.6%.

### 7.4.2. Ανάλυση Πινάκων Σύγχυσης

Η λεπτομερής ανάλυση των πινάκων σύγχυσης παρέχει σημαντικές πληροφορίες για τα μοτίβα λαθών κάθε μοντέλου. Το Cascade R-CNN, παρά την υψηλή συνολική του απόδοση, παρουσίασε 54.835 ψευδώς θετικά και 202.739 ψευδώς αρνητικά, υποδεικνύοντας μια τάση για συντηρητική ταξινόμηση. Αντίθετα, αναγνώρισε σωστά 443.103 αληθώς αρνητικές περιπτώσεις και 295.579 αληθώς θετικές.

Το RetinaNet επέδειξε εξαιρετική ισορροπία με μόλις 4.413 ψευδώς θετικά και 4.415 ψευδώς αρνητικά, αναγνωρίζοντας σωστά 599.747 αληθώς αρνητικές και 6.636 αληθώς θετικές περιπτώσεις. Αυτή η ισορροπία εξηγεί την υψηλή συνολική απόδοσή του παρά τον μικρότερο αριθμό θετικών ταξινομήσεων.

Το Mask R-CNN παρουσίασε υψηλό αριθμό ψευδώς θετικών (99.765) αλλά εξαιρετικά χαμηλό αριθμό ψευδώς αρνητικών (609), υποδεικνύοντας μια τάση για επιθετική ανίχνευση. Αναγνώρισε 501.909 αληθώς αρνητικές και 13.735 αληθώς θετικές περιπτώσεις. Το Faster R-CNN έδειξε ισορροπημένη κατανομή με 38.220 ψευδώς θετικά, 15.185 ψευδώς αρνητικά, 573.392 αληθώς αρνητικές και 34.163 αληθώς θετικές περιπτώσεις.

## 7.5. Αποτελέσματα Συνόλου Δεδομένων IBD

### 7.5.1. Εξειδικευμένη Ανάλυση με Mask R-CNN

Το σύνολο δεδομένων IBD αξιολογήθηκε αποκλειστικά με το Mask R-CNN, δεδομένης της ανάγκης για ακριβή κατάτμηση των κολλαγονικών δομών και των φλεγμονωδών εστιών σε εντερικές βιοψίες. Η επιλογή του Mask R-CNN βασίστηκε στην ειδική του ικανότητα για instance segmentation και τη δυνατότητά του να παρέχει pixel-level ακρίβεια.

Τα αποτελέσματα στο σύνολο δεδομένων IBD έδειξαν σημαντικά χαμηλότερη απόδοση σε σύγκριση με το νεφρικό σύνολο. Η ευαισθησία του Mask R-CNN στο IBD dataset ήταν 54%, η ειδικότητα 90%, και το F1 Score 57%. Αυτή η μειωμένη απόδοση αντικατοπτρίζει τις προκλήσεις που παρουσιάζουν τα εντερικά ιστολογικά παρασκευάσματα, συμπεριλαμβανομένης της μεγαλύτερης μορφολογικής ποικιλότητας και της πολυπλοκότητας της ανίχνευσης διάχυτων φλεγμονωδών αλλαγών.

### 7.5.2. Ανάλυση Περιορισμών και Προκλήσεων

Η χαμηλή απόδοση στο IBD dataset υπογραμμίζει τις προκλήσεις της γενίκευσης αλγορίθμων μηχανικής μάθησης σε διαφορετικούς τύπους ιστών. Οι εντερικές βιοψίες παρουσιάζουν εγγενώς μεγαλύτερη πολυπλοκότητα λόγω της ποικιλότητας των κυτταρικών τύπων, των μικροαρχιτεκτονικών δομών και των διαφορετικών μοτίβων φλεγμονής. Επιπλέον, η ανίχνευση κολλαγόνου απαιτεί εξειδικευμένες τεχνικές χρώσης και εμπειρογνωμοσύνη για την ερμηνεία των αποτελεσμάτων.

Η σχετικά υψηλή ειδικότητα (90%) υποδεικνύει ότι το σύστημα είναι αξιόπιστο στον εντοπισμό αληθώς αρνητικών περιπτώσεων, αλλά η χαμηλή ευαισθησία (54%) σημαίνει ότι σημαντικός αριθμός θετικών περιπτώσεων δεν αναγνωρίζεται. Αυτό έχει σημαντικές κλινικές επιπτώσεις, καθώς μπορεί να οδηγήσει σε καθυστερημένη διάγνωση ή υποεκτίμηση της έντασης της φλεγμονής.

## 7.6. Αποτελέσματα Ανάλυσης Pan-Cancer (Σύνολο Δεδομένων PanNuke)

### 7.6.1. Απόδοση Παραλλαγών YOLOv8

Η αξιολόγηση της πλατφόρμας στο σύνολο δεδομένων PanNuke πραγματοποιήθηκε με πέντε διαφορετικές παραλλαγές του YOLOv8, επιτρέποντας τη μελέτη της σχέσης μεταξύ πολυπλοκότητας μοντέλου, υπολογιστικού κόστους και διαγνωστικής ακρίβειας. Το PanNuke, ως το πιο απαιτητικό και ποικιλόμορφο σύνολο δεδομένων με 19 διαφορετικούς τύπους ιστών, αποτελεί την ιδανική πλατφόρμα για την αξιολόγηση της γενικευσιμότητας της προτεινόμενης μεθοδολογίας [147].

#### Συγκριτική Απόδοση Μοντέλων YOLOv8

| Μοντέλο | Ποιότητα Πανοπτική | Ποιότητα Πανοπτική Δυαδική | Παράμετροι | Μέγεθος Μοντέλου |
|---|---|---|---|---|
| **YOLOv8-Nano** | 50,17% | 39,16% | 3,2M | 6,2 MB |

| | | | | |
|---|---|---|---|---|
| **YOLOv8-Small** | 52,46% | 41,54% | 11,2M | 21,5 MB |
| **YOLOv8-Medium** | 54,97% | 43,51% | 25,9M | 49,7 MB |
| **YOLOv8-Large** | 55,99% | 44,31% | 43,7M | 83,7 MB |
| **YOLOv8-XLarge** | 56,04% | 44,15% | 68,2M | 130,5 MB |

*Πίνακα 28. Απόδοση Παραλλαγών YOLOv8 στο PanNuke[147]*

Σύμφωνα με τα πειραματικά αποτελέσματα του άρθρου [140], το YOLOv8-XLarge επέτυχε την υψηλότερη απόδοση με Ποιότητα Πανοπτική 56,04%, ενώ το YOLOv8-Large παρουσίασε ελάχιστα χαμηλότερη απόδοση (55,99%) με σημαντικά μειωμένο υπολογιστικό κόστος.

Βασικές Παρατηρήσεις:

- Σταδιακή Βελτίωση: Κάθε μεγαλύτερο μοντέλο παρουσιάζει σταθερή αύξηση στην Ποιότητα Πανοπτική
- Φθίνουσες Αποδόσεις: Από Medium σε Large (+1,02%) και Large σε XLarge (+0,05%)
- Βέλτιστη Επιλογή: Το Large παρέχει καλή ισορροπία (56% Ποιότητα Πανοπτική με 36% λιγότερες παραμέτρους από το XLarge)
- Ανάλυση Απόδοσης ανά Παραλλαγή

YOLOv8-Nano: Με μόλις 3,2M παραμέτρους και μέγεθος 6,2 MB, το Nano παρέχει το πιο συμπαγές μοντέλο, επιτυγχάνοντας Ποιότητα Πανοπτική 50,17%. Παρά τη χαμηλή πολυπλοκότητα, η απόδοση παραμένει σε αποδεκτά επίπεδα για εφαρμογές κινητών συσκευών ή υπολογιστικής ακμής.

YOLOv8-Small & Medium: Παρουσίασαν σταδιακή βελτίωση (52,46% και 54,97% αντίστοιχα). Το Medium επιτυγχάνει ~55% Ποιότητα Πανοπτική, πλησιάζοντας την απόδοση των μεγαλύτερων μοντέλων με μέγεθος 49,7 MB.

YOLOv8-Large έναντι XLarge: Η διαφορά στην απόδοση είναι ελάχιστη (55,99% έναντι 56,04% - μόλις 0,05% βελτίωση), ενώ το XLarge απαιτεί 56% περισσότερες παραμέτρους (68,2M έναντι 43,7M) και 56% μεγαλύτερο μέγεθος μοντέλου (130,5 MB έναντι 83,7 MB). Αυτό καθιστά το Large την πιο αποδοτική επιλογή για περιβάλλοντα παραγωγής.

## Απόδοση ανά Κυτταρικό Τύπο

| Τύπος Κυττάρου | Ποιότητα Πανοπτική (Large) | Ποιότητα Πανοπτική (XLarge) | Κλινική Σημασία |
|---|---|---|---|

| | | | |
|---|---|---|---|
| **Νεοπλασματικά** | 50,44% | 50,87% | Υψηλότερη απόδοση - καρκινικά κύτταρα |
| **Επιθηλιακά** | 44,10% | 44,35% | Μη-νεοπλασματικά επιθηλιακά |
| **Φλεγμονώδη** | 38,93% | 38,91% | Φλεγμονώδη κύτταρα |
| **Συνδετικού Ιστού/Μαλακοί Ιστοί** | 38,93% | 38,91% | Συνδετικός ιστός |
| **Νεκρά/Νεκρωτικά** | 10,31% | 10,77% | Νεκρωτικά κύτταρα (πολύ δύσκολα) |

*Πίνακα 29. Ποιότητα Πανοπτική ανά Τύπο Κυττάρου*

Κύρια Ευρήματα:

- Νεοπλασματικά κύτταρα (50,44%): Η υψηλότερη απόδοση επιτεύχθηκε στα νεοπλασματικά κύτταρα λόγω των διακριτών μορφολογικών τους χαρακτηριστικών και του μεγαλύτερου μεγέθους πυρήνων.
- Νεκρωτικά κύτταρα (10,31%): Η χαμηλότερη απόδοση οφείλεται στην αποδόμηση των κυτταρικών δομών, την έλλειψη σαφών ορίων και τη δυσκολία αναγνώρισης καταστραμμένων πυρήνων.
- Φλεγμονώδη και Συνδετικού Ιστού (38,93%): Μέτρια απόδοση λόγω μικρότερου μεγέθους, υψηλής πυκνότητας και επικάλυψης.

### 7.6.2. Συγκριτική Αξιολόγηση και Θέση στη Βιβλιογραφία

Η απόδοση των παραλλαγών YOLOv8 στο σύνολο δεδομένων PanNuke αξιολογήθηκε στο πλαίσιο των προηγούμενων μελετών που έχουν χρησιμοποιήσει το ίδιο σύνολο δεδομένων. Το PanNuke αποτελεί ένα από τα πιο απαιτητικά σημεία αναφοράς για κατάτμηση και ταξινόμηση πυρήνων λόγω της ποικιλομορφίας των 19 διαφορετικών τύπων ιστών.

#### Βασικά Χαρακτηριστικά της Προσέγγισης

1. Αρχιτεκτονική Ενός Σταδίου - YOLOv8: Η χρήση του YOLOv8 παρέχει σημαντικά πλεονεκτήματα σε σχέση με τις παραδοσιακές προσεγγίσεις δύο σταδίων:

- Ενοποιημένη αρχιτεκτονική: Ανίχνευση και ταξινόμηση σε ένα στάδιο
- Δυνατότητα πραγματικού χρόνου: Κατάλληλο για κλινική ανάπτυξη
- Κλιμακωσιμότητα: Πέντε παραλλαγές (Nano-XLarge) για διαφορετικούς υπολογιστικούς προϋπολογισμούς
- Σύγχρονη ραχοκοκαλιά: Βελτιωμένη εξαγωγή χαρακτηριστικών με CSPDarknet

2. Πανοπτική Κατάτμηση: Το YOLOv8 υποστηρίζει πανοπτική κατάτμηση που συνδυάζει:

- Κατάτμηση στιγμιοτύπων για μεμονωμένα κύτταρα
- Σημασιολογική κατάτμηση για φόντο/προσκήνιο
- Ενοποιημένες προβλέψεις για ολοκληρωμένη ανάλυση σκηνής

### Σύγκριση με Άλλες Μεθόδους

Προηγούμενες μελέτες στο PanNuke έχουν χρησιμοποιήσει διάφορες προσεγγίσεις:

Ανιχνευτές Δύο Σταδίων

- Πλεονεκτήματα: Υψηλή ακρίβεια, εξαιρετική κατάτμηση επιπέδου εικονοστοιχείων
- Μειονεκτήματα: Υψηλό υπολογιστικό κόστος, πολύπλοκη διαδικασία με δίκτυο προτάσεων περιοχών και κεφαλές ανίχνευσης
- Απόδοση: Συνήθως υψηλότερη ακρίβεια αλλά σημαντικά αργότερη επεξεργασία

Εξειδικευμένες Μέθοδοι Κατάτμησης Πυρήνων: Μέθοδοι όπως HoVerNet και CPP-Net έχουν σχεδιαστεί ειδικά για κατάτμηση πυρήνων:

- Χρησιμοποιούν χάρτες οριζόντιας/κάθετης απόστασης
- Προσαρμοσμένες συναρτήσεις απώλειας για επικαλυπτόμενους πυρήνες
- Υψηλή ακρίβεια σε πυκνές περιοχές

Συμβιβασμοί YOLOv8: Τα αποτελέσματα δείχνουν ότι το YOLOv8 πετυχαίνει:

- Καλή ισορροπία: Ποιότητα Πανοπτική ~56% είναι ανταγωνιστική για ανιχνευτή γενικής χρήσης
- Αποδοτικότητα: Κατάλληλο για πραγματικές κλινικές εφαρμογές
- Ευελιξία: Ενιαία αρχιτεκτονική για πολλαπλούς τύπους ιστών
- Βελτιώσεις σε Σχέση με Βασική Γραμμή

Προοδευτική Βελτίωση

- Nano → Small: +2,29% Ποιότητα Πανοπτική (+4,6% σχετική βελτίωση)
- Small → Medium: +2,51% Ποιότητα Πανοπτική (+4,8% σχετική βελτίωση)
- Medium → Large: +1,02% Ποιότητα Πανοπτική (+1,9% σχετική βελτίωση)
- Large → XLarge: +0,05% Ποιότητα Πανοπτική (+0,1% σχετική βελτίωση)

Η σταδιακή μείωση στον ρυθμό βελτίωσης υποδεικνύει φθίνουσες αποδόσεις, με το Large να αποτελεί το βέλτιστο σημείο ισορροπίας.

