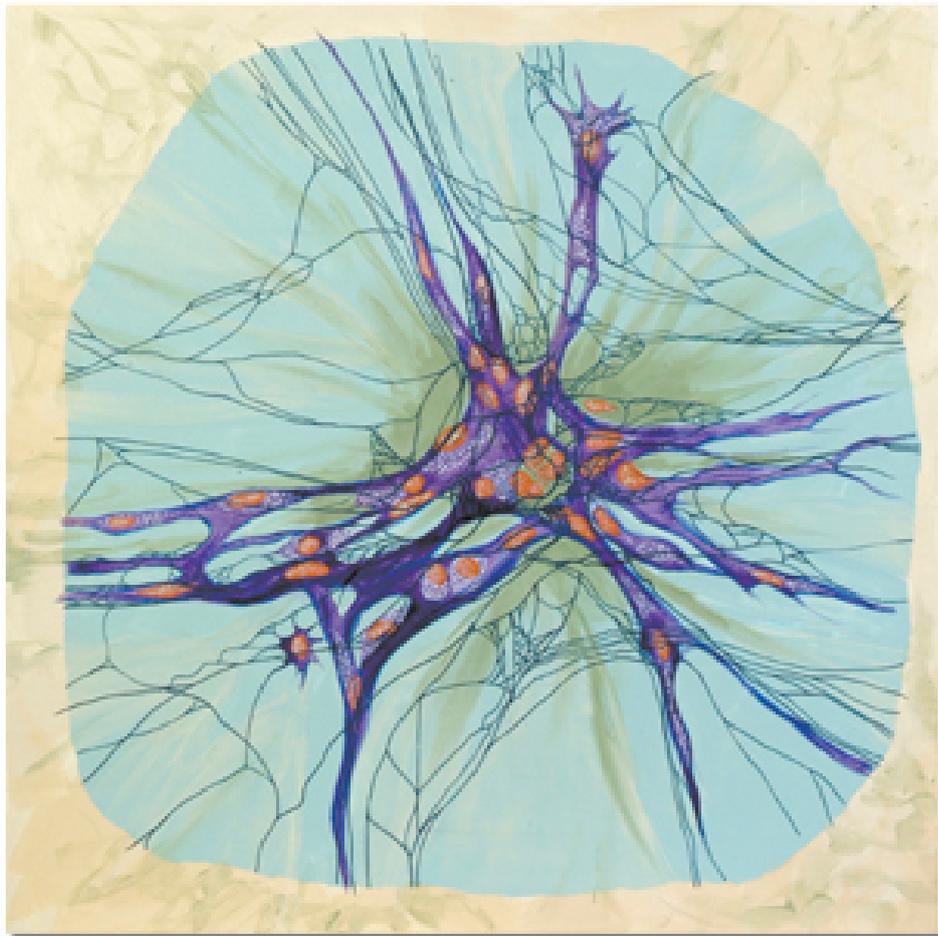


ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ ΑΥΤΩΝ



ΣΠΟΥΔΑΣΤΕΣ:
ΖΩΡΗΣ ΝΙΚΟΛΑΟΣ
ΚΑΤΣΙΝΟΥΛΑΣ ΝΙΚΟΛΑΟΣ

ΔΗΛΩΣΗ ΠΕΡΙ ΛΟΓΟΚΛΟΠΗΣ

Όλες οι προτάσεις οι οποίες παρουσιάζονται σε αυτό το κείμενο και οι οποίες ανήκουν σε άλλους αναγνωρίζονται από τα εισαγωγικά και υπάρχει η σαφής δήλωση του συγγραφέα. Τα υπόλοιπα γραφόμενα είναι επινόηση του γράφοντος ο οποίος φέρει και την καθολική ευθύνη γι' αυτό το κείμενο και δηλώνω υπεύθυνα ότι δεν υπάρχει λογοκλοπή γι' αυτό το κείμενο.

Όνοματεπώνυμο.....
.....

Υπογραφή..... Ημερομηνία.....

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ΚΕΦΑΛΑΙΟ 1.....3

1.1	ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ (ΤΝ)-ARTIFICIAL INTELLIGENCE (ΑΙ).....	3
1.2	ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (ΤΝΔ)-ARTIFICIAL NEURAL NETWORKS (ANN's).....	3
1.3	ΠΩΣ ΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΔΙΑΦΕΡΟΥΝ ΑΠΟ ΤΑ ΠΑΡΑΔΟΣΙΑΚΑ ΥΠΟΛΟΓΙΣΤΙΚΑ ΚΑΙ ΕΜΠΕΙΡΙΚΑ ΣΥΣΤΗΜΑΤΑ;.....	4
1.4	ΤΟ ΙΣΤΟΡΙΚΟ ΥΠΟΒΑΘΡΟ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	5
1.5	ΑΠΟ ΤΙ ΑΠΟΤΕΛΟΥΝΤΑΙ ΤΑ ΤΝΔ.....	8
1.6	ΔΟΜΗ ΚΑΙ ΛΕΙΤΟΥΡΓΙΑ ΑΝΘΡΩΠΙΝΟΥ ΕΓΚΕΦΑΛΟΥ - ΒΙΟΛΟΓΙΚΟΣ ΝΕΥΡΩΝΑΣ.....	8
1.7	Η ΔΟΜΗ ΤΟΥ ΝΕΥΡΩΝΑ.....	9
1.8	ΑΠΟ ΤΟΥΣ ΑΝΘΡΩΠΙΝΟΥΣ ΝΕΥΡΩΝΕΣ ΣΤΟΥΣ ΤΕΧΝΗΤΟΥΣ ΝΕΥΡΩΝΕΣ.....	11
1.9	Η ΛΕΙΤΟΥΡΓΙΑ ΤΟΥ ΝΕΥΡΩΝΙΚΟΥ ΣΥΣΤΗΜΑΤΟΣ.....	12
1.10	ΤΑ ΣΤΡΩΜΑΤΑ (LAYERS) ΕΝΟΣ ΝΔ.....	13
1.11	SINGLE - LAYER ΤΝΔ – ΜΟΝΟΣΤΡΩΜΑΤΙΚΑ.....	14
1.12	MULTILAYER ΤΝΔ – ΠΟΛΥΣΤΡΩΜΑΤΙΚΑ.....	15
1.13	ΣΥΝΔΕΣΕΙΣ ΕΝΔΙΑΜΕΣΩΝ ΣΤΡΩΜΑΤΩΝ (INTER - LAYER CONNECTIONS).....	16
1.14	ΣΥΝΔΕΣΕΙΣ ΔΙΑΣΤΡΩΜΑΤΩΝ (INTRA - LAYER CONNECTIONS).....	17
1.15	ΓΙΑΤΙ ΕΙΝΑΙ ΔΥΣΚΟΛΟ ΝΑ ΔΙΑΜΟΡΦΩΘΕΙ ΕΝΑ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ ΟΜΟΕΙΔΕΣ ΜΕ ΤΟΝ ΑΝΘΡΩΠΙΝΟ ΕΓΚΕΦΑΛΟ;.....	18
1.16	ΤΑ ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ.....	18
1.17	ΕΦΑΡΜΟΓΕΣ ΤΩΝ ANNs - ΤΙ ΜΠΟΡΟΥΝ ΝΑ ΚΑΝΟΥΝ.....	19
1.18	ΌΡΙΑ ΤΩΝ ΤΝΔ - ΠΟΥ ΑΠΟΤΥΓΧΑΝΟΥΝ.....	21
1.19	ΠΩΣ ΑΝΑΠΤΥΣΣΟΝΤΑΙ ΤΑ ΤΝΔ.....	21

ΚΕΦΑΛΑΙΟ 2.....22

2.1	Η ΕΚΠΑΙΔΕΥΣΗ ΤΩΝ ΤΝΔ.....	22
2.2	ΜΕΘΟΔΟΙ ΕΚΜΑΘΗΣΗΣ ΤΩΝ ΤΝΔ.....	23
2.3	ΜΗ ΕΠΟΠΤΕΥΟΜΕΝΗ ΕΚΜΑΘΗΣΗ-UNSUPERVISED LEARNING (ΧΩΡΙΣ "ΔΑΣΚΑΛΟ").....	23
2.4	ΕΠΟΠΤΕΥΟΜΕΝΗ ΕΚΜΑΘΗΣΗ - SUPERVISED LEARNING (ΜΕ "ΔΑΣΚΑΛΟ").....	24
2.5	ΜΗ ΕΠΟΠΤΕΥΟΜΕΝΗ ΕΚΠΑΙΔΕΥΣΗ - UNSUPERVISED TRAINING.....	25
2.6	ΕΠΟΠΤΕΥΟΜΕΝΗ ΕΚΠΑΙΔΕΥΣΗ - SUPERVISED TRAINING.....	26
2.7	ΤΑ ΕΙΔΗ ΤΩΝ ΔΕΔΟΜΕΝΩΝ ΠΟΥ ΔΕΧΟΝΤΑΙ ΤΑ ΤΝΔ.....	27
2.8	ΠΑΡΑΔΕΙΓΜΑ ΕΠΕΞΗΓΗΣΗΣ ΤΗΣ ΑΝΩΤΕΡΩ ΔΙΑΔΙΚΑΣΙΑΣ ΔΙΔΑΣΚΑΛΙΑΣ.....	27
2.9	ΤΑΧΥΤΗΤΑ - ΧΡΟΝΟΣ ΕΚΜΑΘΗΣΗΣ.....	28
2.10	ΚΑΝΟΝΕΣ ΕΚΜΑΘΗΣΗΣ ΤΩΝ ΤΝΔ.....	28
2.11	HEBB'S RULE.....	29
2.12	HOPFIELD LAW.....	29
2.13	DELTA RULE.....	29
2.14	KOHONEN'S LEARNING LAW.....	30
2.15	GRADIENT DESCENT RULE (Ο ΚΑΝΟΝΑΣ ΚΑΘΟΔΟΥ ΚΛΙΣΗΣ).....	30
2.16	ΠΑΡΑΔΕΙΓΜΑ ΕΚΠΑΙΔΕΥΣΗΣ ΔΙΚΤΥΟΥ (ΓΙΑ ΤΗΝ ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΣΩΠΟΥ).....	30
2.17	ΔΙΑΔΙΚΑΣΙΑ ΕΚΠΑΙΔΕΥΣΗΣ.....	31
2.18	FEED FORWARD ΚΑΙ FEEDBACK ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	32
2.19	FEEDBACK ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	32
2.20	ΑΛΓΟΡΙΘΜΟΣ ΜΑΘΗΣΗΣ.....	35
2.21	Ο BACKPROPAGATION ΑΛΓΟΡΙΘΜΟΣ.....	35
2.22	ΠΕΡΙΓΡΑΦΗ ΤΟΥ BACK PROPAGATION ALGORITHM.....	36
2.23	ΕΝΑ BACK-PROPAGATION ΠΑΡΑΔΕΙΓΜΑ ΔΙΚΤΥΩΝ.....	40

ΚΕΦΑΛΑΙΟ 3.....42

3.1	ΤΑΞΙΝΟΜΗΣΗ ΔΙΚΤΥΩΝ.....	42
3.2	ΤΑ ΠΙΟ ΔΗΜΟΦΙΛΗ ΜΟΝΤΕΛΑ.....	42
3.3	PERCEPTRON (ΝΟΗΜΟΝΟΣ ΑΙΣΘΗΤΗΡΑΣ).....	42
3.4	Ο ΛΟΓΑΡΙΘΜΟΣ ΜΑΘΗΣΗΣ ΤΟΥ PERCEPTRON.....	45
3.5	ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ (CLASSIFICATION).....	47
3.6	ΓΡΑΜΜΙΚΟΣ ΔΙΑΧΩΡΙΣΜΟΣ ΤΩΝ ΚΑΤΗΓΟΡΙΩΝ.....	47
3.7	ADALINE (ADAPTIVE LINEAR NEURONE).....	49
3.8	ΔΙΚΤΥΑ ΓΙΑ ΣΥΣΧΕΤΙΣΜΟ ΔΕΔΟΜΕΝΩΝ (NETWORKS FOR DATA ASSOCIATION).....	51
3.9	ΔΙΚΤΥΑ HOPFIELD.....	51

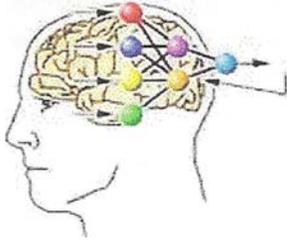
3.10	ΤΟ ΠΡΟΒΛΗΜΑ ΤΟΥ ΠΛΑΝΟΔΙΟΥ ΠΩΛΗΤΗ(TSP).....	53
3.11	ΜΗΧΑΝΗ BOLTZMANN (BOLTZMANN MACHINE).....	56
3.12	ΔΙΚΤΥΟ HAMMING.....	57
3.13	ΤΝΔ ΒΑΣΙΖΟΜΕΝΑ ΣΤΗ ΔΟΥΛΕΙΑ ΤΟΥ ΚΟΗΟΝΕΝ.....	58
3.14	LEARNING VECTOR QUANTIZATION (ΔΙΑΝΥΣΜΑΤΙΚΗ ΚΒΑΝΤΟΠΟΙΗΣΗ ΕΚΜΑΘΗΣΗΣ)	58
3.15	ΔΙΚΤΥΟ ΑΝΤΙΘΕΤΗΣ ΔΙΑΔΟΣΗΣ (COUNTER PROPAGATION NETWORK).....	60
3.16	ΠΙΘΑΝΟΛΟΓΙΚΟ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ (PROBABILISTIC NEURAL NETWORK).....	62
3.17	SELF- ORGANIZING MAP.....	64
3.18	ΕΠΑΝΑΚΥΚΛΟΦΟΡΙΑ (RECIRCULATION).....	66

ΚΕΦΑΛΑΙΟ 4.....68

	<i>ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....</i>	<i>68</i>
4.1	ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΟΥ (PATTERN RECOGNITION).....	68
4.2	ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΣΩΠΟΥ (FACE RECOGNITION).....	72
4.3	ΑΝΑΓΝΩΡΙΣΗ 2-D ΠΟΛΥΓΩΝΩΝ.....	108
4.4	ΠΡΟΒΛΕΨΗ ΧΡΗΜΑΤΙΣΤΗΡΙΟΥ (STOCKMARKET PREDICTION).....	117
4.5	ΑΝΑΓΝΩΡΙΣΗ ΟΜΙΛΙΑΣ (SPEECH RECOGNITION).....	131
4.6	ΑΝΑΓΝΩΡΙΣΗ ΔΑΚΤΥΛΙΚΩΝ ΑΠΟΤΥΠΩΜΑΤΩΝ (FINGERPRINT IDENTIFICATION).....	132
4.7	ΠΡΟΒΛΕΨΗ ΚΑΙΡΟΥ (WEATHER PREDICTION).....	135
4.8	ΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΣΤΗΝ ΙΑΤΡΙΚΗ1.....	146
4.9	ΠΟΛΥΔΙΑΝΕΜΟΜΕΝΗ ΜΕΤΑΓΩΓΗ ΣΕ ΔΙΚΤΥΑ ΑΤΜ ΜΕ ΧΡΗΣΗ ΝΔ HOPFIELD.....	152
4.10	ΆΠΟ ΕΝΑ ΣΑΛΙΓΚΑΡΙ.....ΤΟ ΠΡΩΤΟ ΜΕΡΙΚΩΣ "ΖΩΝΤΑΝΟ" ΟΛΟΚΛΗΡΩΜΕΝΟ ΚΥΚΛΩΜΑ.....	159
4.11	ΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΣΤΗΝ ΑΝΑΓΝΩΡΙΣΗ ΦΥΛΛΩΝ.....	159

ΒΙΒΛΙΟΓΡΑΦΙΑ.....166

1.1 Τεχνητή Νοημοσύνη (TN)-Artificial Intelligence (AI)



Τεχνητή Νοημοσύνη είναι ο κλάδος της επιστήμης της πληροφορικής που ασχολείται με τη μελέτη των θεωριών και των μεθόδων που παράγουν νοήμονα ή ευφυή συμπεριφορά όταν εφαρμοστούν μέσω του ηλεκτρονικού υπολογιστή. Επιδιώκει να αναπτύξει το λογισμικό που μιμείται τη λειτουργία του ανθρώπινου εγκεφάλου για να λύσει τα διάφορα προβλήματα.

Η τεχνητή νοημοσύνη μπορεί να μιμηθεί τον ανθρώπινο εγκέφαλο όσον αφορά την αρχιτεκτονική και τη λειτουργία του. Μπορεί να χρησιμοποιηθεί για να αναγνωρίσει πρότυπα και εικόνες, να κατασκευάσει ένα λογικό διάγραμμα για να λύσει ένα πρόβλημα, να ταξινομήσει δεδομένα, να προβλέψει αποτελέσματα.

Δύο είναι τα βασικά προβλήματα που αντιμετωπίζει η TN: Η *αναπαράσταση της γνώσης* γύρω από ένα πρόβλημα και η *αναζήτηση μιας λύσης* για το πρόβλημα χρησιμοποιώντας τη γνώση αυτή.

Υπολογιστική Νοημοσύνη (YN) είναι το τμήμα της TN, το οποίο προέρχεται από την προσπάθεια εξομοίωσης νοητικών και γενετικών λειτουργιών των έμβιων όντων. Στην κατηγορία αυτή ανήκουν τα Νευρωνικά Δίκτυα (ΝΔ) και οι Γενετικοί αλγόριθμοι (ΓΑ).

1.2 Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ)-Artificial Neural Networks (ANN's)

Ένα νευρωνικό δίκτυο είναι ένα σύνολο κόμβων ή νευρώνων που ο καθένας ενώνεται με όλους τους άλλους. Ουσιαστικά πρόκειται για ένα σύστημα επεξεργασίας πληροφοριών, σχεδιασμένο με βάση τη λογική συνδεσμολογίας των νευρώνων του ανθρώπινου εγκεφάλου. Το σημείο-κλειδί του συστήματος είναι η δικτυακή δομή του συστήματος επεξεργασίας πληροφορίας.

Αποτελείται από ένα μεγάλο αριθμό πολλαπλά διασυνδεδεμένων επεξεργαστών (νευρώνες), που δουλεύουν σε πλήρη συμφωνία μεταξύ τους. Τα νευρωνικά δίκτυα, όπως και ο άνθρωπος, έχουν τη δυνατότητα μάθησης μέσα από παραδείγματα. Στα βιολογικά συστήματα αυτό επιτυγχάνεται με την τροποποίηση των συνοπτικών συνδέσεων των νευρώνων. Η ίδια διαδικασία εφαρμόζεται και στα νευρωνικά δίκτυα. Ένα "εκπαιδευμένο" νευρωνικό δίκτυο είναι δυνατόν να θεωρηθεί "ειδήμονας" στην κατηγορία των πληροφοριών που του δίνονται για ανάλυση.

Ο όρος "Τεχνητά" για τα Νευρωνικά Δίκτυα χρησιμοποιείται για τον διαχωρισμό που γίνεται από τα Νευρωνικά Δίκτυα του ανθρώπινου εγκεφάλου. Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) είναι κατάλληλες απλουστεύσεις των νευρωνικών δικτύων του εγκεφάλου, δηλαδή εμπνέονται από τον τρόπο με τον οποίο ο εγκέφαλος παράγει πληροφορίες. Ένα τυπικό μοντέλο τεχνητού νευρωνικού δικτύου αποτελείται από διάφορα επίπεδα μονάδων επεξεργασίας. Η μονάδα επεξεργασίας μπορεί να θεωρηθεί ως ένας νευρώνας ή ομάδα νευρώνων. Ένας τεχνητός νευρώνας αθροίζει πληροφορίες από άλλους νευρώνες, εκτελεί έναν απλό υπολογισμό σε αυτό το άθροισμα, π.χ. αποφασίζει αν είναι μεγαλύτερο από μια τιμή κατωφλίου και περνά το αποτέλεσμα σε άλλους

νευρώνες. Ένα ΤΝΔ διαμορφώνεται για μια συγκεκριμένη εφαρμογή (όπως η αναγνώριση προτύπων ή η ταξινόμηση δεδομένων, η ανάλυση τάσεων του χρηματιστηρίου, η ανίχνευση ανωμαλιών σε καρδιογραφήματα και η αναγνώριση ύποπτων αντικειμένων στα αεροδρόμια) μέσω μιας διαδικασίας εκμάθησης.

Έτσι λοιπόν το κίνητρο για την ανάπτυξη της τεχνολογίας των νευρωνικών δικτύων προήλθε από την επιθυμία να αναπτυχθεί ένα τεχνητό σύστημα που θα μπορούσε να εκτελέσει τις "ευφρείς" στοιχειώδεις αυτές εργασίες, παρόμοιες με εκείνες που εκτελούνται από τον ανθρώπινο εγκέφαλο αφού τα νευρωνικά δίκτυα μοιάζουν με τον ανθρώπινο εγκέφαλο. Ένα νευρωνικό δίκτυο αποκτά τη γνώση μέσω της εκμάθησης. Η γνώση ενός νευρωνικού δικτύου καταχωρείται μέσα στις δια-νευρωνικές δυνάμεις, σύνδεσης γνωστές ως συνοπτικά βάρη.

Άλλοι ορισμοί για τα Νευρωνικά Δίκτυα:

Σύμφωνα με τη DARPA Neural Network Study* : “... ένα νευρωνικό δίκτυο είναι ένα σύστημα που αποτελείται από πολλά απλά στοιχεία επεξεργασίας που λειτουργούν παράλληλα και των οποίων η λειτουργία καθορίζεται από τη δομή δικτύων, τις δυνάμεις σύνδεσης, και την επεξεργασία που εκτελείται στον υπολογισμό των στοιχείων ή των κόμβων”.

Σύμφωνα με τον Haykin** : “Ένα νευρωνικό δίκτυο είναι ένας μαζικά παράλληλος διανεμημένος επεξεργαστής που έχει μια φυσική ροπή για την καταχώρηση της εμπειρικής γνώσης ώστε να την κάνει διαθέσιμη για τη χρήση. Μοιάζει με τον εγκέφαλο από δύο απόψεις:

1. Η γνώση αποκτιέται από το δίκτυο μέσω μιας διαδικασίας εκμάθησης.
2. Οι δυνάμεις των διανευρωνικών συνδέσεων, γνωστές ως *synaptic weights*, χρησιμοποιούνται για να καταχωρήσουν τη γνώση”.

1.3 Πώς τα νευρωνικά δίκτυα διαφέρουν από τα παραδοσιακά υπολογιστικά και εμπειρικά συστήματα:

Οι παραδοσιακοί υπολογιστές είναι ιδανικοί για πολλές εφαρμογές. Μπορούν να επεξεργαστούν δεδομένα, σειρά απογραφών, αποτελέσματα δικτύων και να προστατεύσουν τον εξοπλισμό. Αυτές οι εφαρμογές δεν χρειάζονται τα ειδικά χαρακτηριστικά των νευρωνικών δικτύων.

Τα έμπειρα συστήματα είναι μια επέκταση του παραδοσιακού υπολογισμού και καλούνται μερικές φορές 5^η γενεά του υπολογισμού. (Η 1^η γενεά υπολογισμού χρησιμοποιούσε διακόπτες και καλώδια. Η 2^η γενεά εμφανίστηκε λόγω της ανάπτυξης του τρανζίστορ. Η 3^η γενεά περιελάμβανε την τεχνολογία στερεάς κατάστασης, τη χρήση των ολοκληρωμένων κυκλωμάτων και των γλωσσών υψηλού επιπέδου όπως COBOL, FORTRAN και C. Τα εργαλεία χρηστών, "code generators" (γενετικοί κώδικες), είναι γνωστά ως 4^η γενεά). Η 5^η γενεά περιλαμβάνει την τεχνητή νοημοσύνη.

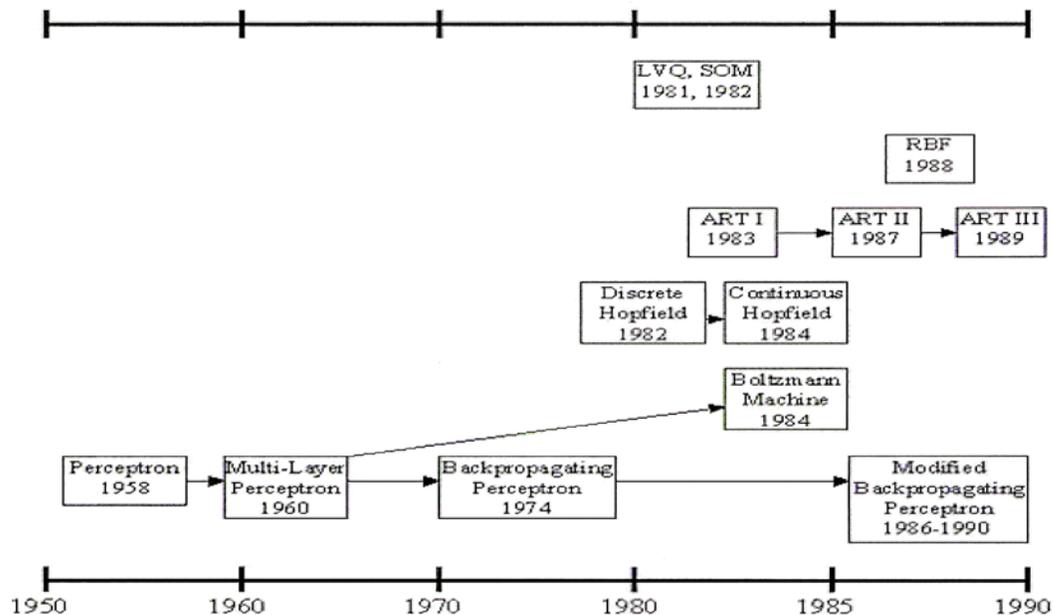
Τα τεχνητά νευρωνικά δίκτυα προσφέρουν μια απολύτως διαφορετική προσέγγιση στην επίλυση προβλήματος και καλούνται μερικές φορές 6^η γενεά του υπολογισμού.

* : (1988, AFCEA διεθνής Τύπος, σελ. 60)

** : (S. (1994), Neural Networks : A Comprehensive Foundation, NY: Macmillan, σελ. 2)

Προσπαθούν να παρέχουν ένα εργαλείο που να αυτό-προγραμματίζεται και συγχρόνως να μαθαίνει από μόνο του. Τα νευρωνικά δίκτυα είναι δομημένα έτσι ώστε να παρέχουν την δυνατότητα λύσης προβλημάτων χωρίς την βοήθεια ενός εμπειρογνώμονα και την ανάγκη προγραμματισμού. Εντούτοις, δεν αποτελούν λύση για όλα τα προβλήματα υπολογισμού.

1.4 Το ιστορικό υπόβαθρο των νευρωνικών δικτύων



Σχήμα 1. 1: Ιστορικό διάγραμμα των νευρωνικών δικτύων

Τα νευρωνικά δίκτυα βρίσκονται σε μια πρόσφατη ανάπτυξη. Είναι μια επιστήμη η οποία ξεκίνησε πριν περίπου 60 χρόνια αλλά μεγάλη ώθηση δόθηκε σε αυτά τη δεκαετία του 80. Εντούτοις, ο τομέας αυτός καθιερώθηκε πριν από την εμφάνιση των υπολογιστών. Όταν η χρηματοδότηση και η επαγγελματική υποστήριξη ήταν ελάχιστες, σημαντικές πρόοδοι έγιναν από σχετικά λίγους ερευνητές. Αυτοί οι πρωτοπόροι ήταν σε θέση να αναπτύξουν την πειστική τεχνολογία που ξεπέρασε τους περιορισμούς που προσδιορίστηκαν από Minsky και Papert. Ο Minsky και ο Papert, δημοσίευσαν ένα βιβλίο (1969) στο οποίο συνόψισαν ένα γενικό συναίσθημα της απογοήτευσης (ενάντια στα νευρωνικά δίκτυα) μεταξύ των ερευνητών και έγιναν αποδεκτά έτσι από τους περισσότερους χωρίς περαιτέρω ανάλυση. Στα πρώτα χρόνια της ανάπτυξης των νευρωνικών δικτύων οι ερευνητές προσπάθησαν να αντιγράψουν τον τρόπο οργάνωσης του εγκεφάλου όταν σκέπτονταν, τον τρόπο της ρύθμισης και τους αλγόριθμους που έπρεπε να τα διέπουν. Όμως οι γνώσεις πάνω στην λειτουργία του εγκεφάλου ήταν περιορισμένες, όπως και σήμερα, έτσι οι ερευνητές έπρεπε να ξεπεράσουν τις γνώσεις αυτές και να βρουν δομές που να εκτελούν χρήσιμες λειτουργίες. Οι υποθέσεις τελικά που κάνανε δεν επέτρεψαν την δημιουργία τέτοιων τεχνητών νευρωνικών δικτύων. Όμως ο συνεχιζόμενος παραλληλισμός με τον ανθρώπινο εγκέφαλο έκανε τους ερευνητές να προσπαθήσουν να οδηγήσουν τις λειτουργίες των ΤΝΔ στην ανθρώπινη συνείδηση.

Αυτό θα οδηγούσε όμως στο να σταματήσει η έρευνα το 1960 αν δεν αναχαιτίζονταν αυτός ο τρόπος σκέψης για την ανάπτυξη των ΤΝΔ .

Αυτήν την περίοδο ο τομέας των νευρωνικών δικτύων απολαμβάνει μια αναβίωση ενδιαφέροντος και μια αντίστοιχη αύξηση στη χρηματοδότηση.

Η ιστορία των νευρωνικών δικτύων που περιγράφηκε ανωτέρω μπορεί να διαιρεθεί σε αρκετές περιόδους:

Πρώτες προσπάθειες:

Υπήρξαν μερικές αρχικές προσομοιώσεις που χρησιμοποιούν την επίσημη λογική. Οι McCulloch και Pitts (1943) ανέπτυξαν μοντέλα νευρωνικών δικτύων βασισμένα στην κατανόηση της νευρολογίας. Παρουσίασαν την ιδέα ότι ένα νευρωνικό δίκτυο αποτελείται από ένα μεγάλο αριθμό νευρώνων, και πως θα μπορούσαν να λειτουργήσουν οι νευρώνες με τις διασυνδέσεις τους. Τα αποτελέσματα του μοντέλου τους ήταν απλές λειτουργίες λογικής όπως "a or b" και "a and b".

Οι ίδιοι συγγραφείς προχώρησαν το 1947 σε πιο εξελιγμένο πρότυπο για την αναγνώριση σχημάτων. Ο νευρώνας μπορεί να έχει μόνο δύο καταστάσεις, να δέχεται πολλές εισόδους αλλά να δίνει μια έξοδο. Οι εξοδοί από διαφορετικούς νευρώνες δεν πρέπει να ενώνονται, αλλά να οδηγούν σε είσοδο άλλου νευρώνα. Μπορούμε να πούμε ότι στα δίκτυα McCulloch-Pitts ο μηχανισμός μνήμης μπορεί να είναι η ύπαρξη των κλειστών διαδρομών του σήματος μέσα στο δίκτυο. Αν δεν υπάρχει τέτοια διαδρομή και νέο εξερχόμενο σήμα, τότε το δίκτυο είναι μόνιμα σε μια κατάσταση ηρεμίας.

Ένα άλλο έργο το οποίο αφήνει την επιρροή του ακόμη και σήμερα είναι το βιβλίο του Hebb "The organization of behavior" το οποίο εισάγει τον *κανόνα εκμάθησης του Hebb*. Το μοντέλο του Hebb έχει ως κεντρική ιδέα τις συνδέσεις μεταξύ των νευρώνων. Ο κανόνας λέει ότι κάθε φορά που το δίκτυο χρησιμοποιεί τις νευρωνικές του συνδέσεις, οι συνδέσεις ενισχύονται και το δίκτυο πλησιάζει στο να μάθει το πρότυπο το οποίο παρουσιάζεται. Όταν ο νευρώνας *i* διεγείρει επανειλημμένα τον νευρώνα *j* τότε αναπτύσσεται μια μεταβολική σύνδεση στον ένα ή και στους δύο νευρώνες, έτσι ώστε η απόδοση των φαινομένων να αυξάνεται.

Μια άλλη προσπάθεια ήταν με τη χρησιμοποίηση των προσομοιώσεων υπολογιστών. Δύο ομάδες (Farley και Clark το 1954, Rochester, Holland, Haibit και Duda, 1956). Η πρώτη ομάδα (ερευνητές της IBM) διατήρησε τη στενή επαφή με τους επιστήμονες στο πανεπιστήμιο McGill. Όποτε τα μοντέλα τους δεν λειτουργούσαν, συμβουλευόνταν τους επιστήμονες αυτούς.

Υποσχόμενη - Νέα τεχνολογία:

Το μοντέλο του αισθητήρα (το Perceptron) παρουσιάστηκε για πρώτη φορά το 1957 από τον F.Rosenblatt, ο οποίος έφτιαξε αρχικά το πρώτο δίκτυο με hardware. Είναι ένα απλό μοντέλο το οποίο έχει απλά δύο επίπεδα, της εισόδου και της εξόδου, είχε τρία στρώματα με το μέσο στρώμα γνωστό ως στρώμα ένωσης. Αυτό το σύστημα μπορούσε να μάθει να συνδέει μια δεδομένη είσοδο σε μια τυχαία μονάδα εξόδου.

Ένα άλλο μοντέλο ήταν το Adaline και το Madaline (ADaptive LInear Element) που αναπτύχθηκε το 1960 από τον Widrow και τον Hoff (του πανεπιστημίου του Stanford). Αυτά τα μοντέλα ήταν τα πρώτα μοντέλα που χρησιμοποιήθηκαν για πρακτικά προβλήματα: χρησιμοποιήθηκαν ως φίλτρα για να εξαλείψουν την ηχώ σε τηλεφωνικές γραμμές. Η μέθοδος που χρησιμοποιήθηκε για την εκμάθηση ήταν διαφορετική από αυτή του Perceptron και υιοθέτησε τον κανόνα εκμάθησης: Least-Mean-Squares (LMS).

Περίοδος απογοήτευσης:

Το 1969 οι Minsky και Papert έγραψαν ένα βιβλίο. Αποτέλεσμα του βιβλίου αυτού ήταν να χαθεί η χρηματοδότηση για την έρευνα των νευρωνικών δικτύων.

Η ωρίμανση:

Ένα μεγάλο έργο παρουσιάστηκε από τον βιολόγο J.Hopfield ο οποίος σε μια εργασία μόλις 5 σελίδων έδειξε με αυστηρά μαθηματική απόδειξη πως ένα νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος και πως μπορεί να ανακτήσει την πληροφορία ενός ολόκληρου συστήματος αν του δοθούν μόνο μερικά τμήματα του συστήματος.

Η πρόοδος κατά τη διάρκεια του τέλους δεκαετίας του '70 και των αρχών δεκαετίας του '80 συντέλεσε στην επανεμφάνιση του ενδιαφέροντος για τον τομέα των νευρωνικών δικτύων. Η ανταπόκριση σε βιβλία και διασκέψεις ήταν πολύ θετική. Τα μέσα ειδήσεων βοηθούν να διαδοθεί η τεχνολογία. Εμφανίστηκαν ακαδημαϊκά προγράμματα και σειρές μαθημάτων στα περισσότερα σημαντικά πανεπιστήμια (ΗΠΑ και Ευρώπη). Η προσοχή στρέφεται τώρα στη χρηματοδότηση σε όλη την Ευρώπη, την Ιαπωνία και τις ΗΠΑ και καθώς αυτή η χρηματοδότηση διατίθεται, προκύπτουν αρκετές νέες εμπορικές βιομηχανικές και χρηματοοικονομικές εταιρίες.

Σήμερα:

Σημαντική πρόοδος έχει σημειωθεί στον τομέα νευρωνικών δικτύων, αρκετή για να προσελκύσει μεγάλη προσοχή και να χρηματοδοτήσει την περαιτέρω έρευνα. Η πρόοδος πέρα από τις παρούσες εμπορικές εφαρμογές εμφανίζεται να είναι δυνατή και η έρευνα προωθεί τον τομέα σε πολλά μέτωπα. Προκύπτουν Neurally based chips και αναπτύσσονται εφαρμογές σε σύνθετα προβλήματα. Σήμερα σαφέστατα είναι μια περίοδος μετάβασης για την τεχνολογία των νευρωνικών δικτύων.

Το Μέλλον

Πρόβλεψη 1:

Τα νευρωνικά δίκτυα θα συναρπάσουν την εκπαίδευση, την επεξεργασία πληροφοριών και την ψυχαγωγία. Τα "Alternative realities" είναι ελκυστικά λόγω της δυνατότητάς τους για τον έλεγχο συστημάτων, την εκπαίδευση και την ψυχαγωγία.

Αυτός ο "προγραμματισμός" θα απαιτούσε την ανατροφοδότηση από το χρήστη προκειμένου να είναι αποτελεσματικός αλλά οι απλοί και "παθητικοί" αισθητήρες (π.χ.

αισθητήρες άκρων δακτύλου, γάντια ή μανικέτια για το σφυγμό, πίεση αίματος, ιονισμός δέρματος, κτλ), θα μπορούσαν να παρέχουν την αποτελεσματική ανατροφοδότηση σε ένα νευρωνικό σύστημα ελέγχου. Αυτό θα μπορούσε να επιτευχθεί, π.χ. με τους αισθητήρες που θα ανίχνευαν το σφυγμό, την πίεση αίματος, τον ιονισμό δερμάτων και άλλες μεταβλητές που το σύστημα θα μπορούσε να μάθει για να συσχετιστεί με την κατάσταση ανταπόκρισης του ανθρώπου.

Πρόβλεψη 2:

Τα νευρωνικά δίκτυα που ενσωματώνονται με άλλες τεχνολογίες τεχνητής νοημοσύνης, με μεθόδους για τον άμεσο πολιτισμό του νευρικού ιστού, και με άλλες εξωτικές τεχνολογίες όπως η γενετική εφαρμοσμένη μηχανική, θα επιτρέψουν σε μας να αναπτύξουμε ριζικές και εξωτικές μορφές ζωής, είτε άνθρωπο, είτε μηχανή, είτε υβρίδιο.

Πρόβλεψη 3:

Τα νευρωνικά δίκτυα θα μας επιτρέψουν να ερευνήσουμε νέες πτυχές των ανθρώπινων ικανοτήτων.

1.5 Από τι αποτελούνται τα ΤΝΔ

Ένα ΤΝΔ αποτελείται από πολλά απλά τμήματα "επεξεργαστές" (νευρώνες), που λειτουργούν ομόφωνα για να λύσουν συγκεκριμένα προβλήματα εκτελώντας διάφορους υπολογισμούς πάνω στα δεδομένα εισόδου.

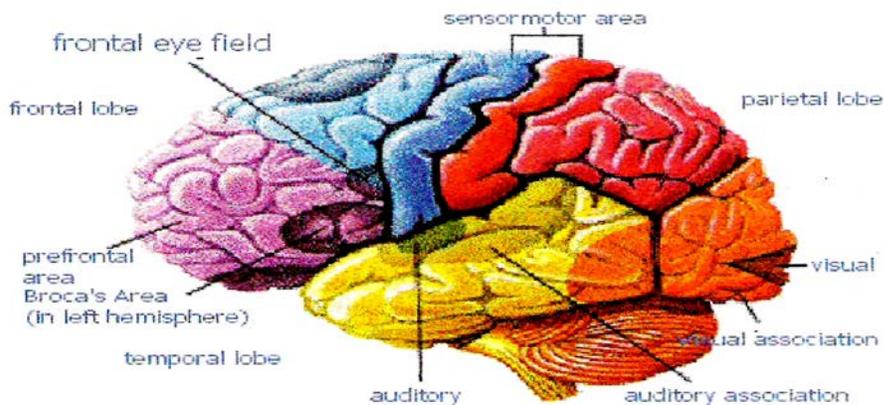
Συνδέονται μεταξύ τους με αμφίδρομα κανάλια επικοινωνίας, τα οποία μεταφέρουν πληροφορίες κωδικοποιημένες με την μορφή αριθμών. Τελικά ένα ΤΝΔ είναι συσκευή επεξεργασίας που υλοποιείται είτε με την μορφή ενός αλγόριθμου, είτε με την μορφή ηλεκτρονικών διατάξεων και ο σχεδιασμός τους είναι εμπνευσμένος από την δομή και τη λειτουργία του ανθρώπινου εγκεφάλου και τον τμημάτων του. Οι νευρώνες όπως και οι άνθρωποι μαθαίνουν από τα παραδείγματα.

1.6 Δομή και Λειτουργία Ανθρώπινου Εγκεφάλου - Βιολογικός Νευρώνας

Η επεξεργασία πληροφοριών σε έναν υπολογιστή, επιτυγχάνεται διαφορετικά από τον ανθρώπινο ή ζωικό εγκέφαλο.

Ο εγκέφαλος είναι ένα γιγαντιαίο σύστημα παράλληλης επεξεργασίας όπου συμμετέχουν δισεκατομμύρια επεξεργαστών τα νευρώνια, τα οποία επεξεργάζονται με βάση τα υπάρχοντα πρότυπα εισερχόμενους ερεθισμούς. Ο ανθρώπινος εγκέφαλος έχει όγκο περί τα 1,5 λίτρα, αλλά η περιφέρειά του ποικίλλει από άτομο σε άτομο και ζυγίζει περί τα 1,5 κιλά. Στο ανώτερο στρώμα που ονομάζεται Neokortex αποδίδεται η φαινομενική ικανότητα επεξεργασίας πληροφοριών. Το στρώμα αυτό καταλαμβάνει επιφάνεια περί τα 2.000 τετραγωνικά εκατοστά, έχει πάχος περί τα 3 χιλιοστά και αποτελείται από πυκνά στρώματα νευρώνων. Στον άνθρωπο υπάρχουν έξι ιεραρχικά δομημένα στρώματα, τα οποία έχουν διαφορετικές λειτουργικές ιδιότητες. Οι στοιχειώδεις μονάδες επεξεργασίας στο ανώτερο στρώμα είναι "τα νευρώνια τα οποία παρέχουν σε μας τις δυνατότητες να

θυμηθούμε, να σκεφτούμε και να εφαρμόσουμε προηγούμενες εμπειρίες σε κάθε ενέργειά μας.



Σχήμα 1. 2: Ανθρώπινος Εγκέφαλος

1.7 Η δομή του νευρώνα

Ένας νευρώνας αποτελείται από το κυρίως σώμα, τον άξονα και τους δενδρίτες.

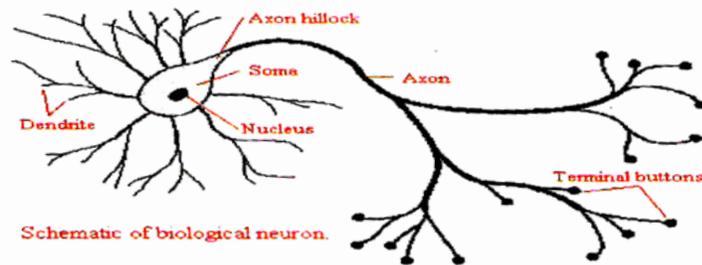
- Σώμα (Soma): Είναι ο κυρίως κορμός του νευρώνα μέσα στο οποίο βρίσκεται ο πυρήνας. Στον πυρήνα βρίσκεται όλο το γενετικό υλικό του οργανισμού, όπου γίνεται η πιο έντονη χημική δράση του κυττάρου για την σύνθεση των ενζύμων, πρωτεϊνών, και άλλων μορίων που είναι απαραίτητα για τη ζωή.
- Ο άξονας (Axon): Παράγει τη σύνδεση με άλλα νευρώνια του κεντρικού νευρικού συστήματος. Κάθε νευρώνας έχει μόνο έναν άξονα ο οποίος μεταδίδει τα σήματα σε άλλους νευρώνες.
- Δενδρίτης (Dendrite): Επεκτάσεις που χρησιμεύουν στη λήψη ερεθισμού. Ορισμένα νευρώνια διαθέτουν αρκετά πολύπλοκα τέτοια δέντρα ενώ άλλα είναι εξοπλισμένα μόνον με λίγες τέτοιες επεκτάσεις των νευρωνίων.
- Σύναψη (Synapse): Είναι το σημείο σύνδεσης ενός άκρου του άξονα με ένα άλλο κύτταρο.

Τα 4 στοιχεία (δενδρίτης, σύναψης, άξονας, σώμα) σχηματίζουν την ελάχιστη δομή που μπορεί να ληφθεί από τα βιολογικά μοντέλα, έτσι ώστε να σχηματισθούν τα τεχνητά νευρώνια.

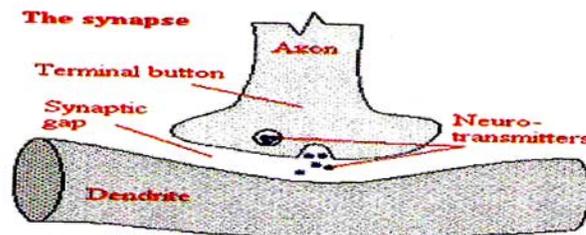
Ο άνθρωπος διαθέτει περίπου 10^{10} νευρώνια. Κάθε νευρώνιο διαθέτει περί τις 10.000 συνδέσεις με γειτονικά νευρώνια, έτσι ώστε να σχηματίζονται μέσα στο στρώμα Neokortex του ανθρώπινου εγκεφάλου μέχρι 10^{14} συνδέσεις. Δεν υπάρχουν δυο ολόιδιοι νευρώνες στον εγκέφαλο. Κάθε νευρώνας συνδέεται με πολλούς άλλους νευρώνες με συνδέσεις ονομαζόμενες συνάψεις. Οι νευρώνες ως κύτταρα πιστεύεται ότι δεν πολλαπλασιάζονται και δεν αναπαράγονται δηλαδή, το κεντρικό νευρωνικό σύστημα είναι τελείως ανεπτυγμένο μερικούς μήνες μετά την κύηση. Το αντίθετο συμβαίνει με τις συνάψεις οι οποίες δημιουργούνται καινούριες και καταστρέφονται οι παλιές. Η

δημιουργία των νέων συνάψεων γίνεται όταν ο εγκέφαλος αποκτά περισσότερες εμπειρίες μαθαίνει, αναγνωρίζει κ.τ.λ. Δουλειά του εγκεφάλου είναι η λήψη, η επεξεργασία και η απόκριση σε ερεθίσματα, τα οποία συλλαμβάνονται δια μέσου αισθητηρίων όπως τα όργανα των αισθήσεων. Τα αισθητήρια αυτά χαρακτηρίζονται σαν λήπτες. Οι λήπτες αυτοί καταχωρούν πραγματικότητες όπως το φώς, πίεση θερμοκρασία, ήχος κ.λ.π. και κωδικοποιούν τα ερεθίσματα αυτά έτσι ώστε να μπορούν να φθάνουν σαν σήματα δια μέσου των νευρωνικών οδών στον εγκέφαλο, που αποτελεί το κεντρικό σημείο αποφάσεων. Ο ρόλος του νευρώνα σε ένα νευρωνικό δίκτυο είναι να λαμβάνει όλα τα σήματα που έρχονται από άλλους νευρώνες, να τα επεξεργάζεται και να μεταδίδει το επεξεργασμένο σήμα σε άλλους νευρώνες. Τα σήματα που επεξεργάζεται ένας νευρώνας είναι ηλεκτρικής μορφής και της τάξης μερικών mV.

Περίπου 10% των νευρώνων χρησιμεύουν για την είσοδο (afferent) και για την έξοδο (efferent). Το υπόλοιπο 90 % συνδέεται με άλλα νευρώνια τα οποία αποθηκεύουν τις πληροφορίες ή αναλαμβάνουν συγκεκριμένες μετατροπές του σήματος το οποίο πολλαπλασιάζεται μέσα στο δίκτυο. Όλα τα νευρώνια με τις συνδέσεις τους σχηματίζουν ένα νευρωνικό δίκτυο



Σχήμα 1. 3: Ο βιολογικός νευρώνας



Σχήμα 1.4: Η σύναψη

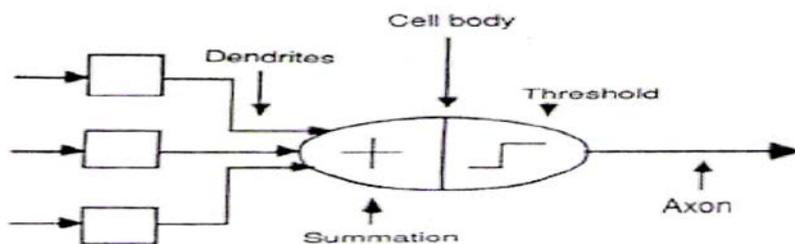
Συγκριτικά στοιχεία για την υπολογιστική ικανότητα του ανθρώπινου εγκεφάλου και του εγκεφάλου ορισμένων μικρών ζώων.

	Βδέλλα	Σκουλήκι	Μύγα	Κατσαρίδα	Μέλισσα	Άνθρωπος
Αριθμός Συνάψεων	$<10^3$	$<10^4$	$<10^8$	10^9	$<10^{10}$	10^{15}
Συνάψεις ανά δευτερόλεπτο	$>10^4$	$>10^5$	10^9	10^{11}	$>10^{11}$	10^{17}

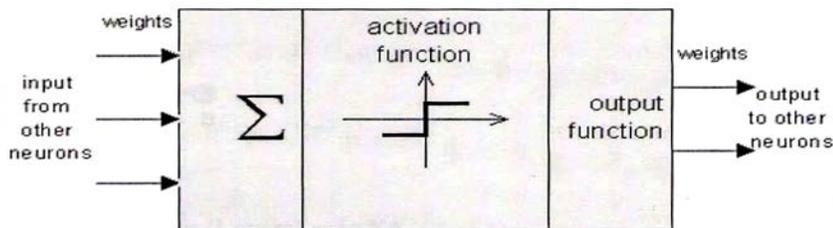
1.8 Από τους Ανθρώπινους Νευρώνες στους Τεχνητούς Νευρώνες

Όπως ο ανθρώπινος εγκεφάλος, έτσι και ένα νευρωνικό δίκτυο αποτελείται από τους νευρώνες και τις συνδέσεις μεταξύ τους. Οι νευρώνες μεταφέρουν τις εισερχόμενες πληροφορίες στις εξερχόμενες συνδέσεις τους και κατόπιν σε άλλους νευρώνες. Στα νευρωνικά δίκτυα αυτές οι συνδέσεις καλούνται βάρη.

Είδαμε ότι οι αριθμοί των βιολογικών νευρώνων και των συνδέσεων τους είναι πράγματι πολλοί μεγάλοι. Η τάξη μεγέθους τους είναι πολύ μεγαλύτερη από τον αριθμό μονάδων που μπορεί να χειριστεί ένας ηλεκτρονικός υπολογιστής. Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) δεν μπορούν να κάνουν πράγματα που ο εγκεφάλος ακόμη και ενός μικρού παιδιού επιτελεί με μεγάλη ευκολία. Ένα τεχνητό νευρωνικό δίκτυο μπορεί να έχει εκατοντάδες ή χιλιάδες νευρώνες αλλά όχι την τάξη μεγέθους που έχει ο εγκεφάλος. Οι συνάψεις στα βιολογικά είναι πολύ πιο περίπλοκες από ότι στα τεχνητά. Αυτή ίσως είναι η βασικότερη διαφορά τους. Η ταχύτητα στους υπολογιστές, είναι χιλιάδες φορές μεγαλύτερη από την ταχύτητα διάδοσης των βιολογικών δικτύων κάτι το οποίο έγκειται κατά μεγάλο βαθμό στη διαφορά πολυπλοκότητας. Τα ΤΝΔ μόλις έχουν ξεπεράσει το σκουλήκι και προσπαθούν να φτάσουν την μύγα. Ο εγκεφάλος μπορεί να κάνει σύγχρονη ή ασύγχρονη ενημέρωση των μονάδων του δηλ. και σε συνεχή χρόνο, ενώ τα ΤΝΔ κάνουν σύγχρονη ενημέρωση δηλ. δε διακριτό χρόνο.



Σχήμα 1. 5: Το νευρωνικό μοντέλο



Παρακάτω φαίνεται ένας ιδανικός νευρώνας ενός νευρωνικού δικτύου.

Σχήμα 1. 6: Ιδανικός νευρώνας νευρωνικού δικτύου.

Όπως φαίνεται ένας τεχνητός νευρώνας είναι παρόμοιος με ένα βιολογικό νευρωνικό κύτταρο και λειτουργεί με τον ίδιο τρόπο.

Οι πληροφορίες (είσοδος) στέλνονται στο νευρώνα στα εισερχόμενα βάρη του.

Στη συνέχεια οι τιμές όλων προστίθενται των εισερχόμενων βαρών. Η προκύπτουσα αξία συγκρίνεται με μια συγκεκριμένη αξία ευαισθησίας.

Εάν η είσοδος υπερβεί την αξία ευαισθησίας, ο νευρώνας θα ενεργοποιηθεί, διαφορετικά θα εμποδιστεί.

Εάν ενεργοποιηθεί, ο νευρώνας στέλνει μια έξοδο στα εξερχόμενα βάρη του σε όλους τους συνδεδεμένους νευρώνες κ.ο.κ.

1.9 Η λειτουργία του νευρωνικού συστήματος

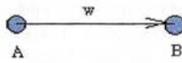
Η φύση των διασυνδέσεων μεταξύ δύο νευρώνων μπορεί να είναι τέτοια που ένας νευρώνας να μπορεί είτε να υποκινήσει είτε να εμποδίσει τον άλλο. Μια αλληλεπίδραση μπορεί να πραγματοποιηθεί μόνο εάν υπάρχει μια άκρη μεταξύ δύο νευρώνων. Εάν ο νευρώνας A συνδέεται με το νευρώνα B με ένα βάρος w όπως παρακάτω, τότε εάν το A υποκινηθεί αρκετά, στέλνει ένα σήμα στο B. Το σήμα εξαρτάται από το βάρος w και τη φύση του σήματος από το εάν υπάρχει παρακίνηση ή παρεμπόδιση. Αυτό εξαρτάται από το εάν το w είναι θετικό ή αρνητικό. Εάν στέλνονται αρκετά ισχυρά σήματα, το B μπορεί να γίνει υποκινούμενο.

Το A θα στείλει ένα σήμα μόνο εάν υποκινείται αρκετά, δηλαδή εάν η υποκίνησή του είναι μεγαλύτερη από την ευαισθησία του. Επίσης εάν στείλει ένα σήμα, θα το στείλει σε όλους τους κόμβους με τους οποίους συνδέεται. Η ευαισθησία για διαφορετικούς νευρώνες μπορεί να είναι διαφορετική. Εάν πολλοί νευρώνες στέλνουν σήματα στο A, το συνδυασμένο ερέθισμα μπορεί να είναι περισσότερο από την ευαισθησία.

Έπειτα εάν το B υποκινείται αρκετά, μπορεί να προκαλέσει ένα σήμα σε όλους τους νευρώνες με τους οποίους συνδέεται.

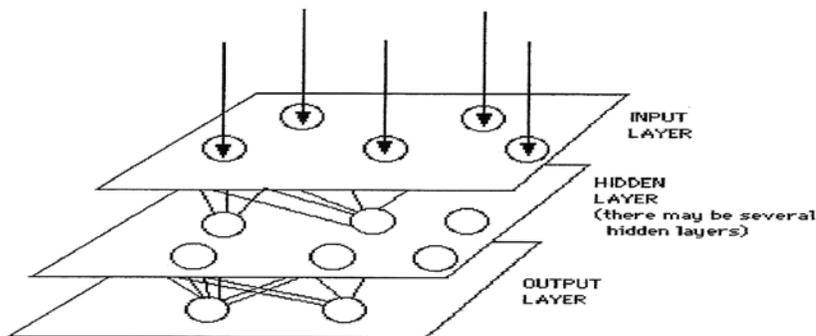
Ανάλογα με την πολυπλοκότητα της δομής, η γενική λειτουργία μπορεί να είναι πολύ σύνθετη αλλά η λειτουργία των μεμονωμένων νευρώνων είναι απλή.

Έτσι μπορούμε να το μιμηθούμε να μιμηθούμε κάτι τέτοιο χρησιμοποιώντας το λογισμικό (software) ή ακόμα και ειδικό υλικό (hardware).

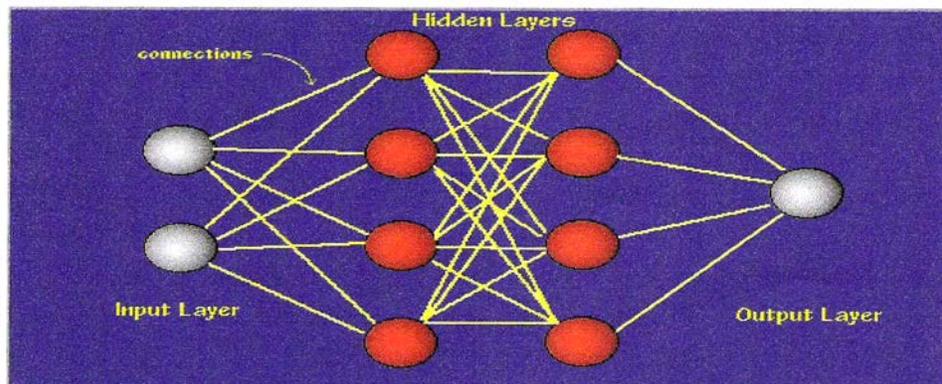


1.10 Τα Στρώματα (Layers) ενός ΝΔ

Βασικά, όλα τα τεχνητά νευρωνικά δίκτυα έχουν μια παρόμοια δομή. Μερικοί από τους νευρώνες διασυνδέουν τον πραγματικό κόσμο για να λάβουν τις εισόδους του και άλλοι νευρώνες παρέχουν στον πραγματικό κόσμο τα αποτελέσματα του δικτύου. Όλο το υπόλοιπο των νευρώνων είναι κρυφή μορφή.



Σχήμα 1. 7: Στρώματα νευρωνικού δικτύου



Σχήμα 1. 8: Στρώματα νευρωνικού δικτύου

Οι νευρώνες ομαδοποιούνται σε στρώματα (neuron layers). Συνήθως κάθε νευρώνας ενός στρώματος συνδέεται με όλους τους προηγούμενους νευρώνες και το επόμενο στρώμα, εκτός από το στρώμα εισόδου (input layer) και το στρώμα εξόδου (output layer). Το στρώμα εισόδου αποτελείται από τους νευρώνες που λαμβάνουν κάποια είσοδο από το εξωτερικό περιβάλλον. Το στρώμα εξόδου αποτελείται από τους νευρώνες που διαβιβάζουν την έξοδο του συστήματος στο χρήστη ή στο εξωτερικό περιβάλλον, Υπάρχουν συνήθως διάφορα κρυμμένα στρώματα (hidden layers) μεταξύ αυτών των δύο

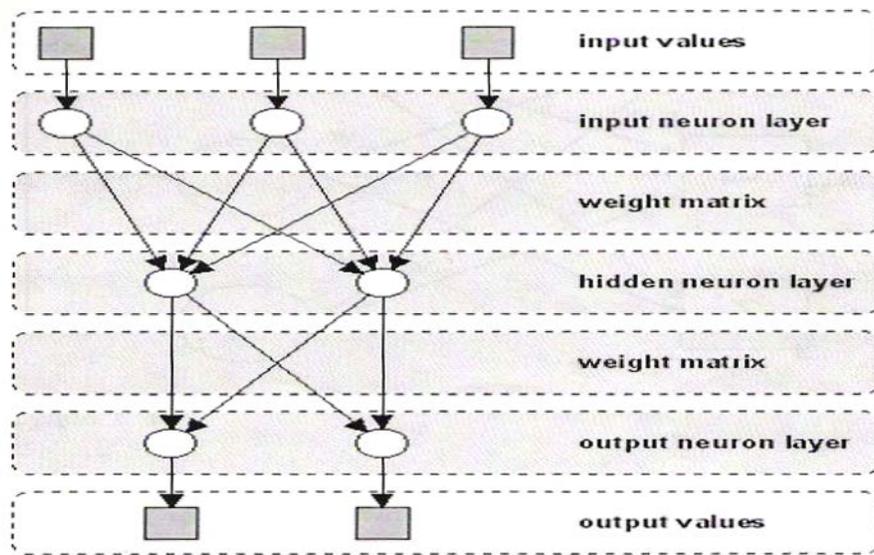
στρωμάτων. Οι πληροφορίες που δίνονται σε ένα νευρωνικό δίκτυο μεταβιβάζονται από στρώμα σε στρώμα, από το στρώμα εισόδου στο στρώμα εξόδου μέσω είτε κανενός, είτε ενός, είτε περισσότερων κρυμμένων στρωμάτων.

Όταν το στρώμα εισόδου λαμβάνει μια είσοδο, οι νευρώνες του παράγουν μια έξοδο, η οποία γίνεται είσοδος στα άλλα στρώματα του συστήματος. Η διαδικασία συνεχίζεται έως ότου ικανοποιηθεί μια συγκεκριμένη κατάσταση.

Είναι επίσης δυνατό, ανάλογα με τον αλγόριθμο εκμάθησης οι πληροφορίες να διαδίδονται ανάποδα.

Εάν αυξηθεί πάρα πολύ ο αριθμός των κρυμμένων νευρώνων, το δίκτυο θα έχει πρόβλημα. Το σύνολο των στοιχείων εκμάθησης θα απομνημονευθεί, καθιστώντας το δίκτυο άχρηστο στα νέα σύνολα στοιχείων για την εκμάθησή του.

Παρακάτω φαίνεται ένα νευρωνικό δίκτυο με 3 στρώματα νευρώνων.



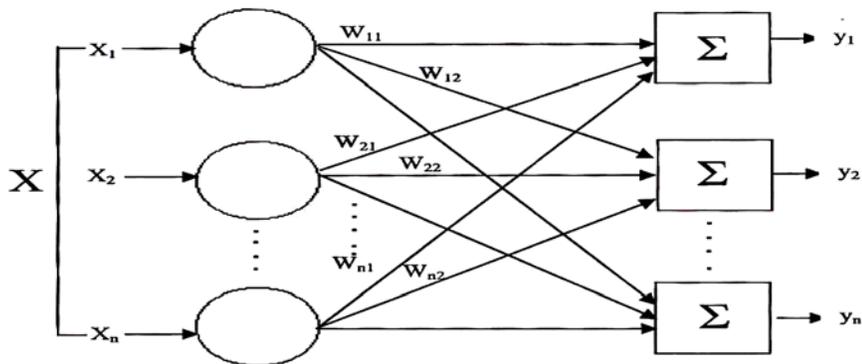
Σχήμα 1. 9: Νευρωνικό δίκτυο με 3 στρώματα νευρώνων.

Αυτή δεν είναι η γενική δομή ενός νευρωνικού δικτύου. Για παράδειγμα, μερικοί τύποι νευρωνικών δικτύων δεν έχουν κανένα κρυμμένο στρώμα ή οι νευρώνες σε ένα στρώμα τακτοποιούνται ως πίνακας (matrix). Αυτό που είναι κοινό για όλους τους τύπους νευρωνικών δικτύων είναι η παρουσία τουλάχιστον ενός weight matrix, οι συνδέσεις μεταξύ δύο στρωμάτων.

1.11 Single-Layer TΝΔ-Μονοστρωματικά

Μολονότι ένα μόνο του νευρώνιο μπορεί να εκτελέσει μερικές απλές λειτουργίες που αφορούν την ανίχνευση απλών προτύπων, η δύναμη της υπολογιστικότητας των νευρωνίων ανοίγεται μπροστά μας μόνο όταν αυτά συνδεθούν σε δίκτυο. Το πιο απλό δίκτυο αποτελείται από μια ομάδα από νευρώνια διατεταγμένα σε στρώμα, όπως φαίνεται στην δεξιά πλευρά του Σχήματος 1.10. Οι κύκλοι που φαίνονται στα αριστερά εργάζονται μόνο για το μοίρασμα των τιμών εισόδου, δεν εκτελούν υπολογισμούς, και έτσι δεν θεωρούνται ότι αποτελούν στρώμα, αντίθετα, τα νευρώνια που εκτελούν

υπολογισμούς έχουν την μορφή τετραγώνων. Το σετ των τιμών εισόδου X έχει το κάθε του στοιχείο συνδεδεμένο σε κάθε τεχνητό νευρώνα διαμέσου διαφορετικών βαρών. Τα πρώτα ΤΝΔ δεν ήταν περισσότερο πολύπλοκα από ότι αυτό εδώ. Το κάθε νευρώνιο απλά παράγει ένα άθροισμα από τις τιμές εισόδου του δικτύου που έχουν πολλαπλασιαστεί με τα αντίστοιχα βάρη. Στην πραγματικότητα στα τεχνητά και βιολογικά δίκτυα πολλές από τις συνδέσεις τους μπορεί να μην υπάρχουν, όμως φαίνονται όλες για λόγους γενικότητας.



Σχήμα 1. 10

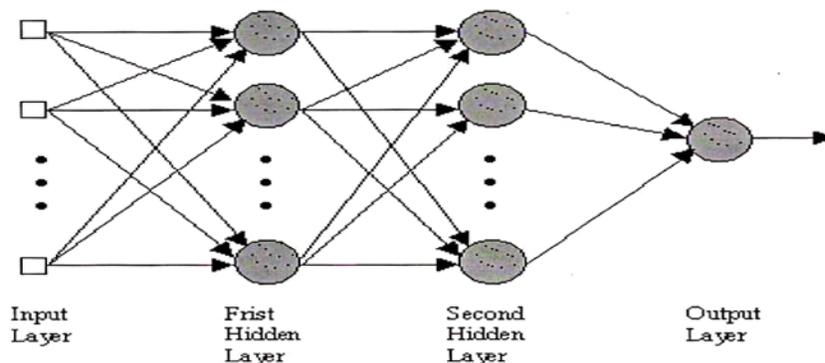
Είναι πιο συμφέρον να θεωρούμε τα βάρη σαν τα στοιχεία ενός πίνακα W . Οι διαστάσεις του πίνακα είναι x γραμμές και n στήλες, όπου x ο αριθμός των εισόδων και n ο αριθμός των νευρώνων. Για παράδειγμα, το βάρος που συνδέει την 3η είσοδο με το 2ο νευρώνιο είναι το $w_{3,2}$. Με αυτό τον τρόπο φαίνεται ότι ο υπολογισμός του σετ των νευρώνων NET τιμών εξόδου N για ένα στρώμα πετυχαίνεται με πολλαπλασιασμό πινάκων. Έτσι $N=X*W$, όπου N και X είναι διανύσματα σειράς (row vectors).

1.12 Multilayer ΤΝΔ -Πολυστρωματικά

Μεγαλύτερα, περισσότερο πολύπλοκα δίκτυα, γενικά προσφέρουν μεγαλύτερη ικανότητα υπολογισμών. Μολονότι τα δίκτυα έχουν κατασκευαστεί με κάθε δυνατό τρόπο διάταξής τους, διατάσσοντας τα νευρώνια σε στρώμα, μιμούνται την στρωματική δομή των διάφορων τμημάτων του εγκεφάλου. Τα πολυστρωματικά δίκτυα, έχει αποδειχθεί, ότι έχουν ικανότητες πέρα από αυτές των μονοστρωματικών δικτύων και στα πρόσφατα χρόνια αναπτύχθηκαν αλγόριθμοι για να τα εκπαιδεύσουν. Τα πολυστρωματικά δίκτυα μπορούν να σχηματιστούν από ομάδες μονοστρωματικών δικτύων. Η έξοδος ενός στρώματος αποτελεί την είσοδο του επόμενου στρώματος.

Το πιο κοινό μοντέλο νευρωνικού δικτύου είναι το πολυστρωματικό perceptron (MLP). Αυτός ο τύπος δικτύου είναι γνωστός ως supervised network (εποπτευόμενο δίκτυο) επειδή απαιτεί μια επιθυμητή έξοδο για να μάθει. Ο στόχος αυτού του δικτύου είναι να δημιουργήσει ένα μοντέλο που να χαρτογραφεί σωστά την είσοδο στην έξοδο έτσι ώστε το μοντέλο να μπορεί έπειτα να χρησιμοποιηθεί, για να παράγει την έξοδο όταν η

επιθυμητή έξοδος είναι άγνωστη. Μια γραφική αντιπροσώπευση ενός MLP φαίνεται παρακάτω στο Σχήμα 1.11:



Σχήμα 1.11: Block διάγραμμα του multiplayer perceptron (MLP) (2 κρυμμένων στρωμάτων).

Οι είσοδοι τροφοδοτούνται στο στρώμα εισόδου και περνούν πολλαπλασιασμένες με τα βάρη διασύνδεσης από το στρώμα εισόδου στο πρώτο κρυμμένο στρώμα. Μέσα στο πρώτο κρυμμένο στρώμα, αθροίζονται, έπειτα επεξεργάζονται από μια μη γραμμική συνάρτηση (συνήθως υπερβολική-hyperbolic εφαπτομένη). Καθώς το επεξεργασμένο δεδομένο αφήνει το πρώτο κρυμμένο στρώμα, πολλαπλασιάζεται πάλι με τα βάρη διασύνδεσης, κατόπιν αθροίζονται και υποβάλλονται σε επεξεργασία από το δεύτερο κρυμμένο στρώμα. Τελικά το δεδομένο πολλαπλασιάζεται με τα βάρη διασύνδεσης έπειτα επεξεργάζεται μια τελευταία φορά μέσα στο στρώμα εξόδου για να παραγάγει την έξοδο του νευρικού δικτύου.

1.13 Συνδέσεις ενδιάμεσων στρωμάτων (Inter-layer connections)

Υπάρχουν διαφορετικοί τύποι συνδέσεων που χρησιμοποιούνται μεταξύ των στρωμάτων. Αυτές οι συνδέσεις μεταξύ των στρωμάτων καλούνται συνδέσεις ενδιάμεσων στρωμάτων.

- **Fully connected**
Κάθε νευρώνας στο πρώτο στρώμα συνδέεται με κάθε νευρώνα στο δεύτερο στρώμα.
- **Feed forward**
Ένα νευρώνιο του πρώτου στρώματος δεν είναι απαραίτητο να συνδέεται με όλους τους νευρώνες στο δεύτερο στρώμα.
- **Feed forward**
Οι νευρώνες στο πρώτο στρώμα στέλνουν την έξοδό τους στους νευρώνες στο δεύτερο στρώμα, αλλά δεν λαμβάνουν πίσω κάποια μορφή εισόδου από τους νευρώνες του δεύτερου στρώματος.

- **Bi-directional**

Υπάρχει ένα άλλο σύνολο συνδέσεων που μεταφέρει την έξοδο των νευρώνων του δεύτερου στρώματος στους νευρώνες του πρώτου στρώματος.

Οι προς τα εμπρός και αμφίδρομες συνδέσεις θα μπορούσαν να είναι πλήρως ή μερικώς συνδεδεμένες.

- **Hierarchical**

Εάν ένα νευρωνικό δίκτυο έχει μια ιεραρχική δομή, οι νευρώνες ενός χαμηλότερου στρώματος μπορούν να επικοινωνήσουν μόνο με τους νευρώνες του επόμενου στρώματος.

- **Resonance**

Τα στρώματα έχουν bi-directional connections και μπορούν να συνεχίσουν να στέλνουν αρκετές φορές μηνύματα μέσω των συνδέσεων, έως ότου επιτευχθεί μια συγκεκριμένη κατάσταση.

1.14 Συνδέσεις διαστρωμάτων (Intra-layer connections)

Στις πιο σύνθετες δομές, οι νευρώνες επικοινωνούν μεταξύ τους μέσω ενός στρώματος (συνδέσεις διαστρώματος).

Υπάρχουν δύο τύποι συνδέσεων διαστρώματος :

- **Recurrent**

Οι νευρώνες μέσα σε ένα στρώμα είναι πλήρως ή μερικώς συνδεδεμένοι μεταξύ τους. Αφού λάβουν είσοδο από ένα άλλο στρώμα, μεταδίδουν τα αποτελέσματά τους αρκετές φορές ο ένας με τον άλλο, πριν τους επιτραπεί να στείλουν τα αποτελέσματά τους σε ένα άλλο στρώμα. Γενικά κάποιες προϋποθέσεις μεταξύ των νευρώνων ενός στρώματος πρέπει να πραγματοποιηθούν προτού διαβιβάσουν τα αποτελέσματά τους σε άλλο στρώμα.

- **On-center/off surround**

Ένας νευρώνας μέσα σε ένα στρώμα έχει ενισχυτικές συνδέσεις με τον εαυτό του και με τους άμεσους γείτονές του και έχει ανασταλτικές συνδέσεις με άλλους νευρώνες. Κάθε ομάδα νευρώνων διεγείρει τον εαυτό της και τις γειτονικές ομάδες νευρώνων και εμποδίζει όλες τις άλλες. Μετά από μερικούς κύκλους ανταλλαγής σημάτων, υπερτερούν οι νευρώνες που έχουν μια ενεργό αξία εξόδου και μπορούν έτσι να ανανεώσουν τα βάρη τα δικά τους και των γειτόνων τους.

Υπάρχουν δύο τύποι συνδέσεων μεταξύ δύο νευρώνων: ο ενισχυτικός και ο ανασταλτικός. Στην ενισχυτική σύνδεση, η έξοδος ενός νευρώνα αυξάνει την ενεργητική δυνατότητα του νευρώνα με τον οποίο συνδέεται. Όταν ο τύπος σύνδεσης μεταξύ δύο νευρώνων είναι ανασταλτικός, η έξοδος του νευρώνα που στέλνει ένα μήνυμα, θα μειώνει τη δυνατότητα δραστηριότητας ή ενέργειας του λαμβάνοντος νευρώνα. Ο ένας προκαλεί το μηχανισμό αθροίσματος του

επόμενου νευρώνα για να προσθέσει ενώ ο άλλος προκαλεί την αφαίρεση. Ο ένας διεγείρει ενώ άλλος εμποδίζει.

1.15 Γιατί είναι δύσκολο να διαμορφωθεί ένα νευρωνικό δίκτυο ομοειδές με τον ανθρώπινο εγκέφαλο;

Είδαμε ότι η λειτουργία των μεμονωμένων νευρώνων είναι αρκετά απλή.

Η δυσκολία όμως προκύπτει διότι είναι δύσκολο να ανακαλυφθεί ποιοι νευρώνες πρέπει να συνδεθούν μεταξύ τους. Αυτό πρόβλημα έχει να κάνει με την οριοθέτηση της δομής των νευρωνικών δικτύων. Οι διασυνδέσεις στον εγκέφαλο αλλάζουν συνεχώς. Οι αρχικές διασυνδέσεις φαίνονται να κυβερνώνται κατά ένα μεγάλο μέρος από τους γενετικούς παράγοντες.

Τα βάρη στις άκρες και οι ευαισθησίες στους κόμβους αλλάζουν συνεχώς. Αυτό το πρόβλημα έχει αποτελέσει το αντικείμενο έρευνας και έχει λυθεί σε μεγάλο βαθμό. Λαμβάνοντας υπόψη κάποια είσοδο, εάν το νευρωνικό δίκτυο κάνει κάποιο σφάλμα, τότε μπορεί να καθοριστεί ακριβώς ποιοι νευρώνες ήταν ενεργοί πριν το σφάλμα. Τότε μπορούμε να αλλάξουμε τα βάρη και τις ευαισθησίες για να μειώσουμε κατάλληλα αυτό το σφάλμα.

Το νευρωνικό δίκτυο πρέπει να "ξέρει" ότι έχει κάνει ένα λάθος. Στην πραγματική ζωή, το λάθος γίνεται συνήθως προφανές μόνο μετά από πολύ χρόνο. Αυτή η κατάσταση είναι δυσκολότερο να αντιμετωπιστεί δεδομένου ότι μπορεί να μην ξέρουμε ποια είσοδος οδήγησε σε σφάλμα.

Αυτό το πρόβλημα μπορεί να θεωρηθεί ως γενίκευση του προηγούμενου προβλήματος της δομής των νευρωνικών δικτύων. Εάν λυθεί αυτό, λύνεται και το άλλο διότι εάν το βάρος μεταξύ δύο νευρώνων είναι μηδέν τότε είναι τόσο καλό όσο οι δύο νευρώνες δεν συνδέονται καθόλου. Έτσι εάν μπορούσαμε να υπολογίσουμε τα βάρη κατάλληλα, τότε η δομή γίνεται γνωστή.

