

**ΣΧΕΔΙΑΣΗ ΕΥΦΥΩΝ ΚΕΡΑΙΩΝ  
ΜΕ ΤΗ ΧΡΗΣΗ  
ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

**ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

**Ιανουάριος 2010**

**ΣΧΕΔΙΑΣΗ ΕΥΦΥΩΝ ΚΕΡΑΙΩΝ  
ΜΕ ΤΗ ΧΡΗΣΗ  
ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

**Πτυχιακή εργασία**  
της Νικοπούλου Δέσποινας

Επιβλέπων καθηγητής

Αγγέλης Κωνσταντίνος  
Αναπληρωτής Καθηγητής



ΠΡΟΛΟΓΟΣ.....	7
ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ ΣΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	9
1.1 Ιστορία των νευρωνικών δικτύων.....	9
1.2 Σχέση Φυσικών – Τεχνητών Νευρωνικών Δικτύων.....	12
1.3 Βασικές κατηγορίες Νευρωνικών Δικτύων .....	13
1.4 Πλεονεκτήματα και Μειονεκτήματα των Νευρωνικών Δικτύων.....	14
1.5 Περιγραφή ενός Νευρώνα.....	15
1.6 Βασικές Συναρτήσεις Ενεργοποίησης ( <i>Activation Functions</i> ).....	18
1.7 Δομή και Αρχιτεκτονική Δικτύων .....	20
1.8 Γνώση – Πληροφορία στην είσοδο του νευρωνικού δικτύου .....	24
1.8.1 Ορισμός γνώσης- Μορφή δεδομένων .....	24
1.8.2 Διαδικασία εκπαίδευσης .....	26
ΚΕΦΑΛΑΙΟ 2: ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ “PERCEPTRON” ΕΝΟΣ ΚΑΙ ΠΟΛΛΩΝ ΕΠΙΠΕΔΩΝ (SINGLE-LAYER & MULTILAYER) .....	29
2.1 Το μοντέλο “PERCEPTRON” .....	29
2.2 Περιγραφή Λειτουργίας του “PERCEPTRON” .....	30
2.3 Αλγόριθμος Σύγκλισης “PERCEPTRON” .....	31
2.4 PERCEPTRON πολλών στρωμάτων (Multilayer) .....	33
2.5 Μειονεκτήματα των MLP - Εφαρμογές.....	35
ΚΕΦΑΛΑΙΟ 3: Ο ΑΛΓΟΡΙΘΜΟΣ BACK PROPAGATION.....	37
3.1 Περιγραφή του αλγορίθμου Αντίστροφης Διάδοσης (BACK PROPAGATION).....	37
3.2 Εκπαίδευση Προτύπου και Εκπαίδευση κατά Ομάδες.....	43
3.2.1 Εκπαίδευση προτύπου.....	44
3.2.1 Εκπαίδευση κατά ομάδες .....	44
3.3 Συνθήκες τερματισμού της εκπαίδευσης.....	45
3.4 Μέθοδοι βελτίωσης του BACK-PROPAGATION.....	46
3.5 Μειονεκτήματα του BACK-PROPAGATION.....	47

ΚΕΦΑΛΑΙΟ 4: ΕΦΑΡΜΟΓΕΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΚΙΝΗΤΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ .....	49
4.1 Εισαγωγή .....	49
4.2 Προσαρμοζόμενη συστοιχία κεραιών επεξεργασίας σήματος ( <i>Adaptive Antenna Array Processing</i> ) .....	51
4.3 Νευρωνικό Δίκτυο Βασισμένο στην Εύρεση Διεύθυνσης.....	53
4.3.1 Αρχιτεκτονική Νευρωνικού Δικτύου.....	54
4.3.2 Είσοδος Νευρωνικού Δικτύου .....	56
4.4 Διαδικασία εκπαίδευσης του Νευρωνικού Δικτύου και αποτελέσματα.....	57
4.4.1 Εκπαίδευση Νευρωνικού Δικτύου .....	57
4.4.2 Αποτελέσματα για ένα σήμα .....	60
4.4.3 Αποτελέσματα για δύο σήματα (ένας user και ένας jammer) .....	63
 ΚΕΦΑΛΑΙΟ 5: ΜΕΛΕΤΗ ΔΙΑΜΟΡΦΩΣΗΣ ΔΕΣΜΗΣ ΤΗΣ ΕΚΠΙΕΜΠΟΜΕΝΗΣ ΑΚΤΙΝΟΒΟΛΙΑΣ (Beamforming) ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ .....	73
5.1 Εισαγωγή .....	73
5.2 Γενικά για τις «έξυπνες κεραιές».....	75
5.2.1 Επίπεδα ευφυΐας ( <i>levels of intelligence</i> ). .....	77
5.2.2 Βελτιώσεις, πλεονεκτήματα και μειονεκτήματα συστημάτων έξυπνων κεραιών.....	79
5.2.3 Σχεδιασμός κάλυψης ( <i>radio planning</i> ).....	81
5.3 Μέθοδος προσαρμογής ελαχίστων (ή μηδενισμών) και μεγίστων εκπομπής ( <i>Adaptive Nulling and Steering</i> ) .....	82
5.4 Νευρωνικό δίκτυο βασισμένο στην ακύρωση των jammers ( <i>beamforming</i> ) Αποτελέσματα.....	83
5.4.1 Αρχιτεκτονική NN για <i>beamforming</i> .....	83
5.4.2 Διαδικασία παραγωγής των δεδομένων εκπαίδευσης.....	85
5.4.3 Αποτελέσματα.....	86
 ΚΕΦΑΛΑΙΟ 6: ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ.....	88
6.1 Συμπεράσματα για την διεύθυνση άφιξης των σημάτων (DOA) .....	88
6.2 Συμπεράσματα για την χωρική κατανομή της εκπεμπόμενης ισχύος ( <i>Beamforming</i> ) .....	91
 ΠΑΡΑΡΤΗΜΑ.....	92
A. Στατιστική Μελέτη.....	92
A.1 Μέση Τιμή Τυχαίας Μεταβλητής.....	92
A.2 Διασπορά Τυχαίας Μεταβλητής .....	93

A.3 Η Gaussian Πυκνότητα Πιθανότητας.....	95
B. Κώδικας αλγορίθμων DOA και Beamforming .....	97
B.1 Αλγόριθμος για την DOA .....	97
B.2 Αλγόριθμος για το beamforming.....	99
BIBΛΙΟΓΡΑΦΙΑ.....	102

## Πρόλογος

Η ιδιαίτερα μεγάλη ανάπτυξη στις κινητές και προσωπικές επικοινωνίες τα τελευταία χρόνια έχει δημιουργήσει την ανάγκη αναζήτησης τεχνικών κωδικοποίησης και κρυπτογράφησης για την ασφάλεια των συστημάτων μετάδοσης, αφού στο μέσο μετάδοσης η πρόσβαση είναι μη ελέγχσιμη.