### Κλινική Εφαρμοσιμότητα

Για κλινική χρήση, τα κρίσιμα κριτήρια είναι:

1. Ακρίβεια: Ποιότητα Πανοπτική >50% είναι αποδεκτή για εφαρμογές διαλογής
2. Συνέπεια: Σταθερή απόδοση σε διαφορετικούς ιστούς
3. Ταχύτητα: Ικανότητα επεξεργασίας μεγάλου όγκου δειγμάτων
4. Δυνατότητα Ανάπτυξης: Μέγεθος μοντέλου και υπολογιστικές απαιτήσεις

Το YOLOv8-Large/XLarge ικανοποιεί αυτά τα κριτήρια, παρέχοντας:

- Ποιότητα Πανοπτική 56% - επαρκής για κλινική υποστήριξη
- Συνεπής ~55-63% Ποιότητα Πανοπτική σε 19 τύπους ιστών
- Αρχιτεκτονική ενός σταδίου - ταχύτερη από αρχιτεκτονικές δύο σταδίων
- 83,7-130,5 MB - δυνατότητα ανάπτυξης σε τυπικό υλικό

## 7.6.3. Γενίκευση Μεταξύ Ιστών και Απόδοση Πολλαπλών Οργάνων

Ένα από τα κυριότερα πλεονεκτήματα του συνόλου δεδομένων PanNuke είναι η δυνατότητα αξιολόγησης της γενικευσιμότητας σε πολλαπλούς τύπους ιστών. Το YOLOv8 δοκιμάστηκε σε 19 διαφορετικούς τύπους καρκινικών ιστών για να αξιολογηθεί η ικανότητά του να γενικεύει σε διαφορετικά ιστολογικά μοτίβα.

### Απόδοση ανά Τύπο Ιστού

| Τύπος Οργάνου | ΔΠΠ (Large) | ΔΠΠ (XLarge) | Κατάταξη |
|---|---|---|---|
| **Ουροδόχος Κύστη** | 63,22% | 62,01% | 1η (Καλύτερη) |
| **Ήπαρ** | 62,04% | 62,40% | 2η |
| **Επινεφριδιακός Αδένας** | 61,16% | 61,64% | 3η |
| **Νεφρός** | 59,96% | 59,86% | 4η |
| **Τράχηλος Μήτρας** | 58,37% | 58,21% | 5η |
| **Θυρεοειδής** | 57,53% | 58,35% | 6η |
| **Μαστός** | 56,97% | 57,29% | 7η |
| **Χοληφόρος Πόρος** | 57,20% | 57,70% | 8η |
| **Στομάχι** | 56,81% | 57,52% | 9η |
| **Όρχεις** | 57,10% | 56,49% | 10η |
| **Οισοφάγος** | 56,26% | 56,27% | 11η |
| **Προστάτης** | 56,04% | 56,16% | 12η |
| **Κεφαλή & Τράχηλος** | 55,56% | 55,30% | 13η |
| **Πνεύμονας** | 53,36% | 53,35% | 14η |
| **Πάγκρεας** | 53,75% | 53,67% | 15η |
| **Ωοθήκες** | 52,08% | 52,05% | 16η |
| **Μήτρα** | 51,48% | 50,30% | 17η |
| **Δέρμα** | 48,71% | 49,65% | 18η |

| | | | |
|---|---|---|---|
| **Παχύ Έντερο** | 46,13% | 46,53% | 19η (Πιο Απαιτητικό) |

*Πίνακα 30. Δυαδική Ποιότητα Πανοπτική ανά Τύπο Ιστού [147]*

Μέση Δυαδική Ποιότητα Πανοπτική: 55,99% (YOLOv8-Large)

*ΔΠΠ: Δυαδική Ποιότητα Πανοπτική (Binary Panoptic Quality - BPQ)

## Ανάλυση Απόδοσης

Ιστοί Κορυφαίας Απόδοσης (ΔΠΠ >60%):

1. Ουροδόχος Κύστη (63,22%): Η καλύτερη απόδοση οφείλεται σε:

   Καλά οριοθετημένες κυτταρικές δομές

   Υψηλή αντίθεση μεταξύ ουροθηλιακών κυττάρων και φόντου

   Σχετικά ομοιόμορφη κυτταρική μορφολογία

2. Ήπαρ (62,04%): Εξαιρετική απόδοση λόγω:

   Ομοιόμορφης ιστικής αρχιτεκτονικής (ηπατοκύτταρα)

   Σαφούς διάκρισης πυρήνων

   Συνεπών μοτίβων χρώσης

3. Επινεφριδιακός Αδένας (61,16%): Υψηλή απόδοση χάρη σε:

   Διακριτή κυτταρική οργάνωση (φλοιός/μυελός)

   Καλά οριοθετημένους πυρήνες

   Χαμηλό θόρυβο φόντου

Απαιτητικοί Ιστοί (ΔΠΠ <50%):

1. Παχύ Έντερο (46,13%): Η χαμηλότερη απόδοση οφείλεται σε:

   - Πολύ πυκνές κυτταρικές κατανομές
   - Έντονη επικάλυψη πυρήνων
   - Πολύπλοκη τρισδιάστατη αρχιτεκτονική των κρυπτών
   - Μεγάλη ποικιλομορφία κυτταρικών τύπων (κυτταράρια κυπέλλου, απορροφητικά, κύτταρα Paneth)

2. Δέρμα (48,71%): Δυσκολίες από:

   - Πολυστρωματική δομή (επιδερμίδα, χόριο)
   - Μεταβλητή πυκνότητα κυττάρων
   - Παρουσία θυλάκων τριχών και σμηγματογόνων αδένων

3. Μήτρα (51,48%): Προκλήσεις από:
    - Κυκλικές μεταβολές στον ιστό (επιδράσεις εμμηνορροϊκού κύκλου)
    - Ποικιλομορφία τύπων κυττάρων
    - Πυκνό στρώμα με επικαλυπτόμενους πυρήνες

### Ανάλυση Συνέπειας

Τυπική Απόκλιση: 4,73% (ΔΠΠ σε 19 ιστούς) Συντελεστής Μεταβλητότητας: 8,4%

Η σχετικά χαμηλή διακύμανση (Συντελεστής Μεταβλητότητας <10%) υποδεικνύει ότι το YOLOv8-Large διατηρεί σταθερή απόδοση σε ποικίλους τύπους ιστών, χωρίς να εξειδικεύεται υπερβολικά σε συγκεκριμένες κατηγορίες.

### Μετρικές Ανθεκτικότητας

Απόδοση Ομάδων Ιστών:

- Συμπαγή Όργανα (Ήπαρ, Νεφρός, Πάγκρεας): Μέση ΔΠΠ 58,58%
- Κοίλα Όργανα (Ουροδόχος Κύστη, Παχύ Έντερο, Στομάχι): Μέση ΔΠΠ 55,39%
- Αδενικοί Ιστοί (Μαστός, Θυρεοειδής, Προστάτης): Μέση ΔΠΠ 56,84%
- Αναπαραγωγικά (Ωοθήκες, Μήτρα, Όρχεις, Τράχηλος): Μέση ΔΠΠ 54,73%

Το μοντέλο επιδεικνύει παρόμοια απόδοση σε διαφορετικές κατηγορίες οργάνων, επιβεβαιώνοντας την ικανότητά του για γενίκευση.

### Κλινική Ερμηνεία

Για Εφαρμογές Διαλογής:

- Όλοι οι ιστοί επιτυγχάνουν ΔΠΠ >46%, αποδεκτό για αρχική διαλογή
- 12/19 ιστοί (63%) έχουν ΔΠΠ >55%, κατάλληλο για κλινική υποστήριξη
- 3/19 ιστοί (16%) έχουν ΔΠΠ >60%, εξαιρετικό για αυτοματοποιημένη ανάλυση

Για Διαγνωστική Υποστήριξη:

- Το σύστημα μπορεί να χρησιμοποιηθεί με εμπιστοσύνη σε ιστούς υψηλής απόδοσης (Ουροδόχος Κύστη, Ήπαρ, Νεφρός)
- Απαιτείται προσοχή σε απαιτητικούς ιστούς (Παχύ Έντερο, Δέρμα) - χρήση ως εργαλείο δεύτερης γνωμάτευσης
- Η συνεπής απόδοση επιτρέπει ανάπτυξη σε προγράμματα διαλογής πολλαπλών οργάνων

## Συμπεράσματα Απόδοσης

Τα αποτελέσματα της αξιολόγησης των παραλλαγών YOLOv8 στο σύνολο δεδομένων PanNuke αποδεικνύουν ότι:

1. Ακρίβεια Κλινικού Επιπέδου:
    - Ποιότητα Πανοπτική 56,04% (XLarge), 55,99% (Large) - επαρκής για εφαρμογές κλινικής υποστήριξης
    - Δυαδική Ποιότητα Πανοπτική 44,31% (Large) - αποδεκτή για διαλογή και συστήματα δεύτερης γνωμάτευσης
2. Συνεπής Απόδοση Πολλαπλών Οργάνων:
    - Εύρος 46,13-63,22% ΔΠΠ σε 19 τύπους ιστών
    - Συντελεστής Μεταβλητότητας 8,4% - εξαιρετική συνέπεια
    - 63% των ιστών (12/19) με ΔΠΠ >55%
3. Καλύτερη Απόδοση στην Κατηγορία:
    - Νεοπλασματικά κύτταρα: 50,44% Ποιότητα Πανοπτική - η υψηλότερη κατηγορία
    - Ιστός ουροδόχου κύστης: 63,22% ΔΠΠ - ο καλύτερος τύπος οργάνου
    - Επιθηλιακά κύτταρα: 44,10% Ποιότητα Πανοπτική - καλή απόδοση σε μη-νεοπλασματικά
4. Ανθεκτική Γενίκευση:
    - Σταθερή απόδοση σε συμπαγή, κοίλα και αδενικά όργανα
    - Ελάχιστη πτώση απόδοσης μεταξύ διαφορετικών κατηγοριών ιστών
    - Κλιμακούμενη αρχιτεκτονική (Nano έως XLarge) για διαφορετικά σενάρια ανάπτυξης
5. Ετοιμότητα Κλινικής Ανάπτυξης:
    - Επαρκής ακρίβεια για διαλογή (>46% όλοι οι ιστοί)
    - Εξαιρετική απόδοση σε ιστούς υψηλής προτεραιότητας (Ουροδόχος Κύστη, Ήπαρ, Νεφρός >60%)
    - Λογικά μεγέθη μοντέλων (6,2-130,5 MB) - δυνατότητα ανάπτυξης σε τυπικό υλικό
    - Αρχιτεκτονική ενός σταδίου - ταχύτερη από παραδοσιακούς ανιχνευτές δύο σταδίων
6. Βέλτιστη Επιλογή Μοντέλου:

- YOLOv8-Large: Καλύτερη ισορροπία (55,99% Ποιότητα Πανοπτική, 83,7 MB)
- YOLOv8-XLarge: Οριακή βελτίωση (+0,05% Ποιότητα Πανοπτική) με 56% περισσότερες παραμέτρους
- YOLOv8-Medium: Οικονομική επιλογή (54,97% Ποιότητα Πανοπτική, 49,7 MB) για περιβάλλοντα περιορισμένων πόρων

Η προτεινόμενη μεθοδολογία με YOLOv8 παρέχει μια πρακτική, κλιμακούμενη λύση για αυτοματοποιημένη ανίχνευση και ταξινόμηση πυρήνων σε πολλαπλούς τύπους καρκινικών ιστών, κατάλληλη για ενσωμάτωση σε κλινικές ροές εργασίας ως εργαλείο υποστήριξης αποφάσεων.

## 7.7. Συγκριτική Ανάλυση και Αξιολόγηση

### 7.7.1. Πειραματικά Αποτελέσματα Μεταφοράς Μάθησης ανά εφαρμογή

#### 7.7.1.1. Ανάλυση παγκρεατικού ιστού (Pancreatic Tissue Analysis)

Χαρακτηριστικά συνόλου δεδομένων:

- Εικόνες: 2,400 παγκρεατικά patches (512×512)
- Κλάσεις: 4 (Normal, Acinar, Ductal, Adipose)
- Train/Validation/Test: 60%/20%/20%

| Αρχιτεκτονική | Accuracy | Precision | Recall | F1-Score | Training Time |
|---|---|---|---|---|---|
| **AlexNet** | 91.2% | 90.8% | 90.6% | 90.7% | 2.1h |
| **VGG-16** | 93.7% | 93.2% | 93.5% | 93.4% | 4.2h |
| **VGG-19** | 94.6% | 94.1% | 94.3% | 94.2% | 4.8h |
| **ResNet-50** | **95.1%** | **94.8%** | **95.0%** | **94.9%** | 3.1h |

*Πίνακα 31. Στατιστικά από transfer learning αποτελέσματα των αρχιτεκτονικών στο pancreatic tissue*

Confusion Matrix Analysis - ResNet-50

| | Normal | Acinar | Ductal | Adipose | Precision |
|---|---|---|---|---|---|

| | | | | | |
|---|---|---|---|---|---|
| **Normal** | 186 | 3 | 2 | 1 | 96.9% |
| **Acinar** | 4 | 178 | 5 | 1 | 94.7% |
| **Ductal** | 2 | 6 | 184 | 0 | 95.8% |
| **Adipose** | 1 | 0 | 1 | 190 | 99.0% |
| **Recall** | 96.4% | 95.2% | 95.8% | 98.9% | 95.1% |

*Πίνακα 32. Στατιστικά από conifusion matrix σε ResNet-50 στο pancreatic tissue ανά κλαση*

#### 7.7.1.2. Comparative Analysis: Transfer vs From-Scratch

Training Efficiency Comparison

| Μετρική | From Scratch | Transfer Learning | Βελτίωση |
|---|---|---|---|
| **Epochs to Convergence** | 45-60 | 8-12 | **75-80%** |
| **Training Time** | 12-18h | 3-5h | **70-75%** |
| **Final Accuracy** | 76-85% | 91-95% | **15-20%** |
| **Validation Stability** | High variance | Low variance | **60% less std** |
| **GPU Memory Usage** | 8-12 GB | 6-8 GB | **25-33%** |

*Πίνακα 33. Σύγκριση απόδοση εκπαιδεύσεις*

#### 7.7.1.3. Learning Curves Analysis

Μοτίβα σύγκλισης (Convergence Patterns):

- Μεταφορά μάθησης (Transfer Learning): Ταχεία αρχική βελτίωση, με σταθεροποίηση της απόδοσης μετά την 6η–8η εποχή.
- Εκπαίδευση από την αρχή (From Scratch): Σταδιακή βελτίωση με συνεχιζόμενη μάθηση έως περίπου την 40ή–50ή εποχή.
- Κίνδυνος υπερεφαρμογής (Overfitting Risk): Κατά 45% χαμηλότερος στις προσεγγίσεις μεταφοράς μάθησης.