Η λειτουργία των μεμονωμένων νευρώνων μπορεί να μην είναι τόσο απλή τελικά. Παραδείγματος χάριν, εάν ένας νευρώνας λαμβάνει τα σήματα από πολλούς γειτονικούς νευρώνες, το συνδυασμένο ερέθισμα μπορεί να υπερβεί την ευαισθησία του. Στην πραγματικότητα, ο νευρώνας δεν χρειάζεται να λάβει όλα τα σήματα ακριβώς στον ίδιο χρόνο, αλλά πρέπει να τα λάβει όλα σε ένα σύντομο διάστημα. Συνήθως υποτίθεται ότι τέτοιες λεπτομέρειες δεν έχουν επιπτώσεις στη λειτουργία του μιμούμενου νευρωνικού δικτύου αλλά μπορεί και να έχουν.

Ένα άλλο παράδειγμα της απόκλισης από την κανονική λειτουργία είναι ότι μερικές άκρες μπορούν να διαβιβάσουν σήματα και στις δύο κατευθύνσεις. Πραγματικά, όλες οι άκρες μπορούν να διαβιβάσουν σήματα και στις δύο κατευθύνσεις αλλά συνήθως διαβιβάζουν σε μία μόνο κατεύθυνση, από τον ένα νευρώνα στον άλλον.

1.16 Τα πλεονεκτήματα ενός νευρωνικού δικτύου

- Τη δυνατότητά τους να αντιπροσωπεύουν και τις γραμμικές και μη γραμμικές σχέσεις και τη δυνατότητά τους να μάθουν αυτές τις σχέσεις άμεσα από τα στοιχεία που διαμορφώνονται.
- Δυνατότητα προσαρμοστικής εκμάθησης. Το δίκτυο είναι σε θέση να μάθει να εκτελεί διαδικασίες βασισμένες στα δεδομένα που του δίνονται.

- Αυτό-οργάνωση. Ένα νευρωνικό δίκτυο είναι σε θέση να οργανώνεται με την πάροδο του χρόνου και με βάση τα δεδομένα που δέχεται από τις διάφορες εισόδους του.
- Επεξεργασία σε συνθήκες πραγματικού χρόνου. Οι υπολογισμοί ενός νευρωνικού δικτύου γίνονται ιδιαίτερα γρήγορα, αφού η σχεδίασή τους είναι βασισμένη σε παράλληλη αρχιτεκτονική των επεξεργαστών του συστήματος.
- Δυνατότητα διόρθωσης λαθών. Ανοχή σφάλματος μέσω της περιττής κωδικοποίησης πληροφοριών. Αυτό σημαίνει ότι, εάν ένα νευρωνικό δίκτυο έχει εκπαιδευτεί για ένα συγκεκριμένο πρόβλημα, θα είναι σε θέση να ανακαλέσει τα σωστά αποτελέσματα, ακόμα κι αν το πρόβλημα προς λύση δεν είναι ακριβώς το ίδιο με αυτό στο οποίο έχει γίνει η εκμάθηση. Παραδείγματος χάριν, αν υποθέσουμε ότι ένα νευρωνικό δίκτυο έχει εκπαιδευτεί για να αναγνωρίζει την ανθρώπινη ομιλία. Κατά τη διάρκεια της διαδικασίας εκμάθησης, ένα συγκεκριμένο άτομο πρέπει να προφέρει μερικές λέξεις, τις οποίες μαθαίνει το δίκτυο. Εάν το νευρωνικό δίκτυο εκπαιδευτεί σωστά, πρέπει να είναι σε θέση να αναγνωρίσει εκείνες τις λέξεις και όταν αυτές λεχθούν από ένα άλλο πρόσωπο.

1.17 Εφαρμογές των ANNs - Τι μπορούν να κάνουν

Τα νευρωνικά δίκτυα κατασκευάζονται για να λύσουν τα προβλήματα που δεν μπορούν να λυθούν χρησιμοποιώντας τους συμβατικούς αλγορίθμους. Τέτοια προβλήματα είναι συνήθως προβλήματα βελτιστοποίησης ή ταξινόμησης. Σε γενικές γραμμές, ένα νευρωνικό δίκτυο μπορεί να υπολογίσει οποιαδήποτε υπολογίσιμη λειτουργία, δηλ. μπορεί να κάνει όλα εκείνα που μπορεί και ένας κανονικός ψηφιακός υπολογιστής.

Λόγω της ικανότητας των νευρωνικών δικτύων να βρίσκουν λύσεις σε περιπτώσεις με πολύπλοκα ή αποσπασματικά δεδομένα, χρησιμοποιούνται για την αναγνώριση προτύπων και την εξαγωγή συμπερασμάτων. Ένα "εκπαιδευμένο" νευρωνικό δίκτυο είναι δυνατόν να θεωρηθεί "ειδήμονας" στην κατηγορία των πληροφοριών που του δίνονται για ανάλυση.

Τα νευρωνικά δίκτυα έχουν εφαρμοστεί στην επίλυση ποικίλων προβλημάτων.

Η πιο συνηθισμένη χρήση τους είναι να προβλέπουν τι είναι πιθανόν να συμβεί. Υπάρχουν πολλές περιπτώσεις όπου η πρόβλεψη μπορεί να βοηθήσει στον καθορισμό των προτεραιοτήτων.

Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την πρόβλεψη χρηματιστηρίου με εκπληκτικά ακριβή αποτελέσματα, για τον έλεγχο βιομηχανικών διαδικασιών, τη διαχείριση κρίσεων και για να προσφέρουν βοήθεια στην ιατρική όσον αφορά τη διάγνωση ασθενειών (π.χ. πρόωμη αναγνώριση καρκίνου του στήθους). Επίσης για τη ρύθμιση κινητήρα έτσι ώστε να ελαχιστοποιείται η αποβολή καυσαερίων, για τον έλεγχο ρομπότ έτσι ώστε να αποφεύγεται η σύγκρουσή του με εμπόδια και για την πρόβλεψη πτώχευσης για τα ιδρύματα πιστωτικών καρτών.

Τα νευρωνικά δίκτυα έχουν εφαρμοστεί επίσης για να μετατρέψουν το κείμενο σε ομιλία. Το NETtalk είναι ένα από τα συστήματα που έχουν αναπτυχθεί για αυτόν το λόγο. Μια από τις πιο γνωστές εφαρμογές τους είναι ακόμη η ανίχνευση βομβών που εγκαθίσταται σε μερικούς Αμερικάνικους αερολιμένες. Αυτή η συσκευή αποκαλούμενη SNOOPE, καθορίζει την παρουσία ορισμένων ενώσεων, από τις χημικές διαμορφώσεις των συστατικών τους.

Η επεξεργασία εικόνας και η αναγνώριση προτύπων αποτελούν ίσως έναν από τους σημαντικότερους τομείς εφαρμογής των νευρωνικών δικτύων καθώς επίσης και η αναγνώριση χαρακτήρα και η αναγνώριση γραφής. Το τελευταίο έχει εφαρμογή στις τραπεζικές εργασίες, στην επεξεργασία πιστωτικών καρτών και άλλες οικονομικές υπηρεσίες, όπου η ανάγνωση και η σωστή αναγνώριση γραφής σε έγγραφα είναι μεγάλης σημασίας.

Βασικά τα περισσότερα νευρωνικά δίκτυα ανήκουν σε κάποια από τις παρακάτω κατηγορίες:

Πρόβλεψη (prediction)

Χρησιμοποιούν τιμές εισόδου για να προβλέψουν κάποια έξοδο π.χ. να διαλέξουν τις καλύτερες αξίες στο χρηματιστήριο, να προβλέψουν τον καιρό, να αναγνωρίζουν ανθρώπους με τον κίνδυνο εμφάνισης καρκίνου.

Ταξινόμηση (Classification)

Χρησιμοποιούν τιμές εισόδου για να καθορίσουν την ταξινόμηση π.χ. εάν είναι η είσοδος το γράμμα Α, εάν είναι κάποια τηλεοπτική ένδειξη ή ένα αεροπλάνο και ποιο είδος αεροπλάνου είναι.

Συνδυασμός δεδομένων (Data association)

Όμοια με την ταξινόμηση, αλλά εδώ αναγνωρίζονται επίσης τα δεδομένα που περιέχουν σφάλματα π.χ. όχι μόνο προσδιορίζει τους χαρακτήρες που ανιχνεύθηκαν αλλά αναγνωρίζει και όταν ακόμα δεν λειτουργεί κατάλληλα ο σαρωτής.

Data Conceptualization

Ανάλυση των εισόδων έτσι ώστε να προκύπτουν ομαδικές σχέσεις π.χ. εξαγωγή από μια βάση δεδομένων των πιο πιθανών ονομάτων καταναλωτών που θα αγοράσουν ένα προϊόν.

Φιλτράρισμα δεδομένων (Data Filtering)

Ομαλοποίηση ενός σήματος εισόδου π.χ. απομάκρυνση του θορύβου από μια τηλεφωνική γραμμή.

Τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για:

- ταξινόμηση προτύπων
- ανίχνευση προτύπων.
- ικανότητα ανίχνευσης
- επεξεργασία εικόνας
- φωνητική ανάλυση
- προβλήματα βελτιστοποίησης
- οδήγηση ρομπότ
- επεξεργασία ανακριβών ή ελλιπών εισόδων
- εξασφάλιση ποιότητας
- πρόβλεψη χρηματιστηρίου
- προσομοίωση

Γενικά τα νευρωνικά δίκτυα είναι πολύ εύκαμπτα συστήματα για την επίλυση προβλημάτων.

1.18 Όρια των ΤΝΔ - Που αποτυγχάνουν

Αν και η αποτελεσματικότητα των νευρωνικών δικτύων στην επίλυση προβλημάτων δεν αμφισβητείται, εντούτοις αυτά δεν θεωρούνται ιδιαίτερα "έξυπνα".

Τα προγράμματα των νευρωνικών δικτύων γίνονται μερικές φορές ασταθή όταν εφαρμόζονται σε μεγαλύτερα προβλήματα. Οι πυρηνικές και διαστημικές βιομηχανίες, ανησυχούν για το ζήτημα της δοκιμής και της επαλήθευσης. Οι μαθηματικές θεωρίες που χρησιμοποιούνται για να εγγυηθούν την απόδοση ενός εφαρμοσμένου νευρωνικού δικτύου είναι ακόμα υπό ανάπτυξη. Η λύση προς το παρόν είναι να εκπαιδεύσουν και να εξετάσουν αυτά τα ευφυή συστήματα όπως κάνουμε για τους ανθρώπους.

Επίσης υπάρχουν κάποια πρακτικά προβλήματα όπως:

Το λειτουργικό πρόβλημα κατά την προσπάθεια της μίμησης των νευρωνικών δικτύων. Δεδομένου ότι η πλειοψηφία των νευρωνικών δικτύων μιμείται πάνω σε διαδοχικές μηχανές, προκαλεί μια πολύ γρήγορη αύξηση στις χρονικές απαιτήσεις επεξεργασίας.

Δεν μπορούν να εξηγήσουν οποιαδήποτε αποτελέσματα επιτυγχάνουν. Τα δίκτυα λειτουργούν ως "μαύρα κιβώτια" των οποίων οι κανόνες λειτουργίας είναι απολύτως άγνωστοι.

Αν και τα νευρωνικά δίκτυα είναι σε θέση να βρουν λύσεις για τα δύσκολα προβλήματα, δεν μπορεί να εγγυηθεί κανείς ότι τα αποτελέσματα είναι τέλεια ή ακόμα και σωστά. Είναι ακριβώς προσεγγίσεις μιας επιθυμητής λύσης και πάντα υπάρχει κάποιο σφάλμα.

Υπάρχουν προβλήματα που δεν μπορούν να λυθούν σωστά από τα νευρωνικά δίκτυα.

Για παράδειγμα στην αναγνώριση προτύπων:

Εάν συναντήσετε ένα πρόσωπο που έχετε ξανασυναντήσει στη ζωή σας, συνήθως θα το αναγνωρίσετε τη δεύτερη φορά, ακόμα κι αν δεν είναι ακριβώς έτσι όπως πριν.

Υποθέστε τώρα ότι εκπαιδεύσατε ένα νευρωνικό δίκτυο με τη φωτογραφία αυτού του προσώπου. Αυτή η εικόνα θα αναγνωριστεί σίγουρα από το δίκτυο. Αλλά εάν προσθέσετε βαρύ θόρυβο στην εικόνα (με άλλα λόγια την τροποποιήσετε σημαντικά) ή την περιστρέψετε μέχρι ενός ορισμένου βαθμού, η αναγνώριση πιθανώς να αποτύχει.

1.19 Πώς αναπτύσσονται τα ΤΝΔ

Τα ΤΝΔ δεν είναι προγραμματισμένα να λειτουργούν όπως τα συμβατικά προγράμματα υπολογιστών, αλλά μαθαίνουν από την εμπειρία. Ένα ΤΝΔ μαθαίνει κατά τη διάρκεια μιας φάσης κατάρτισης στην οποία οι γνωστές είσοδοι και έξοδοι (αποτελέσματα) δείχνονται στο ΤΝΔ διαδοχικά και επανειλημμένα. Ένας αλγόριθμος κατάρτισης ρυθμίζει τα βάρη σε κάθε σύνδεση με στόχο να μειώσει το σφάλμα. Αρχικά τα αποτελέσματα που παράγονται από το ΤΝΔ είναι κάπως αυθαίρετα. Αλλά καθώς περνά χρόνος, δεδομένου ότι οι περιπτώσεις είναι επανειλημμένα επανεισαγμένες (εκατοντάδες ή χιλιάδες φορές), το ΤΝΔ αρχίζει να παίρνει σωστές μερικές των απαντήσεων. Ο αλγόριθμος κατάρτισης συνεχίζει να αλλάζει τα βάρη έως ότου οι περισσότερες από τις απαντήσεις είναι σωστές οπότε και η κατάρτιση του δικτύου σταματά.

Η επόμενη φάση είναι να εξεταστεί ή να επικυρωθεί το ΤΝΔ. Αυτό γίνεται με ένα σύνολο περιπτώσεων που το ΤΝΔ δεν έχει δει ξανά. Ανάλογα με την απόδοση του ΤΝΔ σε αυτό το σημείο καθορίζεται εάν αυτό έχει εκπαιδευτεί και διδαχθεί σωστά.

2.1 Η Εκπαίδευση των ΤΝΔ

Το γεγονός ότι τα ΤΝΔ έχουν την δυνατότητα να μαθαίνουν, δηλ να εκπαιδεύονται, είναι ίσως το πιο σημαντικό τους χαρακτηριστικό. Όπως και τα βιολογικά έτσι και τα τεχνητά δίκτυα μεταβάλλονται από την εμπειρία που αποκτούν, στην προσπάθεια τους να δώσουν ως έξοδο το ζητούμενο σωστό αποτέλεσμα.

Έχουμε καταλάβει μέχρι στιγμής ότι το πιο χαρακτηριστικό γνώρισμα των νευρώνων είναι τα βάρη τα οποία πολλαπλασιάζουν τη στάθμη των εισερχόμενων σημάτων. Για τον καθορισμό τους πρέπει να λάβουμε υπόψην πολλούς παράγοντες που γίνονται όλο και περισσότεροι καθώς αυξάνονται οι απαιτήσεις για τα νευρωνικά δίκτυα. Γιατί όμως θα πρέπει να προβληματιζόμαστε για το πώς θα υπολογίσουμε αυτούς τους συντελεστές; Εμείς όταν βλέπουμε κάποιο αντικείμενο μας λέει κάποιος με ποιους συντελεστές βαρών πρέπει να πολλαπλασιάσουν οι νευρώνες του εγκεφάλου μας τα οπτικά ερεθίσματα; Όχι φυσικά, θα λέγαμε μάλιστα ότι το ίδιο πρέπει να γίνεται και με τους τεχνητούς νευρώνες. Είναι απαραίτητο λοιπόν να βρούμε έναν τρόπο ώστε το νευρωνικό δίκτυο να προσδιορίζει τα βάρη της κάθε εισόδου χωρίς τη δική μας παρέμβαση. Η διαδικασία αυτή είναι γνωστή ως διαδικασία εκμάθησης και πραγματοποιείται με τη βοήθεια ειδικών λογαρίθμων.

Αν θεωρήσουμε ότι τα διανύσματα εισόδου αποτελούνται από d μεταβλητές και κάθε μεταβλητή λαμβάνει N διακριτές τιμές τότε το πρόβλημα της εκπαίδευσης στοιχειοθετείται από N^d διανύσματα εισόδου που λαμβάνουν N διακριτές τιμές. Τα εκπαιδευτικά διανύσματα εισόδου είναι τα «στοιχεία» που βοηθούν στην ανακάλυψη της σωστής συναρτήσεως. Όσο πιο μεγάλο είναι το μέγεθος του ΤΝΔ τόσο περισσότερες συναρτήσεις μπορεί να υλοποιήσει και επομένως αυξάνεται η πιθανότητα η επιθυμητή συνάρτηση να βρίσκεται σε αυτό το σύνολο συναρτήσεων. Αν υποθέσουμε ότι το μέγεθος του ΤΝΔ είναι αρκετά μεγάλο ώστε να συμπεριλαμβάνει την επιθυμητή συνάρτηση, τότε μπορούμε να θεωρήσουμε ότι τα εκπαιδευτικά διανύσματα εισόδου μας δίνουν την δυνατότητα απόρριψης των ανεπιθύμητων συναρτήσεων. Όσο περισσότερα διανύσματα διαθέτουμε τόσο περισσότερες συναρτήσεις μπορούμε να απορρίψουμε. Αν όμως το μέγεθος του ΤΝΔ δεν είναι αρκετά μεγάλο τότε το ΤΝΔ αναζητεί τη συνάρτηση που ταιριάζει καλύτερα με την επιθυμητή.

Κατά τη διάρκεια της διαδικασίας εκμάθησης του ανθρώπινου εγκεφάλου, η δομή σύνδεσης μεταξύ των νευρώνων αλλάζει, έτσι ώστε ορισμένα ερεθίσματα να γίνονται αποδεκτά μόνο από ορισμένους νευρώνες. Αυτό σημαίνει ότι υπάρχουν οι σταθερές συνδέσεις μεταξύ των νευρωνικών κυττάρων που κάποια φορά έμαθαν κάποια πληροφορία και έπειτα είναι σε θέση να την ανακαλέσουν.

Εάν κάποιες σχετικές πληροφορίες αποκτιούνται αργότερα, τα ίδια νευρωνικά κύτταρα προσαρμόζουν τη δομή σύνδεσής τους σύμφωνα με αυτές τις νέες πληροφορίες. Αφ' ετέρου, εάν συγκεκριμένες πληροφορίες δεν υπενθυμίζονται για μεγάλο χρονικό διάστημα, η καθιερωμένη δομή σύνδεσης μεταξύ των αρμόδιων νευρωνικών κυττάρων θα γίνει περισσότερο "αδύναμη". Αυτό συμβαίνει εάν κάποιος "ξέχασε" κάτι που έμαθε κάποια στιγμή ή μπορεί μόνο να το θυμηθεί αόριστα.

Αντίθετα από το βιολογικό μοντέλο, ένα νευρωνικό δίκτυο έχει μια αμετάβλητη δομή από έναν προσδιορισμένο αριθμό νευρώνων και έναν προσδιορισμένο αριθμό συνδέσεων μεταξύ τους -βάρη- τα οποία έχουν ορισμένες τιμές. Αυτό που αλλάζει κατά τη διάρκεια της διαδικασίας εκμάθησης είναι οι τιμές των βαρών.

Η εισερχόμενη πληροφορία "υποκινεί" (υπερβαίνει μια προσδιορισμένη τιμή ευαισθησίας) ορισμένους νευρώνες που περνούν τις πληροφορίες στους συνδεδεμένους νευρώνες ή αποτρέπουν την περαιτέρω μεταφορά κατά μήκος των σταθμισμένων συνδέσεων. Η αξία ενός βάρους θα αυξηθεί εάν οι πληροφορίες μεταφερθούν και θα μειωθεί σε αντίθετη περίπτωση.

Κατά τη διάρκεια εκμάθησης διαφορετικών εισόδων, οι τιμές βάρους αλλάζουν δυναμικά μέχρι οι τιμές τους να ισορροπήσουν, έτσι κάθε είσοδος θα οδηγήσει στην επιθυμητή έξοδο.

Η κατάρτιση ενός ΤΝΔ καταλήγει σε έναν πίνακα (matrix) που κρατά τις τιμές βάρους μεταξύ των νευρώνων. Όταν ένα ΤΝΔ έχει εκπαιδευτεί σωστά, θα είναι σε θέση πιθανώς να βρει την επιθυμητή έξοδο σε μια δεδομένη είσοδο που ήταν διδαγμένη, με τη χρησιμοποίηση αυτών των τιμών του πίνακα.

Πολύ συχνά υπάρχει ένα ορισμένο σφάλμα μετά από τη διαδικασία εκμάθησης, έτσι στις περισσότερες περιπτώσεις, η έξοδος είναι απλά μόνο μια καλή προσέγγιση τις τέλειες εξόδου.

2.2 Μέθοδοι εκμάθησης των ΤΝΔ

Μόλις κατασκευαστεί ένα δίκτυο για μια εφαρμογή, τότε είναι έτοιμο να εκπαιδευθεί. Αρχικά επιλέγονται τυχαία τα βάρη. Ύστερα αρχίζει η κατάρτιση ή εκμάθηση.

Υπάρχουν δύο βασικές περιπτώσεις κατάρτισης, η εποπτευόμενη (supervised) και η μη εποπτευόμενη (unsupervised). Η εποπτευόμενη κατάρτιση περιλαμβάνει έναν μηχανισμό που παρέχει στο δίκτυο την επιθυμητή έξοδο είτε "βαθμολογώντας" την απόδοση του δικτύου είτε παρέχοντας τις επιθυμητές εξόδους. Η μη εποπτευόμενη κατάρτιση είναι αυτή όπου το δίκτυο πρέπει να επεξεργαστεί τις εισόδους χωρίς κάποια εξωτερική βοήθεια.

Τα περισσότερα δίκτυα χρησιμοποιούν την εποπτευόμενη κατάρτιση. Η μη εποπτευόμενη κατάρτιση χρησιμοποιείται για να εκτελέσει κάποια αρχική επεξεργασία στις εισόδους.

Υπάρχουν ήδη πολλές μέθοδοι εκμάθησης για τα ΤΝΔ που ανήκουν σε μια από τις δύο παραπάνω βασικές κατηγορίες (supervised, unsupervised). Κανένας δεν ξέρει πόσες ακριβώς. Κάθε εβδομάδα εφευρίσκονται νέες (τουλάχιστον παραλλαγές των υπαρχόντων). Παρακάτω είναι μια συλλογή από τις πιο γνωστές μεθόδους.

2.3 Μη Εποπτευόμενη Εκμάθηση – (Unsupervised Learning) (χωρίς "δάσκαλο")

Παρακάτω ακολουθούν μερικές ονομασίες των μεθόδων μη εποπτευόμενης εκμάθησης:

1) Feedback Nets:

- Additive Grossberg (AG)
- Shunting Grossberg (SG)
- Binary Adaptive Resonance Theory (ART1)

- Analog Adaptive Resonance Theory (ART2, ART2a)
- Discrete Hopfield (DH)
- Continuous Hopfield (CH)
- Discrete Bidirectional Associative Memory (BAM)
- Temporal Associative Memory (TAM)
- Adaptive Bidirectional Associative Memory (ABAM)
- Kohonen Self-organizing Map/Topology-preserving map (SOM/TPM)
- Competitive learning

2) Feedforward-only Nets:

- Learning Matrix (LM)
- Driver-Reinforcement Learning (DR)
- Linear Associative Memory (LAM)
- Optimal Linear Associative Memory (OLAM)
- Sparse Distributed Associative Memory (SDM)
- Fuzzy Associative Memory (FAM)
- Counterpropagation (CPN)

2.4 Εποπτευόμενη Εκμάθηση – (Supervised Learning) (με "δάσκαλο")

Παρακάτω ακολουθούν μερικές ονομασίες των μεθόδων εποπτευόμενης εκμάθησης:

1) Feedback Nets :

- Brain-State-in-a-Box (BSB)
- Fuzzy Cognitive Map (FCM)
- Boltzmann Machine (BM)
- Mean Field Annealing (MFA)
- Recurrent Cascade Correlation (RCC)
- Learning Vector Quantization (LVQ)
- Backpropagation through time (BPTT)
- Real-time recurrent learning (RTRL)
- Recurrent Extended Kalman Filter (EKF)

2) Feedforward-only Nets :

- Perceptron
- Adaline, Madaline
- Backpropagation (BP)
- Cauchy Machine (CM)
- Adaptive Heuristic Critic (AHC)
- Time Delay Neural Network (TDNN)
- Associative Reward Penalty (ARP)

- Avalanche Matched Filter (AMF)
- Backpercolation (Perc)
- Artmap
- Adaptive Logic Network (ALN)
- Cascade Correlation (CasCor)
- Extended Kalman Filter(EKF)

2.5 Μη Εποπτευόμενη Εκπαίδευση - Unsupervised Training

Παρά την επιτυχία μερικών εφαρμογών, η εποπτευόμενη εκπαίδευση έχει κατηγορηθεί ότι είναι βιολογικά αδύνατη. Είναι δύσκολο να συλλάβει κανείς ένα μηχανισμό εκπαίδευσης στον εγκέφαλο που να συγκρίνει της επιθυμητές και τις ενεργές εξόδους, που να εκτελεί διαδικασίες διόρθωσης τροφοδοτώντας προς τα πίσω διαμέσου του δικτύου. Αν ίσχυε κάτι τέτοιο, τότε από που αυτός ο μηχανισμός του εγκεφάλου θα είχε το πρότυπο της επιθυμητής εξόδου;

Η μη εποπτευόμενη εκπαίδευση είναι πολύ περισσότερο εύλογη σαν μοντέλο μάθησης στα βιολογικά συστήματα. Στην μη εποπτευόμενη κατάρτιση παρέχονται στο δίκτυο οι εισοδοί όχι όμως και οι επιθυμητές εξοδοί. Το σύστημα πρέπει έπειτα από μόνο του να αποφασίσει ποια χαρακτηριστικά γνωρίσματα θα χρησιμοποιήσει για να ομαδοποιήσει τα δεδομένα εισόδου. Αυτό αναφέρεται συχνά ως αυτο-οργάνωση ή προσαρμογή (self-organization ή adaption).

Το σύνολο εκπαίδευσης αποτελείται μόνο από διανύσματα εισόδου. Ο αλγόριθμος εκπαίδευσης αλλάζει τα βάρη του δικτύου για να παράγονται διανύσματα εξόδου που να είναι συνεπή, δηλαδή είτε η εφαρμογή ενός από τα διανύσματα εκπαίδευσης είτε η εφαρμογή ενός διανύσματος που είναι αρκετά όμοιο με αυτό, θα παράγει το ίδιο πρότυπο εξόδου. Η διαδικασία εκπαίδευσης βγάζει της στατιστικές ιδιότητες του συνόλου εκπαίδευσης και ομαδοποιεί τα παρόμοια διανύσματα σε τάξεις. Εφαρμόζοντας ένα διάνυσμα από δοσμένη τάξη στη είσοδο, θα παράγει συγκεκριμένο διάνυσμα εξόδου, αλλά δεν υπάρχει κανένας τρόπος ώστε να καθοριστεί πριν από την εκπαίδευση ποιο συγκεκριμένο πρότυπο εξόδου θα παραχθεί από δοσμένη τάξη διανύσματος εισόδου. Γι' αυτό οι εξοδοί ενός τέτοιου δικτύου πρέπει γενικά να μετατραπούν σε μια κατανοητή μορφή που είναι επακόλουθο της διαδικασίας εκπαίδευσης. Αυτό δεν είναι ένα σοβαρό πρόβλημα. Είναι συνήθως απλό το θέμα της αναγνώρισης της σχέσης εισόδου-εξόδου που έχει εγκαθιδρυθεί από το δίκτυο.

Ένας από τους κορυφαίους ερευνητές στην μη εποπτευόμενη εκμάθηση είναι ο Tuevo Kohonen, ένας ηλεκτρολόγος μηχανικός (Helsinki University). Έχει αναπτύξει ένα self-organizing δίκτυο, αποκαλούμενο auto-associator, το οποίο μαθαίνει χωρίς να έχει το πλεονέκτημα να γνωρίζει τη σωστή απάντηση. Είναι ένα ασυνήθιστο δίκτυο, περιέχει ένα ενιαίο στρώμα με πολλές συνδέσεις. Τα βάρη των συνδέσεων πρέπει να αρχικοποιηθούν και οι εισοδοί πρέπει να ομαλοποιηθούν. Οι νευρώνες ανταγωνίζονται.

2.6 Εποπτευμένη Εκπαίδευση - Supervised Training

Στην εποπτευμένη κατάρτιση, παρέχονται και οι εισόδοι και τα αποτελέσματα (έξοδοι). Η εποπτευόμενη εκπαίδευση απαιτεί το ζευγάρι του κάθε διανύσματος εισόδου με το διάνυσμα-στόχο που αντιπροσωπεύει την επιθυμητή έξοδο, και μαζί ονομάζονται training pair (ζευγάρι εκπαίδευσης). Για να εκπαιδευτεί ένα δίκτυο χρειάζεται κάποιος αριθμός τέτοιων ζευγαριών.

Εφαρμόζεται ένα διάνυσμα εισόδου, η έξοδος του δικτύου υπολογίζεται και συγκρίνεται με το αντίστοιχο διάνυσμα-στόχο και η διαφορά (λάθος-σφάλμα) τροφοδοτείται προς τα πίσω διαμέσου του δικτύου. Τα βάρη αλλάζουν σύμφωνα με ένα αλγόριθμο που τείνει να ελαττώσει το σφάλμα. Τα διανύσματα εισόδου εφαρμόζονται συνεχώς, υπολογίζονται τα σφάλματα και τα βάρη προσαρμόζονται για το κάθε διάνυσμα μέχρι το σφάλμα ολόκληρου του συνόλου εκπαίδευσης να είναι σε ένα αποδεκτό χαμηλό επίπεδο.

Το σύνολο των δεδομένων που αποτελούν την κατάρτιση καλείται "σύνολο κατάρτισης". Κατά τη διάρκεια της κατάρτισης ενός δικτύου το ίδιο σύνολο δεδομένων υποβάλλεται σε επεξεργασία πολλές φορές καθώς επαναπροσδιορίζονται τα βάρη συνδέσεων.

Εάν ένα δίκτυο δεν μπορεί να λύσει το πρόβλημα, ο σχεδιαστής πρέπει να αναθεωρήσει την είσοδο και τις εξόδους, τον αριθμό των στρωμάτων, τον αριθμό των συστατικών ανά στρώμα, τις συνδέσεις μεταξύ των στρωμάτων, το συνολικό αποτέλεσμα, τις συναρτήσεις εκμάθησης και τα αρχικά βάρη.

Υπάρχουν πολλοί νόμοι (αλγόριθμοι) που χρησιμοποιούνται για να εφαρμόσουν την προσαρμοστική ανατροφοδότηση που απαιτείται για να ρυθμιστούν τα βάρη κατά τη διάρκεια της κατάρτισης. Πιο συγκεκριμένα, κάποιος αλγόριθμος καθοδήγησης από εξωτερική πηγή ακολουθεί μια επαναληπτική διαδικασία βήμα προς βήμα σύμφωνα με την οποία τροποποιούνται οι τιμές των βαρών που συνδέουν τους TN.

Οι παράγοντες που επηρεάζουν την μεταβολή των βαρών είναι:

- Οι τρέχουσες τιμές των βαρών.
- Οι εισόδοι (σταθμισμένο άθροισμα) των TN.
- Οι έξοδοι των TN.
- Οι επιθυμητές έξοδοι.

Η επαναληπτική διαδικασία σταματάει όταν ελαχιστοποιηθεί κάποια συνάρτηση σφάλματος, η οποία δίνει το μέτρο της διαφοράς της πραγματικής εξόδου από τη επιθυμητή έξοδο του TNΔ. Το βασικό μειονέκτημα αυτής της μεθόδου είναι η πιθανότητα παγίδευσης του TNΔ σε κάποιο τοπικό ελάχιστο. Με απλά λόγια στη εκπαίδευση με εποπτεία υπάρχει ένας δάσκαλος εκτός δικτύου, ο οποίος συνεχώς εκτιμά τη συμπεριφορά του συστήματος και καθοδηγεί όποιες αλλαγές χρειάζονται. Η πιο κοινή τεχνική είναι η διάδοση του σφάλματος προς τα πίσω η οποία θα αναπτυχθεί παρακάτω (backward-error propagation ή back-propagation).

Όταν τελικά το σύστημα εκπαιδευθεί σωστά και δεν απαιτείται καμία περαιτέρω εκμάθηση, τα βάρη μπορούν να "παγώσουν". Σε μερικά συστήματα αυτό το οριστικό δίκτυο μετατρέπεται έπειτα σε υλικό, έτσι ώστε να μπορεί να είναι γρήγορο. Άλλα συστήματα δεν κλειδώνονται αλλά συνεχίζουν να μαθαίνουν ενώ είναι σε χρήση.

2.7 Τα είδη των δεδομένων που δέχονται τα ΤΝΔ

Τα δύο βασικά είδη δεδομένων είναι:

- categorical και
- quantitative

Οι categorical μεταβλητές παίρνουν μόνο έναν πεπερασμένο (τεχνικά, υπολογίσιμο) αριθμό πιθανών τιμών, και υπάρχουν συνήθως αρκετές ή περισσότερες περιπτώσεις που συμπίπτουν σε κάθε κατηγορία. Οι μεταβλητές αυτές μπορούν να έχουν συμβολικές τιμές (π.χ., "αρσενικό" και "θηλυκό", ή "κόκκινο", "πράσινο" και "μπλε") που πρέπει να κωδικοποιηθούν σε αριθμούς προτού δοθούν στο δίκτυο. Η εποπτευμένη εκμάθηση με τις categorical τιμές-στόχων καθώς και η ανεπίβλεπτη εκμάθηση με τις categorical εξόδους, καλούνται "ταξινόμηση-Classification".

Οι ποσοτικές μεταβλητές είναι αριθμητικές μετρήσεις μερικών ιδιοτήτων, όπως το μήκος στους μετρητές. Οι μετρήσεις πρέπει να γίνουν κατά τέτοιο τρόπο ώστε τουλάχιστον μερικές αριθμητικές σχέσεις μεταξύ των μετρήσεων να απεικονίζουν τις αναλογικές σχέσεις μεταξύ των ιδιοτήτων των αντικειμένων που μετριοούνται. Η εποπτευμένη εκμάθηση με τις ποσοτικές τιμές-στόχων καλείται "οπισθοδρόμηση Regression".

Μερικές μεταβλητές μπορούν να αντιμετωπιστούν είτε ως categorical, είτε ως ποσοτικός, όπως ο αριθμός των παιδιών ή οποιαδήποτε δυαδική μεταβλητή. Οι περισσότεροι αλγόριθμοι οπισθοδρόμησης μπορούν επίσης να χρησιμοποιηθούν για την εποπτευμένη ταξινόμηση κωδικοποιώντας τις categorical τιμές-στόχων ως 0/1 δυαδικές μεταβλητές και χρησιμοποιώντας εκείνες τις δυαδικές μεταβλητές σαν τιμές στόχων για τον αλγόριθμο οπισθοδρόμησης. Τα αποτελέσματα του δικτύου είναι μεταγενέστερες πιθανότητες όταν χρησιμοποιούνται οποιεσδήποτε από τις πιο κοινές μεθόδους κατάρτισης.

2.8 Παράδειγμα επεξήγησης της ανωτέρω διαδικασίας διδασκαλίας

Ας υποθέσουμε ότι θέλουμε ένα δίκτυο για να αναγνωρίσουμε τα χειρόγραφα ψηφία. Μπορούμε να χρησιμοποιήσουμε έναν πίνακα π.χ. 256 αισθητήρων, όπου κάθε ένα θα καταγράφει την παρουσία ή την απουσία μελανιού σε μια μικρή περιοχή ενός ψηφίου. Το δίκτυο επομένως θα χρειαζόταν 256 μονάδες εισόδου (μια για κάθε αισθητήρα), 10 μονάδες εξόδου (μια για κάθε είδος ψηφίου) και έναν αριθμό κρυμμένων μονάδων. Για κάθε είδος ψηφίου που καταγράφεται από τους αισθητήρες, το δίκτυο πρέπει να παραγάγει υψηλή δραστηριότητα στην κατάλληλη μονάδα εξόδου και χαμηλή δραστηριότητα στις άλλες μονάδες εξόδου.

Για να εκπαιδύσουμε το δίκτυο, παρουσιάζουμε μια εικόνα ενός ψηφίου και συγκρίνουμε την πραγματική δραστηριότητα των 10 μονάδων εξόδου με την επιθυμητή δραστηριότητα. Υπολογίζουμε έπειτα το σφάλμα, το οποίο ορίζεται ως το τετράγωνο της διαφοράς μεταξύ των πραγματικών και των επιθυμητών εξόδων. Έπειτα αλλάζουμε το βάρος κάθε σύνδεσης ώστε να μειωθεί το σφάλμα, επαναλαμβάνουμε αυτήν την

διαδικασία κατάρτισης για πολλές διαφορετικές εικόνες κάθε είδους ψηφίου έως ότου το δίκτυο ταξινομήσει κάθε εικόνα σωστά.

Για να εφαρμόσουμε αυτή την διαδικασία πρέπει να υπολογίσουμε την παράγωγο του σφάλματος για το βάρος (EW), προκειμένου να αλλαχτεί το βάρος από ένα ποσό που είναι ανάλογο, σε ένα ποσοστό στο οποίο το σφάλμα αλλάζει καθώς αλλάζει το βάρος. Ένας τρόπος να υπολογιστεί το EW είναι να διαταραχτεί ελαφρώς ένα βάρος και να παρατηρηθεί πώς αλλάζει το σφάλμα. Αλλά αυτή η μέθοδος είναι ανεπαρκής επειδή απαιτεί μια χωριστή διαταραχή για κάθε ένα από τα βάρη.

Ένας άλλος τρόπος να υπολογιστεί το EW είναι να χρησιμοποιηθεί ο back-propagation αλγόριθμος που θα περιγραφεί παρακάτω, και έχει γίνει σήμερα ένα από τα σημαντικότερα εργαλεία για τα νευρωνικά δίκτυα κατάρτισης. Αναπτύχθηκε ανεξάρτητα από δύο ομάδες: Fogelman-Soulie, Gallinari και Le Cun στη Γαλλία και Rumelhart, Hinton και Williams στις Η.Π.Α.

2.9 Ταχύτητα-Χρόνος Εκμάθησης

Η ταχύτητα εκμάθησης των ΤΝΔ εξαρτάται από διάφορους ελέγξιμους παράγοντες. Προφανώς, μια πιο αργή ταχύτητα σημαίνει ότι ξοδεύεται πολύ περισσότερος χρόνος στην ολοκλήρωση της εκμάθησης για να παραχθεί ένα επαρκώς εκπαιδευμένο σύστημα. Όμως με μια πιο γρήγορη ταχύτητα εκμάθησης, το δίκτυο μπορεί να μην είναι σε θέση να καταστήσει τις λεπτές διακρίσεις με ένα σύστημα που μαθαίνει πιο αργά.

Πρέπει να εξετάζονται η πολυπλοκότητα των δικτύων, το μέγεθος, η επιλογή παραδείγματος, η αρχιτεκτονική, ο τύπος του κανόνα ή των κανόνων εκμάθησης που χρησιμοποιούνται και η επιθυμητή ακρίβεια. Αυτοί οι παράγοντες διαδραματίζουν έναν σημαντικό ρόλο στον καθορισμό του χρόνου που απαιτείται για την εκπαίδευση ενός νευρωνικού δικτύου. Η αλλαγή οποιουδήποτε από αυτούς τους παράγοντες μπορεί είτε να παρατείνει πολύ το χρόνο κατάρτισης ή ακόμα και να οδηγήσει σε μια μη αποδεκτή ακρίβεια.

Οι περισσότερες λειτουργίες εκμάθησης έχουν κάποιο όρο (provision) για μια ταχύτητα εκμάθησης ή σταθερά εκμάθησης. Συνήθως αυτός ο όρος είναι θετικός και μεταξύ του 0 και 1.

Εάν η ταχύτητα εκμάθησης είναι μεγαλύτερη από 1, είναι εύκολο για τον αλγόριθμο εκμάθησης να υπερβεί τα όρια, στη διόρθωση των βαρών και το δίκτυο να ταλαντευτεί.

Οι μικρές τιμές της ταχύτητας εκμάθησης δεν θα διορθώσουν το παρόν σφάλμα τόσο γρήγορα αλλά εάν κατά τη διόρθωση των σφαλμάτων γίνουν μικρά βήματα, υπάρχει μια καλή πιθανότητα για καλύτερη ελάχιστη σύγκλιση.

2.10 Κανόνες εκμάθησης των ΤΝΔ

Τα περισσότερα ΤΝΔ περιέχουν κάποια μορφή "κανόνα εκμάθησης" που τροποποιεί τα βάρη των συνδέσεων σύμφωνα με τα πρότυπα εισόδου. Από μία άποψη, τα ΤΝΔ μαθαίνουν από τα παραδείγματα, όπως ένας ανθρώπινος εγκέφαλος, ένα παιδί μαθαίνει να αναγνωρίζει τα σκυλιά από τα παραδείγματα σκύλων.

Οι κανόνες εκμάθησης είναι μαθηματικοί αλγόριθμοι που χρησιμοποιούνται για να ανανεώσουν τα βάρη των συνδέσεων. Οι περισσότεροι από αυτούς τους νόμους είναι κάποιο είδος παραλλαγής του πιο γνωστού και παλαιότερου νόμου εκμάθησης, του

κανόνα Hebb. Η ανθρώπινη κατανόηση για το πώς λειτουργεί πραγματικά η επεξεργασία μιας νευρωνικής εργασίας είναι πολύ περιορισμένη. Η έρευνα στις διαφορετικές λειτουργίες εκμάθησης συνεχίζεται καθώς παρουσιάζονται συνεχώς νέες ιδέες. Μερικοί από τους σημαντικότερους κανόνες δίνονται παρακάτω.

Βασικοί κανόνες εκμάθησης

2.11 Hebb's Rule

Εάν ένας νευρώνας λαμβάνει μια είσοδο από έναν άλλο νευρώνα, και εάν και οι δύο είναι ενεργοί (μαθηματικά έχουν το ίδιο πρόσημο), το βάρος μεταξύ των νευρώνων πρέπει να ενισχυθεί.

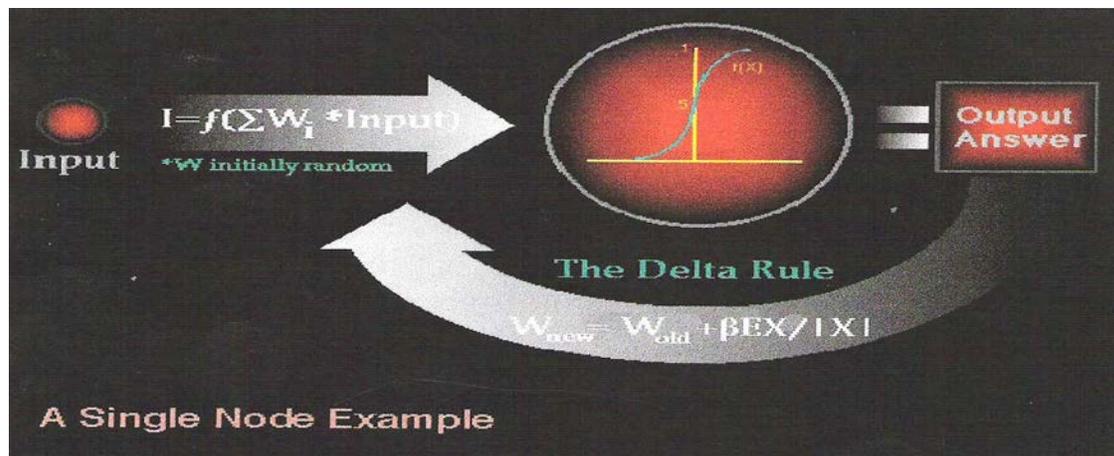
2.12 Hopfield Law

Αυτός ο νόμος είναι παρόμοιος με του Hebb με εξαίρεση ότι προσδιορίζει το μέγεθος της ενίσχυσης ή της αποδυνάμωσης.

Εάν η επιθυμητή έξοδος και είσοδος είναι και οι δύο ενεργές ή ανενεργές, αυξάνουν το βάρος σύνδεσης από το ποσοστό εκμάθησης, διαφορετικά το μειώνουν. (Οι περισσότερες συναρτήσεις εκμάθησης έχουν κάποια παροχή για ένα ποσοστό εκμάθησης ή σταθερά εκμάθησης. Συνήθως αυτός ο όρος είναι θετικός και μεταξύ του 0 και 1)

2.13 Delta Rule

Είναι μια περαιτέρω παραλλαγή του Hebb, και είναι ένας από τους συνηθέστερους κανόνες εκμάθησης. Είναι βασισμένος στην ιδέα της συνεχούς τροποποίησης των δυνάμεων των συνδέσεων εισόδου για να μειώσει έτσι την διαφορά μεταξύ της επιθυμητής αξίας εξόδου και της πραγματικής εξόδου ενός νευρώνα. Αυτός ο κανόνας αλλάζει τα βάρη σύνδεσης με τον ίδιο τρόπο που ελαχιστοποιεί τον μέσο όρο των τετραγώνων των σφαλμάτων του δικτύου. Το σφάλμα μεταδίδεται στα προηγούμενα στρώματα, ένα στρώμα τη φορά. Η διαδικασία συνεχίζεται έως ότου φτάσει στο πρώτο στρώμα. Απλούστερα, όταν παρουσιάζεται αρχικά ένα πρότυπο σε ένα νευρωνικό δίκτυο, αυτό κάνει μια τυχαία "εικασία" ως προς το τι μπορεί να είναι. Έπειτα βλέπει πόσο διαφορετική ήταν η απάντησή του από την πραγματική και προσαρμόζει κατάλληλα τα βάρη στις συνδέσεις του. Η διαδικασία φαίνεται με το παρακάτω γραφικό:



Σχήμα 2. 1: Γραφικό διαδικασίας του Delta Rule

Τα δίκτυα αυτά ονομάζονται Feed-forward δίκτυα και ο back-propagation αντλεί το όνομά του από αυτή την μέθοδο. Αυτός ο κανόνας αναφέρεται επίσης ως κανόνας εκμάθησης Windrow-Hoff Learning Rule και Least Mean Square Learning Rule.

2.14 Kohonen's Learning Law

Αναπτύχθηκε από τον Τευνο Kohonen που εμπνεύστηκε από την εκμάθηση στα βιολογικά συστήματα.

Οι νευρώνες ανταγωνίζονται για την ευκαιρία να μάθουν ή να ανανεώσουν τα βάρη τους. Ο νευρώνας με τη μεγαλύτερη έξοδο δηλώνεται ως ο "νικητής" και έχει την ικανότητα της παρεμπόδισης των "ανταγωνιστών" του καθώς επίσης και της διέγερσης των γειτόνων του. Μόνο στο νικητή επιτρέπεται η έξοδος, και μόνο ο νικητής και οι γείτονές του έχουν την άδεια να ανανεώσουν τα βάρη σύνδεσής τους.

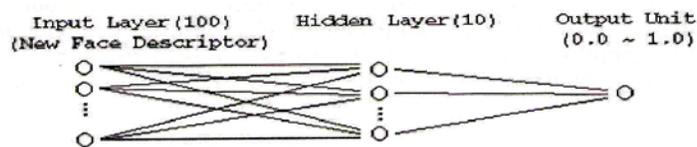
Ο κανόνας Kohonen δεν απαιτεί επιθυμητή έξοδο. Γι' αυτό εφαρμόζεται στις μη εποπτευόμενες μεθόδους. Ο Kohonen χρησιμοποίησε αυτόν τον κανόνα για να δημιουργήσει το self-organizing νευρωνικό δίκτυο, το οποίο έχει μια μη εποπτευόμενη μέθοδο εκμάθησης.

2.15 Gradient Descent Rule (Ο κανόνας καθόδου κλίσης)

Αυτός ο κανόνας είναι παρόμοιος με τον Delta κανόνα δεδομένου ότι η παράγωγος της συνάρτησης μεταφοράς χρησιμοποιείται ακόμα για να τροποποιήσει το σφάλμα του Delta Rule προτού να εφαρμοστεί στα βάρη σύνδεσης. Εδώ, μια πρόσθετη αναλογική σταθερά που σχετίζεται με το ρυθμό εκμάθησης, επισυνάπτεται στον τελικό τροποποιητικό παράγοντα ενεργώντας επάνω στο βάρος. Αυτός ο κανόνας χρησιμοποιείται συνήθως ακόμα κι αν συγκλίνει πολύ αργά σε ένα σημείο σταθερότητας. Έχει αποδειχθεί ότι διαφορετικοί ρυθμοί εκμάθησης για διαφορετικά στρώματα ενός δικτύου, βοηθούν τη διαδικασία εκμάθησης στο να συγκλίνει γρηγορότερα.

2.16 Παράδειγμα εκπαίδευσης δικτύου (για την αναγνώριση προσώπου)

Τα νευρωνικά δίκτυα έχουν μια γενική backpropagation δομή με 3 στρώματα. Το στρώμα εισόδου έχει 100 κόμβους από τους περιγραφείς νέου προσώπου. Το κρυμμένο στρώμα έχει 10 κόμβους. Η μονάδα εξόδου δίνει ένα αποτέλεσμα από 0,0 έως 1,0 λέγοντας κατά πόσο το πρόσωπο εισόδου μπορεί να θεωρηθεί σαν νέος επισκέπτης.



Σχήμα 2. 2: Δομή δικτύου

Προκειμένου να γίνει ευκολότερη η εκπαίδευση ενός νευρωνικού δικτύου, δημιουργείται ένα ΤΝΔ για κάθε πρόσωπο. Κάθε ΤΝΔ αναγνωρίζει εάν το πρόσωπο εισόδου είναι ξένο

για το δίκτυο ή όχι. Ο αλγόριθμος αναγνώρισης επιλέγει το δίκτυο με τη μέγιστη έξοδο. Εάν η έξοδος του επιλεγμένου δικτύου υπερβεί μια προκαθορισμένη ευαισθησία, θα αναφερθεί σαν ξένο πρόσωπο. Διαφορετικά το πρόσωπο εισόδου θα απορριφθεί.

2.17 Διαδικασία εκπαίδευσης

Αφού καθοριστεί η δομή του νευρωνικού δικτύου, το σημαντικότερο πράγμα είναι να προετοιμαστούν τα παραδείγματα εκμάθησής του. Αρχικά, επιλέγουμε διάφορες εικόνες προσώπων από κάθε άτομο με καλά ευθυγραμμισμένη μετωπική όψη. Οποιαδήποτε εικόνα μπορεί να αντιπροσωπεύσει έναν ξένο. Όλα τα πρόσωπα εξάγονται ή αποκόπτονται από τον κώδικα ανίχνευσης προσώπου. Αυτά τα πρόσωπα θα χρησιμοποιηθούν ως θετικά παραδείγματα για τα δίκτυά τους και αρνητικά παραδείγματα για άλλα δίκτυα. Τις περισσότερες φορές ο κώδικας ανίχνευσης προσώπου μπορεί να βρει το πρόσωπο εάν αυτό υπάρχει.

Αφότου δημιουργηθούν τα βασικά ΤΝΔ, τα τρέχουμε πάνω σε νέα πρόσωπα. Εάν η εικόνα αποτύχει να περάσει τη δοκιμή ανίχνευσης προσώπου, θα αγνοηθεί. Εάν ο κώδικας ανίχνευσης προσώπου αναφέρει ένα πρόσωπο στην εικόνα, θα υποβληθεί στον κώδικα αναγνώρισης προσώπου. Ελέγχουμε το αποτέλεσμα αναγνώρισης για να βρούμε περισσότερα πρόσωπα για την κατάρτιση του δικτύου. Εδώ κάθε πρόσωπο θα πέσει σε μια από τις εξής τέσσερις κατηγορίες:

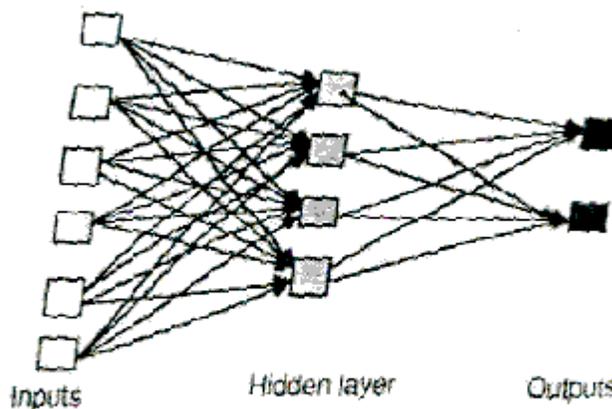
- Τα πρόσωπα έχουν υψηλή έξοδο στα δίκτυά τους και χαμηλή έξοδο σε άλλα δίκτυα. Καμία ενέργεια εδώ.
- Τα πρόσωπα έχουν υψηλή έξοδο και στα δίκτυά τους και σε μερικά άλλα δίκτυα. Αυτά τα πρόσωπα θα χρησιμοποιηθούν ως αρνητικά παραδείγματα για άλλα δίκτυα.
- Τα πρόσωπα υποβάλλονται σε καλά ευθυγραμμισμένη μετωπική όψη και αντιπροσωπεύουν τους ξένους τους. Έχουν χαμηλή έξοδο στα δίκτυά τους. Αυτά τα πρόσωπα θα χρησιμοποιηθούν ως θετικά παραδείγματα για τα δίκτυά τους και ως αρνητικά παραδείγματα για άλλα δίκτυα.
- Τα πρόσωπα δεν αποκόβονται καλά και δεν μπορούν να αντιπροσωπεύσουν τους ξένους τους. Έχουν χαμηλή έξοδο στα δίκτυά τους. Εάν έχουν υψηλή έξοδο σε μερικά άλλα δίκτυα, θα περιληφθούν ως αρνητικά παραδείγματα για άλλα δίκτυα. Διαφορετικά θα αγνοηθούν.

Μόλις πάρουμε αυτά τα νέα πρόσωπα, τα προσθέτουμε στα παραδείγματα κατάρτισης και επανεκπαιδεύουμε τα νευρωνικά δίκτυα. Τα σφάλματα αναγνώρισης θα διορθωθούν και η συνολική απόδοση θα βελτιωθεί. Προσθέτοντας μερικά παραδείγματα ακόμα θα βελτιωθεί η απόδοση του δικτύου και θα επηρεαστεί επίσης και η απόδοση άλλων δικτύων. Η διαδικασία εκμάθησης ενός δικτύου συνεχίζεται έως ότου δεν βρεθεί κανένα σημαντικό σφάλμα αναγνώρισης.

2.18 Feed Forward και Feedback νευρωνικά δίκτυα

Η πιο γνωστή μορφή ενός νευρωνικού δικτύου είναι αυτή των τριών στρωμάτων με την ονομασία "feed forward" ή "non recurrent" (μη επαναλαμβανόμενα) δίκτυα, τα οποία είναι τα δίκτυα που δεν έχουν συνδέσεις επανατροφοδοσίας (feedback), δηλαδή συνδέσεις μέσω βαρών που ξεκινούν από την έξοδο ενός στρώματος και καταλήγουν στην είσοδο του ίδιου ή ενός άλλου προηγούμενου στρώματος. Το πρώτο στρώμα λαμβάνει τα εισερχόμενα σήματα και τα κατανέμει στο δεύτερο στρώμα. Το δεύτερο στρώμα ονομάζεται κρυφό στρώμα (hidden layer), επειδή δεν διαθέτει συνδέσεις προς τα έξω. Το τρίτο στρώμα εξόδου παραδίδει τα αποτελέσματα στον εξωτερικό κόσμο.

Τα Feed-forward νευρωνικά δίκτυα επιτρέπουν τη διέλευση σημάτων μόνο προς μία κατεύθυνση, από την είσοδο στην έξοδο, δηλ. όλα τα σήματα προωθούνται μόνον από το πρώτο στρώμα και δεν υπάρχουν αναδράσεις (από εκεί προέρχεται και η ονομασία τους). Δεν υπάρχουν προς τα πίσω loops και έτσι η έξοδος οποιουδήποτε στρώματος δεν επηρεάζει το ίδιο το στρώμα. Γι' αυτό και τα Feed-forward ΤΝΔ παράγουν γρήγορα μια έξοδο σε κάποια είσοδο. Τα Feed-forward δίκτυα δεν έχουν μνήμη, έτσι η έξοδος τους καθορίζεται πάντα από την παρούσα είσοδο και από τις τιμές των βαρών. Χρησιμοποιούνται κυρίως στην αναγνώριση προτύπου (pattern recognition).

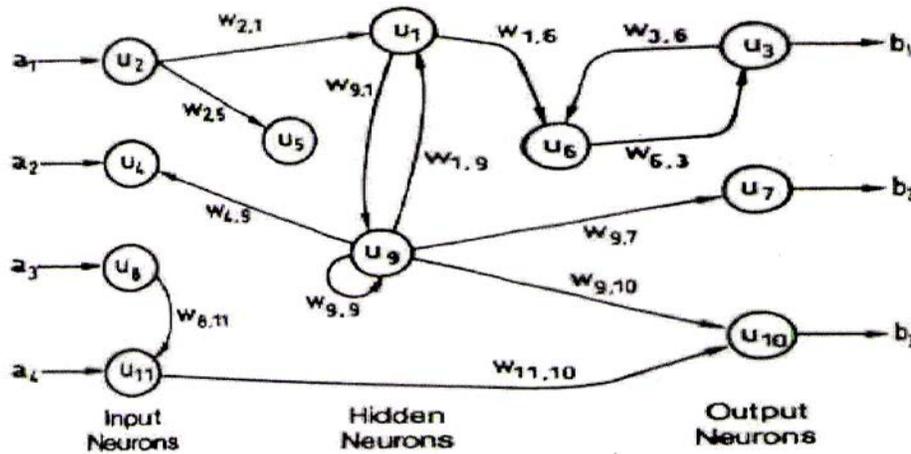


Σχήμα 2.3: Feed-forward νευρωνικό δίκτυο

2.19 Feedback νευρωνικά δίκτυα

Στα Feedback νευρωνικά δίκτυα επιτρέπεται εντός του δικτύου η προώθηση σημάτων και προς τα πίσω, δηλ. έχουμε αμφίδρομη διέλευση σημάτων με loops. Είναι πολύ δυναμικά και σε πολλές περιπτώσεις μπορεί να είναι πολύπλοκα. Η κατάσταση τους αλλάζει συνεχώς έως ότου να φτάσουν σε ένα σημείο ηρεμίας. Παραμένουν σ' αυτό το σημείο έως ότου αλλάξει η είσοδος. Σε κάποια Feedback ΤΝΔ κάθε φορά που τίθεται μια είσοδος, το δίκτυο πρέπει να κάνει πολλές επαναλήψεις προτού παράγει μια έξοδο. Γι' αυτό, τα δίκτυα που περιλαμβάνουν feedback συνδέσεις, λέγεται ότι επαναλαμβάνονται.

Η Feedback αρχιτεκτονική αναφέρεται συχνά και ως interactive ή recurrent (επαναλαμβανόμενη).

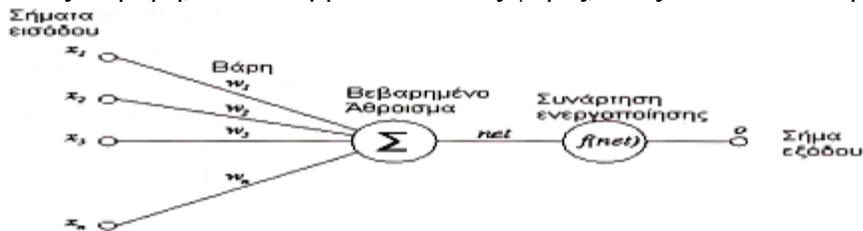


Σχήμα 2. 4: Feedback νευρωνικό δίκτυο

Τα Feedback ΤΝΔ είναι συνήθως πιο δύσκολο να εκπαιδευτούν από ότι τα Feed-forward ΤΝΔ. Μερικά είδη νευρωνικών δικτύων μπορεί να εφαρμόζονται και ως Feed-forward και ως Feedback.

Με τον τρόπο αυτό δημιουργείται μεταξύ των νευρωνίων εισόδου και εξόδου μια πολυδιάστατη συνάρτηση μεταφοράς, η πολυπλοκότητα της οποίας εξαρτάται από το πλήθος των νευρωνίων. Προκειμένου να διδαχθεί το δίκτυο ώστε να έχει μια καθορισμένη συνάρτηση μεταφοράς, πρέπει αυτό να εξασκηθεί με συγκεκριμένο αλγόριθμο διδασκαλίας. Στόχος του αλγόριθμου διδασκαλίας είναι η ρύθμιση των τιμών που θα πάρουν τα βάρη. Ο κανόνας της διδασκαλίας φροντίζει ώστε κατά τη διάρκεια της εξάσκησης (προπόνησης), τα βάρη να λάβουν σταδιακά τις κατάλληλες και λογικές τιμές. Η ίδια αντιστοιχία υπάρχει και στη συμπεριφορά μάθησης των ανθρώπων. Αν ένα παιδί διδάσκεται, στην αρχή κάνει πολλά λάθη, τα οποία σταδιακά μειώνονται.

Σαν παράδειγμα, ας υποθέσουμε ότι πρέπει να διδαχθεί σε ένα δίκτυο η συνάρτηση μεταφοράς μιας επεξεργασίας. Το νευρωνικό δίκτυο παράγει κάθε φορά σήματα εξόδου αποκρινόμενα στα σήματα εισόδου. Αρχικά, παρουσιάζουμε στο δίκτυο μερικά σήματα εισόδου και προσδοκώμενα πραγματικά σήματα εξόδου. Σχηματίζουμε τη διαφορά (δηλαδή το σφάλμα) μεταξύ του σήματος εξόδου και του αναμενόμενου σήματος εξόδου. Στη συνέχεια, αλλάζουμε τα βάρη όλων των συνδέσεων με τέτοιο τρόπο ώστε το σφάλμα αυτό να μειωθεί. Με τον τρόπο αυτό παρουσιάζει η έξοδος του δικτύου μια ακόμη πιο βελτιωμένη προσέγγιση στο αναμενόμενο αποτέλεσμα. Η διαδικασία της εξάσκησης αλλάζοντας τα βάρη, επαναλαμβάνεται τόσες φορές, όσες απαιτούνται προκειμένου να



Σχήμα 2.5: Σχηματική παράσταση ενός τεχνητού νευρωνίου.

γίνει το σφάλμα μηδέν ή να μη ξεπερνά ένα συγκεκριμένο κατώφλι.

Από τα σήματα εισόδου X_i σχηματίζεται το βεβαρημένο άθροισμα net . Από το άθροισμα αυτό, σχηματίζεται στη συνέχεια από τη συνάρτηση ενεργοποίησης $f(net)$ η τιμή της εξόδου o .

Σήματα εισόδου x_i

Τα δεδομένα αυτά μπορούν να είναι οι αρχικές εισοδοί, ή να προέρχονται από την έξοδο ενός άλλου τεχνητού νευρωνίου. Διάφορα μοντέλα δίδουν διαφορετικές τιμές σε αυτά. Τυπικές τιμές είναι πραγματικοί αριθμοί, το διάστημα $[0,1]$ ή οι απόλυτες τιμές 0 και 1.

Βάρη W_i

Σε κάθε σύνδεση σε ένα νευρωνικό δίκτυο αντιστοιχεί ένας πραγματικός αριθμός σαν βάρος. Το βάρος παριστάνει τη ισχύ της σύνδεσης. Σε αυτά τα βάρη είναι αποθηκευμένη η γνώση των νευρωνικών δικτύων.

Netto-Είσοδος net

Η Netto-είσοδος αντιστοιχεί στο άθροισμα των βεβαρημένων σημάτων εισόδου

$$net = \sum_i W_i X_i$$

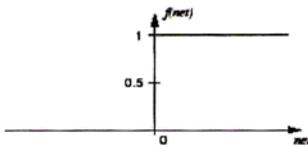
Συνάρτηση δραστηριοποίησης $f(net)$

Η συνάρτηση δραστηριοποίησης καθορίζει την έξοδο o του νευρωνίου που εξαρτάται από την Netto-είσοδο. Η έξοδος o μπορεί να είναι έξοδος του νευρωνικού δικτύου ή σήμα εισόδου για ένα άλλο νευρωνικό δίκτυο. Σαν συναρτήσεις δραστηριοποίησης χρησιμοποιούνται κυρίως οι πιο κάτω:

Συνάρτηση βηματική :

$$f(net) = \begin{cases} 0 & : net < 0 \\ 1 & : net \geq 0 \end{cases}$$

Μαθηματική παράσταση βηματικής συνάρτησης:

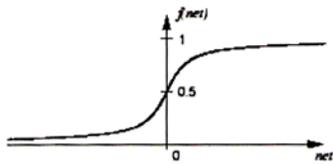


Σχήμα 2.6: Γραφική παράσταση βηματικής συνάρτησης σαν συνάρτηση δραστηριοποίησης

Συνάρτηση Sigmoide

Μαθηματική παράσταση συνάρτησης Sigmoide:

$$f(\text{net}) = 1 / (1 + e^{-\text{net}})$$



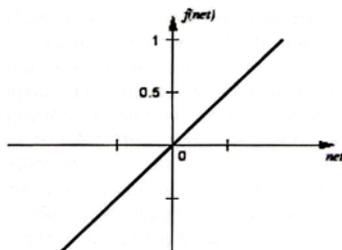
Σχήμα 2. 7: Γραφική παράσταση της συνάρτησης Sigmoide σαν συνάρτηση ενεργοποίησης.

Η διαφορά μεταξύ της βηματικής και της Sigmoide συνάρτησης, βρίσκεται στο συνεχόμενο σήμα εξόδου της Sigmoide το οποίο μπορεί να διαφορισθεί.

Γραμμική συνάρτηση

Μαθηματική παράσταση της γραμμικής συνάρτησης:

$$f(\text{net}) = \text{net}$$



Σχήμα 2. 8: Γραφική παράσταση της γραμμικής συνάρτησης σαν συνάρτηση δραστηριοποίησης.

Η γραμμική συνάρτηση είναι η απλούστατη και λιγότερο χρησιμοποιούμενη. Τοποθετώντας στρώματα από νευρώνια γραμμικής συνάρτησης σχηματίζουν την ίδια μορφή συνάρτησης όπως ένα μοναδικό νευρόνιο, επειδή η διαδοχική χρησιμοποίηση γραμμικών συναρτήσεων πάλι είναι γραμμική.

Επιπρόσθετα των ιδιοτήτων των νευρωνίων, καθορίζονται οι ιδιότητες και η ορολογία νευρωνικών δικτύων.

2.20 Αλγόριθμος μάθησης

Πρόκειται για εκείνον τον αλγόριθμο με τον οποίο το δίκτυο εξασκείται για τη μελλοντική εργασία του. Σαν βασικός τέτοιος αλγόριθμος μάθησης των νευρωνικών δικτύων είναι ο Backpropagation που περιγράφεται πιο κάτω.

2.21 Ο Backpropagation αλγόριθμος

Στον αλγόριθμο 'Backpropagation', το σφάλμα από το στρώμα εξόδου μεταφέρεται πίσω στα προηγούμενα στρώματα φθάνοντας μέχρι το στρώμα εισόδου. Από τη μεθοδολογία προέρχεται και η ονομασία «πρόβλεψη προς τα πίσω». Ταυτόχρονα τα βάρη προσαρμόζονται σε όλα τα στρώματα. Αυτή η μέθοδος διδασκαλίας ανήκει στην υπό επίβλεψη μάθηση "supervised learning", επειδή κατά τη διδασκαλία δείχνεται η επιθυμητή αντίδραση.

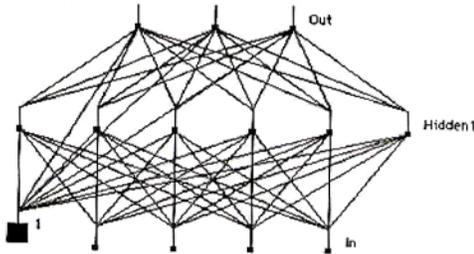
2.22 Περιγραφή του Back Propagation Algorithm

Για να εκπαιδύσουμε ένα ΝΔ για να εκτελέσει κάποια στοιχειώδη εργασία, πρέπει να ρυθμίσουμε τα βάρη κάθε μονάδας κατά τέτοιο τρόπο ώστε το σφάλμα μεταξύ της επιθυμητής εξόδου και της πραγματικής εξόδου να μειωθεί. Αυτή η διαδικασία απαιτεί από το νευρωνικό δίκτυο να υπολογίζει την παράγωγο του σφάλματος των βαρών (EW). Με άλλα λόγια, πρέπει να υπολογίσει πώς το σφάλμα αλλάζει καθώς τα βάρη αυξάνονται ή μειώνονται ελαφρώς. Ο αλγόριθμος αυτός είναι η ευρύτερη χρησιμοποιούμενη μέθοδος για τον προσδιορισμό του EW (του σφάλματος των βαρών). Του είναι εύκολο να καταλάβει εάν όλες οι μονάδες στο δίκτυο είναι γραμμικές. Ο αλγόριθμος υπολογίζει κάθε EW, με πρώτο το EA.(διαφορά μεταξύ πραγματικής εξόδου και επιθυμητής). Για τις μονάδες εξόδου, το EA είναι απλά η διαφορά μεταξύ της πραγματικής και επιθυμητής εξόδου. Για να υπολογίσουμε EA για μια κρυμμένη μονάδα στο στρώμα αμέσως πριν από το στρώμα εξόδου, προσδιορίζουμε αρχικά όλα τα βάρη μεταξύ εκείνης της κρυμμένης μονάδας και των μονάδων εξόδου με τις οποίες συνδέεται. Πολλαπλασιάζουμε έπειτα εκείνα τα βάρη με το EA εκείνων των μονάδων εξόδου και προσθέτουμε τα αποτελέσματα.

Αυτό το άθροισμα ισούται με το EA για την επιλεγμένη κρυμμένη μονάδα. Μετά από τον υπολογισμό όλων των EA στο κρυμμένο στρώμα, αμέσως πριν από το στρώμα εξόδου, μπορούμε να υπολογίσουμε τα EA για άλλα στρώματα, μετακινούμενοι από στρώμα σε στρώμα με μια κατεύθυνση αντίθετη από τον τρόπο με τον οποίο οι δραστηριότητες διαδίδονται μέσω του δικτύου. Μόλις υπολογιστεί το EA για μια μονάδα τότε είναι απλό να υπολογιστεί το EW για κάθε εισερχόμενη σύνδεση της μονάδας. Το EW προκύπτει από το EA και την δραστηριότητα back-propagating της εισερχόμενης σύνδεσης. Για τις μη γραμμικές μονάδες, ο back-propagation αλγόριθμος περιλαμβάνει κάτι επιπλέον. Πριν ξεκινήσει ο back-propagation αλγόριθμος, το EA πρέπει να μετατραπεί σε EI, το ποσοστό στο οποίο οι αλλαγές σφάλματος καθώς και η συνολική είσοδος που παραλαμβάνεται από μια μονάδα αλλάζει.

Στο παρακάτω σχήμα έχουμε ένα νευρωνικό δίκτυο πολλαπλών στρωμάτων Multilayer Perceptron (MLP). Το σήμα εισόδου εφαρμόζεται στο στρώμα εισόδου (input layer). Στη συνέχεια ακολουθεί ένα ή περισσότερα στρώματα (hidden layer). Στο τέλος του δικτύου έχουμε το στρώμα εξόδου (output layer). Το κάθε νευρώνιο ενός στρώματος συνδέεται με τις εξόδους όλων των νευρωνίων που βρίσκονται πριν από αυτό. Δεν υπάρχει περιορισμός ή μεθοδολογία ως προς το πλήθος των στρωμάτων που χρησιμοποιούνται. Το τυπικό back-propagation δίκτυο έχει ένα στρώμα εισόδου, ένα στρώμα εξόδου και ένα τουλάχιστον κρυμμένο στρώμα. Ένα νευρωνικό δίκτυο με ένα μόνον εσωτερικό στρώμα περιγράφεται σαν νευρωνικό δίκτυο 2 στρωμάτων. Κάθε στρώμα συνδέεται

πλήρως με το επόμενο στρώμα, όπως φαίνεται στο Σχήμα 2.9.



Σχήμα 2. 9: Feedforward Back-Propagation Δίκτυο

Τα εσωτερικά και εξωτερικά στρώματα δείχνουν τη ροή των πληροφοριών κατά τη διάρκεια της ανάκλησης. Η ανάκληση είναι η διαδικασία κατά την οποία εισάγονται δεδομένα εισόδου σε ένα εκπαιδευμένο δίκτυο και λαμβάνεται κάποια απάντηση (έξοδος). Ο Back-propagation δεν χρησιμοποιείται κατά τη διάρκεια της ανάκλησης, αλλά μόνο κατά τη διάρκεια κατάρτισης του δικτύου.



Ο αριθμός στρωμάτων και ο αριθμός δεδομένων επεξεργασίας ανά στρώμα είναι σημαντικές παράμετροι. Αυτές οι παράμετροι σε μια feedforward, back-propagation τοπολογία είναι επίσης εξιδανικευμένες. Δεν υπάρχει κάποια καλύτερη απάντηση στο σχεδιάγραμμα ενός δικτύου για κάποια συγκεκριμένη εφαρμογή. Υπάρχουν μόνο γενικοί κανόνες που ακολουθούνται από τους περισσότερους ερευνητές και μηχανικούς που εφαρμόζουν αυτήν την αρχιτεκτονική.

1^{ος} Κανόνας:

Καθώς αυξάνεται η πολυπλοκότητα στη σχέση μεταξύ των δεδομένων εισόδου και των επιθυμητών εξόδων, ο αριθμός των δεδομένων επεξεργασίας στο κρυμμένο στρώμα

πρέπει επίσης να αυξηθεί.

2^{ος} Κανόνας:

Εάν η διαδικασία που διαμορφώνεται είναι διαχωρισμένη σε πολλαπλά στάδια, τότε το πρόσθετο κρυμμένο στρώμα (στρώματα) μπορεί να είναι απαραίτητο. Εάν η διαδικασία δεν είναι διαχωρισμένη σε στάδια, τότε τα πρόσθετα στρώματα μπορούν απλά να επιτρέψουν την αποστήθιση και όχι μια πραγματική γενική λύση.

3^{ος} Κανόνας:

Ο αριθμός των δεδομένων επεξεργασίας στα κρυμμένα στρώματα εξαρτάται από τον αριθμό των διαθέσιμων στοιχείων εκμάθησης. Για να υπολογίσουμε αυτόν τον αριθμό, χρησιμοποιούμε τον αριθμό παραδειγμάτων ζευγαριού εξόδου-εισόδου στο σύνολο κατάρτισης και διαιρούμε αυτό τον αριθμό με το συνολικό αριθμό των δεδομένων επεξεργασίας εισόδου και εξόδου στο δίκτυο. Κατόπιν διαιρούμε το αποτέλεσμα πάλι με έναν παράγοντα διαβάθμισης (scaling factor) μεταξύ 5 και 10. Οι μεγαλύτεροι παράγοντες χρησιμοποιούνται για τα σχετικά θορυβώδη δεδομένα. Τα εξαιρετικά θορυβώδη μπορούν να απαιτήσουν έναν παράγοντα 20 ή ακόμα και 50, ενώ τα πολύ καθαρά δεδομένα εισόδου με μια ακριβή σχέση στην έξοδο, μπορούν να μειώσουν τον παράγοντα περίπου στο 2. Είναι σημαντικό ότι τα κρυμμένα στρώματα έχουν λίγα δεδομένα επεξεργασίας. Πάρα πολλοί τεχνητοί νευρώνες και το σύνολο κατάρτισης θα απομνημονευθούν. Εάν αυτό συμβεί τότε **δεν θα εμφανιστεί καμία γενίκευση των τάσεων των στοιχείων, καθιστώντας το δίκτυο άχρηστο στα νέα σύνολα στοιχείων.**

Μόλις οι ανωτέρω κανόνες έχουν χρησιμοποιηθεί για να δημιουργηθεί ένα δίκτυο, αρχίζει η διαδικασία της διδασκαλίας του. Αυτή η διαδικασία για ένα feedforward δίκτυο χρησιμοποιεί κανονικά κάποια παραλλαγή του Delta Rule, ο οποίος αρχίζει με τον υπολογισμό της διαφοράς μεταξύ των πραγματικών αποτελεσμάτων και των επιθυμητών αποτελεσμάτων.