Πέρα από τις τεχνικές αυτές όμως θεωρείται πλέον απαραίτητο να υπάρχει ένας επιλεκτικός τρόπος εκπομπής ως προς τον επιθυμητό χρήστη.

Η αύξηση της ζήτησης αφενός σε νέες συνδρομές και αφετέρου σε υπηρεσίες μετάδοσης δεδομένων, που προφανώς απαιτούν υψηλότερους ρυθμούς μετάδοσης από τη φωνή καθώς και η κινητικότητα των χρηστών, επιβάλλουν την όσο το δυνατό πιο ορθολογιστική διαχείριση του φάσματος.

Στον συνεχώς πιο απαιτητικό τομέα των ασυρμάτων ζεύξεων των συστημάτων κινητών επικοινωνιών, η τεχνολογία των ευφυών κεραιών συντελεί στην βελτίωση της ασφάλειας των ζεύξεων αυτών, καθώς και την σωστότερη διαχείριση του διατιθέμενου φάσματος. Μέσω της καλύτερης διαχείρισης του φάσματος επιτυγχάνεται βελτίωση της ποιότητας των παρεχόμενων υπηρεσιών, μεγαλύτεροι ρυθμοί μετάδοσης καθώς και αύξηση της χωρητικότητας του συστήματος σε χρήστες. Ο όρος «έξυπνες κεραιές» χρησιμοποιείται για να περιγράψει σύνθετες τηλεπικοινωνιακές διατάξεις στις οποίες χρησιμοποιούνται στοιχειοκεραίες σε συνδυασμό με κάποιο σύστημα επεξεργασίας σημάτων ως προς τον χώρο και τον χρόνο. Ο συνδυασμός αυτός έχει σαν σκοπό την προσαρμογή του διαγράμματος ακτινοβολίας της διάταξης στις απαιτήσεις ενός δικτύου των ασυρμάτων επικοινωνιών.

Στην παρούσα εργασία θα ασχοληθούμε με αλγορίθμους νευρωνικών δικτύων για την επεξεργασία του σήματος εκπομπής και λήψης, για την εκτίμηση της διεύθυνσης άφιξης προσπίπτοντων σημάτων καθώς και την ανάδειξη του σήματος όταν θόρυβος από άλλα ανεπιθύμητα σήματα υπάρχει στο ηλεκτρομαγνητικό περιβάλλον.

Αναλυτικότερα στα κεφάλαια της εργασίας θα μας απασχολήσουν τα παρακάτω ζητήματα:

Στο πρώτο κεφάλαιο θα δούμε την θεωρία των νευρωνικών δικτύων (Neural Networks – NN). Εξηγουμέ για πιο λόγο είναι αποτελεσματική η χρήση τους και προσεγγίζουμε την σχέση των βιολογικών με τους τεχνητούς νευρώνες. Στην συνέχεια αναλύοντας τις βασικές τους κατηγορίες, περιγράφουμε την λειτουργία του νευρώνα και των συναρτήσεων ενεργοποίησης (activation function). Έπειτα αναλύουμε την δομή και αρχιτεκτονική τους καθώς επίσης και τον γενικό τρόπο εκπαίδευσής τους.

Στο δεύτερο κεφάλαιο αναλύουμε τα νευρωνικά δίκτυα “perceptron” ενός (single layer) και πολλών επιπέδων (multilayer). Αναλύουμε το μοντέλο “perceptron”, που είναι και η πιο απλή μορφή NN. Γίνεται στην συνέχεια μια αναφορά στον αλγόριθμο σύγκλισης “perceptron”, που αποτελεί NN ενός επιπέδου και η ανάλυση των “perceptrons” πολλών επιπέδων.

Στο τρίτο κεφάλαιο περιγράφεται ο αλγόριθμος αντίστροφης διάδοσης (Back-Propagation), και αναφέρουμε τον τρόπο με τον οποίο μπορεί να πραγματοποιηθεί όσον αφορά στη δομή της παρουσίας των στοιχείων της εκπαίδευσης (προτύπου (Pattern) και κατά ομάδες (Batching)). Αναφέρονται επίσης οι συνθήκες τερματισμού της εκπαίδευσης και οι μέθοδοι βελτίωσης του αλγορίθμου.

Στο τέταρτο κεφάλαιο χρησιμοποιούμε τον αλγόριθμο της διεύθυνσης άφιξης των σημάτων (Direction of Arrival), ο οποίος μας βοηθά να εντοπίζουμε τα σήματα και τους κινητούς χρήστες που παρεμβάλλονται μεταξύ τους (cochannel mobile users).

Στο πέμπτο κεφάλαιο γίνεται μια θεωρητική αναφορά στις έξυπνες κεραιές και μελετάμε την χωρική διαμόρφωση ισχύος (Beamforming), που την υλοποιήσαμε με νευρωνικό δίκτυο. Αναφερόμαστε επίσης και στην μέθοδο προσαρμογής ελαχίστων (ή μηδενισμών) και μεγίστων εκπομπής (Adaptive Nulling and Steering).

Στα δύο τελευταία κεφάλαια (κεφάλαιο 6 και παράρτημα), παραθέτουμε τα συμπεράσματα που προέκυψαν από την παρούσα εργασία, ενώ στο παράρτημα παραθέτουμε τα μαθηματικά για την στατιστική μελέτη και τον κώδικα που χρησιμοποιήσαμε.



# ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ ΣΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

## 1.1 Ιστορική αναδρομή

Η έρευνα πάνω στα νευρωνικά δίκτυα (Neural Network - NN) ξεκίνησε πριν από 50 περίπου χρόνια. Θα μπορούσαμε να χωρίσουμε την έρευνα αυτή σε έξι σημαντικές περιόδους.

Το 1940 ξεκίνησε η πρώτη περίοδος έρευνας στον σχεδιασμό των NN. Οι McCulloch και Pitts, σχεδίασαν την εκτίμηση τους για το πρώτο NN και ήταν οι πρώτοι οι αναγνώρισαν πως μπορούν να χρησιμοποιηθούν για υπολογισμό.

Ο Hebb, την ίδια περίοδο παρουσίασε πρώτος τους ψυχολογικούς ρόλους για την συναπτική αλλαγή (βάρη) των NN.

Γύρω στο 1950, ο Rosenblatt παρουσίασε και ανέπτυξε μια μεγάλη ομάδα νευρωνικών δικτύων, τα *Perceptrons*.

Στην δεκαετία (1960) εκδόθηκε η αναφορά από τον Widrow και Hoff, οι οποίοι παρουσίασαν τον LMS αλγόριθμο, ο οποίος αποτελούσε έναν νέο αλγόριθμο για την εκπαίδευση (training) δικτύου perceptron ενός επιπέδου (one-layer perceptron network), ενώ οι Minsky και Papert δημοσίευσαν το *Perceptrons*, στο οποίο θεμελιώναν τα υπολογιστικά όρια του δικτύου perceptron ενός επιπέδου

Στη δεκαετία 1970, η έρευνα στα νευρωνικά δίκτυα δεν χρηματοδοτήθηκε από εταιρείες που δραστηριοποιούνταν στον χώρο ενώ οι ηλεκτρονικοί υπολογιστές δεν είχαν τις απαραίτητες δυνατότητες που απαιτούσαν τα συστήματα των NN για πειραματισμό, με αποτέλεσμα την απογοήτευση των επιστημόνων και την ονομασία της δεκαετίας αυτής ως αδρανής περιόδου. Υπήρξαν ωστόσο αρκετοί ερευνητές που παρόλες τις δυσκολίες συνέχισαν την έρευνα. Ορισμένοι από αυτούς ήταν ο

Grossberg, ο Kohonen, ο Fukusima, ο Amari και ο Anderson. Ο Grossberg, ο οποίος παρουσίασε το προσθετικό μοντέλο των νευρώνων, το οποίο βασίστηκε στην διαφορετικότητα των μη- γραμμικών εξισώσεων και αργότερα ο ίδιος ανέπτυξε την θεωρία του προσαρμοσμένου συντονισμού των δικτύων (adaptive resonance - ART).

Ο Kohonen, έγινε γνωστός για την αυτό-οργάνωση των χαρακτηριστικών χαρτών – δικτύων (self-organizing feature maps). Ο Fukusima, παρουσίασε τα cognitron και τα neocognitron δίκτυα, ο Amari, συζήτησε για τα δυναμικά δίκτυα ενώ ο Anderson, έγινε γνωστός για το δίκτυο brain-state-in-a-box. Όλοι αυτοί οι ερευνητές, ενώ την περίοδο που δρούσαν έτυχαν κακής κριτικής, σήμερα θεωρούνται από τους πρωτόπλους στο πεδίο των νευρωνικών δικτύων. Μετά την «σκοτεινή»

περίοδο της δεκαετίας 1970, ακολούθησε η δεκαετία, που αποτέλεσε μια αναγεννητική περίοδος.

Το 1982, ο Hopfield χρησιμοποιώντας την ιδέα μιας ενεργειακής εξίσωσης διατύπωσε έναν νέο τρόπο για την κατανόηση του υπολογισμού των περιοδικών δικτύων. Επίσης απέδειξε την ικανότητα αυτών των δικτύων να λειτουργούν ως συσχετιζόμενες μνήμες (associative memories). Στην συνέχεια έλαβαν δράση οι Rumelhart, McClelland και PDP Group, οι οποίοι έκαναν δημοφιλή τον αλγόριθμο της ανάστροφης διάδοσης (back-propagation algorithm) που παραμένει ακόμα και σήμερα από τους πιο δημοφιλείς για την εκπαίδευση (training) των νευρωνικών δικτύων perceptron πολλαπλών επιπέδων (multilayer perceptron). Τα δύο αυτά γεγονότα δημιούργησαν μια φρενίτιδα στην έρευνα των νευρωνικών δικτύων ως τα τέλη της δεκαετίας του 1980.

Η επόμενη δεκαετία μπορεί να θεωρηθεί ως η περίοδος της ωρίμανσης στην έρευνα των νευρωνικών δικτύων, λόγω του ότι η φρενίτιδα για τα νευρωνικά είχε μειωθεί/εξαλείφθηκε και ελάχιστοι συνέχισαν την έρευνα σ' αυτό το πεδίο. Παρόλα αυτά εισήχθησαν νέες αρχιτεκτονικές NNs και πολλές από αυτές εφαρμόστηκαν με επιτυχία σε ποικίλα επιστημονικά πεδία. Άλλα επιστημονικά δεδομένα που εισήχθησαν/παρουσιάστηκαν στην δεκαετία του 1990 ήταν η ολοκληρωτική συνεργασία «έξυπνων» τεχνικών υπολογισμού, όπως η ασαφής λογική (fuzzy logic) και ο εξελικτικός υπολογισμός για τον σχεδιασμό έξυπνων συστημάτων. Επίσης η δεκαετία του 1990 ήταν αυτή κατά την οποία τα νευρωνικά δίκτυα καθιερώθηκαν στην τεχνολογία, με αποτέλεσμα να μπορούν να επιλύσουν πολλά προβλήματα σε διάφορες επιστημονικές περιοχές.

Από το 2000 μέχρι και σήμερα, με την παράλληλη και συνεχώς αυξανόμενη ανάπτυξη της τεχνολογίας τα νευρωνικά δίκτυα μπορούν να είναι αυτά τα οποία θα εξηγήσουν μια μεγάλη απορία του ανθρώπου, το ανθρώπινο μυαλό.