Μελέτες δια-τομεακής επικύρωσης (Cross-Domain Validation Studies).

#### 7.7.1.4. Multi-Organ Generalization Test

Μοντέλα εκπαιδευμένα σε παγκρεατικούς ιστούς δοκιμάστηκαν σε:

| Target Domain | Source Accuracy | Cross-Domain Accuracy | Domain Gap |
|---|---|---|---|

| | | | |
|---|---|---|---|
| **Liver Tissue** | 95.1% | 78.4% | -16.7% |
| **Breast Tissue** | 95.1% | 71.2% | -23.9% |
| **Colon Tissue** | 95.1% | 83.6% | -11.5% |
| **Lung Tissue** | 95.1% | 75.8% | -19.3% |

*Πίνακα 34. Πολυοργανικές δοκιμές από μοντέλα παγκρεατικών ιστών.*

Λεπτορρύθμιση στο στοχευμένο τομέα (Fine-tuning on Target Domain):

- Επιπλέον εκπαίδευση (Additional Training): 2-3 εποχές (epochs) στο νέο τομέα (domain).
- Ρυθμός μάθησης (Learning Rate): 0.00001 (10× μικρότερο).
- Βελτίωση (Improvement): Ανάρρωση 8-15% του κενού τομέα (domain gap)

| Target Domain | Before Fine-tuning | After Fine-tuning | Recovery Rate |
|---|---|---|---|
| **Liver** | 78.4% | 89.2% | 64.3% |
| **Breast** | 71.2% | 85.6% | 60.3% |
| **Colon** | 83.6% | 92.1% | 73.9% |
| **Lung** | 75.8% | 88.4% | 65.3% |

*Πίνακα 35. Στρατιστικα απο multi-organ σχετικά με την σύγκριση πριν και μετα την βελτίωση της εκπαιδυεσεις.*

## 7.7.2. Σύγκριση Επιδόσεων ανά Μοντέλο

Η συγκριτική αξιολόγηση των τεσσάρων αρχιτεκτονικών στο νεφρικό σύνολο δεδομένων αναδεικνύει σαφείς διαφορές στην απόδοση που σχετίζονται με τις δομικές ιδιαιτερότητες κάθε μοντέλου. Το Cascade R-CNN και το RetinaNet αναδύονται ως οι πιο αποτελεσματικές προσεγγίσεις, με σχεδόν άριστη απόδοση στις περισσότερες μετρικές.

Το Cascade R-CNN, με την πολυστάδια αρχιτεκτονική του, επιτυγχάνει την υψηλότερη συνολική ακρίβεια και την τέλεια ειδικότητα, καθιστώντας το ιδανικό για εφαρμογές όπου η αποφυγή ψευδώς θετικών είναι κρίσιμη. Το RetinaNet, παρά την ελαφρώς χαμηλότερη συνολική ακρίβεια, παρουσιάζει την υψηλότερη ευαισθησία, καθιστώντας το κατάλληλο για screening εφαρμογές όπου η μη παράλειψη θετικών περιπτώσεων είναι προτεραιότητα.

Το Mask R-CNN, παρά την μέτρια απόδοσή του στο νεφρικό σύνολο, διατηρεί την ικανότητα instance segmentation που είναι απαραίτητη για εξειδικευμένες εφαρμογές

όπως η ανάλυση IBD. Το Faster R-CNN, με την χαμηλότερη συνολική απόδοση, παραμένει μια βιώσιμη επιλογή για εφαρμογές με περιορισμένους υπολογιστικούς πόρους όπου η ταχύτητα υπερτερεί της απόλυτης ακρίβειας.

### 7.7.3. Κλινικές Επιπτώσεις των Αποτελεσμάτων

Τα αποτελέσματα έχουν σημαντικές επιπτώσεις για την κλινική εφαρμογή των αλγορίθμων. Η άριστη απόδοση του Cascade R-CNN και του RetinaNet στο νεφρικό σύνολο υποδεικνύει ότι αυτά τα συστήματα είναι έτοιμα για ενσωμάτωση σε κλινικές ροές εργασίας ως εργαλεία υποστήριξης διάγνωσης. Ωστόσο, οι σημαντικές διαφορές στην απόδοση μεταξύ διαφορετικών τύπων ιστών τονίζουν την ανάγκη για εξειδικευμένα μοντέλα ή προσεγγίσεις domain adaptation.

Η χαμηλή απόδοση στο IBD dataset αναδεικνύει τους περιορισμούς των γενικών αρχιτεκτονικών και την ανάγκη για περισσότερα εξειδικευμένα δεδομένα εκπαίδευσης ή εναλλακτικές προσεγγίσεις για συγκεκριμένες παθολογίες. Αυτό έχει σημαντικές επιπτώσεις για τη στρατηγική ανάπτυξης και εφαρμογής τέτοιων συστημάτων σε διαφορετικά κλινικά περιβάλλοντα.

# *Κεφάλαιο 8*

## *ΣΥΖΗΤΗΣΗ ΚΑΙ ΑΞΙΟΛΟΓΗΣΗ*

## 8.1. Τεχνικές Καινοτομίες της Πλατφόρμας

Η κύρια τεχνική καινοτομία της εργασίας εντοπίζεται στην ολιστική προσέγγιση του προβλήματος της ψηφιακής παθολογίας. Αντί για μεμονωμένες λύσεις που επικεντρώνονται σε συγκεκριμένες πτυχές του προβλήματος, αναπτύχθηκε μια ενοποιημένη πλατφόρμα που διαχειρίζεται ολόκληρη τη ροή εργασίας - από την εισαγωγή και διαχείριση των εικόνων μέχρι την εκπαίδευση προσαρμοσμένων μοντέλων και την παρουσίαση αποτελεσμάτων [141].

Η τμηματική αρχιτεκτονική που υιοθετήθηκε επιτρέπει την ανεξάρτητη εξέλιξη κάθε συστατικού μέρους, διασφαλίζοντας ευελιξία και επεκτασιμότητα. Η χρήση του Socket.IO για πραγματικού χρόνου επικοινωνία μεταξύ των υποσυστημάτων αποτελεί μια καινοτόμα εφαρμογή που εξασφαλίζει άμεση ανταπόκριση και ομαλή εμπειρία χρήστη.

Ιδιαίτερα σημαντική είναι η ανάπτυξη του συστήματος διαχείρισης πολλαπλών μοντέλων που επιτρέπει την παράλληλη εκπαίδευση και λειτουργία διαφορετικών αλγορίθμων για διαφορετικούς τύπους βιοψιών. Αυτή η δυνατότητα, που δεν υπάρχει στα υπάρχοντα εμπορικά συστήματα, παρέχει στους χρήστες την ευελιξία να προσαρμόζουν την πλατφόρμα στις ειδικές τους ανάγκες χωρίς περιορισμούς [135].

Η βελτιστοποίηση για εκπαίδευση σε πολλαπλές μονάδες επεξεργασίας γραφικών επέτρεψε τη δραματική μείωση του χρόνου εκπαίδευσης, καθιστώντας πρακτικά εφικτή την ανάπτυξη νέων μοντέλων ακόμη και για μικρότερα ερευνητικά κέντρα με περιορισμένους πόρους.

## 8.2. Κανονιστικές και Ηθικές Πτυχές

### 8.2.1. Κανονιστική Συμμόρφωση και Εγκρίσεις

Η ενσωμάτωση συστημάτων τεχνητής νοημοσύνης στην κλινική πρακτική απαιτεί αυστηρή συμμόρφωση με κανονιστικές απαιτήσεις. Στην Ευρωπαϊκή Ένωση, ο Κανονισμός για Ιατροτεχνολογικά Προϊόντα αποτελεί το βασικό νομικό πλαίσιο που ρυθμίζει την ανάπτυξη και εμπορευματοποίηση τέτοιων συστημάτων. Το σύστημα σχεδιάστηκε με γνώμονα τη συμμόρφωση με αυτές τις απαιτήσεις, ενσωματώνοντας μηχανισμούς ποιοτικού ελέγχου και ιχνηλασιμότητας.

Η διαδικασία κλινικής επικύρωσης που ακολουθήθηκε περιλαμβάνει προσπέκτιβες και αναδρομικές μελέτες σε πολλαπλά κέντρα, παρέχοντας ισχυρά στοιχεία για την αποτελεσματικότητα και ασφάλεια του συστήματος. Η συλλογή τεκμηρίωσης για τη διαδικασία εγκρίσεως από ρυθμιστικές αρχές αποτελεί συνεχή διεργασία που εξασφαλίζει τη μακροχρόνια βιωσιμότητα της λύσης.

### 8.2.2. Προστασία Δεδομένων και Ιδιωτικότητα

Η συμμόρφωση με τον Γενικό Κανονισμό Προστασίας Δεδομένων αποτελεί θεμελιώδη απαίτηση για τη λειτουργία του συστήματος στην Ευρώπη. Η πλατφόρμα υλοποιεί τεχνικές ανωνυμοποίησης και ψευδωνυμοποίησης για την προστασία της ταυτότητας των ασθενών, ενώ παράλληλα διατηρεί τη δυνατότητα σύνδεσης με κλινικά δεδομένα όταν αυτό είναι απαραίτητο.

Η εφαρμογή κρυπτογράφησης από άκρο σε άκρο για όλες τις μεταδόσεις δεδομένων και η χρήση ασφαλών πρωτοκόλλων αποθήκευσης εξασφαλίζει την προστασία των ευαίσθητων ιατρικών πληροφοριών. Η πλατφόρμα διατηρεί λεπτομερή αρχεία ελέγχου για όλες τις προσβάσεις και τροποποιήσεις, επιτρέποντας την ιχνηλασιμότητα και τη συμμόρφωση με κανονιστικές απαιτήσεις.

### 8.2.3. Ηθικές Προκλήσεις και Ευθύνη

Η χρήση συστημάτων τεχνητής νοημοσύνης στη διάγνωση εγείρει σημαντικά ηθικά ζητήματα σχετικά με την ευθύνη σε περιπτώσεις διαγνωστικών σφαλμάτων. Το νομικό πλαίσιο παραμένει ασαφές σχετικά με την κατανομή ευθύνης μεταξύ του κατασκευαστή του συστήματος, του ιδρύματος που το χρησιμοποιεί και του κλινικού που λαμβάνει την τελική απόφαση.

Για την αντιμετώπιση αυτών των προκλήσεων, το σύστημα σχεδιάστηκε ως εργαλείο υποστήριξης και όχι αντικατάστασης του παθολόγου. Όλες οι προτάσεις του συστήματος συνοδεύονται από δείκτες εμπιστοσύνης και οπτικές επεξηγήσεις, επιτρέποντας στον κλινικό να αξιολογήσει κριτικά τα αποτελέσματα.

## 8.3. Περιορισμοί και Τεχνικές Προκλήσεις

### 8.3.1. Περιορισμοί Γενίκευσης και Μετατόπιση Πεδίου

Παρά την επιτυχημένη πολυκεντρική επικύρωση, το σύστημα εμφανίζει μειωμένη απόδοση όταν εφαρμόζεται σε δεδομένα από ιδρύματα με σημαντικά διαφορετικά πρωτόκολλα προετοιμασίας δειγμάτων. Η διακύμανση στις τεχνικές χρώσης, το πάχος των τομών και η ποιότητα της σάρωσης μπορούν να επηρεάσουν την ακρίβεια των προβλέψεων κατά 8-12%.

Η εξάρτηση από επισημειωμένα δεδομένα εκπαίδευσης αποτελεί σημαντικό περιορισμό για την επέκταση σε νέες παθολογίες. Η δημιουργία υψηλής ποιότητας σημειώσεων απαιτεί σημαντική επένδυση χρόνου από έμπειρους παθολόγους, περιορίζοντας τον ρυθμό ανάπτυξης νέων εφαρμογών[137].

### 8.3.2. Τεχνικές Προκλήσεις Κλιμάκωσης

Η επεξεργασία εικόνων ολόκληρης τομής που μπορούν να ξεπερνούν τα 100.000 x 100.000 pixels παρουσιάζει σημαντικές υπολογιστικές προκλήσεις. Παρά τις βελτιστοποιήσεις που εφαρμόστηκαν, η επεξεργασία εξαιρετικά μεγάλων εικόνων μπορεί να απαιτεί πάνω από 32GB μνήμης GPU, περιορίζοντας τη χρήση σε εγκαταστάσεις με περιορισμένους πόρους.

Η ανάγκη για συνεχή ενημέρωση και επανεκπαίδευση των μοντέλων καθώς νέα δεδομένα γίνονται διαθέσιμα δημιουργεί προκλήσεις στη διαχείριση εκδόσεων και τη διασφάλιση συνέπειας. Το φαινόμενο της καταστροφικής λήθης μπορεί να οδηγήσει σε υποβάθμιση της απόδοσης σε παλαιότερες εργασίες όταν τα μοντέλα εκπαιδεύονται σε νέα δεδομένα.

## 8.4. Σύγκριση με Υπάρχουσες Λύσεις

Η αξιολόγηση της πλατφόρμας έναντι υπαρχουσών εμπορικών και ερευνητικών λύσεων αναδεικνύει σημαντικά πλεονεκτήματα αλλά και περιοχές για βελτίωση. Σε σύγκριση με εμπορικές πλατφόρμες όπως η AIFORIA και η HALO-AI, η πλατφόρμα παρέχει μεγαλύτερη ευελιξία στην προσαρμογή και χαμηλότερο κόστος εφαρμογής, ιδιαίτερα για ερευνητικά ιδρύματα με περιορισμένους πόρους.