Το σύνθετο μέρος αυτού του μηχανισμού εκμάθησης είναι το σύστημα να καθορίσει ποια είσοδος συνέβαλε πιο πολύ σε μια ανακριβή έξοδο και πώς αλλάζει το δεδομένο προκειμένου να διορθωθεί το σφάλμα. Ένας ανενεργός κόμβος δεν συμβάλλει στο σφάλμα και δεν χρειάζεται να αλλάξει τα βάρη του.

Για να λυθεί αυτό το πρόβλημα, οι είσοδοι κατάρτισης εφαρμόζονται στο στρώμα εισόδου του δικτύου, και τα επιθυμητά αποτελέσματα συγκρίνονται στο στρώμα εξόδου. Κατά τη διάρκεια της διαδικασίας εκμάθησης, γίνεται ένα προς τα εμπρός «πέρασμα» μέσω του δικτύου και η έξοδος κάθε δεδομένου υπολογίζεται από στρώμα σε στρώμα. Η διαφορά μεταξύ της εξόδου του τελικού στρώματος και της επιθυμητής εξόδου διαδίδεται προς τα πίσω στο προηγούμενο στρώμα (στρώματα), μέχρι και το αρχικό, και αρχίζουν να προσαρμόζονται ομαλά τα βάρη των συνδέσεων με τη χρήση του Delta Rule.

Υπάρχουν πολλές παραλλαγές στους κανόνες εκμάθησης για back-propagation δίκτυο. Μπορούν να χρησιμοποιηθούν διαφορετικές συναρτήσεις σφάλματος, ακόμη και η μέθοδος τροποποίησης της παραγώγου της συνάρτησης μεταφοράς. Η έννοια του «momentum error-σφάλμα ορμής», εισήχθη για να επιτρέψει τη γρηγορότερη εκμάθηση ελαχιστοποιώντας την ασταθή συμπεριφορά. Εδώ η συνάρτηση σφάλματος, ή η delta weight equation (εξίσωση), τροποποιείται έτσι ώστε ένα μέρος του προηγούμενου delta weight να τροφοδοτείται κατευθείαν στο παρόν delta weight. Αυτό ενεργεί, σε όρους εφαρμοσμένης μηχανικής, ως χαμηλής διέλευσης φίλτρο στους delta weight terms,

δεδομένου ότι γενικές τάσεις ενισχύονται ενώ η συμπεριφορά ταλαντώσεων ακυρώνεται. Αυτό επιτρέπει ένα χαμηλό, φυσιολογικά πιο αργό, συντελεστή εκμάθησης για να χρησιμοποιηθεί, αλλά δημιουργεί πιο σύντομη εκμάθηση.

Μια άλλη τεχνική που έχει επίδραση στην ταχύτητα σύγκλισης είναι να ενημερωθούν μόνο τα βάρη μετά την παρουσίαση στο δίκτυο πολλών ζευγαριών εισόδων-επιθυμητών εξόδων, παρά μετά από κάθε παρουσίαση. Αυτό αναφέρεται ως cumulative back-propagation (συσσωρευτικός back propagation) επειδή τα delta weights δεν συσσωρεύονται έως ότου παρουσιαστεί το πλήρες σύνολο ζευγαριών. Ο αριθμός των ζευγαριών εισόδου-εξόδου που παρουσιάζονται κατά τη διάρκεια της συσσώρευσης αναφέρεται ως "epoch" το οποίο μπορεί να αντιστοιχεί είτε στο πλήρες σύνολο ζευγαριών κατάρτισης, είτε σε ένα υποσύνολο.

Υπάρχουν κάποιοι περιορισμοί στην feedforward, back-propagation αρχιτεκτονική:

- Η Back-propagation απαιτεί εποπτευόμενη εκμάθηση, με πολλά παραδείγματα εισόδων-εξόδων.
- Επιπλέον, οι εσωτερικές διαδικασίες χαρτογράφησης δεν είναι εύκολα κατανοητές και δεν υπάρχει καμία εγγύηση ότι το σύστημα θα συγκλίνει σε μια αποδεκτή λύση.
- Κατά περιόδους, η εκμάθηση μένει κολλημένη σε ένα τοπικό ελάχιστο, περιορίζοντας μια καλύτερη λύση. Αυτό προκύπτει όταν τα συστήματα δικτύων βρίσκουν ένα σφάλμα που είναι μικρότερο από τις περιβάλλουσες δυνατότητες αλλά δεν φτάνει τελικά στο μικρότερο πιθανό σφάλμα.

Τυπικά οι feedforward, back-propagation εφαρμογές περιλαμβάνουν τη σύνθεση λόγου από ένα κείμενο, τα όπλα ρομπότ, την αξιολόγηση των τραπεζικών δανείων, την επεξεργασία εικόνας, την αντιπροσώπευση γνώσης, τη γενική πρόβλεψη και την πρόβλεψη καιρού.

Ο αλγόριθμος Backpropagation λειτουργεί σε δύο βήματα:

Κατά το βήμα προώθησης προς τα εμπρός (Feedforward), τοποθετείται στην είσοδο ένα δείγμα ελέγχου και υπολογίζεται η έξοδος. Από την προκύπτουσα έξοδο και την επιθυμητή έξοδο υπολογίζεται το σφάλμα με τη βοήθεια της συνάρτησης σφάλματος. Το σφάλμα αυτό, κατά το βήμα της διάδοσης προς τα πίσω (Backpropagation) ξεκινώντας με το στρώμα εξόδου, μοιράζεται στα βάρη των στρωμάτων και τροποποιείται έτσι ώστε να μειώνεται κάθε φορά. Το σφάλμα υπολογίζεται από την τετραγωνική συνάρτηση σφάλματος E:

$$\tilde{E} = \sum (t-o)^2$$

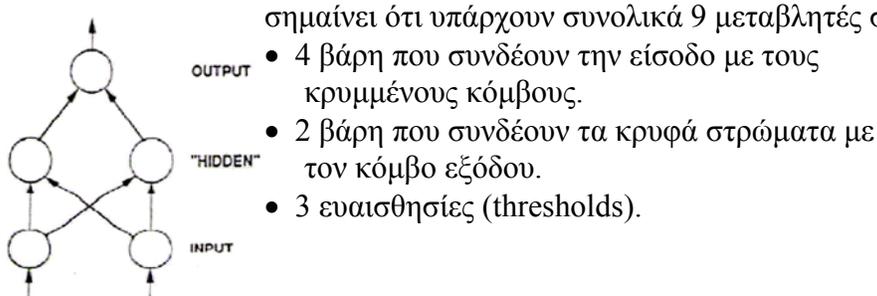
όπου:

o : Η πραγματική έξοδος του νευρωνίου του στρώματος εξόδου.

t : Η επιθυμητή έξοδος του νευρωνίου για το ορθό αποτέλεσμα.

Ο αλγόριθμος Backpropagation ψάχνει το ελάχιστο της συνάρτησης σφάλματος ενός συγκεκριμένου προβλήματος μάθησης, με τη βοήθεια της διεύθυνσης κλίσης κατά μήκος της συνάρτησης σφάλματος. Ο συνδυασμός των βαρών ενός δικτύου ο οποίος ελαχιστοποιεί το υπολογιζόμενο σφάλμα θεωρείται λύση του προβλήματος μάθησης.

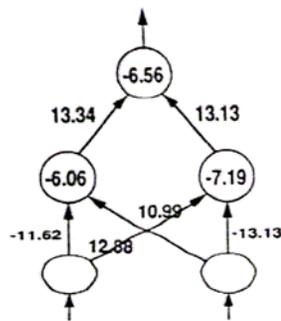
Η βασική αρχιτεκτονική για αυτό το πρόβλημα έχει δύο κόμβους εισόδου, δύο κρυμμένους κόμβους και έναν ενιαίο κόμβο εξόδου όπως φαίνεται δίπλα. Αυτή η δομή έχει μεταβλητές ευαισθησίας στα δύο κρυμμένα στρώματα και έναν κόμβο εξόδου. Αυτό



Σχήμα 2. 10

2.23 Ένα Back-Propagation παράδειγμα δικτύων

Σε αυτό το παράδειγμα, ένα back-propagation δίκτυο χρησιμοποιείται για να λύσει ένα συγκεκριμένο πρόβλημα, αυτό μιας πύλης XOR. Αυτό σημαίνει ότι τα πρότυπα εισόδου (0,0) ή (1,1) πρέπει να παραγάγουν μια αξία κοντά στο 0 στον κόμβο εξόδου, και τα πρότυπα εισόδου (1,0) ή (0,1) πρέπει να παραγάγουν μια αξία κοντά στο 1 στον κόμβο εξόδου. Έστω ότι υποβάλλουμε ένα πρότυπο, για παράδειγμα (0.1). Δηλαδή 0 στον αριστερό νευρώνα του πρώτου στρώματος και 1 στον δεξιό νευρώνα.



Results for Input Patterns:

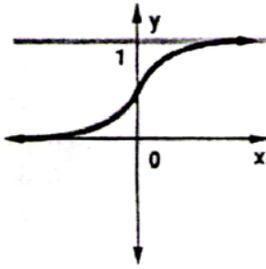
INPUT	OUTPUT
(0, 0)	0.057
(1, 0)	0.949
(0, 1)	0.946
(1, 1)	0.052

Η εύρεση ενός συνόλου βαρών σύνδεσης για αυτήν την στοιχειώδη εργασία δεν είναι εύκολη. Απαιτείται η εφαρμογή του back-propagation αλγορίθμου για αρκετές χιλιάδες επαναλήψεις ώστε να επιτευχθεί ένα καλό σύνολο βαρών σύνδεσης και ευαισθησιών νευρώνων.

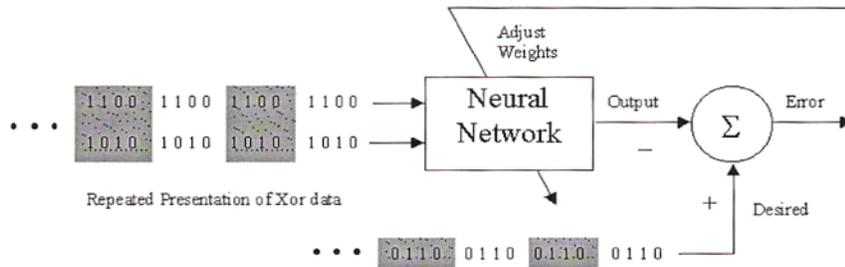
Τώρα κινούμε την προσοχή μας προς το επόμενο στρώμα επάνω. Για κάθε νευρώνα σε αυτό το στρώμα, υπολογίζουμε μια είσοδο που είναι το άθροισμα βαρών όλων των ενεργοποιήσεων από το πρώτο στρώμα. Το άθροισμα αυτό επιτυγχάνεται από το διάνυσμα που πολλαπλασιάζει τις ενεργοποιήσεις στο πρώτο στρώμα με

για "μήτρα" σύνδεσης.

Στην περίπτωση μας παίρνουμε μια τιμή $0 * (-11,62) + 1 * (10,99) = 10,99$ για το νευρώνα στα αριστερά στο δεύτερο στρώμα και $0 * (12,88) + 1 * (13,13) = 13,13$ για το νευρώνα στα δεξιά. Αυτά δεν είναι η ενεργοποίηση αυτών των νευρώνων. Για να επιτύχουμε τις ενεργοποιήσεις, προσθέτουμε μια τιμή "ευαισθησίας" (που βρίσκεται για κάθε νευρώνα χρησιμοποιώντας το back-propagation κανόνα), και εφαρμόζουμε μια συνάρτηση μεταφοράς εισόδου-εξόδου. Η συνάρτηση μεταφοράς καθορίζεται για κάθε διαφορετικό δίκτυο. Στην περίπτωση μας είναι η sigmoid:



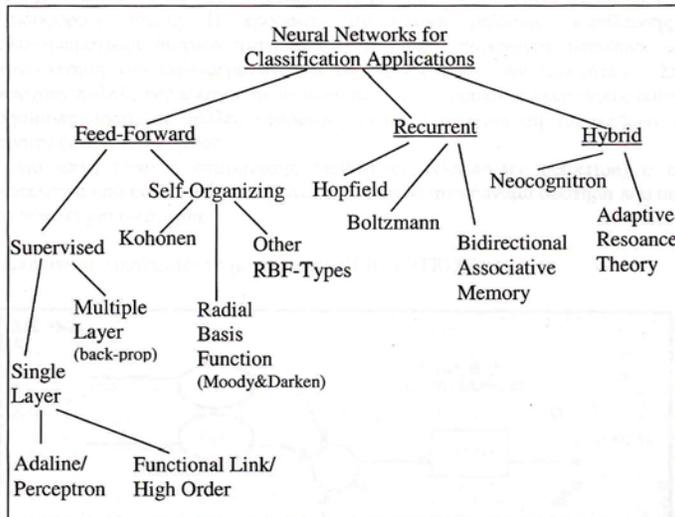
Σχήμα 2.12 : Συνάρτηση Sigmoid



Σχήμα 2. 13: Νευρωνικό δίκτυο που μαθαίνει να διαμορφώνει exclusive-or (XOR) Δεδομένα.

Τα δεδομένα αυτά παρουσιάζονται επανειλημμένα στο νευρωνικό δίκτυο. Με κάθε παρουσίαση, υπολογίζεται το σφάλμα μεταξύ της εξόδου του δικτύου και της επιθυμητής εξόδου και ανατροφοδοτείται στο νευρωνικό δίκτυο. Το νευρωνικό δίκτυο χρησιμοποιεί αυτό το σφάλμα για να ρυθμίσει τα βάρη του, έτσι ώστε το σφάλμα να μειωθεί. Αυτή η ακολουθία γεγονότων επαναλαμβάνεται συνήθως έως ότου να επιτευχθεί ένα αποδεκτό σφάλμα ή έως ότου το δίκτυο παύει να μαθαίνει.

3.1 Ταξινόμηση Δικτύων



Σχήμα 3. 1

3.2 Τα πιο Δημοφιλή Μοντέλα

3.3 Perceptron (Νοήμονος Αισθητήρας)

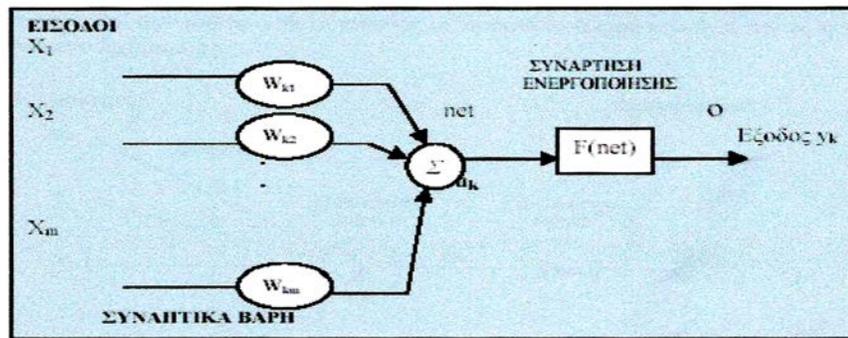
Ένα από τα πρώτα μοντέλα νευρωνικών δικτύων που αναπτύχθηκαν είναι το Perceptron. Ο τύπος αυτός προτάθηκε από τον Rosenblatt στα μέσα της δεκαετίας του '50 για να εξηγήσει την αναγνώριση προτύπων από το οπτικό σύστημα και θεωρήθηκε ως ένα λειτουργικό μοντέλο του αμφιβληστροειδή. Ο Widrow* έκανε ένα σημαντικό αριθμό από παρουσιάσεις συστημάτων παρόμοιων με τα perceptron και έτσι ερευνητές από όλον τον κόσμο πρόθυμα άρχισαν να εξερευνούν τις δυνατότητες αυτών των συστημάτων. Η αρχική χαρά αντικαταστάθηκε από απογοήτευση όταν τα perceptron βρέθηκαν να αποτυγχάνουν σε ορισμένα απλά παραδείγματα εκπαίδευσης. Ο βασικός περιορισμός του perceptron είναι η αδυναμία ταξινόμησης μη γραμμικά διαχωρίσιμων εισόδων. Δηλαδή για να ταξινομηθούν σωστά όλα τα διανύσματα που ανήκουν στον υπερχώρο των διανυσμάτων εισόδου και που ανήκουν στον υπερχώρο σε κάποια κατηγορία ταξινόμησης, πρέπει να βρίσκονται στην ίδια πλευρά του υπερχώρου που διαχωρίζει τις κατηγορίες ταξινόμησης. Αν για παράδειγμα έχουμε δύο TN στο επίπεδο εισόδου, τότε ο διαχωριστικός υπερχώρος είναι μια απλή γραμμή. Για τρεις TN ο διαχωριστικός υπερχώρος είναι ένα επίπεδο του τρισδιάστατου Ευκλείδειου χώρου κ.τ.λ. Σε πραγματικά προβλήματα οι εισοδοί δεν είναι γραμμικά διαχωρίσιμες, όπως στο περίφημο πρόβλημα της XOR. Ο Minsky (Minsky και Papert 1969) έχοντας αναλύσει αυτό το πρόβλημα με μεγαλύτερη αυστηρότητα βρήκε ότι υπάρχουν μερικοί περιορισμοί στο τι μπορεί να αντιπροσωπεύσει ένα μονοστρωματικό perceptron και τι μπορεί σχετικά να μάθει.

* (Widrow 1961, Widrow και Angell 1962, Widrow και Hoff 1960)

Επειδή δεν υπήρχαν γνωστές τεχνικές εκείνη την εποχή για την εκπαίδευση των πολυστρωματικών δικτύων, οι ερευνητές στράφηκαν σε πιο ελπιδοφόρους τομείς. Η πρόσφατη ανακάλυψη μεθόδων εκπαίδευσης των πολυστρωματικών δικτύων ήταν, από οποιονδήποτε παράγοντα, υπεύθυνη για την επανεκκίνηση του ενδιαφέροντος και της προσπάθειας των ερευνητών. Σήμερα υπάρχουν πολλές παραλλαγές με διαφορετικές και περίπλοκες νευρωνικές δομές που χρησιμοποιούνται σε πολλές εφαρμογές όπως, η αναγνώριση χαρακτήρων και η τεχνητή όραση των ρομπότ.

Η πιο απλή είναι ο στοιχειώδης αισθητήρας (elementary percerton) ο οποίος αποτελείται από ένα νευρώνα και είναι το πιο απλό αυτοδύναμο σύστημα που υπάρχει και εκτελεί μια διεργασία.

Παρακάτω απεικονίζεται το μοντέλο του PERCEPTRON.



Σχήμα 3.2: Το μοντέλο του Perceptron

Ο μοναδικός νευρώνας του συστήματος έχει έναν ορισμένο αριθμό συνδέσεων που προέρχονται από άλλους νευρώνες. Ο νευρώνας είναι ο κύκλος και οι συνδέσεις οι άλλες γραμμές. Έχει έναν ορισμένο αριθμό εισόδων x_1, x_2, x_3 αλλά μόνο μία έξοδο y_k όπως φαίνεται και στο Σχήμα 3.2.

Κάθε εισερχόμενο σήμα συνδέεται με τον κεντρικό νευρώνα με ένα βάρος w_i . Το βάρος w μας δείχνει κατά κάποιο τρόπο την αλληλεπίδραση μεταξύ των δύο νευρώνων τους οποίους συνδέει. Δεν έχει σημασία η τιμή του βάρους w από μόνη της, ούτε η τιμή του σήματος x αλλά το γινόμενο $x_i w_i$ και έτσι κάθε x_i πολλαπλασιάζεται με επί τα βάρους w_i που έχει η σύνδεση i και τελικά αυτό που παρουσιάζεται στον νευρώνα από κάθε εισερχόμενο σήμα είναι το γινόμενο $x_i w_i$. Ο αισθητήρας αθροίζει τα γινόμενα αυτά και λαμβάνει ένα συνολικό σήμα:

$$S = \sum_i x_i w_i$$

Σαν σήματα εισόδου επιτρέπονται οι πραγματικοί αριθμοί, ενώ τα βάρη αντιστοιχούν επίσης σε πραγματικούς αριθμούς. Σαν συνάρτηση δραστηριοποίησης $f(\text{net})$ (παρακάτω απεικονίζεται ως $f(X_i)$), χρησιμοποιείται η βηματική συνάρτηση με μεταβλητό κατώφλι

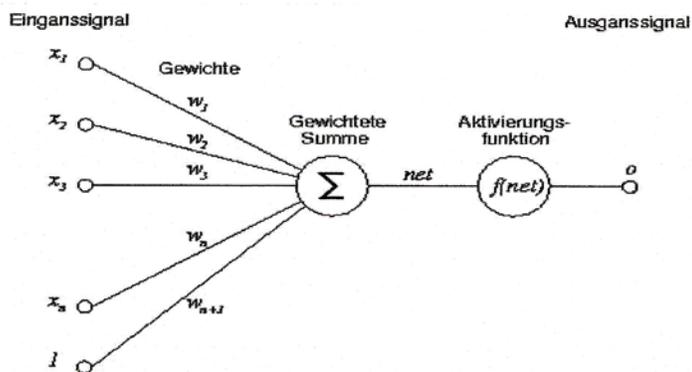
(Threshold Θ). Το σήμα εξόδου του Perceptron είναι τα 0 και 1.

$$f(x_i) = \begin{cases} 0 & : \sum_{i=1}^n x_i w_i < \theta \\ 1 & : \sum_{i=1}^n x_i w_i \geq \theta \end{cases}$$

Για απλοποίηση μπορεί η συνάρτηση δραστηριοποίησης να γραφεί και διαφορετικά:

$$f(x_i) = \begin{cases} 0 & : \sum_{i=1}^n x_i w_i - \theta < 0 \\ 1 & : \sum_{i=1}^n x_i w_i - \theta \geq 0 \end{cases}$$

Αν χρησιμοποιηθεί αυτός ο τρόπος παράστασης, τότε το κατώφλι Θ μπορεί να παρασταθεί σαν μια πρόσθετη είσοδος με πρόσθετο βάρος που έχει την τιμή 1 (βλέπε επόμενο Σχήμα 3.3).

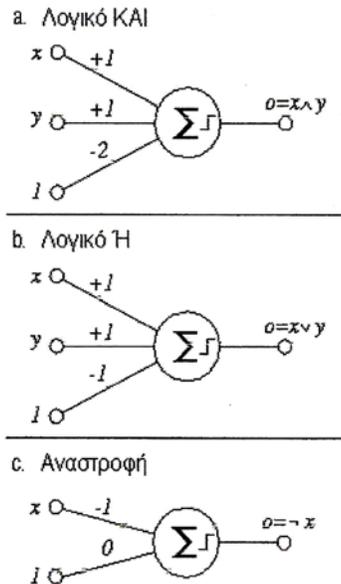


Σχήμα 3. 3: Perceptron υλοποιημένο με συνάρτηση κατωφλίου με μια πρόσθετη είσοδο και πρόσθετο βάρος

Έτσι, η συνάρτηση ενεργοποίησης παριστάνεται με:

$$f(x_i) = \begin{cases} 0 & : \sum_{i=1}^{n+1} x_i w_i < 0 \\ 1 & : \sum_{i=1}^{n+1} x_i w_i \geq 0 \end{cases}$$

Όπως φαίνεται παρακάτω με τον τρόπο αυτό παράστασης, μπορεί να απλοποιηθεί ο αλγόριθμος διδασκαλίας για τα βάρη καθώς και για τις τιμές του κατωφλίου.



Σχήμα 3. 4: Υλοποίηση λογικών πράξεων με τη βοήθεια ενός Perceptron.

Η βεβαρημένη συνάρτηση για το λογικό AND είναι:

$$net = 1*x + 1*y + (-2)*1 = x + y - 2$$

Στον παρακάτω πίνακα παριστάνονται τα βεβαρημένα αθροίσματα και οι τιμές εξόδου για όλους τους δυνατούς συνδυασμούς μιας λογικής πράξης AND.

x	y	net=x+y-2	f(net)=θ
1	1	0	1
1	0	-1	0
0	1	-1	0
0	0	-2	0

Βεβαρημένα αθροίσματα και σήματα εξόδου υλοποιημένα με τη βοήθεια του Perceptron

3.4 Ο λογάριθμος μάθησης του Perceptron

Η ισχύς των νευρωνικών δικτύων έγκειται στην ιδιότητά τους, ότι μπορούν να εξασκηθούν για την μελλοντική τους εργασία. Σαν απλός αλγόριθμος μάθησης θα παρασταθεί τώρα ο αλγόριθμος μάθησης Der Perceptron.

Ο αλγόριθμος αυτός, παρουσιάστηκε για πρώτη φορά το 1958 από τον F. Rosenblatt. Πρόκειται για απλό τρόπο μάθησης υπό επίβλεψη. Στην αρχή της μάθησης αρχικοποιούνται τυχαία τα βάρη. Σαν πρώτο βήμα μάθησης τοποθετείται στην είσοδο το επιθυμητό δείγμα εισόδου και στη συνέχεια συγκρίνει το αποτέλεσμα (την έξοδο) του Perceptron με την επιθυμητή τιμή. Με τη βοήθεια του αλγόριθμου μάθησης μεταβάλλονται τα βάρη έτσι ώστε να μειωθεί το σφάλμα. Η αλλαγή των βαρών γίνεται σύμφωνα με τον ακόλουθο μαθητικό τύπο:

$$\Delta w_i = n(t-o)x_i$$

όπου:

Δw_i :είναι η αλλαγή βάρους του βάρους W_i .

n :ρυθμός μάθησης καθορισμένων βημάτων με τα οποία μεταβάλλεται το βάρος.

t :η επιθυμητή έξοδος της μάθησης.

o : $o=f(\text{net})$

x_i :Σήμα εισόδου στην είσοδο i .

Ο υπολογισμός των νέων βαρών γίνεται με τον τόπο:

$$W_i^{\text{new}} = u_i^{\text{old}} + \Delta W_i$$

όπου: new: είναι η νέα τιμή

old : είναι η παλαιά τιμή του βάρους i

Επειδή η έξοδος του Perceptron μπορεί να λάβει τις τιμές 0 και 1, ο συντελεστής $(t-o)$ μπορεί να λάβει μόνον τις τιμές $\{-1,0,1\}$. Έτσι, για κάθε βάρος W_i ακολουθούνται τα επόμενα βήματα:

- Είναι η επιθυμητή έξοδος ίση με την πραγματική έξοδο τότε μην κάνεις τίποτε.
- Είναι η επιθυμητή έξοδος $t=0$ και η πραγματική έξοδος $o=1$ τότε μειώνεται το βάρος κατά το συντελεστή $\eta \cdot i$.
- Είναι η επιθυμητή έξοδος $t=1$ και η πραγματική έξοδος $o=0$ τότε αυξάνεται το βάρος κατά το συντελεστή $\eta \cdot i$.

Στις εφαρμογές επιλέγεται η τιμή του η , σαν συμβιβασμός μεταξύ της μέγιστης δυνατής τιμής των βημάτων μάθησης (μεγάλο η) και όσο το δυνατό μικρότερης μεταβολής των ήδη μαθημένων (μικρό η).

Αν ο ρυθμός μάθησης είναι υπερβολικά μεγάλος μπορεί ένα ήδη βήμα μάθησης να καταστραφεί. Το δίκτυο κρατά (θυμάται) καλύτερα κάθε φορά το τελευταίο υπόδειγμα που του παρουσιάστηκε. Προηγουμένως, τα μαθημένα υποδείγματα δεν αποθηκεύονται επαρκώς.

Αν ο ρυθμός μάθησης είναι υπερβολικά μικρός, απαιτούνται πολλά βήματα μάθησης. Συνήθως, επιλέγεται μεγάλο η στην αρχή της φάσης της μάθησης, ώστε να πλησιάζει την λύση με μεγάλα βήματα, και στη συνέχεια κατά τη διάρκεια της επεξεργασίας μάθησης

ελαττώνεται σταδιακά.

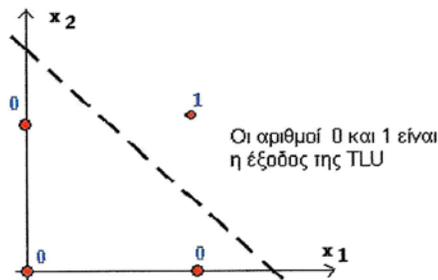
Η μεθόδευση που ακολουθείται στον αλγόριθμο αυτό, μεταβάλλει τα βάρη, έτσι ώστε να ελαχιστοποιείται στο σύνολο των δεδομένων ελέγχου το μέσο σφάλμα. Αν υπάρχει ένα σύνολο από βάρη W_i για τα οποία για όλα τα δεδομένα εξάσκησης προκύπτει επιτυχής έξοδος, τότε ο αλγόριθμος μάθησης τείνει προς μια λύση. Δεν είναι απαραίτητο όμως η λύση αυτή να είναι μονοσήμαντη, δηλαδή μπορεί να υπάρχουν και άλλα σύνολα από βάρη τα οποία να δίνουν την ορθή έξοδο για δεδομένα εξάσκησης (Minsky και Papert 1969).

Το ερώτημα είναι ποίου είδους προβλήματα μπορούν να λυθούν με τη βοήθεια του Perceptron.

3.5 Κατηγοριοποίηση (Classification)

Κατά τη διαδικασία της κατηγοριοποίησης για κάθε δείγμα εισόδου αποφασίζεται από το νευρωνικό δίκτυο σε ποια κατηγορία των εισόδων ανήκει.

Αν μελετήσουμε τον πίνακα αλήθειας του λογικού AND μπορούμε να φαντασθούμε την TLU (Threshold Logic Unit) να κατηγοριοποιεί τα δεδομένα εισόδου σε δύο κατηγορίες, αυτές που δίνουν έξοδο 1 και αυτές που δίνουν έξοδο 0. Κάθε είσοδος διαθέτει δύο συντεταγμένες τις x_1 και x_2 που παριστάνονται στο δισδιάστατο χώρο σύμφωνα με το παρακάτω Σχήμα 3.5.



Σχήμα 3.5: Γραφική παράσταση του Perceptron με δύο εισόδους.

Ο χώρος μέσα στον οποίο βρίσκονται οι εισοδοί χαρακτηρίζεται σαν "pattern space". Κάθε ζεύγος καθορίζει ένα σημείο χώρου. Γενικότερα, για n -εισόδους ο χώρος θα είναι n -διάστατος. Για $n > 3$ ο χώρος των pattern δεν μπορεί να σχεδιασθεί ή να παρουσιασθούν στο φυσικό χώρο.

3.6 Γραμμικός διαχωρισμός των κατηγοριών

Επειδή η κρίσιμη συνθήκη για την κατηγοριοποίηση συμβαίνει όταν η ενεργοποίηση a είναι ίση με το κατώφλι Θ , είναι βασικό να μελετηθεί η γεωμετρική εφαρμογή. Αν τοποθετηθεί ενεργοποίηση $a = \Theta$ τότε:

$$\sum_{i=1}^n w_i x_i = \theta$$

Στην περίπτωση 2 διαστάσεων:

$$W_1 X_1 + W_2 X_2 = \Theta \text{ ή λύνοντας ως προς } X_2:$$

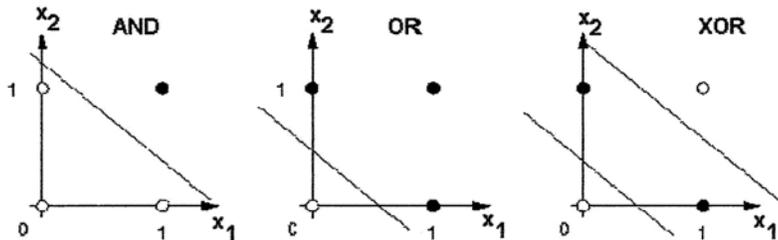
$$X_2 = -(W_1 / W_2) X_1 + (\Theta / W_2) \text{ που είναι της γενικής μορφής:}$$

$$X_2 = a X_1 + b$$

Πρόκειται για μια ευθεία γραμμή με κλίση a και τέμνει τον άξονα X_2 στο b . Επειδή είναι $W_1 = W_2 = 1$ και $a = -1$ προκύπτει $b = -1,5$.

Οι δύο κατηγορίες χωρίζονται από τη γραμμή απόφασης η οποία τοποθετείται τοποθετώντας την ενεργοποίηση ίση με το κατώφλι ($a = \theta$). Είναι επίσης δυνατό να γενικευθεί το αποτέλεσμα αυτό σε TLU με n εισόδους. Σε 3 διαστάσεις, οι 2 κλάσεις χωρίζονται από ένα επίπεδο απόφασης, ενώ σε n διαστάσεις λαμβάνουμε ένα υπερεπίπεδο απόφασης.

Τα σημεία που βρίσκονται κάτω από τη διακεκομμένη γραμμή ανήκουν στην κατηγορία (κλάση) 0, ενώ τα στοιχεία πάνω από αυτή ανήκουν στην κατηγορία 1. Η εξάσκηση ενός Perceptron είναι η εύρεση του διαχωρισμού των 2 κατηγοριών. Για το λογικό AND και OR ο διαχωρισμός είναι μια ευθεία γραμμή. Για το λογικό XOR απαιτούνται 2 γραμμές.



Σχήμα 3.6 : Γραφική παράσταση του Perceptron, με δύο κατηγορίες (κλάσεις) γραμμικά χωριζόμενες με μια γραμμή.

Γραμμικά χωριζόμενα προβλήματα κατηγοριοποίησης μπορούν να λυθούν με ένα Perceptron. Αντίθετα, μη γραμμικά χωριζόμενα προβλήματα κατηγοριοποίησης δεν μπορούν να λυθούν με ένα απλό Perceptron.

Το πρόβλημα αυτό, μπορεί να επιδειχθεί με τη λειτουργία του λογικού XOR. Για την υλοποίηση του λογικού XOR πρέπει να υπάρχουν 3 βάρη W_1, W_2, W_3 τέτοια έτσι ώστε να πληρούνται οι πιο κάτω εξισώσεις:

x=0, y=0 : $0*w_1 + 0*w_2 + 1*w_3 < 0$ Output o=0
x=0, y=1 : $0*w_1 + 1*w_2 + 1*w_3 \geq 0$ Output o=1
x=1, y=0 : $1*w_1 + 0*w_2 + 1*w_3 \geq 0$ Output o=1
x=1, y=1 : $1*w_1 + 1*w_2 + 1*w_3 < 0$ Output o=0

Απλοποιημένα μπορεί να γραφούν ως εξής:

x=0, y=0 : $w_3 < 0$ Output o=0
x=0, y=1 : $w_2 + w_3 \geq 0$ Output o=1
x=1, y=0 : $w_1 + w_3 \geq 0$ Output o=1
x=1, y=1 : $w_1 + w_2 + w_3 < 0$ Output o=0

Είναι προφανές ότι αν πληρούνται οι τρεις πρώτες ανισότητες δεν πληρείται η τέταρτη. Έτσι δεν μπορούν να βρεθούν βάρη για να λύσουν το πρόβλημα του με τη βοήθεια ενός Perceptron.

Επειδή με τη βοήθεια των Perceptron μπορούν να υλοποιούνται λογικές πράξεις και επειδή το λογικό XOR μπορεί να επιλυθεί με λογικό AND και λογικό OR είναι ευνόητο ότι αν συνδεθούν περισσότερα Perceptron το ένα μετά το άλλο, μπορεί να επιλυθεί με αυτά το λογικό XOR καθώς και άλλα πολυπλοκότερα προβλήματα.

Το 1986 δημοσιεύθηκε από τους Rumelhart, Hinton και Williams ο αλγόριθμος με την ονομασία Back-Propagation που χρησιμοποιούσε πολλαπλά στρώματα (Multi Layer Perceptron) από Perceptron.

Ένα κλασσικό παράδειγμα κατηγοριοποίησης είναι η αναγνώριση χαρακτήρων (pattern Recognition), στο οποίο θα αναφερθούμε στα επόμενα κεφάλαια.

3.7 Adaline (Adaptive Linear Neyrone)

Το Adaline (adaptive linear element) είναι ένα από τα απλούστερα μοντέλα των ΤΝΔ με ικανότητα εκμάθησης και ταξινόμησης ψηφιακών γραμμικών διαχωρίσιμων διανυσμάτων εισόδου. Προτάθηκε από τον Widrow το 1962 και η λειτουργία του έχει ως εξής:

Τα n-διάστατα διανύσματα εισόδου **x** παρουσιάζονται στο Adaline μαζί με την επιθυμητή έξοδο **t**. Στόχος είναι να προσαρμοσθούν τα συναπτικά βάρη **w_i** και το κατώφλι **θ** έτσι ώστε μετά την διαδικασία εκπαίδευσης η εμφάνιση κάποιου διανύσματος **x** στην είσοδο να δίνει έξοδο ίση με το **x** (**k=1,2,...**). Οι αρχικές τιμές των βαρών πρέπει να είναι τυχαίες για να αποφεύγεται η παγίδευση του αλγόριθμου εκπαίδευσης στα τοπικά ελάχιστα του υπερχώρου των βαρών.

Αν **x=(ξ_{1k}, ξ_{2k},...,ξ_{nk})** τότε η έξοδος του αθροιστή (που είναι η έξοδος του νευρωνίου) θα δίνεται από την εξίσωση :

$$n = \sum_{i=1}^n w_i \xi_{ik} \theta$$

Ο κανόνας εκμάθησης που υλοποιείται από τους ελεγκτές των μεταβλητών αντιστάσεων (ή συναπτικών βαρών) με το σύμβολο \mathbf{k} θα πρέπει να αντιστοιχεί τόσο σε κάποιο ζεύγος εισόδων -εξόδου (X_k, Π_k) όσο και στις διακριτές τιμές χρόνου:

$$w_i(\mathbf{k} + 1) = w_i(\mathbf{k}) + a(\mathbf{k})(\eta_k - \eta)\xi_{ik}$$

όπου η παράμετρος $a(\mathbf{k})$ είναι το προσαρμοστικό κέρδος (ή ρυθμός προσαρμογής ή επίσης και ο ρυθμός εκμάθησης) και επιλέγεται συνήθως ως ένας μικρός θετικός αριθμός δηλ. $\mathbf{a}(\mathbf{k}) = \mathbf{a} > 0$ ή τείνων στο μηδέν ικανοποιώντας τις παρακάτω συνθήκες στοχαστική προσέγγισης:

$$\sum_{k=1}^{\infty} a(k) = \infty \text{ και } \sum_{k=1}^{\infty} a^2(k) < \infty$$

Όταν τα διανύσματα εισόδου είναι γραμμικώς ανεξάρτητα ο αλγόριθμος αυτός συγκλίνει σε μοναδικά όρια. Στην ουσία ο κανόνας προσαρμογής των βαρών διορθώνει τα βάρη ανάλογα με το σφάλμα που παρατηρείται κάθε φορά στην έξοδο ανάμεσα στην πραγματική \mathbf{o} και στην επιθυμητή \mathbf{t} έξοδο. Στην περίπτωση που η πραγματική έξοδος είναι διαφορετική από την επιθυμητή, η διόρθωση θα γίνει προς την κατεύθυνση ελαχιστοποίησης του σφάλματος εξόδου.

Μετά την φάση προσαρμογής των βαρών (φάση εκπαίδευσης), τα βάρη σταθεροποιούνται στις τελικές τιμές και αρχίζει η φάση ανάκλησης. Στην φάση αυτή για κάθε διάνυσμα που εμφανίζεται στην είσοδο παίρνουμε μία έξοδο (απόκριση συστήματος). Τις περισσότερες φορές θέλουμε η έξοδος να είναι δυαδική (+1 ή -1). Ο αθροιστής πρέπει να ακολουθείται από έναν κβαντιστή ώστε η έξοδος του όλου συστήματος να είναι το πρόσημο της πραγματικής εξόδου.

Η παράλληλη σύνδεση πολλών Adaline δημιουργεί το Madaline (Multiple ADALINES). Με το Madaline είναι δυνατή η συσχέτιση διανυσμάτων εισόδου με διανύσματα εξόδου. Η φυσική υλοποίηση του Adaline με αντιστάσεις δεν επιτρέπει την ύπαρξη αρνητικών βαρών, είναι πιθανό να χρειαστεί επανακλιμάκωση των εισόδων. Αν η έξοδος του Madaline είναι διαφορετική από την επιθυμητή, τροποποιούμε τα βάρη εκείνου του Adaline που έχει διαφορετική έξοδο από την επιθυμητή του Madaline και επιπλέον έχει την μικρότερη απόλυτη τιμή σταθμισμένου αθροίσματος εισόδου από όλα τα Adalines.

Τα ADALINE και MADALINE υπήρξαν από τα πρώτα ΤΝΔ που χρησιμοποιήθηκαν σε πραγματικά προβλήματα. Το MADALINE ανήκει στην κατηγορία δικτύων για φιλτράρισμα δεδομένων. Ο Widrow τα εφάρμοσε με μεγάλη επιτυχία στις τηλεπικοινωνίες, στην κατασκευή προσαρμοζόμενων συστοιχιών κεραιών, την ανάλυση σεισμικών δεδομένων, καθώς και σε συστήματα ελέγχου. Το MADALINE αφαίρεσε τις ηχώ από μια τηλεφωνική γραμμή μέσω ενός δυναμικού κυκλώματος ακύρωσης της ηχώ. Η πιο πρόσφατες εργασίες έχουν επιτρέψει στα modem να λειτουργήσουν αξιόπιστα στα 4800 και 9600 baud μέσω των δυναμικών τεχνικών εξίσωσης. Και οι δύο εφαρμογές χρησιμοποιούν τα νευρωνικά δίκτυα που ενσωματώθηκαν σε ειδικά τσιπ. Στις σημαντικές εφαρμογές περιλαμβάνονται η πρόβλεψη του καιρού, η αναγνώριση φωνής,

η ρύθμιση της πίεσης του αίματος.

3.8 Δίκτυα για Συσχετισμό δεδομένων (Networks for Data Association)

Στο συσχετισμό δεδομένων, γίνεται ταξινόμηση. Παρακάτω αναφέρονται κάποια δίκτυα τα οποία ανήκουν στην κατηγορία αυτή.

3.9 Δίκτυα Hopfield

Ο Hopfield παρουσίασε το 1982 μια νέα κατηγορία δικτύων, τα οποία έχουν μεγάλες υπολογιστικές ικανότητες και είναι χρήσιμα σε δύο κατηγορίες προβλημάτων:

- σε προβλήματα μνήμης συνειρμού (associative memory) και
- σε προβλήματα βελτιστοποίησης (optimization).

Η μέθοδος αυτή δεν έλυσε άγνωστα προβλήματα ούτε και πρότεινε τις καλύτερες λύσεις αλλά ήταν πολύ χρήσιμη για την διορατικότητα που μας δίνει για την φύση του προβλήματος.

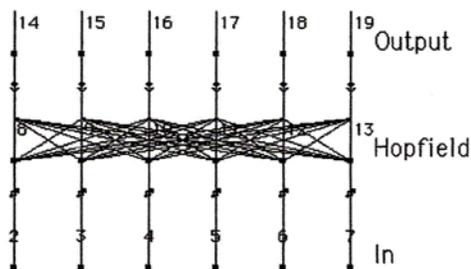
Το δίκτυο Hopfield ανήκει στην κατηγορία των ανατροφοδοτούμενων ΤΝΔ με ανατροφοδότηση καταστάσεων και έχει τόσα νευρώνια όσες και οι εισοδοί. Αποτελείται από ένα μόνο επίπεδο με πολλές μονάδες, του οποίου κάθε ΤΝ μπορεί να οριστεί ως ΤΝ εξόδου, ενώ το διάνυσμα εισόδου εισάγεται απευθείας σε όλους τους ΤΝ. Τα διανύσματα εισόδου πρέπει να είναι δυαδικά δηλαδή με νευρώνες στο $\{+1, -1\}$. Μια κατάσταση του συστήματος είναι πλήρης όταν δίνονται οι τιμές των νευρώνων από τις οποίες αποτελείται π.χ. $s=(s_1, s_2, s_3, \dots, s_n)=(1, 0, 1, 1, \dots, \dots, 0)$ για ένα δίκτυο με n μονάδες. Τα νευρώνια του δικτύου έχουν πλήρη συνδεσμολογία δηλ. κάθε νευρόνιο είναι συνδεδεμένο με όλα τα άλλα (εκτός από τον εαυτό του) μέσω των συναπτικών βαρών. Αυτό σημαίνει ότι θα έχουμε $n(n-1)$ συνδέσεις.

Σε γενική περίπτωση οι συνδέσεις έχουν συγκεκριμένη κατεύθυνση. Έτσι σε κάθε ζευγάρι μονάδων που συνδέεται υπάρχει αμφίδρομη σύνδεση με βάρη ίδιας τιμής και ισχύει πάντοτε η σχέση:

$$W_{ij}=W_{ji}$$

Διότι εξασφαλίζει ότι το δίκτυο συγκλίνει και καταλήγει σε μια σταθερή κατάσταση.

Η δομή του δικτύου φαίνεται παρακάτω:



Σχήμα 3. 7: Δομή δικτύου

Τα βάρη με θετική τιμή θεωρούνται «διεγερτικά», ενώ τα βάρη με αρνητική τιμή θεωρούνται «κατασταλτικά». Το άθροισμα των j εισόδων του j TN υπολογίζεται ως εξής:

$$\Sigma_j = \sum^N W_{ji} O_i \quad i \neq j$$

όπου: O_i : είναι η έξοδος i του TN.

W_{ji} : Το βάρος που συνδέει την έξοδο του i .

N : ο αριθμός των TN του TNA.

Η έξοδος του j TN λαμβάνει τις διακριτές τιμές $[0, +1]$ όπως ορίζει η:

$$o_j = \begin{cases} +1 & \text{όταν } \Sigma_j > 0 \\ 0 & \text{όταν } \Sigma_j \leq 0 \end{cases}$$

Σύμφωνα με τον αλγόριθμο εκπαίδευσης του Hopfield τα βάρη μεταβάλλονται ως εξής:

$$\Delta W_{ji} = (2o_j - 1) * (2o_i - 1)$$

Παρατηρούμε ότι ένα βάρος ενδυναμώνεται ($\Delta W_{ji}=1$) όταν οι έξοδοι των TN που συνδέει είναι ίσες δηλ. όταν $o_i=o_j$. Αντίθετα αποδυναμώνεται ($\Delta W_{ji}= -1$) όταν $o_i \neq o_j$.

Το δίκτυο Hopfield έχει ως χαρακτηριστικό του ότι οι νευρώνες του συνεχώς αναπροσαρμόζονται. Αυτό αποτελεί την εκπαίδευση του δικτύου. Αρχικά μπορεί να βρίσκεται σε μια τυχαία κατάσταση και ακολούθως κάθε νευρώνας να αναπροσαρμόζει την κατάσταση του, ακολουθώντας κάποιους κανόνες ως συνάρτηση του χρόνου (αυθαίρετες μονάδες χρόνου). Κατά την αναπροσαρμογή αυτή η κατάσταση των νευρώνων αλλάζει ενώ κάποιες φορές παραμένει ίδια. Όταν δεν γίνονται πλέον αλλαγές τότε ολοκληρώνεται η εκπαίδευση. Ο Hopfield πρότεινε να γίνονται οι αναπροσαρμογές με τυχαίο τρόπο. Ο τρόπος αυτός έχει χαρακτηριστικά ασύγχρονης λειτουργίας και είναι πιο κοντά στα βιολογικά δίκτυα όπου οι νευρώνες αναπροσαρμόζονται με τυχαία αλληλουχία χωρίς να υπάρχει συσχετισμός από νευρώνα σε νευρώνα

Το δίκτυο Hopfield χαρακτηρίζεται από μία παράμετρο E η οποία εξαρτάται από τα σήματα εισόδου και τα βάρη και η οποία είναι αντίστοιχη της ενέργειας σε φυσικά προβλήματα. Η παράμετρος E δίδεται από τη σχέση:

$$E = - \frac{1}{2} \sum_j \sum_i W_{ji} O_i O_j \quad i \neq j$$

Η ενέργεια E_j του j TN είναι:

$$E_j = - \frac{1}{2} \sum_j W_{ji} O_i O_j$$

Αν ο $j \in \text{TN}$ είναι δραστηριοποιημένος δηλ, αν $o_j=1$ τότε η παραπάνω εξίσωση γράφεται ως εξής:

$$E = - \frac{1}{2} \sum_{i \neq j}^N W_{ji} O_i$$

Αν $o_j = 0$ τότε $E_j = 0$

Άρα η μεταβολή της ενέργειας $j \in \text{TN}$ μπορεί να γραφτεί ως εξής :

$$E = - \frac{1}{2} \Delta O_j \sum_j^N W_{ji} O_i$$

Παρατηρούμε ότι ένας TN αλλάζει κατάσταση μόνο όταν μειώνεται ταυτόχρονα η συνολική του ενέργεια E . Κάθε χρονική στιγμή μεταβάλλεται η κατάσταση μόνο ενός TN ο οποίος επιλέγεται με τυχαίο τρόπο. Στην πράξη αυτό επιτυγχάνεται αν ορίσουμε μια πιθανότητα δραστηριοποίησης για όλους τους TN. Με την μέθοδο αυτή βρίσκουμε κάποιο ελάχιστο της συνάρτησης ενέργειας. Η χωρητικότητα της συσχετικής μνήμης έχει υπολογισθεί στο $0.15N$ δηλαδή, σε ένα δίκτυο 100 νευρώνων μπορούν να αποθηκευτούν περίπου 15 πρότυπα.

Το πλεονέκτημα του δικτύου Hopfield έναντι των γραμμικών συσχετιστικών μνημών είναι ότι στην περίπτωση που η είσοδος είναι ένας γραμμικός συνδυασμός προτύπων τότε, η έξοδος στον δίκτυο Hopfield θα είναι κάποιο από τα αποθηκευμένα πρότυπα ενώ για τις γραμμικές μνήμες η έξοδος θα είναι ο ίδιος γραμμικός συνδυασμός των αντίστοιχων εξόδων.

Το σημαντικότερο μειονέκτημα του δικτύου είναι η συχνή παγίδευση του στα τοπικά ελάχιστα της πολύπλοκης επιφάνειας ενέργειας. Παρόλα αυτά ο ρυθμός σύγκλισης είναι μεγάλος και σχετικά ανεξάρτητος από το μέγεθος του προβλήματος.

Έως σήμερα το δίκτυο Hopfield έχει κατασκευαστεί με αναλογικά ολοκληρωμένα κυκλώματα και με οπτικά στοιχεία επεξεργασίας πληροφοριών. Χρησιμοποιείται σε προβλήματα βελτιστοποίησης όπως το πρόβλημα του περιοδεύοντος πωλητή (TSP), στην ρομποτική στην αναγνώριση οπτικών προτύπων, στόχων κ.λ.π.

3.10 Το πρόβλημα του πλανόδιου πωλητή (TSP)

Το TSP (Traveling Salesman Problem) είναι από τα πιο γνωστά προβλήματα της βελτιστοποίησης και από τα πιο δύσκολα. Ανήκει στην κατηγορία προβλημάτων "NP complete" (non-deterministic polynomial) τα οποία δεν έχουν ακριβείς λύσεις. Το πρόβλημα TSP ορίζεται ως εξής:

Έχουμε μια ομάδα από πόλεις σε έναν χάρτη με συγκεκριμένες συντεταγμένες που πρέπει να επισκεφθεί ένας πλανόδιος πωλητής ακολουθώντας συγκεκριμένη διαδρομή. Οι περιορισμοί είναι οι εξής: ο πλανόδιος πωλητής πρέπει να επισκεφθεί κάθε πόλη από μια φορά και στο τέλος να επιστρέψει στην αρχική πόλη. Ζητείται η μικρότερη διαδρομή.

Ο Hopfield πρότεινε την παρακάτω λύση η οποία ακολουθεί την εξής διαδικασία: η λύση περιλαμβάνει την επίσκεψη σε μια ομάδα από n πόλεις. Θέλουμε να αναπαραστήσουμε την ομάδα αυτή σε ένα νευρωνικό δίκτυο. Κάθε πόλη είναι μια σειρά από n νευρώνες. Σε κάθε σειρά μπορεί μόνο ένας νευρώνας να είναι 1 ενώ οι άλλοι πρέπει να είναι 0. Ο νευρώνας που είναι ίσος με 1 δείχνει την σειρά με την οποία ο πωλητής θα επισκεφθεί τις πόλεις. Τα παραπάνω φαίνονται στον παρακάτω πίνακα ο οποίος είναι για το πρόβλημα με 10 πόλεις. Οι πόλεις είναι από A,B,C... έως J. Οι στήλες δείχνουν την σειρά που γίνεται η επίσκεψη στην πόλη. Από ότι βλέπουμε από τον πίνακα η διαδρομή αρχίζει από την πόλη G ακολούθως B,J,A,D,H,C,F,I,E.

ΠΟΛΗ	1	2	3	4	5	6	7	8	9	10
A	0	0	0	1	0	0	0	0	0	0
B	0	1	0	0	0	0	0	0	0	0
C	0	0	0	0	0	0	1	0	0	0
D	0	0	0	0	1	0	0	0	0	0
E	0	0	0	0	0	0	0	0	0	1
F	0	0	0	0	0	0	0	1	0	0
G	1	0	0	0	0	0	0	0	0	0
H	0	0	0	0	0	1	0	0	0	0
I	0	0	0	0	0	0	0	0	1	0
J	0	0	1	0	0	0	0	0	0	0

Το σύστημα αυτό απαιτεί n νευρώνες και βλέπουμε ότι ο αριθμός αυτός αυξάνεται πολύ γρήγορα με το n . Επειδή ο πλανόδιος πωλητής επισκέπτεται κάθε φορά μια πόλη και από μια φορά δηλ. δεν μπορεί να είναι ταυτόχρονα σε δύο πόλεις υπάρχει μόνον ένας άσπος σε κάθε σειρά και σε κάθε στήλη του πίνακα. Το πρόβλημα με n πόλεις έχει $n!/2n$ διαφορετικές διαδρομές άρα έχει αυτό τον αριθμό λύσεων. Αν $n=10$ τότε υπάρχουν 181440 διαφορετικές διαδρομές αν $n=60$ τότε υπάρχουν 6.9×10^{79} διαφορετικές διαδρομές. Στη λύση προτείνεται κάθε νευρώνας να έχει δύο δείκτες που δείχνουν την πόλη και την σειρά με την οποία θα επισκεφθεί ο πωλητής τις πόλεις. Πρέπει να προτιμώνται οι λύσεις που έχουν την μικρότερη διαδρομή. Η ενέργεια δίδεται από:

$$E = A/2 \sum_x \sum_i \sum_j V_{xi} V_{xj} \quad j \neq i \quad 1^{ος} \text{ όρος}$$

$$+ B/2 \sum_i \sum_x \sum_y V_{xi} V_{yi} \quad y \neq x \quad 2^{ος} \text{ όρος}$$

$$+ C/2 \sum_x \sum_i (V_{xi} - n^2) \quad 3^{ος} \text{ όρος}$$

$$+ D/2 \sum_x \sum_y \sum_i d_{xy} S_{xi} (V_{x,i+1} V_{y,i-1}) \quad 4^{ος} \text{ όρος}$$

και D είναι παράμετροι (σταθερές), V είναι ένα στοιχείο του πίνακα x στην σειρά x και

στην στήλη i .

Κάθε όρος στην εξίσωση της ενέργειας εισάγει κάποιους περιορισμούς τους οποίους έχει εξ ορισμού το πρόβλημα TSP. Κάθε περιορισμός επιβάλλεται με την ελαχιστοποίηση του αντίστοιχου όρου.

Ο πρώτος όρος επιτρέπει μια μόνο επίσκεψη σε κάθε πόλη. Έχει μικρή τιμή (είναι 0) μόνο όταν κάθε σειρά έχει έναν άσσο.

Ο δεύτερος όρος δεν επιτρέπει στον πλανόδιο πωλητή να βρίσκεται σε δύο διαφορετικές πόλεις την ίδια στιγμή. Ο όρος αυτός είναι μικρός (είναι 0) όταν κάθε στήλη έχει έναν άσσο.

Ο τρίτος όρος επιτρέπει μόνον n πόλεις να υπάρχουν στην διαδρομή. Ο όρος αυτός είναι μικρός (είναι 0) όταν υπάρχουν ακριβώς n αριθμοί από 1 στον πίνακα.

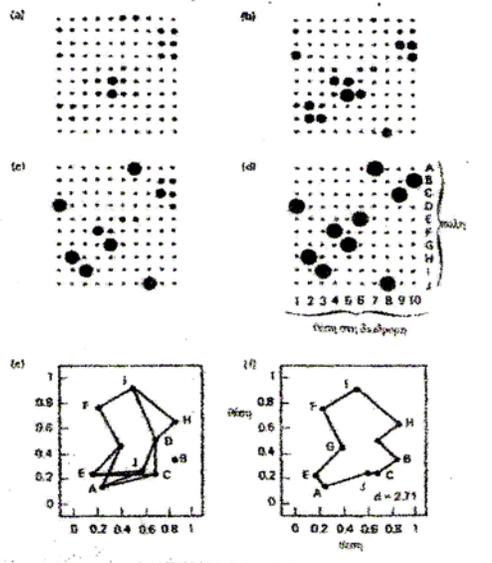
Ο τέταρτος όρος παριστάνει το συνολικό μήκος της διαδρομής που πρέπει να ελαχιστοποιηθεί. Οι τιμές των σταθερών A , B , και C πρέπει να είναι μεγάλες έτσι ώστε οι καταστάσεις που έχουν χαμηλή ενέργεια να παριστάνουν «καλές» διαδρομές. Η μεγάλη τιμή στο D εξασφαλίζει ότι θα βρεθεί μία σύντομη διαδρομή. Το επόμενο βήμα είναι να βρούμε τα βάρη. Έχουμε :

$$\begin{aligned} W_{xi,yi} = & - A\delta_{xy}(1-\delta_{ij}) \\ & - B\delta_{ij} (1-\delta_{xy}) \\ & - C \\ & - Dd_{xy} (\delta_{j,i+1} + \delta_{j,i-1}) \end{aligned}$$

όπου: δ_{ij} είναι το Kronecker , $\delta_{ij} = 1$ και $i = j$ και $i \neq j$. Ο όρος A δεν επιτρέπει πλέον του ενός άσσου σε μια σειρά, ο όρος B δεν επιτρέπει πλέον του ενός άσσου σε μια στήλη, ο όρος C δίνει έναν συνολικό περιορισμό, ενώ τέλος ο όρος D είναι όρος απόστασης. Επί πλέον κάθε νεύρωνας έχει μια εξωτερική ορμή (bias):

$$I_{kj} = C_n$$

Η αρχική κατάσταση του νευρωνικού δικτύου είναι τυχαία και το δίκτυο υφίσταται συνεχείς αναπροσαρμογές μέχρις ότου συγκλίνει σε μία σταθερή κατάσταση. Όταν επιτευχθεί η σύγκλιση τότε η διαδρομή του πλανόδιου πωλητή δίδεται από την τελική κατάσταση του δικτύου.



Σχήμα 3.8

Στο Σχήμα 3.8 βλέπουμε την εξέλιξη του δικτύου ενώ αναπροσαρμόζει τις τιμές των μονάδων του. Κάθε πίνακας έχει διάσταση 10×10 για το πρόβλημα $n=10$. Η τιμή του στοιχείου του πίνακα είναι ανάλογη με την διάμετρο του κύκλου. Στα (a),(b), και (c) έχουμε φωτογραφίες από ενδιάμεσες καταστάσεις, ενώ στο (d) έχουμε την τελική λύση, αφού έχουν τελειώσει όλες οι αναπροσαρμογές. Στο (e) έχουμε την διαδρομή του πωλητή για μια ενδιάμεση τέτοια κατάσταση που δείχνει ότι μια ενδιάμεση κατάσταση μπορεί να έχει διαδρομή με δύο πόλεις την ίδια χρονική στιγμή (δύο στοιχεία στην ίδια στήλη), ή να μην επισκέπτεται καθόλου κάποιες πόλεις (κανένα στοιχείο σε μια σειρά). Στο (f) έχουμε την τελική διαδρομή, η οποία και υπακούει όλους τους κανόνες προβλήματος. Επί πλέον η συνολική απόσταση είναι μικρότερη από άλλες πιθανές διαδρομές.

Το δίκτυο Hopfield λύνει το πρόβλημά TSP ικανοποιητικά για τιμές $n = 10 \sim 30$, αλλά έχει προβλήματα για μεγαλύτερα n . Τέλος το δίκτυο Hopfield έχει χαρακτηριστικά παράλληλης αρχιτεκτονικής, κάτι το οποίο θα μπορούσε να είναι χρήσιμο σε αντίστοιχες πειραματικές διατάξεις.

3.11 Μηχανή Boltzmann (Boltzmann Machine)

Οι Ackley, Hinton και Sejnowski ανέπτυξαν τον κανόνα εκμάθησης Boltzmann το 1985. Όπως το δίκτυο Hopfield, η μηχανή Boltzmann έχει μια σχετική ενέργεια κατάστασης που βασίζεται στα βάρη σύνδεσης στο στρώμα προτύπου. Οι διαδικασίες εκμάθησης ενός καθορισμένου συνόλου γεμάτων πρότυπα περιλαμβάνει την ελαχιστοποίηση αυτής της κατάστασης ενέργειας. Λόγω αυτού, η μηχανή θα έλθει σε ένα βελτιωμένο σύνολο τιμών για τα βάρη σύνδεσης ενώ τα δεδομένα επαναλαμβάνονται μέσω του συστήματος. Η μηχανή Boltzmann απαιτεί ένα πρόγραμμα προσομοίωσης, το οποίο προστίθεται στη διαδικασία εκμάθησης του δικτύου. Ακριβώς όπως στη φυσική ανόπτηση, οι

θερμοκρασίες αρχίζουν από υψηλότερες τιμές και μειώνονται κατά τη διάρκεια του χρόνου. Η αυξανόμενη θερμοκρασία προσθέτει έναν αυξανόμενο παράγοντα θορύβου σε κάθε τμήμα επεξεργασίας στο στρώμα προτύπου. Τυπικά, η τελική θερμοκρασία είναι μηδέν. Εάν το δίκτυο αποτύχει, η προσθήκη περισσότερων επαναλήψεων στις χαμηλότερες θερμοκρασίες μπορεί να βοηθήσει να φτάσει σε μια βέλτιστη λύση.

Μια μηχανή Boltzmann που μαθαίνει σε υψηλή θερμοκρασία συμπεριφέρεται σαν ένα τυχαίο πρότυπο και στις χαμηλές θερμοκρασίες συμπεριφέρεται όπως ένα αιτιοκρατικό πρότυπο.

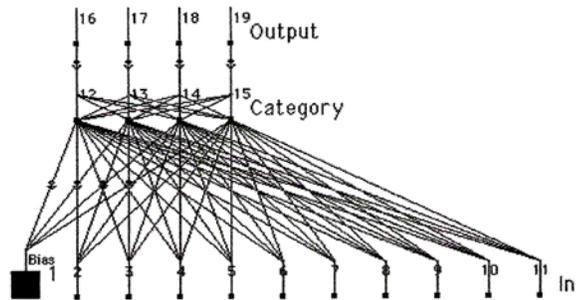
Όπως και στο δίκτυο Hopfield, το οποίο μαθαίνει μια φορά ένα σύνολο προτύπων, έτσι και εδώ μπορεί να παρουσιαστεί στο δίκτυο, ένα μερικό σχέδιο και στην συνέχεια το δίκτυο θα ολοκληρώσει τις ελλείπουσες πληροφορίες.

3.12 Δίκτυο Hamming

Το δίκτυο Hamming είναι μια επέκταση του δικτύου Hopfield δεδομένου ότι προσθέτει έναν ταξινομητή μέγιστης πιθανότητας στο τέλος. Αυτό το δίκτυο αναπτύχθηκε από τον Richard Lippman στα μέσα της δεκαετίας του '80. Το δίκτυο Hamming εφαρμόζει έναν ταξινομητή που βασίζεται στο λιγότερο λάθος για τα δυαδικά διανύσματα εισόδου, όπου το λάθος καθορίζεται από την απόσταση Hamming. Η απόσταση Hamming ορίζεται ως ο αριθμός των bits που διαφέρουν μεταξύ δύο αντίστοιχων, καθορισμένου μήκους διανυσμάτων εισόδου. Για παράδειγμα, η απόσταση Hamming των δύο δυαδικών διανυσμάτων $x=(10011110)^T$ και $y=(11011010)^T$ θα είναι $HD(x,y)=2$ επειδή διαφέρουν σε δυο bits. Σε αυτή τη δικτυακή αρχιτεκτονική, οι κατηγορίες εξόδου καθορίζονται από ένα αθόρυβο, pattern-filled σύνολο κατάρτισης. Στον τρόπο ανάκλησης οποιαδήποτε εισερχόμενα διανύσματα εισόδου ορίζονται έπειτα στην κατηγορία για την οποία η απόσταση μεταξύ των διανυσμάτων εισόδου του παραδείγματος και του τρέχοντος διανύσματος εισόδου είναι ελάχιστη.

Το δίκτυο Hamming έχει τρία στρώματα. Υπάρχει ένα δίκτυο παραδείγματος που παρουσιάζεται στο Σχήμα 3.9. Το δίκτυο χρησιμοποιεί ένα στρώμα εισόδου με τόσους κόμβους όσα είναι τα χωριστά δυαδικά χαρακτηριστικά γνωρίσματα. Έχει ένα στρώμα κατηγορίας, που είναι το στρώμα Hopfield με τόσους κόμβους όσες είναι οι κατηγορίες, ή οι τάξεις. Αυτό διαφέρει σημαντικά από την επίσημη αρχιτεκτονική Hopfield η οποία έχει τόσους κόμβους στο μέσο στρώμα όσοι είναι οι κόμβοι εισόδου. Και τελικά, υπάρχει ένα στρώμα εξόδου που ταιριάζει με τον αριθμό κόμβων στο στρώμα κατηγορίας.

Το δίκτυο είναι μια απλή feedforward αρχιτεκτονική με το στρώμα εισόδου πλήρως συνδεδεμένο με το στρώμα κατηγορίας. Κάθε τμήμα επεξεργασίας στο στρώμα κατηγορίας συνδέεται πίσω σε κάθε άλλο τμήμα σε αυτό το ίδιο στρώμα, καθώς επίσης και σε μια άμεση σύνδεση με το τμήμα επεξεργασίας εξόδου. Η έξοδος από το στρώμα κατηγορίας στο στρώμα εξόδου γίνεται μέσω του ανταγωνισμού.



Σχήμα 3. 9: Ένα παράδειγμα δικτύου Hamming.

Η εκμάθηση ενός δικτύου Hamming είναι παρόμοια με τη μεθοδολογία του Hopfield δεδομένου ότι απαιτεί ένα single-pass σύνολο κατάρτισης. Εδώ η έξοδος περιέχει μόνο την κατηγορία εξόδου στην οποία ανήκει το διάνυσμα εισόδου. Πάλι, η επαναλαμβανόμενη φύση του Hopfield στρώματος παρέχει έναν τρόπο ρύθμισης όλων των βαρών σύνδεσης.

Τα βάρη σύνδεσης αρχικά τίθενται στην είσοδο στο στρώμα κατηγορίας έτσι ώστε τα ταιριαγμένα αποτελέσματα που παράγονται από τις εξόδους των τμημάτων επεξεργασίας να είναι ίσα με τον αριθμό κόμβων εισόδου μείον τις αποστάσεις Hamming στα διανύσματα εισόδου του παραδείγματος. Αυτά τα όμοια αποτελέσματα κυμαίνονται από μηδέν ως το συνολικό αριθμό των τμημάτων εισόδου και είναι τα υψηλότερα για αυτά τα διανύσματα εισόδου που ταιριάζουν καλύτερα με τα σχέδια εκμάθησης. Τα επαναλαμβανόμενα βάρη σύνδεσης του στρώματος κατηγορίας εκπαιδεύονται με τον ίδιο τρόπο όπως στο δίκτυο Hopfield. Σε κανονική feedforward λειτουργία εφαρμόζεται ένα διάνυσμα εισόδου στο στρώμα εισόδου και πρέπει να παρουσιαστεί αρκετό χρονικό διάστημα για να επιτρέψει στις εξόδους χαμηλότερης εισόδου στο υποδίκτυο κατηγορίας, με όμοια αποτελέσματα να εγκατασταθούν. Αυτό θα αρχικοποιήσει την είσοδο στη συνάρτηση Hopfield στο στρώμα κατηγορίας και θα επιτρέψει αυτή σε αυτή τη μερίδα υποδικτύου να βρει την πιο στενή κατηγορία στην οποία ανήκει το διάνυσμα εισόδου. Αυτό το στρώμα είναι ανταγωνιστικό, έτσι μόνο μια έξοδος επιτρέπεται τη φορά.

Το δίκτυο Hamming έχει διάφορα πλεονεκτήματα σε σχέση με το δίκτυο Hopfield. Εφαρμόζει το βέλτιστο ελάχιστο ταξινομητή σφάλματος όταν τα σφάλματα εισόδου είναι τυχαία και ανεξάρτητα. Για τη λύση Hamming απαιτούνται λιγότερα τμήματα επεξεργασίας, δεδομένου ότι το μέσο στρώμα απαιτεί μόνο ένα τμήμα ανά κατηγορία, αντί ενός τμήματος για κάθε κόμβο εισόδου. Και τελικά, το δίκτυο Hamming δεν πάσχει από τις ψεύτικες ταξινομήσεις που μπορούν να εμφανιστούν στο δίκτυο Hopfield. Τελικά, το δίκτυο Hamming είναι και γρηγορότερο και ακριβέστερο από το δίκτυο Hopfield.

3.13 TNA βασισμένα στη δουλειά του Kohonen

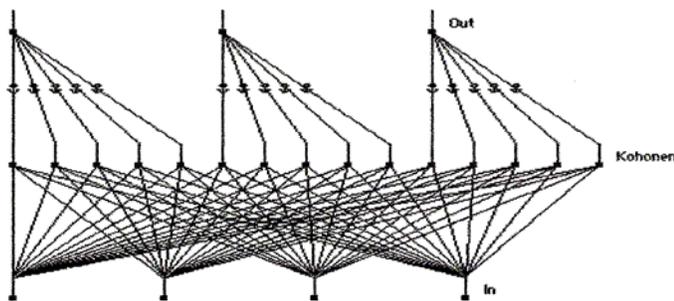
3.14 Learning Vector Quantization (Διανυσματική κβαντοποίηση εκμάθησης)

Αυτή η τοπολογία δικτύων προτάθηκε αρχικά από τον Tuevo Kohonen στα μέσα της

δεκαετίας του '80. μετά από την αρχική εργασία του στους self-organizing maps. Και αυτό το δίκτυο και οι self-organizing χάρτες είναι βασισμένοι στο στρώμα Kohonen, το οποίο είναι σε θέση να τακτοποιεί τα αντικείμενα σε κατάλληλες κατηγορίες παρόμοιων αντικειμένων. Συγκεκριμένα, η Learning Vector Quantization είναι ένα τεχνητό νευρωνικό πρότυπο δικτύων που χρησιμοποιείται και για τα προβλήματα ταξινόμησης και για τα προβλήματα κατάτμησης (segmentation) μιας εικόνας.

Το δίκτυο περιέχει ένα στρώμα εισόδου, ένα ενιαίο στρώμα Kohonen και ένα στρώμα εξόδου. Ένα τέτοιο δίκτυο φαίνεται στο Σχήμα 3.10. Το στρώμα εξόδου έχει τόσα τμήματα επεξεργασίας όσες είναι οι ευδιάκριτες κατηγορίες, ή οι τάξεις. Το στρώμα Kohonen έχει έναν αριθμό τμημάτων επεξεργασίας ομαδοποιημένα για κάθε μια από αυτές τις κατηγορίες. Ο αριθμός των τμημάτων επεξεργασίας ανά κατηγορία εξαρτάται από την πολυπλοκότητα της σχέσης εισόδου-εξόδου. Συνήθως, κάθε κατηγορία θα έχει τον ίδιο αριθμό τμημάτων σε όλο το στρώμα. Το στρώμα Kohonen είναι αυτό που μαθαίνει και εκτελεί τις συγγενικές ταξινομήσεις με τη βοήθεια ενός συνόλου κατάρτισης. Αυτό το δίκτυο χρησιμοποιεί εποπτευόμενους κανόνες εκμάθησης. Εντούτοις, αυτοί οι κανόνες ποικίλλουν σημαντικά από τους back-propagation κανόνες. Για να βελτιστοποιηθούν οι συναρτήσεις εκμάθησης και υπενθύμισης, το στρώμα εισόδου πρέπει να περιέχει ένα μόνο τμήμα επεξεργασίας για κάθε ξεχωριστή παράμετρο εισόδου. Θα μπορούσαν επίσης να χρησιμοποιηθούν δομές εισόδου υψηλής-τάξης.

Η Learning Vector Quantization ταξινομεί τα δεδομένα εισόδου της σε σχηματισμούς ομάδας που καθορίζει. Ουσιαστικά, χαρτογραφεί ένα n -διαστατικό διάστημα σε ένα m -διαστατικό διάστημα. Παίρνει n εισόδους και παράγει m εξόδους. Τα δίκτυα μπορούν να εκπαιδευθούν για να ταξινομήσουν τις εισόδους συντηρώντας την τοπολογία του συνόλου κατάρτισης. Οι χάρτες συντηρούν τις κοντινότερες σχέσεις γειτόνων στο σύνολο κατάρτισης έτσι ώστε τα σχέδια εισόδου που δεν είναι γνωστά από προηγουμένως να ταξινομηθούν από τους κοντινότερους γείτονές τους στα δεδομένα κατάρτισης.



Σχήμα 3. 10: Παράδειγμα του Learning Vector Quantization δικτύου.

Στον τρόπο κατάρτισης, αυτό το εποπτευόμενο δίκτυο χρησιμοποιεί το στρώμα Kohonen έτσι ώστε να υπολογίζεται η απόσταση ενός διανύσματος κατάρτισης σε κάθε τμήμα επεξεργασίας και το κοντινότερο τμήμα επεξεργασίας να δηλώνεται ως νικητής. Υπάρχει μόνο ένας νικητής για ολόκληρο το στρώμα. Ο νικητής θα επιτρέψει μόνο σε ένα τμήμα επεξεργασίας εξόδου να διεγερθεί, αναγγέλλοντας την τάξη ή την κατηγορία που το διάνυσμα εισόδου άνηκε. Εάν το τμήμα-νικητής είναι στην αναμενόμενη κατηγορία του

διανύσματος κατάρτισης, ενισχύεται προς το διάνυσμα κατάρτισης. Εάν δεν είναι στην κατηγορία του διανύσματος κατάρτισης, τα βάρη σύνδεσης που μπαίνουν στο τμήμα επεξεργασίας απομακρύνονται από το διάνυσμα κατάρτισης. Κατά τη διάρκεια αυτής της διαδικασίας κατάρτισης, τα μεμονωμένα τμήματα επεξεργασίας που κατατάσσονται σε μια ιδιαίτερη κατηγορία μεταναστεύουν στην περιοχή που συνδέεται με τη συγκεκριμένη κατηγορία τους.

Κατά τη διάρκεια του τρόπου ανάκλησης, υπολογίζεται η απόσταση ενός διανύσματος εισόδου με κάθε τμήμα επεξεργασίας και πάλι το κοντινότερο τμήμα δηλώνεται ως νικητής. Αυτό παράγει στη συνέχεια μια έξοδο, που δηλώνει μια ιδιαίτερη τάξη που βρίσκεται από το δίκτυο.

Υπάρχουν μερικές ανεπάρκειες με την Learning Vector Quantization αρχιτεκτονική. Προφανώς, για τα σύνθετα προβλήματα ταξινόμησης με παρόμοια αντικείμενα ή διανύσματα εισόδου, το δίκτυο απαιτεί ένα μεγάλο στρώμα Kohonen με πολλά τμήματα επεξεργασίας ανά κατηγορία. Αυτό μπορεί να υπερνικηθεί με επιλεκτικά καλύτερες επιλογές για τις παραμέτρους εισόδου.