( )

Η χρήση των νευρωνικών δικτύων σε προβλήματα μετάδοσης ενδείκνυται:

1. όταν δεν υπάρχουν λύσεις κλειστής μορφής (closed form) και η επίλυση του προβλήματος γίνεται με μεθόδους δοκιμής και σφάλματος (trial-and-error),
2. όταν υπάρχουν εφαρμογές που απαιτούν εκτέλεση σε πραγματικό χρόνο
3. όταν γίνεται Χρήση γρήγορου ρυθμού σύγκλισης για την βελτιστοποίηση μεγάλων συστημάτων
4. όταν υπάρχουν αρκετά πειραματικά δεδομένα για την εκπαίδευση ενός NN για την προτεινόμενη πρόβλεψη, ειδικά όταν δεν υπάρχουν αναλυτικά εργαλεία.

Ο σχεδιασμός επιφανειών επιλογής συχνότητας (frequency selective surfaces) αποτελεί ένα παράδειγμα του προβλήματος το οποίο ανήκει στην πρώτη κατηγορία. Στην περίπτωση αυτή ο κύριος σκοπός του NN είναι να εκτελέσει τη διαδικασία προσέγγισης, συσχέτισης και πρόβλεψης. Τα προβλήματα που μπορεί να προκύψουν κατά τη διαδικασία αυτή σχετίζονται με το σχεδιασμό του δικτύου και το "έξυπνο" (smart) beamforming.

Στην δεύτερη κατηγορία, όπου απαιτείται εκτέλεση σε πραγματικό χρόνο, η πάρα πολύ γρήγορη απόκριση των NN είναι πολύ χρήσιμη. Για παράδειγμα οι προσαρμοσμένες συστοιχίες κεραιών (adaptive array antennas), χρησιμοποιούνται ευρύτατα για beamforming και για αυτορρυθμιζόμενες μεθόδους ακύρωσης και κατευθυντικότητας (null steering) σε πολλά στρατιωτικά και πολιτικά συστήματα, όπως GPS, κυψελωτές και ασύρματες επικοινωνίες. Το σημαντικό στη λειτουργία των συστημάτων αυτών είναι ο καθορισμός της γωνίας άφιξης των επιθυμητών σημάτων, καθώς επίσης και ο καθορισμός της διεύθυνσης των σημάτων παρεμβολής και των παρασίτων (interfering & jamming).

Οι νευρωνικοί beamformers, βασιζόμενοι στον υψηλής ταχύτητας υπολογισμό, μπορούν εύκολα να αφήσουν την κεραία να ανιχνεύσει παραπάνω από μια γωνία άφιξης (ή έναν κινητό χρήστη σε ένα σύστημα επικοινωνίας) σε πραγματικό χρόνο (real-time). Η διαφορά ανάμεσα στα νευρωνικά δίκτυα και τις κλασσικές υπάρχουσες λύσεις είναι ότι το δίκτυο μπορεί να εκπαιδευτεί off-line για ένα μεγάλο αριθμό γωνιών των επιθυμητών σημάτων και των πηγών παρεμβολής. Συνεπώς, εάν το NN εκπαιδευτεί επιτυχώς μια φορά, μπορεί στην συνέχεια να χρησιμοποιηθεί σε real-time, για να ανιχνεύσει την γωνία άφιξης των επιθυμητών σημάτων, να προσαρμόσει κατάλληλα τα βάρη και να λάβει τα σήματα χωρίς καμία βελτιστοποίηση. Σ' αυτή την ειδική περίπτωση, το κύριο καθήκον του NN είναι η πρόβλεψη (prediction) και η λειτουργία προσέγγισης (function approximation).

Η τρίτη κατηγορία αποτελεί την έμφυτη φύση των NNs, στην οποία αυτά δρουν ως καταναμημένα ή μαζικά παράλληλοι υπολογιστές, οι οποίοι εργάζονται για να επιταχύνουν την βελτιστοποίηση των προβλημάτων. Τα πολύπλοκα προβλήματα που υφίστανται ωθούν προς την κατεύθυνση ανάπτυξης των νευρωνικών δικτύων. Τα NN μπορούν να χρησιμοποιηθούν για να εκτελέσουν περισσότερες πρακτικές και αλληλεπιδραστικές μεθόδους βελτιστοποίησης.

Η απομακρυσμένη ανίχνευση (remote sensing) και η στοχευμένη ταξινόμηση (target classification), αποτελούν παραδείγματα τα οποία ανήκουν στην τέταρτη κατηγορία. Στην περίπτωση του remote sensing, όπως η στόχευση ραντάρ, ή το «χιόνι» στην οθόνη του ραντάρ, μετράμε τα δεδομένα από κλιμακούμενα μοντέλα τα οποία μπορούν να χρησιμοποιηθούν για να εκπαιδεύσουν τα NN για κάθε πιθανό σενάριο το οποίο μπορεί να υπάρξει. Μερικά από αυτά τα σενάρια είναι πιθανό να μην μπορούν να μοντελοποιηθούν από ήδη γνωστές αναλυτικές ή ακόμα και αριθμητικές τεχνικές, οπότε τα NN αρχικά προσδιορίζουν την «αποστολή» και στην την ταξινόμηση, την πρόβλεψη και το clustering.

## **1.2 Σχέση Βιολογικών – Τεχνητών Νευρωνικών Δικτύων.**

Στις αρχές του αιώνα με την αρχή της κατανόησης της λειτουργίας του ανθρώπινου εγκεφάλου ξεκίνησε και η έρευνα σε θέματα που αφορούν στα τεχνητά νευρωνικά δίκτυα .

Τα Τεχνητά νευρωνικά Δίκτυα έχουν φτιαχτεί θα λέγαμε κατ εικόνα και καθ ομοίωση του ανθρώπινου εγκεφάλου , αφού η μελέτη του από τους βιολόγους ήταν αυτή που έδωσε την ευκαιρία στους μηχανικούς να δημιουργήσουν ένα σύστημα λήψης αποφάσεων ( τιμών εξόδου) , όχι τόσο αυτόνομο μεν όσο ο ανθρώπινος εγκέφαλος , αλλά σίγουρα γρηγορότερο και πιο αξιόπιστο από οποιαδήποτε συμβατική τεχνική ανάλυσης.