Η τμηματική αρχιτεκτονική επιτρέπει την ανεξάρτητη ενημέρωση κάθε συστατικού, προσφέροντας μεγαλύτερη ευκαμψία από μονολιθικές λύσεις. Ωστόσο, αυτή η προσέγγιση απαιτεί μεγαλύτερη τεχνική εμπειρία για τη διαχείριση και συντήρηση.

Η έλλειψη προεκπαιδευμένων μοντέλων για ευρύ φάσμα παθολογιών αποτελεί μειονέκτημα σε σχέση με εμπορικές λύσεις που προσφέρουν έτοιμα μοντέλα για δεκάδες διαφορετικές εφαρμογές. Η ανάπτυξη μιας βιβλιοθήκης προεκπαιδευμένων μοντέλων αποτελεί προτεραιότητα για μελλοντική ανάπτυξη.

## 8.5. Επιπτώσεις για την Κλινική Πράξη

### 8.5.1. Μετασχηματισμός του Ρόλου του Παθολόγου

Η ενσωμάτωση συστημάτων όπως η πλατφόρμα δεν αποσκοπεί στην αντικατάσταση των παθολόγων αλλά στον μετασχηματισμό του ρόλου τους. Οι παθολόγοι θα εξελιχθούν από παρατηρητές μορφολογικών χαρακτηριστικών σε διαχειριστές πολύπλοκων διαγνωστικών πληροφοριών, συνθέτοντας δεδομένα από πολλαπλές πηγές για ολοκληρωμένη διάγνωση.

Η αυτοματοποίηση ρουτινικών εργασιών θα επιτρέψει στους παθολόγους να επικεντρωθούν σε πιο σύνθετες περιπτώσεις και στην ερμηνεία των αποτελεσμάτων σε κλινικό πλαίσιο. Αυτή η μετάβαση απαιτεί αναπροσαρμογή των εκπαιδευτικών

προγραμμάτων για να περιλάβουν δεξιότητες στη χρήση και κριτική αξιολόγηση συστημάτων τεχνητής νοημοσύνης.

### 8.5.2. Οικονομικές Επιπτώσεις και Βιωσιμότητα

Η υιοθέτηση τέτοιων συστημάτων μπορεί να συμβάλει στην αντιμετώπιση της αυξανόμενης ζήτησης για παθολογικές υπηρεσίες χωρίς ανάλογη αύξηση του προσωπικού. Με την παγκόσμια έλλειψη παθολόγων που εκτιμάται σε 60% έως το 2030, η αυτοματοποίηση είναι κρίσιμη για τη διατήρηση της ποιότητας υπηρεσιών.

Η μείωση των διαγνωστικών σφαλμάτων και των επαναλαμβανόμενων εξετάσεων έχει σημαντικό οικονομικό όφελος για τα συστήματα υγείας. Εκτιμάται ότι η ευρεία υιοθέτηση τέτοιων συστημάτων θα μπορούσε να εξοικονομήσει 2-3 δισεκατομμύρια ευρώ ετησίως στην Ευρωπαϊκή Ένωση.

### 8.5.3. Κοινωνικές και Ηθικές Διαστάσεις

Η εξασφάλιση ισότιμης πρόσβασης σε προηγμένες διαγνωστικές τεχνολογίες αποτελεί σημαντική πρόκληση. Υπάρχει κίνδυνος διεύρυνσης του χάσματος μεταξύ ιδρυμάτων με πόρους για τέτοιες τεχνολογίες και αυτών χωρίς, επιδεινώνοντας τις υπάρχουσες ανισότητες στην υγειονομική περίθαλψη.

Η ανάγκη για διαφάνεια και λογοδοσία στη χρήση τεχνητής νοημοσύνης στην υγεία απαιτεί την ανάπτυξη νέων πλαισίων διακυβέρνησης. Η δημιουργία επιτροπών ηθικής για την επίβλεψη της ανάπτυξης και εφαρμογής τέτοιων συστημάτων είναι απαραίτητη για τη διασφάλιση της ηθικής χρήσης.

## 8.6. Συμπεράσματα Κεφαλαίου

Η ανάλυση που παρουσιάστηκε σε αυτό το κεφάλαιο αναδεικνύει τόσο τις σημαντικές επιτεύξεις όσο και τις προκλήσεις που απομένουν για την πλήρη ενσωμάτωση της πλατφόρμας στην κλινική πρακτική. Οι τεχνικές καινοτομίες που εισήχθησαν, ιδιαίτερα η τμηματική αρχιτεκτονική και η ευέλικτη διαχείριση μοντέλων, τοποθετούν το σύστημα σε πλεονεκτική θέση έναντι των υπαρχουσών λύσεων.

Η κλινική αξία της πλατφόρμας έχει τεκμηριωθεί μέσω εκτεταμένων μελετών, με αποδεδειγμένη βελτίωση στην ακρίβεια διάγνωσης και την αποδοτικότητα της ροής εργασίας. Ωστόσο, οι προκλήσεις που σχετίζονται με την κανονιστική συμμόρφωση, την ερμηνευσιμότητα και την εμπιστοσύνη των χρηστών απαιτούν συνεχή προσπάθεια και καινοτομία.

Οι μελλοντικές κατευθύνσεις που σκιαγραφήθηκαν, από την ενσωμάτωση νέων τεχνολογιών μηχανικής μάθησης έως την ανάπτυξη συνεργατικών πλατφορμών, υπόσχονται περαιτέρω βελτιώσεις και διεύρυνση των δυνατοτήτων του συστήματος. Η

επιτυχής υλοποίηση αυτών των κατευθύνσεων θα εξαρτηθεί από τη συνεργασία μεταξύ ερευνητών, κλινικών, ρυθμιστικών αρχών και της βιομηχανίας.

Τελικά, η πλατφόρμα αντιπροσωπεύει ένα σημαντικό βήμα προς την πραγματοποίηση του οράματος της ψηφιακής παθολογίας ως αναπόσπαστου μέρους της σύγχρονης διαγνωστικής ιατρικής. Η συνεχής εξέλιξη και βελτίωση του συστήματος, καθοδηγούμενη από κλινικές ανάγκες και τεχνολογικές καινοτομίες, θα διασφαλίσει τη μακροχρόνια επίδρασή του στη βελτίωση της υγειονομικής περίθαλψης.

# Κεφάλαιο 9

## ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΣΥΝΕΙΣΦΟΡΕΣ

## 9.1. Συνοπτική Ανακεφαλαίωση

Η παρούσα διδακτορική διατριβή παρουσίασε την ανάπτυξη και υλοποίηση της πλατφόρμας Deep-in-Biopsies, ένα ολοκληρωμένο σύστημα για την αυτοματοποιημένη ανάλυση ιστοπαθολογικών εικόνων με χρήση προηγμένων τεχνικών βαθιάς μάθησης. Μέσω διεπιστημονικής προσέγγισης που συνδυάζει τεχνολογική καινοτομία με την κλινική πραγματικότητα, αναπτύχθηκε μια πλατφόρμα που αποδείχθηκε όχι μόνο τεχνικά ανώτερη αλλά και πρακτικά χρήσιμη για τους επαγγελματίες υγείας.

Η διατριβή καλύπτει συνολικά την πορεία από την αρχική εννοιολογική σκέψη μέχρι την πλήρη υλοποίηση και κλινική αξιολόγηση της πλατφόρμας. Εξετάστηκαν εκτενώς οι τεχνικές προκλήσεις της ψηφιακής παθολογίας, αναλύθηκαν οι σύγχρονες μέθοδοι βαθιάς μάθησης και παρουσιάστηκε μια καινοτόμος αρχιτεκτονική που ανταποκρίνεται στις πραγματικές ανάγκες των παθολογοανατομικών εργαστηρίων [133].

Η εκτεταμένη κλινική επικύρωση σε επτά διαφορετικά ιδρύματα με διαφορετικούς τύπους ιστοπαθολογικών εξετάσεων κατέδειξε την αξιοπιστία και γενίκευση της πλατφόρμας. Τα αποτελέσματα υπερέβησαν τις αρχικές προσδοκίες, επιτυγχάνοντας διαγνωστική ακρίβεια που ανταγωνίζεται και σε πολλές περιπτώσεις ξεπερνά την ανθρώπινη απόδοση, ενώ ταυτόχρονα προσφέρει σημαντικά πλεονεκτήματα σε ταχύτητα, συνεπή ποιότητα και οικονομικότητα.

## 9.2. Βασικές Επιστημονικές Συνεισφορές

### 9.2.1. Ολοκληρωμένη Αρχιτεκτονική Πλατφόρμας

Η πρώτη και σημαντικότερη επιστημονική συνεισφορά της παρούσας διατριβής είναι η ανάπτυξη μιας ολοκληρωμένης, τμηματικής αρχιτεκτονικής για την ψηφιακή παθολογία που διαχειρίζεται ολόκληρη τη ροή εργασίας από την εισαγωγή εικόνων μέχρι την εκπαίδευση και εφαρμογή μοντέλων τεχνητής νοημοσύνης. Αντίθετα με τις υπάρχουσες λύσεις που επικεντρώνονται σε μεμονωμένες πτυχές του προβλήματος, η πλατφόρμα προσφέρει μια ενοποιημένη εμπειρία που καλύπτει όλες τις ανάγκες των ερευνητών και κλινικών [23].

Η καινοτομία εντοπίζεται στη χρήση μικρουπηρεσιών που επικοινωνούν μέσω Socket.IO, επιτρέποντας την ανεξάρτητη ανάπτυξη και κλιμάκωση κάθε συστατικού μέρους. Αυτή η προσέγγιση εξασφαλίζει υψηλή διαθεσιμότητα, ανοχή σε σφάλματα και δυνατότητα προσαρμογής σε διαφορετικές υπολογιστικές υποδομές.

### 9.2.2. Σύστημα Διαχείρισης Πολλαπλών Μοντέλων

Η δεύτερη κύρια συνεισφορά αφορά την ανάπτυξη ενός προηγμένου συστήματος διαχείρισης πολλαπλών μοντέλων που επιτρέπει την παράλληλη εκπαίδευση, αξιολόγηση

και εφαρμογή διαφορετικών αλγορίθμων βαθιάς μάθησης για διαφορετικούς τύπους ιστοπαθολογικών αναλύσεων. Η δυνατότητα δυναμικής επιλογής αρχιτεκτονικής (Mask R-CNN, Cascade R-CNN, RetinaNet) και παραμέτρων εκπαίδευσης ανάλογα με τον τύπο δεδομένων αποτελεί σημαντική καινοτομία στον χώρο [141].

Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για κλινικές μελέτες που απαιτούν ειδική αντιμετώπιση διαφορετικών τύπων ιστών ή παθολογιών, επιτρέποντας την προσαρμογή της πλατφόρμας στις ειδικές ανάγκες κάθε εφαρμογής χωρίς περιορισμούς.

### 9.2.3. Εργονομική Διεπαφή και Ροή Εργασίας

Η τρίτη συνεισφορά σχετίζεται με τη δημιουργία μιας ροής εργασίας φιλικής προς τον χρήστη, με εργονομικό περιβάλλον σημειοθέτησης και δυνατότητα επικοινωνίας σε πραγματικό χρόνο μεταξύ διεπαφής και συστήματος τεχνητής νοημοσύνης. Αυτό καθιστά την πλατφόρμα προσβάσιμη και σε μη εξειδικευμένους χρήστες, επιτρέποντας σε παθολόγους να αλληλεπιδρούν άμεσα με τα εργαλεία και τα αποτελέσματα χωρίς να απαιτείται βαθιά γνώση των υποκείμενων τεχνολογιών.

Η ενσωμάτωση προηγμένων εργαλείων οπτικοποίησης και η δυνατότητα αμφίδρομης επικοινωνίας με το σύστημα επεξεργασίας δημιουργούν ένα περιβάλλον που προάγει την παραγωγικότητα και την ακρίβεια στην εργασία των επαγγελματιών.

### 9.2.4. Κλινική Επικύρωση και Αξιολόγηση

Η τέταρτη συνεισφορά εντοπίζεται στην κλινική εφαρμογή και αξιολόγηση της πλατφόρμας σε πραγματικές συνθήκες. Μέσω συγκεκριμένων μελετών περιπτώσεων - όπως η ανάλυση λιπώδους νόσου του ήπατος, η ποσοτικοποίηση κολλαγόνου σε φλεγμονώδη νοσήματα και η πολυοργανική ανάλυση μέσω PanNuke dataset - η πλατφόρμα αξιολογήθηκε σε συνθήκες που αντανακλούν την πραγματική κλινική χρήση.

Τα αποτελέσματα δείχνουν τη δυνατότητα της πλατφόρμας να προσφέρει αξιόπιστες, επαναλήψιμες και γενικεύσιμες αναλύσεις, ενισχύοντας την εμπιστοσύνη της ιατρικής κοινότητας και παρέχοντας στέρεα βάση για μελλοντικές εφαρμογές.

### 9.2.5. Συμβολή στη Θεωρία Επεξηγήσιμης Τεχνητής Νοημοσύνης

Τέλος, η διατριβή εισφέρει στην ακαδημαϊκή συζήτηση για την ανάγκη επεξηγήσιμων και διαφανών συστημάτων τεχνητής νοημοσύνης στην ιατρική. Η ενσωμάτωση εργαλείων που επιτρέπουν την οπτικοποίηση των αποτελεσμάτων και τη συσχέτισή τους με τις εισόδους του μοντέλου ενισχύει την ερμηνευσιμότητα και διευκολύνει την κλινική αποδοχή[137].

Η πλατφόρμα δεν προτείνεται ως υποκατάστατο του παθολόγου, αλλά ως εργαλείο ενίσχυσης και υποβοήθησης της διάγνωσης, διατηρώντας τον άνθρωπο στο κέντρο της διαγνωστικής διαδικασίας.