Η απλή μορφή του Learning Vector Quantization δικτύου πάσχει από την ατέλεια που μερικά τμήματα επεξεργασίας τείνουν να κερδίσουν πάρα πολύ συχνά ενώ άλλα, στην πραγματικότητα, δεν κάνουν τίποτα. Αυτό συμβαίνει ιδιαίτερα όταν τα τμήματα επεξεργασίας αρχίζουν μακριά από τα διανύσματα κατάρτισης. Εδώ, μερικά τμήματα προσεγγίζονται κοντά (πολύ γρήγορα) και τα άλλα παραμένουν μόνιμα μακριά. Για να αντιμετωπιστεί αυτό το πρόβλημα, προστίθεται ένας μηχανισμός συνείδησης έτσι ώστε ένα τμήμα επεξεργασίας που κερδίζει πάρα πολύ συχνά να αναπτύσσει μια "ένοχη συνείδηση" και να τιμωρείται. Ο πραγματικός μηχανισμός συνείδησης είναι μια distance bias που προστίθεται σε κάθε τμήμα επεξεργασίας.

Ο αλγόριθμος ρύθμισης του ορίου χρησιμοποιείται για να καθαρίσει μια λύση μόλις βρεθεί μια σχετικά καλή λύση. Αυτός ο αλγόριθμος επηρεάζει τις περιπτώσεις όπου το νικητήριο τμήμα επεξεργασίας είναι στη λανθασμένη κατηγορία και το δεύτερο καλύτερο τμήμα επεξεργασίας είναι στη σωστή κατηγορία. Ένας περαιτέρω περιορισμός είναι ότι το διάνυσμα κατάρτισης πρέπει να είναι κοντά στο μεσαίο σημείο του διαστήματος ενώνοντας αυτά τα δύο τμήματα επεξεργασίας. Το νικητήριο λανθασμένο τμήμα επεξεργασίας απομακρύνεται από το διάνυσμα κατάρτισης και το δεύτερο τμήμα κινείται προς το διάνυσμα κατάρτισης. Αυτή η διαδικασία καθαρίζει το όριο μεταξύ των περιοχών όπου προκύπτουν συνήθως φτωχές ταξινομήσεις.

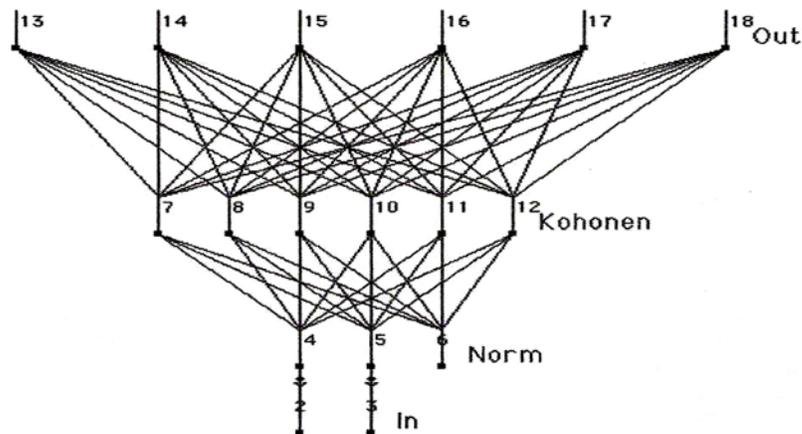
3.15 Δίκτυο αντίθετης διάδοσης (Counter Propagation Network)

Ο Robert Hecht-Nielsen ανέπτυξε το δίκτυο αντίθετης διάδοσης, για να συνδυάσει ένα ανεπίβλεπτο στρώμα Kohonen με ένα διδάξιμο στρώμα εξόδου. Αυτό είναι μια ακόμα τοπολογία για να συνθέσει σύνθετα προβλήματα ταξινόμησης, προσπαθώντας να ελαχιστοποιήσει τον αριθμό τμημάτων επεξεργασίας και του χρόνου εκμάθησης. Η λειτουργία για το δίκτυο αντίθετης-διάδοσης είναι παρόμοια με αυτήν του Learning Vector Quantization δικτύου δεδομένου ότι το μέσο στρώμα Kohonen ενεργεί ως προσαρμοστικός look-up πίνακας, βρίσκοντας την πιο στενή αντιπροσώπευση σε ένα ερέθισμα εισόδου και βγάζοντας ως έξοδο την ισοδύναμη χαρτογράφησης του.

Το πρώτο δίκτυο αντίθετης-διάδοσης αποτελούνταν από μια αμφίδρομη χαρτογράφηση μεταξύ των στρωμάτων εισόδου και εξόδου. Στην ουσία, ενώ τα δεδομένα

παρουσιάζονται στο στρώμα εισόδου για να παραγάγει ένα σχέδιο ταξινόμησης στο στρώμα εξόδου, το στρώμα εξόδου στη συνέχεια θα δεχόταν ένα πρόσθετο διάνυσμα εισόδου και θα παράγαγε μια ταξινόμηση εξόδου στο στρώμα εισόδου του δικτύου. Το δίκτυο πήρε το όνομά του από αυτήν την αντίθετη ροή των πληροφοριών δια μέσω της δομής του. Οι κατασκευαστές για την ανάπτυξη χρησιμοποιούν μια παραλλαγή, μονής-ροής παραλλαγή αυτής της επίσημης αντιπροσώπευσης της αντίθετης-διάδοσης. Με άλλα λόγια υπάρχει μόνο μια feedforward πορεία από το στρώμα εισόδου στο στρώμα εξόδου.

Ένα παράδειγμα παρουσιάζεται στο Σχήμα 3.11. Το μονο-κατευθυνόμενο δίκτυο αντίθετης-διάδοσης έχει τρία στρώματα. Εάν οι εισοδοί δεν είναι ήδη ομαλοποιημένες προτού να εισαχθούν στο δίκτυο, μερικές φορές προστίθεται ένα τέταρτο στρώμα. Τα κύρια στρώματα περιλαμβάνουν ένα στρώμα απομονωτή εισόδου, ένα self-organizing στρώμα Kohonen, και ένα στρώμα εξόδου που χρησιμοποιεί τον Delta κανόνα για να τροποποιήσει τα εισερχόμενα βάρη σύνδεσής του. Μερικές φορές αυτό το στρώμα καλείται στρώμα Grossberg Outstar.



Σχήμα 3. 11: Παράδειγμα του Counter-propagation δικτύου.

Το μέγεθος του στρώματος εισόδου εξαρτάται από το πόσες ξεχωριστές παράμετροι καθορίζουν το πρόβλημα. Με πολύ λίγες, το δίκτυο μπορεί να μην γενικεύσει επαρκώς. Με πάρα πολλές ο χρόνος επεξεργασίας είναι πολύ μεγάλος.

Για να λειτουργήσει το δίκτυο κατάλληλα, πρέπει το διάνυσμα εισόδου να ομαλοποιηθεί. Αυτό σημαίνει ότι για κάθε συνδυασμό τιμών εισόδου, το συνολικό "μήκος" του διανύσματος εισόδου πρέπει να καταλήγει σε 1. Αυτό μπορεί να γίνει με ένα προεπεξεργαστή, προτού τα δεδομένα εισαχθούν στο δίκτυο αντίθετης-διάδοσης. Η μπορεί να προστεθεί ένα στρώμα ομαλοποίησης μεταξύ της εισόδου και των στρωμάτων Kohonen. Το στρώμα αυτό απαιτεί ένα τμήμα επεξεργασίας για κάθε είσοδο, συν ένα ακόμα για ένα τμήμα ισορροπίας. Αυτό το στρώμα τροποποιεί την είσοδο που τίθεται, πριν πάει στο στρώμα Kohonen για να εγγυηθεί ότι όλα τα σύνολα εισόδου συνδυάζουν το ίδιο σύνολο.

Η ομαλοποίηση των εισόδων είναι απαραίτητη για να ασφαλίσει ότι το στρώμα Kohonen

βρίσκει τη σωστή τάξη για το πρόβλημα. Χωρίς αυτή, τα μεγαλύτερα διανύσματα εισόδου προκαταλαμβάνουν πολλά από τα τμήματα επεξεργασίας Kohonen έτσι ώστε τα πιο αδύναμα σύνολα αξίας εισόδου να μην μπορούν να ταξινομηθούν κατάλληλα. Λόγω της ανταγωνιστικής φύσης του στρώματος Kohonen, τα διανύσματα εισόδου μεγαλύτερης αξίας εξουδετερώνουν τα μικρότερα διανύσματα. Η αντίθετη-διάδοση χρησιμοποιεί ένα στάνταρ παράδειγμα Kohonen το οποίο αυτο-οργανώνει τα σύνολα εισόδου στις ζώνες ταξινόμησης. Ακολουθεί τον κλασικό νόμο εκμάθησης Kohonen. Αυτό το στρώμα ενεργεί ως nearest neighbor classifier δεδομένου ότι τα τμήματα επεξεργασίας στο ανταγωνιστικό στρώμα ρυθμίζουν αυτόνομα τα βάρη των συνδέσεων τους για να κατανεύμουν το διανυσματικό διάστημα εισόδου (κατά προσέγγιση) στην συχνότητα με την οποία οι εισοδοί εμφανίζονται. Πρέπει να είναι τουλάχιστον τόσα τμήματα επεξεργασίας στο στρώμα Kohonen όσες είναι οι κατηγορίες εξόδου. Το στρώμα Kohonen έχει συνήθως πολλά περισσότερα τμήματα από ότι οι κατηγορίες επειδή τα πρόσθετα τμήματα επεξεργασίας παρέχουν μια λεπτότερη ανάλυση μεταξύ παρόμοιων αντικειμένων.

Το στρώμα εξόδου για την αντίθετη-διάδοση είναι βασικά φτιαγμένο από τμήματα επεξεργασίας που μαθαίνουν να παράγουν μια έξοδο όταν εφαρμόζεται μια συγκεκριμένη είσοδος. Δεδομένου ότι το στρώμα Kohonen περιλαμβάνει ανταγωνισμό παράγεται μόνο μια έξοδος για ένα δεδομένο διάνυσμα εισόδου. Αυτό το στρώμα παρέχει έναν τρόπο αποκρυπτογράφησης αυτής της εισόδου σε μια σημαντική κατηγορία εξόδου. Χρησιμοποιεί τον Delta κανόνα για να διαδοθεί προς τα πίσω το λάθος μεταξύ της επιθυμητής κατηγορίας εξόδου και της πραγματικής εξόδου που παράγεται με το σύνολο κατάρτισης. Τα λάθη ρυθμίζουν μόνο τα βάρη των συνδέσεων που μπαίνουν στο στρώμα εξόδου. Το στρώμα Kohonen δεν επηρεάζεται.

Δεδομένου ότι μόνο μια έξοδος από το ανταγωνιστικό στρώμα Kohonen είναι ενεργή κάθε φορά και όλα τα άλλα τμήματα είναι μηδέν, τα μόνα βάρη που είναι ρυθμισμένα για τα τμήματα επεξεργασίας εξόδου είναι αυτά που συνδέονται με το νικητήριο τμήμα στο ανταγωνιστικό στρώμα. Κατ' αυτό τον τρόπο το στρώμα εξόδου μαθαίνει να αναπαράγει ένα ορισμένο σχέδιο για κάθε ενεργό τμήμα επεξεργασίας στο ανταγωνιστικό στρώμα. Εάν διάφορα ανταγωνιστικά τμήματα ανήκουν στην ίδια κατηγορία, εκείνο το τμήμα επεξεργασίας εξόδου θα εξελίξει τα βάρη σε απάντηση σε εκείνα τα ανταγωνιστικά τμήματα επεξεργασίας και μηδέν για όλα τα άλλα.

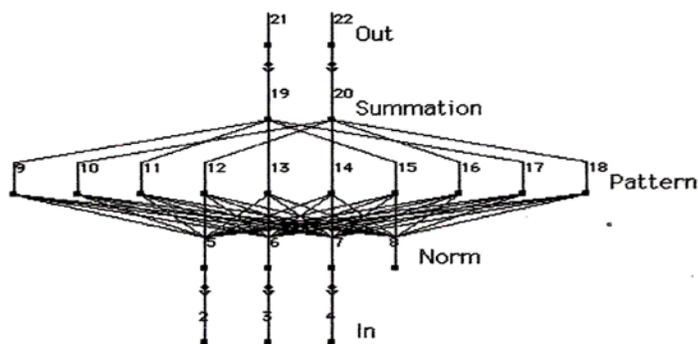
Υπάρχει ένα πρόβλημα που θα μπορούσε να προκύψει με αυτήν την αρχιτεκτονική. Το ανταγωνιστικό στρώμα Kohonen μαθαίνει χωρίς οποιαδήποτε επίβλεψη. Δεν ξέρει σε ποια κατηγορία αποκρίνεται. Αυτό σημαίνει ότι είναι δυνατό για ένα τμήμα επεξεργασίας στο στρώμα Kohonen να μάθει να παίρνει την ευθύνη για δύο ή περισσότερες εισόδους κατάρτισης που ανήκουν σε διαφορετικές κατηγορίες. Όταν αυτό συμβαίνει, η έξοδος του δικτύου θα είναι διαφορετούμενη για οποιεσδήποτε εισόδους που ενεργοποιούν αυτό το τμήμα επεξεργασίας. Για να αντιμετωπιστεί αυτό το πρόβλημα, τα τμήματα επεξεργασίας στο στρώμα Kohonen θα μπορούσαν να έχουν σαν προϋπόθεση να μάθουν μόνο για μια ιδιαίτερη κατηγορία.

3.16 Πιθανολογικό νευρωνικό δίκτυο (Probabilistic Neural Network)

Το πιθανολογικό νευρωνικό δίκτυο αναπτύχθηκε από το Donald Specht. Αυτό το δίκτυο παρέχει μια γενική λύση στα προβλήματα ταξινόμησης σχεδίων ακολουθώντας μια προσέγγιση που αναπτύσσεται με στατιστικές, αποκαλούμενες Bayesian ταξινομητές (classifiers). Η θεωρία Bayes, που αναπτύχθηκε στη δεκαετία του '50, λαμβάνει υπόψη τη σχετική πιθανότητα των γεγονότων και χρησιμοποιεί προγενέστερες πληροφορίες για να βελτιώσει την πρόβλεψη.

Το probabilistic νευρωνικό δίκτυο χρησιμοποιεί ένα σύνολο εποπτευμένης κατάρτισης για να αναπτύξει τις συναρτήσεις κατανομής μέσα σε ένα στρώμα σχεδίου. Αυτές οι συναρτήσεις, στον τρόπο ανάκλησης (recall mode), χρησιμοποιούνται για να υπολογίσουν την πιθανότητα ενός διάνυσματος εισόδου χαρακτηριστικού γνωρίσματος να είναι μέρος μιας κατηγορίας η οποία είναι γνωστή. Εάν η σχετική συχνότητα των κατηγοριών είναι άγνωστη, κατόπιν όλες οι κατηγορίες μπορούν να υποτίθεται ότι είναι εξίσου πιθανές και ο προσδιορισμός της κατηγορίας είναι απλώς βασισμένος στη στενότητα του διανύσματος εισόδου χαρακτηριστικών γνωρισμάτων στη συνάρτηση κατανομής μιας κατηγορίας.

Ένα παράδειγμα ενός τέτοιου νευρωνικού δικτύου παρουσιάζεται στο Σχήμα 3.12. Αυτό το δίκτυο έχει τρία στρώματα. Το δίκτυο περιέχει ένα στρώμα εισόδου που έχει τόσα τμήματα όσες είναι οι ξεχωριστές παράμετροι που απαιτούνται για να περιγράψουν τα αντικείμενα που ταξινομούνται. Έχει ένα στρώμα σχεδίου, το οποίο οργανώνει το σύνολο κατάρτισης έτσι ώστε κάθε διάνυσμα εισόδου να αντιπροσωπεύεται από ένα μεμονωμένο τμήμα επεξεργασίας. Και τελικά, το δίκτυο περιέχει ένα στρώμα εξόδου, αποκαλούμενο στρώμα αθροίσματος, το οποίο έχει τόσα τμήματα επεξεργασίας όσες είναι οι κατηγορίες που αναγνωρίζονται. Μερικές φορές προστίθεται ένα τέταρτο στρώμα για να ομαλοποιήσει το διάνυσμα εισόδου, εάν οι εισοδοί προτού να εισαχθούν στο δίκτυο δεν είναι ήδη ομαλοποιημένες. Όπως με το δίκτυο αντίθετης-διάδοσης, το διάνυσμα εισόδου πρέπει να ομαλοποιηθεί σε παρεχόμενο κατάλληλο χωρισμό αντικειμένου στο στρώμα σχεδίου.



Σχήμα 3. 12: Παράδειγμα ενός Probabilistic νευρωνικού δικτύου.

Στο στρώμα προτύπου, υπάρχει ένα τμήμα επεξεργασίας για κάθε διάνυσμα εισόδου στο σύνολο κατάρτισης. Κανονικά, υπάρχει ίσος αριθμός τμημάτων επεξεργασίας για κάθε κατηγορία εξόδου. Διαφορετικά, μια ή περισσότερες κατηγορίες μπορούν να στραφούν ανακριβώς και το δίκτυο θα παραγάγει φτωχά αποτελέσματα. Κάθε τμήμα επεξεργασίας

στο στρώμα σχεδίου εκπαιδεύεται μία φορά. Ένα τμήμα εκπαιδεύεται για να παραγάγει μια υψηλή αξία εξόδου όταν ένα διάνυσμα εισόδου ταιριάζει με το διάνυσμα κατάρτισης. Η συνάρτηση κατάρτισης μπορεί να περιλαμβάνει έναν παράγοντα ομαλοποίησης για να γενικεύσει καλύτερα τα αποτελέσματα ταξινόμησης. Σε κάθε περίπτωση, τα διανύσματα κατάρτισης δεν είναι απαραίτητο να είναι σε κάποια συγκεκριμένη σειρά στο σύνολο κατάρτισης, δεδομένου ότι η κατηγορία ενός ιδιαίτερου διανύσματος διευκρινίζεται από την επιθυμητή έξοδο της εισόδου. Η συνάρτηση εκμάθησης απλά επιλέγει το πρώτο ανεκπαιδευτο δεδομένο επεξεργασίας στη σωστή κατηγορία εξόδου και τροποποιεί τα βάρη της για να ταιριάζει με το διάνυσμα κατάρτισης.

Μόνο μια κατηγορία ταξινόμησης παράγεται για οποιοδήποτε δεδομένο διάνυσμα εισόδου. Εάν η είσοδος δεν συσχετίζεται καλά με οποιαδήποτε σχέδιο που προγραμματίζεται στο στρώμα σχεδίου, δεν παράγεται καμία έξοδος.

Η κατάρτιση του πιθανολογικού νευρωνικού δικτύου είναι πολύ απλούστερη απ' ότι του back-propagation. Εντούτοις, το στρώμα σχεδίου μπορεί να είναι αρκετά τεράστιο εάν η διάκριση μεταξύ των κατηγοριών ποικίλει. Υπάρχουν πολλοί υπερασπιστές για αυτόν τον τύπο δικτύου, δεδομένου ότι η προκαταρκτική εργασία για τη βελτιστοποίηση βασίζεται στα περίφημα κλασσικά μαθηματικά.

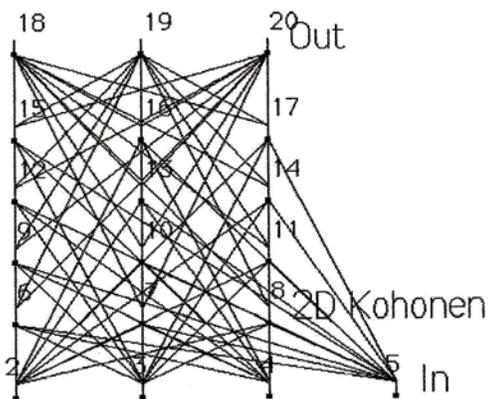
3.17 Self-Organizing Map

Αναπτυγμένο από τον Teuvo Kohonen στις αρχές της δεκαετίας του '80, τα δεδομένα εισόδου προβάλλεται σε ένα δισδιάστατο στρώμα που διατηρεί τη σειρά, συμπίπτει τα δεδομένα, και διαδίδει έξω τα συμπαγή δεδομένα. Με άλλα λόγια, εάν δύο διανύσματα εισόδου είναι κοντά, θα χαρτογραφηθούν στα τμήματα επεξεργασίας που είναι κοντά στο δισδιάστατο στρώμα Kohonen που αντιπροσωπεύει τα χαρακτηριστικά γνωρίσματα των δεδομένων εισόδου. Εδώ, τα τμήματα επεξεργασίας αντιπροσωπεύουν έναν δισδιάστατο χάρτη δεδομένων εισόδου.

Η αρχική χρήση του self-organizing map είναι να απεικονιστούν οι τοπολογίες και οι ιεραρχικές δομές των διαστατικών διαστημάτων εισόδου υψηλής-σειράς. Το self-organizing δίκτυο έχει χρησιμοποιηθεί για να δημιουργήσει τις γεμισμένες-περιοχές καμπύλων στο δισδιάστατο διάστημα που δημιουργείται από το στρώμα Kohonen. Το στρώμα Kohonen μπορεί επίσης να χρησιμοποιηθεί για τα προβλήματα βελτιστοποίησης επιτρέποντας στα βάρη σύνδεσης να ρυθμιστούν σε ένα ελάχιστο ενεργειακό πρότυπο.

Μια βασική διαφορά μεταξύ αυτού του δικτύου και πολλών άλλων δικτύων είναι ότι ο self-organizing map μαθαίνει χωρίς επίβλεψη. Εντούτοις, όταν συνδυάζεται με άλλα νευρωνικά στρώματα για την πρόβλεψη ή την κατηγοριοποίηση, το δίκτυο μαθαίνει αρχικά με έναν ανεπίβλεπτο τρόπο και έπειτα μεταπηδά σε έναν εποπτευόμενο τρόπο για το δίκτυο με το οποίο είναι συνδεδεμένο.

Ένα παράδειγμα παρουσιάζεται στο Σχήμα 3.13. Ο self-organizing map έχει τυπικά δύο στρώματα. Το στρώμα εισόδου συνδέεται πλήρως με ένα δισδιάστατο στρώμα Kohonen. Το στρώμα εξόδου που παρουσιάζεται χρησιμοποιείται σε ένα πρόβλημα κατηγοριοποίησης και αντιπροσωπεύει τρεις κατηγορίες στις οποίες μπορεί να ανήκει το διάνυσμα εισόδου. Αυτό το στρώμα εξόδου τυπικά μαθαίνει χρησιμοποιώντας τον Delta κανόνα και είναι παρόμοιο σε λειτουργία με τον παράδειγμα αντίθετης-διάδοσης (counter propagation).



Σχήμα 3. 13: Ένα Παράδειγμα Self-organizing Map Δικτύου.

Τα τμήματα επεξεργασίας Kohonen: κάθε ένα μετρά την Ευκλείδεια απόσταση των βαρών του από τις εισερχόμενες τιμές εισόδου. Κατά τη διάρκεια της ανάκλησης, το τμήμα Kohonen με την ελάχιστη απόσταση είναι ο νικητής και βγάζει έναν άσσο (1) στο στρώμα εξόδου, ενδεχομένως. Αυτή είναι μια ανταγωνιστική νίκη, έτσι όλα τα άλλα τμήματα επεξεργασίας αναγκάζονται σε μηδέν για εκείνο το διάνυσμα εισόδου. Κατά συνέπεια το νικητήριο τμήμα επεξεργασίας είναι το πλησιέστερο στην αξία εισόδου και αντιπροσωπεύει έτσι την αξία εισόδου στο δισδιάστατο χάρτη Kohonen. Έτσι τα δεδομένα εισόδου που μπορεί να έχουν πολλές διαστάσεις, έρχονται να αντιπροσωπευθούν από ένα δισδιάστατο διάνυσμα το οποίο διατηρεί τη σειρά των υψηλότερων διαστατικών δεδομένων εισόδου.

Κατά τη διάρκεια της κατάρτισης, το τμήμα επεξεργασίας Kohonen με τη μικρότερη απόσταση ρυθμίζει το βάρος του ώστε να είναι πλησιέστερο στις τιμές των δεδομένων εισόδου. Οι γείτονες του νικητήριου τμήματος ρυθμίζουν επίσης τα βάρη τους για να είναι πλησιέστεροι στο ίδιο διάνυσμα δεδομένων εισόδου. Η ρύθμιση των γειτονικών τμημάτων επεξεργασίας συμβάλλει στη διατήρηση της σειράς του διαστήματος εισόδου. Η κατάρτιση γίνεται με τον ανταγωνιστικό κανόνα εκμάθησης Kohonen.

Σε αυτό το παράδειγμα παρουσιάζεται το πρόβλημα ύπαρξης ενός μόνο τμήματος επεξεργασίας που αναλαμβάνει μια περιοχή και αντιπροσωπεύει πάρα πολλά δεδομένα εισόδου. Όπως με την αντίθετη-διάδοση, αυτό το πρόβλημα λύνεται από έναν μηχανισμό συνείδησης που χτίζεται στη συνάρτηση εκμάθησης. Ο κανόνας αυτός εξαρτάται από τη διατήρηση ενός αρχείου, του πόσο συχνά κάθε τμήμα επεξεργασίας Kohonen κερδίζει και αυτές οι πληροφορίες χρησιμοποιούνται έπειτα κατά τη διάρκεια της κατάρτισης για τη μέτρηση της distance bias. Αυτός ο μηχανισμός συνείδησης βοηθά το στρώμα Kohonen να επιτύχει το ισχυρότερο όφελός του. Τα τμήματα επεξεργασίας φυσικά αντιπροσωπεύουν τις περίπου ίσες πληροφορίες για το σύνολο δεδομένων εισόδου. Όπου το διάστημα εισόδου έχει τα αραιά δεδομένα, η αντιπροσώπευση συμπιέζεται στο διάστημα Kohonen, ή το χάρτη. Το διάστημα εισόδου έχει υψηλή συμπίεση (density), τα αντιπροσωπευτικά τμήματα Kohonen διαδίδουν για να επιτρέψουν τη καλύτερη διαφοροποίηση. Κατ' αυτό τον τρόπο το στρώμα Kohonen θεωρείται ότι μιμείται την αντιπροσώπευση γνώσης των βιολογικών συστημάτων.

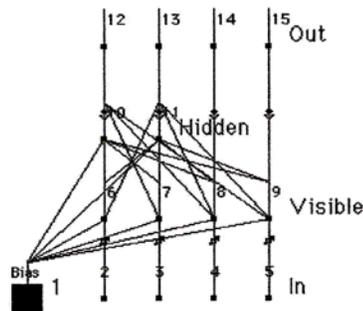
3.18 Επανακυκλοφορία (Recirculation)

Τα δίκτυα επανακυκλοφορίας εισήχθησαν από τους Geoffrey Hinton και James McClelland σαν μια βιολογικά εύλογη εναλλακτική λύση των back-propagation δικτύων. Σε ένα back-propagation δίκτυο, τα λάθη περνούν προς τα πίσω μέσω των ίδιων συνδέσεων που χρησιμοποιούνται στο feedforward μηχανισμό με μία πρόσθετη διαβάθμιση (scaling) από την παράγωγο της feedforward συνάρτησης μεταφοράς. Αυτό καθιστά το back-propagation αλγόριθμο δύσκολο να εφαρμοστεί στο ηλεκτρονικό hardware.

Σε ένα δίκτυο επανακυκλοφορίας τα δεδομένα υποβάλλονται σε επεξεργασία σε μια κατεύθυνση μόνο και η εκμάθηση γίνεται χρησιμοποιώντας μόνο την τοπική γνώση.

Ειδικότερα, η γνώση προέρχεται από την κατάσταση του τμήματος επεξεργασίας και την αξία της εισόδου στη συγκεκριμένη σύνδεση που προσαρμόζεται. Τα δίκτυα επανακυκλοφορίας χρησιμοποιούν την ανεπίβλεπτη εκμάθηση έτσι κανένα επιθυμητό διάνυσμα εξόδου δεν απαιτείται να παρουσιαστεί στο στρώμα εξόδου. Το δίκτυο είναι αυτο-συνδιαστικό (autoassociative), όπου υπάρχει ο ίδιος αριθμός εξόδων με τις εισόδους.

Αυτό το δίκτυο έχει δύο στρώματα μεταξύ των στρωμάτων εισόδου και εξόδου, αποκαλούμενων ορατά και κρυμμένα στρώματα. Ο σκοπός του κανόνα εκμάθησης είναι να κατασκευάσει στο κρυμμένο στρώμα μια εσωτερική αντιπροσώπευση των δεδομένων που παρουσιάζονται στο ορατό στρώμα. Μια σημαντική περίπτωση αυτού είναι να συμπιεστούν τα δεδομένα εισόδου χρησιμοποιώντας λιγότερα τμήματα επεξεργασίας στο κρυμμένο στρώμα. Σε αυτήν την περίπτωση, η κρυμμένη αντιπροσώπευση μπορεί να θεωρηθεί μια συμπιεσμένη έκδοση της ορατής αντιπροσώπευσης. Τα ορατά και κρυμμένα στρώματα συνδέονται πλήρως το ένα με το άλλο και στις δύο κατευθύνσεις. Επίσης, κάθε τμήμα και στα κρυμμένα και στα ορατά στρώματα συνδέεται με ένα bias τμήμα. Αυτές οι συνδέσεις έχουν μεταβλητά βάρη που μαθαίνουν με τον ίδιο τρόπο με τα άλλα μεταβλητά βάρη στο δίκτυο.



Σχήμα 3. 14: Ένα Παράδειγμα Recirculation Δικτύου.

Εδώ, το δεδομένο εισόδου παρουσιάζεται στο ορατό στρώμα και μεταφέρεται προς το κρυμμένο στρώμα. Το κρυμμένο στρώμα περνά τα εισερχόμενα δεδομένα πίσω στο ορατό, το οποίο περνά στη συνέχεια τα αποτελέσματα πίσω στο κρυμμένο στρώμα και μέχρι το στρώμα εξόδου. Είναι το δεύτερο πέρασμα μέσω του κρυμμένου στρώματος

όπου η εκμάθηση εμφανίζεται. Με τον τρόπο αυτό τα δεδομένα εισόδου διανέμονται εκ νέου μέσω της δικτυακής αρχιτεκτονικής.

Κατά τη διάρκεια της κατάρτισης η έξοδος του κρυμμένου στρώματος στο πρώτο πέρασμα είναι η κωδικοποιημένη έκδοση του διανύσματος εισόδου. Η έξοδος του ορατού στρώματος στο επόμενο πέρασμα είναι η ανασυγκρότηση του αρχικού διανύσματος εισόδου από το κωδικοποιημένο διάνυσμα στο κρυμμένο στρώμα. Ο στόχος της εκμάθησης είναι να μειωθεί το λάθος μεταξύ του ανασυγκροτημένου διανύσματος και του διανύσματος εισόδου. Αυτό το λάθος απεικονίζεται επίσης στη διαφορά μεταξύ των εξόδων του κρυμμένου στρώματος στα πρώτα και στα τελικά περάσματα. Η εκμάθηση επιδιώκει να μειώσει το λάθος ανασυγκρότησης στο κρυμμένο στρώμα επίσης.

Στις περισσότερες εφαρμογές του δικτύου, ένα σήμα δεδομένων εισόδου ομαλοποιείται με τη συμπίεση έπειτα ανασυγκροτεί το διάνυσμα εισόδου στο στρώμα εξόδου. Το δίκτυο ενεργεί σαν low bandpass φίλτρο, του οποίου το σημείο μετάβασης ελέγχεται από τον αριθμό των κρυμμένων κόμβων.

Εφαρμογές των Νευρωνικών Δικτύων

4.1 Αναγνώριση Προτύπου (Pattern Recognition)

Εισαγωγή

Μια ενδιαφέρουσα εφαρμογή των νευρωνικών δικτύων είναι η αναγνώριση προτύπου (pattern recognition). Χρησιμοποιείται ευρύτατα σε βιομηχανικές εφαρμογές όπως αυτόματος έλεγχος βιομηχανικών προϊόντων, αυτοματισμός της παραγωγής, ποιότητα του τελικού προϊόντος καθώς και αναγνώριση ταχυδρομικών διευθύνσεων.

Η αναγνώριση χαρακτήρων (Character Recognition) αποτελεί ένα μέρος της αναγνώρισης σχημάτων (Pattern Recognition). Οι αλγόριθμοι οι οποίοι θα αναλυθούν παρακάτω αποτελούν τα βασικά νευρώνια τα οποία αποτελούν τη βάση και αρχή λειτουργίας των τεχνητής νοημοσύνης προγραμμάτων (Artificial Intelligence programs) τα οποία αναγνωρίζουν γράμματα και γενικότερα χαρακτήρες.

Ένας απλός αλγόριθμος αναγνώρισης χαρακτήρα

Για να αναγνωριστεί ένα γράμμα της αλφαβήτου, π.χ. το Ε, έχουμε αναλύσει τον χαρακτήρα σε μία 21x21 μήτρα που αποτελείται από 'άσσους' (1) και 'μηδενικά' (0). Η βασική ιδέα για την αναγνώριση είναι να 'σπάσει' η μήτρα σε εννέα μικρότερα κομμάτια στα οποία θα αναζητηθούν βασικά τμήματα (οριζόντια, κάθετα και διαγώνια) συστοιχίας 'άσπων' (1). Αυτές οι συστοιχίες θα αποτελέσουν το χαρακτηριστικό πρότυπο μέσω του οποίου γίνεται η αναγνώριση του χαρακτήρα.

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Σχήμα 4. 1: Το γράμμα Ε σαν πίνακας από 'άσσους' και 'μηδενικά'. Η περιοχή έχει διασπαστεί σε 9 υποπεριοχές.

Οι οριζόντιες, κάθετες και διαγώνιες συστοιχίες 'άσσων' τις οποίες θα αναζητήσει ο αλγόριθμος να βρει σε κάθε μία από τις 9 υποπεριοχές αναπαρίστανται παρακάτω.

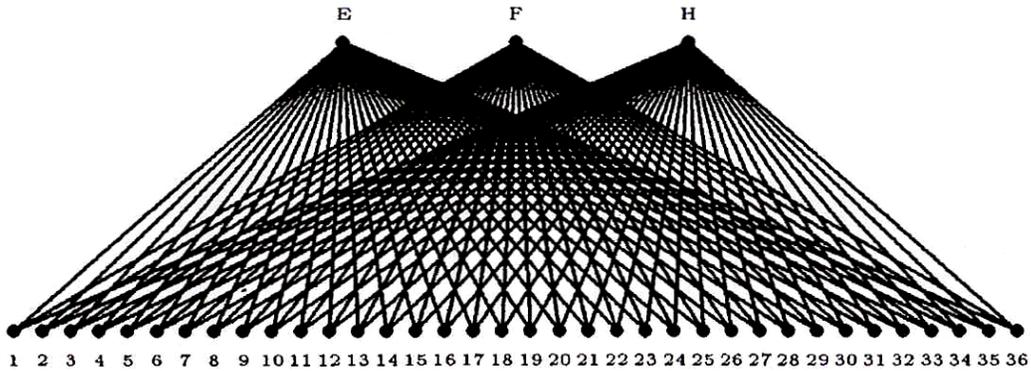
	1	
	1	
	1	

1	1	1

1		
	1	
		1

		1
	1	
1		

Οι απαντήσεις τώρα προσεγγίζουν περισσότερο την πραγματικότητα. Ο αλγόριθμος αυτός αποτελεί ένα μέρος του νευρωνικού δικτύου το οποίο χρησιμοποιείται για αναγνώριση χαρακτήρων μεταξύ 36 επιλογών.



Η σχέση που μας δίνει των 36 εισόδων σε συνδυασμό με το βάρος $w_{j,k}$ και της εξόδου k είναι η παρακάτω:

$$o_k = \sum_{j=1,36} w_{j,k} i_j$$

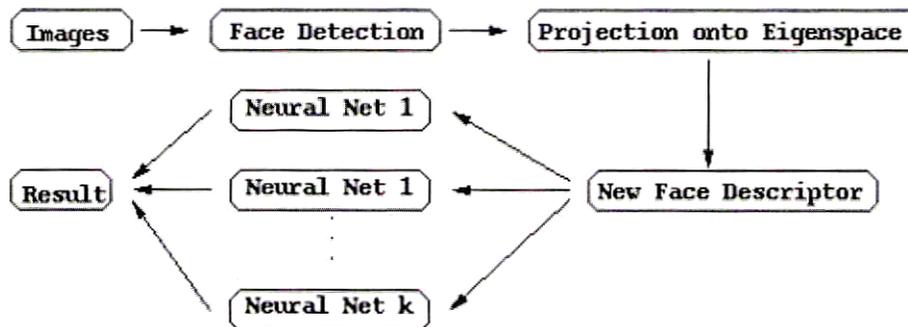
4.2 Αναγνώριση Προσώπου (Face Recognition)

Λαμβάνοντας υπόψη μια εικόνα ανθρώπινου προσώπου, αυτή συγκρίνεται με τα πρότυπα της βάση δεδομένων και αναφέρεται ποια είναι εάν υπάρχει. Εδώ η εικόνα είναι gray scale, σε κάθετα προσανατολισμένη μετωπική άποψη. Επιτρέπεται η κανονική παραλλαγή έκφρασης και η εικόνα προετοιμάζεται κάτω από κατά προσέγγιση σταθερό φωτισμό.

Επειδή συνήθως οι εικόνες είναι μεγαλύτερες από τα πραγματικά πρόσωπα, το πρώτο πρόβλημα είναι να βρεθεί το πρόσωπο στην εικόνα, ή η ανίχνευση προσώπου που είναι ένα άλλο πολύ σχετικό πρόβλημα. Εδώ χρησιμοποιείται ο κώδικας ανίχνευσης προσώπου από τον Kah-Kay Sung από το εργαστήριο τεχνητής νοημοσύνης MIT Artificial Intelligence Lab. Με κάποια αλλαγή στον κώδικα τρέχει γρηγορότερα και εντοπίζει το πρόσωπο ακριβέστερα.

Η ανάλυση κύριων τμημάτων εφαρμόζεται για να βρει τις πτυχές του προσώπου που είναι σημαντικές για τον προσδιορισμό. Τα Eigenvectors (eigenfaces) υπολογίζονται από το αρχικό σύνολο εικόνων προσώπου. Τα βάρη χρησιμοποιούνται για να προσδιορίσουν τα πρόσωπα.

Το νευρωνικό δίκτυο χρησιμοποιείται για να δημιουργήσει τη βάση δεδομένων προσώπων και να αναγνωρίσει το πρόσωπο. Για κάθε πρόσωπο χτίζεται ένα χωριστό δίκτυο. Το πρόσωπο εισόδου προβάλλεται πρώτα πάνω στο eigenface διάστημα και παίρνει έναν νέο περιγραφέα. Ο νέος περιγραφέας χρησιμοποιείται ως δίκτυο εισόδου και εφαρμόζεται στο δίκτυο κάθε προσώπου. Επιλέγεται αυτό, με τη μέγιστη έξοδο και αναφέρεται ως οικοδεσπότης (host) εάν περνά το προκαθορισμένο κατώτατο όριο αναγνώρισης.



Σχήμα 4.2: Δομή Αναγνώρισης Προσώπου

Ανίχνευση προσώπου

Το πρόβλημα πριν από την αναγνώριση ενός προσώπου είναι η ανίχνευση η οποία βρίσκει το πρόσωπο μέσα στην εικόνα. Εδώ χρησιμοποιείται ο κώδικας από το εργαστήριο τεχνητής νοημοσύνης MIT (παρακάτω τον καλούμε κώδικα ανίχνευσης προσώπου) για να εντοπίσει το πρόσωπο μέσα στην εικόνα.

Η χρησιμοποίηση του κώδικα ανίχνευσης προσώπου για να προετοιμάσει το πρόσωπο όχι μόνο διευκολύνει το πρόβλημα της αναγνώρισης, αλλά και καθορίζει ομοιόμορφα

πρότυπα ως προς το ποιο μέρος της εικόνας πρέπει να χρησιμοποιηθεί ως πρόσωπο, το οποίο δεν μπορεί να επιτευχθεί μέσω της κατάτμησης δια χειρός (hand segmentation).

Ο κώδικας ανίχνευσης προσώπου ψάχνει το πρόσωπο με εξαντλητική ανίχνευση της εικόνας σε όλες τις πιθανές κλίμακες. Ο Kah-Kay Sun ξεκίνησε το μέγεθος των σχεδίων προσώπου από 20x20 pixels και το αύξησε από μια κλίμακα (0.1). Στην περίπτωση που έχουμε εδώ, ψάχνουμε ένα συγκεκριμένο τμήμα της εικόνας (συνήθως από 40% έως 80%) για το πρόσωπο. Θα βοηθήσει να επιταχυνθεί η διαδικασία ανίχνευσης προσώπου. Εάν το πραγματικό μέγεθος προσώπου είναι μεγάλο, η γραμμική αύξηση του μεγέθους του πρότυπου προσώπου θα οδηγήσει στη χονδροειδή (coarse) θέση προσώπου. Έτσι αυξάνουμε το μέγεθος του προτύπου του προσώπου αριθμητικά από 4 pixels σε κάθε βήμα για να εντοπίσουμε το πρόσωπο ακριβέστερα.

Για κάθε παράθυρο προτύπου, μια σειρά 3 προτύπων εφαρμόζεται διαδοχικά για να καθορίσει εάν η εικόνα εισόδου είναι ένα πρόσωπο. Εάν η έξοδος οποιασδήποτε δοκιμής αποτυγχάνει να περάσει το προκαθορισμένο όριο κατωφλίου (συνήθως 0.5), αυτό απορρίπτεται αμέσως. Ένα πρόσωπο αναφέρεται μόνο αφού το παράθυρο προτύπου έχει περάσει όλες τις δοκιμές και το ελάχιστο των 3 αποτελεσμάτων δοκιμής θα επιλεγεί ως τελική έξοδος. Στο περιβάλλον μας, μπορούμε να υποθέσουμε ότι δεν υπάρχει περισσότερο από ένα πρόσωπο στην εικόνα. Θέτουμε το κατώτατο όριο δυναμικά αντικαθιστώντας το με τη μέγιστη έξοδο μέχρι το ερευνηθέν σημείο. Αυτό μειώνει πολύ το χρονικό κόστος στην έρευνα με την αποφυγή των περιττών δοκιμών.

Εάν η εικόνα περιέχει περισσότερα από ένα πρόσωπα, πρέπει να θέσουμε ένα προκαθορισμένο κατώφλι (threshold) για την εύρεση του προσώπου. Για κάθε πρόσωπο μέσα στην εικόνα, τις περισσότερες φορές ο κώδικας θα βρει τα πολλαπλάσια πρότυπα προσώπου για αυτό, με μικρή μετατόπιση θέσης και αλλαγή μεγέθους. Τελικά όλα τα πρότυπα προσώπου συσκευάζονται για να δώσουν μόνο ένα πρόσωπο για κάθε πρόσωπο στην εικόνα.

Τις περισσότερες φορές ο κώδικας ανίχνευσης προσώπου μπορεί να βρει το πρόσωπο. Δίνει υψηλότερα αποτελέσματα στις όρθιες εικόνες προσώπου από εκείνες τις εικόνες με αλλαγή προσανατολισμού. Αλλά ο στόχος του κώδικα ανίχνευσης προσώπου είναι να βρεθούν τα πρόσωπα μέσα στις εικόνες. Ο στόχος του δεν είναι να κόψει τα πρόσωπα από τις εικόνες για το σκοπό της αναγνώρισης. Μερικές φορές τα πρότυπα προσώπου που βρίσκονται από τον κώδικα είναι μικρότερα από το πραγματικό μέγεθός τους ή μη κεντρικά στα πραγματικά πρόσωπα.

Face Model Resize

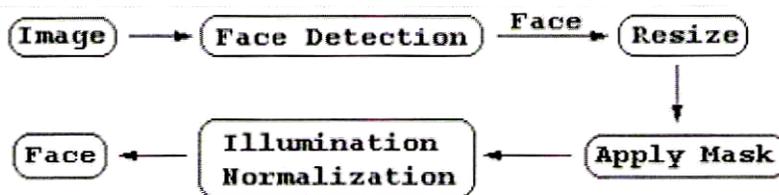
Το πρότυπο του προσώπου που χρησιμοποιείται από τον κώδικα ανίχνευσης προσώπου είναι 19x19. Είναι λίγο μικρό μέγεθος για την αναγνώριση. Χρησιμοποιούμε ένα πρότυπο 46x46 για την αναγνώριση. Είναι όμως ακόμα ένα μικρό μέγεθος και μπορεί να κρατήσει όλες τις απαραίτητες λεπτομέρειες για την αναγνώριση. Αφότου βρίσκεται το πρόσωπο, επαναταξινομείται σε αυτό το τυποποιημένο μέγεθος.

Edge Removal

Αφού βρεθεί το πρόσωπο και επαναταξινομηθεί, μια δυαδική μάσκα εφαρμόζεται για να αποβάλει εκείνα τα pixels στις άκρες. Αυτό γίνεται προκειμένου να αφαιρεθούν αυτά τα pixels από το background. Ένας άλλος λόγος είναι ότι το πρότυπο που χρησιμοποιείται από τον κώδικα ανίχνευσης προσώπου είναι τετραγωνικό. Η μάσκα θα το διαμορφώσει σε ορθογώνιο που είναι το πλησιέστερο στη μορφή του ανθρώπινου προσώπου.

Ομαλοποίηση φωτισμού

Το πρόσωπο εισόδου πρέπει να έχει κατά προσέγγιση τον ίδιο φωτισμό με εκείνα τα πρόσωπα στη βάση δεδομένων. Για να αποφευχθεί ο ισχυρός ή αδύνατος φωτισμός, κάθε πρόσωπο είναι ομαλοποιημένο. Η εικόνα αντιμετωπίζεται σαν ένα διάνυσμα στο υψηλό διαστατικό διάστημα. Το διανυσματικό μήκος του προσαρμόζεται στο διανυσματικό μήκος του μέσου προσώπου στο διάστημα προσώπου.



Σχήμα 4.3: Δομή ανίχνευσης προσώπου

Το ενδιαφέρον για την αναγνώριση προσώπου είναι η παραλλαγή ενός προσώπου μεταξύ διαφορετικών ατόμων. Αυτό που χρειαζόμαστε είναι μια μαθηματική περιγραφή και εξήγηση του φαινομένου ότι το πρόσωπο A και το B είναι το ίδιο πρόσωπο, ή το πρόσωπο A και το πρόσωπο C είναι διαφορετικοί άνθρωποι.

Αντίθετα από την ανίχνευση προσώπου όπου υπάρχουν μόνο δύο κατηγορίες αντικειμένων, προσώπων και μη-προσώπων, εδώ κάθε άτομο είναι μια χωριστή κατηγορία. Όλα τα πρόσωπα έχουν τα ίδια χαρακτηριστικά γνωρίσματα προσώπου και είναι βασικά πολύ παρόμοια στη γενική διαμόρφωση, κάτι που κάνει την αναγνώριση προσώπου ένα δύσκολο και λεπτό πρόβλημα διάκρισης. Ένα άλλο πράγμα που το καθιστά πιο περίπλοκο είναι ότι το πρόσωπο κάθε ατόμου μπορεί να έχει πολλές παραλλαγές λόγω της αλλαγής στον προσανατολισμό, την έκφραση και το φωτισμό. Ενώ ελπίζουμε ότι το σύστημα θα μπορούσε να χειριστεί ένα ευρύ φάσμα της παραλλαγής στις πραγματικές δοκιμές, ο αριθμός παραδειγμάτων στην εκμάθηση ενός συγκεκριμένου προσώπου ατόμου είναι πάντα περιορισμένος.

Μια εικόνα προσώπου είναι ένας δισδιάστατος πίνακας δύο τιμών έντασης. Στα πειράματα παρακάτω το τυποποιημένο μέγεθος είναι 46x46. Αλλά οι εικόνες προσώπου δεν διανέμονται τυχαία σε αυτό το υψηλό διαστατικό διάστημα. Το γεγονός ότι όλα τα πρόσωπα είναι πολύ παρόμοια το ένα με το άλλο και έχουν τα ίδια χαρακτηριστικά γνωρίσματα όπως τα μάτια, η μύτη και το στόμα κάνει όλα τα πρόσωπα ένα υποσύνολο ολόκληρου του διαστήματος εικόνας, με άλλα λόγια, η διάσταση του διαστήματος

προσώπου είναι μικρότερη από αυτό του διαστήματος εικόνας.

Οι Sirovich και Kirby αρχικά εφάρμοσαν την ανάλυση κύριων τμημάτων στην αντιπροσώπευση προσώπου. Σε αυτήν την τεχνική δημιουργείται ένα νέο ισότιμο σύστημα για τα πρόσωπα όπου οι συντεταγμένες είναι μέρος των eigenvectors ενός συνόλου εικόνων προσώπου.

Ο Matthew Turk και ο Alex Pentland επέκτειναν την ιδέα στην αναγνώριση προσώπου. Τα πρόσωπα κωδικοποιούνται από ένα μικρό σύνολο βαρών που αντιστοιχούν στην προβολή τους επάνω στο νέο ισότιμο σύστημα, και αναγνωρίζονται μέσω της σύγκρισής τους με εκείνα των γνωστών ατόμων.

Eigenspace Representation

Πρώτα προετοιμάζουμε ένα αρχικό σύνολο εικόνων προσώπου $[X_1, X_2, \dots, X_n]$. Το μέσο πρόσωπο ολόκληρης της διανομής προσώπου είναι:

$$X = (X_1 + X_2 + \dots + X_n) / n$$

Κατόπιν το μέσο πρόσωπο αφαιρείται από κάθε πρόσωπο:

$$X_i' = X_i - X, i = 1, 2, \dots, n$$

Τα Eigenvectors υπολογίζονται από το νέο σύνολο εικόνας $[X_1', X_2', \dots, X_n']$ σαν $[Y_1, Y_2, \dots, Y_n]$. Αυτά τα δεν αντιστοιχούν άμεσα σε οποιαδήποτε χαρακτηριστικά γνωρίσματα προσώπου όπως τα μάτια, τη μύτη και το στόμα. Είναι ένα σύνολο σημαντικών χαρακτηριστικών γνωρισμάτων που περιγράφουν την παραλλαγή στο σύνολο της εικόνας ενός προσώπου. Η διάσταση του πλήρους eigenspace είναι $n-1$ επειδή η αξία eigenvalue της υπολειπόμενης eigenface είναι 0. Το διάστημα eigenface δημιουργείται με 593 εικόνες προσώπου.

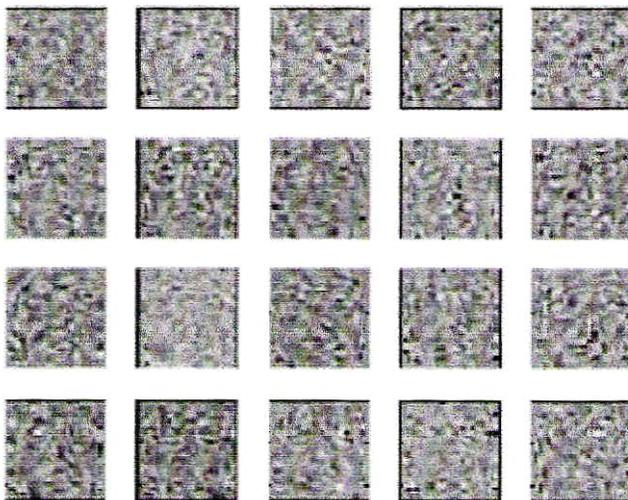


Σχήμα 4.4: Μέρος των εικόνων προσώπου που χρησιμοποιούνται για να δημιουργήσουν το eigenspace.

Το διάνυσμα eigenvector έχει την εξής ιδιότητα. Κάθε ένα από αυτά έχει μια αξία eigenvalue που συνδέεται με αυτό. Τα Eigenvectors με μεγαλύτερες eigenvalues παρέχουν περισσότερες πληροφορίες για την παραλλαγή του προσώπου από εκείνα με μικρότερες eigenvalues. Σε αντίθεση με τη Ευκλείδεια αντιπροσώπευση όπου όλοι οι άξονες είναι ίδιας σπουδαιότητας. Στα επόμενα δύο σχήματα (Σχήμα 4.5 και Σχήμα 4.6), παρουσιάζονται τα eigenfaces με υψηλές και χαμηλές αξίες eigenvalues αντίστοιχα.

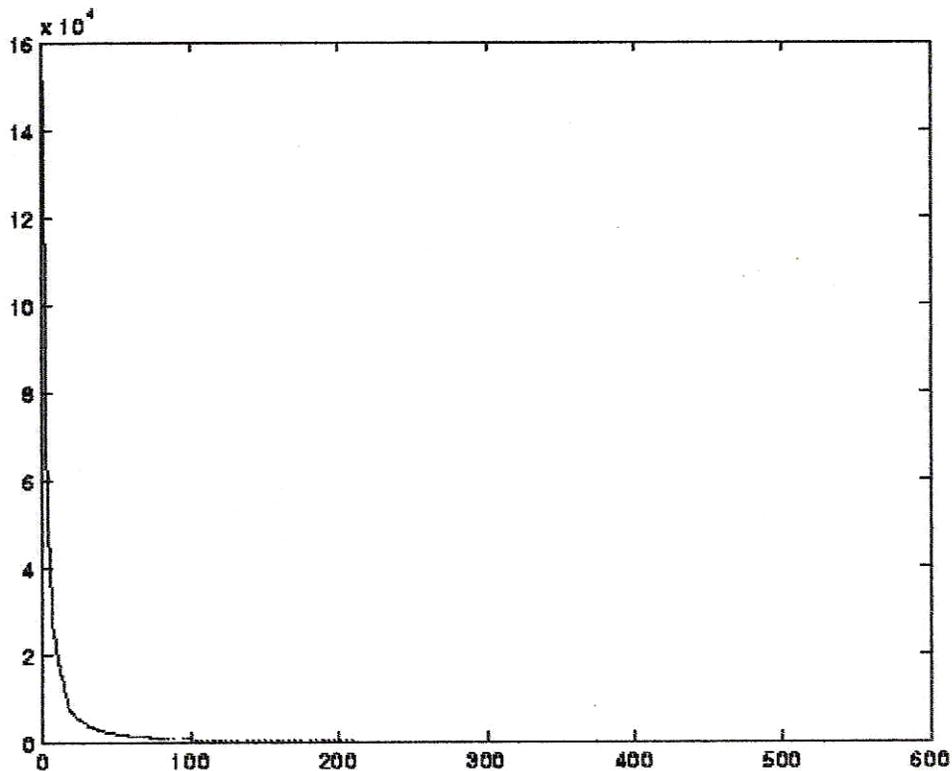


Σχήμα 4.5: Τα πρώτα 20 eigenfaces με τις υψηλότερες eigenvalues.



Σχήμα 4.6: Eigenfaces με eigenvalues ταξινομημένες από 141 σε 160,

Από το Σχήμα 4.7 μπορούμε να δούμε ότι η καμπύλη eigenvalue μειώνεται πολύ γρήγορα.



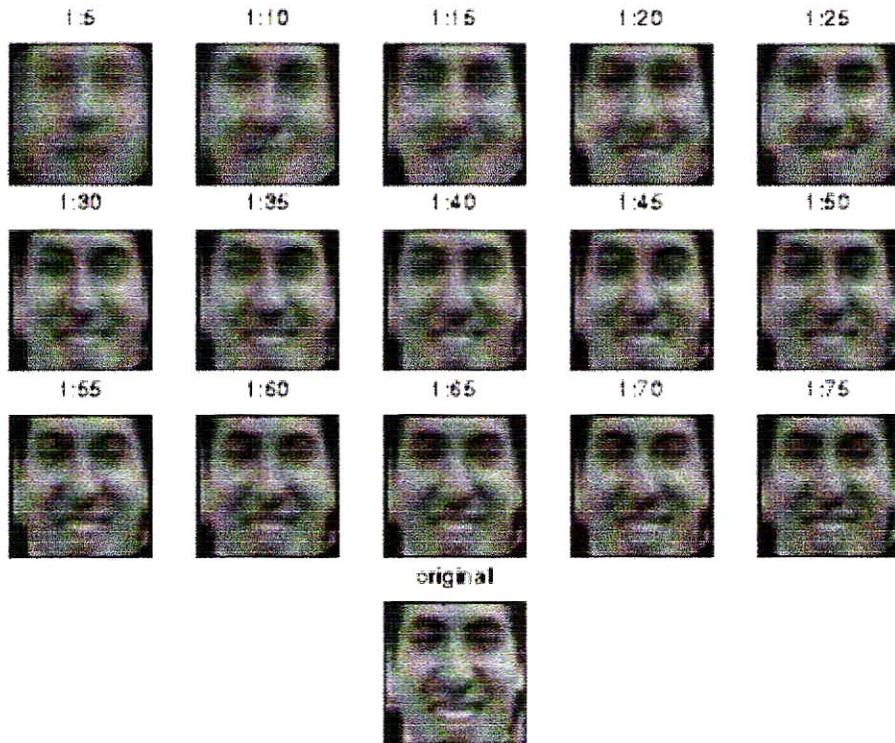
Σχήμα 4.7: Eigenvalues of eigenfaces

Αφότου εξάγονται τα eigenfaces από τη μήτρα συνδιακύμανσης ενός συνόλου προσώπων, κάθε πρόσωπο προβάλλεται επάνω στο διάστημα eigenface και αντιπροσωπεύεται από έναν γραμμικό συνδυασμό των eigenfaces, ή έχει έναν νέο περιγραφέα που αντιστοιχεί σε ένα σημείο μέσα στο υψηλό διαστατικό διάστημα με τα eigenfaces ως άξονες.

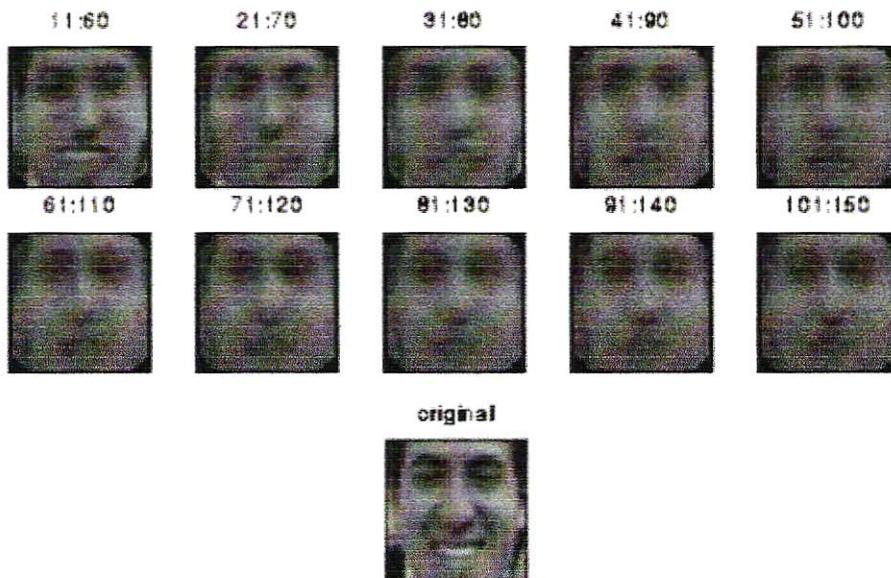
Εάν χρησιμοποιούμε όλα τα eigenfaces για να αντιπροσωπεύσουμε τα πρόσωπα, εκείνα στο αρχικό σύνολο εικόνας μπορούν να αναδημιουργηθούν εντελώς. Αλλά αυτά τα eigenfaces χρησιμοποιούνται για να αντιπροσωπεύσουν ή να κωδικοποιήσουν οποιαδήποτε πρόσωπα που προσπαθούμε να μάθουμε ή να αναγνωρίσουμε. Το Σχήμα 4.8 παρουσιάζει τα πρόσωπα που αναδημιουργούνται από τα eigenfaces με υψηλές eigenvalues και το Σχήμα 4.9 χρησιμοποιώντας εκείνα με χαμηλές eigenvalues. Είναι σαφές ότι πρέπει να χρησιμοποιήσουμε eigenfaces με υψηλότερες eigenvalues για να αναδημιουργήσουμε τα πρόσωπα επειδή παρέχουν πολύ περισσότερες πληροφορίες για την παραλλαγή προσώπου.

Το Σχήμα 4.8 διευκρινίζει επίσης ότι ενώ το μικρό σύνολο των eigenfaces δεν μπορεί να αναδημιουργήσει το αρχικό πρόσωπο, χρησιμοποιώντας πάρα πολλά eigenfaces θα εισαχθεί θόρυβος στο αναδημιουργημένο πρόσωπο. Χρησιμοποιούμε τα πρώτα 100 eigenfaces με τις υψηλότερες eigenvalues. Το πρόσωπο που προσπαθούμε να

αναγνωρίσουμε προβάλλεται επάνω στα 100 eigenfaces πρώτα. Παράγει μια νέα περιγραφή του προσώπου με μόνο 100 πραγματικούς αριθμούς.



Σχήμα 4.8: Πρόσωπα που αναδημιουργούνται χρησιμοποιώντας eigenfaces με υψηλές eigenvalues. Η ετικέτα επάνω από κάθε πρόσωπο είναι η σειρά των eigenfaces που χρησιμοποιήθηκαν.



Σχήμα 4.9: Πρόσωπα που αναδημιουργούνται χρησιμοποιώντας eigenfaces με χαμηλές eigenvalues. Η ετικέτα επάνω από κάθε πρόσωπο είναι η σειρά των eigenfaces που

χρησιμοποιούνται.

Επειδή η προβολή επάνω στο διάστημα *eigenface* περιγράφει την παραλλαγή της κατανομής του προσώπου, είναι φυσικό να χρησιμοποιηθούν αυτοί οι νέοι περιγραφείς των προσώπων για να τους ταξινομήσει. Τα πρόσωπα αναγνωρίζονται με τη σύγκριση του περιγραφέα νέου προσώπου με τη βάση δεδομένων προσώπων που έχει κωδικοποιηθεί με τον ίδιο τρόπο. Μια προσέγγιση για να βρεθεί το πρότυπο προσώπου είναι να υπολογιστεί η Ευκλείδεια απόσταση μεταξύ του περιγραφέα του προσώπου εισόδου και κάθε γνωστού προτύπου προσώπου στη βάση δεδομένων. Όλα τα πρόσωπα του ίδιου ατόμου είναι υποτιθέμενα για να είναι, το ένα κοντά στο άλλο ενώ διαφορετικά πρόσωπα έχουν διαφορετικές συστάδες προσώπου. Αλλά πραγματικά δεν έχουμε οποιαδήποτε προγενέστερη γνώση σχετικά με τη διανομή των περιγραφέων του νέου προσώπου.

Μια καλύτερη προσέγγιση είναι να αναγνωριστεί το πρόσωπο με τον ανεπίβλεπτο τρόπο που χρησιμοποιεί η νευρωνική δικτυακή αρχιτεκτονική. Συλλέγουμε, τα χαρακτηριστικά πρόσωπα από κάθε άτομο, τα προβάλλουμε επάνω στο *eigenspace* και τα νευρωνικά δίκτυα μαθαίνουν πώς να τα ταξινομήσουν με τον περιγραφέα του νέου προσώπου ως είσοδο.

Πειράματα

Συνδυάζοντας τις ανωτέρω τεχνικές, έχει κατασκευαστεί ένα σύστημα πραγματικού χρόνου που παίρνει συνεχώς την εικόνα από μια κάμερα, βρίσκει το πρόσωπο με τον κώδικα ανίχνευσης προσώπου και το αναγνωρίζει χρησιμοποιώντας τη βάση δεδομένων που έχει δημιουργηθεί με το νευρωνικό δίκτυο. Εάν το πρόσωπο αναγνωριστεί, ο *speaker* θα πει το όνομά του, διαφορετικά θα πει "καμία αντιστοιχία". Τα πειράματα πραγματοποιούνται αυστηρά κάτω από τις ίδιες συνθήκες. Οι ευρείες παραλλαγές έκφρασης ενσωματώνονται. Τα πρόσωπα βασικά είναι σε μετωπική όψη χωρίς σημαντική αλλαγή προσανατολισμού.

Στις δοκιμές μας, κάθε εικόνα είναι 200x200 pixels. Ψάχνουμε μια περιοχή από 40% σε 80% για το πρόσωπο. Εάν ένα πρόσωπο υπάρχει, η αναγνώριση μπορεί να διευθυνθεί αμέσως. Ένα ποσοστό αναγνώρισης περισσότερο από 95% έχει επιτευχθεί. Μπορούμε να βελτιώσουμε το ποσοστό αναγνώρισης αναγνωρίζοντας το ίδιο πρόσωπο σε πολλαπλούς χρόνους. Δεν εκθέτουμε το αποτέλεσμα αναγνώρισης έως ότου οι περισσότερες από τις αναγνώρισεις κατά τη διάρκεια μικρής χρονικής περιόδου δώσουν το ίδιο αποτέλεσμα. Στην αρχή η βάση δεδομένων μας περιέχει 5 άτομα. Αφότου δημιουργηθεί η αρχική βάση δεδομένων, έχουμε προσθέσει ένα άλλο πρόσωπο στη βάση δεδομένων. Αποδεικνύεται ότι η βάση δεδομένων μπορεί να επεκταθεί εύκολα

<i>Individuals</i>	<i>Traning Examples Number</i>	<i>Recognition Rate (%)</i>
Alian	142	100
Ari	202	95
Charlie	107	92.5
Josh	118	95
Peter	103	97.5
Mike	179	95
Average	142	96

Ένα άλλο σύστημα για την Αναγνώριση Προσώπου

Το σύστημα συνδυάζει την τοπική δειγματοληψία εικόνας, ένα self-organizing νευρωνικό δίκτυο, και ένα convolutional νευρωνικό δίκτυο. Ο self-organizing χάρτης (map) παρέχει μια κβαντοποίηση των δειγμάτων εικόνας σε ένα τοπολογικό διάστημα όπου οι είσοδοι που είναι κοντινές στο αρχικό διάστημα είναι επίσης κοντινές στο διάστημα εξόδου. Το convolutional δίκτυο εξάγει διαδοχικά μεγαλύτερα χαρακτηριστικά με ένα ιεραρχικό σύνολο στρωμάτων. Παρακάτω παρουσιάζουμε τα αποτελέσματα χρησιμοποιώντας τη μετατροπή Karhunen-Loeve αντί του self-organizing map, και πολυστρωματικό perceptron αντί του convolutional δικτύου. Η μετατροπή Karhunen-Loeve αποδίδει σχεδόν το ίδιο καλά (5,3% σφάλμα έναντι 3.8%). Το πολυστρωματικό perceptron αποδίδει πολύ λίγο (40% σφάλμα έναντι 3.8%). Η μέθοδος είναι ικανή για γρήγορη ταξινόμηση, απαιτεί μόνο γρήγορη, κατά προσέγγιση κανονικοποίηση και προεπεξεργασία, και εκθέτει καλύτερη απόδοση ταξινόμησης από την προσέγγιση eigenfaces. Με 5 εικόνες ανά άτομο η προτεινόμενη μέθοδος και τα eigenfaces οδηγούν σε σφάλμα 3,8% και 10,5% αντίστοιχα. Το σύστημα αναγνώρισης παρέχει ένα μέτρο εμπιστοσύνης στις εξόδους του και το σφάλμα ταξινόμησης προσεγγίζει το μηδέν κατά την απόρριψη μόνο 10% των παραδειγμάτων.

Χρησιμοποιείται μια βάση δεδομένων 400 εικόνων των 40 ατόμων που περιέχει αρκετά υψηλό βαθμό ποικιλίας στην έκφραση, στις στάσεις, και στις λεπτομέρειες του προσώπου.

Οι τεχνικές που χρησιμοποιούνται στα καλύτερα συστήματα αναγνώρισης προσώπου μπορούν να εξαρτηθούν από την εφαρμογή του συστήματος. Μπορούμε να προσδιορίσουμε τουλάχιστον δύο ευρείες κατηγορίες συστημάτων αναγνώρισης προσώπου:

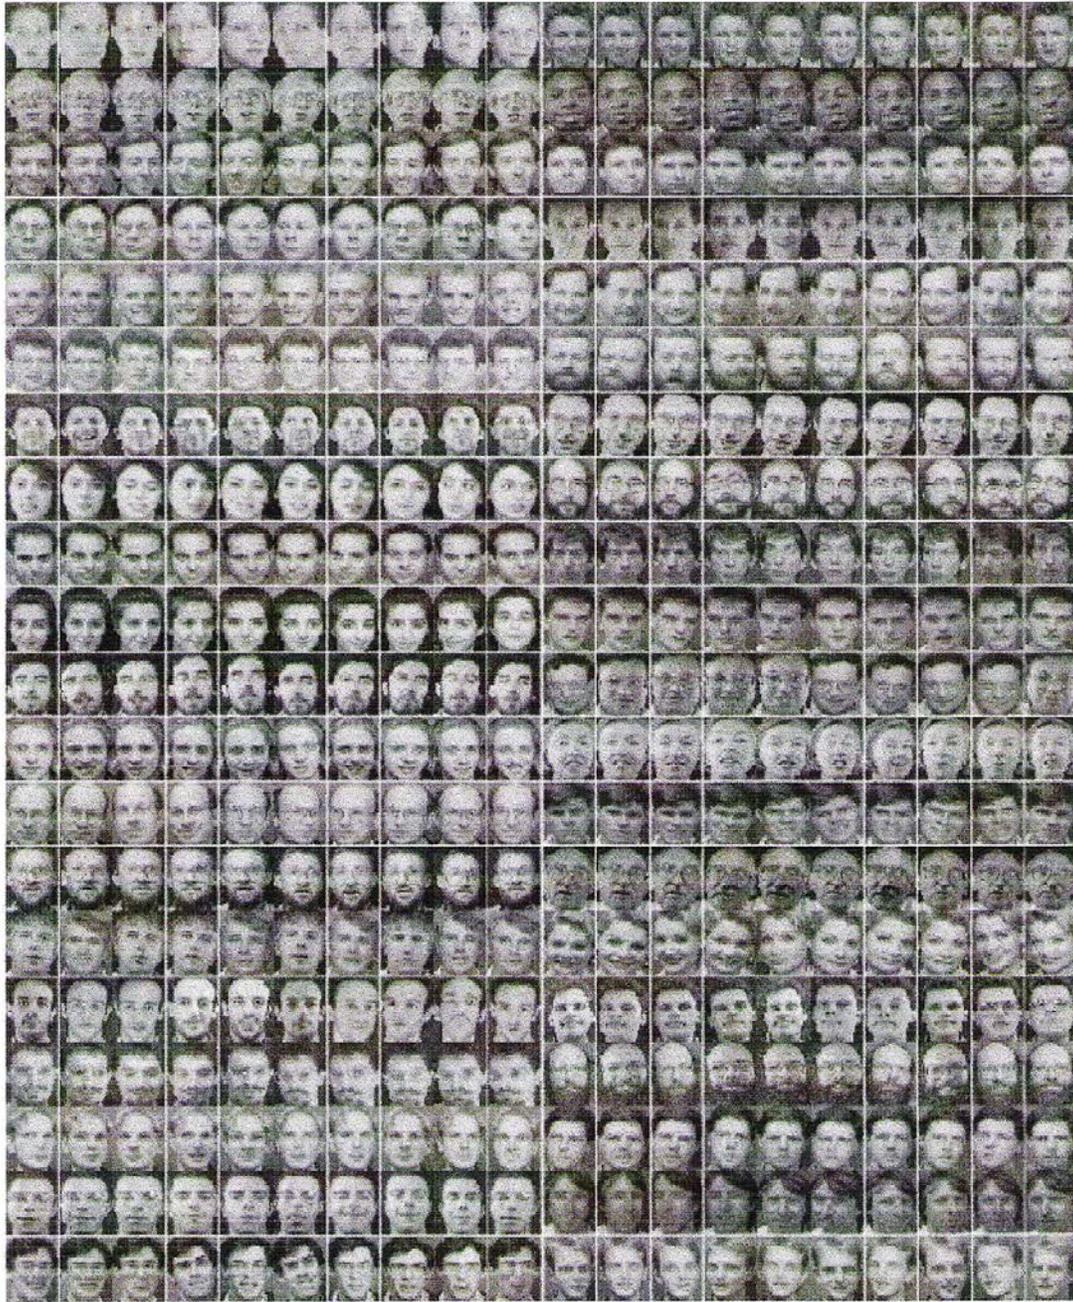
1. Θέλουμε να βρούμε ένα πρόσωπο μέσα σε μια μεγάλη βάση δεδομένων προσώπων (π.χ. σε μια βάση δεδομένων της αστυνομίας). Αυτά τα συστήματα επιστρέφουν μια λίστα των πλέον πιθανότερων ανθρώπων από τη βάση δεδομένων. Συχνά μόνο μια εικόνα είναι διαθέσιμη ανά άτομο. Για την αναγνώριση δεν είναι συνήθως απαραίτητο να γίνει σε πραγματικό χρόνο.
2. Θέλουμε να προσδιορίσουμε συγκεκριμένους ανθρώπους σε πραγματικό χρόνο (π.χ. σε ένα σύστημα ελέγχου ασφάλειας, σε ένα σύστημα εντοπισμού θέσης, κ.λ.π.), ή θέλουμε να επιτρέψουμε την

πρόσβαση σε μια ομάδα ανθρώπων και να αρνηθούμε την πρόσβαση σε κάποιους άλλους (π.χ. πρόσβαση σε ένα κτήριο, σε έναν υπολογιστή, κ.λ.π.). Οι πολλαπλάσιες εικόνες ανά άτομο είναι συχνά διαθέσιμες για την κατάρτιση και απαιτείται αναγνώριση σε πραγματικό χρόνο.

Ενδιαφερόμαστε για την αναγνώριση με ποικιλία στις λεπτομέρειες του προσώπου, την έκφραση, τη στάση, κ.λ.π. Ενδιαφερόμαστε για τη γρήγορη ταξινόμηση και ως εκ τούτου δεν υποθέτουμε ότι ο χρόνος είναι διαθέσιμος για εκτενείς προεπεξεργασία και κανονικοποίηση.

Δεδομένα

Έχει χρησιμοποιηθεί η ORL database που περιέχει ένα σύνολο προσώπων που ελήφθησαν από Απρίλιο του 1992 έως τον Απρίλιο του 1994 στο ερευνητικό εργαστήριο της Olivetti στο Cambridge, UK. Υπάρχουν 10 διαφορετικές εικόνες των 40 ευδιάκριτων θεμάτων. Για μερικά από τα θέματα, οι εικόνες λήφθηκαν σε διαφορετικούς χρόνους. Υπάρχουν παραλλαγές στην έκφραση του προσώπου (ανοικτά /κλειστά μάτια, με χαμόγελο /χωρίς χαμόγελο), και λεπτομέρειες προσώπου (γυαλιά /χωρίς γυαλιά). Όλες οι εικόνες ελήφθησαν σε ένα σκοτεινό ομοιογενές background με τα πρόσωπα σε μια όρθια, μετωπική θέση, με ανοχή για κάποια κλίση και περιστροφή μέχρι περίπου 20 βαθμών. Υπάρχει κάποια παραλλαγή στην κλίμακα μέχρι περίπου 10%. Οι εικόνες είναι greyscale και ανάλυσης 92x112.



Σχήμα 4.10 Η ORL face database. 10 εικόνες για κάθε ένα από τα 40 πρόσωπα.



Σχήμα 4.11: Το σύνολο των 10 εικόνων για ένα πρόσωπο. Εμφανής η μεγάλη ποικιλία.

Γεωμετρικά χαρακτηριστικά γνωρίσματα

Πολλοί έχουν ερευνήσει μεθόδους βασισμένες σε γεωμετρικά χαρακτηριστικά για την αναγνώριση προσώπου. Ο Kanade παρουσίασε μια μέθοδο αυτόματης εξαγωγής χαρακτηριστικών γνωρισμάτων βασισμένη στις αναλογίες των αποστάσεων και εξέθεσε ένα ποσοστό αναγνώρισης μεταξύ 45-75% με μια βάση δεδομένων των 20 ανθρώπων. Οι Brunelli και Roggio υπολόγισαν ένα σύνολο γεωμετρικών χαρακτηριστικών γνωρισμάτων όπως το πλάτος και το μήκος της μύτης, τη θέση του στόματος, και η μορφή των πηγουνιών. Εκθέτουν ένα ποσοστό αναγνώρισης 90% σε μια βάση δεδομένων των 47 ανθρώπων. Ο COX και άλλοι, έχει εισαγάγει πρόσφατα μια *mixture-distance* τεχνική η οποία επιτυγχάνει ένα ποσοστό αναγνώρισης 95% χρησιμοποιώντας μια βάση δεδομένων των 95 εικόνων από συνολικά 685 άτομα. Κάθε πρόσωπο αντιπροσωπεύεται από 30 *manually extracted* αποστάσεις.