Λειτουργούν και δομούνται σύμφωνα με την γνωστή ως τώρα αρχιτεκτονική και δομή των βιολογικών νευρώνων του οργανισμού. Τους έχουν προσδοθεί ικανότητες ταξινόμησης χαρακτηριστικών και γενίκευσης δεδομένων όπως ακριβώς και η λειτουργία του ανθρώπινου οργανισμού.

Το κύριο χαρακτηριστικό που κάνει τα ΤΝΔ τόσο ιδιαίτερα είναι η ιδιότητά τους να απομνημονεύουν καταστάσεις και να τις χρησιμοποιούν ως εμπειρίες σε νέες παρόμοιες . Έτσι η ικανότητα «σκέψης» τα κατατάσσει σε ένα από τα βασικότερα συστήματα Τεχνητής Νοημοσύνης, μαζί με τους Γενετικούς αλγορίθμους, τα συστήματα επίλυσης ασαφούς λογικής , τους έξυπνους πράκτορες και άλλα Τελικά, αντιλαμβανόμαστε ότι το τεχνητό νευρωνικό δίκτυο είναι ένας παράλληλα διανεμημένος επεξεργαστής, με δυνατότητα αποθήκευσης εμπειρικής γνώσης, άμεσης διάθεσής για χρήση, οποτεδήποτε αυτό είναι επιθυμητό. Οι ομοιότητές του με το αντίστοιχο βιολογικό νευρωνικό δίκτυο του εγκεφάλου συνοψίζονται στα εξής δύο σημεία:

□ Τη γνώση του αποκτάται μέσω μιας διαδικασίας εκμάθησης - εμπειρίας.

□ Την αποθήκευση της γνώσης, η οποία πραγματοποιείται με συνδέσεις μεταξύ των νευρώνων, ανάλογες των βιολογικών νευρικών συνάψεων, και πιο συγκεκριμένα, με τα συναπτικά βάρη που χαρακτηρίζουν αυτές τις συνδέσεις.

Σε ένα τεχνητό νευρωνικό δίκτυο, οι νευρώνες διατάσσονται σε στρώματα (*layers*), έτσι ώστε οι νευρώνες κάθε στρώματος να επιτελούν ομοειδή και ταυτόχρονη διεργασία. Ωστόσο η υπολογιστική του δύναμη οφείλεται στην παράλληλα κατανεμημένη δομή του, η οποία αποτελεί και τη βασική αιτία της ανάπτυξης της ικανότητας γενίκευσης που το χαρακτηρίζει (δηλαδή της ικανότητας του δικτύου να δίνει λογικές εξόδους για εισόδους οι οποίες δεν έχουν συμπεριληφθεί στο σύνολο εκπαίδευσης (*training set*)).

Παρ' όλα αυτά, σε εξαιρετικά πολύπλοκα προβλήματα, η τακτική που ακολουθείται είναι η εξής: το πολύπλοκο πρόβλημα διασπάται σε απλούστερα, καθένα από τα οποία ανατίθεται σε διαφορετικό νευρωνικό δίκτυο. Είναι φανερό άλλωστε, ότι απέχουμε αρκετά από τη δημιουργία ενός πιστού αντίγραφου του ανθρώπινου εγκεφάλου.

### 1.3 Βασικές κατηγορίες Νευρωνικών Δικτύων

Θεωρούμε ένα σύνολο ζευγών  $(\vec{x}_i, \vec{y}_i)$ , όπου  $x_i \in X$  και  $y_i \in Y$ , τα οποία σχετίζονται μεταξύ τους μέσω μιας άγνωστης συνάρτησης  $F : X \rightarrow Y$

Στόχος του νευρωνικού δικτύου είναι να προσεγγίσει τη συνάρτηση αυτή, με όσο το δυνατό μεγαλύτερη ακρίβεια. Η εκπαίδευση του δικτύου για την επίτευξη ακριβώς αυτού του σκοπού μπορεί να γίνει με δύο τρόπους:

- Με επίβλεψη (Supervised Learning)
- Χωρίς επίβλεψη (Unsupervised Learning)

Στην πρώτη περίπτωση, εισάγεται είσοδος  $x_i$ , με αποτέλεσμα μια έξοδο  $y'_i$ , γενικά διαφορετική από την  $y_i$ . Η διαφορά των δύο,  $y'_i - y_i$ , τείνει να ελαχιστοποιηθεί μέσω του αλγόριθμου εκπαίδευσης, βάσει του οποίου τροποποιούνται βασικές παράμετροι του δικτύου. Η διαδικασία επαναλαμβάνεται για όλο το πλήθος των ζευγών, μέχρι το σφάλμα να φτάσει σε κάποια επιθυμητή ανοχή.

Μέθοδοι που χρησιμοποιούνται συνήθως για αυτή την τροποποίηση είναι οι:

- Μέθοδος Κατιούσας κλίσης (Gradient Descent)
- Μέθοδος Newton
- Μέθοδος Μεγίστης κλίσης (Steepest Descent)
- Κανόνας Polak-Ribiere

Για εκμάθηση χωρίς επίβλεψη, το δίκτυο αυτοδιοργανώνεται μόνο του, και όχι μέσω ανάδρασης από το περιβάλλον. Απαραίτητη σε αυτή την περίπτωση είναι η ύπαρξη μεγάλου πλήθους δεδομένων. Οι σπουδαιότερες μέθοδοι σε αυτή την περίπτωση είναι:

- Ο νόμος του Hebb
- Ο ανταγωνιστικός νόμος
- Ο διαφορικός νόμος του Hebb
- Ο διαφορικός ανταγωνιστικός

Άλλος βασικός παράγοντας κατά την εκπαίδευση είναι ο συνολικός χρόνος που απαιτείται και ο τρόπος που μεταβάλλονται τα στατιστικά χαρακτηριστικά των δεδομένων σε σχέση μ' αυτόν. Τα νευρωνικά δίκτυα, λοιπόν, κατηγοριοποιούνται και με βάση την παράμετρο του χρόνου, με διαδικασία εκμάθησης που μπορεί να είναι:

- Δομική (Structural), για στάσιμο στατιστικά περιβάλλον (δηλαδή, στατιστικά χαρακτηριστικά που δε μεταβάλλονται με το χρόνο), ή

- Χρονική (Temporal), για μη στάσιμο στατιστικά περιβάλλον (real - time learning).