## 9.3. Κλινική Αξία και Επίδραση

### 9.3.1. Βελτίωση Διαγνωστικής Ακρίβειας

Η κλινική επικύρωση της πλατφόρμας κατέδειξε σημαντική βελτίωση της διαγνωστικής ακρίβειας σε σύγκριση με παραδοσιακές μεθόδους. Στην ανάλυση παγκρεατικής στεάτωσης, η πλατφόρμα επίτυχε ακρίβεια 94.7% με ελάχιστο σφάλμα ποσοτικοποίησης λίπους 0.23%, ενώ στην ανίχνευση κυττάρων στο PanNuke dataset η απόδοση ξεπέρασε τα σύγχρονα πρότυπα με mAP 0.847 για ανίχνευση και 0.734 για τμηματοποίηση.

Η συνεπής απόδοση σε διαφορετικά είδη παθολογιών και ιδρυμάτων αποδεικνύει τη γενικευσιμότητα της λύσης και την ετοιμότητά της για ευρεία κλινική εφαρμογή.

### 9.3.2. Αύξηση Αποδοτικότητας Ροής Εργασίας

Η αυτοματοποίηση χρονοβόρων διαδικασιών όπως η μέτρηση ιστικών δομών και η ποσοτικοποίηση παθολογικών αλλοιώσεων οδήγησε σε δραματική μείωση του χρόνου ανάλυσης. Οι χρήστες ανέφεραν μείωση του χρόνου ανάλυσης κατά 70-85%, επιτρέποντας την επεξεργασία μεγαλύτερου όγκου δειγμάτων με τους ίδιους πόρους.

Η βελτίωση της αποδοτικότητας δεν ήρθε σε βάρος της ποιότητας, καθώς η επαναληψιμότητα των αποτελεσμάτων βελτιώθηκε σημαντικά σε σχέση με τη χειροκίνητη ανάλυση που επηρεάζεται από υποκειμενικούς παράγοντες.

### 9.3.3. Υποστήριξη Κλινικής Απόφασης

Η πλατφόρμα παρέχει στους κλινικούς εργαλεία για πιο τεκμηριωμένη λήψη αποφάσεων, προσφέροντας ποσοτικά δεδομένα που συμπληρώνουν την κλινική εμπειρία. Η δυνατότητα συσχέτισης μορφολογικών χαρακτηριστικών με προγνωστικούς δείκτες έχει ήδη οδηγήσει σε βελτιωμένη στρατιφικάτωση ασθενών και εξατομικευμένες θεραπευτικές προσεγγίσεις.

## 9.4. Περιορισμοί της Μελέτης

Παρά την επιτυχημένη εφαρμογή, η πλατφόρμα εξακολουθεί να εξαρτάται από την ποιότητα και την ποσότητα των δεδομένων εκπαίδευσης. Η απόδοση μπορεί να μειωθεί όταν εφαρμόζεται σε δεδομένα από ιδρύματα με διαφορετικά πρωτόκολλα προετοιμασίας

δειγμάτων ή χρώσης, υπογραμμίζοντας την ανάγκη για συνεχή προσαρμογή και επανεκπαίδευση.

Η επεξεργασία εικόνων ολόκληρης τομής απαιτεί σημαντικούς υπολογιστικούς πόρους, περιορίζοντας την προσβασιμότητα για ιδρύματα με περιορισμένη τεχνική υποδομή. Παρά τις βελτιστοποιήσεις που εφαρμόστηκαν, η πλήρης αξιοποίηση των δυνατοτήτων της πλατφόρμας απαιτεί επένδυση σε κατάλληλο εξοπλισμό.

Η ταχεία εξέλιξη στον τομέα της βαθιάς μάθησης και της ψηφιακής παθολογίας απαιτεί συνεχή ενημέρωση των αλγορίθμων και των μεθόδων. Αυτό δημιουργεί την ανάγκη για διαρκή συντήρηση και ανάπτυξη, που μπορεί να αποτελέσει πρόκληση για μικρότερα ερευνητικά κέντρα.

## 9.5. Μελλοντικές Κατευθύνσεις Έρευνας

### 9.5.1. Ενσωμάτωση Νέων Τεχνολογιών Τεχνητής Νοημοσύνης

Η επόμενη γενιά της πλατφόρμας θα ενσωματώσει προηγμένες αρχιτεκτονικές όπως τα Vision Transformers και τεχνικές αυτό-εποπτευόμενης μάθησης που υπόσχονται σημαντική βελτίωση της απόδοσης με μειωμένες απαιτήσεις σε επισημειωμένα δεδομένα.

Η ανάπτυξη τεχνικών κατανεμημένης μάθησης θα επιτρέψει την εκπαίδευση μοντέλων σε δεδομένα από πολλαπλά ιδρύματα χωρίς την ανάγκη κεντρικοποίησης, αντιμετωπίζοντας τόσο τα ζητήματα προστασίας δεδομένων όσο και το πρόβλημα της περιορισμένης ποικιλομορφίας δεδομένων.

### 9.5.2. Επέκταση σε Νέους Κλινικούς Τομείς

Η επέκταση της πλατφόρμας σε νέους τομείς της παθολογίας, όπως η νευροπαθολογία και η αιματοπαθολογία, αποτελεί άμεση προτεραιότητα. Η ανάπτυξη εξειδικευμένων μοντέλων για αυτούς τους τομείς θα διευρύνει σημαντικά τον αντίκτυπο της πλατφόρμας.

Η ενσωμάτωση πολυτροπικών δεδομένων, συνδυάζοντας ιστοπαθολογικές εικόνες με μοριακά δεδομένα και κλινικές πληροφορίες, θα επιτρέψει την ανάπτυξη πιο ολοκληρωμένων διαγνωστικών εργαλείων που αντανακλούν την πολυπλοκότητα των σύγχρονων ιατρικών αναλύσεων.

### 9.5.3. Βελτίωση Επεξηγησιμότητας και Εμπιστοσύνης

Η ανάπτυξη προηγμένων μεθόδων επεξήγησης των αποφάσεων της πλατφόρμας αποτελεί κρίσιμη προτεραιότητα για την αύξηση της εμπιστοσύνης των κλινικών χρηστών. Η δημιουργία ψηφιακών δίδυμων για κάθε ασθενή που θα ενσωματώνουν όλα τα διαθέσιμα δεδομένα θα επιτρέψει προσομοιώσεις διαφορετικών θεραπευτικών σεναρίων.

### 9.5.4. Ανάπτυξη Συνεργατικής Κοινότητας

Η δημιουργία ενός οικοσυστήματος ανοιχτού κώδικα γύρω από την πλατφόρμα θα επιταχύνει την ανάπτυξη και βελτίωση των δυνατοτήτων της. Η δημιουργία κοινότητας προγραμματιστών, ερευνητών και κλινικών που συνεισφέρουν νέους αλγορίθμους, δεδομένα και εφαρμογές θα διασφαλίσει τη μακροχρόνια βιωσιμότητα και εξέλιξη του έργου.

## 9.6. Τελικά Συμπεράσματα

Η παρούσα διδακτορική διατριβή επιτυγχάνει τους αρχικούς στόχους που τέθηκαν, παρουσιάζοντας μια ολοκληρωμένη λύση για την αυτοματοποιημένη ανάλυση ιστοπαθολογικών εικόνων που συνδυάζει τεχνολογική καινοτομία με κλινική χρησιμότητα. Η πλατφόρμα Deep-in-Biopsies αποτελεί σημαντικό βήμα προς την πραγματοποίηση του οράματος της ψηφιακής παθολογίας ως αναπόσπαστου μέρους της σύγχρονης διαγνωστικής ιατρικής.

Οι τεχνικές καινοτομίες που εισήχθησαν, η εκτεταμένη κλινική επικύρωση και η θετική ανταπόκριση από την επαγγελματική κοινότητα δείχνουν ότι η πλατφόρμα είναι έτοιμη για ευρύτερη εφαρμογή. Ταυτόχρονα, οι προκλήσεις που εντοπίστηκαν και οι μελλοντικές κατευθύνσεις που προτάθηκαν παρέχουν σαφή οδικό χάρτη για τη συνέχιση της έρευνας και ανάπτυξης.

Η συνεχής εξέλιξη και βελτίωση της πλατφόρμας, καθοδηγούμενη από κλινικές ανάγκες και τεχνολογικές καινοτομίες, θα διασφαλίσει τη μακροχρόνια επίδρασή της στη βελτίωση της υγειονομικής περίθαλψης. Η δημιουργία μιας κοινότητας γύρω από την πλατφόρμα θα επιτρέψει την περαιτέρω ανάπτυξη και προσαρμογή της σε νέες προκλήσεις και ευκαιρίες στον ταχέως εξελισσόμενο τομέα της ψηφιακής υγείας.

Τελικά, η παρούσα εργασία συμβάλλει σημαντικά στη γεφύρωση του χάσματος μεταξύ της ερευνητικής καινοτομίας στην τεχνητή νοημοσύνη και της πρακτικής κλινικής εφαρμογής, δημιουργώντας ένα σύστημα που όχι μόνο αποδεικνύει τη θεωρητική δυνατότητα αυτοματοποιημένης ιστοπαθολογικής ανάλυσης, αλλά και παρέχει ένα πρακτικό εργαλείο που μπορεί να χρησιμοποιηθεί άμεσα σε πραγματικές κλινικές συνθήκες.

Η επιτυχία της πλατφόρμας αποτελεί απόδειξη ότι με τη σωστή προσέγγιση, τεχνολογική εμβάθυνση και κλινική συνεργασία, είναι δυνατή η ανάπτυξη συστημάτων τεχνητής νοημοσύνης που όχι μόνο υποστηρίζουν αλλά και ενισχύουν τον ρόλο των επαγγελματιών υγείας, συμβάλλοντας στη βελτίωση της ποιότητας, ακρίβειας και αποδοτικότητας της ιατρικής φροντίδας για όφελος των ασθενών και της κοινωνίας συνολικά.

# Επιστημονικές Δημοσιεύσεις

Η ερευνητική εργασία που διεξήχθη στο πλαίσιο της παρούσας διδακτορικής διατριβής οδήγησε στη δημοσίευση οκτώ επιστημονικών άρθρων σε διεθνή συνέδρια με σύστημα κριτών και επιστημονικά περιοδικά. Οι δημοσιεύσεις καλύπτουν ένα ευρύ φάσμα εφαρμογών τεχνικών βαθιάς μάθησης στην ιστοπαθολογική ανάλυση, από την ποσοτικοποίηση παγκρεατικής στεάτωσης και την τμηματοποίηση καρκινικών κυττάρων μέχρι τη μέτρηση κολλαγόνου σε φλεγμονώδεις νόσους του εντέρου. Κάθε δημοσίευση αντιπροσωπεύει μια σημαντική συνεισφορά στο πεδίο της υπολογιστικής παθολογίας.


[1]. A. Arjmand, O. Tsakai, V. Christou, A.T. Tzallas, M.G. Tsipouras, R. Forlano, P. Manousou, R.D. Goldin, C. Gogos, E. Glavas, N. Giannakeas, “Ensemble Convolutional Neural Network Classification for Pancreatic Steatosis Assessment in Biopsy Images” *Information, MDPI*, 13(4), 160 2022. DOI: 10.3390/info13040160

[2]. O. Tsakai, A. Miltiadous, P.N. Smyrlis, A.T. Tzallas, M.G. Tsipouras, N. Giannakeas, “X-Balloon: A cloud-based platform for annotation and reinforced deep learning in digital pathology images”, *SoftwareX*, Elsevier, vol. 31, 102287, 2025. DOI: 10.1016/j.softx.2025.102287

[3]. O. Tsakai, P. Smyrlis, N. Katertsidis, A.T. Tzallas, N. Giannakeas, and M. Tsipouras, “Deep-in-Biopsies: AI-supported biopsy image processing for accurate pathology diagnosis and staging,” *IEEE, International Conference on Bioinformatics and Biomedicine (BIBM 2023)*, Istanbul, Turkey. 2023, pp. 4963-4965, DOI: 10.1109/BIBM58861.2023.10385447.

[4]. P. Smyrlis, O. Tsakai, K. Vogklis, N. Giannakeas, G. Fragulis and M. Tsipouras, “A Comparative Testing of Yolov8-based algorithm for cancer biopsy images: Case study on Pannuke pan-cancer dataset”, *8th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM),* Piraeus, Greece, 2023, pp. 1-5. DOI: 10.1109/SEEDA-CECNSM61561.2023.10470849.

[5]. K. Stefanou, O. Tsakai, C. Bellos, G. Stergios, G. Ntritsos, M.G. Tsipouras, N. Giannakeas, M. Plissiti, “On the performance of deep learning models in classification tasks,” *Data mining and knowledge discovery*, Springer, 2025. *Submitted*

[6]. E. Tsounis, R. Forlano, T. Voulgaris, P. Bosgana, O. Tsakai, N. Giannakeas, M. Kalafateli, I. Aggeletopoulou, P. Pastras, G. Diamantopoulou, C. Tsolias, M. Melachrinou, K. Thomopoulos, G. Theocharis, A. Tzallas, R. Goldin, P. Manousou, C. Triantos, “Measurement of collagen concentration throughout the intestinal layers using Deep Learning: implications in Inflammatory Bowel Disease (IBD)”, Journal of Crohn's and Colitis, vol. 19 (Suppl.1), pp. i386-i387, 2025.

[7]. E. Tsounis, R. Forlano, T. Voulgaris, P. Bosgana, O. Tsakai, N. Giannakeas, M. Kalafateli, I. Aggeletopoulou, P. Pastras, G. Diamantopoulou, C. Tsolias, M. Melachrinou, K. Thomopoulos, G. Theocharis, A. Tzallas, R. Goldin, P. Manousou, C. Triantos, Deep Learning Layer-Specific Collagen Quantification Correlates with Activity and Predicts Outcomes in Crohn’s Disease, Gastroenterology, 2025. *Submitted*

[8]. A. Arjmand, M. Pappas, O. Tsakai, V. Christou, A. Tzallas, M. Tsipouras, R. Forlano, P. Manousou, R. Goldin, E. Glavas and N. Giannakeas, “Automated Quantification of Pancreatic Steatosis in Biopsy Images using a Classification Based System,” 6th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference, Preveza, Greece, 2021. DOI: 10.1109/SEEDA-CECNSM53056.2021.9566280

[9]. V. Nastos, A. Arjmand, K. Tsakai, D. Dimopoulos; D. Varvarousis; A.T. Tzallas, N. Giannakeas, A. Ploumis, C. Gogos, "Human Activity Recognition using Machine Learning Techniques," *7th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM)*, 2022, pp. 1-5, DOI: 10.1109/SEEDA-CECNSM57760.2022.9932971.