Eigenfaces

Οι υψηλού επιπέδου στόχοι αναγνώρισης τυπικά διαμορφώνονται με πολλά στάδια επεξεργασίας. Εντούτοις, οι Turk και Pentland υποστήριξαν ότι είναι πιθανό να υπάρχει ακόμη μια διαδικασία αναγνώρισης βασισμένη στη χαμηλού επιπέδου, διδιάστατη επεξεργασία εικόνας. Το επιχείρημά τους είναι βασισμένο στην πρόωρη ανάπτυξη και ταχύτατη αναγνώριση του ανθρώπινου προσώπου, και σε φυσιολογικά πειράματα στο φλοιό εγκεφάλου των πιθήκων όπου υποστηρίζεται ότι έχουν απομονώσει τους νευρώνες που αποκρίνονται επιλεκτικά στα πρόσωπα.

Οι Turk και Pentland παρουσίασαν ένα σχέδιο αναγνώρισης προσώπου στο οποίο οι εικόνες προσώπου προβάλλονται επάνω στα κύρια συστατικά του αρχικού συνόλου εικόνων κατάρτισης. Τα *eigenfaces* είναι ταξινομημένα σε σύγκριση με τα γνωστά άτομα. Παρουσίασαν τα αποτελέσματα σε μια βάση δεδομένων 16 θεμάτων με ποικίλο προσανατολισμό του κεφαλιού. Οι εικόνες τους εμφανίζονται ίδιες με λίγες παραλλαγές στην έκφραση του προσώπου, τις λεπτομέρειες του προσώπου, την στάση κλπ. Για το

φωτισμό, τον προσανατολισμό, και την παραλλαγή κλίμακας το σύστημά τους επιτυγχάνει σωστή ταξινόμηση 96%, 85% και 64% αντίστοιχα. Η κλίμακα προσαρμόζεται στο μέγεθος του eigenface ανάλογα με μια εκτίμηση του μεγέθους του κεφαλιού. Το κέντρο των προσώπων είναι τονισμένο, μειώνοντας οποιαδήποτε αρνητική επιρροή από την αλλαγή στο χτένισμα των μαλλιών και του υπόβαθρου (background).

Οι Swets και Weng παρουσίασαν μια μέθοδο επιλογής eigenfeatures χρησιμοποιώντας την πολυδιάστατη γραμμική διακρίνουσα ανάλυση. Παρουσίασαν μεθόδους για τα πιο εκφραστικά χαρακτηριστικά γνωρίσματα (Most Expressive Features (MEF) και τα πιο μεροληπτικά χαρακτηριστικά γνωρίσματα (Most Discriminatory Features (MDF). Φαίνεται ότι το eigenfaces είναι ένας γρήγορος, απλός, και πρακτικός αλγόριθμος. Εντούτοις, μπορεί να περιοριστεί διότι η βέλτιστη απόδοση απαιτεί έναν υψηλό βαθμό συσχετισμού μεταξύ των εντάσεων των pixel των εικόνων κατάρτισης και δοκιμής.

Αντιστοίχιση προτύπων

Η αντιστοίχιση προτύπων είναι αποτελεσματικό μόνο όταν οι άγνωστες εικόνες έχουν την ίδια κλίμακα, προσανατολισμό, και φωτισμό με τις εικόνες κατάρτισης.

Αντιστοίχιση γραφικών παραστάσεων

Μια άλλη προσέγγιση για την αναγνώριση προσώπου είναι η πολύ γνωστή μέθοδος αντιστοίχισης γραφικών παραστάσεων. Τα αντικείμενα αντιπροσωπεύονται με αραιές γραφικές παραστάσεις των οποίων οι κορυφές απεικονίζονται με μια περιγραφή πολυ-ανάλυσης από την άποψη ενός δυναμικού τοπικού φάσματος, και οι άκρες των οποίων απεικονίζονται με γεωμετρικές αποστάσεις. Παρουσιάζουν τα καλά αποτελέσματα με μια βάση δεδομένων 87 ανθρώπων και οι εικόνες δοκιμής αποτελούνται από διαφορετικές εκφράσεις. Η διαδικασία της αντιστοίχισης είναι πολύ ακριβή, παίρνοντας κατά προσέγγιση 25 δευτερόλεπτα για να συγκρίνει μια εικόνα με 87 αποθηκευμένα αντικείμενα με τη χρησιμοποίηση μιας παράλληλης μηχανής με 23 transputer.

Προσεγγίσεις των Νευρωνικών Δικτύων

Μέσα στα πρώτα 50 κύρια συστατικά των εικόνων εξάγονται και μειώνονται σε 5 διαστάσεις χρησιμοποιώντας ένα autoassociative νευρωνικό δίκτυο. Η προκύπτουσα αντιπροσώπευση είναι ταξινομημένη χρησιμοποιώντας ένα τυποποιημένο πολυστρωματικό perceptron. Αναφέρονται τα καλά αποτελέσματα αλλά η βάση δεδομένων είναι αρκετά απλή: οι εικόνες ευθυγραμμίζονται χειροκίνητα και δεν υπάρχει παραλλαγή φωτισμού, περιστροφή, ή κλίση. Υπάρχουν 20 άνθρωποι στη βάση δεδομένων.

Συστατικά του συστήματος

Εν συντομία, ερευνάμε τη χρήση της τοπικής δειγματοληψίας εικόνας και μια τεχνική για τη μερική σταθερότητα φωτισμού, έναν self-organizing map (SOM) για την προβολή της αντιπροσώπευσης των δειγμάτων εικόνας, τη Karhunen-Loeve (KL) μετατροπή για τη σύγκριση με το self-organizing map, ένα convolutional δίκτυο (CN) για τη μερική σταθερότητα μεταφράσεων και παραμόρφωσης, και ένα πολυστρωματικό perceptron (MLP) για τη σύγκριση με το convolutional δίκτυο.

Δύο διαφορετικές μέθοδοι για την παρουσίαση των τοπικών δειγμάτων εικόνας. Σε κάθε μέθοδο ανιχνεύεται ένα παράθυρο πέρα από την εικόνα όπως φαίνεται στο Σχήμα 4.12.

1. Η πρώτη μέθοδος δημιουργεί απλά ένα διάνυσμα από ένα τοπικό παράθυρο της εικόνας χρησιμοποιώντας τις τιμές έντασης σε κάθε σημείο στο παράθυρο.

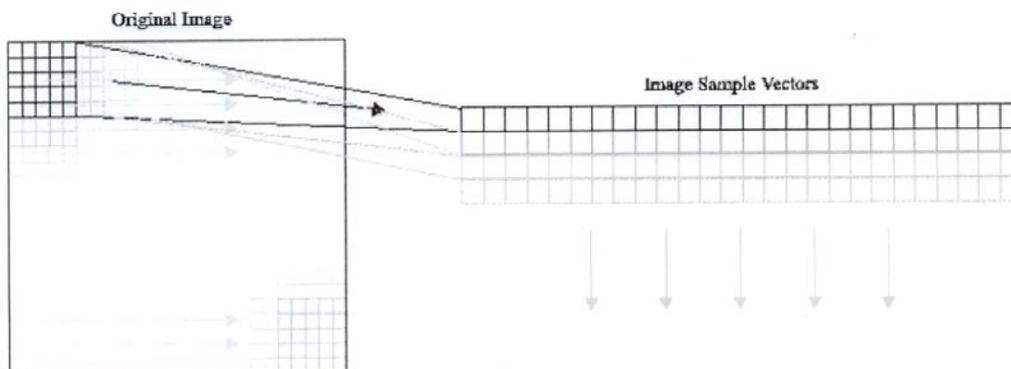
Έστω ότι X_{ij} είναι η ένταση στην i κολώνα, και j γραμμή της εικόνας. Εάν το τοπικό παράθυρο είναι ένα τετράγωνο πλευρών $2W+1$, με κέντρο το X_{ij} , τότε το διάνυσμα που σχετίζεται με αυτό το παράθυρο θα είναι :

$$[X_{i-W_j-W}, X_{i-W_j-W+1}, \dots, X_i, \dots, X_{i+W_j+W-1}, X_{i+W_j+W}].$$

2. Η δεύτερη μέθοδος δημιουργεί μια αντιπροσώπευση του τοπικού δείγματος διαμορφώνοντας ένα διάνυσμα από α) την ένταση του κεντρικού pixel X_{ij} , και β) τη διαφορά στην ένταση μεταξύ κεντρικού pixel και όλων των άλλων pixels μέσα στο τετραγωνικό παράθυρο. Το διάνυσμα δίνεται από τη σχέση:

$$[X_{ij}-X_{i-W_j-W}, X_{ij}-X_{i-W_j-W+1}, \dots, W_{ij}X_{ij}, \dots, X_{ij}-X_{i+W_j+W-1}, X_{ij}-X_{i+W_j+W}].$$

Ο βαθμός σταθερότητας μπορεί να τροποποιηθεί με τη ρύθμιση του βάρους W_{ij} που συνδέεται με το κεντρικό συστατικό (τμήμα) έντασης.



Σχήμα 4.12: Μια απεικόνιση της διαδικασίας της τοπικής δειγματοληψίας της εικόνας.

Self-Organizing Map

Οι χάρτες είναι ένα σημαντικό μέρος τόσο των φυσικών όσο και των τεχνητών νευρωνικών συστημάτων επεξεργασίας πληροφοριών. Παραδείγματα χαρτών στο νευρωνικό σύστημα είναι οι *retinotopic* maps στον οπτικό φλοιό, *tonotopic* maps στον ακουστικό φλοιό, και maps από το δέρμα μέχρι το *somatosensory* φλοιό. Ο self-organizing map ή SOM, είναι μια ανεπίβλεπτη διαδικασία εκμάθησης που μαθαίνει την κατανομή ενός συνόλου σχεδίων χωρίς οποιεσδήποτε πληροφορίες. Ένα σχέδιο προβάλλεται από μια είσοδο σε μια θέση στο χάρτη - οι πληροφορίες κωδικοποιούνται ως θέση ενός ενεργοποιημένου κόμβου. Ο SOM ξεχωρίζει των άλλων τεχνικών, δεδομένου ότι παρέχει μια τοπολογική σειρά των κατηγοριών. Η ομοιότητα στα σχέδια εισόδου συντηρείται στην διαδικασία εξόδου. Είναι ιδιαίτερα χρήσιμος στην ταξινόμηση δεδομένων που περιλαμβάνουν έναν μεγάλο αριθμό κατηγοριών.

Αλγόριθμος

Ο SOM καθορίζει μια χαρτογράφηση από ένα διάστημα εισόδου \mathbf{R}^n σε ένα τοπολογικά διαταγμένο σύνολο κόμβων, συνήθως σε ένα χαμηλότερο διάστημα διαστάσεων. Ένα παράδειγμα ενός δισδιάστατου SOM φαίνεται στο Σχήμα 4.18.

Ένα διάνυσμα αναφοράς στο διάστημα εισόδου, $\mathbf{m}_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{in}]^T \in \mathbf{R}^n$, εφαρμόζεται σε κάθε κόμβο στο SOM. Κατά τη διάρκεια της κατάρτισης, κάθε διάνυσμα εισόδου \mathbf{x} , συγκρίνεται με όλα τα \mathbf{m}_i , στοχεύοντας στη θέσης της πιο στενής αντιστοιχίας \mathbf{m}_c (δίνεται από $|\mathbf{x} - \mathbf{m}_c| = \min_i \{ |\mathbf{x} - \mathbf{m}_i| \}$ όπου $|\mathbf{a}|$ δείχνει τον κανόνα του διανύσματος \mathbf{a}). Το σημείο εισόδου χαρτογραφείται σε αυτήν την θέση του SOM. Οι κόμβοι στο SOM ανανεώνονται σύμφωνα με:

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)] \quad (1)*\text{main}::\text{open_tags}$$

όπου t είναι ο χρόνος κατά τη διάρκεια της εκμάθησης και $h_{ci}(t)$ είναι η *γειτονική συνάρτηση*, ένας λείος πυρήνας που είναι μέγιστος στο \mathbf{m}_c .

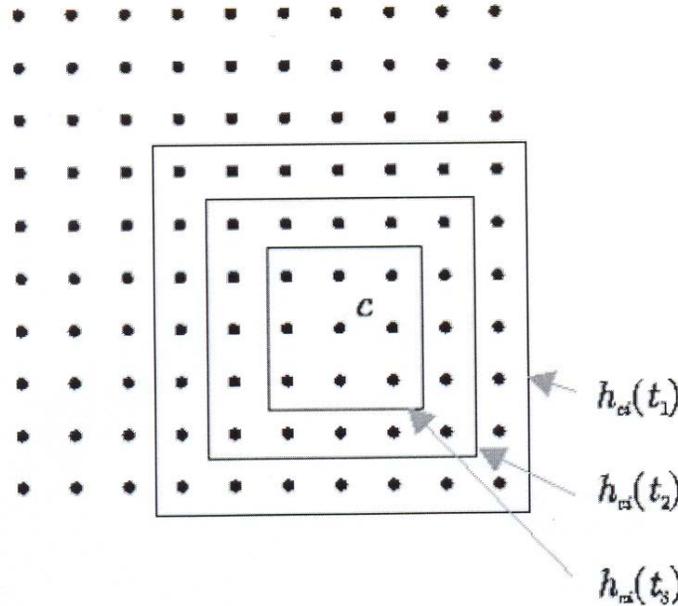
Συνήθως, $h_{ci}(t) = h(|\mathbf{r}_c - \mathbf{r}_i|, t)$, όπου \mathbf{r}_c και \mathbf{r}_i αντιπροσωπεύουν τη θέση των κόμβων στο εξωτερικό διάστημα του SOM. \mathbf{r}_c είναι ο κόμβος με το πλησιέστερο διάνυσμα βάρους σ' αυτό του δείγματος εισόδου και \mathbf{r}_i ποικίλει από όλους τους κόμβους.

Το $h_{ci}(t)$ πλησιάζει το 0 καθώς $|\mathbf{r}_c - \mathbf{r}_i|$ μεγαλώνει και επίσης όσο το t πλησιάζει το ∞ . Μια ευρέως εφαρμοσμένη γειτονική συνάρτηση είναι η εξής:

$$h_{ci} = a(t) \exp\left(-\frac{|\mathbf{r}_c - \mathbf{r}_i|^2}{2\sigma^2(t)}\right) \quad (2)*\text{main}::\text{open_tags}$$

όπου $a(t)$ είναι ένα κλιμακωτό εκτιμημένο ποσοστό εκμάθησης και $\sigma(t)$ καθορίζει το πλάτος του πυρήνα. Και τα δύο μειώνονται με το πέρασμα του χρόνου.

Το $\sigma(\mathbf{t})$ δεν πρέπει να μειωθεί πάρα πολύ δεδομένου ότι ο χάρτης θα χάσει την τοπογραφική διαταγή του εάν οι γειτονικοί κόμβοι δεν ανανεώνονται μαζί με τον πιο κοντινό κόμβο. Ο SOM μπορεί να θεωρηθεί μια μη γραμμική προβολή της πιθανότητας της πυκνότητας, $\mathbf{p}(\mathbf{x})$.



Σχήμα 4.13: Ένας διδιάστατος SOM παρουσιάζοντας μια γειτονική τετραγωνική συνάρτηση που ξεκινά ως $h_{ci}(t_1)$ και μειώνεται στο μέγεθος $h_{ci}(t_3)$ κατά τη διάρκεια του χρόνου.

Μετασχηματισμός Karhunen-Loeve

Η βέλτιστη γραμμική μέθοδος για τη μείωση του πλεονασμού σε ένα σύνολο δεδομένων είναι η μετατροπή ή η eigenvector επέκταση του Karhunen-Loeve (KL) μέσω της ανάλυσης τμημάτων αρχής (Principle Components Analysis (PCA)). Η PCA παράγει ένα σύνολο ορθογώνιων αξόνων από προβολές γνωστές ως κύρια συστατικά, ή eigenvectors, της διανομής των δεδομένων εισόδου της τάξεως της μειωμένης διαφοράς. Η KL μετατροπή είναι μια καλά γνωστή στατιστική μέθοδος για την εξαγωγή χαρακτηριστικών γνωρισμάτων και την προβολή ποικίλων (σε μεταβλητές) στοιχείων και έχει χρησιμοποιηθεί ευρέως στην αναγνώριση σχεδίων, την επεξεργασία σήματος, την επεξεργασία εικόνας, και την ανάλυση στοιχείων. Τα σημεία σε ένα n -διάστατο διάστημα εισόδου προβάλλεται σε ένα m -διάστατο διάστημα, $m \leq n$. Η μετατροπή KL χρησιμοποιείται εδώ για τη σύγκριση με το SOM στη μείωση της διαστατικότητας των τοπικών δειγμάτων εικόνας. Η μετατροπή KL χρησιμοποιείται επίσης στα eigenfaces.

Convolutional Networks (Δίκτυα Συνέλιξης)

Το πρόβλημα της αναγνώρισης προσώπου από 2D εικόνες είναι τυπικά πολύ "άρρωστο", δηλ. υπάρχουν πολλά πρότυπα που ταιριάζουν καλά με τα σημεία κατάρτισης αλλά δεν γενικεύουν καλά τις απαρατήρητες εικόνες. Με άλλα λόγια, δεν υπάρχουν αρκετά σημεία κατάρτισης στο διάστημα που δημιουργείται από τις εικόνες εισόδου προκειμένου να επιτραπεί η ακριβής εκτίμηση των πιθανοτήτων κατηγορίας σε όλο το διάστημα εισόδου. Επιπλέον, για τα MLP δίκτυα με τις 2D εικόνες ως είσοδο, δεν υπάρχει καμία σταθερότητα στη μετάφραση ή την τοπική παραμόρφωση των εικόνων.

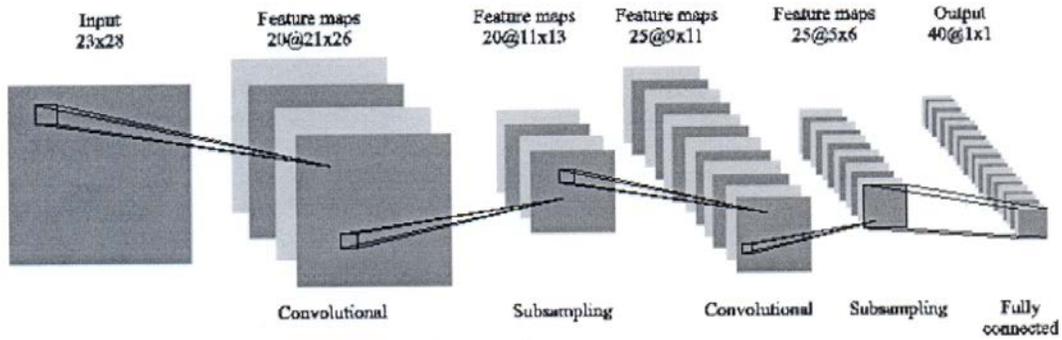
Τα convolutional networks (CN) ενσωματώνουν τους περιορισμούς και επιτυγχάνουν κάποιο βαθμό σταθερότητας μετατόπισης και παραμόρφωσης χρησιμοποιώντας τρεις ιδέες: τοπικοί δεκτικοί τομείς (local receptive fields), κοινά βάρη (shared weights), και spatial subsampling. Τα convolutional networks έχουν εφαρμοστεί επιτυχώς στην αναγνώριση χαρακτήρα.

Ένα χαρακτηριστικό convolutional network παρουσιάζεται στο Σχήμα 4.14. Το δίκτυο αποτελείται από ένα σύνολο στρώματων. Κάθε ένα περιέχει ένα ή περισσότερα στρώματα. Οι περίπου κεντροθετημένες και ομαλοποιημένες εικόνες εισάγονται στο στρώμα εισόδου. Κάθε μονάδα σε ένα υπόστρωμα λαμβάνει μια είσοδο από μια μικρή γειτονιά του προηγούμενου στρώματος. Η ιδέα της σύνδεσης των μονάδων με τους τοπικούς δεκτικούς τομείς χρονολογείται από τη δεκαετία του '60 με το Perceptron και την ανακάλυψη του Hubel και Wiesel σχετικά με τα τοπικά ευαίσθητα. Τα βάρη που διαμορφώνουν το δεκτικό τομέα για ένα υπόστρωμα επιβάλλονται να είναι ίσα σε όλα τα σημεία στο επίπεδο. Κάθε υπόστρωμα μπορεί να θεωρηθεί ως χάρτης χαρακτηριστικών γνωρισμάτων που έχει έναν σταθερό ανιχνευτή χαρακτηριστικών γνωρισμάτων. Τα πολλαπλάσια επίπεδα χρησιμοποιούνται συνήθως σε κάθε στρώμα έτσι ώστε τα πολλαπλάσια χαρακτηριστικά γνωρίσματα να μπορούν να ανιχνευθούν. Αυτά τα στρώματα καλούνται convolutional στρώματα. Μόλις ανιχνευθεί ένα χαρακτηριστικό γνώρισμα, η ακριβής θέση του είναι λιγότερο σημαντική. Ως εκ τούτου, τα convolutional στρώματα τυπικά ακολουθούνται από ένα άλλο στρώμα που κάνει έναν τοπικό υπολογισμό μέσου όρου και subsampling λειτουργία (π.χ. για έναν subsampling παράγοντα 2:

$$y_{ij} = (x_{2i,2j} + x_{2i+1,2j} + x_{2i,2j+1} + x_{2i+1,2j+1})/4$$

όπου y_{ij} είναι η έξοδος ενός subsampling επιπέδου στη θέση i,j και x_{ij} είναι η έξοδος του ίδιου του επιπέδου στο προηγούμενο στρώμα).

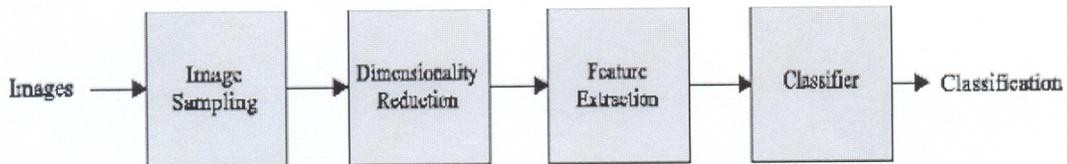
Το δίκτυο εκπαιδεύεται με τη συνηθισμένη backpropagation κλίσης-καθόδου διαδικασία. Μια στρατηγική σύνδεσης μπορεί να χρησιμοποιηθεί για να μειώσει τον αριθμό των βαρών στο δίκτυο. Παραδείγματος χάριν, ο LE Cun και άλλοι συνέδεσαν τους χάρτες χαρακτηριστικών γνωρισμάτων στο δεύτερο convolutional στρώμα μόνο με 1 ή 2 από τους χάρτες στο πρώτο subsampling στρώμα.



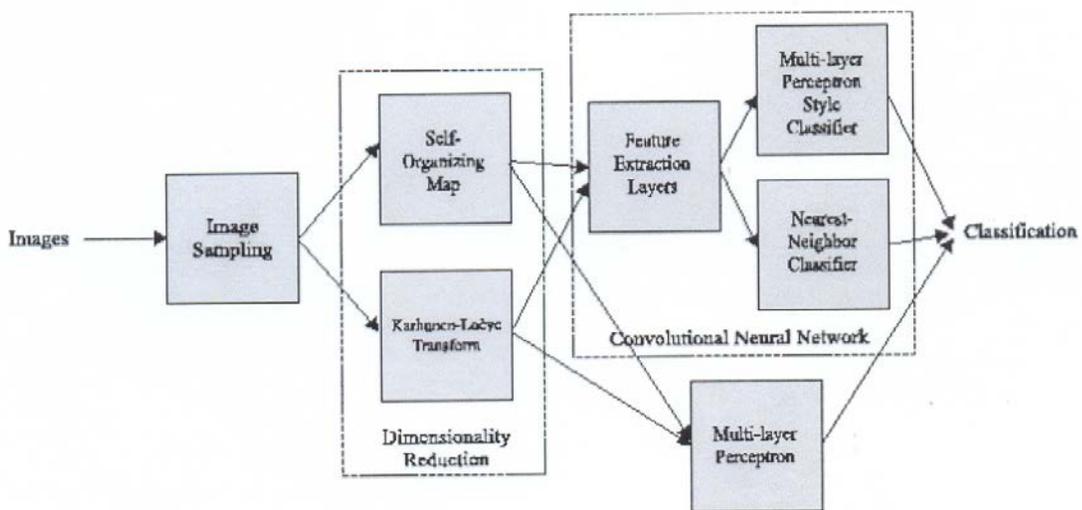
Σχήμα 4.14: Ένα τυπικό convolutional network.

Λεπτομέρειες συστήματος

Το σύστημα που έχει χρησιμοποιηθεί παρακάτω για την αναγνώριση προσώπου είναι ένας συνδυασμός των προηγούμενων τμημάτων - στα παρακάτω σχήματα (Σχήμα 4.15 και Σχήμα 4.16), παρουσιάζονται ένα υψηλού επιπέδου block διάγραμμα και μια διακοπή των διάφορων υποσυστημάτων αντίστοιχα.



Σχήμα 4.15: Ένα υψηλού επιπέδου block diagram του συστήματος που χρησιμοποιήθηκε για την αναγνώριση προσώπου.



Σχήμα 4.16: Ένα διάγραμμα του συστήματος που έχει χρησιμοποιηθεί για την αναγνώριση προσώπου παρουσιάζοντας εναλλακτικές μεθόδους.

Ο πολυστρωματικός perceptron ταξινομητής αντιπροσωπεύει το τελικό MLP πλήρως συνδεδεμένο στρώμα του convolutional δικτύου. Ο πλησιέστερος γειτονικός ταξινομητής είναι ενδεχομένως ενδιαφέρων επειδή μπορεί να το καταστήσει πιθανό να προσθέσει τις νέες κατηγορίες με ελάχιστο πρόσθετο χρόνο κατάρτισης. Το κατώτατο πολυστρωματικό perceptron δείχνει ότι ολόκληρο το convolutional δίκτυο μπορεί να αντικατασταθεί με ένα πολυστρωματικό perceptron. Τα αποτελέσματα παρουσιάζονται με είτε έναν self-organizing map είτε με τη Karhunen-Loeve μετατροπή που χρησιμοποιείται για τη μείωση της διαστατικότητας, και είτε ένα convolutional νευρωνικό δίκτυο, είτε ένα πολυστρωματικό perceptron για την ταξινόμηση.

1. Για τις εικόνες στο σύνολο κατάρτισης, ένα σταθερό παράθυρο μεγέθους (π.χ. 5x5) προβάλλεται μπροστά από ολόκληρη την εικόνα όπως φαίνεται στο Σχήμα 4.13 και τα τοπικά δείγματα εικόνας εξάγονται σε κάθε βήμα. Σε κάθε βήμα το παράθυρο κινείται κατά 4 pixels.

2. Ένας self-organizing map (π.χ. με τρεις διαστάσεις και πέντε κόμβους ανά διάσταση, $5^3=125$ συνολικούς κόμβους) εκπαιδεύεται στα διανύσματα από το προηγούμενο στάδιο. Το SOM κβαντοποιεί τα 25-διάστασης διανύσματα εισόδου σε 125 τοπολογικά διαταγμένες τιμές. Οι τρεις διαστάσεις του SOM μπορούν να θεωρηθούν ως τρία χαρακτηριστικά γνωρίσματα.

3. Το ίδιο παράθυρο όπως στην πρώτη φάση is stepped over όλες τις εικόνες του συνόλου κατάρτισης και δοκιμής. Τα τοπικά δείγματα εικόνας περνούν μέσω του SOM σε κάθε βήμα, δημιουργώντας έτσι νέα σύνολα κατάρτισης και δοκιμής στο διάστημα εξόδου που δημιουργείται από τον self-organizing map. (Κάθε εικόνα εισόδου αντιπροσωπεύεται τώρα από 3 χάρτες, κάθε ένας από τους οποίους αντιστοιχεί σε μια διάσταση στο SOM. Το μέγεθος αυτών των χαρτών είναι ίσο με το μέγεθος της εικόνας εισόδου (92x112) διαιρούμενο με το μέγεθος των βημάτων (για ένα μέγεθος βημάτων 4, οι χάρτες είναι 23x28).)

4. Ένα convolutional νευρωνικό δίκτυο εκπαιδεύεται στο πρόσφατα δημιουργημένο σύνολο κατάρτισης.

Λεπτομέρειες προσομοίωσης

Για το SOM, η κατάρτιση είναι χωρισμένη σε δύο φάσεις, μια φάση διαταγής και μια φάση λεπτής ρύθμισης. Στην πρώτη φάση εκτελούνται 100.000 αναπροσαρμογές, και 50.000 στη δεύτερη. Στην πρώτη φάση, η γειτονική ακτίνα αρχίζει στα 2/3 του μεγέθους του χάρτη και μειώνεται γραμμικά στο 1. Το ποσοστό εκμάθησης κατά τη διάρκεια αυτής της φάσης είναι:

$$0.7x(1-n/N)$$

όπου το n είναι ο τρέχων αριθμός αναπροσαρμογών, και N είναι ο συνολικός αριθμός αναπροσαρμογών.

Στη δεύτερη φάση, η γειτονική ακτίνα αρχίζει από 2 και μειώνεται σε 1. Το ποσοστό εκμάθησης κατά τη διάρκεια αυτής της φάσης είναι: $0.02x(1-n/N)$.

Το convolutional δίκτυο περιείχε πέντε στρώματα αποκλείοντας το στρώμα εισόδου. Υπολογίστηκε ένα μέτρο αξιοπιστίας για κάθε ταξινόμηση:

$$y_m (y_m - y_{2m})$$

όπου y_m είναι η μέγιστη έξοδος, και y_{2m} είναι η δεύτερη μέγιστη έξοδος (για τα αποτελέσματα που έχουν μετασχηματιστεί χρησιμοποιώντας το μετασχηματισμό *softmax*):

$$y_i = \frac{\exp(u_i)}{\sum_j^k \exp(u_j)}$$

όπου u_i είναι τα αρχικά αποτελέσματα, y_i είναι τα μετασχηματισμένα αποτελέσματα, και το k είναι ο αριθμός των αποτελεσμάτων). Ο αριθμός των επιπέδων σε κάθε στρώμα, οι διαστάσεις των επιπέδων, και οι διαστάσεις των δεκτικών τομέων παρουσιάζονται στον Πίνακα 1. Το δίκτυο εκπαιδεύθηκε με backpropagation για συνολικά 20.000 αναπροσαρμογές. Τα βάρη στο δίκτυο ενημερώθηκαν μετά από κάθε παρουσίαση σχεδίου, σε αντίθεση με την αναπροσαρμογή batch όπου τα βάρη ενημερώνονται μόνο μια φορά σε κάθε πέρασμα μέσω του συνόλου κατάρτισης. Όλες οι εισοδοί ομαλοποιήθηκαν για να βρεθούν στη σειρά -1 έως 1. Όλοι οι κόμβοι περιέλαβαν μια bias είσοδο που ήταν μέρος της διαδικασίας βελτιστοποίησης. Επιλέχτηκε το καλύτερο των 10 τυχαίων συνόλων βάρους για τις αρχικές παραμέτρους του δικτύου με την αξιολόγηση της απόδοσης του συνόλου κατάρτισης. Τα βάρη αρχικοποιήθηκαν σε κάθε κόμβο από τον κόμβο βάσης ως ομοιόμορφα διανεμημένοι τυχαίοι αριθμοί στη σειρά:

$$(-2,4/F_i, 2,4/F_i)$$

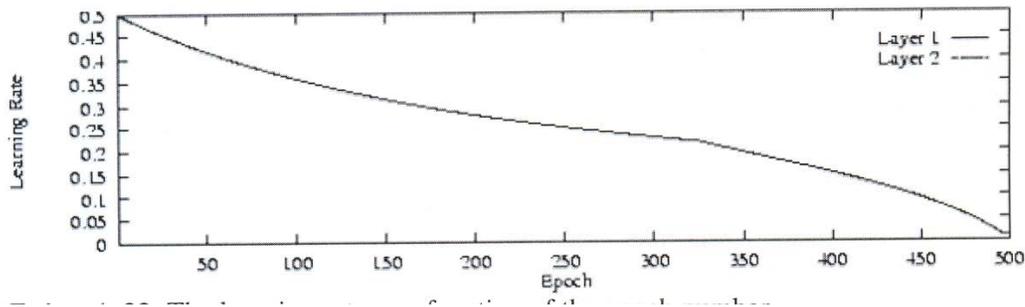
όπου το F_i είναι fan-in του νευρώνα i .

Τα αποτελέσματα στόχων ήταν -0,8 και 0,8 χρησιμοποιώντας τη συνάρτηση ενεργοποίησης εξόδου tanh. Χρησιμοποιήθηκε η τετραγωνική συνάρτηση κόστους. Έπειτα χρησιμοποιήθηκε μια αναζήτηση του converge ποσοστού εκμάθησης:

$$\eta = \frac{\eta_0 c_1}{N/2 + \max\left(1, (c_1 - \frac{\max(0, c_1(n - c_2 N))}{(1 - c_2)N})\right)}$$

όπου n είναι το ποσοστό εκμάθησης, n_0 είναι το αρχικό ποσοστό εκμάθησης ίσο με 0.1, N είναι ο συνολικός αριθμός εκπαιδεύσεων (total training epochs), n είναι η τρέχουσα training epoch, $c1=50$, $c2=0,65$. Το σχεδιάγραμμα παρουσιάζεται στο Σχήμα 4.17. Ο συνολικός χρόνος κατάρτισης ήταν περίπου τέσσερις ώρες σε ένα σύστημα SGI Indy

100Mhz MIPS R4400.



Σχήμα 4.17: The learning rate as a function of the epoch number.

Layer	Type	Units	x	y	Receptive field x	Receptive field y	Connection Percentage
1	Convolutional	20	21	26	3	3	100
2	Subsampling	20	11	13	2	2	-
3	Convolutional	25	9	11	3	3	30
4	Subsampling	25	5	6	2	2	-
5	Fully Connected	40	1	1	5	6	100

Πίνακας 4. 1: Διαστάσεις για το convolutional δίκτυο. Το ποσοστό σύνδεσης αναφέρεται στο ποσοστό των κόμβων στο προηγούμενο στρώμα με το οποίο κάθε κόμβος στο τρέχον στρώμα συνδέεται - μια αξία λιγότερο από 100% μειώνει το συνολικό αριθμό βαρών στο δίκτυο και μπορεί να βελτιώσει τη γενίκευση. Η στρατηγική σύνδεσης που χρησιμοποιείται εδώ είναι παρόμοια με αυτήν που χρησιμοποιείται για την αναγνώριση χαρακτήρα. Εντούτοις, οι συνδέσεις μεταξύ των στρωμάτων 2 και 3 επιλέγονται τυχαία. Σαν παράδειγμα για το πώς οι ακριβείς συνδέσεις μπορούν να καθοριστούν από τον πίνακα - το μέγεθος των πρώτων ενδιάμεσων στρωμάτων (21x26) είναι ίσο με το συνολικό αριθμό τρόπων τοποθέτησης ενός 3x3 δεκτικού τομέα στα ενδιάμεσα στρώματα εισόδου (23x28).

Πειραματικά αποτελέσματα

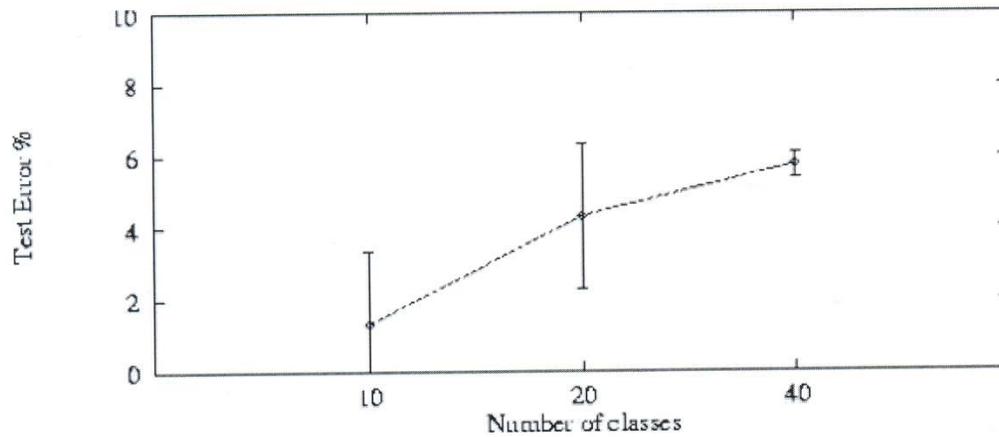
Εκτελέστηκαν διάφορα πειράματα και παρακάτω παρουσιάζονται τα αποτελέσματα. Όλα τα πειράματα εκτελέστηκαν με 5 εικόνες κατάρτισης και 5 εικόνες δοκιμής ανά άτομο για συνολικά 200 εικόνες κατάρτισης και 200 εικόνες δοκιμής. Δεν υπήρξε καμία επικάλυψη μεταξύ των συνόλων κατάρτισης και δοκιμής. Σημειώνουμε ότι ένα σύστημα που υποθέτει τη σωστή απάντηση θα ήταν το κατάλληλο μέσα από σαράντα φορές, δίνοντας ένα ποσοστό λάθους 97,5%. Για τα ακόλουθα σύνολα πειραμάτων, ποικίλλουμε μόνο μια παράμετρο σε κάθε περίπτωση. Οι φραγμοί λάθους που παρουσιάζονται στις γραφικές παραστάσεις αντιπροσωπεύουν συν ή πλην μια σταθερή απόκλιση της διανομής των αποτελεσμάτων από έναν αριθμό προσομοιώσεων. Οι σταθερές που χρησιμοποιήθηκαν σε κάθε σύνολο πειραμάτων ήταν: αριθμός κατηγοριών: 40, μέθοδος μείωσης διαστατικότητας: SOM, διαστάσεις στο SOM: 3, αριθμός κόμβων ανά διάσταση

SOM: 5, εξαγωγή δειγμάτων εικόνας: αρχικές τιμές έντασης, εικόνες κατάρτισης ανά κατηγορία: 5. Οι σταθερές σε κάθε σύνολο πειραμάτων μπορεί να μη δώσουν την καλύτερη δυνατή απόδοση όπως το τρέχον καλύτερο σύστημα εκτέλεσης λήφθηκε μόνο ως αποτέλεσμα αυτών των πειραμάτων. Τα πειράματα είναι τα ακόλουθα:

1. *Παραλλαγή του αριθμού των μονάδων εξόδου* - ο Πίνακας 4.2 και το Σχήμα 4.18 παρουσιάζουν το ποσοστό λάθους του συστήματος καθώς ο αριθμός των κατηγοριών ποικίλει από 10 έως 20 και έως 40. Όπως αναμενόταν, η απόδοση βελτιώνεται με τις χαμηλότερες κατηγορίες για να κάνει διακρίσεις μεταξύ τους.

Number of classes	10	20	40
Error rate	1.33%	4.33%	5.75%

Πίνακας 4. 2: Error rate of the face recognition system with varying number of classes (subjects). Each result is the average of three simulations.

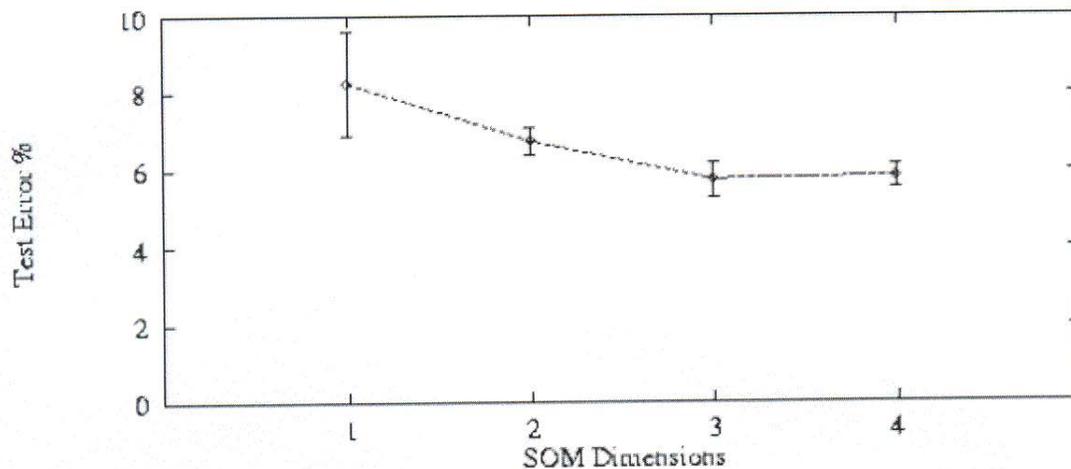


Σχήμα 4.18: The error rate as a function of the number of classes. We did not modify the network from that used for the 40 class case.

2. *Παραλλαγή της διαστατικότητας του SOM* - ο Πίνακας 4.3 και το Σχήμα 4.19 παρουσιάζουν το ποσοστό λάθους του συστήματος καθώς η διάσταση του selforganizing map ποικίλει από 1 έως 4. Η καλύτερη τιμή εκτέλεσης είναι οι τρεις διαστάσεις.

SOM Dimension	1	2	3	4
Error rate	8.25%	6.75%	5.75%	5.83%

Πίνακας 4.3: Error rate of the face recognition system with varying number of dimensions in the self-organizing map. Each result given is the average of three simulations.

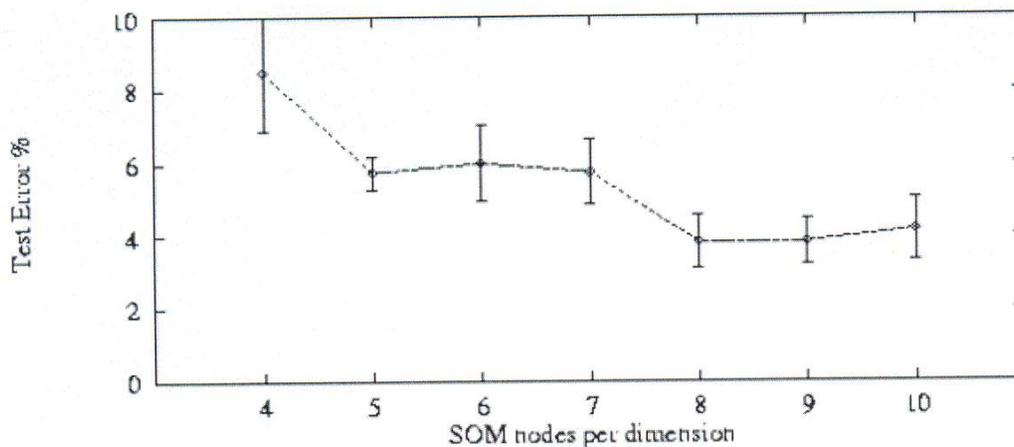


Σχήμα 4.19: The error rate as a function of the number of dimensions in the SOM.

3. Παραλλαγή του επιπέδου κβαντοποίησης του SOM - ο Πίνακας 4.4 και το Σχήμα 4.20 παρουσιάζουν το ποσοστό λάθους του συστήματος καθώς το μέγεθος του selforganizing map ποικίλει από 4 έως 10 κόμβους ανά διάσταση. Το SOM έχει τρεις διαστάσεις σε κάθε περίπτωση. Το καλύτερο μέσο ποσοστό λάθους εμφανίζεται για 8 ή 9 κόμβους ανά διάσταση. Αυτό είναι επίσης το καλύτερο μέσο ποσοστό λάθους όλων των πειραμάτων.

SOM Size	4	5	6	7	8	9	10
Error rate	8.5%	5.75%	6.0%	5.75%	3.83%	3.83%	4.16%

Πίνακας 4. 4: Error rate of the face recognition system with varying number of nodes per dimension in the self-organizing map. Each result given is the average of three simulations.



Σχήμα 4.20: The error rate as a function of the number of nodes per dimension in the SOM.

4. *Παραλλαγή του αλγορίθμου εξαγωγής δειγμάτων εικόνας* - ο Πίνακας 4.5 παρουσιάζει το αποτέλεσμα της χρησιμοποίησης των δύο τοπικών αντιπροσωπεύσεων δειγμάτων εικόνας που περιγράφονται νωρίτερα. Η χρησιμοποίηση των αρχικών τιμών έντασης έδωσε την καλύτερη απόδοση. Δεν είναι δυνατή η βελτίωση των αποτελεσμάτων ακόμα και με έρευνα της αλλαγής του βάρους που ορίστηκε στην κεντρική αξία έντασης στην εναλλακτική αντιπροσώπευση.

Input type	Pixel intensities	Differences w/base intensity
Error rate	5.75%	7.17%

Πίνακας 4.5: Error rate of the face recognition system with varying image sample representation. Each result is the average of three simulations.

5. *Αντικαθιστώντας το SOM με την KL μετατροπή* - ο Πίνακας 4.6 παρουσιάζει τα αποτελέσματα της αντικατάστασης του self-organizing map με τη Karhunen-Loeve μετατροπή. Ερευνήθηκε η χρησιμοποίηση αρχικά ενός, δύο, και τριών eigenvectors για την προβολή. Εκπληκτικά, το σύστημα αποδίδει καλύτερα με μόνο ένα eigenvector. Η ενυπάρχουσα κβαντοποίηση στο SOM θα μπορούσε να παρέχει έναν βαθμό σταθερότητας στις δευτερεύουσες (πιο ασήμαντες) διαφορές δειγμάτων εικόνας και η κβαντοποίηση των PCA προβολών μπορεί να βελτιώσει την απόδοση.

Dimensionality reduction	Linear PCA	SOM
Error rate	5.33%	3.83%

Πίνακας 4. 6: Error rate of the face recognition system with linear PCA and SOM feature extraction mechanisms. Each result is the average of three simulations.

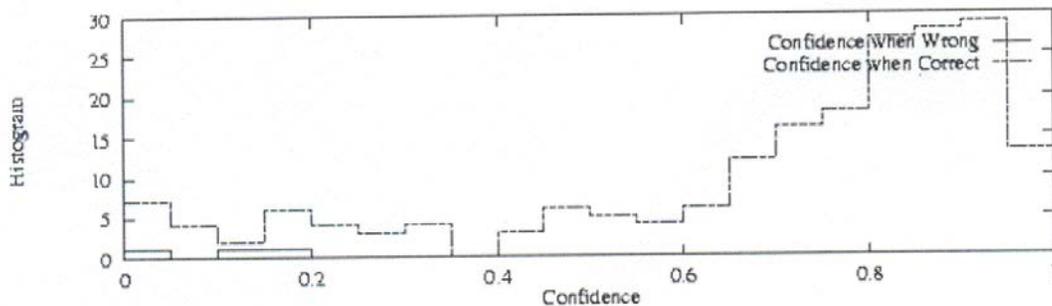
6. *Αντικαθιστώντας το CN με ένα MLP* - ο Πίνακας 4.7 παρουσιάζει τα αποτελέσματα της αντικατάστασης του convolutional δικτύου με ένα πολυστρωματικό perceptron. Η απόδοση είναι πολύ κακή. Αυτό το αποτέλεσμα αναμενόταν επειδή το πολυστρωματικό perceptron δεν έχει ενσωματωμένη σταθερότητα στη δευτερεύουσα μετάφραση και στην τοπική παραμόρφωση που δημιουργείται στο convolutional δίκτυο χρησιμοποιώντας τους τοπικούς δεκτικούς τομείς, τα κοινά βάρη, και το spatial subsampling. Σαν παράδειγμα, εξετάστε τότε ένα χαρακτηριστικό γνώρισμα μετατοπίζεται σε μια εικόνα δοκιμής σε σύγκριση με την εικόνα (εικόνες) κατάρτισης για το άτομο. Αναμένουμε το MLP να έχει τη δυσκολία να αναγνωρίσει ένα χαρακτηριστικό γνώρισμα που έχει μετατοπιστεί σε σύγκριση με τις εικόνες κατάρτισης επειδή τα βάρη που συνδέθηκαν με τη νέα θέση δεν εκπαιδεύθηκαν για το χαρακτηριστικό γνώρισμα.

Το MLP περιείχε ένα κρυμμένο στρώμα. Ερευνήθηκαν τα ακόλουθα κρυμμένα μεγέθη στρωμάτων για το πολυστρωματικό perceptron: 20,50,100,200, και 500. Η καλύτερη απόδοση λήφθηκε με 200 κρυμμένους κόμβους και έναν χρόνο κατάρτισης 2 ημερών. Το χρονοδιάγραμμα του ποσοστού εκμάθησης και το αρχικό ποσοστό εκμάθησης ήταν τα ίδια όπως για το αρχικό δίκτυο. Η επιλογή του κατάλληλου αριθμού κόμβων σε κάθε στρώμα είναι δύσκολη (π.χ. ένα δίκτυο με δύο κρυμμένα στρώματα που περιέχουν 100 και 50 κόμβους αντίστοιχα τα οποία οδήγησαν σε ένα ποσοστό λάθους 90%).

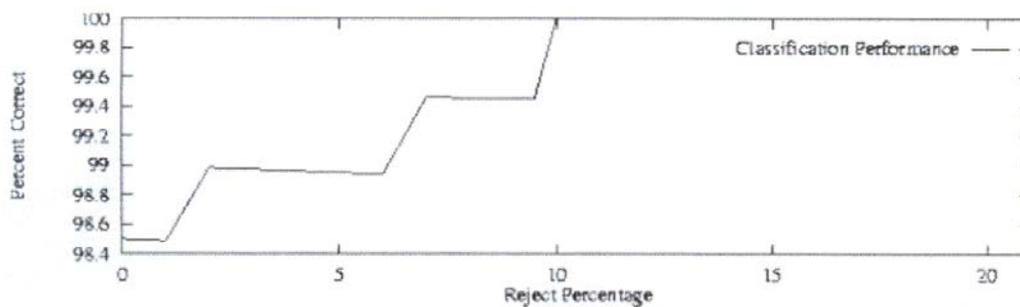
	Linear PCA	SOM
MLP	41.2%	39.6%
CN	5.33%	3.83%

Πίνακας 4. 7: Error rate comparison of the various feature extraction and classification methods. Each result is the average of three simulations.

7. Η ανταλλαγή μεταξύ κατώτατου ορίου απόρριψης και ακρίβειας αναγνώρισης - το Σχήμα 4.21 παρουσιάζει ένα ιστόγραμμα της εμπιστοσύνης του συστήματος αναγνώρισης για τις περιπτώσεις όπου ο ταξινομητής είναι σωστός και όπου είναι λανθασμένος για ένα από τα καλύτερα συστήματα εκτέλεσης. Από αυτήν τη γραφική παράσταση αναμένουμε ότι η απόδοση ταξινόμησης θα αυξηθεί σημαντικά εάν απορρίψουμε τις περιπτώσεις κάτω από ένα ορισμένο κατώτατο όριο εμπιστοσύνης. Το Σχήμα 4.22 παρουσιάζει την απόδοση του συστήματος καθώς το κατώτατο όριο απόρριψης αυξάνεται. Μπορούμε να δούμε ότι με την απόρριψη των παραδειγμάτων με χαμηλή εμπιστοσύνη μπορούμε σημαντικά να αυξήσουμε την απόδοση ταξινόμησης του συστήματος. Εάν πάρουμε σαν παράδειγμα ένα σύστημα που χρησιμοποίησε μια τηλεοπτική φωτογραφική μηχανή για να πάρει διάφορες εικόνες κατά τη διάρκεια μιας μικρής χρονικής περιόδου, θα μπορούσαμε να αναμένουμε ότι μια υψηλή απόδοση θα ήταν εφικτή με ένα κατάλληλο κατώτατο όριο απόρριψης.



Σχήμα 4.21: Ένα ιστόγραμμα που απεικονίζει την εμπιστοσύνη του ταξινομητή όταν αποδεικνύεται να είναι σωστός, και η εμπιστοσύνη όταν είναι λανθασμένος. Η γραφική παράσταση προτείνει ότι μπορούμε να βελτιώσουμε αρκετά την απόδοση ταξινόμησης με την απόρριψη των περιπτώσεων όπου ο ταξινομητής έχει μια χαμηλή εμπιστοσύνη.



Σχήμα 4.22: Η καθορισμένη απόδοση ταξινόμησης (δοκιμής) σε συνάρτηση του ποσοστού των απορριφθέντων δειγμάτων. Η απόδοση ταξινόμησης μπορεί να βελτιωθεί σημαντικά με την απόρριψη των περιπτώσεων με χαμηλή εμπιστοσύνη.

8. Σύγκριση με άλλα γνωστά αποτελέσματα στην ίδια βάση δεδομένων - ο Πίνακας 4.8 παρουσιάζει μια περίληψη της απόδοσης των συστημάτων για τα οποία έχουμε αποτελέσματα χρησιμοποιώντας την ORL βάση δεδομένων. Σε αυτήν την περίπτωση, χρησιμοποιήθηκε ένα SOM επίπεδο κβαντοποίησης των 8. Το Σχήμα 4.23 παρουσιάζει τις εικόνες που ταξινομήθηκαν ανακριβώς για ένα από τα καλύτερα συστήματα εκτέλεσης.



Σχήμα 4.23: Εικόνες δοκιμής. Οι εικόνες με παχιά άσπρη άκρη ταξινομήθηκαν ανακριβώς από ένα από τα καλύτερα συστήματα εκτέλεσης.

System	Error rate	Classification time
Top-down HMM	13%	n/a
Eigenfaces	10.5%	n/a
Pseudo 2D-HMM	5%	240 seconds ¹
SOM+CN	3.8%	<0.5 seconds ²

Πίνακας 4. 8: Error rate of the various systems. ¹ On a Sun Sparc II. ² On an SGI Indy MIPS R4400 100Mhz system.

9. Παραλλαγή του αριθμού εικόνων κατάρτισης ανά άτομο. Ο Πίνακας 4.9 παρουσιάζει τα αποτελέσματα της ποικιλίας του αριθμού εικόνων ανά κατηγορία που χρησιμοποιείται στο σύνολο κατάρτισης από 1 έως 5 για PCA+CN, SOM+CN και επίσης για τον eigenfaces αλγόριθμο. Εφαρμόστηκαν δύο εκδόσεις του eigenfaces αλγόριθμου: η πρώτη έκδοση δημιουργεί τα διανύσματα για κάθε κατηγορία στο σύνολο κατάρτισης με τον υπολογισμό του μέσου όρου των αποτελεσμάτων της αντιπροσώπευσης eigenface σε όλες τις εικόνες για το ίδιο πρόσωπο. Εντούτοις, διαπιστώθηκε ότι χρησιμοποιώντας χωριστά διανύσματα κατάρτισης για κάθε εικόνα κατάρτισης υπάρχει καλύτερη απόδοση. Διαπιστώθηκε ακόμα ότι η χρησιμοποίηση μεταξύ 40 έως 100 eigenfaces οδήγησε σε παρόμοια απόδοση. Μπορούμε να δούμε ότι οι μέθοδοι PCA +CN και SOM+CN είναι και οι δύο ανώτερες στην τεχνική eigenfaces ακόμα και όταν υπάρχει μόνο μια εικόνα κατάρτισης ανά άτομο. Η μέθοδος SOM+CN αποδίδει με συνέπεια καλύτερα από τη μέθοδο PCA+CN.

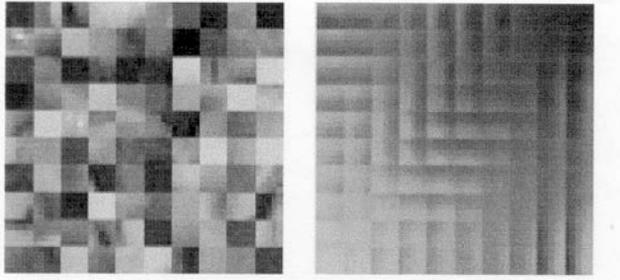
Images per person	1	2	3	4	5
Eigenfaces-average per class	38.6	28.8	28.9	27.1	26
Eigenfaces-one per image	38.6	20.9	18.2	15.4	10.5
PCA+CN	34.2	17.2	13.2	12.1	7.5
SOM+CN	30.0	17.0	11.8	7.1	3.8

Πίνακας 4. 9: Το ποσοστό λάθους για τον eigenfaces αλγόριθμο και το SOM+CN καθώς το μέγεθος του συνόλου κατάρτισης ποικίλει από 1 έως 5 εικόνες ανά άτομο.

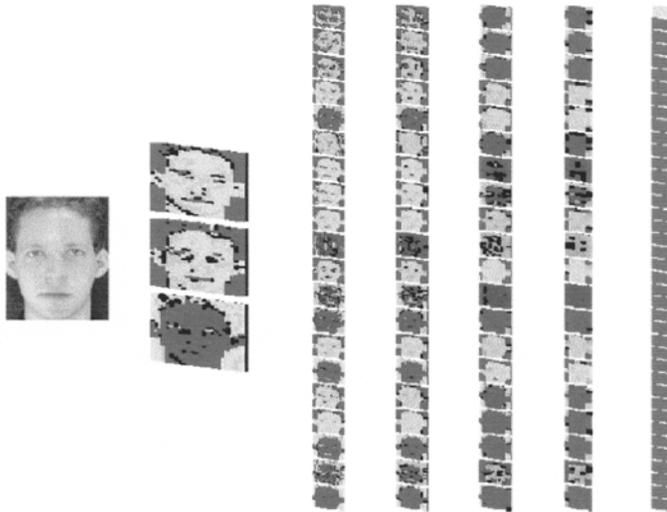
Τα αποτελέσματα δείχνουν ότι ένα convolutional δίκτυο μπορεί να είναι καταλληλότερο στη δεδομένη κατάσταση σε σύγκριση με ένα τυποποιημένο πολυστρωματικό perceptron. Αυτό ανταποκρίνεται με την κοινή πεποίθηση ότι η ενσωμάτωση της προγενέστερης γνώσης είναι επιθυμητή για τα δίκτυα του τύπου MLP.

Τα convolutional δίκτυα έχουν χρησιμοποιηθεί στις ακατέργαστες εικόνες χωρίς οποιαδήποτε προεπεξεργασία. Χωρίς την προεπεξεργασία τα προκύπτοντα CN είναι μεγαλύτερα, πιο εντατικά υπολογιστικά, και δεν έχουν αποδώσει τόσο καλά στα πειράματα (π.χ. χρησιμοποιώντας καμία προεπεξεργασία και την ίδια αρχιτεκτονική CN εκτός από τους αρχικούς δεκτικούς τομείς 8x8 οδήγησαν σε περίπου δύο φορές μεγαλύτερο λάθος (για την περίπτωση πέντε εικόνων ανά άτομο)).

Το Σχήμα 4.24 παρουσιάζει τα τυχαία αρχικά τοπικά δείγματα εικόνας τα οποία ανταποκρίνονται σε κάθε κόμβο σε ένα διδιάστατο SOM, και τα τελικά δείγματα στα οποία το SOM συγκλίνει. Ανιχνεύοντας κατά μήκος των σειρών και των στηλών μπορούμε να δούμε ότι τα κβαντοποιημένα δείγματα αντιπροσωπεύουν σχέδια ομαλής αλλαγής σκιάς. Αυτό είναι η αρχική αντιπροσώπευση από την οποία διαδοχικά τα χαρακτηριστικά γνωρίσματα υψηλού επιπέδου εξάγονται χρησιμοποιώντας το convolutional δίκτυο. Το Σχήμα 4.25 παρουσιάζει την ενεργοποίηση των κόμβων σε ένα πειραματικό convolutional δίκτυο για μια συγκεκριμένη δοκιμή εικόνας.

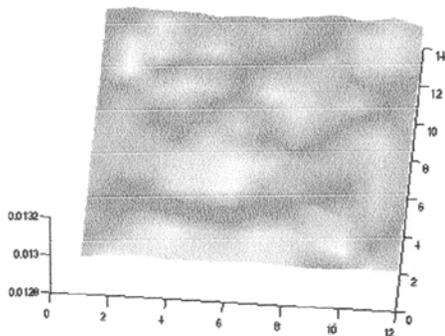


Σχήμα 4.24: SOM image samples before training (a random set of image samples) and after training.



Σχήμα 4.25: Μια απεικόνιση των κόμβων χαρτών σε ένα convolutional δίκτυο παρουσιάζοντας τις τιμές ενεργοποίησης για μια συγκεκριμένη εικόνα δοκιμής. Η εικόνα εισόδου παρουσιάζεται στα αριστερά. Σε αυτήν την περίπτωση η εικόνα είναι σωστά ταξινομημένη με μόνο ένα ενεργοποιημένο κόμβο εξόδου (top node). Από τα αριστερά στα δεξιά μετά από την εικόνα εισόδου, τα στρώματα είναι τα εξής το στρώμα εισόδου, το convolutional στρώμα 1, το subsampling στρώμα 1, το convolutional στρώμα 2, το subsampling στρώμα 2, και το στρώμα εξόδου. Τα τρία επίπεδα στο στρώμα εισόδου αντιστοιχούν στις τρεις διαστάσεις του SOM.

Το Σχήμα 4.26 παρουσιάζει τα αποτελέσματα της ανάλυσης της ευαισθησίας προκειμένου να καθοριστεί ποια μέρη της εικόνας εισόδου είναι σημαντικότερα για την ταξινόμηση. Χρησιμοποιώντας τη μέθοδο Baluja και Pomerleau κάθε ένα από τα επίπεδα εισόδου στο convolutional δίκτυο διαιρέθηκε σε 2x2 τμήματα (τα επίπεδα εισόδου είναι 23x28). Κάθε ένα από 168 (12x14) segments αντικαταστάθηκαν με τυχαίο θόρυβο, ένα segment τη φορά. Η απόδοση δοκιμής υπολογίστηκε σε κάθε βήμα. Το σφάλμα του δικτύου κατά την αντικατάσταση των τμημάτων εισόδου με τυχαίο θόρυβο δίνει μια ένδειξη για το πόσο σημαντικό είναι το κάθε μέρος της εικόνας για το στόχο της ταξινόμησης. Από το σχήμα μπορεί να παρατηρηθεί ότι, όπως αναμένεται, τα μάτια, η μύτη, το στόμα, το πηγούνι, και οι περιοχές με μαλλιά είναι όλες σημαντικές στο στόχο της ταξινόμησης.



Σχήμα 4.26: Η ευαισθησία στα διάφορα μέρη της εικόνας εισόδου. Μπορεί να παρατηρηθεί ότι τα μάτια, το στόμα, η μύτη, το πηγούνι, και οι περιοχές με μαλλιά είναι όλες σημαντικές για την ταξινόμηση. Ο Z άξονας αντιστοιχεί στο μέσο τετραγωνικό σφάλμα παρά στο σφάλμα ταξινόμησης (το μέσο τετραγωνικό σφάλμα είναι προτιμότερο διότι ποικίλλει σε μια ομαλότερη μορφή δεδομένου ότι οι εικόνες εισόδου είναι διαταραγμένες). Ο προσανατολισμός της εικόνας αντιστοιχεί σε κάθετες εικόνες προσώπου.

Είναι απίθανο το δίκτυο να μπορούσε να εξαγάγει ένα βέλτιστο σύνολο χαρακτηριστικών γνωρισμάτων για όλες τις εικόνες. Αν και η ακριβής διαδικασία της ανθρώπινης αναγνώρισης προσώπου είναι άγνωστη, υπάρχουν πολλά χαρακτηριστικά γνωρίσματα που οι άνθρωποι μπορούν να χρησιμοποιήσουν αλλά τα συστήματα είναι απίθανο να ανακαλύψουν βέλτιστα - π.χ. α) γνώση της τρισδιάστατης δομής του προσώπου, β) γνώση της μύτης, των ματιών, του στόματος, κλπ., γ) γενίκευση στο γυαλιά / καθόλου γυαλιά, διαφορετικό μήκος μαλλιών, κλπ., και δ) γνώση των εκφράσεων του προσώπου.

Υπολογιστική πολυπλοκότητα

Το SOM παίρνει ιδιαίτερο χρόνο να εκπαιδευτεί. Εντούτοις αυτό δεν είναι ένα μειονέκτημα της προσέγγισης, καθώς το σύστημα μπορεί να επεκταθεί για να καλύψει νέες κατηγορίες χωρίς επανεκπαίδευση του SOM. Αυτό που απαιτείται είναι τα δείγματα εικόνας που χρησιμοποιούνται αρχικά για να εκπαιδεύσουν το SOM να είναι αρκετά αντιπροσωπευτικά των δειγμάτων εικόνας που χρησιμοποιούνται στις νέες εικόνες.

Το convolutional δίκτυο εξάγει χαρακτηριστικά γνωρίσματα από την εικόνα. Είναι δυνατό να χρησιμοποιηθεί η σταθερή εξαγωγή χαρακτηριστικών γνωρισμάτων. Σκεφτείτε εάν χωρίζαμε το convolutional δίκτυο σε δύο μέρη: τα αρχικά στρώματα εξαγωγής χαρακτηριστικών γνωρισμάτων και τα τελικά στρώματα εξαγωγής και ταξινόμησης χαρακτηριστικών γνωρισμάτων. Λαμβάνοντας υπόψη ένα καλά επιλεγμένο δείγμα της πλήρους διανομής των προσώπων που θέλουμε να αναγνωρίσουμε, τα χαρακτηριστικά γνωρίσματα που εξάγονται από το πρώτο τμήμα θα μπορούσαν να αναμένονται ώστε να είναι χρήσιμα για την ταξινόμηση των νέων κατηγοριών. Αυτά τα χαρακτηριστικά γνωρίσματα θα μπορούσαν έπειτα να θεωρηθούν σταθερά χαρακτηριστικά γνωρίσματα και το πρώτο μέρος του δικτύου μπορεί να μην χρειάζεται να επανεκπαιδευθεί κατά την προσθήκη νέων κατηγοριών. Το σημείο στο οποίο το convolutional δίκτυο είναι διαιρεμένο σε δύο θα εξαρτώνταν από το πόσο καλά τα χαρακτηριστικά γνωρίσματα σε κάθε στάδιο είναι χρήσιμα για την ταξινόμηση των νέων κατηγοριών (τα μεγαλύτερα χαρακτηριστικά γνωρίσματα στα τελικά στρώματα είναι λιγότερο πιθανό να είναι μια καλή βάση για την ταξινόμηση των νέων παραδειγμάτων). Σημειώνουμε ότι μπορεί να είναι δυνατό να αντικατασταθεί το δεύτερο μέρος με έναν άλλο τύπο ταξινομητή - π.χ. ένας nearestneighbors ταξινομητής. Σε αυτήν την περίπτωση ο χρόνος που απαιτείται για την επανεκπαίδευση του συστήματος κατά την προσθήκη των νέων κατηγοριών είναι ελάχιστος (τα αποσπασματικά διανύσματα χαρακτηριστικών γνωρισμάτων απλά αποθηκεύονται για τις εικόνες κατάρτισης). Για να δώσουμε μια ιδέα της υπολογιστικής πολυπλοκότητας κάθε μέρους του συστήματος καθορίζουμε:

N_c	The number of classes
N_s	The number of nodes in the self-organizing map
N_{w1}	The number of weights in the convolutional network
N_{w2}	The number of weights in the classifier
N_{tr}	The number of training examples
N_n	The number of nodes in the neighborhood function
N_{m1}	The total number of next nodes used to backpropagate the error in the CN
N_{m2}	The total number of next nodes used to backpropagate the error in the MLP Classifier
N_{od}	The output dimension of the KL projection
N_{id}	The input dimension of the KL projection
$N_{samples}$	The number of training samples for the SOM or the KL projection

N_{window} The number of local image samples per image

Οι Πίνακες 10 και 11 παρουσιάζουν την κατά προσέγγιση πολυπλοκότητα των διάφορων μερών του συστήματος κατά τη διάρκεια της κατάρτισης και της ταξινόμησης. Παρουσιάζουμε την πολυπλοκότητα και για το SOM και εναλλακτικές λύσεις KL για τη μείωση διαστατικότητας και τόσο για το νευρωνικό δίκτυο (MLP) όσο για έναν ταξινομητή nearest-neighbor (ως τελευταίο μέρος του CN - όχι ως πλήρη αντικατάσταση, δηλ. αυτό δεν είναι το ίδιο σαν τα προηγούμενα πολυστρωματικά perceptron πειράματα). Σημειώνουμε ότι η σταθερά που συνδέεται με τους λογαριθμικούς παράγοντες μπορεί να αυξηθεί εκθετικά στη χειρότερη περίπτωση. Έχουμε στοχεύσει να επιδείξουμε πώς οι υπολογιστικές κλίμακες πολυπλοκότητας σύμφωνα με τον αριθμό κατηγοριών, π.χ. για την πολυπλοκότητα κατάρτισης του ταξινομητή MLP: αν και $N_{w2} + N_{nn2}$ μπορεί να είναι μεγαλύτερο από το N_c , και οι δύο N_{w2} και N_{nn2} κλίμακες κατά προσέγγιση ανταποκρίνονται με το N_c .

Section	Training complexity
KL	$O((2 + N_{id}^2)N_{samples} + 3N_{od}^3) \approx O(N_{id}^2 + N_{od}^3)$
SOM	$O(k_1 N_{samples} N_n k_2 \log N_s) \approx O(N_{samples} N_n \log N_s)$ (N_n varies)
CN	$O(k_3 N_{tr} (N_{w1} + N_{nn1})) \approx O(N_{tr} N_{w1})$
MLP Classifier	$O(k_3 N_{tr} (N_{w2} + N_{nn2})) \approx O(N_{tr} N_c)$
NN Classifier	$O(N_{tr})$

Πίνακας 4. 10: Πολυπλοκότητα κατάρτισης. Τα k_1 και k_3 αντιπροσωπεύουν τον αριθμό των επαναλήψεων όπου το σύνολο κατάρτισης παρουσιάζεται στο δίκτυο για το SOM και για το CN αντίστοιχα.

Section	Classification complexity
KL	$O(N_{window} N_{id} N_{od})$
SOM	$O(N_{window} k_1 \log N_s) \approx O(N_{window} \log N_s)$
CN	$O(k_2 N_{w1}) \approx O(N_{w1})$
MLP Classifier	$O(N_{w2}) \approx O(N_c)$
NN Classifier	$O(k_4 \log N_{tr}) \approx O(\log N_c)$

Πίνακας 4. 11: Πολυπλοκότητα ταξινόμησης. Το k_2 αντιπροσωπεύει το βαθμό της κοινής αντένστασης βάρους. (degree of shared weight replication)

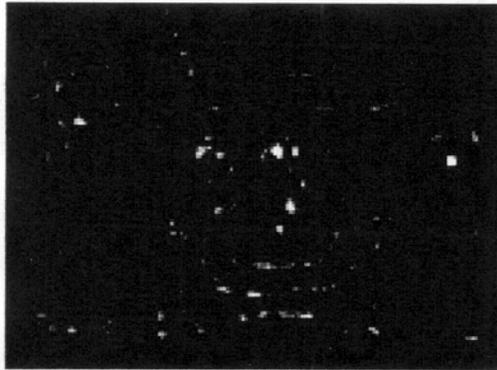
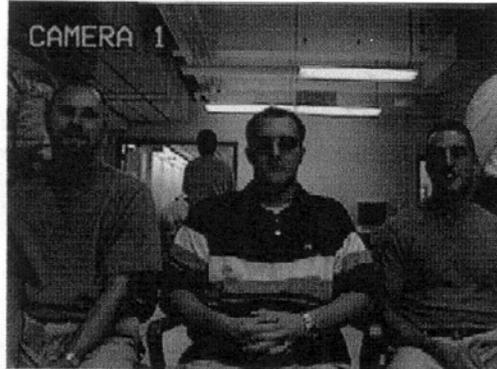
Η πολυπλοκότητα του SOM είναι ανεξάρτητη από τον αριθμό των κατηγοριών. Η πολυπλοκότητα των CN διαβαθμίζεται ανάλογα με τον αριθμό των βαρών στο δίκτυο. Όταν ο αριθμός των χαρτών χαρακτηριστικών γνωρισμάτων στα εσωτερικά στρώματα είναι σταθερός, ο αριθμός των βαρών διαβαθμίζεται κατά προσέγγιση σύμφωνα με τον αριθμό των κατηγοριών εξόδου (ο αριθμός βαρών στο στρώμα εξόδου εξουσιάζει τα βάρη στα αρχικά στρώματα).

Αναγνώριση Προσώπου με τη χρήση των Morphological Shared-Weight Neural Networks (MSNN)

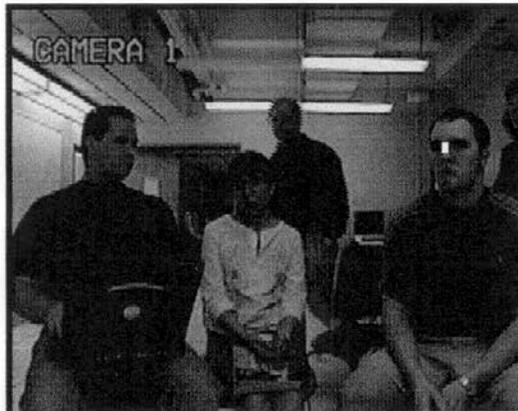
Τα μέχρι στιγμής υπάρχον συστήματα αναγνώρισης προσώπου έχουν τους περιορισμούς τους στην απόδοση κάτω από πραγματικές συνθήκες. Συχνά η απόδοση πέφτει καθώς οι εικόνες-στόχοι ποικίλλουν από μια ευθεία (κατά μέτωπο) σύλληψη ενός προσώπου. Πολλά συστήματα μπορούν να είναι "FOOLED" από τις απλές παραλλαγές στο επίπεδο φωτισμού περιβάλλοντος, τις εκφράσεις του προσώπου και διάφορες παραλλαγές μορφής προσώπου (καπέλα, μαλλιά, γυαλιά ήλιου, κ.λ.π.). Για να υπερνικήσουμε αυτούς τους περιορισμούς, σχεδιάστηκε μια μορφολογική δομή νευρωνικών δικτύων «μοιραζόμενου» βάρους (Shared-Weight) ικανή να μαθαίνει τα πρόσωπα από τις εικόνες gray-scale. Το MSNN είναι ανεπηρέαστο από τις μετατοπίσεις στα ελαφρά επίπεδα, και παρουσιάζει πολύ υψηλή αξιοπιστία κατά τη διάρκεια της κλίσης, της περιστροφής και του κλεισίματος αντικειμενικού στόχου.

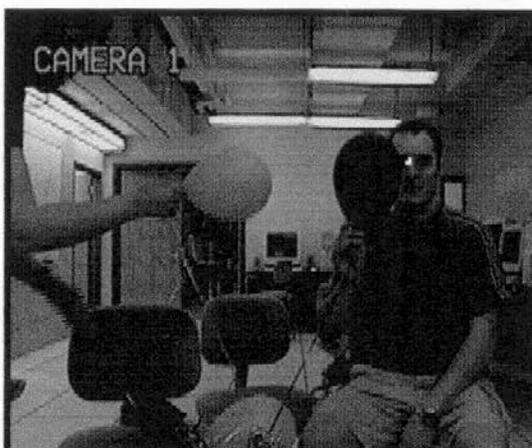
Το MSNN είναι ένα ετερογενές δίκτυο που αποτελείται από δύο κλιμακωτά υποδίκτυα, την εξαγωγή χαρακτηριστικών γνωρισμάτων και τα νευρωνικά δίκτυα ταξινόμησης. Το στρώμα εξόδου χαρακτηριστικών παίρνει έναν δύο διαστάσεων πίνακα ως είσοδο, ο οποίος είναι η sub-image εισόδου. Αυτή η είσοδος περνά μέσω πυρήνων (kernels) που μπορούν να εκτελέσουν μια γραμμική ή μη γραμμική χαρτογράφηση και οι οποίοι είναι τα μορφολογικά εργαλεία δόμησης. Κάθε subimage εισόδου στο δίκτυο περνά και τόσο μέσω των *hit* όσο και των *miss* πυρήνων. Αυτά τα δομικά εργαλεία συνθέτουν μαζί τα βάρη εισόδου του επόμενου στρώματος, έναν χάρτη χαρακτηριστικών γνωρισμάτων. Ο συνδυασμός των πυρήνων δόμησης και οι χάρτες χαρακτηριστικών γνωρισμάτων εκτελούν την gray-scale hit-miss συνάρτηση, η οποία είναι το αποτέλεσμα εξόδου για τη φάση εξαγωγής χαρακτηριστικών γνωρισμάτων του MSNN. Αυτή η έξοδος είναι η άμεση είσοδος σε ένα κλασικό feed-forward νευρωνικό δίκτυο. Τα δίκτυα εξαγωγής και ταξινόμησης χαρακτηριστικών γνωρισμάτων εκπαιδεύονται μαζί, επιτρέποντας στο MSNN να μάθει ταυτόχρονα την εξαγωγή και την ταξινόμηση χαρακτηριστικών γνωρισμάτων για ένα πρόσωπο. Το MSNN εκπαιδεύεται με ένα σύνολο εικόνων που παρουσιάζουν το πρόσωπο σε πολυάριθμους προσανατολισμούς-εκφράσεις, 20-35 εικόνες.