Επιπλέον τα τεχνητά νευρωνικά δίκτυα ανάλογα με την ικανότητά τους να έχουν μνήμη ή όχι διακρίνονται σε:

- Στατικά, τα οποία δε διαθέτουν μνήμη, οπότε η έξοδός τους είναι συνάρτηση μόνο της τρέχουσας εισόδου και όχι προηγούμενων ή επόμενων.
- Δυναμικά, τα οποία διαθέτουν μνήμη και περιγράφονται από διαφορικές εξισώσεις.

## 1.4 Πλεονεκτήματα και Μειονεκτήματα των Νευρωνικών Δικτύων

Βασικότερο πλεονέκτημα των νευρωνικών δικτύων είναι η μη γραμμικότητα, η οποία αρχίζει ήδη να υφίσταται από το επίπεδο του ενός απλού νευρώνα, για να διανεμηθεί τελικά σε όλο το δίκτυο. Η σημασία αυτής της ιδιότητας φαίνεται να λαμβάνει σημαντικές διαστάσεις, αν αναλογιστεί κανείς πως τα περισσότερα προς επεξεργασία προβλήματα είναι μη γραμμικά.

Επιπλέον, τα δίκτυα αυτά, μετά την εκπαίδευση που τους γίνεται για την προσέγγιση της συνάρτησης εισόδου-εξόδου, μπορούν να χρησιμοποιηθούν και για πρόβλεψη. Επίσης σημαντική είναι η ικανότητά τους να προσαρμόζονται (Retraining), γεγονός που επιτρέπει την επανεκπαίδευσή τους, έτσι ώστε να ανταποκρίνονται κάθε φορά στις αλλαγές του περιβάλλοντος.

Αξιοσημείωτη είναι και η μεγαλύτερη ανοχή τους σε σφάλματα, εξαιτίας των πολλών μονάδων επεξεργασίας και της διανομής της πληροφορίας σε όλο το δίκτυο.

Συνέπεια αυτού είναι, ακόμη και καταστροφή μέρους των νευρώνων του συστήματος ή και των μεταξύ τους συνδέσεων, να μην οδηγεί σε ολική καταστροφή, ούτε να επηρεάζει σημαντικά την απόκρισή του.

Τέλος, σημαντική είναι η ταχύτητά τους, η οποία οφείλεται στον έντονο παραλληλισμό των διεργασιών τους, γεγονός που τα καθιστά κατάλληλα για χρήση σε τεχνολογία VLSI (Very Large Scale Integrated).

Στα μειονεκτηματά τους, καταλογίζονται τα εξής:


- ✓ Η πιθανότητα απομνημόνευσης των δεδομένων εκπαίδευσης, με αποτέλεσμα να μην αποδώσουν σε νέα δεδομένα το ίδιο καλά (άσχημη γενίκευση).

- ✓ Η αυξημένη πιθανότητα να παγιδευτούν σε τοπικό ελάχιστο της επιφάνειας σφάλματος κατά την εκπαίδευση. Αυτή η περίπτωση εξετάζεται αναλυτικά στο επόμενο κεφάλαιο, μαζί με τους κατάλληλους τρόπους για την αντιμετώπισή της.

## 1.5 Περιγραφή ενός Νευρώνα

Τα βασικά χαρακτηριστικά ενός νευρώνα είναι τα εξής:

1. Τα συναπτικά βάρη (Synaptic Weights): αν η είσοδος του νευρώνα  $k$  στη σύναψη  $j$  είναι το σήμα  $x_j$ , τότε αυτό πολλαπλασιάζεται με το συναπτικό βάρος  $W_{kj}$ , όπου ο πρώτος δείκτης αναφέρεται στο νευρώνα και ο δεύτερος, στη σύναψη που δέχεται στην είσοδό της το σήμα  $W_{kj}$
2. Ο αθροιστής (Adder): ο οποίος στην έξοδό του δίνει το άθροισμα των σταθμισμένων εισόδων.
3. Η συνάρτηση ενεργοποίησης (Activation Function): από αυτήν περνά η έξοδος του αθροιστή και δίνει αποτέλεσμα στο διάστημα  $[0, 1]$  ή  $[-1, 1]$ , ανάλογα με τον τύπο της συνάρτησης που επιλέχθηκε.
4. Το κατώφλι  $\theta_k$  : πρόκειται για δευτερεύουσα παράμετρο του συστήματος, η οποία συνήθως επιλέγεται με στόχο την καλύτερη ευελιξία του.



Σχήμα 1.1: Μοντέλο μη γραμμικού νευρώνα

Στο παραπάνω σχήμα δίνεται το μοντέλο ενός νευρώνα με κατώφλι  $\theta_k$  είσοδο το διάνυσμα

$$P = \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{pmatrix} \text{ και βάρη } W = (w_{11}, w_{12}, \dots, w_{1n})$$

Έτσι ισχύει: 
$$U_k = \sum_{j=1}^N w_{kj} \cdot x_j \quad (1.1)$$

όπου προκειμένου  $k=1$ , η έξοδος του νευρώνα είναι: 
$$y_k = \varphi(u_k - \theta_k) \quad (1.2)$$

όπου  $x_1, x_2, \dots, x_n$ , τα σήματα εισόδου και  $w_1, w_2, \dots, w_n$ , τα συναπτικά βάρη του νευρώνα  $k$ ,  $\theta_k$  το κατώφλι του, και  $\varphi(\cdot)$  η συνάρτηση ενεργοποίησής του.