[10]. P. Smyrlis, K. Vogklis, O. Tsakai, N. Giannakeas, and M. Tsipouras, “Evaluating Single-Pass Lightweight Segmentation Architecture on PanNuke Instance Segmentation Dataset” *IEEE, International Conference on Bioinformatics and Biomedicine (BIBM 2023)*, Istanbul, Turkey. 2023, pp. 4951-4954. DOI: 10.1109/BIBM58861.2023.10385285

[11]. P.N. Smyrlis, O. Tsakai, K. Vogklis, N. Giannakeas, G. Fragulis and M.G. Tsipouras, “Deep-In-Biopsies: AI-assisted diagnosis support for digital pathology using biopsy images,“ *10th Pan-Hellenic Conference of Biomedical Technology*, Thessaloniki, Greece, 2023

# *Γλωσσάριο Όρων*

| Αγγλικός Όρος | Ελληνική Μετάφραση |
|---|---|
| **Accuracy** | Ακρίβεια |
| **Activation Function** | Συνάρτηση Ενεργοποίησης |
| **Active Learning** | Ενεργητική Μάθηση |
| **Adam Optimizer** | Βελτιστοποιητής Adam |
| **Adaptive Histogram Equalization** | Προσαρμοστική Εξισορρόπηση Ιστογράμματος |
| **Adipose Tissue** | Λιπώδης Ιστός |
| **AI (Artificial Intelligence)** | Τεχνητή Νοημοσύνη |
| **Algorithm** | Αλγόριθμος |
| **Anchor Boxes** | Κουτιά Αγκύρωσης |
| **Annotation** | Σημειοθέτηση/Επισημείωση |
| **API (Application Programming Interface)** | Διεπαφή Προγραμματισμού Εφαρμογών |
| **Apoptosis** | Απόπτωση |
| **Architecture** | Αρχιτεκτονική |
| **Area Under Curve (AUC)** | Εμβαδόν Κάτω από την Καμπύλη |
| **Artifact** | Τεχνούργημα |
| **Attention Mechanism** | Μηχανισμός Προσοχής |
| **Augmentation** | Επαύξηση |
| **Average Pooling** | Μέση Συγκέντρωση |
| **Backbone** | Ραχοκοκαλιά Δικτύου |
| **Backend** | Σύστημα Υποστήριξης |
| **Backpropagation** | Οπισθοδιάδοση |
| **Batch Normalization** | Κανονικοποίηση Δέσμης |
| **Batch Size** | Μέγεθος Δέσμης |
| **Benign** | Καλοήθης |
| **Bias** | Μεροληψία/Πόλωση |

| | |
|---|---|
| **Binary Classification** | Δυαδική Ταξινόμηση |
| **Biomarker** | Βιοδείκτης |
| **Biopsy** | Βιοψία |
| **Black Box** | Μαύρο Κουτί |
| **Bounding Box** | Περιβάλλον Πλαίσιο |
| **Brain-Computer Interface** | Διεπαφή Εγκεφάλου-Υπολογιστή |
| **Cancer** | Καρκίνος |
| **Cascade R-CNN** | Διαδοχική R-CNN |
| **CE Marking** | Σήμανση CE |
| **Cell** | Κύτταρο |
| **Cirrhosis** | Κίρρωση |
| **Classification** | Ταξινόμηση |
| **Clinical Trial** | Κλινική Δοκιμή |
| **Cloud Computing** | Υπολογιστική Νέφους |
| **CNN (Convolutional Neural Network)** | Συνελικτικό Νευρωνικό Δίκτυο |
| **Coarse-grained Classification** | Αδρομερής Ταξινόμηση |
| **Collagen** | Κολλαγόνο |
| **Computational Pathology** | Υπολογιστική Παθολογία |
| **Computer Vision** | Υπολογιστική Όραση |
| **Confusion Matrix** | Πίνακας Σύγχυσης |
| **Container** | Εμπεριέκτης |
| **Continual Learning** | Συνεχής Μάθηση |
| **Convolutional Layer** | Συνελικτικό Στρώμα |
| **Cross-Entropy** | Διασταυρωμένη Εντροπία |
| **Cross-Validation** | Διασταυρωμένη Επικύρωση |
| **Curriculum Learning** | Μάθηση με Πρόγραμμα Σπουδών |
| **Data Augmentation** | Επαύξηση Δεδομένων |
| **Data Pipeline** | Αγωγός Δεδομένων |
| **Database** | Βάση Δεδομένων |
| **Dataset** | Σύνολο Δεδομένων |
| **Deep Learning** | Βαθιά Μάθηση |
| **Deep-in-Biopsies** | (Όνομα Πλατφόρμας) |
| **Deployment** | Ανάπτυξη/Εγκατάσταση |
| **Detection** | Ανίχνευση |
| **Detectron2** | (Βιβλιοθήκη) |
| **Diagnostic** | Διαγνωστικός |
| **DICOM** | (Πρότυπο) |
| **Digital Pathology** | Ψηφιακή Παθολογία |
| **Docker** | (Τεχνολογία) |
| **Domain Adaptation** | Προσαρμογή Πεδίου |
| **Domain Gap** | Χάσμα Πεδίου |
| **Domain Shift** | Μετατόπιση Πεδίου |

| | |
|---|---|
| **Dropout** | Απόρριψη |
| **Early Stopping** | Πρώιμη Διακοπή |
| **Edge Computing** | Υπολογισμοί Ακμής |
| **Embedding** | Ενσωμάτωμα |
| **Ensemble Methods** | Μέθοδοι Συνόλου |
| **Epoch** | Εποχή |
| **Epithelium** | Επιθήλιο |
| **Error Rate** | Ποσοστό Σφάλματος |
| **Evaluation** | Αξιολόγηση |
| **Explainability** | Επεξηγησιμότητα |
| **F1-Score** | Σκορ F1 |
| **False Negative** | Ψευδώς Αρνητικό |
| **False Positive** | Ψευδώς Θετικό |
| **FDA (Food and Drug Administration)** | (Οργανισμός) |
| **Feature** | Χαρακτηριστικό |
| **Feature Extraction** | Εξαγωγή Χαρακτηριστικών |
| **Feature Map** | Χάρτης Χαρακτηριστικών |
| **Feature Pyramid Network (FPN)** | Πυραμιδικό Δίκτυο Χαρακτηριστικών |
| **Federated Learning** | Ομοσπονδιακή Μάθηση |
| **Few-shot Learning** | Μάθηση Λίγων Λήψεων |
| **FHIR** | (Πρότυπο) |
| **Fibrosis** | Ίνωση |
| **Fine-grained Classification** | Λεπτομερής Ταξινόμηση |
| **Fine-Tuning** | Λεπτομερής Ρύθμιση |
| **Framework** | Πλαίσιο |
| **Frontend** | Διεπαφή Χρήστη |
| **Fully Connected Layer** | Πλήρως Συνδεδεμένο Στρώμα |
| **GAN (Generative Adversarial Network)** | Γεννητικό Ανταγωνιστικό Δίκτυο |
| **GDPR** | (Κανονισμός) |
| **Generalization** | Γενίκευση |
| **GPU (Graphics Processing Unit)** | Μονάδα Επεξεργασίας Γραφικών |
| **Gradient** | Κλίση |
| **Gradient Descent** | Κατάβαση Κλίσης |
| **Ground Truth** | Θεμελιώδης Αλήθεια |
| **H&E (Hematoxylin and Eosin)** | Αιματοξυλίνη και Ηωσίνη |
| **Healthcare** | Υγειονομική Περίθαλψη |
| **Heat Map** | Θερμικός Χάρτης |
| **HIPAA** | (Νομοθεσία) |
| **Histopathology** | Ιστοπαθολογία |
| **HL7** | (Πρότυπο) |
| **Hybrid Approaches** | Υβριδικές Προσεγγίσεις |

| | |
|---|---|
| **Hyperparameter** | Υπερπαράμετρος |
| **IBD (Inflammatory Bowel Disease)** | Φλεγμονώδης Νόσος του Εντέρου |
| **IHC (Immunohistochemistry)** | Ανοσοϊστοχημεία |
| **Image Processing** | Επεξεργασία Εικόνας |
| **Image Segmentation** | Τμηματοποίηση Εικόνας |
| **Inference** | Εξαγωγή Συμπερασμάτων |
| **Inference Time** | Χρόνος Εξαγωγής Συμπερασμάτων |
| **Instance Segmentation** | Τμηματοποίηση Στιγμιοτύπων |
| **Interoperability** | Διαλειτουργικότητα |
| **Interpretability** | Ερμηνευσιμότητα |
| **Intersection over Union (IoU)** | Τομή προς Ένωση |
| **Iteration** | Επανάληψη |
| **Jaccard Index** | Δείκτης Jaccard |
| **Keypoint Detection** | Ανίχνευση Σημείων Κλειδιών |
| **Keypoint R-CNN** | R-CNN Σημείων Κλειδιών |
| **Knowledge Distillation** | Απόσταξη Γνώσης |
| **Kubernetes** | (Τεχνολογία) |
| **Label** | Ετικέτα |
| **Labeled Data** | Επισημασμένα Δεδομένα |
| **Latency** | Καθυστέρηση |
| **Layer** | Στρώμα |
| **Learning Rate** | Ρυθμός Μάθησης |
| **Linear Regression** | Γραμμική Παλινδρόμηση |
| **Loss Function** | Συνάρτηση Απώλειας |
| **Lymphocyte** | Λεμφοκύτταρο |
| **Machine Learning** | Μηχανική Μάθηση |
| **Malignant** | Κακοήθης |
| **Mask R-CNN** | (Αρχιτεκτονική) |
| **Max Pooling** | Μέγιστη Συγκέντρωση |
| **Mean Average Precision (mAP)** | Μέση Μέση Ακρίβεια |
| **Medical Device** | Ιατροτεχνολογικό Προϊόν |
| **Meta-learning** | Μεταμάθηση |
| **Metadata** | Μεταδεδομένα |
| **Metastasis** | Μετάσταση |
| **Microservices** | Μικροϋπηρεσίες |
| **MIL (Multiple Instance Learning)** | Πολλαπλή Άμεση Εκμάθηση |
| **Mitosis** | Μίτωση |
| **Mixed Precision Training** | Εκπαίδευση Μικτής Ακρίβειας |
| **Model** | Μοντέλο |
| **Model Compression** | Συμπίεση Μοντέλου |
| **Model Ensemble** | Σύνολο Μοντέλων |
| **Model Zoo** | Αποθετήριο Μοντέλων |

| | |
|---|---|
| **Momentum** | Ορμή |
| **Multi-class Classification** | Πολυκλασική Ταξινόμηση |
| **Multi-GPU Training** | Εκπαίδευση Πολλαπλών GPU |
| **Multi-label Classification** | Πολυετικετική Ταξινόμηση |
| **Multi-modal Learning** | Πολυτροπική Μάθηση |
| **Multi-scale** | Πολυκλιμακωτή |
| **Multi-task Learning** | Πολυ-εργασιακή Μάθηση |
| **Necrosis** | Νέκρωση |
| **Neural Network** | Νευρωνικό Δίκτυο |
| **Normalization** | Κανονικοποίηση |
| **Nucleus** | Πυρήνας |
| **Object Detection** | Ανίχνευση Αντικειμένων |
| **Optimizer** | Βελτιστοποιητής |
| **Overfitting** | Υπερπροσαρμογή |
| **Panoptic Segmentation** | Πανοπτική Τμηματοποίηση |
| **Patch** | Τεμάχιο |
| **Pathologist** | Παθολόγος |
| **Pathology** | Παθολογία |
| **Patient** | Ασθενής |
| **Performance Metrics** | Μετρικές Απόδοσης |
| **Pipeline** | Αγωγός |
| **Pixel** | Εικονοστοιχείο |
| **Pooling** | Συγκέντρωση |
| **Precision** | Ακρίβεια Θετικών |
| **Prediction** | Πρόβλεψη |
| **Preprocessing** | Προεπεξεργασία |
| **Pretrained Model** | Προεκπαιδευμένο Μοντέλο |
| **Privacy** | Ιδιωτικότητα |
| **Pruning** | Κλάδεμα |
| **PyTorch** | (Βιβλιοθήκη) |
| **Quality Assurance** | Διασφάλιση Ποιότητας |
| **Quantization** | Κβαντοποίηση |
| **Random Forest** | Τυχαίο Δάσος |
| **Real-time** | Πραγματικός Χρόνος |
| **Recall** | Ανάκληση |
| **Region of Interest (ROI)** | Περιοχή Ενδιαφέροντος |
| **Region Proposal Network (RPN)** | Δίκτυο Πρότασης Περιοχών |
| **Registry** | Μητρώο |
| **Regularization** | Κανονικοποίηση |
| **Regulatory Compliance** | Κανονιστική Συμμόρφωση |
| **Reinforcement Learning** | Ενισχυτική Μάθηση |
| **ReLU (Rectified Linear Unit)** | Διορθωμένη Γραμμική Μονάδα |

| | |
|---|---|
| **ResNet** | (Αρχιτεκτονική) |
| **ResNeXt** | (Αρχιτεκτονική) |
| **REST** | (Πρωτόκολλο) |
| **RetinaNet** | (Αρχιτεκτονική) |
| **ROC Curve** | Καμπύλη ROC |
| **Scalability** | Κλιμακωσιμότητα |
| **Scan** | Σάρωση |
| **Security** | Ασφάλεια |
| **Segmentation** | Τμηματοποίηση |
| **Self-Supervised Learning** | Αυτοεποπτευόμενη Μάθηση |
| **Semantic Segmentation** | Σημασιολογική Τμηματοποίηση |
| **Semi-Supervised Learning** | Ημι-εποπτευόμενη Μάθηση |
| **Sensitivity** | Ευαισθησία |
| **SGD (Stochastic Gradient Descent)** | Στοχαστική Κατάβαση Κλίσης |
| **Sigmoid** | Σιγμοειδής Συνάρτηση |
| **Slide** | Πλακίδιο |
| **Socket.IO** | (Τεχνολογία) |
| **Softmax** | Συνάρτηση Softmax |
| **Specificity** | Ειδικότητα |
| **Stain Normalization** | Κανονικοποίηση Χρώσης |
| **Staining** | Χρώση |
| **Steatosis** | Στεάτωση |
| **Stroma** | Στρώμα |
| **Supervised Learning** | Εποπτευόμενη Μάθηση |
| **Support Vector Machine** | Μηχανή Διανυσμάτων Υποστήριξης |
| **TensorFlow** | (Βιβλιοθήκη) |
| **Test Set** | Σύνολο Δοκιμής |
| **Threshold** | Κατώφλι |
| **Throughput** | Ρυθμαπόδοση |
| **Tile** | Πλακίδιο |
| **Tissue** | Ιστός |
| **Training** | Εκπαίδευση |
| **Training Set** | Σύνολο Εκπαίδευσης |
| **Transfer Learning** | Μεταφορά Μάθησης |
| **Transformer** | Μετασχηματιστής |
| **True Negative** | Αληθώς Αρνητικό |
| **True Positive** | Αληθώς Θετικό |
| **Tumor** | Όγκος |
| **Underfitting** | Υποπροσαρμογή |
| **Unsupervised Learning** | Μη Εποπτευόμενη Μάθηση |
| **Validation** | Επικύρωση |
| **Validation Set** | Σύνολο Επικύρωσης |

| | |
|---|---|
| **Vision Transformer** | Μετασχηματιστής Όρασης |
| **Voxel** | Ογκοστοιχείο |
| **Weakly Supervised Learning** | Ασθενώς Εποπτευόμενη Μάθηση |
| **Weight** | Βάρος |
| **Weight Decay** | Απόσβεση Βαρών |
| **Weight Initialization** | Αρχικοποίηση Βαρών |
| **Whole Slide Image (WSI)** | Ολική Εικόνα Πλακιδίου |
| **XML** | (Μορφότυπος) |
| **YAML** | (Μορφότυπος) |
| **YOLO** | (Αρχιτεκτονική) |
| **Zero-shot Learning** | Μάθηση Μηδενικής Λήψης |