Η φάση ταξινόμησης FFN έχει μια fuzzy έξοδο της εμπιστοσύνης όπου μια sub-image είσοδο είναι το επιθυμητό πρόσωπο-στόχος. Για να χρησιμοποιήσουμε αυτήν την έξοδο, σκανάρουμε ολόκληρη την εικόνα και δημιουργούμε ένα Detection Image Plane (DIP-image black with gray and white pixels)-επίπεδο εικόνας ανίχνευσης, με τιμές εμπιστοσύνης μετατρεπόμενες σε gray-scale. Εφαρμόζεται ένα όριο κατωφλίου σε αυτήν την εικόνα, με τις αντίστοιχες υψηλές τιμές να τοποθετούνται επάνω στην εικόνα εισόδου. Το αποτέλεσμα αυτού είναι μια εικόνα με το στόχο μαρκαρισμένο από άσπρο χρώμα στη μέση του προσώπου (όπως φαίνεται παρακάτω). Μια άλλη εικόνα εξόδου είναι η BOX εικόνα. Αυτό ολοκληρώνεται με τη μετατροπή της DIP σε μια δυαδική εικόνα στο σημείο κατώτατων ορίων (κατωφλίου) και εφαρμόζοντας κάποια επεξεργασία σε αυτήν την εικόνα που παράχθηκε. Το αποτέλεσμα χρησιμοποιείται έπειτα για να κατασκευάσει ένα box (κιβώτιο) που το μέγεθος της sub-image κεντραρισμένη στο στόχο.



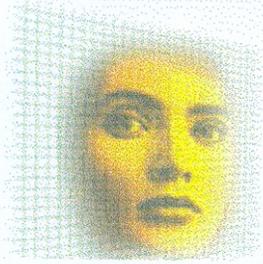
Πείραμα του στόχου-προσώπου που φορά γυαλιά ήλιου. Αρχική εικόνα εισόδου, επίπεδο εικόνας ανίχνευσης, Boxed στόχος εξόδου.





Διάφορα άλλα αποτελέσματα: μέγιστη αναγνώριση απόστασης, μερικό σχεδιάγραμμα αριστερής πλευράς, κοιτάζοντας κάτω, κλίση κεφαλιού, μερικό κλείσιμο από μπαλόνι, και φορώντας κανονικά γυαλιά μυωπίας.

Μια άλλη προσέγγιση από την εταιρεία Visage



Η τεχνολογία αναγνώρισης προσώπου της εταιρίας Visage όχι μόνο βελτιώνει τις ήδη υπάρχουσες λύσεις εξακρίβωσης ταυτότητας, αλλά προσφέρει και νέες ευκαιρίες για μια ποικιλία νέων εφαρμογών. Το πρόγραμμα χρησιμοποιεί έναν εκλεπτυσμένο αλγόριθμο που βασίζεται στη μέθοδο ανάλυσης PCA (principle Component Analysis) που έχει αναπτυχθεί στο Media Lab του MIT.

Όλη η διαδικασία γίνεται μέσω ενός software που μεταφράζει τα χαρακτηριστικά του προσώπου, όπως αυτά λαμβάνονται από μια εικόνα ή ένα video, σε ένα μοναδικό σύνολο ψηφιακών δεδομένων, διαμορφώνοντας έτσι αυτό που θα ονομάζαμε ηλεκτρονικό "αποτύπωμα προσώπου".

Όπως όλες οι βιοτεχνολογίες, έτσι και αυτή βασίζεται στην ιδιότητα που έχει το ανθρώπινο πρόσωπο να είναι μοναδικό για κάθε άνθρωπο. Το πρόγραμμα χαρτογραφεί την γεωγραφία του ανθρώπινου κρανίου, διαβάζοντας την σχετική θέση και το μέγεθος των διαφόρων χαρακτηριστικών (μέτωπο, μάτια κ.α.) και τις διάφορες γωνίες και καμπυλότητες που αυτό έχει. Το αποτύπωμα που σχηματίζεται χρησιμοποιείται τόσο σε συστήματα ταυτοποίησης, όσο και σε συστήματα πιστοποίησης, με συγκρίσεις προσώπων που γίνονται σε πραγματικό χρόνο. Κατά την διαδικασία ταυτοποίησης γίνεται σύγκριση του προσώπου ενός ατόμου με τα πρόσωπα που υπάρχουν σε μια βάση δεδομένων ώστε να καθοριστεί η ταυτότητά του. Η πιστοποίηση χαρακτηρίζεται σαν ένα-προς-ένα ταίριασμα, αφού το πρόσωπο ενός ατόμου συγκρίνεται με ένα μόνο αποθηκευμένο αποτύπωμα με σκοπό να επιβεβαιωθεί η ταυτότητά του.

Η τεχνολογία αναγνώρισης προσώπου της εταιρίας Visage είναι μοναδική λόγω της ικανότητάς της για γρήγορη επεξεργασία και ακριβές αποτέλεσμα σε πραγματικό χρόνο, σε βάσεις δεδομένων που περιέχουν εκατομμύρια πρόσωπα. Το software μπορεί στιγμιαία να υπολογίσει το αποτύπωμα του προσώπου ενός ατόμου, είτε από ζωντανό video είτε από μια ακίνητη ψηφιακή εικόνα και ύστερα να βρει σε λίγα δευτερόλεπτα, μέσα από μια πολύ μεγάλη βάση δεδομένων, αυτά τα πρόσωπα που μοιάζουν ή αυτό που ταιριάζει ακριβώς.

Οι εφαρμογές που μπορεί να έχει το πρόγραμμα είναι πάρα πολλές. Η χρήση του σαν σύστημα πιστοποίησης βρίσκει εφαρμογή σε όλα τα σημεία που πρέπει να γίνει έλεγχος πρόσβασης. Ένα τέτοιο σημείο είναι τα μηχανήματα ATM των τραπεζών. Μεγάλη χρησιμότητα μπορεί να έχει επίσης και η χρήση του στο Internet και στο ηλεκτρονικό εμπόριο. Όμως η μεγάλη γκάμα των εφαρμογών του βρίσκεται στα συστήματα ασφαλείας.

Το μεγάλο πλεονέκτημα της τεχνολογίας αναγνώρισης προσώπου δεν είναι τόσο η ένα προς ένα πιστοποίηση της ταυτότητας κάποιου, που θα του δίνει κάποια δυνατότητα πρόσβασης. Αυτό μπορεί να γίνει με πάρα πολλούς και ίσως και πιο εύκολους τρόπους που βασίζονται είτε σε συνήθειες τρόπους (passwords, PINs, κάρτες, κ.α.), είτε σε άλλες βιομετρικές τεχνολογίες.

Η αναγνώριση προσώπου αποτελεί μια βιομετρική τεχνολογία που έχει ένα σημαντικό πλεονέκτημα σε σχέση με τις άλλες. Το σύστημα μπορεί να καταγράψει το αποτύπωμα του προσώπου, με διακριτικό τρόπο, χωρίς το εν λόγω άτομο να το γνωρίζει και χωρίς να έχει την δυνατότητα να το αρνηθεί. Ο συνδυασμός του προγράμματος με ένα δίκτυο από κάμερες και η χρήση μεγάλων βάσεων δεδομένων, μας δίνουν σε όλη την έκταση τις δυνατότητες του συστήματος αυτού. Μπορεί να γίνεται η καταγραφή ενός πλήθους ανθρώπων με συστήματα video και το πρόγραμμα να εντοπίζει σε πραγματικό χρόνο τα προεπιλεγμένα αυτά άτομα (π.χ. ύποπτοι) που υπάρχουν στη βάση δεδομένων. Εκεί λοιπόν που το πρόγραμμα αυτό εμφανίζει τις μεγάλες του ικανότητες, είναι στις περιπτώσεις παρακολούθησης, ταυτοποίησης και επιτήρησης ανάμεσα σε μεγάλο αριθμό ατόμων. Αυτό το κάνει πολύτιμο σε συστήματα ασφαλείας μεγάλων χώρων. Έτσι αποτελεί απαραίτητο εργαλείο, στον εντοπισμό υπόπτων ή ανεπιθύμητων προσώπων σε αεροδρόμια, στρατιωτικές βάσεις, κυβερνητικά κτήρια ή άλλους αντίστοιχους χώρους, όπου υπάρχει ανάγκη να γίνεται εντοπισμός υπόπτων, είτε σε μεγάλη απόσταση, είτε ανάμεσα σε μεγάλο πλήθος.

Εκτός αυτών, η τεχνολογία αναγνώρισης προσώπου βρίσκει μεγάλη χρήση στην περίπτωση διαχείρισης καταστάσεων που αφορούν την συγκέντρωση μεγάλου αριθμού ατόμων, όπως θερμόαιμοι οπαδοί ομάδων ή διαδηλωτές. Έχει ήδη χρησιμοποιηθεί σε γήπεδα της Αμερικής, αλλά και στην καταπολέμηση του χουλιγκανισμού στα ποδοσφαιρικά γήπεδα της Αγγλίας. Η εταιρία ήδη παρέχει και νέες λύσεις που συνδυάζουν την τεχνολογία αναγνώρισης προσώπου με άλλες βιομετρικές τεχνολογίες (ίριδα, φωνή, κ.α.) αλλά και με ήδη υπάρχοντα συστήματα ταυτοποίησης που βασίζονται σε κάρτες.

Η τεχνολογία αναγνώρισης προσώπου θα μπορούσε να οδηγήσει στο μέλλον σε ένα κόσμο που δεν θα υπάρχει η ανάγκη για χρήση καρτών, κλειδιών, PIN και υπογραφών, αφού το πρόσωπό μας θα είναι ένα ιδιωτικό, ασφαλές και βολικό password για όλες τις πιθανές χρήσεις.

4.3 Αναγνώριση 2-D Πολυγώνων

Παρακάτω χρησιμοποιείται ένα βασισμένο σε γωνίες μοντέλο διαστημικού-τομέα για να αντιπροσωπεύσει τα δισδιάστατα πρότυπα στα οποία τα όρια του αντικειμένου περιγράφονται από ένα αρχικό σύνολο. Κάθε ένα ζευγάρι πρωτόγονων αντιπροσωπεύεται από δύο γεωμετρικά χαρακτηριστικά γνωρίσματα: το μήκος και τη γωνία του. Το πολυστρωματικό feed-forward perceptron με νευρωνικά δίκτυα ενός κρυμμένου στρώματος, χρησιμοποιούνται για να εξετάσουν δύο παράγοντες, κάθε ένας με δύο διαφορετικά επίπεδα. Ο πρώτος παράγοντας είναι η μέθοδος I/O χαρτογράφησης. Δύο τύποι, το l του C (selector-επιλογέας) και ο κωδικοποιημένος ταξινομητής. Ο δεύτερος παράγοντας είναι η ύπαρξη της bias μονάδας εισόδου. Επομένως, συνολικά εξετάζονται τέσσερα συστήματα. Η δομή του δικτύου είναι ανεξάρτητη από τον αριθμό των πρωτόγονων προτύπων. Οκτώ πολύγωνα με διαφορετικά σχήματα χρησιμοποιούνται για να τρέξουν δύο σύνολα πειραμάτων: έξι πειράματα για εισόδους θορύβου και δύο πειράματα για απώλεια δεδομένων. Το αποτέλεσμα δείχνει ότι το δίκτυο που χρησιμοποιεί τον κωδικοποιημένο ταξινομητή I/O χαρτογράφηση χωρίς μονάδα bias εισόδου είναι το καλύτερο δίκτυο για αυτήν την εφαρμογή.

Πολλές τεχνικές έχουν προταθεί για να εξετάσουν αυτό το πρόβλημα. το οποίο μπορεί να ταξινομηθεί βασισμένο στα ακόλουθα κριτήρια:

- region-based or edge-based μέθοδοι,
- space domain or scale transform domain μέθοδοι και
- syntactic (structural or mathematical (statistical) προσεγγίσεις

Μια region-based μέθοδος είναι για να χωρίσει την εσωτερική περιοχή του αντικειμένου σε διάφορα κομμάτια (Shapiro, 1980), όπως φαίνεται στο Σχήμα 4.27(α), όπου ο έντονος χαρακτήρας "E" χωρίζεται σε τέσσερα ορθογώνια. Ο Shapiro (1980) χρησιμοποίησε μια τοπολογική προσέγγιση για να αντιπροσωπεύσει τα σχήματα για την επίλυση των προβλημάτων αναγνώρισης χαρακτήρα. Από την άλλη, η edge-based μέθοδος αποσυνθέτει το οριακό περίγραμμα του αντικειμένου σε σημαντικούς πρωτόγονους, όπως φαίνεται στο Σχήμα 4.27(β), ο χαρακτήρας "E" μπορεί να αντιπροσωπευθεί από δώδεκα άκρες που είναι συσχετισμένες η μία με την άλλη στο χώρο.



(a) region-based

(b) edge-based

Σχήμα 4.27: Region-based και edge-based αντιπροσωπεύσεις.

Και οι δύο αντιπροσωπεύσεις είναι τεχνικές διαστημικού τομέα, οι οποίες εκφράζουν τη δομική και τη συγγενική ιδιοκτησία. Εναλλακτικά, οι μέθοδοι μετατροπής κλίμακας παράγουν τους περιγραφείς σχημάτων οι οποίοι αντιπροσωπεύουν ένα μαθηματικό άθροισμα του σχήματος όπως ο περιγραφέας Fourier (Etesami και Uicker, 1985) και τα πιθανολογικά μοντέλα.

Το τελευταίο κριτήριο είναι για να ταξινομηθούν οι τεχνικές κωδικοποίησης σχημάτων στις δομικές μεθόδους ή τις στατιστικές μεθόδους. Για τις δομικές μεθόδους, τα πρότυπα εκφράζονται ως συνθέσεις των πρωτόγονων, οι οποίες αναγνωρίζονται στη συνέχεια με το ταίριασμα της δομικής αντιπροσώπευσής τους με ένα πρότυπο αναφοράς. Για τις στατιστικές μεθόδους, ένα σύνολο χαρακτηριστικών μετρήσεων, αποκαλούμενο συνήθως χαρακτηριστικά γνωρίσματα, εξάγεται από τα πρότυπα, τα οποία διαμορφώνουν το σχηματικό (πρότυπο) διάστημα. Το διάστημα προτύπων χωρίζεται έπειτα σε διάφορες κατηγορίες αναφοράς έτσι ώστε το σφάλμα ταξινόμησης να ελαχιστοποιηθεί.

Οι Ventura και Chen (1993) πρότειναν ένα edge-based space-domain μοντέλο για να αντιπροσωπεύσουν τα δισδιάστατα σχήματα, στα οποία τα όρια του αντικειμένου περιγράφονται από ένα σύνολο πρωτόγονων, κάθε ένα από τα οποία αντιπροσωπεύεται από τρία γεωμετρικά χαρακτηριστικά γνωρίσματα:

- το μήκος (length)
- την κυρτότητα (curvature) και
- τον σχετικό προσανατολισμό του (relative orientation).

Αυτό το μοντέλο χρησιμοποιεί ένα πολυστρωματικό feed-forward νευρωνικό δίκτυο. Στο μοντέλο τους, δεν χρησιμοποιείται το l του C επιλογή I/O χαρτογράφησης και κανένα αντικείμενο bias εισόδου και διαφορετικά δίκτυα χρησιμοποιούνται για εκείνα τα μέρη

που έχουν διαφορετικούς αριθμούς πρωτόγονων.

Με τη χρησιμοποίηση των σημείων τέλους των οριακών πρωτόγονων αντί των ακατέργαστων pixel δεδομένων σαν διανύσματα εισόδου, το μοντέλο αυτό μειώνει μαζικά τον αριθμό των κόμβων εισόδου. Κατά συνέπεια συμπιέζει κατά ένα μεγάλο μέρος τα δεδομένα, σώζει το χώρο υπολογιστών, και καθιστά την επόμενη στοιχειώδη εργασία αποδοτική και αξιόπιστη. Επιπλέον, η κανονικοποίηση των διανυσμάτων εισόδου κάνει το μοντέλο αυτό να μπορεί να εφαρμοστεί σε διαφορετικής διάστασης αντικείμενα που έχουν το ίδιο σχήμα με τα πρότυπα αναφοράς.

Στο προτεινόμενο μοντέλο του Ventura και Chen (1993), χρησιμοποιούνται διαφορετικά δίκτυα για εκείνα τα μέρη που έχουν διαφορετικό αριθμό πρωτόγονων. Αυτό το κάνει εφαρμόσιμο μόνο στα μέρη που έχουν τον ίδιο αριθμό πρωτόγονων.

Η μεθοδολογία

Αντιπροσώπηση σχήματος

Δύο πτυχές του προβλήματος αναγνώρισης αντικειμένου είναι:

1. διαμόρφωση σχήματος, η οποία εξετάζει τις ερωτήσεις σχετικά με το πώς τα αντικείμενα αντιπροσωπεύονται δηλαδή ποια είδη χαρακτηριστικών γνωρισμάτων εικόνας χρησιμοποιούνται για να αντιπροσωπεύσουν τα αντικείμενα και
2. ταιριάζοντας με το ποιο είναι ενδιαφερόμενο για την ανάπτυξη μιας μεθόδου, για να βρει μια ανταπόκριση μεταξύ στην sensed εικόνα και στην εικόνα αναφοράς, και να αξιολογήσει το καλό ταίριασμα μεταξύ αυτών των δύο εικόνων.

Παρακάτω η προτεινόμενη αντιπροσώπηση σχεδίου S , είναι 2-tuple που μπορεί να περιγραφεί ως δύο στοιχεία που καθορίζονται:

$$S=(P,R)$$

όπου.

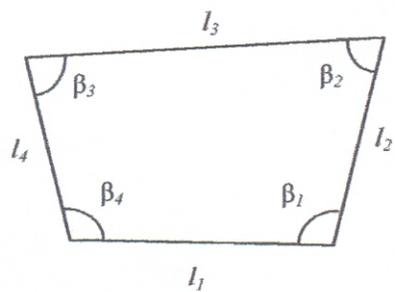
P: is the set of edge primitives that defines a particular polygon, which are straightline segments.

$$P = \{P_i, i = 1, 2, \dots, n\} \text{ and } l_i \text{ is the length of } P_i$$

R: is the set of geometric relations among the elements in **P**, e.g.. the turning angles between two consecutive primitives.

$$R = \{\beta_i, i = 1, 2, \dots, n\}, \text{ where } \beta_i \text{ is the change of angles between primitives } P_i \text{ and } P_{i-1}.$$

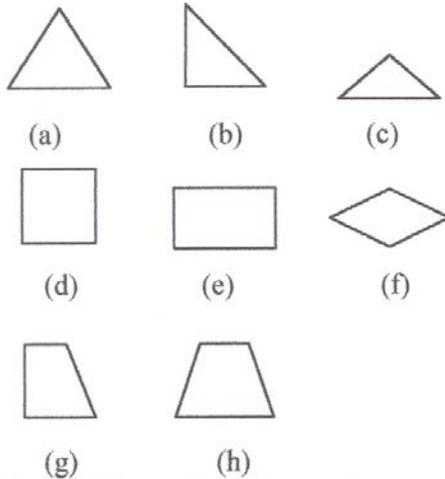
Όπως φαίνεται στο Σχήμα 4.28, οι πρωτόγονοι ενός αντικειμένου τακτοποιούνται στην αντίθετη προς τη φορά των δεικτών του ρολογιού ακολουθία. Αυτό το μοντέλο μπορεί να εφαρμοστεί στην αναγνώριση διαφορετικών τύπων πολυγώνων.



Σχήμα 4.28: Αντιπροσώπευση πολυγώνων.

Πολύγωνα Αναφοράς

Ένα σύνολο πολυγώνων αναφοράς δημιουργείται για σκοπούς εκμάθησης όπως φαίνεται στο Σχήμα 4.29.



Σχήμα 4.29: Πολύγωνα Αναφοράς

Δεδομένου ότι η ονομαστική αξία κάθε κόμβου εισόδου μπορεί να ποικίλει κατά ένα μεγάλο μέρος (π.χ., I_1 μπορεί να είναι πολύ μικρό, δηλ 0,1, και β_1 μπορεί να είναι πολύ μεγάλο, δηλ 900), καθιστά τον κόμβο εισόδου για το χαρακτηριστικό γνώρισμα β_1 , σημαντικότερο από τον κόμβο για το χαρακτηριστικό γνώρισμα I_1 . Ως εκ τούτου η κανονικοποίηση των διανυσμάτων εισόδου απαιτείται να υπερνικήσει αυτό το μειονέκτημα. Επιπλέον, η κανονικοποίηση των διανυσμάτων εισόδου μπορεί να κάνει αυτήν την πρότυπη διάσταση σταθερά. Το ίδιο νευρωνικό δίκτυο μπορεί να εφαρμοστεί σε διαφορετικής διάστασης αντικείμενα με το ίδιο σχήμα. Τα διανύσματα εισόδου είναι κανονικοποιημένα ως εξής:

$$I_i^{new} = I_i / \sum_{j=1}^n I_j, \quad i=1,2,\dots,n$$

$$\beta_i^{new} = \beta_i / \sum_{j=1}^n \beta_j, \quad i = 1, 2, \dots, n$$

Δομή δικτύου

Χρησιμοποιείται ένα πολυστρωματικό feed-forward perceptron με ένα κρυμμένο στρώμα. Η δομή αυτού του νευρωνικού δικτύου συνοψίζεται παρακάτω.

- το στρώμα εισόδου είναι το σύνολο των πρωτόγονων πολυγώνων και των γεωμετρικών σχέσεών τους:

$$I = (P, R) = \{(I_i, \beta_i), \quad i = 1, 2, \dots, n\}$$

Ο αριθμός κόμβων εισόδου είναι ίσος με $2n+1$ που περιλαμβάνει τον bias κόμβο εισόδου, ή $2n$ που δεν περιλαμβάνει την bias μονάδα, όπου n είναι ο μέγιστος αριθμός

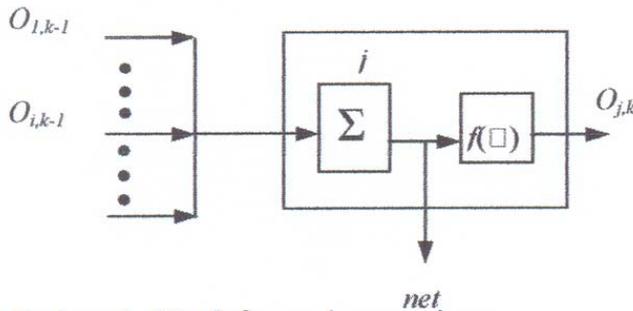
πρωτόγονων των πολυγώνων αναφοράς. Για εκείνα τα πολύγωνα που έχουν λιγότερους πρωτόγονους, οι υπόλοιπες τιμές εισόδου τίθενται 0. Εάν χρησιμοποιείται η bias μονάδα, η αξία της καθορίζεται σε 1.

- το κρυμμένο στρώμα χρησιμοποιείται για την εξαγωγή χαρακτηριστικών γνωρισμάτων και ο αριθμός κρυμμένων κόμβων είναι ίσος με 21 που περιλαμβάνει την bias μονάδα, ή 20 που δεν την περιλαμβάνει.
- το στρώμα εξόδου είναι το σύνολο των πολυγώνων αναφοράς στη μελέτη. Εάν χρησιμοποιείται το 1 του C επιλογή (selector) I/O τύπου χαρτογράφησης, ο αριθμός κόμβων εξόδου είναι ίσος με τον αριθμό πολυγώνων αναφοράς, δηλ., 8, σε αυτό το παράδειγμα. Εάν χρησιμοποιείται ο κωδικοποιημένος ταξινομητής I/O τύπου χαρτογράφησης, ο αριθμός κόμβων εξόδου είναι ίσος με το μικρότερο ακέραιο αριθμό που είναι μεγαλύτερος από το $\log_2 N$, όπου το N είναι ο αριθμός κλάσεων (πρότυπα αναφοράς), δηλ., 3, σε αυτό το παράδειγμα.
- η βασική μονάδα (ο νευρώνας j) μέσα στο στρώμα K εκτελεί τον υπολογισμό του σταθμισμένου αθροίσματος της εισόδου του (Σχήμα 4.30), που περνά μέσω μιας συνάρτησης ενεργοποίησης. Χρησιμοποιείται μια συνάρτηση sigmoid ως συνάρτηση ενεργοποίησης:

$$O_{j,k} = f(net) = 1/(1+e^{-net})$$

$$net = \sum_i W_{i,j} O_{i,k-1}$$

Όπου, η $O_{j,k}$ είναι η έξοδος του νευρώνα j στο στρώμα K. Για το στρώμα εισόδου, $O_{j,l}$ είναι ίσο με την τιμή της εισόδου.



Σχήμα 4.30: Ο βασικός νευρώνας.

Αλγόριθμος εκμάθησης

Ο back-propagation αλγόριθμος:

$$\Delta W_{i,j}(t+1) = \eta \delta_{j,k} O_{i,k-1} + \alpha \Delta W_{i,j}(t)$$

σε αυτό το παράδειγμα, $\eta = \alpha = 0.5$.

$$W_{i,j}(t+1) = W_{i,j}(t) + \Delta W(t+1)$$

για ένα νευρώριο εξόδου,

$$\delta_{j,k} = O_{j,k}(1 - O_{j,k})(T_{j,k} - O_{j,k})$$

και για ένα κρυφό νευρώριο,

$$\delta_{j,k} = O_{j,k}(1 - O_{j,k}) \sum_r \delta_{r,k+1} W_{j,r}(t)$$

Όλα τα αρχικά βάρη τίθενται τυχαία σε μια μικρή ποσότητα (μια ομοιόμορφη διανομή ανάμεσα ± 0.5) και το σφάλμα εξόδου τίθεται έτσι ώστε να είναι λιγότερο από 0,1.

Αριθμητικά αποτελέσματα

Ο πρώτος παράγοντας είναι η μέθοδος I/O χαρτογράφησης. Δύο τύποι συζητούνται, 1 του επιλογέα C και ο κωδικοποιημένος ταξινομητής. Ο δεύτερος παράγοντας είναι η ύπαρξη του bias εισόδου αντικειμένου. Επομένως, συνολικά τέσσερα συστήματα εξετάζονται (Πίνακας 4.12).

	Sys. 1	Sys.2	Sys.3	Sys.4
# of input nodes	9	8	9	8
# of hidden nodes	21	20	21	20
# of output nodes	8	8	3	3
# of connections	348	320	243	220

Πίνακας 4. 12: The tested systems.

Τα αρχικά και κανονικοποιημένα διανύσματα εισόδου των πολυγώνων αναφοράς όπως φαίνεται στο Σχήμα 4.29 περιλαμβάνονται στους Πίνακες 4.13 και 4.14.

Pattern	I_i	O_i
(a)	(1,1,1,0)	(60,60,60,0)
(b)	(1,1,414,1,0)	(45,45,90,0)
(c)	(1.732,1,1,0)	(30,120,30,0)
(d)	(1,1,1,1)	(90,90,90,90)
(e)	(1,.5,1,.5)	(90,90,90,90)
(f)	(1,1,1,1)	(120,60,120,60)
(g)	(1.5,1,1,.886)	(60,120,90,90)
(h)	(2,1,1,1)	(60,120,120,60)

Πίνακας 4. 13: The original input vector.

Pattern	I_i	O_i
(a)	(.333,.333,.333,0)	(.333,.333,.333,0)
(b)	(.293,.414,.293,0)	(.25,.25,.5,0)
(c)	(.464,.268,.268,0)	(.167,.667,.167,0)
(d)	(.25,.25,.25,.25)	(.25,.25,.25,.25)
(e)	(.333,.167,.333,.167)	(.25,.25,.25,.25)
(f)	(.25,.25,.25,.25)	(.333,.167,.333,.167)
(g)	(.344,.229,.229,.198)	(.167,.333,.25,.25)
(h)	(.4,.2,.2,.2)	(.167,.333,.333,.167)

Πίνακας 4. 14: The normalized input vector.

Χρησιμοποιώντας τα δίκτυα που εμφανίζονται στον Πίνακα 4.12 και τα κανονικοποιημένα διανύσματα εισόδου που εμφανίζονται στον πίνακα 4.14, αυτά τα τέσσερα συστήματα εκπαιδεύονται με $\eta = 0,5$ (ποσοστό εκμάθησης), $\alpha = 0,5$ (ποσοστό ορμής), και το σφάλμα εξόδου = 0,1. Οι αριθμοί επαναλήψεων κατάρτισης για να γίνει σύγκλιση στο σφάλμα εξόδου συγκρίνονται στον Πίνακα 4.15. Από τον Πίνακα 4.15, μπορούμε να δούμε ότι ο αριθμός επαναλήψεων κατάρτισης είναι βασικά ανάλογος προς τον αριθμό αλληλοσυνδέσεων των νευρώνων του συστήματος.

	Sys.1	Sys.2	Sys.3	Sys.4
# of training iterations	1522	1506	1251	1207

Πίνακας 4. 15: The number of training iterations.

Χρησιμοποιούνται δύο κριτήρια για να εξετάσουν αυτά τα τέσσερα συστήματα. Το πρώτο κριτήριο είναι να εξεταστεί πώς ο θόρυβος εισόδου έχει επιπτώσεις στο ποσοστό αναγνώρισης και το δεύτερο κριτήριο είναι να εξεταστεί πώς τα ελλιπή δεδομένα έχουν επιπτώσεις στο αποτέλεσμα του κάθε συστήματος. Ο Πίνακας 4.16 εμφανίζει τα έξι πειράματα του θορύβου εισόδου και ο Πίνακας 4.17 εμφανίζει τα δύο πειράματα των ελλιπών δεδομένων.

Experiment	Description
1	Add noise to one length data
2	Add noise to one angle data
3	Add noise to one pair of length and angle
4	Add noise to all length data
5	Add noise to all angle data
6	Add noise to all length and angle data

Πίνακας 4. 16: Experiments of input noise.

Experiment	Description
1	One missing length data
2	One missing angle data

Πίνακας 4. 17: Experiments of missing data.

Εάν ο θόρυβος 10% προστίθεται τυχαία στο l_i , η αξία του l_i ενημερώνεται από:

$$l_i \leftarrow l_i(1 + U(-.1, .1)), i = 1, 2, \dots, n$$

όπου $U(-.1, .1)$ είναι τυχαία διανεμημένες τυχαίες μεταβλητές οριακά από -0,1 και 0,1. Δηλαδή το l_i μπορεί να παρεκκλίνει μέχρι $\pm 10\%$ από την αρχική αξία του. Ο ίδιος τύπος θορύβων προστίθεται στο β_i και τα δύο μεγέθη (l_i , β_i) ταυτόχρονα. Ο Πίνακας 4.22 εμφανίζει το ποσοστό επιτυχίας των ελλιπών δεδομένων. Όλα τα στοιχεία είναι βασισμένα στα στοιχεία που υπολογίζονται κατά μέσο όρο άνω των 1024 επαναλήψεων και σε όλα τα οκτώ πολύγωνα αναφοράς που εμφανίζονται στον Πίνακα 4.15.

Noise	.1	.2	.3	.4	.5
Exp.1	.9990	.8193	.8047	.7871	.7686
Exp.2	.8125	.8144	.7900	.7695	.7354
Exp.3	.8125	.8066	.7998	.7803	.7676
Exp.4	.8023	.8353	.6909	.5969	.5300
Exp.5	.3193	.1894	.0644	.0400	.0312
Exp.6	.3193	.1934	.0566	.0332	.0244
Average	.6775	.6097	.5344	.5012	.4762

Πίνακας 4. 18: Success rate of adding noise of system 1.

Noise	.1	.2	.3	.4	.5
Exp.1	.9990	1	.9971	.9795	.9482
Exp.2	.9990	1	.9873	.9551	.8926
Exp.3	.9990	1	.9922	.9619	.9082
Exp.4	.8934	.9050	.8953	.7403	.6076
Exp.5	.3652	.1475	.0684	.0400	.0234
Exp.6	.4131	.1611	.0644	.0352	.0234
Average	.7781	.7023	.6675	.6187	.5672

Πίνακας 4. 19: Success rate of adding noise of system 2.

Noise	.1	.2	.3	.4	.5
Exp.1	.1	.7549	.7363	.7188	.6953
Exp.2	.7490	.7646	.7686	.7666	.7519
Exp.3	.7510	.7568	.7588	.7320	.7402
Exp.4	.7907	.7665	.6337	.5591	.5058
Exp.5	.4404	.4482	.2295	.1846	.1592
Exp.6	.4990	.4609	.2021	.1709	.1611
Average	.7050	.6587	.5548	.5220	.5023

Πίνακας 4. 20: Success rate of adding noise of system 3.

Noise	.1	.2	.3	.4	.5
Exp.1	1	.9834	.9473	.9141	.8760
Exp.2	.9990	1	.9756	.9394	.8877
Exp.3	1	.9892	.9609	.9189	.8672
Exp.4	1	.8149	.8508	.6095	.5610
Exp.5	.4717	.4248	.2021	.1660	.1562
Exp.6	.4990	.4609	.2021	.1709	.1611
Average	.8356	.7763	.6900	.6205	.5836

Πίνακας 4. 21: Success rate of adding noise of system 4.

Missing in	Sys.1	Sys.2	Sys.3	Sys.4	Average
Length	.0375	.375	.4375	.5	.4219
Angle	.75	1	.75	1	.875
Average	.5625	.6875	.5938	.75	

Πίνακας 4.22: Success rate of missing data.

Συμπεράσματα

Μερικά ενδιαφέροντα συμπεράσματα παρατηρούνται από αυτά τα πειράματα:

- (1) Ο αριθμός των επαναλήψεων κατάρτισης για την σύγκλιση είναι βασικά ανάλογος προς τον αριθμό των αλληλοσυνδέσεων του συστήματος (βλ. τον Πίνακα 4.15).
- (2) Το γενικό μέσο ποσοστό επιτυχίας του προστιθέμενου θορύβου στα χαρακτηριστικά εισόδου μειώνεται καθώς το επίπεδο θορύβου αυξάνεται (βλ. τους Πίνακες 4.18 και 4.21).
- (3) Τα ποσοστά επιτυχίας διαφέρουν πολύ λίγο (βλ. τους Πίνακες 4.18 και 4.21).
- (4) Τα πειράματα θορύβου 1, 2, και 3 έχουν σχεδόν τα ίδια ποσοστά επιτυχίας τα οποία έχουν μικρές παραλλαγές πέρα από όλα τα επίπεδα θορύβου (βλ. τους Πίνακες 4.18 και 4.21).
- (5) Η απόδοση των συστημάτων 2 και 4 (χωρίς bias μονάδα) είναι καλύτερη από τα συστήματα 1 και 3 (με την bias μονάδα) (βλ. τους Πίνακες 4.18 και 4.21). Έτσι, η χρησιμοποίηση των bias μονάδων στα νευρωνικά δίκτυα δεν αποδίδει απαραίτητα καλύτερα. Πρέπει να εξαρτάται από τις εφαρμογές.
- (6) Η απόδοση του συστήματος 1.(1 του επιλογέα C με την bias μονάδα) έχει μικρή μόνο διαφορά με την απόδοση του συστήματος 3 (κωδικοποιημένος ταξινομητής με bias μονάδα). Προκύπτει ότι η επίδραση της I/O μεθόδου χαρτογράφησης δεν είναι τόσο σημαντική όσο η ύπαρξη της bias μονάδας.
- (7) Τα συστήματα 2 και 4 (κωδικοποιημένος ταξινομητής) έχουν υψηλότερα ποσοστά επιτυχίας από τα συστήματα 1 και 3 (1 των επιλογέων C) για τα χαμένα δεδομένα (βλ. τον Πίνακα 4.22). Προκύπτει επίσης ότι η μη χρησιμοποίηση της bias μονάδας έχει καλύτερη απόδοση τα missing data.
- (8) Η επίδραση από την απώλεια ενός δεδομένου γωνίας δεν είναι τόσο σημαντική όσο η επίδραση από την απώλεια ενός δεδομένου μήκους (βλ. Πίνακας 4.22).
- (9) Συνοψίζοντας το σύστημα 4 είναι το καλύτερο δίκτυο για αυτήν την εφαρμογή.

4.4 Πρόβλεψη Χρηματιστηρίου (StockMarket Prediction)

Η επικρατούσα αντίληψη μιας κοινωνίας είναι ότι ο πλούτος φέρνει την άνεση και την πολυτέλεια. Έτσι δεν αποτελεί έκπληξη το γεγονός ότι έχουν γίνει τόσες πολλές εργασίες πάνω στις μεθόδους πρόβλεψης των χρηματιστηριακών αγορών. Διάφορες τεχνικές, θεμελιώδεις και στατιστικοί δείκτες έχουν προταθεί και έχουν χρησιμοποιηθεί με ποικίλα αποτελέσματα. Εντούτοις, καμία τεχνική ή συνδυασμός τεχνικών είναι αρκετά επιτυχής ώστε "να χτυπηθεί η αγορά". Με την ανάπτυξη των νευρωνικών δικτύων, οι ερευνητές και οι επενδυτές ελπίζουν ότι τα μυστήρια της αγοράς μπορούν να διευκρινιστούν.

Κίνητρο

Υπάρχουν διάφορα κίνητρα στην προσπάθεια να προβλεφθούν οι τιμές αγοράς αποθεμάτων. Το πιο βασικό από αυτά είναι το οικονομικό κέρδος.

Υπάρχει ένα δεύτερο κίνητρο στην έρευνα και τις οικονομικές αγορές. Έχει προταθεί στην Efficient Market Hypothesis (EMH) ότι οι αγορές που είναι αποδοτικές σ' αυτές τις ευκαιρίες για το κέρδος ανακαλύπτονται τόσο γρήγορα που παύουν να είναι ευκαιρίες. Η EMH αποτελεσματικά δηλώνει ότι κανένα σύστημα δεν μπορεί συνεχώς να χτυπάει την αγορά διότι εάν αυτό το σύστημα γίνει δημόσιο, καθένας θα το χρησιμοποιήσει, κατά συνέπεια τη μείωση του πιθανού κέρδους του. Έχει υπάρξει μια συνεχόμενη συζήτηση για την ισχύ του EMH, και μερικοί ερευνητές προσπάθησαν να χρησιμοποιήσουν τα νευρωνικά δίκτυα για να επικυρώσουν τις απόψεις τους. Δεν έχει υπάρξει καμία συναίνεση για την ισχύ του EMH, αλλά πολλοί παρατηρητές αγοράς τείνουν να θεωρήσουν στις πιο αδύνατες μορφές του, και είναι έτσι συχνά απρόθυμοι να μοιραστούν προνομιακά συστήματα επένδυσης.

Τα νευρωνικά δίκτυα χρησιμοποιούνται για να προβλέψουν τις τιμές αγοράς αποθεμάτων διότι είναι σε θέση να μάθουν τις μη γραμμικές χαρτογραφήσεις μεταξύ των εισόδων και των εξόδων. Αντίθετα με την EMH, πολλοί ερευνητές υποστηρίζουν ότι αυτή η χρηματιστηριακή αγορά και άλλα σύνθετα συστήματα, εκθέτουν το χάος. Το χάος είναι μια μη γραμμική ντετερμινιστική (αιτιοκρατική) διαδικασία που εμφανίζεται μόνο τυχαία επειδή δεν μπορεί να προβλεφτεί εύκολα. Με τη δυνατότητα των νευρωνικών δικτύων να εκπαιδεύονται σε μη γραμμικά, χαοτικά συστήματα, μπορεί να είναι πιθανό να ξεπεραστεί η παραδοσιακή ανάλυση (traditional analysis) και άλλες βασισμένες σε υπολογιστή (computer based) μέθοδοι.

Σε αντίθεση με την stock market πρόβλεψη, τα νευρωνικά δίκτυα έχουν εκπαιδευθεί για να εκτελέσουν ποικίλες οικονομικές στοιχειώδεις εργασίες. Υπάρχουν πειραματικά και εμπορικά συστήματα που χρησιμοποιούνται για την ξένη ανταλλαγή εμπορίου, οικονομικός προγραμματισμός - σχεδιασμός, σταθερότητα επιχείρησης, και πρόβλεψη πτώχευσης. Οι τράπεζες χρησιμοποιούν νευρωνικά δίκτυα για να ανιχνεύσουν τις εφαρμογές πίστωσης και δανείων για να υπολογίσουν τις πιθανότητες πτώχευσης, ενώ οι χρηματοοικονομικοί διευθυντές μπορούν να χρησιμοποιήσουν τα νευρωνικά δίκτυα για να προγραμματίσουν και να κατασκευάσουν τα κερδοφόρα χαρτοφυλάκια στον πραγματικό χρόνο.

Τελικά, αν και τα νευρωνικά δίκτυα χρησιμοποιούνται αρχικά ως εργαλείο εφαρμογής στο οικονομικό περιβάλλον, έχουν γίνει αρκετές ερευνητικές βελτιώσεις κατά τη διάρκεια της εφαρμογής τους. Αξιόλογες βελτιώσεις στη σχεδίαση και την κατάρτιση δικτύων και την εφαρμογή θεωρητικών τεχνικών επιδεικνύονται από την εξέταση διαφόρων παραδειγματικών συστημάτων.

Μέθοδοι Ανάλυσης

Πριν από την εποχή των υπολογιστών, οι άνθρωποι έκαναν εμπόριο αγορών και προϊόντων βασιζόμενοι στη διαίσθηση. Όσο το επίπεδο επένδυσης και εμπορικών συναλλαγών αυξανόταν, άνθρωποι αναζητούσαν εργαλεία και μεθόδους που θα αύξαναν τα κέρδη τους ελαχιστοποιώντας το ρίσκο. Στατιστικές, τεχνικές αναλύσεις, θεμελιώδεις

αναλύσεις, όλες χρησιμοποιούνται για να προσπαθήσουν να προβλέψουν και να ωφεληθούν από την κατεύθυνση της αγοράς. Καμία από αυτές τις τεχνικές δεν έχει αποδειχτεί να είναι το επιθυμητό αξιόπιστο σωστό εργαλείο πρόβλεψης, και πολλοί αναλυτές διαφωνούν για την έλλειψη χρησιμότητας πολλών προσεγγίσεων. Εντούτοις, αυτές οι μέθοδοι παρουσιάζονται καθώς χρησιμοποιούνται συνήθως στην πράξη και αντιπροσωπεύουν πρότυπα βάσεων για τα οποία τα νευρωνικά δίκτυα πρέπει να ξεπεράσουν. Επίσης, πολλές από αυτές τις τεχνικές χρησιμοποιούνται για να προεπεξεργαστούν τις ακατέργαστες εισόδους δεδομένων, και τα αποτελέσματά τους τροφοδοτούνται στα νευρωνικά δίκτυα σαν είσοδος.

Τεχνικές Μέθοδοι

Η ιδέα πίσω από την τεχνική ανάλυση είναι ότι οι τιμές μεριδίου κινούν τις τάσεις που υπαγορεύονται από τις συνεχώς μεταβαλλόμενες τοποθετήσεις των επενδυτών σε απάντηση στις διαφορετικές δυνάμεις. Χρησιμοποιώντας την τιμή και τις ανοικτές στατιστικές ενδιαφέροντος, ο τεχνικός αναλυτής χρησιμοποιεί τα διαγράμματα για να προβλέψει τις μελλοντικές μετακινήσεις αποθεμάτων. Η τεχνική ανάλυση στηρίζεται στην υπόθεση ότι η ιστορία επαναλαμβάνεται και ότι η μελλοντική κατεύθυνση αγοράς μπορεί να καθοριστεί με την εξέταση των προηγούμενων τιμών. Κατά συνέπεια, η τεχνική ανάλυση είναι αμφισβητούμενη και έρχεται σε αντίθεση με την Efficient Market Hypothesis.

Παρά τη διαδεδομένη χρήση της, η τεχνική ανάλυση επικρίνεται επειδή είναι ιδιαίτερα υποκειμενική. Διαφορετικά άτομα μπορούν να ερμηνεύσουν τα διαγράμματα με διαφορετικούς τρόπους.

Ένα παράδειγμα ενός τεχνικού δείκτη είναι ο κινούμενος μέσος όρος. Διάφοροι κανόνες εμπορικών συναλλαγών που έχουν αναπτυχθεί αναφέρονται στον κινούμενο μέσο όρο. Παραδείγματος χάριν, "όταν κινείται μια τιμή κλεισίματος πάνω από έναν κινούμενο μέσο όρο παράγεται ένα σήμα αγοραπωλησίας". Δυστυχώς, αυτοί οι δείκτες δίνουν συχνά ψεύτικα σήματα και καθυστερούν την αγορά. Δηλαδή δεδομένου ότι ένας κινούμενος μέσος όρος είναι μια εκτίμηση του παρελθόντος, ένας τεχνικός έμπορος συχνά χάνει μεγάλη δυνατότητα στη μετακίνηση αποθεμάτων προτού να παραχθεί το κατάλληλο σήμα εμπορικών συναλλαγών. Κατά συνέπεια, αν και η τεχνική ανάλυση μπορεί να παραγάγει τις διορατικότητες στην αγορά, η ιδιαίτερα υποκειμενική φύση και η έμφυτη χρονική καθυστέρησή της δεν την καθιστούν ιδανική για τις γρήγορες δυναμικές αγορές εμπορικών συναλλαγών της σημερινής.

Θεμελιώδης Ανάλυση

Η θεμελιώδης ανάλυση περιλαμβάνει τη σε βάθος ανάλυση της απόδοσης και της αποδοτικότητας μιας επιχείρησης για να καθορίσει την τιμή μεριδίου της. Μελετώντας τους γενικούς οικονομικούς όρους τον ανταγωνισμό της επιχείρησης και άλλους παράγοντες, είναι πιθανό να καθοριστούν οι αναμενόμενες επιστροφές και η εγγενής αξία των μεριδίων. Αυτή η μορφή ανάλυσης υποθέτει ότι η τωρινή τιμή ενός μεριδίου (και μελλοντική) εξαρτάται από την εγγενή αξία και την προσδοκώμενη επιστροφή της στην επένδυση. Δεδομένου ότι νέες πληροφορίες εκδίδονται σχετικά με τη θέση της

επιχείρησης, η αναμενόμενη επιστροφή των μετοχών της επιχείρησης θα αλλάξουν, κάτι το οποίο έχει επιπτώσεις στην τιμή αποθεμάτων.

Τα πλεονεκτήματα της θεμελιώδους ανάλυσης είναι η συστηματική προσπέλαση και η δυνατότητα να προβλέψει τις αλλαγές προτού να εμφανιστούν στα διαγράμματα. Οι επιχειρήσεις συγκρίνονται μεταξύ τους και οι προοπτικές ανάπτυξής τους σχετίζονται με το υπάρχον οικονομικό περιβάλλον. Αυτό επιτρέπει στον επενδυτή να εξοικειωθεί με την επιχείρηση. Δυστυχώς, γίνεται δυσκολότερο να τυποποιηθεί όλη αυτή η γνώση για σκοπούς αυτοματισμού (με ένα νευρωνικό δίκτυο παραδείγματος χάριν), και η ερμηνεία αυτής της γνώσης μπορεί να είναι υποκειμενική. Αν και οι σημαντικές πληροφορίες μπορούν να επιτρέψουν τη μετακίνηση αποθεμάτων, η πραγματική μετακίνηση μπορεί να καθυστερήσει εξαιτίας αγνώστων παραγόντων ή έως ότου το υπόλοιπο της αγοράς ερμηνεύει τις πληροφορίες με τον ίδιο τρόπο. Εντούτοις, η θεμελιώδης ανάλυση είναι μια ανώτερη μέθοδος για μακροπρόθεσμη σταθερότητα και ανάπτυξη. Βασικά, η θεμελιώδης ανάλυση υποθέτει ότι οι επενδυτές είναι 90% λογικοί, εξετάζοντας τις επενδύσεις τους λεπτομερώς, ενώ η τεχνική ανάλυση υποθέτει ότι οι επενδυτές είναι 90% ψυχολογικοί, αντιδρώντας στις αλλαγές του περιβάλλοντος αγοράς με προβλέψιμους τρόπους.

Traditional Time Series Forecasting

Υπάρχουν δύο βασικοί τύποι πρόβλεψης Traditional Time Series : μεταβλητός (univariate) και πολλών μεταβλητών (multivariate). Τα μεταβλητά μοντέλα, όπως το Box-Jenkins, περιέχουν μόνο μια μεταβλητή στην εξίσωση επανάληψης. Το Box Jenkins είναι μια περίπλοκη διαδικασία στοιχείων στις κατάλληλες πρότυπες παραμέτρους. Οι εξισώσεις που χρησιμοποιούνται στο μοντέλο περιέχουν τις προηγούμενες τιμές κίνησης των μέσων όρων και των τιμών. Το Box-Jenkins είναι καλό για τη βραχυπρόθεσμη πρόβλεψη αλλά απαιτεί πολλά δεδομένα, και είναι μια περίπλοκη διαδικασία ώστε να καθορίσει τις κατάλληλες πρότυπες εξισώσεις και παραμέτρους.

Τα μοντέλα πολλών μεταβλητών είναι μεταβλητά μοντέλα και επεκτείνονται για "να ανακαλύψουν τους περιστασιακούς παράγοντες που έχουν επιπτώσεις στη συμπεριφορά των δεδομένων". Αυτά τα μοντέλα περιέχουν περισσότερη από μια μεταβλητή στις εξισώσεις τους. Η ανάλυση οπισθοδρόμησης (Regression analysis) είναι ένα μοντέλο πολλών μεταβλητών που έχει συχνά συγκριθεί με τα νευρωνικά δίκτυα. Συνολικά, η time series forecasting παρέχει τη λογική ακρίβεια κατά τη διάρκεια των μικρών περιόδων χρόνου, αλλά η ακρίβεια μικραίνει αισθητά καθώς το μήκος της πρόβλεψης αυξάνεται.

Efficient Market Hypothesis

Η Efficient Market Hypothesis (EMH) δηλώνει ότι σε οποιαδήποτε στιγμή, η τιμή ενός μεριδίου συλλαμβάνει πλήρως όλες τις γνωστές πληροφορίες για το μερίδιο. Δεδομένου ότι όλες οι γνωστές πληροφορίες χρησιμοποιούνται βέλτιστα από τους συμμετέχοντες αγοράς, οι παραλλαγές τιμής είναι τυχαίες, καθώς οι νέες πληροφορίες εμφανίζονται τυχαία. Κατά συνέπεια, οι τιμές μεριδίου εκτελούν έναν "τυχαίο περίπατο", και δεν είναι πιθανό για έναν επενδυτή να κτυπήσει την αγορά.

Παρά τη μάλλον ισχυρή άποψή του, που εμφανίζεται να είναι αναληθής στην πράξη, έχουν υπάρξει αναποτελεσματικά στοιχεία στην απόρριψη του EMH. Διαφορετικές μελέτες έχουν καταλήξει τόσο στο να αποδεχθούν όσο και να απορρίψουν το EMH.

Πολλές από αυτές τις μελέτες χρησιμοποίησαν τα νευρωνικά δίκτυα για να δικαιολογήσουν τις αξιώσεις τους. Στην πράξη, οι συντριβές αγοράς αποθεμάτων, όπως το χρηματιστηριακό *crashe* τον Οκτώβριο του 1987, έρχονται σε αντίθεση με το EMH διότι δεν είναι βασισμένες σε τυχαίες εμφανιζόμενες πληροφορίες, αλλά προκύπτουν σε περιόδους συντριπτικού φόβου των επενδυτών.

Το EMH είναι σημαντικό επειδή έρχεται σε αντίθεση με όλες τις άλλες μορφές ανάλυσης. Εάν είναι αδύνατο να κτυπηθεί η αγορά, τότε η τεχνική, η θεμελιώδης ή *time series* ανάλυση πρέπει να οδηγήσει σε καμία καλύτερη απόδοση παρά από την τυχαία εικασία. Το γεγονός ότι πολλοί συμμετέχοντες αγοράς μπορούν να χτυπήσουν την αγορά είναι μια ένδειξη ότι το EMH μπορεί να μην είναι αληθινό στην πράξη. Το EMH μπορεί να είναι αληθινό στον ιδανικό κόσμο με την ίση διανομή πληροφοριών, αλλά οι σημερινές αγορές περιέχουν διάφορους προνομιούχους φορείς που μπορούν να ξεπεράσουν την αγορά με τη χρησιμοποίηση εσωτερικών πληροφοριών ή άλλων μέσων.

Chaos Theory

Μια σχετικά νέα προσέγγιση στη διαμόρφωση των μη γραμμικών δυναμικών συστημάτων όπως στην χρηματιστηριακή αγορά είναι η θεωρία χάους. Η θεωρία του χάους αναλύει μια διαδικασία κάτω από την υπόθεση ότι μέρος της διαδικασίας είναι αιτιοκρατικό (*deterministic*) και μέρος της διαδικασίας είναι τυχαίο. Το χάος είναι μια μη γραμμική διαδικασία που εμφανίζεται να είναι τυχαία. Διάφορες θεωρητικές δοκιμές έχουν αναπτυχθεί για να εξετάσουν εάν ένα σύστημα είναι χαοτικό.

Η θεωρία του χάους είναι μια προσπάθεια να δείξει ότι η κατάταξη υπάρχει στο προφανές τυχαίο. Με το υπονοούμενο ότι η χρηματιστηριακή αγορά δεν είναι χαοτική και όχι απλά τυχαία, η θεωρία χάους έρχεται σε αντίθεση με το EMH.

Στην ουσία, ένα χαοτικό σύστημα είναι ένας συνδυασμός μιας αιτιοκρατικής και τυχαίας διαδικασίας. Η αιτιοκρατική διαδικασία μπορεί να χαρακτηριστεί χρησιμοποιώντας τη συναρμολόγηση οπισθοδρόμησης, ενώ η τυχαία διαδικασία μπορεί να χαρακτηριστεί από τις στατιστικές παραμέτρους μιας συνάρτησης κατανομής. Κατά συνέπεια, η χρησιμοποίηση μόνο των αιτιοκρατικών ή στατιστικών τεχνικών δεν θα συλλάβει πλήρως τη φύση ενός χαοτικού συστήματος. Μια δυνατότητα των νευρωνικών δικτύων να συλλαμβάνουν και τα αιτιοκρατικά και τα τυχαία χαρακτηριστικά γνωρίσματα τα καθιστούν ιδανικά για τη διαμόρφωση των χαοτικών συστημάτων.

Άλλες τεχνικές

Πολλές άλλες τεχνικές βασισμένες σε υπολογιστή, έχουν υιοθετηθεί για να προβλέψουν τη χρηματιστηριακή αγορά. Κυμαίνονται από προγράμματα χαρτογράφησης μέχρι περίπλοκα ειδικά συστήματα. Η *Fuzzy logic* (συγκεχυμένη λογική) έχει χρησιμοποιηθεί επίσης.

Τα έμπειρα συστήματα επεξεργάζονται διαδοχικά τη γνώση και την διαμορφώνουν στους κανόνες. Μπορούν να χρησιμοποιηθούν για να διαμορφώνουν τους κανόνες εμπορικών συναλλαγών που βασίζονται σε τεχνικούς δείκτες. Σε αυτή τη χωρητικότητα, τα έμπειρα συστήματα μπορούν να χρησιμοποιηθούν από κοινού με τα νευρωνικά δίκτυα για να προβλέψουν τη χρηματιστηριακή αγορά. Σε ένα τέτοιο συνδυαστικό σύστημα, το νευρωνικό δίκτυο μπορεί να πραγματοποιήσει την πρόβλεψή του, ενώ το έμπειρο

σύστημα μπορούσε να επικυρώσει την πρόβλεψη που βασίστηκε στους γνωστούς του κανόνες εμπορικών συναλλαγών.

Το πλεονέκτημα των έμπειρων συστημάτων είναι ότι μπορούν να εξηγήσουν πώς παράγουν τα αποτελέσματά τους. Με τα νευρωνικά δίκτυα, είναι δύσκολο να αναλυθεί η σημασία των δεδομένων εισόδου και πώς το δίκτυο παρήγαγε τα αποτελέσματά του.

Εντούτοις, τα νευρωνικά δίκτυα είναι γρηγορότερα διότι εκτελούν την παραπάνω εργασία σε παράλληλη σύνδεση και είναι περισσότερο ανεκτικά σε σφάλμα.

Το σημαντικότερο πρόβλημα με την εφαρμογή των έμπειρων συστημάτων στην χρηματιστηριακή αγορά είναι η δυσκολία στην διατύπωση της γνώσης πάνω στις αγορές διότι εμείς οι ίδιοι δεν τα καταλαβαίνουμε απόλυτα. Τα νευρωνικά δίκτυα έχουν ένα πλεονέκτημα σε σχέση με τα έμπειρα συστήματα επειδή μπορούν να εξαγάγουν κανόνες χωρίς να τους έχουν τυποποιήσει ρητά. Ιδιαίτερα σε ένα χαοτικό και μόνο μερικώς κατανοητό περιβάλλον, όπως η χρηματιστηριακή αγορά, αυτός είναι ένας σημαντικός παράγοντας. Είναι δύσκολο να εξαχθούν πληροφορίες από τους εμπειρογνώμονες και να τυποποιηθούν με έναν τρόπο χρησιμοποιήσιμο από τα έμπειρα συστήματα.

Τα έμπειρα συστήματα είναι καλά μόνο μέσα στο τομέα γνώσης τους και δεν λειτουργούν καλά όταν υπάρχει απώλεια πληροφορίας ή ελλιπείς πληροφορίες. Τα νευρωνικά δίκτυα χειρίζονται καλύτερα δυναμικά δεδομένα και μπορούν να γενικεύσουν και να κάνουν τις "εκπαιδευμένες εικασίες." Κατά συνέπεια, τα νευρωνικά δίκτυα είναι περισσότερο ιδανικά για το περιβάλλον της χρηματιστηριακής αγοράς από τα έμπειρα συστήματα.

Εφαρμογή των Νευρωνικών Δικτύων στην Πρόβλεψη Αγοράς

Το περιβάλλον εκμάθησης

Ένας από τους σημαντικότερους παράγοντες στην κατασκευή ενός νευρωνικού δικτύου είναι η απόφαση σχετικά με το που και το τι θα μάθει το δίκτυο. Ο στόχος των περισσότερων από αυτά τα δίκτυα είναι να αποφασιστεί το πότε να αγοραστεί ή να πωληθεί τίτλος που βασίζεται στους προηγούμενους δείκτες αγοράς. Η πρόκληση καθορίζει ποιοι δείκτες και δεδομένα εισόδου θα χρησιμοποιηθούν, συλλέγοντας αρκετά στοιχεία κατάρτισης για να εκπαιδευτεί το σύστημα κατάλληλα.

Τα δεδομένα εισόδου μπορούν να είναι ακατέργαστα δεδομένα στην ένταση του ήχου, την τιμή ή την καθημερινή αλλαγή, αλλά μπορούν επίσης να περιλαμβάνουν τα παραγόμενα δεδομένα όπως τεχνικοί δείκτες (κινούμενος μέσος όρος κλπ) ή θεμελιώδεις δείκτες (ευγενής αξία μεριδίου, οικονομικό περιβάλλον, κλπ.).

Τα δεδομένα εισόδου πρέπει να επιτρέψουν στο νευρωνικό δίκτυο να γενικεύσει τη συμπεριφορά της αγοράς περιέχοντας εντούτοις περιορισμένα περιττά δεδομένα. Ένα περιεκτικό παράδειγμα νευρωνικού δικτύου, ονομαζόμενο JSE- system, διαμόρφωσε την απόδοση της ανταλλαγής αποθεμάτων Johannesburg. Αυτό το σύστημα είχε 63 δείκτες, από ποικίλες κατηγορίες, σε μία προσπάθεια να αποκτηθεί μια γενική όψη του περιβάλλοντος αγοράς χρησιμοποιώντας ακατέργαστα δεδομένα και παραγόμενους δείκτες. Οι 63 εισερχόμενες αξίες μπορούν να διαιρεθούν στις ακόλουθες κλάσεις με τον αριθμό δεικτών σε κάθε κλάση στην παρένθεση:

1. fundamental(3) - volume, yield, price/earnings

2. technical(17) - moving averages, volume trends, κ.τ.λ.
3. JSE indices(20) - market indices for various sectors: gold, metals. κ.τ.λ.
4. international indices(9) - DJIA. κ.τ.λ.
5. gold price/foreign exchange rates(3)
6. interest rates(4)
7. economic statistics(7) – exports, imports, κ.τ.λ.

Παρακάτω παρουσιάζεται ένα νευρωνικό δίκτυο για την τεχνική ανάλυση του χρηματιστηρίου, και η μέθοδος εκπαίδευσής του για την βελτίωση της δυνατότητας πρόβλεψής του. Όταν ο αριθμός των δειγμάτων εκμάθησης είναι ανώμαλος μεταξύ των κατηγοριών, το νευρωνικό δίκτυο με την κανονική εκμάθηση συναντά πρόβλημα στην προσπάθεια να βελτιώσει μόνο την ακρίβεια πρόβλεψης της πιο κυρίαρχης κατηγορίας. Παρακάτω προτείνεται μια μέθοδος εκμάθησης για τη βελτίωση της ακρίβειας πρόβλεψης άλλων κατηγοριών, ελέγχοντας τον αριθμό των δειγμάτων εκμάθησης με τη χρησιμοποίηση πληροφοριών γύρω από τη σημασία κάθε μιας κατηγορίας. Η πειραματική προσομοίωση χρησιμοποιώντας πραγματικές τιμές δεδομένων πραγματοποιείται για να καταδείξει τη χρησιμότητα της μεθόδου.

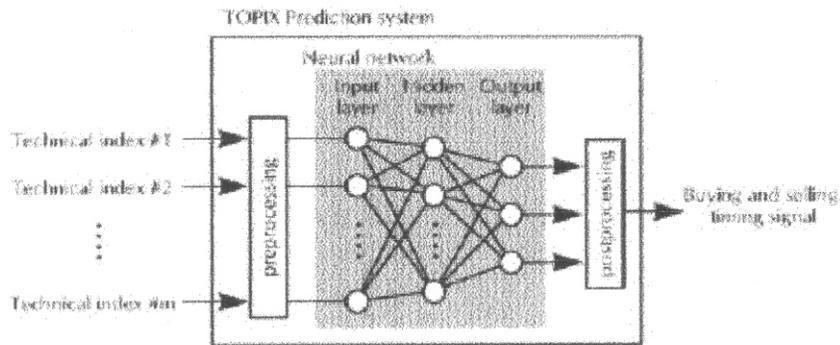
Προτείνεται ένα νευρωνικό δίκτυο για την τεχνική ανάλυση του χρηματιστηρίου, και η μέθοδος εκμάθησής του για την βελτίωση της ικανότητα πρόβλεψης. Στην χρηματιστηριακή πρόβλεψη, έχουν αναπτυχθεί και χρησιμοποιούνται πολλές μέθοδοι για την τεχνική ανάλυση. Στην τεχνική ανάλυση, οι τεχνικοί δείκτες που υπολογίζονται από την ακολουθία τιμών χρησιμοποιούνται για την πρόβλεψη την τάση αλλαγών των μελλοντικών τιμών. Πολλές στατιστικές μέθοδοι έχουν προταθεί, αλλά τα αποτελέσματα είναι ανεπαρκή στην ακρίβεια της πρόβλεψης. Το παρακάτω νευρωνικό δίκτυο εφαρμόζεται στην τεχνική ανάλυση ως πρότυπο πρόβλεψης και ένα αγοράς και πώλησης σύστημα χρονικής πρόβλεψης για το TOPIX (Tokyo Stock Exchange Prices Index) παρουσιάζεται. Το TOPIX είναι ένας σταθμισμένος μέσος όρος τιμών όλων των αποθεμάτων που απαριθμούνται στον πρώτο Τμήμα της ανταλλαγής αποθεμάτων του Τόκιο (First Section of Tokyo Stock Exchange).

Διάφορα νευρωνικά δίκτυα έχουν ήδη αναπτυχθεί για την πρόβλεψη του χρηματιστηρίου. Μερικά εφαρμόζονται για την πρόβλεψη της μελλοντικής τιμής ή του ποσοστού αλλαγών, και μερικά άλλα εφαρμόζονται για την αναγνώριση ορισμένων σχεδίων τιμών που είναι χαρακτηριστικά για την μελλοντική αλλαγή της τιμής.

Στη μέθοδο αυτή, οι αριθμοί των δειγμάτων εκμάθησης ελέγχονται με τη χρησιμοποίηση πληροφοριών γύρω από τη σημασία κάθε κατηγορίας. Η πειραματική προσομοίωση χρησιμοποιώντας πραγματικές TOPIX τιμές δεδομένων, έρχεται να καταδείξει τη χρησιμότητα της προτεινόμενης μεθόδου.

Παρακάτω φαίνεται το σχήμα του συστήματος πρόβλεψης για το TOPIX (Σχήμα 4.31). Το σύστημα πρόβλεψης ταξινομεί το σχέδιο εισόδου που αποτελείται από διάφορους τεχνικούς δείκτες του TOPIX και παράγει ένα σήμα αγοράς ή πώλησης για την ειδοποίηση των χρηστών. Όπως φαίνεται στο Σχήμα 4.36, το σύστημα αποτελείται από ένα νευρωνικό δίκτυο, μια μονάδα προεπεξεργασίας, και μια postprocessing μονάδα. Η μονάδα προεπεξεργασίας ομαλοποιεί κάθε τεχνικό δείκτη σε μια αναλογική αξία (τιμή) 0 έως 1 για να διαμορφώσει ένα σχέδιο εισόδου στο νευρωνικό δίκτυο. Κατόπιν το δίκτυο αναγνωρίζει την κρίσιμη καμπή της καμπύλης τιμών του TOPIX από το σχέδιο

εισαγωγής. Τέλος, η postprocessing μονάδα μετατρέπει το αποτέλεσμα της αναγνώρισης σε ένα σήμα συγχρονισμού αγοράς και πώλησης.



Σχήμα 4.31

Όπως φαίνεται στο σχήμα, το νευρωνικό δίκτυο ως πρότυπο πρόβλεψης είναι ένα ιεραρχικό δίκτυο που αποτελείται από τρία στρώματα (layers) :

το στρώμα εισόδου, το κρυμμένο στρώμα και το στρώμα εξόδου. Κάθε μονάδα στο δίκτυο συνδέεται με όλες τις μονάδες στα παρακείμενα στρώματα. Κάθε μονάδα λαμβάνει τις εξόδους (αποτελέσματα) των μονάδων στο χαμηλότερο στρώμα και υπολογίζει το άθροισμα των βαρών για να καθορίσει τη συνολική είσοδο. Κατόπιν η έξοδος καθορίζεται εφαρμόζοντας την συνάρτηση λογιστικής (logistic function) στη συνολική είσοδο. Κατά συνέπεια, η έξοδος κυμαίνεται από 0 έως 1.

Τα δεδομένα για τη διαμόρφωση του σχεδίου εισόδου στο σύστημα είναι τεχνικοί δείκτες του TOPIX.

Οι χαρακτηριστικοί τεχνικοί δείκτες είναι:

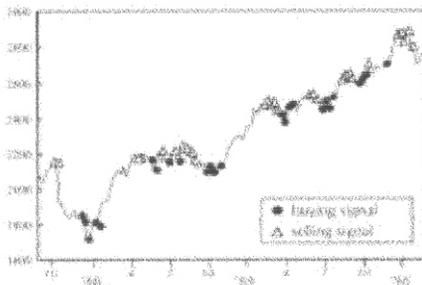
- Μέσος Όρος Κίνησης:
Αυτός είναι ένας μέσος όρος των τιμών κατά τη διάρκεια συγκεκριμένης προηγούμενης περιόδου, και αναπτυσσόμενος για να επιτρέψει στους χρήστες να κατανοούν την τάση χωρίς καθημερινή διακύμανση. Υπάρχουν διάφορες παραλλαγές ανάλογα με την περίοδο: 6, 10, 25, 75, 100, 150, και 200 ημέρες. Η κατεύθυνση και η θέση της καμπύλης του κινούμενου μέσου όρου χρησιμοποιούνται για την πρόβλεψη της μεταβολή των τιμών.
- Απόκλιση της τιμής από τον κινούμενο μέσο όρο:
Αυτός ο δείκτης χρησιμοποιείται για τον έλεγχο εάν η τιμή κάθε ημέρα είναι πάρα πολύ υψηλή ή χαμηλή εάν συγκριθεί με την αναμενόμενη τιμή.
- Ψυχολογική γραμμή:
Αυτός ο δείκτης υπολογίζεται διαίρεση τον αριθμό ημερών της τιμής ups με συγκεκριμένη προηγούμενη περίοδο. Αυτό χρησιμοποιείται για την πρόβλεψη της μεταβολής τιμών από το ρυθμό των ups και downs.
- Σχετικός δείκτης δύναμης:
Αυτός ο δείκτης είναι παρόμοιος με την ψυχολογική γραμμή, και υπολογίζεται με τη διαίρεση του αθροίσματος των τιμών ups με το άθροισμα των τιμών διακυμάνσεων (ups και downs) κατά τη διάρκεια συγκεκριμένης προηγούμενης περιόδου.

Κάθε ένας από αυτούς τους δείκτες είναι ομαλοποιημένος από 0 έως 1 για να διαμορφώσει ένα σχέδιο εισόδου στο πρότυπο νευρωνικό δίκτυο.

Στο νευρωνικό δίκτυο, το στρώμα εξόδου έχει τρεις μονάδες. Σαν σχέδια εξόδου του δικτύου, καθορίζουμε τρία σχέδια όπως φαίνεται στον παρακάτω πίνακα. Κάθε ένας αντιστοιχεί σε συγκεκριμένα σχέδια καμπυλών TOPIX: σήμα αγοράς (δηλ. η τρέχουσα τιμή είναι στο κατώτατο σημείο), σήμα πώλησης (δηλ. η τρέχουσα τιμή είναι στην κορυφή), και καμία αλλαγή (δηλ. ειδιάλλως), αντίστοιχα. Τα κατώτατα σημεία (bottoms) και οι κορυφές (tops) στην καμπύλη τιμών συσχετίζονται πολύ με τον συγχρονισμό αγοράς και πώλησης. Όταν εκπαιδεύεται το νευρωνικό δίκτυο, κάθε σωστό σχέδιο εξόδου του δείγματος εκμάθησης υπολογίζεται από τρία TOPIX δεδομένα όπως περιγράφονται στον πίνακα: τρέχουσα τιμή, τιμή σε πέντε εβδομάδες πριν, και τιμή πέντε εβδομάδες μετά.

TOPIX curve			neural network correct output pattern
(past)	(current)	(future)	
			(1, 0, 0) : selling signal
			(0, 1, 0) : no change
			(0, 0, 1) : buying signal

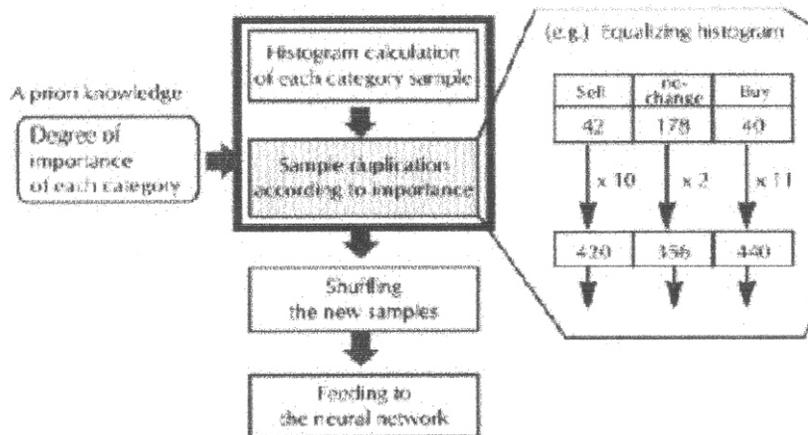
Στο Σχήμα 4.32 που ακολουθεί παρουσιάζεται ένα παράδειγμα σωστών παραγομένων (από υπολογιστή) σημάτων αγοράς και πώλησης στη γραφική παράσταση TOPIX. Τα σήματα αυτά υποδεικνύονται από τους μαύρους κύκλους και τα άσπρα τρίγωνα, αντίστοιχα. Τα σωστά αυτά σήματα υπολογίζονται από τρία TOPIX δεδομένα (δηλ. τρέχουσα τιμή, τιμή πριν από πέντε εβδομάδες, και τιμή μετά από πέντε εβδομάδες) όπως περιγράφονται στον πίνακα, και δεν αναγνωρίζονται από τους εμπειρογνώμονες. Εντούτοις, ένας εμπειρογνώμονας αναλυτής σχολιάζει ότι αυτά τα σωστά σήματα είναι σχεδόν ικανοποιητικά όσο η περίοδος επένδυσης υποτίθεται ότι είναι τριών μηνών.



Σχήμα 4.32

Επειδή σε ένα νευρωνικό δίκτυο η έξοδος των μονάδων στο στρώμα εξόδου κυμαίνεται από αναλογικό 0 σε αναλογικό 1, ένα πραγματικό σχέδιο εξόδου μπορεί να μην ταιριάζει με κανένα από τα τρία σχέδια. Σε αυτήν την περίπτωση, η postprocessing μονάδα μετατρέπει την αναλογική αξία σε 0 ή 1 χρησιμοποιώντας δύο κατώτερα όρια (thresholds). Στην πειραματική προσομοίωση που περιγράφεται περαιτέρω, χρησιμοποιούνται ως thresholds τα 0,4 και 0,6. Όταν η έξοδος είναι μικρότερη από 0,4, τότε επιλέγεται το 0. Με τον ίδιο τρόπο, όταν η έξοδος είναι μεγαλύτερη από 0,6, τότε

επιλέγεται το 1. Εάν η έξοδος είναι μεταξύ 0,4 και 0,6, ή εάν το σχέδιο ακόμα δεν ταιριάζει με καμία από τις τρεις κατηγορίες, το σύστημα ενημερώνει ότι η πρόβλεψη έχει αποτύχει.



Σχήμα 4.33

Εξισωμένη μέθοδος εκμάθησης

Όπως περιγράφεται παραπάνω, το νευρωνικό δίκτυο προσπαθεί να παραγάγει ένα από τρία σχέδια εξόδου για ταξινόμηση (classification).

Η εκμάθηση του δικτύου γίνεται χρησιμοποιώντας τον back-propagation αλγόριθμο. Η στρατηγική εκμάθησης σε αυτόν τον αλγόριθμο είναι να τροποποιηθούν τα βάρη των συνδέσεων μεταξύ των μονάδων προς τη μείωση του συνολικού ποσού των λαθών πρόβλεψης. Εντούτοις, στην περίπτωση όπου η απόκλιση των αριθμών των δειγμάτων εκμάθησης είναι μεγάλη μεταξύ των κατηγοριών των σχεδίων εξόδου, προκύπτει το εξής πρόβλημα:

Το νευρωνικό δίκτυο θα έχει την τάση να βελτιώσει μόνο την ακρίβεια πρόβλεψης της πιο κυρίαρχης κατηγορίας. Κατά συνέπεια, το σύστημα πρόβλεψης παράγει λιγότερα από το αναμενόμενο σήματα συγχρονισμού αγοράς και πώλησης. Αυτό συμβαίνει επειδή δεν λαμβάνονται υπόψη η διαφορά της σημασίας μεταξύ των κατηγοριών.

Πρέπει να διδάξουμε το νευρωνικό δίκτυο ότι το αναμένουμε να παραγάγει σήματα συγχρονισμού αγοράς και πώλησης, και αν δεν κάνει κάτι τέτοιο δεν υπάρχει κανένα νόημα.