Θεωρώντας, και το κατώφλι ως συναπτικό βάρος  $W_{k0}$  της εισόδου  $x_0 = -1$ , το  $v_k$ , δηλαδή η έξοδος του αθροιστή, δίνεται από τη σχέση:

$$v_k = \sum_{i=0}^N w_{ki} \cdot x_i \quad (1.3)$$

ενώ η έξοδος του νευρώνα είναι:

$$y_k = \varphi(v_k) \quad (1.4)$$

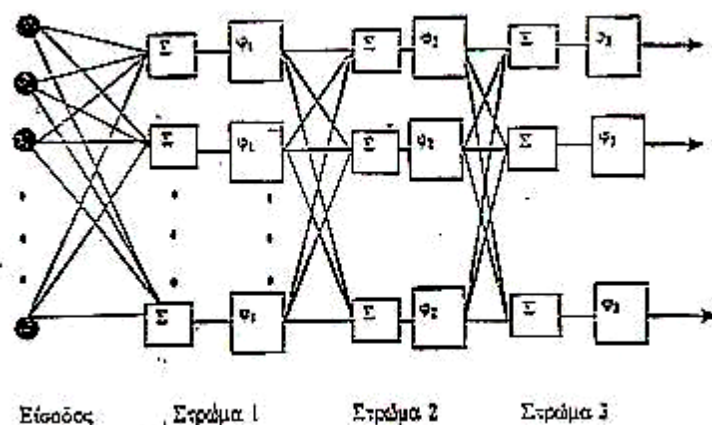
Στο σχήμα που ακολουθεί φαίνεται και ο ρόλος που διαδραματίζει το κατώφλι  $\theta_k$ , το οποίο τελικά ελαττώνει την είσοδο της συνάρτησης ενεργοποίησης όταν το σήμα είναι θετικό και την αυξάνει όταν είναι αρνητικό.



Σχήμα 1.2: Επίδραση του κατωφλίου  $\theta_k$  στην είσοδο της συνάρτησης ενεργοποίησης



Τα σύγχρονα νευρωνικά δίκτυα αποτελούνται από πολλούς απλούς νευρώνες, όπως αυτόν που περιγράφηκε παραπάνω, οι οποίοι συνθέτουν αρχικά ένα στρώμα και στη συνέχεια ένα σύστημα πολλαπλών στρωμάτων.




Σχήμα 1.3: Νευρωνικό δίκτυο τριών στρωμάτων

## 1.6 Βασικές Συναρτήσεις Ενεργοποίησης (Activation Functions)

Οι βασικότερες συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στη διαδικασία εκπαίδευσης των νευρωνικών δικτύων είναι:

- Συνάρτηση κατωφλίου (Threshold Function), η οποία ορίζεται ως εξής:

$$\varphi_v = \begin{cases} 1 & \text{αν } v \geq 0 \\ 0 & \text{αν } v < 0 \end{cases} \quad (1.5)$$




Σχήμα 1.4: Συνάρτηση κατωφλίου

Οπότε η έξοδος του νευρώνα κ θα είναι:

$$y_k = \begin{cases} 1, & \alpha v \nu_k \geq 0 \\ 0, & \alpha v \nu_k \leq 0 \end{cases} \quad (1.6)$$

• Τμηματικά γραμμική συνάρτηση (Piecewise-Linear Function):

$$\varphi_v = \begin{cases} 1, & \alpha v \nu \geq \frac{1}{2} \\ v + \frac{1}{2}, & -\frac{1}{2} \leq v \leq \frac{1}{2} \\ 0, & \alpha v \nu \leq -\frac{1}{2} \end{cases} \quad (1.7)$$




Σχήμα 1.5: Τμηματικά γραμμική συνάρτηση

• Σιγμοειδής συνάρτηση (Sigmoid Function). Μια σιγμοειδής συνάρτηση, είναι η λογιστική σιγμοειδής συνάρτηση, η οποία έχει την εξής μορφή:

$$\phi_v = \frac{1}{(1+\exp(-a_v))} \quad (1.8)$$


όπου  $a$ , παράμετρος η μεταβολή της οποίας έχει σαν αποτέλεσμα τη μεταβολή της κλίσης της συνάρτησης, γεγονός που αποδίδει ευελιξία στο σύστημα. Επίσης, είναι παραγωγίσιμη.



Σχήμα 1.6: Σιγμοειδής συνάρτηση

Άλλη παραγωγίσιμη συνάρτηση σιγμοειδούς μορφής που χρησιμοποιείται στη διαδικασία εκμάθησης των δικτύων, είναι η σιγμοειδής συνάρτηση υπερβολικής εφαπτομένης (Hyperbolic Tangent Function), που ορίζεται ως εξής:

$$\varphi_v = \tanh\left(\frac{v}{2}\right) = \frac{(1 - \exp(-v))}{(1 + \exp(-v))} \quad (1.9)$$



Σχήμα 1.7: Γραφική παράσταση της συνάρτησης υπερβολικής εφαπτομένης  $y = \tanh(x)$ .

## 1.7 Δομή και Αρχιτεκτονική Δικτύων

Η δομή των δικτύων είναι άμεσα συνδεδεμένη με τον αλγόριθμο εκπαίδευσης με μια αμφίδρομη σχέση αλληλεξάρτησης και επιρροής. Ωστόσο, ανεξάρτητα από το είδος της εκπαίδευσης, είναι δεδομένο ότι για την ύπαρξη δικτύου, υπάρχουν τουλάχιστον δύο στρώματα νευρώνων, ένα για την είσοδο και ένα για την έξοδο. Τα δύο αυτά στρώματα δεν έχουν απαραίτητα τον ίδιο αριθμό νευρώνων. Για το στρώμα εισόδου, ο αριθμός αυτός καθορίζεται από τον όγκο των δεδομένων, ενώ για το στρώμα εξόδου, συνηθίζεται να χρησιμοποιείται ένας νευρώνας.

Τα στρώματα, τα οποία παρεμβάλλονται μεταξύ εισόδου - εξόδου, δεν έχουν άμεση επαφή με το περιβάλλον, γι' αυτό και ονομάζονται κρυμμένα στρώματα (Hidden Layers). Ο αριθμός των νευρώνων τους είναι τελείως ανεξάρτητος από τον αριθμό των άλλων στρωμάτων. Εδώ, πρέπει να σημειώσουμε ότι:


Οι νευρώνες των διαφόρων στρωμάτων μπορούν να συνδέονται μεταξύ τους με τους εξής δύο τρόπους:

η επιλογή του αριθμού των στρωμάτων των νευρώνων που τα αποτελούν, της συνάρτησης ενεργοποίησης όπως επίσης και της μεθόδου εκμάθησης γίνεται τυχαία ή κάποιες φορές με βάση εμπειρικούς κανόνες που έχουν κατά καιρούς εφαρμοστεί με καλά αποτελέσματα.