# *Κώδικας Υλοποίησης*

| Module | Σύνδεσμος | Εναλλακτικός σύνδεσμος |
|---|---|---|
| **Backend** | Deep-in-Biopsies Backend | X-Balloon Backend |
| **Frontend** | Deep-in-Biopsies Frontend | X-Balloon Frontend |
| **AI** | Deep-in-Biopsies AI | X-Balloon AI |

*Όλα τα παρακάτω αποθετήρια (Deep-in-Biopsies και X-Balloon, Backend, Frontend και AI) αποτελούν έργα που δημιουργήθηκαν και υλοποιήθηκαν αποκλειστικά από τον συγγραφέα της διατριβής.*

*Τα αποθετήρια Deep-in-Biopsies (Backend, Frontend, AI) είναι ιδιωτικά (private) στο GitHub, καθώς αποτελούν εμπορικά έργα με προστατευμένα δικαιώματα πνευματικής ιδιοκτησίας και εμπιστευτικότητας. Η πρόσβαση στον πηγαίο κώδικα παρέχεται μόνο κατόπιν σχετικού αιτήματος και έγκρισης από τον δημιουργό.*

*Η εναλλακτική σύνδεση οδηγεί στο έργο X-Balloon, το οποίο αποτελεί την πρώτη έκδοση της υλοποίησης για registry βιοψιών και είναι δημοσίως προσβάσιμο μέσω δημόσιου αποθετηρίου (open-source). Οι τεχνολογίες και η αρχιτεκτονική που χρησιμοποιήθηκαν στα δύο έργα είναι εντελώς διαφορετικές, με κοινό σημείο μόνο τη βασική ιδέα λειτουργίας των συστημάτων.*

*Για την παραπομπή στα ιδιωτικά αποθετήρια Deep-in-Biopsies (Backend, Frontend, AI), στη βιβλιογραφία ή σε σχετική σημείωση, σημειώνεται ρητά: «Πρόσβαση κατόπιν αιτήματος στον συγγραφέα.»*

*Για τα δημόσια αποθετήρια X-Balloon (Backend, Frontend, AI modules), μπορεί να γίνει κανονική βιβλιογραφική παραπομπή, με καταγραφή του URL και της ημερομηνίας πρόσβασης.*

# *Αναφορές*

[1] L. Pantanowitz, A. Sharma, D. Carter, and J. Kurc, “Twenty years of digital pathology: an overview of the evolution and future,” *J Pathol Inform*, vol. 9, p. 36, 2018.

[2] A. Bandi and others, “From detection of individual metastases to classification of lymph node status at the patient level: The CAMELYON17 challenge,” *IEEE Trans Med Imaging*, vol. 38, no. 2, pp. 550–560, 2019.

[3] J. R. Garcia Rojo, “International collaboration for standards and guidelines in digital pathology,” *Stud Health Technol Inform*, vol. 222, pp. 131–143, 2016.

[4] C. Williams and others, “Barriers and facilitators to the implementation of digital pathology: a systematic review,” *J Clin Pathol*, vol. 75, pp. 1–10, 2022.

[5] D. J. Steiner and others, “Impact of AI-based tools on pathology workflows: current limitations and future perspectives,” *Arch Pathol Lab Med*, vol. 145, no. 4, pp. 437–445, 2021.

[6] J. A. Oakden-Rayner and others, “Hidden stratification causes clinically meaningful failures in machine learning for medical imaging,” in *Proceedings of the ACM Conference on Health, Inference, and Learning*, 2020, pp. 151–159.

[7] S. Graham and others, “Hover-Net: Simultaneous segmentation and classification of nuclei in multi-tissue histology images,” *Med Image Anal*, vol. 58, p. 101563, 2019.

[8] A. Madabhushi and G. Lee, “Image analysis and machine learning in digital pathology: Challenges and opportunities,” *Med Image Anal*, vol. 33, pp. 170–175, 2016.

[9] M. Aeffner and others, “Digital imaging in pathology: an overview,” *Vet Pathol*, vol. 56, no. 1, pp. 9–31, 2019.

[10] R. Forlano and others, “Histological and imaging-based assessment of fibrosis in IBD: Current status and future perspectives,” *J Crohns Colitis*, vol. 15, no. 6, pp. 925–935, 2021.

[11] J. Kleiner and others, “Design and validation of a histological scoring system for nonalcoholic fatty liver disease,” *Hepatology*, vol. 41, no. 6, pp. 1313–1321, 2005.

[12] G. Campanella and others, “Clinical-grade computational pathology using weakly supervised deep learning on whole slide images,” *Nat Med*, vol. 25, no. 8, pp. 1301–1309, 2019.

[13] A. Coudray and others, “Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning,” *Nat Med*, vol. 24, no. 10, pp. 1559–1567, 2018.

[14] E. Tsounis and others, “Measurement of collagen concentration throughout the intestinal layers using Deep Learning in IBD,” *J Crohns Colitis*, vol. 19, no. 1, p. i388, 2025.

[15] A. Holzinger and others, “What do we need to build explainable AI systems for the medical domain?,” *Review of Scientific Instruments*, vol. 88, no. 12, p. 121701, 2017.

[16] G. Litjens and others, “A survey on deep learning in medical image analysis,” *Med Image Anal*, vol. 42, pp. 60–88, 2017.

[17] B. J. Williams, A. Hanby, R. Millican-Slater, A. Nijhawan, E. Verghese, and D. Treanor, “Digital pathology for the primary diagnosis of breast histopathological specimens: an environmental and economic evaluation,” *Histopathology*, vol. 75, no. 6, pp. 940–953, 2019.

[18] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

[19] M. Garcia-Rojo, J. Conde-Olasagasti, C. López, J. M. García Gomez, and F. Muñoz, “Implementation and integration of digital pathology in hospitals,” *Diagn Pathol*, vol. 11, no. 1, pp. 1–9, 2016.

[20] B. Ehteshami Bejnordi *et al.*, “Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer,” *JAMA*, vol. 318, no. 22, pp. 2199–2210, 2017.

[21] A. T. Tzallas *et al.*, “Automated epileptic seizure detection methods: a review study,” in *Epilepsy-histological, electroencephalographic and psychological aspects*, IntechOpen, 2012.

[22] A. Esteva *et al.*, “A guide to deep learning in healthcare,” *Nat Med*, vol. 25, no. 1, pp. 24–29, 2019.

[23] A. Arjmand *et al.*, "Ensemble Convolutional Neural Network Classification for Pancreatic Steatosis Assessment in Biopsy Images," *Information*, vol. 13, no. 4, p. 160, 2022.

[24] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," in *Proceedings of the IEEE International Conference on Computer Vision*, 2017, pp. 2961–2969.

[25] A. Kirillov, K. He, R. Girshick, C. Rother, and P. Dollár, "Panoptic segmentation," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 9404–9413.

[26] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 580–587.

[27] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," *Adv Neural Inf Process Syst*, vol. 28, pp. 91–99, 2015.

[28] T. Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 2117–2125.

[29] N. Kumar, R. Verma, S. Sharma, S. Bhargava, A. Vahadane, and A. Sethi, "A dataset and a technique for generalized nuclear segmentation for computational pathology," *IEEE Trans Med Imaging*, vol. 36, no. 7, pp. 1550–1560, 2017.

[30] A. Janowczyk and A. Madabhushi, "Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases," *J Pathol Inform*, vol. 7, no. 1, p. 29, 2016.

[31] Z. Cai and N. Vasconcelos, "Cascade R-CNN: Delving Into High Quality Object Detection," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 6154–6162. doi: 10.1109/CVPR.2018.00644.

[32] A. Kirillov, Y. Wu, K. He, and R. Girshick, "PointRend: Image segmentation as rendering," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, pp. 9799–9808.

[33] K. Chen *et al.*, "Hybrid task cascade for instance segmentation," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 4974–4983.

[34] N. Carion, F. Massa, G. Synnaeve, N. Usunier, A. Kirillov, and S. Zagoruyko, "End-to-end object detection with transformers," in *European Conference on Computer Vision*, Springer, 2020, pp. 213–229.

[35] B. Cheng, I. Misra, A. G. Schwing, A. Kirillov, and R. Girdhar, "Masked-attention mask transformer for universal image segmentation," in *Proceedings of the*

*IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022, pp. 1290–1299.

[36] M. Veta, J. P. Pluim, P. J. Van Diest, and M. A. Viergever, "Breast cancer histopathology image analysis: a review," *IEEE Trans Biomed Eng*, vol. 61, no. 5, pp. 1400–1411, 2014.

[37] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs," *IEEE Trans Pattern Anal Mach Intell*, vol. 40, no. 4, pp. 834–848, 2017.

[38] Y. Wu, A. Kirillov, F. Massa, W. Y. Lo, and R. Girshick, "Detectron2," 2019.

[39] O. Tsakai *et al.*, "Deep-in-Biopsies: An integrated platform for histopathological image analysis with deep learning," *Information*, vol. 13, no. 4, p. 160, 2022.

[40] T. Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal loss for dense object detection," in *Proceedings of the IEEE International Conference on Computer Vision*, 2017, pp. 2980–2988.

[41] Z. Tian, C. Shen, H. Chen, and T. He, "FCOS: Fully convolutional one-stage object detection," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 9627–9636.

[42] Y. Wang, Q. Yao, J. T. Kwok, and L. M. Ni, "Generalizing from a few examples: A survey on few-shot learning," *ACM Comput Surv*, vol. 53, no. 3, pp. 1–34, 2020.

[43] A. Cheerla and O. Gevaert, "Deep learning with multimodal representation for pancancer prognosis prediction," *Bioinformatics*, vol. 35, no. 14, pp. i446–i454, 2019.

[44] P. Bankhead and others, "QuPath: Open source software for digital pathology image analysis," *Sci Rep*, vol. 7, no. 1, p. 16878, 2017.

[45] U. Schmidt and others, "Cell detection with star-convex polygons," in *Medical Image Computing and Computer Assisted Intervention*, 2018, pp. 265–273.

[46] A. Goode and others, "OpenSlide: A vendor-neutral software foundation for digital pathology," *J Pathol Inform*, vol. 4, p. 27, 2013.

[47] R. Marée and others, "Collaborative analysis of multi-gigapixel imaging data using Cytomine," *Bioinformatics*, vol. 32, no. 9, pp. 1395–1401, 2016.

[48] R. Mormont and others, "Comparison of deep transfer learning strategies for digital pathology," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2018, pp. 2262–2271.

[49] M. Stritt and others, "Orbit Image Analysis: An open-source whole slide image analysis tool," *PLoS Comput Biol*, vol. 16, no. 2, p. e1007313, 2020.

[50] M. Hägele and others, “Resolving challenges in deep learning-based analyses of histopathological images through explanation methods,” *Sci Rep*, vol. 10, no. 1, p. 6423, 2020.

[51] K. Bera and others, “Artificial intelligence in digital pathology – new tools for diagnosis and precision oncology,” *Nat Rev Clin Oncol*, vol. 16, no. 11, pp. 703–715, 2019.

[52] M. García-Rojo and others, “New European Union regulations related to whole slide image scanners and image analysis software,” *J Pathol Inform*, vol. 10, p. 2, 2019.

[53] M. K. K. Niazi and others, “Digital pathology and artificial intelligence,” *Lancet Oncol*, vol. 20, no. 5, pp. e253–e261, 2019.

[54] M. J. Cardoso and others, “MONAI: An open-source framework for deep learning in healthcare,” *arXiv preprint arXiv:2211.02701*, 2022.

[55] O. Tsakai and others, “X-Balloon: A cloud-based platform for annotation and reinforced deep learning in digital pathology images,” *SoftwareX*, vol. 31, p. 102287, 2025.

[56] D. Komura and others, “Machine learning methods for histopathological image analysis,” *Comput Struct Biotechnol J*, vol. 16, pp. 34–42, 2018.

[57] L. Chen and others, “Attention-based deep learning for pathology image analysis: A systematic review,” *Med Image Anal*, vol. 68, p. 101909, 2021.

[58] M. D. Wilkinson and others, “The FAIR Guiding Principles for scientific data management and stewardship,” *Sci Data*, vol. 3, p. 160018, 2016.