Για να υπερνικήσουμε αυτό το πρόβλημα, προτείνεται η "εξισωμένη μέθοδο εκμάθησης" όπως παρουσιάζεται στο παρακάτω Σχήμα 4.34. Πριν την εκμάθηση τα δείγματα τροφοδοτούνται στο νευρωνικό δίκτυο, και εισάγονται το ιστόγραμμα του βήματος υπολογισμού (histogram calculation step) και το δείγμα του βήματος διπλασιασμού (sample duplication step). Η εξισωμένη εκμάθηση πραγματοποιείται με το ακόλουθο τρόπο:

1. Υπολογισμός ιστογράμματος (Histogram calculation)

Το ιστόγραμμα υπολογίζεται μετρώντας τα δείγματα εκμάθησης σε κάθε κατηγορία.

2. Αναπαραγωγή δειγμάτων (Sample duplication)

Με τη χρησιμοποίηση των πληροφοριών για τη σημασία των κατηγοριών και του ιστογράμματος τα δείγματα εκμάθησης σε κάθε κατηγορία αναπαράγονται για να τροποποιήσουν το ιστόγραμμα.

3. Μετάθεση νέων δειγμάτων (Shuffling new samples)
4. Τροφοδοτώντας το νευρωνικό δίκτυο (Feeding the neural network).

Στο βήμα αναπαραγωγής δειγμάτων, όσο σημαντικότερη είναι η κατηγορία, τόσο μεγαλύτερος είναι ο συντελεστής διπλασιασμού που ορίζεται. Στο σύστημα πρόβλεψης TOPIX τα δείγματα εκμάθησης του σήματος αγοράς και του σήματος πώλησης είναι λιγότερο σημαντικά παρά απ' ότι στην κατηγορία καμίας αλλαγής. Επομένως, οι συντελεστές αναπαραγωγής τίθενται στις υψηλότερες τιμές αυτών των κατηγοριών. Εντούτοις είναι δύσκολο να αποφασιστούν αυτές οι τιμές για κάθε κατηγορία, αν και είναι δυνατό να αποφασιστεί η σειρά τους. Στο σύστημα πρόβλεψης, οι συντελεστές τίθενται έτσι ώστε το ιστόγραμμα να γίνει σχεδόν επίπεδο. Συνεπώς το σύστημα πρόβλεψης αρχίζει να παράγει περισσότερα σήματα συγχρονισμού αγοράς και πώλησης τις κατάλληλες στιγμές.

Για να ελέγξουμε την ακρίβεια του συστήματος πρόβλεψης, παρακάτω έχουμε μια πειραματική προσομοίωση που εφαρμόστηκε σε πραγματικά εβδομαδιαία TOPIX δεδομένα. Το σχήμα που ακολουθεί παρουσιάζονται τα δεδομένα δοκιμής. Όπως φαίνεται και στο σχήμα, 260 εβδομαδιαία δεδομένα από τον Σεπτέμβριο του 1982 μέχρι τον Αύγουστο του 1987 (πέντε έτη) έχουν χρησιμοποιηθεί ως δείγματα εκμάθησης για την παραγωγή των προτύπων πρόβλεψης. Μετά από 119 εβδομαδιαία δεδομένα από τον Οκτώβριο του 1987 μέχρι τον Ιανουάριο του 1990 (δύο έτη) χρησιμοποιήθηκαν ως δείγματα πρόβλεψης για την αξιολόγηση (evaluation). Και για τα δύο δείγματα, τα σωστά σχέδια παραγωγής υπολογίζονται σύμφωνα με τον ορισμό που περιγράφεται στον πρώτο πίνακα.

Ένδεκα τεχνικοί δείκτες του TOPIX επιλέγονται για να διαμορφώσουν τα σχέδια εισόδου στο σύστημα όπως περιέχονται στον δεύτερο πίνακα. Αυτοί οι δείκτες επιλέγονται από ειδικούς αναλυτές. Κάθε ένας από αυτούς έχει συχνά χρησιμοποιηθεί και θεωρείται ότι είναι χρήσιμος στην τεχνική ανάλυση.

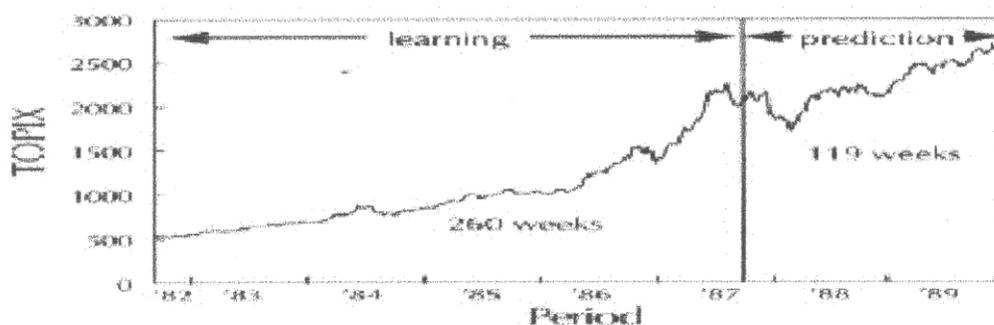
1. Deviation from 25 days moving average	2. Deviation from 75 days moving average
3. Deviation from 200 days moving average	4. Vector curve of 6 days moving average
5. Vector curve of 25 days moving average	6. Vector curve of 75 days moving average
7. Psychological line in 12 days base	8. Psychological line in 25 days base
9. Relative strength index in 9 days base	10. Relative strength index in 12 days base
11. Volume ratio in 25 days base	---

Ο Πίνακας 4.23 παρουσιάζει τις λεπτομέρειες των παραγόμενων (από υπολογιστή) σωστών σχεδίων εξόδου των δεδομένων δοκιμής. Όσον αφορά τα δείγματα εκμάθησης, αναλογίες των δειγμάτων σε τρεις κατηγορίες (δηλ. σήμα πώλησης, σήμα αγοράς, και η καμία-αλλαγή) είναι 16%, 15% και 69% αντίστοιχα. Όσον αφορά τα δείγματα πρόβλεψης, οι αναλογίες των δειγμάτων είναι 26%, 24% και 50% αντίστοιχα. Και στα δύο δείγματα, τα δείγματα στην κατηγορία καμίας-αλλαγής είναι εξαιρετικά μεγαλύτερα από εκείνα στις άλλες δύο κατηγορίες. Αυτό δείχνει ότι ένα νευρωνικό δίκτυο με κανονική μέθοδο εκμάθησης μπορεί πάντα να παραγάγει μια κατηγορία καμίας-αλλαγής ως σχέδιο εξόδου του.

output pattern \ samples	learning samples	prediction samples
sell	42 (16%)	31 (26%)
no change	178 (69%)	59 (50%)
buy	40 (15%)	29 (24%)
total	260	119

Πίνακας 4. 23

Το Σχήμα 4.34 δείχνει επίσης ότι και η περίοδος εκμάθησης και η περίοδος προσομοίωσης έχουν γενικά αυξανόμενη τάση. Αυτό φανερώνει την πιθανή δυσκολία στην πρόβλεψη πώλησης λόγω της έλλειψης αποδοτικών δειγμάτων εκμάθησης για τα σήματα πώλησης.



Σχήμα 4.34

Για τη σύγκριση των αποδόσεων πρόβλεψης, εφαρμόζονται τρία πρότυπα πρόβλεψης:

1. Νευρωνικό δίκτυο με την προτεινόμενη εξισωμένη εκμάθηση
 - συντελεστές αναπαραγωγής των δειγμάτων εκμάθησης: 10, 2 και 11
 - 11 μονάδες στο στρώμα εισόδου, 10 μονάδες στο κρυμμένο στρώμα, και 3 μονάδες στο στρώμα παραγωγής
 - συντελεστές για την ενημέρωση των βαρών: 0,1 και 0,9
 - 5.000 επαναλήψεις
 - thresholds για postprocessing: 0,4 και 0,6
2. Νευρωνικό δίκτυο με κανονική εκμάθηση:
 - ίδιες παράμετροι με το παραπάνω πρότυπο εκτός από την αναπαραγωγή των δειγμάτων εκμάθησης (εδώ δεν υπάρχει)
 - 20.000 επαναλήψεις
3. Στατιστικό πρότυπο βασισμένο στην διακρίνουσα ανάλυση (discriminant analysis)
 - χρησιμοποιούνται δύο πρότυπα: ένα για διαχωρισμό είτε αγοράζοντας σήμα είτε όχι, και ένα για διαχωρισμό είτε πωλείται σήμα είτε όχι.
 - Η γενικευμένη απόσταση των Mahalanobis' χρησιμοποιείται ως μέτρο απόστασης.

Αποτελέσματα Πρόβλεψης

Prediction Result by Neural Network Model with Equalized Learning.

(a) Learning					(b) Prediction						
		correct answer			total			correct answer			total
		sell	no-change	buy				sell	no-change	buy	
result	sell	41	5	0	46	result	sell	14	6	0	20
	no-change	0	157	0	157		no-change	13	39	1	53
	buy	0	4	40	44		buy	1	10	22	33
	invalid	1	9	0	10		invalid	3	4	0	7
total		42	178	40		total		31	59	29	

Πίνακας 4. 24 και Πίνακας 4. 25: Prediction Result by Neural Network Model with Normal Learning.

(a) Learning					(b) Prediction						
		correct answer			total			correct answer			total
		sell	no-change	buy				sell	no-change	buy	
result	sell	35	0	0	35	result	sell	5	0	0	5
	no-change	5	178	1	184		no-change	23	49	5	77
	buy	0	0	39	39		buy	1	7	19	27
	invalid	2	0	0	2		invalid	2	3	5	10
total		42	178	40		total		31	59	29	

Πίνακας 4. 26 και Πίνακας 4.27: Prediction Result by Statistical Model.

(a) Learning					(b) Prediction						
		correct answer			total			correct answer			total
		sell	no-change	buy				sell	no-change	buy	
result	sell	26	24	1	51	result	sell	6	9	3	18
	no-change	15	145	9	169		no-change	25	48	23	96
	buy	0	6	38	44		buy	0	2	6	8
	invalid	1	9	0	10		invalid	3	4	0	7
total		42	178	40		total		31	59	29	

Πίνακας 4. 28 και Πίνακας 4.29: Performance Comparison of Prediction.

model	ratio of correctness (%) in learning				ratio of correctness (%) in prediction			
	sell	no-change	buy	overall	sell	no-change	buy	overall
neural network model with supervised learning	98	100	100	99	45	66	76	63
neural network model with unsupervised learning	83	100	98	97	16	83	66	51
statistical model	62	83	75	78	19	81	31	50
(answering no-change)	0	100	0	67	0	100	0	50

Πίνακας 4. 30

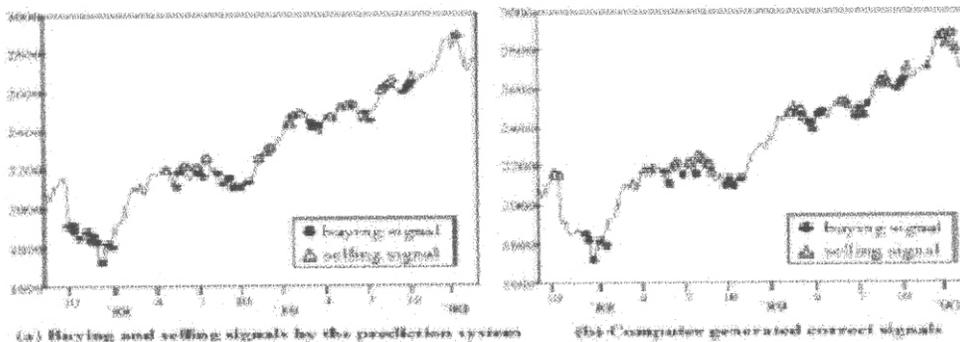
Όπως φαίνεται στον Πίνακα 4.30, το νευρωνικό δίκτυο με κανονική εκμάθηση έχει μάθει τα δείγματα εκμάθησης αποκλειστικά στην κατηγορία καμίας-αλλαγής. Η συνολική αναλογία ακρίβειας για την εκμάθηση είναι 97% και είναι ικανοποιητική. Εντούτοις, για τα δείγματα εκμάθησης σημάτων πώλησης η αναλογία ακρίβειας είναι 83% (35/42), χαμηλότερη από τη συνολική. Αυτός σημαίνει ότι το δίκτυο μαθαίνει κυρίως τα δείγματα στην κατηγορία καμίας-αλλαγής η οποία είναι η πιο κυρίαρχη από τις τρεις κατηγορίες.

Όσον αφορά την πρόβλεψη, αν και η αναλογία ακρίβειας για την πρόβλεψη καμίας - αλλαγής είναι 83% (49/59), οι αναλογίες για την πρόβλεψη των σημάτων αγοράς και πώλησης είναι 66% (19/29) και 16% (5/31) αντίστοιχα, δηλ. πολύ χαμηλότερος. Μπορεί να γίνει κατανοητό ότι δεν έχει αναπτυχθεί αρκετά η εκμάθηση για τα δείγματα εκμάθησης σε αυτές τις δύο τελευταίες κατηγορίες. .

Απ' την άλλη, όπως φαίνεται στον Πίνακα 4.29, το νευρωνικό δίκτυο με την εξισωμένη μέθοδος εκμάθησης έμαθε τα δείγματα εκμάθησης στην κατηγορία καμίας-αλλαγής για 88 %>(157/178), έμαθε τα σήματα πώλησης και τα σήματα αγοράς σε 98% (41/42) και 100% (40/40) αντίστοιχα. Αυτά υπερβαίνουν την απόδοση του νευρωνικού δικτύου με την κανονική εκμάθηση κατά 15% και 2%, αντίστοιχα. Αυτό δείχνει ότι η εκμάθηση πραγματοποιήθηκε εξίσου στις τρεις κατηγορίες. Όσον αφορά την πρόβλεψη, αν και η αναλογία ακρίβειας για την πρόβλεψη καμίας-αλλαγής είναι 66% (39/59) και χαμηλότερη από το κανονικό πρότυπο εκμάθησης η αναλογία της ακρίβειας για την πρόβλεψη των σημάτων πώλησης είναι 45% (14/31), το οποίο υπερβαίνει το κανονικό πρότυπο εκμάθησης κατά 29 %. Η αναλογία ακρίβειας για την πρόβλεψη των σημάτων αγοράς είναι 76% (22/29) και υπερβαίνει το κανονικό πρότυπο εκμάθησης κατά 10%. Η συνολική αναλογία η ακρίβεια είναι 63% και δεν υπάρχει καμία σημαντική διαφορά εάν συγκριθεί με το κανονικό πρότυπο. Υποθέτοντας ότι η βελτίωση της ακρίβειας της πρόβλεψης για τα σήματα πώλησης και αγοράς είναι σημαντικότερη στους χρήστες, αυτά τα αποτελέσματα καταδεικνύουν ότι το προτεινόμενο νευρωνικό δίκτυο παρουσιάζει υψηλότερη απόδοση πρόβλεψης από το κανονικό νευρωνικό πρότυπο δικτύου. Εντούτοις, δεδομένου ότι η ακρίβεια πρόβλεψης για τα σήματα πώλησης είναι ακόμα χαμηλή, είναι απαραίτητη η περαιτέρω ανάλυση για βελτίωση.

Όπως φαίνεται στον πίνακα, η απόδοση του στατιστικού προτύπου είναι πολύ χαμηλότερη από αυτή του κανονικού νευρωνικού δικτύου σε κάθε πτυχή εκτός από την ακρίβεια πρόβλεψης για τα σήματα πώλησης.

Στο Σχήμα 4.35 (α), σχεδιάζονται τα σήματα συγχρονισμού πώλησης και αγοράς που παράγονται από το σύστημα πρόβλεψης. Η σύγκριση τα σωστά σήματα που παράγονται από υπολογιστή στο Σχήμα 4.35 (β), δείχνει ότι τα σήματα από το σύστημα είναι παρόμοια με τα σωστά στο σύνολο.



Σχήμα 4.35

Άλλη εφαρμογή είναι η κατασκευή ενός έμπειρου συστήματος βασισμένο σε ΤΝΔ το οποίο εκτιμάει την δανειοληπτική ικανότητα κάποιου τραπεζικού πελάτη. Τα δεδομένα με τα οποία εκπαιδεύεται είναι:

- Η κοινωνική κατάσταση του πελάτη.

- Η οικονομική κατάσταση του πελάτη.
- Τα περιουσιακά στοιχεία του πελάτη.

Το ΤΝΔ εκτιμάει τον κίνδυνο μη αποπληρωμής του δανείου και αποφασίζει για τη χορήγηση δανείου ή την απόρριψη αίτησης του πελάτη.

4.5 Αναγνώριση Ομιλίας (Speech Recognition)

Η αναγνώριση ομιλίας είναι μία από τις σημαντικότερες εφαρμογές κατά την οποία η ομιλία μετατρέπεται σε κείμενο. Η συνεχής αναγνώριση ομιλίας είναι πρόβλημα μεγάλης πολυπλοκότητας και μπορεί να απλοποιηθεί σε επιμέρους προβλήματα.

- Αναγνώριση φωνημάτων
- Αναγνώριση απλών λέξεων
- Αναγνώριση περιορισμένου αριθμού λέξεων
- Αναγνώριση ενός ομιλητή

Ο άνθρωπος κατανοεί τον προφορικό λόγο μέσω του ακουστικού σήματος που καταφθάνει στο αυτί του. Η κατανόηση είναι πολύ πιο εύκολη όταν ο ακροατής βλέπει τις κινήσεις ή και το πρόσωπο του ομιλητή, δηλ. το ηχητικό σήμα και το οπτικό είναι συμπληρωματικά.

Στην συνέχεια θα εξετάσουμε την αναγνώριση φωνημάτων και την αναγνώριση ενός ομιλητή. Τα οπτικοακουστικά δεδομένα που χρησιμοποιήθηκαν στην εκπαίδευση του ΤΝΔ καταγράφηκαν σε βίντεο με 30 frames/sec και κάθε frame αφορούσε 33msec ήχου. Σε αυτό το χρονικό διάστημα περιλαμβάνονται περισσότερα από ένα επιφωνήματα γι' αυτό το λόγο έγινε επιλογή των φωνημάτων. Ο συνολικός αριθμός των εικόνων είναι 108 δηλ. από 54 εικόνες για εκπαίδευση και έλεγχο των 9 φωνημάτων από 12 φορές το καθένα. Μετά από κάθε επεξεργασία κάθε εικόνα αποτελούνταν από 20x25 pixels. Επομένως το επίπεδο εισόδου του ΤΝΔ διέθετε 500 TN, το κρυφό επίπεδο διέθετε 5 TN και το επίπεδο εξόδου διέθετε 9 TN, έναν για κάθε κατηγορία. Η μέση ικανότητα γενίκευσης ήταν 76%. Το ποσοστό αυτό ήταν περίπου ίδιο με το ποσοστό δύο ανθρώπων που προσπάθησαν να κάνουν την ίδια δουλειά. Όταν όμως τα δεδομένα προέρχονταν από συνεχή ομιλία η γενίκευση μειωνόταν στο 40%.

Η συνάρτηση μεταφοράς του φωνητικού οργάνου μπορεί να υπολογιστεί από την μέτρηση του φάσματος των πλατών του ακουστικού σήματος, δεν μπορεί να προσδιοριστεί όμως ακριβώς από τα οπτικά δεδομένα διότι πολλά ακουστικά σήματα παράγονται από διευθετήσεις του φωνητικού οργάνου που έχουν την ίδια εικόνα. Αν όμως τεθούν επιπλέον περιορισμοί, μπορεί να γίνει ένας ικανοποιητικός υπολογισμός της συνάρτησης μεταφοράς από οπτικά δεδομένα. Οι προηγούμενες εικόνες χρησιμοποιήθηκαν για τη εκτίμηση της συνάρτησης μεταφοράς του φωνητικού οργάνου σε συνδυασμό με το αντίστοιχο ηχητικό σήμα, με σκοπό τη βελτίωση του λόγου σήματος προς θόρυβο πριν από την αναγνώριση. Το επίπεδο εισόδου του ΤΝΔ διέθετε 500 TN, το κρυφό επίπεδο διέθετε 5 TN και το επίπεδο εξόδου διέθετε 500 TN, ένα για κάθε μια από τις 32 περιοχές συχνοτήτων.

Στη συνέχεια ένα ΤΝΔ εκπαιδεύτηκε στην ταξινόμηση 9 φωνημάτων συνδυάζοντας τις φασματικές εκτιμήσεις του οπτικού και του ακουστικού σήματος (6 σύνολα των 9 φωνημάτων διαφορετικά από τα προηγούμενα). Από τις μετρήσεις (για διάφορους

λόγους ηχητικού σήματος προς θόρυβο, διαπιστώθηκε ότι ο συνδυασμός των δύο φασμάτων και μάλιστα με διαφορετική βαρύτητα του καθενός για διάφορους λόγους ηχητικού σήματος προς θόρυβο που μελετήθηκαν, βελτίωσε σημαντικά την ικανότητα αναγνώρισης των φωνημάτων σε σχέση με την αναγνώριση μόνον από το ηχητικό σήμα (π.χ. στα 0db από 25% σε 53% και στα 12db από 80% σε 88%), ενώ με χρήση μόνον του φάσματος του οπτικού σήματος η αναγνώριση ήταν 55%. Η σύγκριση αυτών των αποτελεσμάτων με τεχνικές βέλτιστης γραμμικής εκτίμησης έδειξε ότι το ΤΝΔ παρουσιάζει σημαντικά καλύτερη απόδοση (το μέσο τετραγωνικό σφάλμα ήταν 46% μικρότερο στο εκπαιδευτικό σύνολο και 12% μικρότερο στο σύνολο ελέγχου).

Επειδή κατά τον υπολογισμό του ήχου αλλά και της εικόνας ο αριθμός υπολογισμών κατά το στάδιο προεπεξεργασίας είναι μεγάλος για την υλοποίηση του συστήματος σε πραγματικό χρόνο (on-line), απαιτείται η χρήση εξειδικευμένου hardware π.χ. αναλογικά ολοκληρωμένα κυκλώματα τεχνολογίας VLSI.

4.6 Αναγνώριση Δακτυλικών Αποτυπωμάτων (Fingerprint Identification)

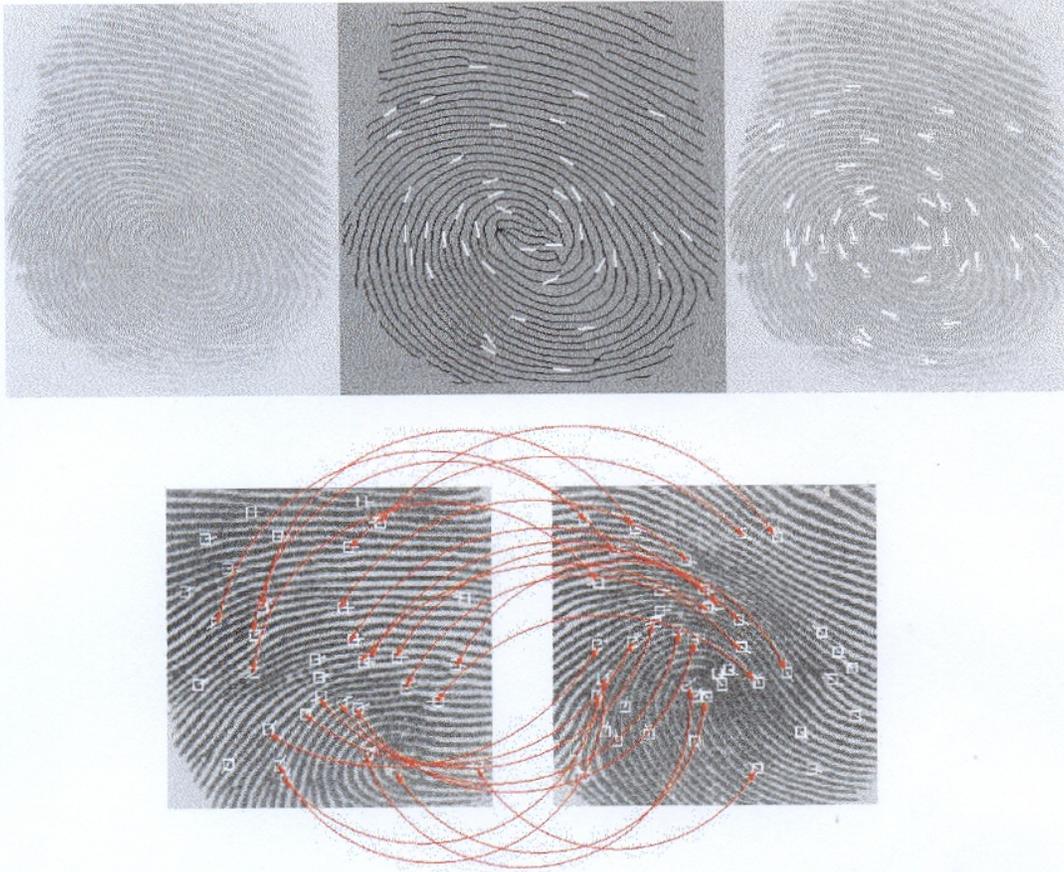
Μεταξύ όλων των βιομετρικών τεχνικών, η αναγνώριση με βάση τα δακτυλικά αποτυπώματα είναι η παλαιότερη μέθοδος που έχει χρησιμοποιηθεί επιτυχώς στις πολυάριθμες εφαρμογές. Ο καθένας έχει μοναδικά, αμετάβλητα δακτυλικά αποτυπώματα. Ένα δακτυλικό αποτύπωμα αποτελείται από μια σειρά κορυφογραμμών και αυλακώσεων (ρυτίδες) στην επιφάνεια του δαχτύλου. Η μοναδικότητα ενός δακτυλικού αποτυπώματος μπορεί να καθοριστεί από το σχέδιο των κορυφογραμμών και των αυλακώσεων καθώς επίσης και των σημείων που έχουν μικρολεπτομέρειες. Τα σημεία μικρολεπτομερειών είναι τοπικά χαρακτηριστικά κορυφογραμμών που εμφανίζονται είτε σε μια διακλάδωση κορυφογραμμών είτε σε ένα τελείωμα κορυφογραμμών.

Οι τεχνικές για την αντιστοίχιση των δακτυλικών αποτυπωμάτων μπορούν να τοποθετηθούν σε δύο κατηγορίες:

- οι βασισμένες σε μικρολεπτομέρειες και
- οι βασισμένες σε συσχετισμούς.

Οι πρώτες αρχικά βρίσκουν τα σημεία μικρολεπτομερειών και χαρτογραφούν έπειτα τη σχετική τοποθέτησή τους στο δάχτυλο. Εντούτοις, υπάρχουν μερικές δυσκολίες κατά τη χρησιμοποίηση αυτής της προσέγγισης. Είναι δύσκολο να εξαχθούν με ακρίβεια τα σημεία μικρολεπτομερειών όταν το δακτυλικό αποτύπωμα είναι χαμηλής ποιότητας. Επίσης αυτή η μέθοδος δεν λαμβάνει υπόψη το σφαιρικό σχέδιο των κορυφογραμμών και των αυλακώσεων.

Η δεύτερη κατηγορία μεθόδου είναι σε θέση να υπερνικήσει μερικές από τις δυσκολίες της πρώτης προσέγγισης. Εντούτοις, έχει μερικές δικές της ανεπάρκειες. Απαιτεί την ακριβή θέση ενός σημείου και επηρεάζεται από τη μετάφραση και την περιστροφή της εικόνας.



Σχήμα 4.36

Η αντιστοίχιση δακτυλικών αποτυπωμάτων βασισμένη στις μικρολεπτομέρειες έχει προβλήματα στο ταίριασμα των σχεδίων μικρολεπτομερειών διαφορετικού μεγέθους (μη καταγεγραμμένων). Οι τοπικές δομές κορυφογραμμών δεν μπορούν να χαρακτηριστούν εντελώς από τις μικρολεπτομέρειες. Δοκιμάζουμε μια εναλλακτική αντιπροσώπευση των δακτυλικών αποτυπωμάτων που θα συλλάβει περισσότερες τοπικές πληροφορίες και θα παραγάγει έναν σταθερό κώδικα για το δακτυλικό αποτύπωμα.

Αναπτύσσουμε αλγόριθμους που είναι πιο ανθεκτικοί στο θόρυβο που υπάρχει στις εικόνες δακτυλικών αποτυπωμάτων και παρέχουν αυξανόμενη ακρίβεια σε πραγματικό χρόνο. Ένα fingerprint-based εμπορικό αυθεντικό σύστημα απαιτεί ένα πολύ χαμηλό ποσοστό λάθους (False Reject Rate (FAR)) για ένα δεδομένο ποσοστό επιτρεπόμενου λάθους (False Accept Rate (FAR)). Αυτό είναι πολύ δύσκολο να επιτευχθεί με οποιαδήποτε τεχνική. Σε μια πραγματική εφαρμογή, ο αισθητήρας, το αποκτηθέν σύστημα και η παραλλαγή στην απόδοση του συστήματος κατά τη διάρκεια του χρόνου είναι πολύ κρίσιμα.

Ταξινόμηση δακτυλικών αποτυπωμάτων

Οι μεγάλοι όγκοι δακτυλικών αποτυπωμάτων συλλέγονται και αποθηκεύονται καθημερινά σε ένα ευρύ φάσμα εφαρμογών συμπεριλαμβανομένων των ιατροδικαστικών, ελέγχου πρόσβασης, και της εγγραφής των αδειών οδήγησης. Μια

αυτόματη αναγνώριση ανθρώπων βασισμένη σε δακτυλικά αποτυπώματα απαιτεί το δακτυλικό αποτύπωμα εισόδου να αντιστοιχεί σε ένα μεγάλο αριθμό δακτυλικών αποτυπωμάτων σε μια βάση δεδομένων (η βάση δεδομένων του FBI περιέχει περίπου 70 εκατομμύρια δακτυλικά αποτυπώματα!!). Για να μειωθεί ο χρόνος αναζήτησης και η υπολογιστική πολυπλοκότητα, είναι επιθυμητό να ταξινομηθούν αυτά τα δακτυλικά αποτυπώματα κατά τρόπο ακριβή και συνεπή έτσι ώστε το δακτυλικό αποτύπωμα εισόδου να αντιστοιχηθεί σε μόνο ένα υποσύνολο των δακτυλικών αποτυπωμάτων της βάσης δεδομένων.



Σχήμα 4.37

Ένας αλγόριθμος που έχει αναπτυχθεί για την ταξινόμηση δακτυλικών αποτυπωμάτων σε πέντε κατηγορίες, ο *δακτύλιος*, τον *δεξιό βρόχο*, τον *αριστερό βρόχο*, την *καμάρα*, και την *tented καμάρα*. Ο αλγόριθμος χωρίζει τον αριθμό κορυφογραμμών που παρουσιάζονται σε τέσσερις κατευθύνσεις (0 degree, 45 degree, 90 degree, και 135 degree) φιλτράροντας το κεντρικό μέρος ενός δακτυλικού αποτυπώματος με μια τράπεζα φίλτρων. Αυτές οι πληροφορίες κβαντοποιούνται για να παραγάγουν έναν *FingerCode* που χρησιμοποιείται για την ταξινόμηση. Εδώ η ταξινόμηση είναι βασισμένη σε έναν ταξινομητή δύο σταδίων που χρησιμοποιεί ένα *K-nearest neighbor* ταξινομητή στο πρώτο στάδιο και ένα σύνολο νευρωνικών δικτύων στο δεύτερο στάδιο. Ο ταξινομητής εξετάζεται σε 4.000 εικόνες στη NIST-4 βάση δεδομένων. Για το πρόβλημα πέμπτης-κατηγορίας, επιτυγχάνεται ακρίβεια ταξινόμησης 90%. Για το πρόβλημα τέταρτης-κατηγορίας (καμάρα και *tented καμάρα* συνδυάζονται σε μια κατηγορία), επιτυγχάνεται ακρίβεια ταξινόμησης 94,8%. Με την ενσωμάτωση μιας απορριπτικής επιλογής, η ακρίβεια ταξινόμησης μπορεί να αυξηθεί σε 96% για την πρώτη ταξινόμηση και σε 97,8% για τη δεύτερη όταν 30,8% των εικόνων απορρίπτονται.

Αύξηση εικόνας δακτυλικών αποτυπωμάτων

Ένα κρίσιμο βήμα στην αυτόματη αντιστοίχιση δακτυλικών αποτυπωμάτων είναι η αυτόματη και αξιόπιστη εξαγωγή μικρολεπτομερειών από τις εικόνες εισόδου δακτυλικών αποτυπωμάτων. Εντούτοις, η απόδοση ενός αλγορίθμου εξαγωγής μικρολεπτομερειών στηρίζεται σε μεγάλο ποσοστό στην ποιότητα των εικόνων των δακτυλικών αποτυπωμάτων εισόδου. Προκειμένου να εξασφαλιστεί ότι η απόδοση ενός

αυτόματου συστήματος προσδιορισμού /επαλήθευσης δακτυλικών αποτυπωμάτων θα είναι ανθεκτική όσον αφορά την ποιότητα των εικόνων, είναι σημαντικό να ενσωματωθεί ένας αλγόριθμος δακτυλικών αποτυπωμάτων στην δομή εξαγωγής μικρολεπτομερειών. Έχει αναπτυχθεί ένας τέτοιος αλγόριθμος ο οποίος μπορεί προσαρμοστικά να βελτιώσει τη διαύγεια των δομών των κορυφογραμμών και των αυλακώσεων των εικόνων εισόδου, βασισμένος στον υπολογισμό του προσανατολισμού και της συχνότητας των τοπικών κορυφογραμμών. Τα πειραματικά αποτελέσματα δείχνουν ότι η ενσωμάτωση των αλγορίθμων βελτιώνει την ακρίβεια επαλήθευσης.



Σχήμα 4.38

4.7 Πρόβλεψη Καιρού (Weather Prediction)

Ένας τομέας έρευνας, που χρησιμοποιεί την ανθρώπινη ειδική γνώση και τη δύναμη υπολογισμού των υπολογιστών να παράγουν αποτελέσματα, είναι, μετεωρολογία. Ακόμα κι αν η έρευνα στον τομέα αυτό έχει πραγματοποιηθεί για πολύ, οι καιρικές προβλέψεις αποτυγχάνουν ακόμα κατά καιρούς. Οι περισσότεροι άνθρωποι εξοικειώνονται με το γεγονός ότι ακόμα κι αν ο μετεωρολόγος στην τηλεόραση υπόσχεται έναν ηλιόλουστο καιρό και υψηλές θερμοκρασίες, μπορεί πολύ εύκολα να αποδειχθεί μια κρύα και βροχερή ημέρα. Γιατί όμως συμβαίνει αυτό; Δεν έχουν δει αρκετές προβλέψεις για να είναι σε θέση να συναγάγουν σωστά συμπεράσματα για τον ερχόμενο καιρό;

Η καιρική πρόβλεψη είναι ένα δυσνόητο θέμα, και αν και οι μετεωρολόγοι χρησιμοποιούν σύνθετα μαθηματικά πρότυπα, τα πράγματα στη φύση σπάνια εμφανίζονται απολύτως αιτιοκρατικά. Η δυνατότητα των νευρωνικών δικτύων να μην επηρεάζονται από μια θορυβώδη είσοδο και οι δυνατότητες εκμάθησής τους όπως και η ελλοχεύουσα δυσκολία στην εύρεση επακριβών συσχετισμών μεταξύ των καιρικών φαινομένων και του προκύπτοντος καιρού, φαίνονται να τα καθιστούν ένα καλό εργαλείο για την πρόβλεψη του καιρού.

Μια μαθηματική εισαγωγή

Τι είναι πρόβλεψη;

Εάν υποθέσουμε ότι έχουμε μια χρονική σειρά που αντιπροσωπεύεται από τις τιμές

$x(1), x(2), x(N)$

Πρόβλεψη είναι να βρεθούν οι μελλοντικές τιμές $x(N+1), x(N+2), \dots$

Αυτό μπορεί να γίνει ακριβώς εάν η σειρά είναι αιτιοκρατική, και πραγματικά υπάρχουν μέθοδοι υπολογισμού εάν είναι ή όχι. Δυστυχώς, αυτό παίρνει πολλά δείγματα, περισσότερα από αυτά που υπάρχουν στα περισσότερα πρακτικά πειράματα.

Οι προβλέψεις του καιρού είναι ιδιαίτερα χαοτικές με έναν σχεδόν άπειρο αριθμό μεταβλητών που έχουν επιπτώσεις στον καιρό, έτσι ένα άλλο πρότυπο πρέπει να χρησιμοποιηθεί για να προσπαθήσει τουλάχιστον να υπολογίσει ποιες πρέπει να είναι οι μελλοντικές τιμές.

Σε μια non-deterministic χρονική σειρά, το σφάλμα σε μια εκτίμηση θα αυξηθεί με το χρόνο, δηλ. εάν δεν πάρουμε $x(N+1)$ σωστό, υπάρχει μια υψηλή πιθανότητα $x(N+2)$ να έχει ακόμα μεγαλύτερο λάθος. Είναι επίσης συχνή η περίπτωση όπου παλαιές τιμές $x(1), \dots, x(N)$ να μην είναι απολύτως ακριβείς. Στην πραγματικότητα, δεν είναι σχεδόν ποτέ ακριβείς. Στην καιρική πρόβλεψη, για παράδειγμα, είναι αδύνατο να παρέχονται ακριβή καιρικά στοιχεία από όλη την υδρόγειο σε μία δεδομένη στιγμή.

Αυτοί είναι μερικοί από τους λόγους για τους οποίους δεν μπορούμε ποτέ να κάνουμε μια ακριβή πρόβλεψη του καιρού για μια εκτεταμένη χρονική περίοδο, αλλά θα ερευνήσουμε πώς ένα νευρωνικό δίκτυο ανταποκρίνεται σε σύγκριση με άλλες μεθόδους.

Τι απαιτείται;

Καιρικά δεδομένα

Ο "καιρός" είναι μια αρκετά συγκεχυμένη λέξη. Διαφορετικοί άνθρωποι εννοούν διαφορετικά πράγματα όταν χρησιμοποιούν τη λέξη "καιρός", ανάλογα με τις προτιμήσεις τους (π.χ. υψηλές θερμοκρασίες ή ηλιοφάνεια). Γενικά, ο καιρός πρέπει να περιλαμβάνει όλα τα σχετικά φαινόμενα που συμβάλλουν σε υπαίθριες καταστάσεις.

Μερικά κοινά φαινόμενα που εξετάζουν τα ANN είναι η θερμοκρασία, η δύναμη του αέρα και η συννεφιά.

Δεδομένου ότι όπως αναφέραμε νωρίτερα ο ακριβής συσχετισμός μεταξύ διαφορετικών καιρικών φαινομένων δεν είναι πάντα πλήρως γνωστός, μπορούμε να προσπαθήσουμε να τροφοδοτήσουμε το δίκτυο με τις παραμέτρους που σκεφτόμαστε ότι μπορεί να είναι σημαντικές, και έπειτα να αξιολογήσουμε τα αποτελέσματα. Εν πάση περιπτώσει, είναι σημαντικό να μην αποκλείσουμε πάρα πολλές παράμετροι από αυτές που έχουμε διαθέσιμες δεδομένου ότι θέλουμε να στηριχθούμε στο δίκτυο όταν έχουμε να κάνουμε με την εύρεση των συσχετισμών.

Ένα ενδιαφέρον παράδειγμα αυτού είναι ένα πείραμα που πραγματοποιείται από το David Rogers, όπου συνδύασε την Kanerva's sparse distributed memory (SDM) (αραιή διανεμημένη μνήμη), ένα συνειρμικό πρότυπο μνήμης που είναι βασισμένο στις μαθηματικές ιδιότητες των διαστημάτων δυαδικών διευθύνσεων υψηλής διαστατικότητας, και στους γενετικούς αλγορίθμους Holland για την εύρεση διαστημάτων υψηλής διαστατικότητας, σε ένα υβρίδιο αυτών των δύο, αποκαλούμενο γενετική μνήμη.

Οι γενετικοί αλγόριθμοι χρησιμοποιήθηκαν για να μετατρέψουν τα βάρη μεταξύ των κόμβων εισόδου και των κρυμμένων κόμβων στο νευρωνικό δίκτυο, έτσι ώστε να ευνοούνταν τα σημαντικότερα χαρακτηριστικά γνωρίσματα των καιρικών στοιχείων. Έτσι το πρόβλημα ποιες παραμέτρους εισόδου πρέπει να εξετάσουν, και πόσο σημαντική κάθε μία από αυτές ήταν, αντιμετωπίστηκε από τους γενετικούς αλγορίθμους. Επιπλέον, τα αποτελέσματα θα μπορούσαν να αντιμετωπισθούν κατόπιν με την εξέταση των βαρών, δίνοντας κάποια διορατικότητα στους συσχετισμούς (που ήταν ένας από τους λόγους που θελήσαμε να συμβουλευθούμε ένα νευρωνικό δίκτυο για την καιρική πρόβλεψη).

Η κατάρτιση της sparse distributed memory, δεν οδηγεί στην αλλαγή των βαρών μεταξύ των εισόδων και του κρυμμένου στρώματος, αντιθέτως μόνο τα βάρη μεταξύ των κρυμμένων κόμβων και των κόμβων εξόδου αλλάζουν.

Αυτός ο συνδυασμός, η γενετική μνήμη, χρησιμοποιήθηκε για την πρόβλεψη της βροχής στην Αυστραλιανή ακτή. Όπως αποδείχτηκε, μόνο μερικά από τα χαρακτηριστικά γνωρίσματα που τροφοδοτήθηκαν στο δίκτυο αποδείχθηκαν σημαντικά για την πρόβλεψη της βροχής και η γενετική μνήμη βοήθησε να τα προσδιορίσει.

Είσοδος

Πρέπει να τροφοδοτήσουμε στο νευρωνικό δίκτυό μας τα καιρικά δείγματα με κάποιο τρόπο. Δεδομένου ότι πολλοί καιρικοί σταθμοί καταγράφουν διάφορα χαρακτηριστικά γνωρίσματα με αριθμητική μορφή, είναι πιθανό ότι θα πρέπει να επεξεργαστούμε τα

δείγματα αυτού του είδους για την καιρική πρόβλεψή μας. Ένα παράδειγμα παρουσιάζεται παρακάτω:

7524

MALILLA

1988 1997

0101 1231

573945. 158250.

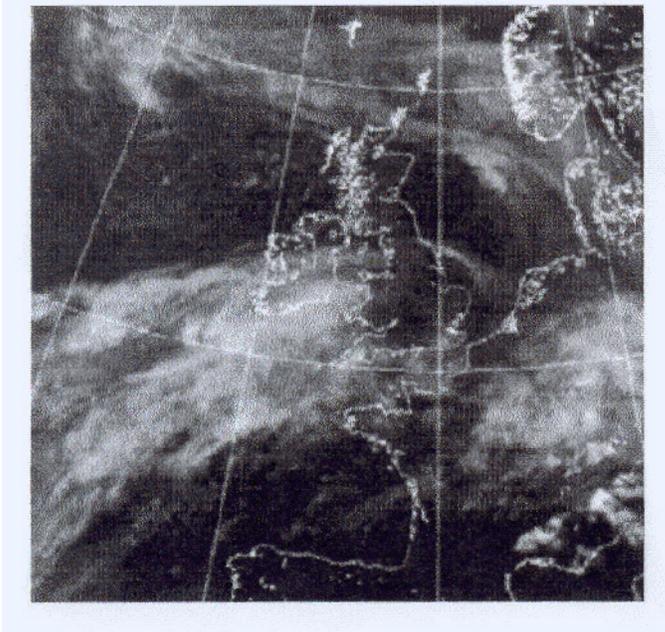
DATE	TTM	TTX	TTN
19880101	4.7	6.7	2.0
19880102	5.6	8.2	4.0
19880103	6.4	10.2	5.1
19880104	3.9	6.2	2.7
19880105	1.6	4.6	-0.5
19880106	2.1	3.0	0.8
19880107	0.4	2.7	0.0
19880108	-2.7	0.6	-3.7
19880109	-2.3	-0.3	-4.8
19880110	2.0	2.7	-0.3
19880111	1.9	3.1	0.3
19880112	2.2	4.2	1.0
19880113	2.1	4.6	0.7
19880114	-0.2	1.5	-2.2
19880115	1.6	4.1	0.0
19880116	0.2	1.8	-1.8
19880117	0.5	1.9	-0.1
19880118	-0.1	0.8	-0.4
19880119	1.3	2.6	-0.2
19880120	0.7	2.1	0.2
19880121	2.0	2.7	0.6
19880122	2.1	3.3	1.6
19880123	0.5	2.6	0.0
19880124	-0.7	0.6	-1.9
19880125	0.1	1.2	-0.5
19880126	0.9	1.7	-0.3
19880127	0.4	1.6	0.1
19880128	0.1	1.1	-0.3
19880129	-1.2	1.2	-2.0
19880130	-2.4	-1.4	-2.7
19880131	-2.3	-1.5	-2.9

Ο Πίνακας 4.31 παρουσιάζει το μέσο (TTM), το μέγιστο (TTX) και τις ελάχιστες (TTN) θερμοκρασίες (σε °C) σε έναν καιρικό σταθμό που βρίσκεται στη Malilla, Σουηδία. τον Ιανουάριο του 1988. Τα δεδομένα προέρχονται από το SMHI [SMHI97]. το Σουηδικό μετεωρολογικό και υδρολογικό ινστιτούτο.

Δεδομένου ότι ένα νευρωνικό δίκτυο είναι ιδανικό για αριθμητική είσοδο, αυτό δεν επιβάλλει σημαντικές δυσκολίες.

Εντούτοις, μια συνοπτική αριθμητική αντιπροσώπευση δεν είναι η μοναδική πιθανή. Θα μπορούσαμε για παράδειγμα να εξετάσουμε τις μετεωρολογικές εικόνες από δορυφόρους.

Κατόπιν αυτό γίνεται ένα πρόβλημα ανάλυσης εικόνας όπου θα πρέπει να αντιπροσωπεύσουμε τα μέρη ή τα pixels μιας εικόνας ως τιμές, προκειμένου να τις παρουσιάσουμε στο δίκτυο. Ένα παράδειγμα παρουσιάζεται παρακάτω:



Η εικόνα παρουσιάζει μια δορυφορική εικόνα από το δορυφόρο Meteorat, απεικονίζοντας την Ευρώπη στις 23 Μαΐου 1996, στις 10:30 UTC.

Τέτοιες δορυφορικές εικόνες είναι ιδιαίτερα χρήσιμες κατά την πρόβλεψη τύπων αέρινων μαζών βασιζμένων στους διαφορετικούς τύπους σύννεφων, δίνοντας στους μετεωρολόγους έναν χρήσιμο υπαινιγμό στο τι να περιμένουν. Φυσικά, ο τύπος των δορυφορικών εικόνων μπορεί να ποικίλει. Ένα παράδειγμα είναι η υπέρυθρη "φωτογραφία" που μπορεί να χρησιμοποιηθεί για την απόκτηση των εικόνων θερμοκρασίας.

Επίσης, πρέπει να εξετάσουμε με ποιο τρόπο πρέπει να παρουσιάσουμε την καιρική κατάσταση στο δίκτυο. Κανονικά, θα περιλαμβάνουμε τις τρέχουσες καιρικές συνθήκες καθώς επίσης και τα καιρικά στοιχεία από ένα προηγούμενο χρονικό διάστημα, π.χ. τέσσερις ώρες πριν.

Το τρέχον καιρικό δείγμα είναι χρήσιμο δεδομένου ότι αποτελεί ένα βήμα σε μια χρονική σειρά και σε συνδυασμό με το προηγούμενο δείγμα, το νευρωνικό δίκτυο πρέπει να είναι σε θέση να ανιχνεύσει την τάση του καιρού.

Τα δίκτυα

Δικτυακές αρχιτεκτονικές

Τα νευρωνικά δίκτυα δεν είναι τόσο κοινά στη μετεωρολογική πρόβλεψη. Οι περισσότερες εφαρμογές σχετικά με την καιρική πρόβλεψη αναπτύσσονται χρησιμοποιώντας μια trial-and-error προσέγγιση. Συχνά υπάρχει μια επιθυμία να είναι τα δίκτυα όσο το δυνατόν απλούστερα για να αποφευχθούν οι δυσκολίες που κληρονομούνται από το δίκτυο και όχι από τα προβλήματα. Με άλλα λόγια, υπάρχει μια γενική συναίνεση να χρησιμοποιούνται γνωστές δικτυακές αρχιτεκτονικές και διαμορφώσεις που είναι εύκολες να προβλέψουν και να συντονίσουν τις παραμέτρους τους.

Η πιο συνηθέστερη χρησιμοποιημένη αρχιτεκτονική είναι το συνηθισμένο πολυστρωματικό feed-forward δίκτυο διάφορων μεγεθών, αλλά μερικές φορές με τις παραλλαγές του. Ένα πράγμα που μπορεί να χρησιμοποιηθεί είναι άμεσες συνδέσεις από τα στρώματα εισόδου στο στρώμα εξόδου. Αυτό οφείλεται στο ότι υπάρχει ένας ισχυρός συσχετισμός μεταξύ του καιρού αυτή τη στιγμή και στο μέλλον. Αυτά τα δίκτυα φαίνονται να συγκλίνουν γρήγορα αλλά δεν επιτυγχάνουν τόσο καλές προβλέψεις όπως τα δίκτυα χωρίς άμεσες συνδέσεις. Αυτό θα μπορούσε να οφείλεται στο γεγονός ότι δίνεται μεγάλη σημασία στην τρέχουσα καιρική κατάσταση, ενώ ο πραγματικός καιρός μπορεί να αλλάξει αρκετά γρήγορα από το ένα άκρο σε κάποιο άλλο.

Εάν εξετάσουμε μερικές εφαρμογές, φαίνεται πως χρησιμοποιούνται περισσότερο δίκτυα με τόσους κρυμμένους κόμβους όσες είναι οι εισοδοί, και έναν ενιαίο κόμβο εξόδου που αντιπροσωπεύει τη μεταβλητή που προβλέπεται (θερμοκρασία, διαφάνεια κ.λ.π.).

Επίσης τα μεγαλύτερα δίκτυα (με περισσότερους κρυμμένους κόμβους) δεν δίνουν οποιαδήποτε σημαντική αλλαγή στην ακρίβεια, και επομένως έχει νόημα η χρήση ενός μικρότερου δικτύου, κερδίζοντας έτσι στην γρηγορότερη εκπαίδευση.

Είναι συχνά αρκετά σύνθετο να προβλεφτεί μόνο μια μεταβλητή. Φαίνεται να είναι ευκολότερο να εκπαιδευθούν και να χρησιμοποιηθούν διάφορα δίκτυα που είναι εξειδικευμένα για έναν ειδικό σκοπό κάθε ένα. Αυτό καθιστά επίσης τους υπολογισμούς σφάλματος ευκολότερους, επειδή εάν έχουμε διάφορες μεταβλητές ως εξόδους, πρέπει να εξετάσουμε ερωτήσεις όπως: "είναι η θερμοκρασία σημαντικότερη από την συννεφιά, και αν ναι, πόσο;".

Εκπαίδευση

Ο Back Propagation χρησιμοποιείται συχνά δεδομένου ότι οι ιδιότητές του είναι ευρέως γνωστές και είναι εύκολο να τεθούν οι παράμετροι σε τέτοιες τιμές που να λειτουργούν αρκετά καλά. Υπάρχουν φυσικά εναλλακτικές λύσεις του Back Propagation, και οι περισσότεροι αλγόριθμοι που χρησιμοποιούνται για να εκπαιδεύσουν ένα νευρωνικό δίκτυο μπορούν να χρησιμοποιηθούν επίσης με την πρόβλεψη, δεδομένου ότι η πρόβλεψη είναι κάποια λειτουργία προσέγγισης (χαρτογράφηση τιμών εισόδου σε μια τιμή εξόδου, ακόμα κι αν το δίκτυο δεν έχει δει ακριβώς εκείνες τις συγκεκριμένες τιμές εισόδου από πριν).

Μια από τις εναλλακτικές λύσεις του συνηθισμένου Back Propagation είναι η *conjugate gradient method* (συζευγμένη μέθοδος κλίσης) που χρησιμοποιεί επίσης τη δεύτερη παράγωγο της συνάρτησης σφάλματος, καθιστώντας πιθανό να ληφθούν μεγαλύτερα βήματα. Αυτό κάνει την κατάρτιση γρηγορότερη, αλλά είναι πιο περίπλοκο για να εφαρμοστεί.

Μια μέθοδος που θα μπορούσε να χρησιμοποιηθεί είναι να σταματηθεί η κατάρτιση μετά από μια στιγμή και να συγκριθούν οι απαντήσεις από το δίκτυο με τις πραγματικές απαντήσεις. Το λάθος χρησιμοποιείται έπειτα για να βρεθεί η μέση και σταθερή απόκλιση, η οποία χρησιμοποιείται στη συνέχεια για να κλιμακώσει την έξοδο. Αυτό θα φροντίσει τα μεγάλα στατιστικά λάθη αφήνοντας τον αλγόριθμο εκμάθησης να ανακαλύψει τις λεπτομέρειες.

Όσον αφορά τη συνάρτηση μεταφοράς, θα μπορούσε να υποστηριχτεί ότι μια sigmoid συνάρτηση θα ήταν καλύτερη από τη γραμμική κανονικοποίηση. Η χρησιμοποίηση μιας sigmoid συνάρτησης μεταφοράς συγκεντρώνει τις ακραίες τιμές, αλλά δίνει μεγαλύτερη ανάλυση στη μέση σειρά όπου ανήκουν οι περισσότερες τιμές.

Υπάρχει μια διαφορά στη δυσκολία της πρόβλεψη ανάλογα με τη θέση και την εποχή. Ο καιρός της άνοιξης και του φθινοπώρου είναι γενικά πιο δύσκολος να προβλεφτεί από το σταθερότερο καιρό του χειμώνα και του καλοκαιριού. Αυτό σημαίνει ότι το ίδιο δίκτυο πρέπει να εκπαιδευθεί για διαφορετικές περιόδους ανάλογα με το που και το πότε χρησιμοποιείται.

Επιπλέον, υπάρχει και το πρόβλημα υπολογισμού του λάθους. Φυσικά αυτό εξαρτάται από το τι προσπαθούμε να προβλέψουμε. Παραδείγματος χάριν, είναι πολύ εύκολο να υπολογιστεί το σφάλμα για τις θερμοκρασίες, είναι ακριβώς η διαφορά μεταξύ της προβλεφθείσας εξόδου και της πραγματικής θερμοκρασίας σε κάποια κλίμακα. Μπορεί να είναι δυσκολότερο να αποκτηθεί μια κλίμακα σε άλλα χαρακτηριστικά γνωρίσματα, όπως η ορατότητα (visibility). Η ορατότητα είναι πολύ σημαντική για τους αερολιμένες, έτσι ώστε να μπορούν να ακυρώσουν ή να επαναπροσανατολίσουν τα αεροπλάνα. Αλλά είναι συχνά δύσκολο να αποκτηθεί μια καλή μέτρηση λάθους σε αυτό το είδος "υποκειμενικών" κλιμάκων.

Ένας τρόπος να αντιμετωπιστεί αυτό είναι να ταξινομηθεί μια πρόβλεψη ως σωστή ή ανακριβής. Θα μπορούσαμε επίσης να εισαγάγουμε κάποια συγκεχυμένη λογική (fuzzy logic) για να περιγράψουμε πόσο ακριβής είναι μια πρόβλεψη, και μετά να χρησιμοποιήσουμε την έξοδο από αυτήν την σαν προσέγγιση λάθους.

Χρόνος εκπαίδευσης

Εξαρτάται έντονα από το πρόβλημα, αλλά γενικά μπορούμε να πούμε ότι η διαδικασία κατάρτισης είναι αρκετά μικρή συγκρινόμενη με τη συλλογή των δεδομένων. Όταν έχουμε έτοιμα δεδομένα, η πραγματική κατάρτιση είναι μια αρκετά γρήγορη διαδικασία.

Εμπορικά προϊόντα

Παρακάτω αναφέρονται μερικά από τα προϊόντα που κυκλοφορούν στην αγορά κατά τη διάρκεια των πρόσφατων ετών. Όλα δίνουν πολλές υποσχέσεις, και πωλούνται συχνά ως γενικά εργαλεία για πολλούς τύπους προβλημάτων.

NeuroShell Predictor: είναι ένα προϊόν που χρησιμοποιείται για την πρόβλεψη και την εκτίμηση των αριθμητικών ποσών. Χρησιμοποιούνται δύο διαφορετικά πρότυπα για να εκπαιδεύσουν το δίκτυο, το ένα καλείται *TurboProp2* το οποίο αυξάνει δυναμικά τους κρυμμένους νευρώνες και έχει μια πολύ γρήγορη καμπύλη κατάρτισης. Το άλλο είναι μια γενετική μέθοδος κατάρτισης που πρέπει να χρησιμοποιηθεί όταν το σύνολο προτύπων είναι μικρό. Η καιρική πρόβλεψη έχει συχνά ένα πολύ μεγάλο σύνολο δεδομένων, έτσι ο πρώτος αλγόριθμος πρέπει πιθανώς να χρησιμοποιηθεί κατά την προσπάθεια πρόβλεψης του καιρού.

BrainMaker: είναι ένα άλλο σύστημα για την πρόβλεψη που έχει χρησιμοποιηθεί επίσης για να αναπτύξει ένα πρότυπο για την πρόβλεψη των βροχοπτώσεων.

Στο παράδειγμά τους, διαίρεσαν τις προβλέψεις σε 5 διαφορετικές κατηγορίες ανάλογα με την ποσότητα των βροχοπτώσεων για μια περίοδο (0 έως 0,49 ίντσες, 0,5 έως 0,99 ίντσες κ.λ.π.).

Υποστήριξαν ότι προβλέπουν την πιθανότητα και την ποσότητα βροχής σε μια τοπική περιοχή με μια ακρίβεια 85% κατά τη διάρκεια μιας εκτεταμένης χρονικής περιόδου. Εντούτοις, δεν είπαν τίποτα για το πόσο πολύ πριν από την πραγματική έκβαση το προέβλεψαν, ούτε είπαν τίποτα για το πόσα δεδομένα χρησιμοποίησαν κατά τη διάρκεια της κατάρτισης. Αυτό δεν λέει πάρα πολλά για το ίδιο το προϊόν.

Παραδείγματα

Πρόβλεψη θερμοκρασίας

Οι προσπάθειες του Peter Bennett να διαμορφώσει την καιρική πρόβλεψη από την άποψη των θερμοκρασιών είναι ένα παράδειγμα των απλούστερων εφαρμογών. Τα καιρικά δεδομένα διαβάζονται από ένα αρχείο, προεπεξεργάζονται (ομαλοποιούνται), και έπειτα τροφοδοτούνται μέσω ενός feed-forward νευρωνικού δικτύου. Ο υπολογισμός λάθους γίνεται με τη λήψη της πραγματικής προκύπτουσας θερμοκρασίας και τη σύγκρισή της με την πρόβλεψη που έδωσε το νευρωνικό δίκτυο. Τα βάρη έπειτα ενημερώνονται όπως συνήθως, με τη χρήση του backpropagation.

Όταν το δίκτυο ήταν εκπαιδευμένο σε ένα μεγάλο σύνολο καιρικών δειγμάτων, εξετάστηκαν οι δυνατότητες πρόβλεψής του με τη χρησιμοποίηση ενός άλλου συνόλου καιρικών δειγμάτων, ένα σύνολο δοκιμής.

Σε αυτήν την περίπτωση, τα καιρικά δείγματα από το Seattle χρησιμοποιήθηκαν κυμαινόμενα κατά τη διάρκεια του χρονικής περιόδου 1976-1990. Ο λόγος για τον οποίο επιλέχτηκε το Seattle ήταν επειδή η γεωγραφική κατάστασή του μοιάζει κάπως με αυτή της Μεγάλης Βρετανίας (από όπου προέρχεται ο Bennett).

Ο Bennett δοκίμασε διάφορες διαφορετικές διαμορφώσεις δικτύων, για πειραματικούς λόγους. Κάθε δίκτυο παρουσιάστηκε με 900.000 καιρικά δείγματα, και το πείραμα εκτελέστηκε κάθε 100.000 παρουσιάσεις.

Αρχίζοντας με ένα δίκτυο 26:26: 1 (με 26 εισόδους, 26 κρυμμένους κόμβους και μια έξοδο) με ρυθμό εκμάθησης 0,1 και με έναν όρο ορμής 0,5, ο Bennett καταλήγει στο συμπέρασμα ότι αυτό το δίκτυο δεν απέδωσε πολύ καλά. Το συμπέρασμα ήταν ότι οι πολλές (26) εισοδοί θα μπορούσαν να έχουν συγχύσει τον δίκτυο, επιβραδύνοντας έτσι τη διαδικασία εκμάθησης. Μερικές φορές το δίκτυο παρήγαγε αποτελέσματα μόνο 55% 1°C ακρίβεια για τριώρες προβλέψεις. Γενικά, για ένα σύστημα θερμοκρασίας που

θεωρείται αποδεκτό, πρέπει να βρει τιμές με 1°C ακρίβεια, σε 70% των περιπτώσεων, όπως καθορίζεται από το διεθνή οργανισμό πολιτικής αεροπορίας (ICAO).

Ο Bennett έπειτα συνεχίζει με τη μείωση του αριθμού των εισόδων σε 14, δίνοντας ένα δίκτυο 14:n:l. Από τις αρχικές παραμέτρους εισόδου, εκείνες που αφήνονται είναι οι εξής: ημέρα, ώρα, θερμοκρασία ξηρών βολβών dry bulb (το είδος θερμοκρασίας που παίρνει κάποιος με ένα κανονικό, ξηρό θερμομέτρο), πίεση, ταχύτητα αέρα και κατεύθυνση αέρα.

Μια πρώτη δοκιμή με ένα δίκτυο 14:14:1 έδωσε πραγματικά τα χειρότερα αποτελέσματα για π.χ. οι τρίωρες προβλέψεις, αλλά ο Bennett επέμεινε ακόμα στην κράτηση της αρχιτεκτονικής 14:n:l.

Ένα απόσπασμα από τα αποτελέσματα αυτού του δικτύου παρουσιάζεται παρακάτω: tt0230 (δίκτυο 14:14:1, $\eta = 0,1$, ορμή = 0,5, 900.000 παρουσιάσεις)

forecast hour	% within tolerance
0	98
1	63
2	57
3	54
4	41
5	44
6	41
7	38
8	39
9	38

Προφανώς, αυτά τα αποτελέσματα δεν είναι συντριπτικά εξετάζοντας τις πολλές παρουσιάσεις (900 000), έτσι υπάρχουν ακόμα περισσότερες βελτιώσεις για να γίνουν.

Ο Bennett έπειτα αυξάνει το ρυθμό εκμάθησης για το δίκτυο, αλλά δεν διευκρινίζει το πόσο. Το προκύπτον δίκτυο επιτυγχάνει ακρίβεια 73% για μια μονόωρη πρόβλεψη και 54% για μια τρίωρη πρόβλεψη. Αυτό σημαίνει ότι η μονόωρη πρόβλεψη είναι μέσα στις απαιτήσεις της ICAO.

Θέλοντας να βελτιώσει τα αποτελέσματα περαιτέρω, υιοθετείται μια προσέγγιση όπου εξετάζονται μόνο τα μέρη του συνόλου δεδομένων - μια εποχή, σε αντίθεση με ολόκληρο το σύνολο δεδομένων. Τα αποτελέσματα αυτής της προσέγγισης (χρησιμοποιώντας δεδομένα για τους χειμώνες, δηλ. οι τρεις μήνες του Δεκεμβρίου, Ιανουαρίου και Φεβρουαρίου) βελτίωσαν τα αποτελέσματα αρκετά. Η τρίωρη πρόβλεψη φθάνει σε ακρίβεια 63%, η δίωρη πρόβλεψη φθάνει σε 68%, και η μονόωρη πρόβλεψη φθάνει σε 79%.

Σημείωση: Αυτή είναι μια σημαντική παρατήρηση. Φαίνεται ότι θα υπήρχε μια ανάγκη για τη χρησιμοποίηση διαφόρων διαφορετικών δικτύων εκπαιδευόμενα σε μια εποχή κάθε ένα για να κερδίσει πραγματικά καλά αποτελέσματα.

Εμπνευσμένος από αυτά τα αποτελέσματα, ο Bennett αποφάσισε να εστιάσει στις τρίωρες προβλέψεις, δεδομένου ότι φάνηκε να είναι ένας λογικός χρόνος πρόβλεψης, και προσιτό για το νευρωνικό δίκτυο πρόβλεψης του καιρού.

Σε αυτή τη φάση, τροποποιήθηκε και αξιολογήθηκε το μέγεθος του κρυμμένου στρώματος. Η έκβαση αυτού ήταν ότι το δίκτυο με το μικρότερο κρυμμένο στρώμα τα πήγε καλύτερα από τα μεγαλύτερα. Δυστυχώς, ο Bennett δεν δείχνει ρητά το μέγεθος του κρυμμένου στρώματος (αλλά πιθανώς έχει 3 κρυμμένους κόμβους).

Τα καλύτερα αποτελέσματα που χρησιμοποιούν αυτήν την απλή προσέγγιση ήταν με ένα δίκτυο 14:3:1 που κατόρθωσε να φθάσει σε ακρίβεια 65%. Ο Bennett αναφέρει ότι τα αποτελέσματα θα μπορούσαν πιθανώς να είναι καλύτερα χρησιμοποιώντας περισσότερες εισόδους.

Σημείωση: Αυτό το συμπέρασμα υπενθυμίζει αυτό που έχει ειπωθεί και πιο πάνω, ότι το δίκτυο πρέπει να είναι σε θέση να αποδώσει καλύτερα εάν μπορεί "να δει" τις τάσεις του καιρού εγκαίρως πολύ πιο πριν.

Σε μια τελευταία προσπάθεια να πειραματιστεί ακόμη περισσότερο, ο Bennett προσθέτει το σημείο δροσιάς, τη σχετική υγρασία και ακόμη μερικές ηλιακές τιμές δεδομένων (ακτινοβολία) ως εισόδους, αλλά παρατηρεί ότι αυτό δεν κάνει το δίκτυο να επιτύχει τα υψηλότερα ποσοστά ακρίβειας.

Φαίνεται λοιπόν ότι το κανονικό, feed-forward νευρωνικό δίκτυο απαιτεί πολλά καιρικά δείγματα κατά τη διάρκεια της κατάρτισης προκειμένου να αποδώσει καλά όταν χρησιμοποιηθεί. Αυτό είναι ένα κοινό μειονέκτημα των νευρωνικών δικτύων, αλλά σκεφτόμενοι ότι η δικτυακή αρχιτεκτονική δεν είναι πολύ εξωτική, και ότι τα καιρικά δεδομένα δεν είναι δύσκολο να βρεθούν, αυτό είναι οπωσδήποτε αποδεκτό.

Επίσης, πρέπει να σημειώσουμε ότι τα δεδομένα εισόδου είναι μόνο τοπικά καιρικά δεδομένα από μια τοποθεσία. Το νευρωνικό δίκτυο πιθανώς θα είχε καλύτερα αποτελέσματα εάν θα μπορούσε να αποκτήσει κάποια γνώση για τις περιβάλλουσες καιρικές συνθήκες (αφού είναι γνωστό ότι οι καιρικές συνθήκες σε μια τοποθεσία έχουν επιπτώσεις στις καιρικές συνθήκες μιας άλλης).

Πρόβλεψη βροχής

Παρακάτω ακολουθεί μια σύντομη ματιά στα πειράματα του David Rogers με τη γενετική μνήμη για να προβλέψει τη βροχή σε μια Αυστραλιανή τοποθεσία.

Όπως αναφέρεται νωρίτερα, αυτός ο συνδυασμός αραιής διανεμημένης μνήμης (SDM) και γενετικών αλγορίθμων επιτρέπουν στο δίκτυο να υπολογίσει ποιος βαθμός σπουδαιότητας έχει κάθε μια από τις εισόδους.

Ο Rogers αποθήκευσε 50.000 καιρικά δείγματα (που αρχικά ελήφθησαν κάθε τέταρτη ώρα για 20 έτη) στη γενετική μνήμη παρουσιάζοντάς τα σε χρονολογική σειρά, και δοκίμασε έπειτα τη γενετική μνήμη ενάντια σε μια κανονική αραιή διανεμημένη μνήμη σε 1000 καιρικά δείγματα που κανένα από αυτά δεν είχε αντιμετωπίσει πριν.

(Περίπου 90% των καιρικών δειγμάτων ήταν τέτοια που δεν έβρεξε μέσα στις επόμενες 4 ώρες και περίπου 10% ήταν τέτοια που έβρεξε μέσα στις επόμενες 4 ώρες.)

Τα αποτελέσματα ήταν ενθαρρυντικά. Η γενετική μνήμη είχε 50% λιγότερα λάθη από την αραιή διανεμημένη μνήμη! Επίσης, δεδομένου ότι και η αραιή διανεμημένη μνήμη και οι γενετικοί αλγόριθμοι είναι ιδανικά για τις υψηλές-διαστατικές περιοχές και η γενετική μνήμη είναι ένας συνδυασμός αυτών των δύο, προκύπτει ότι η γενετική μνήμη θα τα πήγαινε καλά με τις υψηλές-διαστατικές περιοχές.

Στο παράδειγμα του Rogers, η γενετική μνήμη είχε διαπιστώσει ότι ο Ιανουάριος και ο Φεβρουάριος ήταν οι πιο επιθυμητοί μήνες για τη βροχή, ενώ ο Ιούλιος και ο Αύγουστος ήταν λιγότερο.

Επιπλέον, διαπίστωσε ότι η χαμηλή πίεση, η υψηλή κάλυψη από σύννεφα και η χαμηλή θερμοκρασία προτιμήθηκαν από τη γενετική μνήμη για αυτήν τη συγκεκριμένη Αυστραλιανή τοποθεσία. Το γεγονός εάν έβρεξε ή όχι κατά τη διάρκεια των προηγούμενων 4 ωρών δεν θεωρήθηκε πολύ σημαντικό.

Τελικά, το πρόγραμμα του Rogers αποδείχθηκε επιτυχές, και ένα καλό παράδειγμα του τι μπορεί να γίνει με τα νευρωνικά δίκτυα στην καιρική πρόβλεψη.

Ποιο είναι το ανώτερο όριο του τι μπορεί ένα νευρωνικό δίκτυο να κάνει στην πρόβλεψη του καιρού;

Δεν υπάρχει κανένα πραγματικό όριο για το πόσο μεγάλα δίκτυα μπορούμε να καταστήσουμε, ούτε υπάρχει ένα συγκεκριμένο όριο για το πόσο ακριβή μπορούν αυτά να είναι. Το πρόβλημα με τα νευρωνικά δίκτυα είναι μάλλον ότι είναι σχετικά άγνωστα στους ανθρώπους γενικά. Ένας πρώτος θεατής έχει πιθανώς μια πολύ μικρή πιθανότητα να καταλάβει πώς το δίκτυο κάνει τις προβλέψεις του. Αυτό τους κάνει δύσκολο να τα εμπιστευτούν προτού να εξοικειωθούν μαζί τους, και γι' αυτό πιθανώς δεν έχει κανένας τολμήσει ακόμα να χρηματοδοτήσει ένα πείραμα μεγάλης κλίμακας.

Συμπεράσματα

Όπως βλέπουμε τα νευρωνικά δίκτυα στην καιρική πρόβλεψη είναι ακόμα σε ένα πειραματικό στάδιο. Έχουν γίνει μερικές προσπάθειες να ερευνηθούν πόσο καλά τα ANN εκτελούν, και μερικές επιχειρήσεις τα ενσωματώνουν στα προϊόντα τους για να κάνουν φαινομενικά βραβευμένα προϊόντα που πρέπει να είναι σε θέση να προβλέψουν σχεδόν τα πάντα.

Όπως αποδεικνύεται, οι παράμετροι εισόδου είναι μεγάλης σπουδαιότητας (στις περισσότερες περιπτώσεις), και μπορεί να είναι περίπλοκο να αποφασιστεί τι να περιλαμβάνουν και τι όχι. Μερικές δικτυακές αρχιτεκτονικές μπορούν να το αντιμετωπίσουν αυτό από μόνες τους, αλλά συχνά πρέπει να κάνουμε μια καλά εκπαιδευμένη εικασία για να μην συγχύσουμε το δίκτυο πάρα πολύ.

Η κοινότητα της επιστήμης φαίνεται να κάνει μερικές τουλάχιστον σοβαρές προσπάθειες να χρησιμοποιήσει τα νευρωνικά δίκτυα για την καιρική πρόβλεψη (μεταξύ άλλων για την πρόβλεψη του διαστημικού καιρού), αλλά είναι ακόμα δύσκολο να βρεθεί το καλό υλικό σε αυτό το θέμα.

Τα μετεωρολογικά ιδρύματα, όπως η SMHI, φαίνονται να στηρίζονται συνήθως στα μαθηματικά πρότυπα που δεν περιλαμβάνουν τα νευρωνικά δίκτυα, κάτι το οποίο είναι λίγο λυπηρό. Ενδεχομένως μια αυξανόμενη συνεργασία μεταξύ της κοινότητας της επιστήμης και των μετεωρολογικών ιδρυμάτων θα μπορούσε να αλλάξει την τωρινή κατάσταση στο μέλλον.

Πρόβλεψη Καιρού με το ADALINE

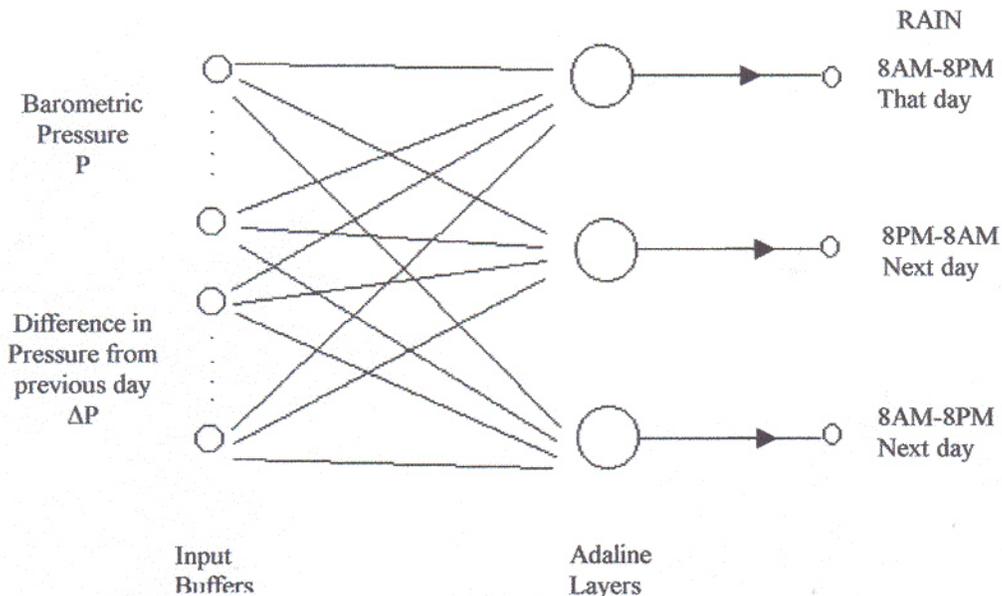
ADALINE = Adaptive Linear Element

Χρησιμοποιεί γραμμική κωδικοποίηση μετατόπισης για P & ΔP.

<u>P</u>	<u>Κωδικός Εισόδου</u>
P<29	1 1 1 1 1
29<P<30	1 1 1 1 0
30<P<31	1 1 1 0 0
31<P<32	1 1 0 0 0
κ.τ.λ	

Εκμάθηση : συγκεντρώνονται δεδομένα μέσα σε 33 ημέρες και χρησιμοποιούνται για την εκπαίδευση του δικτύου.

Αποτέλεσμα : το ποσοστό πρόγνωσης ήταν τόσο καλό όσο και οι περισσότερες καιρικές προβλέψεις.