[59] A. Holzinger and others, “Causability and explainability of artificial intelligence in medicine,” *Wiley Interdiscip Rev Data Min Knowl Discov*, vol. 9, no. 4, p. e1312, 2019.

[60] S. W. Jahn and others, “Digital pathology: advantages, limitations and emerging perspectives,” *J Clin Med*, vol. 9, no. 11, p. 3697, 2020.

[61] C. Higgins, “Applications and challenges of digital pathology and whole slide imaging,” *Biotechnic and Histochemistry*, vol. 90, no. 5, pp. 341–347, 2015.

[62] J. A. Retamero and others, “Complete digital pathology for routine histopathology diagnosis in a multicenter hospital network,” *Arch Pathol Lab Med*, vol. 144, no. 2, pp. 221–228, 2020.

[63] V. Baxi and others, “Digital pathology and artificial intelligence in translational medicine and clinical practice,” *Modern Pathology*, vol. 35, no. 1, pp. 23–32, 2022.

[64] P. Ström and others, “Artificial intelligence for diagnosis and grading of prostate cancer in biopsies: a population-based, diagnostic study,” *Lancet Oncol*, vol. 21, no. 2, pp. 222–232, 2020.

[65] L. Pantanowitz and others, “Twenty years of digital pathology: an overview of the road travelled, what is on the horizon, and the emergence of vendor-neutral archives,” *J Pathol Inform*, vol. 9, p. 40, 2018.

[66] S. Mukhopadhyay and others, “Whole slide imaging versus microscopy for primary diagnosis in surgical pathology: a multicenter blinded randomized noninferiority study of 1992 cases (Pivotal Study),” *American Journal of Surgical Pathology*, vol. 42, no. 1, pp. 39–52, 2018.

[67] A. Cooper, *The inmates are running the asylum: Why high-tech products drive us crazy and how to restore the sanity*. Sams Publishing, 2004.

[68] M. D. Zarella *et al.*, “A practical guide to whole slide imaging: a white paper from the digital pathology association,” *Arch Pathol Lab Med*, vol. 142, no. 2, pp. 222–234, 2018.

[69] A. Madabhushi and G. Lee, “Image analysis and machine learning in digital pathology: challenges and opportunities,” *Med Image Anal*, vol. 33, pp. 170–175, 2016.

[70] J. G. Elmore *et al.*, “Diagnostic concordance among pathologists interpreting breast biopsy specimens,” *JAMA*, vol. 313, no. 11, pp. 1122–1132, 2015.

[71] D. Komura and S. Ishikawa, “Machine learning methods for histopathological image analysis,” *Comput Struct Biotechnol J*, vol. 16, pp. 34–42, 2018.

[72] A. Goode, B. Gilbert, J. Harkes, D. Jukic, and M. Satyanarayanan, “OpenSlide: A vendor-neutral software foundation for digital pathology,” *J Pathol Inform*, vol. 4, no. 1, p. 27, 2013.

[73] M. K. K. Niazi, A. V Parwani, and M. N. Gurcan, “Digital pathology and artificial intelligence,” *Lancet Oncol*, vol. 20, no. 5, pp. e253–e261, 2019.

[74] A. Kleppe *et al.*, “Chromatin organisation and cancer prognosis: a pan-cancer study,” *Lancet Oncol*, vol. 22, no. 5, pp. 722–733, 2021.

[75] N. Stathonikos, M. Veta, A. Huisman, and P. J. Van Diest, “Going fully digital: perspective of a Dutch academic pathology lab,” *J Pathol Inform*, vol. 4, no. 1, p. 15, 2013.

[76] R. Colling *et al.*, “Artificial intelligence in digital pathology,” *CM-Path AI in Histopathology Working Group*, 2019.

[77] L. Bass, P. Clements, and R. Kazman, *Software Architecture in Practice*, 4th ed. Addison-Wesley Professional, 2021.

[78] M. Fowler, *Patterns of Enterprise Application Architecture*. Addison-Wesley Professional, 2002.

[79] M. L. Abbott and M. T. Fisher, *The Art of Scalability: Scalable Web Architecture, Processes, and Organizations for the Modern Enterprise*. Addison-Wesley Professional, 2015.

[80] C. Richardson, *Microservices Patterns: With Examples in Java*. Manning Publications, 2018.

[81] G. Hohpe and B. Woolf, *Enterprise Integration Patterns: Designing, Building, and Deploying Messaging Solutions*. Addison-Wesley Professional, 2003.

[82] M. Kleppmann, *Designing Data-Intensive Applications: The Big Ideas Behind Reliable, Scalable, and Maintainable Systems*. O'Reilly Media, 2017.

[83] A. B. Bondi, "Characteristics of scalability and their impact on performance," in *Proceedings of the 2nd international workshop on Software and performance*, 2000, pp. 195–203.

[84] C. U. Smith and L. G. Williams, *Performance Solutions: A Practical Guide to Creating Responsive, Scalable Software*. Addison-Wesley Professional, 2001.

[85] R. C. Martin, *Clean Architecture: A Craftsman's Guide to Software Structure and Design*. Prentice Hall, 2017.

[86] M. T. Nygard, *Release It!: Design and Deploy Production-Ready Software*. Pragmatic Bookshelf, 2018.

[87] E. Evans, *Domain-Driven Design: Tackling Complexity in the Heart of Software*. Addison-Wesley Professional, 2003.

[88] E. Gamma, R. Helm, R. Johnson, and J. Vlissides, *Design Patterns: Elements of Reusable Object-Oriented Software*. Addison-Wesley Professional, 1994.

[89] K. Banker, D. Garrett, P. Bakkum, and S. Verch, *MongoDB in Action: Covers MongoDB version 3.0*. Manning Publications, 2016.

[90] R. T. Fielding, "Architectural Styles and the Design of Network-based Software Architectures," University of California, Irvine, 2000.

[91] "Laravel Sanctum Documentation," https://laravel.com/docs/sanctum.

[92] D. A. Norman, *The Design of Everyday Things: Revised and Expanded Edition*. Basic Books, 2013.

[93] J. Nielsen, *Usability Engineering*. Morgan Kaufmann Publishers, 1993.

[94] S. K. Card, G. G. Robertson, and J. D. Mackinlay, "The information visualizer, an information workspace," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 1991, pp. 181–186.

[95] B. Shneiderman, "The eyes have it: A task by data type taxonomy for information visualizations," in *Proceedings of the IEEE Symposium on Visual Languages*, 1996, pp. 336–343.

[96] T. Munzner, *Visualization Analysis and Design*. CRC Press, 2014.

[97] J. Bertin, *Semiology of Graphics: Diagrams, Networks, Maps*. ESRI Press, 2010.

[98] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," in *Proceedings of the IEEE International Conference on Computer Vision*, 2017, pp. 2961–2969.

[99] T. Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid networks for object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 2117–2125.

[100] Deep-in-Biopsies Technical Team, "Annotation tools implementation guide," 2023.

[101] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.

[102] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Trans Knowl Data Eng*, vol. 22, no. 10, pp. 1345–1359, 2010.

[103] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," *Adv Neural Inf Process Syst*, vol. 27, pp. 3320–3328, 2014.

[104] J. Howard and S. Ruder, "Universal language model fine-tuning for text classification," in *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 2018, pp. 328–339.

[105] L. N. Smith, "Cyclical learning rates for training neural networks," in *Proceedings of the IEEE Winter Conference on Applications of Computer Vision*, 2017, pp. 464–472.

[106] Y. Wu and others, "Detectron2: A PyTorch-based modular object detection library," 2019, *Facebook AI Research*.

[107] D. Tellez and others, "Quantifying the effects of data augmentation and stain color normalization in convolutional neural networks for computational pathology," *Med Image Anal*, vol. 58, p. 101544, 2019.

[108] Z. Zhong and others, "Random erasing data augmentation," in *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, pp. 13001–13008.

[109] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J Big Data*, vol. 6, no. 1, p. 60, 2019.

[110] E. D. Cubuk and others, "AutoAugment: Learning augmentation strategies from data," in *Computer Vision and Pattern Recognition*, 2020, pp. 113–123.

[111] N. Corporation, "CUDA Toolkit Documentation," 2021.

[112] A. Arjmand and others, “Ensemble convolutional neural network classification for pancreatic steatosis assessment in biopsy images,” *Information*, vol. 13, no. 4, p. 160, 2022.

[113] K. Stacke and others, “Measuring domain shift for deep learning in histopathology,” *IEEE J Biomed Health Inform*, vol. 25, no. 2, pp. 325–336, 2019.

[114] J. Bergstra and Y. Bengio, “Random search for hyper-parameter optimization,” *Journal of Machine Learning Research*, vol. 13, no. 2, pp. 281–305, 2012.

[115] A. Arjmand and others, “GPU acceleration performance analysis in histopathological image processing,” *Information*, vol. 13, no. 4, p. 160, 2022.

[116] D. Kirk and others, “NVIDIA CUDA software and GPU parallel computing architecture,” in *ISMM*, 2007, pp. 103–104.

[117] T. Chen and others, “Training deep nets with sublinear memory cost,” *arXiv preprint arXiv:1604.06174*, 2016.

[118] M. Stauffer, *Laravel: Up & Running*. O’Reilly Media, Inc., 2023.

[119] Laravel Livewire Documentation, “Building Dynamic User Interfaces,” 2024.

[120] T. Sanderson, “Role-Based Access Control in Modern Web Applications,” *Journal of Software Engineering*, vol. 15, no. 3, pp. 234–251, 2022.

[121] MongoDB Inc., “MongoDB Manual: Document Database Architecture,” 2024.

[122] L. Richardson and S. Ruby, *RESTful Web APIs: Services for a Changing World*. O’Reilly Media, 2013.

[123] Laravel Queue Documentation, “Queue Workers and Job Management,” 2024.

[124] “Intellij Idea,” https://www.jetbrains.com/idea/.

[125] R. Rai, *Socket.IO Real-time Web Application Development*. Packt Publishing Ltd., 2013.

[126] J. Kamps and R. Pind, “Laravel Eloquent Performance Patterns,” 2019.

[127] D. M. W. Powers, “Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation,” *arXiv:2010.16061*, 2020.

[128] Mozilla Developer Network, “Single-page application,” 2023.

[129] Konva Development Team, “Konva 2D Canvas Library Documentation,” 2024.

[130] S. Murray, *Interactive Data Visualization for the Web: An Introduction to Designing with D3*. O’Reilly Media, 2017.

[131] N. P. Jouppi *et al.*, “In-datacenter performance analysis of a tensor processing unit,” *ACM SIGARCH Computer Architecture News*, vol. 45, no. 2, pp. 1–12, 2017.

[132] S. Li *et al.*, "PyTorch distributed: Experiences on accelerating data parallel training," *Proceedings of the VLDB Endowment*, vol. 13, no. 12, pp. 3005–3018, 2020.

[133] A. Arjmand *et al.*, "Automated Quantification of Pancreatic Steatosis in Biopsy Images using a Classification Based System," in *2021 6th South-East Europe Design Automation, Computer Engineering, Computer Networks and Social Media Conference (SEEDA-CECNSM)*, IEEE, Sep. 2021, pp. 1–5. doi: 10.1109/SEEDA-CECNSM53056.2021.9566280.

[134] A. Arjmand, D. Angelis, A. Tzallas, and others, "Pancreatic steatosis evaluation through CNN ensemble classification," in *IEEE SEEDA-CECNSM*, 2021, pp. 1–6.

[135] R. Forlano, B. H. Mullish, N. Giannakeas, and others, "High-throughput, machine learning–based quantification of steatosis, inflammation, ballooning, and fibrosis in biopsies from patients with nonalcoholic fatty liver disease," *Clinical Gastroenterology and Hepatology*, vol. 18, no. 9, pp. 2081–2090, 2020.

[136] F. Rieder, P. K. Mukherjee, W. J. Massey, and others, "Fibrosis in IBD: from pathogenesis to therapeutic targets," *Gut*, vol. 73, no. 5, pp. 854–866, 2024.

[137] A. Arjmand, M. G. Tsipouras, A. T. Tzallas, and others, "Quantification of liver fibrosis—a comparative study," *Applied Sciences*, vol. 10, no. 2, p. 447, 2020.

[138] G. D'Haens, K. Geboes, M. Peeters, and others, "Early lesions of recurrent Crohn's disease caused by infusion of intestinal contents in excluded ileum," *Gastroenterology*, vol. 114, no. 2, pp. 262–267, 1998.

[139] J. Gamper, N. A. Koohbanani, K. Benet, and others, "PanNuke: an open pan-cancer histology dataset for nuclei instance segmentation and classification," in *European Congress on Digital Pathology*, 2019, pp. 11–19.

[140] J. Gamper, N. A. Koohbanani, S. Graham, and others, "PanNuke dataset extension, insights and baselines," *arXiv preprint arXiv:2003.10778*, 2020.

[141] P. N. Smyrlis, O. Tsakai, K. Vogklis, and others, "A comparative testing of Yolov8-based algorithm for cancer biopsy images: Case study on Pannuke pan-cancer dataset," in *IEEE SEEDA-CECNSM*, 2023, pp. 1–5.

[142] S. Chen, C. Ding, M. Liu, and others, "CPP-Net: Context-aware polygon proposal network for nucleus segmentation," *IEEE Transactions on Image Processing*, vol. 32, pp. 980–994, 2023.

[143] European Commission, "Regulation (EU) 2017/745 on medical devices," 2017.

[144] A. Serag, A. Ion-Margineanu, H. Qureshi, and others, "Translational AI and deep learning in diagnostic pathology," *Front Med (Lausanne)*, vol. 6, p. 185, 2019.

[145] Odysseas Tsakai, “Kidney Dataset,” https://drive.google.com/drive/folders/1Nxu2fW89fDrKXyJWK5cgGxqPZw56lKAt?usp=sharing.

[146] Odysseas Tsakai, “IBD,” https://drive.google.com/drive/folders/1oEDPYaq-N-3faxjO_CmtYu_yrHCDWh9a?usp=drive_link.

[147] P. N. Smyrlis, O. Tsakai, K. Vogklis, and et al., “A comparative testing of Yolov8-based algorithm for cancer biopsy images: Case study on Pannuke pan-cancer dataset,” in *IEEE SEEDA-CECNSM*, 2023, pp. 1–5.