4.8 Τα νευρωνικά δίκτυα στην Ιατρική

Τα τεχνητά νευρωνικά δίκτυα είναι αυτήν την περίοδο ένας "καυτός" ερευνητικός τομέας στην ιατρική και θεωρείται ότι θα λάβουν εκτενή εφαρμογή στα βιοϊατρικά συστήματα (biomedical systems) στα επόμενα χρόνια. Προς το παρόν, η έρευνα είναι συνήθως στη διαμόρφωση τμημάτων του ανθρώπινου σώματος και την αναγνώριση ασθενειών από διάφορες ανιχνεύσεις (π.χ. καρδιογραφήματα, υπέρηχους, κ.λ.π.).

Τα νευρωνικά δίκτυα είναι ιδανικά στην αναγνώριση ασθενειών με τη χρησιμοποίηση ανιχνύσεων δεδομένου ότι δεν υπάρχει καμία ανάγκη να παρασχεθεί ένας

συγκεκριμένος αλγόριθμος στο πώς να προσδιοριστεί η ασθένεια. Τα νευρωνικά δίκτυα μαθαίνουν από το παράδειγμα έτσι οι λεπτομέρειες για το πώς να αναγνωρίσουν την ασθένεια δεν απαιτούνται. Αυτό που απαιτείται είναι ένα σύνολο παραδειγμάτων τα οποία είναι αντιπροσωπευτικά όλων των παραλλαγών της ασθένειας. Τα παραδείγματα πρέπει να επιλεγούν πολύ προσεκτικά ώστε το σύστημα να αποδώσει σοβαρά και αποτελεσματικά.

Ταξινόμηση Ιατρικών Εικόνων

Εδώ περιλαμβάνονται εξειδικευμένα ιατρικά τεστ όπου π.χ. η παρουσία ή η απουσία κάποιας χημικής αντίδρασης διαφοροποιεί την ιατρική εικόνα δίνοντας θετικό ή αρνητικό αποτέλεσμα στο τεστ.

Ο διαχωρισμός φυσιολογικών και παθολογικών κυττάρων που γίνεται από την εικόνα που λαμβάνεται με μικροσκόπιο, είναι μια άλλη εφαρμογή. Η αυτοματοποίηση αυτής της εργασίας είναι ιδιαίτερα δύσκολη διότι πρέπει να ληφθούν υπόψιν μια σειρά από παραμέτρους όπως το σχήμα, το χρώμα, οι υποπεριοχές των κυττάρων κλπ.

Ως παράδειγμα θα εξετάσουμε το κακοήθους μελάνωμα του δέρματος (Malignant Melanoma MM), το οποίο είναι ο πιο επικίνδυνος τύπος καρκίνου του δέρματος. Το μελάνωμα μπορεί, αν διαγνωστεί έγκαιρα, να αντιμετωπιστεί επιτυχώς και να θεραπευτεί. Η διάγνωση είναι μια δύσκολη εργασία διότι τα ίδια χαρακτηριστικά με το μελάνωμα έχουν και άλλες παθήσεις του δέρματος. Για τον σκοπό αυτό, συνήθως, γίνεται βιοψία με ότι αυτό συνεπάγεται (κόστος, νοσηρότητα).

Εναλλακτικά χρησιμοποιούνται έγχρωμες εικόνες του όγκου του δέρματος από τις οποίες ένα ΤΝΔ διακρίνει το μελάνωμα από τρεις καλοήθεις χρωματισμένους όγκους (dysplastic nevi, intradermal nevi, seborrheic keratoses). Τα χαρακτηριστικά διάκρισης βασίζονται στο σχήμα και στο χρώμα του όγκου.

Το κακοήθους μελάνωμα πήρε το όνομα του από τα μελανοκύτταρα (melanocyte), κύτταρα από τα οποία ενδεχομένως προέρχεται. Τα μελανοκύτταρα είναι τα κύτταρα του δέρματος τα οποία παράγουν χρωστική ουσία μελανίνη η οποία είναι ένα φυσικό φίλτρο των ακτίνων του ηλίου. Τα χαρακτηριστικά του κακοήθους μελανώματος, όπως τα περιέγραψε ο Friedman είναι:

- Ασυμμετρία : το ένα μισό του όγκου είναι διαφορετικό από το άλλο μισό.
- Ακανόνιστα όρια : τα όρια είναι ασαφή με αιχμές και γωνίες.
- Χρώμα : ο φυσικός χρωματισμός των ιστών είναι ανομοιόμορφος. Υπάρχουν ίχνη από σοκολατί, καφέ και μαύρο χρώμα. Επίσης στην εικόνα υπάρχουν κόκκινες, άσπρες και μπλε πιτσιλιές.
- Διάμετρος : μεγαλύτερη από 6mm, αυξανόμενη συνεχώς.

Επειδή τα φυσικά χαρακτηριστικά των τριών ακολουθιών διαφέρουν ελάχιστα από αυτά του κακοήθους μελανώματος, για να επιτευχθεί μια αυτοματοποιημένη προσέγγιση στη διάγνωση του μελανώματος πρέπει να χρησιμοποιηθούν πολλές διαφορετικές εικόνες. Έτσι, συγκεντρώθηκαν 326 ψηφοποιημένες εικόνες εξογκωμάτων του δέρματος (136 μελανώματα., 47dys.nevi, 87idn, 56sk), από όπου φάνηκε ότι υπάρχει μεγάλη συσχέτιση των δεικτών ασυμμετρίας και των ακανόνιστων ορίων με την διάγνωση του μελανώματος. Ωστόσο αυτοί οι δείκτες από μόνοι τους δεν επαρκούν για την ακριβή

διάγνωση, διότι αρκετοί καλοήθεις όγκοι έχουν εξίσου υψηλές τιμές. Εκείνο που χρειάζεται είναι ένας κατάλληλος συνδυασμός παρόμοιων χαρακτηριστικών.

Στην συγκεκριμένη εφαρμογή χρησιμοποιήθηκε το TNΔ BP (Back-Propagation). Ακόμη καθορίστηκαν 14 χαρακτηριστικά (12 για το χρώμα της εικόνας και από ένα για τους δείκτες ασυμμετρίας και ακανόνιστων όρων) τα οποία θεωρήθηκε ότι μπορούν να ταξινομήσουν τις εικόνες στις κατηγορίες κακοήθους μελανώματος ή καλοηθών όγκων. Με αυτά τα χαρακτηριστικά έγινε ανίχνευση του ορίου του όγκου στις εικόνες. Επειδή η αυτοματοποιημένη αναζήτηση των ορίων παρουσίαζε ποσοστό επιτυχίας 80%, τα όρια ανιχνεύονταν με το χέρι από δερματολόγους. Στην συνέχεια υπολογίζονταν οι δείκτες που σχετίζονται με κάθε χαρακτηριστικό. Όπως αναφέρθηκε τα περισσότερα μελανώματα έχουν ακανόνιστο σχήμα. Ακόμη βρέθηκε ότι τα 88% των μελανωμάτων έχουν ποσοστό ασυμμετρίας μεγαλύτερο από 8% ενώ για τις κατηγορίες *idn*, *sk*, και *dys.nevi* το ποσοστό αυτό φτάνει στο 47%, 62%, και 55% των περιπτώσεων.

Ένα από τα σημαντικότερα χαρακτηριστικά των εικόνων ήταν ο διαφοροποιημένος χρωματισμός (*variegated coloring VC*). Το VC ορίζεται από τους δερματολόγους ως ανάμειξη σοκολατί, καφέ, κόκκινου και μαύρου χρώματος που δίνει στον όγκο διάφορους χρωματισμούς. Αυτή η ποικιλοχρωμία σημαίνει μεγάλες διαφορές στην αναλογία των βασικών χρωμάτων μιας εικόνας RGB (κόκκινο (R), πράσινο(α), και μπλε(B)). Σκοπός είναι να μετρηθεί το χρώμα του όγκου σε σχέση με το χρώμα του δέρματος που τον περιβάλλει. Έτσι, 3 χαρακτηριστικά αποτελούν την μεταβλητότητα των R, G, B συνιστωσών των έγχρωμων εικόνων και 3 χαρακτηριστικά αποτελούν τον σχετικό χρωματισμό των όγκων. Ακόμη επειδή έχει αποδειχθεί ότι ο μετασχηματισμός της RGB εικόνας σε σφαιρικές συντεταγμένες (δύο γωνίες και η ένταση-φωτεινότητα) δίνει καλύτερη διάγνωση, συμπεριλήφθηκαν 3 χαρακτηριστικά για τις σφαιρικές συντεταγμένες και 3 για τις έγχρωμες συντεταγμένες.

Στο πρώτο πείραμα η διαμόρφωση του TNΔ περιλάμβανε 14 TN εισόδου, 7 TN στο κρυφό επίπεδο και 1 TN στο επίπεδο εξόδου. Σε αυτή την περίπτωση έγινε διάκριση:

- μεταξύ των τεσσάρων κατηγοριών και
- απομακρύνθηκαν τα διανύσματα της κατηγορίας *dys.nevi*.

Για την εκπαίδευση και τον έλεγχο των TNΔ χρησιμοποιήθηκαν 240 και 216 εικόνες αντίστοιχα. Από εδώ προέκυψε ότι η εξάλειψη των εικόνων *dys.nevi* διευκόλυne την ταξινόμηση και περιόρισε τον αριθμό των λανθασμένων αρνητικών (τα μελανώματα που διαγνώστηκαν ως κακοήθεις όγκοι).

Στο δεύτερο πείραμα υπήρχαν 8 TN στο επίπεδο εισόδου, 4 στο κρυφό επίπεδο, και 1 στο επίπεδο εξόδου. Εδώ στόχος ήταν η εξέταση της επίδρασης των διαφόρων τύπων φωτογραφικού φιλμ που χρησιμοποιήθηκαν για την φωτογράφιση. Έτσι από τα 14 χαρακτηριστικά κρατήθηκαν μόνο τα 8 και συγκεκριμένα οι 3 μεταβλητότητες των R, G, B εγχρωμών εικόνων, τα 3 χαρακτηριστικά του σχετικού χρωματισμού των όγκων και οι δείκτες ασυμμετρίας και ακανόνιστων ορίων.

Έτσι προέκυψε ότι η χρήση των απόλυτων χαρακτηριστικών χρώματος (σφαιρικές συντεταγμένες και έγχρωμες συντεταγμένες), μείωσε σημαντικά τον αριθμό των λανθασμένων αρνητικών αλλά όχι ιδιαίτερα τον αριθμό των λανθασμένων θετικών. Ωστόσο δεν είναι ξεκάθαρο αν τα υπόλοιπα χαρακτηριστικά χρώματος τα οποία βελτιώνουν την ακρίβεια ταξινόμησης, προέρχονται από τον χρωματισμό των όγκων ή

αν προκύπτουν από την διαφορά της ισορροπίας των χρωμάτων των διαφορετικών τόπων φιλμ.

Συμπερασματικά μπορούμε να πούμε ότι τα χαρακτηριστικά του χρώματος των όγκων παίζουν κύριο ρόλο στη διάγνωση, η ασυμμετρία των όγκων και η αταξία των ορίων τους είναι δύο σημαντικά χαρακτηριστικά για την διάκριση του MM και των dys.nevi παρουσιάζουν αρκετές ομοιότητες και επομένως η εξέταση της κακοήθειας, απόντων των dys.nevi, οδηγεί σε καλύτερη διάγνωση.

Η ιατρική εικόνα, όπως είναι το MRI (Magnetic Resonance Imaging), το CT (Computer Tomography), το PET (Positron Emission Tomography) ή οι ακτίνες X, αποτελεί πολύτιμο διαγνωστικό εργαλείο στα χέρια του γιατρού. Επειδή η ποσοτική ανάλυση των εικόνων με χειρονακτικές μεθόδους είναι ανέφικτη απαιτείται κάποιος είδος αυτοματοποίησης της ανάλυσης.

Οι κλασσικοί ταξινομητές μέγιστης πιθανότητας (MLC - Maximum Likelihood Classifiers), χρησιμοποιούνται για τμηματοποίηση (segmentation), δεν λαμβάνουν υπόψη την πολυδιάστατη φύση των δεδομένων του MRI. Η τμηματοποίηση των εικόνων MRI μπορεί να γίνει με τεχνικές αναγνώρισης προτύπων με εποπτεία. Συνήθως ο χρήστης επιλέγει έναν μικρό αριθμό αντιπροσωπευτικών δειγμάτων για τις επιθυμητές κατηγορίες ιστών, το TND εκπαιδεύεται με αυτά τα σημεία και οι εικόνες ταξινομούνται. Στην συνέχεια ο χρήστης βλέπει τις ταξινομημένες εικόνες και επιλέγει τα σημεία που έχουν ταξινομηθεί λανθασμένα. Αυτά τα σημεία προστίθενται στο σύνολο εκπαίδευσης, και το TND εκπαιδεύεται ξανά. Αυτή η διαδικασία συνεχίζεται μέχρι να επιτευχθεί μια ικανοποιητική τμηματοποίηση. Δυστυχώς η πλήρως αυτοματοποιημένη ανάλυση είναι ανέφικτη.

Το πλεονέκτημα των TND σε σχέση με τους MLC είναι ότι δεν βασίζονται στον υπολογισμό της συνάρτησης πυκνότητας και πιθανότητας και επομένως δίνουν καλύτερα αποτελέσματα, όταν τα δεδομένα παρουσιάζουν μεγάλες αποκλίσεις. Οι εικόνες MRI που χρησιμοποιήθηκαν για την εκπαίδευση και τον έλεγχο ήταν οι τυποποιημένες T1 (spin-lattice relaxation time), T2 (spin-spin relaxation time) και η πυκνότητα πρωτονίων PD (positron density).

Τα TND που χρησιμοποιήθηκαν αποτελούνταν από ένα επίπεδο εισόδου, ένα ή δύο κρυφά επίπεδα (0-20TN) και ένα επίπεδο εξόδου. Η εκπαίδευση πραγματοποιήθηκε με τον BP (χωρίς παράγοντα ορμής και με ρυθμό εκπαίδευσης ένα). Κάθε διάνυσμα εισόδου εκπροσωπούσε ένα pixel και αποτελούνταν από κανονικοποιημένες τιμές της έντασης του pixel (φωτεινότητας), μια για κάθε εικόνα που χρησιμοποιήθηκε (T1, T2, PD, και CT). Ο αριθμός των TN του επιπέδου εξόδου ήταν ίσος με τον αριθμό των κατηγοριών των ιστών(7): φόντο, CSF, λευκή ουσία, φαιά ουσία, όγκος (όταν υπήρχε), κranίο (οστό και μυελός των οστών) και τριχωτό της κεφαλής (λίπος και δέρμα). Μετά την εκπαίδευση οι πρότυπες εικόνες μπορεί να τμηματοποιηθούν και να κατασκευαστούν έγχρωμες εικόνες.

Η ποιότητα των τμηματοποιημένων εικόνων που κατασκευάστηκαν με TND ήταν σαφώς ανώτερη από αυτές που κατασκευάστηκαν με MLC (εμφάνιζαν λιγότερο θόρυβο) και επιπλέον δεν επηρεάζονταν από την επιλογή του συνόλου εκπαίδευσης (μικρό ή μεγάλο). Τέλος από τα πειράματα και τις σχετικές παρατηρήσεις διαπιστώθηκε ότι και οι τρεις εικόνες MRI ήταν χρήσιμες για την τμηματοποίηση των μαλακών ιστών, ενώ η εικόνα

CT βοηθούσε στην τμηματοποίηση του οστού και βελτίωνε τον διαχωρισμό της λευκής από την φαιά ουσία.

Η ευρωστία των ΤΝΔ έχει ιδιαίτερη σημασία επειδή δεν απαιτείται προσεκτική επιλογή του συνόλου εκπαίδευσης από κάποιον χρήστη. Επίσης η ικανότητα γενίκευσης των ΤΝΔ προσφέρει αποδεκτές τμηματοποιήσεις με μικρό σύνολο εκπαίδευσης από κάποιον χρήστη. Επίσης η ικανότητα γενίκευσης των ΤΝΔ προσφέρει αποδεκτές τμηματοποιήσεις με μικρό σύνολο εκπαίδευσης, μια ιδιότητα σημαντική όταν η επιλογή μεγάλων συνόλων εκπαίδευσης είναι δύσκολη. Αυτή η ιδιότητα επέτρεψε την ανάπτυξη ενός προσαρμοζόμενου σχεδίου εκπαίδευσης των ΤΝΔ για την τμηματοποίηση του όγκου της εικόνας (volume). Δυστυχώς ένας ταξινομητής εκπαιδευόμενος να ξεχωρίζει την λευκή από την φαιά ουσία π.χ. στην πρώτη εικόνα δεν δουλεύει εξίσου καλά π.χ., στην δέκατη εικόνα, επειδή οι περιοχές έντασης των δύο αυτών ιστών παρουσιάζουν μεγάλη επικάλυψη σε διαδοχικές εικόνες.

Για την επίλυση αυτού του προβλήματος καθορίστηκαν «περιοχές ενδιαφέροντος» (Regions Of Interest-ROI) σε κάποια εικόνα και το δίκτυο εκπαιδεύτηκε με αυτές. Στην συνέχεια ταξινομήθηκε η αμέσως επόμενη επάνω ή κάτω εικόνα χρησιμοποιώντας το εκπαιδευόμενο ΤΝΔ. Όλα τα pixels που ταξινομήθηκαν στην ίδια κατηγορία και στις δύο εικόνες, επιλέχθηκαν για να σχηματίσουν το σύνολο εκπαίδευσης της επάνω ή κάτω εικόνας. Τέλος το ΤΝΔ επανεκπαιδεύτηκε χρησιμοποιώντας το νέο σύνολο εκπαίδευσης. Ακόμη έγινε σύγκριση των περιγραμμάτων των όγκων που σκιαγραφήθηκαν από ειδικούς, με αυτά που ανιχνεύτηκαν από το αυτοματοποιημένο σύστημα. Για τον σκοπό αυτό χρησιμοποιήθηκαν 12 εικόνες από ασθενείς που είχαν όγκο στον εγκέφαλο (MRI και CT εικόνες). Οι ROI σχεδιάστηκαν σε μια εικόνα από κάθε ασθενή και οι ταξινομητές (ΤΝΔ και ΜLC) εκπαιδεύτηκαν με αυτές τις ROI, από έναν για κάθε ασθενή. Κάθε ROI περιλαμβάνει pixels και από τις 7 κατηγορίες ταξινόμησης.

Συμπερασματικά, η χρήση των ΤΝΔ είναι μια υποσχόμενη μέθοδος για την ταξινόμηση ιατρικών εικόνων. Το μεγαλύτερο πλεονέκτημα είναι η αναισθησία στη επιλογή του συνόλου εκπαίδευσης, τόσο για την ταξινόμηση απλών όσο και για την ταξινόμηση πολλαπλών εικόνων.

Διαμόρφωση και διάγνωση καρδιαγγειακού συστήματος

Τα νευρωνικά δίκτυα χρησιμοποιούνται πειραματικά για να διαμορφώσουν το ανθρώπινο καρδιαγγειακό σύστημα. Η διάγνωση μπορεί να επιτευχθεί με την οικοδόμηση ενός προτύπου του καρδιαγγειακού συστήματος ενός ατόμου και με τη σύγκρισή του με τις φυσιολογικές μετρήσεις σε πραγματικό χρόνο που λαμβάνονται από τον ασθενή. Εάν αυτή η ρουτίνα πραγματοποιείται τακτικά, οι πιθανές επιβλαβείς ιατρικές καταστάσεις μπορούν να ανιχνευθούν σε ένα αρχικό στάδιο και να είναι έτσι η διαδικασία της καταπολέμησης της ασθένειας πολύ ευκολότερη.

Ένα πρότυπο του καρδιαγγειακού συστήματος ενός ατόμου πρέπει να μιμηθεί τη σχέση μεταξύ των φυσιολογικών μεταβλητών (δηλ. ρυθμός καρδιάς, συστολικές και διαστολικές πιέσεις αίματος, και ρυθμός αναπνοής) σε διαφορετικά επίπεδα σωματικής δραστηριότητας. Εάν ένα πρότυπο προσαρμόζεται σε ένα άτομο, τότε γίνεται ένα πρότυπο της φυσικής κατάστασης αυτού του συγκεκριμένου ατόμου. Ο προσομοιωτής θα πρέπει να είναι σε θέση να προσαρμοστεί στα χαρακτηριστικά γνωρίσματα

οποιοδήποτε άτομο χωρίς την επίβλεψη ενός εμπειρογνώμονα. Αυτό απαιτεί ένα νευρωνικό δίκτυο.

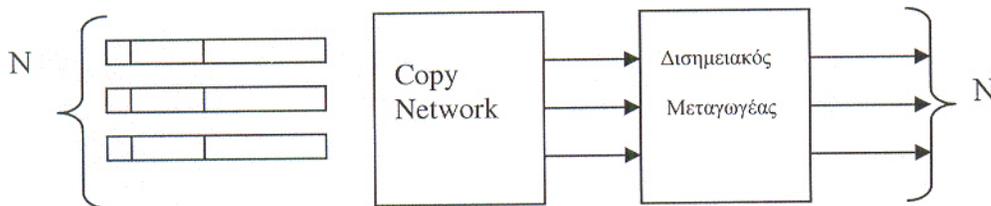
Ένας άλλος λόγος που δικαιολογεί τη χρήση της τεχνολογίας των ΤΝΔ, είναι η δυνατότητα τους να παρέχουν συνδυασμό αισθητήρων που είναι ο συνδυασμός των τιμών από διαφορετικούς αισθητήρες. Κάτι τέτοιο επιτρέπει στα ΤΝΔ να μάθουν σύνθετες σχέσεις μεταξύ των μεμονωμένων τιμών των αισθητήρων, οι οποίες σε αντίθετη περίπτωση θα χάνονταν εάν οι τιμές αναλύονταν χωριστά. Στις ιατρικές διαμορφώσεις και διαγνώσεις, αυτό υπονοεί ότι ακόμα κι αν κάθε αισθητήρας σε ένα σύνολο μπορεί να είναι ευαίσθητος μόνο σε μια συγκεκριμένη φυσιολογική μεταβλητή, τα ΤΝΔ είναι σε θέση να εντοπίσουν τις σύνθετες ιατρικές καταστάσεις συγχωνεύοντας τα δεδομένα από τους μεμονωμένους βιοϊατρικούς αισθητήρες.

4.9 Πολυδιανεσόμενη μεταγωγή σε δίκτυα ATM με γρήση ΝΑ Hopfield

Το παγκόσμιο δίκτυο επικοινωνίας τείνει σήμερα να αντικατασταθεί με ένα προηγμένο ψηφιακό σύστημα που ονομάζεται Broadband Integrated Services Digital Network (B-ISDN). Μια κατάλληλη τεχνολογία για το B-ISDN είναι ο σύγχρονος τρόπος μετάδοσης (Asynchronous Transfer Mode ATM), στον οποίο η πληροφορία τεμαχίζεται σε πακέτα σταθερού μικρού μεγέθους που ονομάζονται cells. Αυτή η τεχνική πραγματοποιεί αποτελεσματική αξιοποίηση των πόρων του δικτύου (Network resources), ενώ παράλληλα διατηρεί αμείωτη την ποιότητα των υπηρεσιών για διάφορες εφαρμογές.

Τα νευρωνικά δίκτυα μπορούν να συμβάλουν στη σημερινή δομή των δικτύων επικοινωνίας, παρέχοντας γρήγορο ευέλικτο, προσαρμόσιμο και έξυπνο έλεγχο. Στην εφαρμογή αυτή για το πρόβλημα της πολυδιανεσόμενης μεταγωγής (multicast switching) σε δίκτυα ATM χρησιμοποιήθηκε ένα δίκτυο τύπου Hopfield. Με τον όρο πολυδιανεσόμενη ορίζεται η παροχή της πληροφορίας από μια πηγή σε πολλούς επιλεγμένους προορισμούς. Το πρόβλημα αυτό ανήκει αλγοριθμικά και στα συνδυαστικά προβλήματα βελτιστοποίησης, τα οποία αποτελούν υποκατηγορία των NP (No deterministic Polynomial complete problems) που είναι δύσκολα στην αντιμετώπιση τους. Τα συνδυαστικά προβλήματα είναι προβλήματα βελτιστοποίησης διακριτών μεταβλητών. Η κάθε λύση που υπάρχει αντιστοιχεί σε κάποιο κόστος που εκφράζεται με κάποια συνάρτηση. Η βέλτιστη λύση ελαχιστοποιεί τη συνάρτηση κόστους. Με κατάλληλη μοντελοποίηση της συνάρτησης κόστους προκύπτουν πληροφορίες για τα στοιχεία του δικτύου (βάρη, είσοδοι, κ.λ.π.) τα οποία είναι αρκετά για να δώσουν μια ικανοποιητική λύση. Όλο το πρόβλημα έγκειται στο ΝΑ βρεθεί μια τέτοια συνάρτηση.

Ας ξεκινήσουμε με την περιγραφή του προβλήματος. Έχουμε ένα τυπικό πολυδιανεσόμενο μεταγωγέα ATM, ο οποίος αποτελείται από Ν θύρες εισόδου καθεμία από τις οποίες διαθέτει ένα σύστημα ουρών Μ/Γ/Ι. Οι ουρές εισόδου τροφοδοτούν ένα δίκτυο αντιγραφής (copy network). Αυτό το δίκτυο συνδέεται σε σειρά με ένα μη συγκρουόμενο δισημειακό μεταγωγέα (no blocking point-to-point switch).



Σχήμα 4.39: Ένας πολυδιανεσόμενος μεταγωγέας

Σε καθεμία από τις εισόδους διέρχονται πακέτα, τα οποία αρχικά αποθηκεύονται στις ουρές εισόδου μέχρι να τους επιτραπεί η διέλευση μέσω του μεταγωγέα ούτως ώστε να κατευθυνθούν προς τις εξόδους που θα οδηγήσουν στους επιθυμητούς προορισμούς. Καθένα από τα πακέτα μπορεί να κατευθύνεται σε μια ή περισσότερες εξόδους. Όταν το πακέτο φτάσει στην πρώτη θέση της ουράς όπου αποθηκεύτηκε, παράγονται αντίγραφα του, τόσο όσες είναι οι εξόδους για τις οποίες προορίζεται. Η πληροφορία που αναφέρει σε πόσες και σε ποιες εξόδους κατευθύνεται ένα πακέτο περιέχεται σε ένα τμήμα της επικεφαλίδας του. Το τμήμα αυτό αποτελείται από μια Ν-άδα από bits. Ν-άδα διότι έχουμε Ν εξόδους. Ένας άσπος στην ι-οστή θέση ($i=1$ έως N) σημαίνει ότι ένα

αντίγραφο του πακέτου πρέπει να μεταφερθεί στην i έξοδο. Το άθροισμα των αντιγράφων ενός πακέτου ισούται με τον αριθμό των άσπων στη N -άδα και ονομάζεται fan out. Για λόγους απλότητας, κάθε πακέτο αναπαρίσταται με την επικεφαλίδα του και όχι με την πλήρη αναπαράσταση των 53 bytes από τα οποία αποτελείται στη πραγματικότητα.

Στην περίπτωση που υπάρχουν τουλάχιστον δυο πακέτα στην πρώτη θέση των ουρών τους δηλαδή, είναι έτοιμα προς μεταφορά μέσω του μεταγωγέα, καθένα εκ των οποίων έχει ένα αντίγραφο που κατευθύνεται στην ίδια έξοδο (ή ισοδύναμα έχουν και τα δύο τον άσσο στην ίδια θέση) λέμε ότι αυτά τα πακέτα ανταγωνίζονται για την ίδια έξοδο ή παρουσιάζουν output connection. Τέτοια cells αποκαλούνται ανταγωνιζόμενα ή συγκρουόμενα (blocking). Ένα παράδειγμα ανταγωνιζόμενων πακέτων είναι τα 10010011 και 00000001. Αν επιτραπεί και στα δύο συγχρόνως η διέλευση τους μέσω του μεταγωγέα θα υπάρξει σύγκρουση κάτι που δεν θέλουμε. Για να αποφευχθεί αυτή η σύγκρουση πρέπει τα πακέτα να διασχίσουν τον μεταγωγέα σε διαφορετικές χρονικές στιγμές.

Αντιθέτως από τα συγκρουόμενα έχουμε και τα μη συγκρουόμενα (non blocking) πακέτα στα οποία δεν εμποδίζει το ένα το άλλο. Τα πακέτα αυτά μπορούν να μεταδοθούν συγχρόνως από τις εισόδους στις εξόδους του μεταγωγέα χωρίς κανένα πρόβλημα. Σκοπός είναι να επιλέξουμε ανάμεσα στα πακέτα που έχουν φτάσει στις πρώτες θέσεις των ουρών και είναι έτοιμα για μετάδοση, μια ομάδα μη συγκρουόμενων πακέτων που είναι όσο το δυνατόν περισσότερα αλλά και τα αντίγραφα τους να καλύπτουν αν είναι δυνατόν και τις N εξόδους του μεταγωγέα. Τότε λέμε ότι έχουμε πλήρες σύνολο αντιγραφών. Αν αυτό δεν είναι εφικτό πρέπει να βρούμε ένα τόσο πληρέστερο σύνολο ώστε το πλήθος των στοιχείων που το αποτελούν να είναι όσο το δυνατόν πιο κοντά στο N .

Στο παρακάτω σχήμα ορίζουμε ως διάνυσμα κίνησης (traffic vector) V ένα διάνυσμα μήκους N αποτελούμενο από άσσους και μηδενικά με έναν τουλάχιστον άσσο στις N θέσεις του.

V1	00000011
V2	01100001
V3	10001100
V4	01000000
V5	00110000
V6	01110000
V7	10001100
-	00000000

Traffic Set

V1	00000011
V3	10001100
V6	01110000

Transmission Set

Διακρίνουμε 7 διανύσματα κίνησης τα $V1$ ως $V7$. Ορίζουμε ως σύνολο κίνησης S (traffic set) το σύνολο από τα διανύσματα που αναπαριστούν τα HOL cell (τα cells που βρίσκονται στο Head-Of-Line, στη πρώτη θέση των ουρών, έτοιμα για αναχώρηση) κάποια χρονική στιγμή. Το σύνολο κίνησης είναι ένα χρονικό στιγμιότυπο που δείχνει τι υπάρχει στην πρώτη θέση καθεμιάς από τις N ουρές εισόδου. Ένα τέτοιο σύνολο 7 διανυσμάτων φαίνεται στο σχήμα. Το γεγονός ότι η τελευταία θέση είναι κενή σημαίνει

ότι στην 8η ουρά εισόδου δεν υπάρχει πακέτο τη συγκεκριμένη χρονική στιγμή. Ως σύνολο μετάδοσης T (transmission set) ορίζουμε ένα υποσύνολο του συνόλου κίνησης, που απαρτίζεται από μη συγκρουόμενα πακέτα και συγκεκριμένα από εκείνα που επελέγησαν τελικά να μεταδοθούν. Έχοντας δεδομένο ένα σύνολο κίνησης το σύνολο μετάδοσης είναι μοναδικό. Άρα πλέον μπορούμε να διατυπώσουμε το ζητούμενο ως εξής: ψάχνουμε να βρούμε μέσα από το σύνολο κίνησης που διαθέτουμε ανά πάσα στιγμή το καλύτερο σύνολο μετάδοσης.

Πολυδιανεμόμενη μεταγωγή

Για την υλοποίηση πολυδιανεμόμενων μεταγωγέων έχουν αναπτυχθεί διάφορες τεχνικές, οι οποίες βασίζονται σε δυο παράγοντες:

- στη χρονική διάρκεια μετάδοσης ενός πακέτου σε χρονοθυρίδες (Time slots) δηλ. μετάδοσης όλων των αντιγράφων του. Ως χρονοθυρίδα ορίζουμε την μονάδα μέτρησης του χρόνου και θεωρούμε ότι είναι η μικρότερη υποδιαίρεση του.
- στη σειρά εξυπηρέτησης των πακέτων που φθάνουν στις ουρές εισόδου του μεταγωγέα.

Το πρόβλημα της πολυδιανεμόμενης μεταγωγής μπορεί να αναχθεί σε ένα κοινό πρόβλημα συνδυαστικού προβλήματος βελτιστοποίησης το οποίο υπόκειται σε κάποιους περιορισμούς. Οι περιορισμοί αυτοί είναι οι εξής:

1. Το σύνολο μετάδοσης πρέπει να αποτελείται υποχρεωτικά από μη συγκρουόμενα διανύσματα κίνησης.
2. Το σύνολο μετάδοσης πρέπει να αποτελείται από όσο το δυνατόν περισσότερα διανύσματα κίνησης.
3. Το σύνολο μετάδοσης πρέπει να προσεγγίζει όσο το δυνατόν περισσότερο ένα πλήρες σύνολο αντιγράφων (άσπων) όσο το δυνατό πιο κοντά στο N .

Αυτοί οι περιορισμοί αργότερα χαλάρωσαν, δεδομένου ότι το παράδειγμα μπορεί να χρησιμοποιήσει μια sigmoid συνάρτηση μεταφοράς για λεπτότερη διάκριση κατηγορίας. Ο ίδιος ο Hopfield έδειξε ότι το προκύπτον δίκτυο είναι ισοδύναμο με το αρχικό δίκτυο που σχεδιάστηκε το 1982.

Βλέπουμε ότι πιο ισχυρός περιορισμός είναι ο πρώτος. Είναι μια συνθήκη που πρέπει να ισχύει οπωσδήποτε για να μην παρουσιαστεί πρόβλημα διαμάχης (output connection). Μόνο σε αυτή την περίπτωση η λύση που θα προκύψει θα είναι δεκτή. Δεν ισχύει ωστόσο τι ίδιο για τους άλλους δυο περιορισμούς. Σε αυτούς αναζητούμε το καλύτερο δυνατό που είναι επιδίωξη και όχι προϋπόθεση, γι αυτό και αυτοί οι περιορισμοί είναι ασθενείς περιορισμοί.

Μπορούμε να δώσουμε προσεγγιστική λύση στο πρόβλημα μας με ένα δίκτυο Hopfield, το οποίο αποτελείται από ένα στρώμα νευρώνων. Αρκεί να υπολογίσουμε στο δίκτυο τα βάρη W_{ij} και τις εισόδους $IN(i)$. Το δίκτυο Hopfield ανήκει στην κατηγορία αναδρομικών (feedback ή recurrent) δικτύων. Αυτά τα δίκτυα έχουν πιο ευρεία εφαρμογή, αλλά δεν είναι εξολοκλήρου ευσταθή όπως τα μη αναδρομικά. Η ευστάθεια ενός τέτοιου δικτύου μπορεί να αποδειχθεί με μια κομψή μαθηματική τεχνική. Ας υποθέσουμε ότι μπορεί να βρεθεί μια συνάρτηση κάτω φραγμένη η οποία πάντοτε ελαττώνεται, κάθε φορά που το δίκτυο αλλάζει κατάσταση. Τελικά η συνάρτηση αυτή

πρέπει να φτάσει σε μια ελάχιστη τιμή και να σταματήσει, επιβεβαιώνοντας την ευστάθεια του συστήματος. Μια τέτοια συνάρτηση ονομάζεται συνάρτηση ενέργειας του δυναμικού συστήματος ή συνάρτηση Lyapunov. Για να είναι λοιπόν ένα νευρωνικό δίκτυο ευσταθές πρέπει να χαρακτηρίζεται από τις εξής ιδιότητες:

- Κάθε αλλαγή κατάστασης του δικτύου οδηγεί σε μείωση της.
- Η συνάρτηση αυτή είναι κάτω φραγμένη
- Όταν η συνάρτηση αυτή αλλάζει πρέπει να αλλάζει κατά πεπερασμένη ποσότητα.

Για το συγκεκριμένο δίκτυο η συνάρτηση αυτή δίνεται από τη σχέση:

$$E = (-1/2) \sum_i \sum_j W_{ij} OUT_i OUT_j - \sum_j I_j OUT_j + \sum_j T_j OUT_j$$

Όπου:

E= η ζητούμενη ενέργεια

W_{ij}= το βάρος από την έξοδο του νευρωνίου j στην είσοδο του νευρωνίου I

OUT_i=η έξοδος του νευρωνίου I

I_i=η εξωτερική είσοδος στο νευρώνιο I

T_i=το κατώφλι του νευρωνίου I

Το διάνυσμα των εξόδων των νευρωνίων αντιστοιχεί στο σύνολο μετάδοσης που τελικά επιλέγει. Αυτό το διάνυσμα θα αποτελείται βέβαια από άσσους και μηδενικά. Άσσος στην ι-οστή θέση (I=1...N) σημαίνει ότι το διάνυσμα κίνησης (δηλαδή το πακέτο) από την ι-οστή είσοδο θα δρομολογηθεί προς την έξοδο ή τις εξόδους που προορίζεται. Ενώ μηδενικό στην ι-οστή θέση σημαίνει ότι το πακέτο της ι-οστής εισόδου μπλοκάρεται (αν υπάρχει cell την ι-οστή είσοδο). Σε κάθε χρονοθυρίδα γίνεται αρχικά η επιλογή του συνόλου μετάδοσης του και κατόπιν πραγματοποιείται η μετάδοση του, ενός της ίδιας χρονοθυρίδας. Βάση των παραπάνω περιορισμών θα σχηματιστεί η συνάρτηση ενέργειας, η οποία θα είναι άθροισμα τριών όρων, ένας όρος για κάθε περιορισμό. Αρχικά θέτουμε στα νευρώνια ένα δείκτη I που αντιστοιχεί στο διάνυσμα κίνησης I όπου i=1 ως N. Αυτό που μας ενδιαφέρει από κάθε νευρώνιο είναι η τιμή της εξόδου V_i.

Ο πρώτος όρος της συνάρτησης ενέργειας προκύπτει από τον πρώτο περιορισμό που όπως είπαμε είναι και ο πιο ισχυρός. Ορίζουμε έναν πίνακα σύνδεσης (connection matrix) H, του οποίου οι διαστάσεις είναι NxN (λόγω των αριθμών εισόδων). Τα στοιχεία του πίνακα H προσδιορίζονται από δύο δείκτες i και j. Κάθε στοιχείο του πίνακα είναι «1» ή «0». Το στοιχείο H_{ij} αναπαριστά τη συνδετικότητα (connectivity) μεταξύ των νευρωνίων i, j που αντιστοιχούν στα διανύσματα κίνησης των θυρών εισόδου i και j (i <> j επειδή δεν έχει νόημα να μιλάμε για συνδετικότητα μεταξύ διαφορετικών νευρωνίων. Οι τιμές των στοιχείων H_{ii} της κύριας διαγωνίου είναι αδιάφορες). Αν τα διανύσματα εισόδου δηλαδή, τα πακέτα HOL των θυρών εισόδου i και j, περιέχουν μία ή περισσότερες κοινές εξόδους (πράγμα που μεταφράζεται στο να έχουμε έναν ή περισσότερους άσσους στην ίδια θέση), τότε H_{ij}=1. Σε διαφορετική περίπτωση H_{ij}=0. Με την βοήθεια του πίνακα H ο πρώτος όρος της συνάρτησης ενέργειας κατασκευάζεται ως εξής:

$$E_1 = A/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N H_{ij} V_i V_j$$

όπου a μια θετική σταθερά. Παρατηρούμε ότι ο όρος E_1 έχει μη μηδενική τιμή, μόνο αν υπάρχουν κάποιο ή κάποια H_{ij} με τιμή 1. Επομένως, αποκτά την ελάχιστη τιμή του (που είναι μηδέν), μόνο αν όλα τα H_{ij} έχουν τιμή 0, πράγμα που μεταφράζεται στο ότι όλα τα πακέτα που επιλέγηκαν είναι μη συγκρουόμενα. Ο δεύτερος όρος της συνάρτησης ενέργειας προκύπτει από τον δεύτερο περιορισμό. Κάθε νευρώνιο i συνοδεύεται από μια εξωτερική παράμετρο J_i . Η J_i παίρνει δύο τιμές: 1 αν στην κεφαλή (HOL) της i -οστής εισόδου υπάρχει κάποιο πακέτο και 0 όταν στην κεφαλή της i -οστής εισόδου δεν υπάρχει. Ο σχετικός όρος κατασκευάζεται ως εξής:

$$E_2 = B/2 \sum_{i=1}^N (J_i - V_i)^2$$

όπου B μια θετική σταθερά. Ο E_2 ελαχιστοποιείται (μηδενίζεται), αν επιλεγούν για δρομολόγηση όλα τα HOL cells. Ωστόσο, 'όλα' σημαίνει τα περισσότερα δυνατόν. Ο τρίτος όρος της συνάρτησης ενέργειας προκύπτει από τον τρίτο περιορισμό. Ορίζουμε την παράμετρο T_i για κάθε νευρώνιο i :

$$T_i = Li/N$$

Όπου Li ο αριθμός των άσων του διανύσματος κίνησης i . Ο σχετικός όρος στη συνάρτηση ενέργειας κατασκευάζεται ως εξής:

$$E_3 = -C \sum_{i=1}^N T_i V_i$$

όπου C μια θετική σταθερά. Ο E_3 ελαχιστοποιείται παίρνοντας την τιμή $-C$, αν τα διανύσματα κίνησης που επελέγησαν συγκροτούν πλήρες σύνολο αντιγράφων. Με βάση τα παραπάνω έχουμε την συνάρτηση:

$$E = E_1 + E_2 + E_3 = A/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N H_{ij} V_i V_j + B/2 \sum_{i=1}^N (J_i - V_i)^2 - C \sum_{i=1}^N T_i V_i$$

Η συνάρτηση αυτή είναι κάτω φραγμένη και πληρεί τις προϋποθέσεις που προαναφέρθηκαν για να χαρακτηριστεί ως συνάρτηση ενέργειας. Στη συνέχεια χρειάζεται να υλοποιήσουμε τις παραμέτρους του νευρωνικού δικτύου Hopfield που θα εφαρμόσουμε τα βάρη των συνδέσεων μεταξύ των νευρώνων καθώς και τις εξωτερικές εισόδους των νευρώνων. Ο υπολογισμός αυτών των παραμέτρων θα επιτευχθεί, αν φέρουμε σε αντιστοιχία τη σχέση με τη γενική μορφή της συνάρτησης ενέργειας που δίδεται από (3,1). Χρησιμοποιώντας νευρώνια με κατώφλι 0, ο τρίτος όρος της (3,1) παραλείπεται και η (3,1) γίνεται ως εξής:

$$E = -1/2 \sum_i \sum_j w_{ij} OUT_i OUT_j - \sum_j I_j OUT_j$$

Η σχέση (3,6) μπορεί να πάρει τη μορφή:

$$E = A/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N H_{ij} V_i V_j + B/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ i=j}}^N J_i J_j + B/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ i=j}}^N V_i V_j - 2 B/2 \sum_{i=1}^N J_i V_i - C \sum_{i=1}^N T_i V_i =$$

$$= (-1/2) \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N (-AH_{ij}) V_i V_j + (-1/2) \sum_{i=1}^N \sum_{\substack{j=1 \\ i=j}}^N (-B)V_i V_j - \sum_{i=1}^N (BJ_i + CT_i)V_i + B/2 \sum_{i=1}^N \sum_{\substack{j=1 \\ i=j}}^N J_i J_j$$

Η αντιστοίχιση μεταξύ (3,7) και (3,8) αποδίδει τις εξής τιμές για τις παραμέτρους:

$$W_{ij} = -A * H_{ij}, \text{ αν } i \neq j$$

$$W_{ij} = -B, \text{ αν } i=j$$

Και

$$I_i = BJ_i + CT_i$$

Το διάνυσμα που απαρτίζεται από τις εξόδους των νευρωνίων και είναι το $V=(V_1, V_2, \dots, V_n)$, αντιστοιχεί στο σύνολο της μετάδοσης που επελέγη για την τρέχουσα χρονοθυρίδα. Το σύνολο αυτό το οποίο προκύπτει από τη βελτιστοποίηση της συνάρτησης ενέργειας, δίνει τη δυνατότητα δίκαιης μεταχείρισης της κίνησης σε διάφορες εισόδους. Αυτό συμβαίνει γιατί λαμβάνονται υπόψη οι περιορισμοί 1,2,3.

Η μελέτη της απόδοσης του νευρωνικού μεταγωγέα έγινε με τη βοήθεια προσομοίωσης επειδή ο θεωρητικός υπολογιστής είναι σχεδόν αδύνατος. Τα δύο σημαντικά μεγέθη για τον υπολογισμό του πολυδιαμενόμενου μεταγωγέα είναι πρώτον ο μέσος χρόνος καθυστέρησης των πακέτων στις ουρές αναμονής που αποτελεί μέρος της συνολικής καθυστέρησης, και δεύτερον η διεκπεραιωτικότητα του μεταγωγέα. Για να υπολογίσουμε το χρόνο καθυστέρησης των πακέτων στις ουρές λαμβάνουμε υπόψη ότι ο χρόνος ανά ουρά (T_i) ισούται με το άθροισμα του μέσου χρόνου εξυπηρέτησης και του μέσου όρου αναμονής ανά ουρά. Άρα ο μέσος χρόνος καθυστέρησης για όλο το σύστημα είναι ο μέσος όρος των N αυτών τιμών. Όταν όλα τα T_i έχουν πεπερασμένη τιμή εξάγουμε απλά το μέσο, ο οποίος θα έχει και αυτός πεπερασμένη τιμή. Καθώς όμως αυξάνουμε την κίνηση, κάποιες ουρές γίνονται ασταθείς και υπερχειλίζουν. Η διεκπεραιωτικότητα ορίζεται ως ο μέσος αριθμός πακέτων που διέρχονται μέσω του μεταγωγέα ανά θύρα εισόδου ανά χρονοθυρίδα. Ο υπολογισμός γίνεται καταμετρώντας συνολικά πόσα πακέτα ήλθαν μέσω του μεταγωγέα κατά τη διάρκεια του χρόνου προσομοίωσης. Αν η παραπάνω καταμέτρηση εξάγει τον αριθμό N_{tot} και ο χρόνος προσομοίωσης είναι T_{sim} τότε:

$$\text{Throughput} = N_{tot}/N * T_{sim} \text{ όπου } N \text{ ο αριθμός των θυρών εισόδου του μεταγωγέα.}$$

Ξεκινώντας την εκτέλεση του προγράμματος ζητείται ο χρόνος προσομοίωσης σε χρονοθυρίδες. Αρχικά γίνεται η αρχικοποίηση κάποιων μεταβλητών και πινάκων και κατόπιν ακολουθεί η κανονική ροή του προγράμματος με την οποία προσομοιώνεται η κυρίως λειτουργία του συστήματος. Αποτελείται από έναν επαναληπτικό βρόχο που

εκτελείται τόσες φορές όσες είναι οι χρονοθυρίδες του χρόνου προσομοίωσης. Σε κάθε επανάληψη καταφθάνουν πακέτα στις N εισόδους του μεταγωγέα, τα οποία αποθηκεύονται στις αντίστοιχες ουρές εισόδου. Τα HOL πακέτα είναι αυτά που θα καθορίσουν το σύνολο κίνησης. Έχοντας δημιουργεί το σύνολο κίνησης καλείται στη συνέχεια να αποφασίσει ο νευρωνικός ελεγκτής ποια από HOL πακέτα θα απαρτίζουν το σύνολο της μετάδοσης, δηλ ποια θα μπορούν να περάσουν μέσω του μεταγωγέα στην τρέχουσα χρονοθυρίδα. Επίσης, ενημερώνονται οι ουρές εισόδου για το ποια πακέτα θα αποφασίστηκε να περάσουν. Τα πακέτα αυτά διαγράφονται από τις ουρές και προωθούνται στην θέση HOL τα αμέσως επόμενα. Η απόδοση του συστήματος υπολογίζεται ανά 1000 χρονοθυρίδες. Το πρόγραμμα έχει ως είσοδο τον πίνακα συνόλου διάστασης 8×8 . Καθεμία από τις γραμμές του πίνακα αυτού αντιστοιχεί σε ένα νευρώνιο. Ο πίνακας αυτός έχει και μηδενικές γραμμές στην περίπτωση που στην αντίστοιχη είσοδο του δεν υπάρχει πακέτο. Κατά την εκτέλεση λειτουργίας του δικτύου μπορεί να έχουμε νευρώνιο μηδενικής εισόδου (νευρώνια τα οποία δεν έχουν πακέτο στην είσοδο) τα οποία να αναπτύξουν μη μηδενική τιμή και τελικά να αποκτήσουν τιμή που θα σημαίνει ότι το πακέτο της αντίστοιχης εισόδου θα πρέπει να μεταδοθεί μέσω του μεταγωγέα στην τρέχουσα χρονοθυρίδα, ενώ δεν υπάρχει πακέτο σε αυτή την είσοδο. Για το λόγο αυτό αποσυνδέουμε όλα τα νευρώνια μηδενικής εισόδου από το νευρωνικό μας δίκτυο. Μετά την ολοκλήρωση της λειτουργίας του νευρωνικού δικτύου τα νευρώνια αποκτούν τις τελικές τους τιμές οι οποίες δεν είναι 1 ή 0 αλλά πολύ κοντά σε αυτές. Αυτό συμβαίνει διότι το δίκτυο εξελίσσεται μέχρι η μέγιστη διαφορά της τωρινής τιμής κάποιου νευρωνίου από την προηγούμενη τιμή του να γίνει μικρότερη από 10^{-5} και όχι μηδέν. Υπάρχουν περιπτώσεις όπου μπορεί κάποια στιγμή να είναι μόνο μια από τις 8 εισόδους γεμάτη με πακέτα. Στην περίπτωση αυτή δεν τίθεται θέμα διαμάχης, αφού πρόκειται να μεταδοθεί μόνο ένα πακέτο. Το ίδιο συμβαίνει και στην περίπτωση που υπάρχουν παραπάνω από ένα πακέτα προς μετάδοση που δεν εμποδίζουν όμως το ένα το άλλο διότι δεν έχουν στην ίδια θέση τους άσσοι. Στις περιπτώσεις αυτές δεν υπάρχει λόγος εκτέλεσης του νευρωνικού δικτύου για να αποφασιστεί ποια από τα πακέτα θα περάσουν στην παρούσα χρονοθυρίδα.

Η απόδοση της μεθόδου επηρεάζεται από τις τιμές των παραμέτρων του προγράμματος και πιο πολύ από την παράμετρο dt που είναι το χρονικό διάστημα dt μεταξύ διαδοχικών ενημερώσεων των νευρωνίων. Η απόδοση επηρεάζεται από τη διαφορά της επόμενης τιμής του νευρωνίου από την προηγούμενη του για να συνεχίζεται η διαδικασία εξέλιξης του νευρωνικού δικτύου. Η μέγιστη αυτή επιτρεπόμενη διαφορά λαμβάνεται υπόψη στον έλεγχο του βρόγχου στη ρουτίνα του νευρωνικού ελεγκτή, η οποία προσομοιώνει τη λειτουργία του νευρωνικού δικτύου. Αν θέσουμε μικρότερη τιμή για το dt και μικρύνουμε ακόμη περισσότερο την μέγιστη επιτρεπόμενη διαφορά της τιμής ενός νευρωνίου από την προηγούμενη του, θα πάρουμε ελαφρώς καλύτερα αποτελέσματα, αλλά το πρόγραμμα θα γίνει πιο αργό.

4.10 Από ένα Σαλιγκάρι..... Το πρώτο μερικώς "ζωντανό" ολοκληρωμένο κύκλωμα



Το σαλιγκάρι Lymnaea stagnalis.

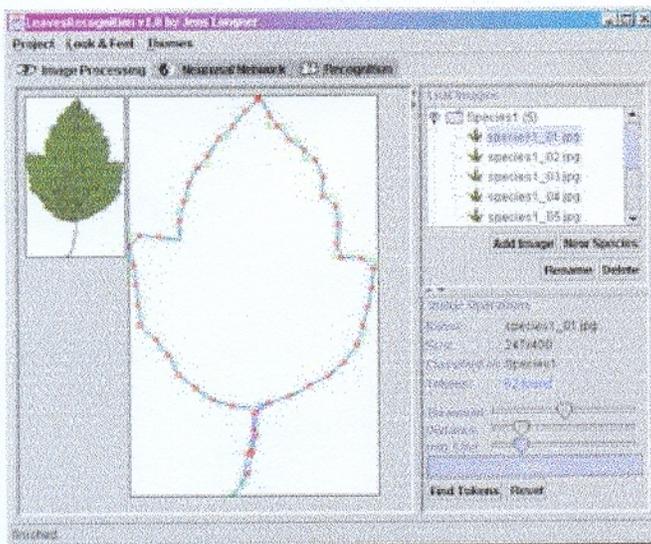
Γερμανοί ερευνητές από το ινστιτούτο βιοχημείας Max Planck, κατάφεραν για πρώτη φορά να δημιουργήσουν ένα ολοκληρωμένο κύκλωμα που συμπεριλαμβάνει νευρωνικά κύτταρα ενός σαλιγκαριού, σύμφωνα με δημοσίευση στην επιθεώρηση Proceedings of the National Academy of Science (PNAS).

Με τη βοήθεια μικροσκοπικής "πιπέττας" (προχοίδας), οι ερευνητές αφαίρεσαν περίπου 20 νευρώνες από το σαλιγκάρι Lymnaea stagnalis, τους οποίους μετά από καλλιέργεια τοποθέτησαν πάνω σε μικροεπεξεργαστές. Κάθε κύτταρο τοποθετήθηκε πάνω σε ένα τρανζίστορ. Οι ερευνητές στη συνέχεια κατάφεραν να αναπτύξουν ανάμεσα στους νευρώνες

συνάψεις (όρος που καθορίζει τη σύνδεση ανάμεσα στα νευρωνικά κύτταρα). Ακολουθεί η διέγερση ενός νευρώνα από ένα μικροεπεξεργαστή που απελευθερώνει ένα ηλεκτρικό σήμα. Το ηλεκτρικό σήμα ανιχνεύεται από ένα τρανζίστορ πάνω στο οποίο βρίσκεται ο νευρώνας, αλλά και από το τρανζίστορ του γειτονικού νευρώνα. Το ηλεκτρικό σήμα που παράγεται από το chip πυριτίου "περνάει" από νευρώνα σε νευρώνα επιστρέφοντας στο σημείο εκκίνησης χωρίς να βλάψει τα κύτταρα.

Είναι η πρώτη φορά που οι ημιαγωγοί που χρησιμοποιούνται σήμερα στα ηλεκτρονικά λειτουργούν με νευρώνες από τον εγκέφαλο ενός οργανισμού, κάτι που θεωρείται ένα πρώτο και σημαντικό βήμα στον τομέα της "νευρο-ηλεκτρονικής". Η έρευνα πάνω σε τέτοιου είδους υβριδικά κυκλώματα προδιαγράφει την ιατρική του μέλλοντος που θα επιτρέπει τη διόρθωση βλαβών του νευρικού συστήματος και τη δημιουργία υπολογιστών νέας γενιάς, τους νευρο-υπολογιστές (neurocomputers).

4.11 Τα Νευρωνικά Δίκτυα ΚΑΙ στην Αναγνώριση Φύλλων



Leaves Recognition v1.0

Neuronal Network based recognition system of leaf images Copyright '2001 by LightSpeedCommunicationsG b Rlannerstrasse

101219Dresden Germany.

<http://www.light-speed.de/>

Author:

Jens Langner

<http://damato.light-speed.de/>

01st September 2001

Ο βασικός σκοπός

Η αναγνώριση φύλλων είναι μια εφαρμογή βασισμένη σε νευρωνικό δίκτυο (σε java) για να αναγνωρίσει τις εικόνες των φύλλων σύμφωνα με ένα προηγουμένως εκπαιδευμένο backpropagation δίκτυο.

Η πρόθεση αυτής της εφαρμογής είναι να δοθεί στο χρήστη η δυνατότητα να διαχειριστεί έναν ιεραρχικό κατάλογο εικόνων φύλλων, όπου μπορεί να διαμορφώσει κάποιο είδος της ανίχνευσης ακρών και να προσδιορίσει τα μεμονωμένα σημεία κάθε εικόνας. Αυτά τα σημεία θα είναι έπειτα η βάση των υπολογισμών του νευρωνικού δικτύου ώστε να είναι σε θέση να αναγνωρίσει μια άγνωστη εικόνα φύλλου και να διευκρινίσει σε ποιο είδος ανήκει.

Ο κύριος σκοπός αυτής της εφαρμογής είναι να αποδειχτεί ότι, το εξωτερικό περίβλημα (πλαίσιο) ενός φύλλου και ένα backpropagation δίκτυο, είναι αρκετά για να γίνει γνωστό ένα φύλλο σε πιο είδος ανήκει.

Ανίχνευση των άκρων της εικόνας

Υποθέτοντας ότι η εικόνα είναι μια πλήρης 2D ανίχνευση ενός φύλλου όπως στα παραδείγματα παρακάτω, χρησιμοποιείται ο αλγόριθμος ανίχνευσης ακρών Prewitt Edge ο οποίος εξηγείται παρακάτω:

Ο Prewitt Edge παράγει μια εικόνα όπου οι υψηλότερες τιμές γκρίζου-επιπέδου υποδεικνύουν την παρουσία μιας άκρης μεταξύ δύο αντικειμένων. Το φίλτρο υπολογίζει τη ρίζα του μέσου τετραγώνου δύο 3x3 πινάκων. Είναι ένα από τα δημοφιλέστερα 3x3 φίλτρα ανίχνευσης ακρών. Το φίλτρο ανίχνευσης ακρών Prewitt χρησιμοποιεί αυτούς τους δύο 3x3 πρότυπα για να υπολογίσει την τιμή κλίσης:

$$\begin{array}{r} -1 \ 0 \ 1 \quad 1 \ 1 \ 1 \\ -1 \ 0 \ 1 \quad 0 \ 0 \ 0 \\ -1 \ 0 \ 1 \quad -1 \ -1 \ -1 \end{array}$$

$$X \quad Y$$

Έστω το παρακάτω 3x3 παράθυρο εικόνας:

$$\begin{array}{|c|c|c|} \hline a1 & a2 & a3 \\ \hline a4 & a5 & a6 \\ \hline a7 & a8 & a9 \\ \hline \end{array}$$

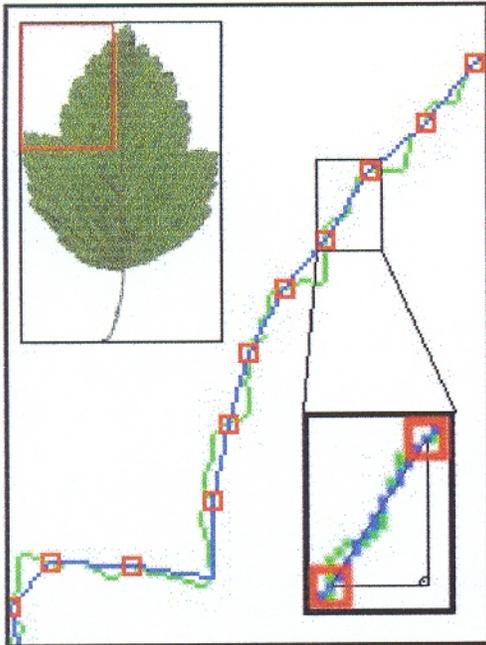
όπου:

- $a1 \dots a9$ - είναι τα γκρίζα επίπεδα κάθε pixel στο παράθυρο φίλτρου
- $X = -1*a1 + 1*a3 - 1*a4 + 1*a6 - 1*a7 + 1*a9$
- $Y = 1*a1 + 1*a2 + 1*a3 - 1*a7 - 1*a8 - 1*a9$
- Prewitt κλίση = $\text{SQRT}(X*X + Y*Y)$

Για να διαπιστωθεί σε ποιο είδος ανήκει ένα φύλλο είναι απαραίτητο να προσδιοριστεί το εξωτερικό πλαίσιο ακριβώς. Η προηγούμενος εφαρμοσμένη ανίχνευση ακρών Prewitt προσδιορίζει τις άκρες με όριο κατωφλίου και μετά από αυτήν την ανίχνευση ακρών πρέπει να εκτελεστεί ένας αλγόριθμος εκλέπτυνσης - ομαλοποίησης.

Το σημείο της εικόνας φύλλου

Το κεντρικό μέρος αυτής της εφαρμογής είναι τα σημεία κάθε εικόνας φύλλων που βρίσκονται αφότου έχει τελειώσει η επεξεργασία εικόνας. Η ιδέα πίσω από τη μεταφορά της μορφής μιας εικόνας φύλλου σε ένα νευρωνικό δίκτυο, είναι ότι οι ημιτονικές και συνημιτονικές γωνίες του σχήματος αντιπροσωπεύουν τα κριτήρια μιας αναγνώρισης προτύπου.



Η αριστερή εικόνα δείχνει ένα μέρος μιας εικόνας φύλλου που υποβλήθηκε σε επεξεργασία.

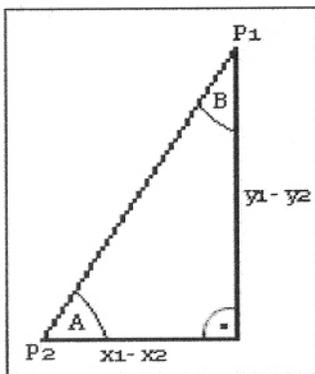
Πράσινη γραμμή: Η μορφή της εικόνας φύλλου μετά από μια επιτυχή ανίχνευση & μια ομαλοποίηση ακρών.

Κόκκινο τετράγωνο: Αυτό το τετράγωνο αντιπροσωπεύει ένα σημείο πάνω στην εικόνα του φύλλου από το οποίο τραβιέται μια γραμμή προς το επόμενο τετράγωνο.

Μπλε γραμμή: Η ένωση των κέντρων δύο τετραγώνων από την οποία υπολογίζεται το ημίτονο και το συνημίτονο της γωνία. Μια τέτοια γραμμή είναι η αντιπροσώπευση ενός σημείου του φύλλου.

Σχετικά με το μικρό ζουμ τριγώνου σε αυτήν δείχνει ένα ορθογώνιο τρίγωνο. Αυτό και το άθροισμα όλων των τριγώνων μιας εικόνας

φύλλου, είναι η αντιπροσώπευση των σημείων ενός φύλλου από το οποίο μπορούμε να αρχίσουμε τους υπολογισμούς νευρωνικού δικτύου.

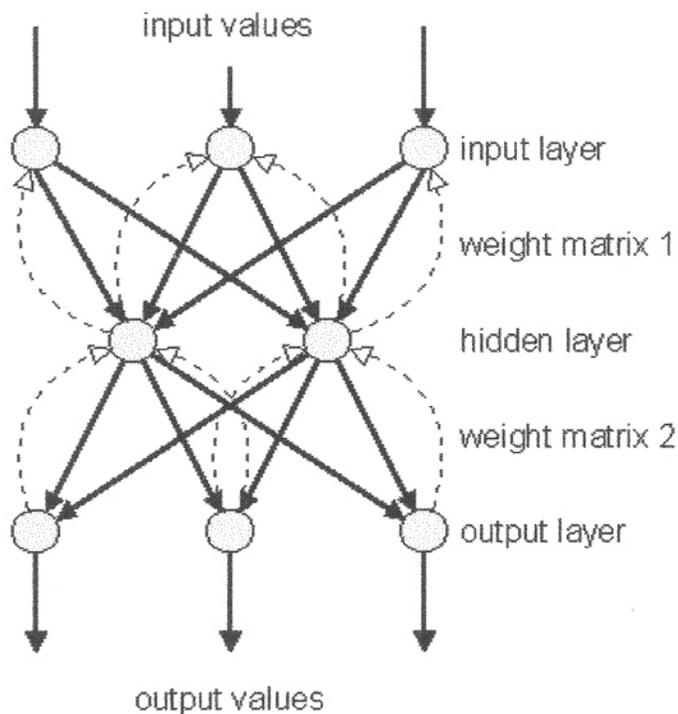


Δίπλα βλέπουμε μια μικρή εικόνα του ορθογώνιου τριγώνου που αντιπροσωπεύει ένα σημείο μιας ενιαίας εικόνας φύλλων. Οι γωνίες A και B είναι τα δύο απαραίτητα μέρη που θα εφαρμοστούν στα στρώματα του νευρωνικού δικτύου. Με αυτές τις δύο γωνίες μπορούμε να αντιπροσωπεύσουμε ακριβώς την κατεύθυνση της υποτεινουσας από το σημείο P1 στο P2 που είναι την αντιπροσώπευση μιας εικόνας φύλλων.

Το νευρωνικό δίκτυο

Ένα άλλο κύριο μέρος αυτής της εργασίας είναι η ολοκλήρωση ενός feed-forward backpropagation νευρωνικού δικτύου. Όπως περιγράφεται νωρίτερα, οι είσοδοι για αυτό το νευρωνικό δίκτυο είναι τα μεμονωμένα σημεία μιας εικόνας φύλλων, και όπως ένα σημείο αποτελείται από το συνημίτονο και το ημίτονο μιας γωνίας, ο αριθμός των στρωμάτων εισόδου για το δίκτυο αυτό, είναι ο αριθμός των σημείων πολλαπλασιασμένα επί δύο.

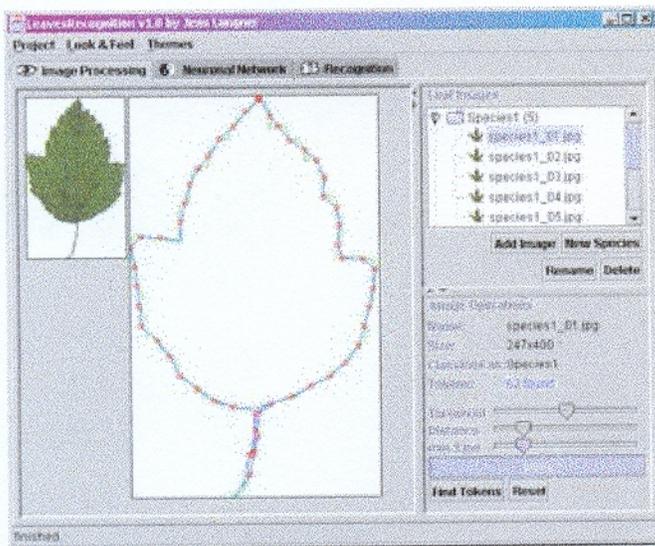
Παρακάτω φαίνεται το νευρωνικό δίκτυο που χρησιμοποιείται στην εφαρμογή του Leaves Recognition. Το εφαρμοσμένο δίκτυο έχει μια είσοδο, ένα κρυφό στρώμα ένα και στρώμα εξόδου για να απλοποιήσει και να επιταχύνει τους υπολογισμούς σε αυτή την εφαρμογή (σε Java). Για να γεμίσουμε τα νευρώνια εισόδου του δικτύου, χρησιμοποιούμε τα προηγούμενα υπολογισμένα σημεία φύλλων. Ο αριθμός των νευρώνων εξόδου, διευκρινίζεται από τον αριθμό των διαφορετικών ειδών επειδή χρησιμοποιούμε μια κωδικοποιημένη μορφή για να διευκρινίσουμε τα αποτελέσματα (έξοδοι).



Η LeavesRecognition εφαρμογή χωρίζεται σε τρία κύρια μέρη τα οποία αντιπροσωπεύουν τις τρεις κύριες διαδικασίες που ένας χρήστης μπορεί να εκτελέσει. Η μία είναι η επεξεργασία εικόνας στην οποία οι εικόνες φύλλων θα φορτωθούν και θα κατανεμηθούν σε έναν ιεραρχικό κατάλογο. Η δεύτερη είναι η εκτέλεση των νευρωνικών υπολογισμών του δικτύου στις προηγουμένως επεξεργασμένες εικόνες. Και η τρίτη είναι η αναγνώριση μιας υπάρχουσας εικόνας φύλλου και ο υπολογισμός του αριθμού των αναγνωρισμένων σημείων ώστε να διευκρινιστεί το είδος στο οποίο ανήκει η εικόνα.

Επεξεργασία εικόνας

Ένα από τα σημαντικότερα μέρη αυτής της εφαρμογής είναι η επεξεργασία εικόνας. Η μικρή αριστερή εικόνα παρακάτω είναι μια άποψη της αρχικής εικόνας και η μεγάλη εικόνα στο κέντρο αυτού του παραθύρου είναι η εικόνα αφότου είχε πιέσει ο χρήστης "Find Token" για να επεξεργαστεί τις διαφορετικές διαδικασίες επεξεργασίας εικόνας συμπεριλαμβανομένης της ανίχνευσης και της ομαλοποίησης των ακρών. Υπάρχουν 3 διαμορφώσιμοι ολισθαίνοντες ρυθμιστές όπου ένας χρήστης μπορεί να καθορίσει, τη μεγάλη μονάδα για την ανίχνευση ακρών, την απόσταση των σημείων (Κόκκινο τετράγωνο) και έναν μικρό αριθμό από pixels από τα οποία αποτελείται μια γραμμή, ώστε να αναγνωριστεί ως μέρος του σχήματος. Στη δεξιά πλευρά βλέπουμε ένα ιεραρχικό JTree όπου μπορούμε να προσθέσουμε και να διαγράψουμε εικόνες σε αυτό το δέντρο. Μπορούμε να μετακινήσουμε εικόνες από ένα είδος προς ένα άλλο απλά με Drag & Drop.



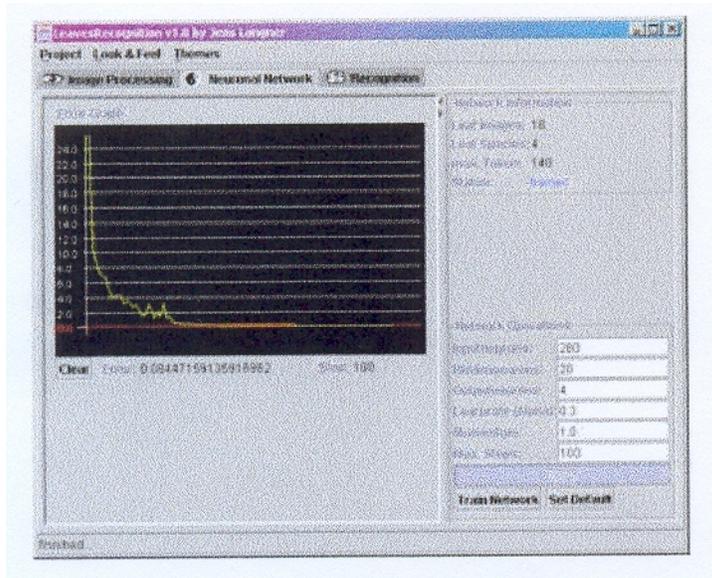
Έτσι εάν έχουμε προσθέσει μια εικόνα σε έναν σύνολο ειδών, αυτή η εικόνα αναγνωρίζεται ως τμήμα αυτού του είδους και θα περιληφθεί στους υπολογισμούς του νευρωνικού δικτύου. Για ένα καλό αποτέλεσμα πρέπει κανονικά να προστεθούν τουλάχιστον 5 εικόνες ενός είδους, για να έχει στο νευρωνικό δίκτυο αρκετά σημεία για να βρει το συγκεκριμένη μορφή αυτού του είδους φύλλου.

Ένα από τα κεντρικά μέρη της εφαρμογής αυτής είναι το νευρωνικό δίκτυο. Με βάση τις πληροφορίες που λαμβάνονται από την επεξεργασία της εικόνας, η εφαρμογή μπορεί να υπολογίσει τα βάρη του νευρωνικού δικτύου και να παράγει μια γραφική παράσταση σφάλματος για να επιδείξει το γενικό λάθος της διαδικασίας εκμάθησης.

Υπάρχει επίσης κάποιο είδος διαμόρφωσης που είναι κυρίως οι ιδιότητες του νευρωνικού δικτύου.

Με βάση τον αριθμό των εικόνων και των ιδιοτήτων του δικτύου, χρειάζεται να διευκρινιστούν περίπου 500-1000 βήματα κατάρτισης, για να πάρουμε ένα καλό αποτέλεσμα στην αναγνώριση αργότερα. Εάν το ποσοστό λάθους είναι κατώτερο του

0,01 δεν πρέπει κανονικά να υπάρχει κανένα πρόβλημα στην αναγνώριση των διαφορετικών εικόνων φύλλων. Ο αριθμός των νευρώνων εισόδου για το δίκτυο είναι κανονικά διπλάσιος του αριθμού των σημείων λόγω της τιμής του ημιτόνου και του συνημιτόνου για ένα σημείο.



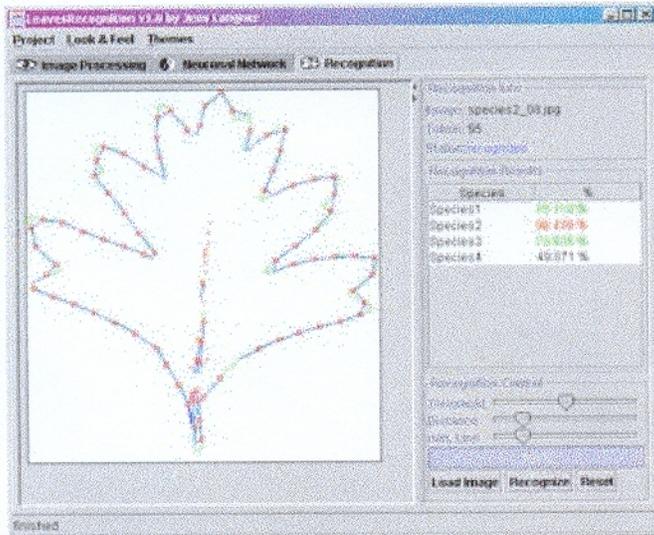
Η αναγνώριση

Το τελευταίο από τα τρία μέρη αυτής της εφαρμογής είναι η αναγνώριση. Εδώ μπορούμε να φορτώσουμε μια εικόνα και να ξεκινήσει η διαδικασία της αναγνώρισης αυτής της εικόνας φύλλου, για να διευκρινιστεί το πιθανό είδος που μπορεί να ανήκει.

Είμαστε σε θέση να ελέγξουμε το όριο κατωφλίου (Threshold), την απόσταση και την ελάχιστη γραμμή της επεξεργασίας της εικόνας που πραγματοποιείται στη φορτωμένη εικόνα μόλις πατάμε το "Recognize".

Μετά από αυτήν την επεξεργασία εικόνας, η Leaves Recognition εφαρμογή πρόκειται να χρησιμοποιήσει τα αναγνωρισμένα σημεία αυτής της νέας εικόνας σαν τιμές για να προσδιορίσει τα είδη που αυτή η εικόνα ανήκει.

Τα αποτελέσματα αυτής της αναγνώρισης θα επιδειχθούν σε ένα πίνακα παρουσίασης JTable, στη δεξιά πλευρά του GUI. Εδώ μπορούμε να δούμε ποιο από τα είδη που βρίσκονται στο εκπαιδευμένο δίκτυο, είναι το πιο παρόμοιο με τη φορτωμένη εικόνα φύλλου.



Μιλώντας για τα αποτελέσματα τα οποία αυτή η εφαρμογή μπορεί να παράγει, μπορούμε να πούμε ότι, ένα καλά εκπαιδευμένο νευρωνικό δίκτυο πρέπει κανονικά να δείξει ένα μόνο συγκεκριμένο είδος ως αποτέλεσμα. Επίσης πολύ ενδιαφέρον παρουσιάζει μια γειτονική κατηγορία που μπορεί κάπως να εξηγηθεί με τα αποτελέσματα του νευρωνικού δικτύου αυτής της εφαρμογής.

ΒΙΒΛΙΟΓΡΑΦΙΑ

«Νευρωνικά δίκτυα και εφαρμογές αυτών».

<http://www.cs.stir.ac.uk/~lss/NNIntro/InvSlides.html>

<http://www.statsoftinc.com/textbook/stneunet.html>

<http://www.gc.ssr.upm.es/inves/neural/ann1/anntutorial.html>

http://www.dacs.dtic.mil/techs/neural/neural_ToC.html

<http://www.it.uom.gr//DigitalLib/notes.htm>

<http://www.mathworks.com/products/neuralnet/>

<http://www.nnoracle.com/>

<http://www-ra.informatik.uni-tuebingen.de/SNNS/>

<http://www.lans.ece.utexas.edu/others.html>

<http://www.cs.utexas.edu/users/nn/pages/>

<http://www.nd.com/nnreference.htm>

http://www.day-trading-commodities.com/neural_net_applications_for_market_analysis.asp

<http://www.taygeta.com/nnet.xml>

http://homepages.pathfinder.gr/georgios_ii/etc/alife/neurons.html

<http://cgi.di.uoa.gr/~kalou/GWelcome.html>

<http://macedonia.uom.gr/~vpasx/snns42.htm>