- Πλήρης διασύνδεση (Full connection), όπου οι νευρώνες ενός στρώματος συνδέονται με όλους τους νευρώνες του επομένου, κ.ο.κ.
- Μερική διασύνδεση (Partial connection), όπου μερικοί μόνο νευρώνες από το ένα στρώμα συνδέονται με μερικούς από το επόμενο.

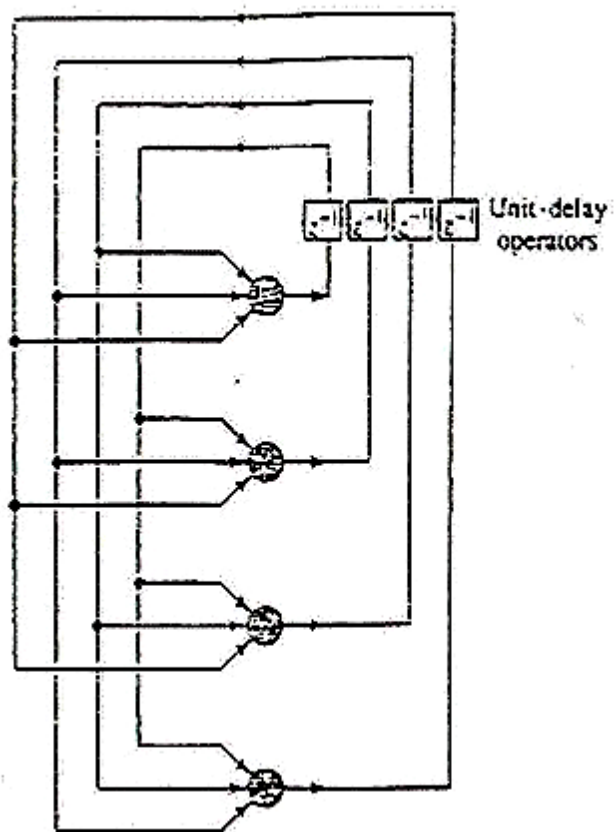
Σχετικά με το αν υπάρχει ανάδραση μεταξύ εισόδου - εξόδου ή όχι, διακρίνονται οι εξής αρχιτεκτονικές:

1. Τα μη αναδρομικά δίκτυα ενός στρώματος, τα οποία δεν παρουσιάζουν ανάδραση, και αποτελούνται από ένα στρώμα εισόδου και ένα εξόδου. Το στρώμα εισόδου δεν υπολογίζεται αφού δεν αποτελεί τμήμα του υπολογιστικού μέρους του συστήματος.
2. Τα μη αναδρομικά δίκτυα πολλών στρωμάτων, τα οποία επίσης δεν παρουσιάζουν ανάδραση και αποτελούν επέκταση της προηγούμενης περίπτωσης, όπου επιπλέον μεταξύ εισόδου και εξόδου συμπεριλαμβάνονται κρυμμένα στρώματα.




Σχήμα 1.8: Μη αναδρομικό δίκτυο ενός στρώματος

3. Τα αναδρομικά δίκτυα, τα οποία περιλαμβάνουν τουλάχιστον έναν αναδρομικό βρόχο είτε μεταξύ στρωμάτων, είτε μεταξύ νευρώνων, είτε ακόμη και για τον ίδιο νευρώνα, όταν η έξοδός του αυτοτροφοδοτεί την είσοδό του (περίπτωση "αυτοανάδρασης", (Self-Feedback) ).



Σχήμα 1.9: Αναδρομικό δίκτυο χωρίς αυτό - ανάδραση.

4. Τα μη αναδρομικά δίκτυα Lattice, πρόκειται για δομή χωρίς ανάδραση, με νευρώνες σε διάταξη γραμμών και στηλών, όπως ακριβώς ένας πίνακας.



Σχήμα 1.10: Δίκτυο δομής "lattice" 3 5 3 β

## 1.8 Γνώση – Πληροφορία στην είσοδο του νευρωνικού δικτύου

### 1.8.1 Ορισμός γνώσης- Μορφή δεδομένων

Η ικανότητα πρόβλεψης των δικτύων βασίζεται στον τρόπο εκπαίδευσής τους, ο οποίος με τη σειρά του εξαρτάται από την ποσότητα της πληροφορίας που διατίθεται στο δίκτυο και κυρίως, από το πώς αυτή παρουσιάζεται. Ως γνώση ορίζεται:

Η πληροφορία που παρέχεται σε ένα σύστημα τεχνητής νοημοσύνης, μπορεί να είναι δύο ειδών:

- Πληροφορία, η οποία έχει σχέση με το περιβάλλον και τις βασικές ιδιότητες που το χαρακτηρίζουν και
- Λαμβανόμενες μετρήσεις, οι οποίες περιέχουν θόρυβο εξαιτίας ανθρωπίνων σφαλμάτων ή ατελειών των οργάνων μέτρησης, και αποτελούν το σύνολο των διανυσμάτων της εκπαίδευσης (Training set).

Η διαδικασία που ακολουθείται είναι συνοπτικά η εξής:

Δίνεται το σήμα εισόδου και η επιθυμητή έξοδος. Στη συνέχεια, αφού ολοκληρωθεί η διαδικασία εκμάθησης δοκιμάζεται η απόδοση του δικτύου σε σύνολο δεδομένων που δεν ανήκουν στο σύνολο εκπαίδευσης. Έτσι δοκιμάζεται η ικανότητα του δικτύου στην εκμάθηση, καθώς με αυτόν τον τρόπο φαίνεται αν αυτή έχει ολοκληρωθεί ή απλά το δίκτυο έχει απομνημονεύσει το σύνολο εκπαίδευσης, με αποτέλεσμα την καλή συμπεριφορά του μόνο σε αυτό. Αυτή είναι η φάση της γενίκευσης (Generalization).

Σημαντικό επίσης είναι, κατά την εκπαίδευση να δίνονται και αρνητικά παραδείγματα, δηλαδή διανύσματα εισόδου των οποίων η έξοδος, είναι γνωστό από πριν, ότι οδηγεί σε αποτελέσματα τελείως διαφορετικά από τα επιθυμητά. Απλά, δίνονται στο δίκτυο για να το εκπαιδεύσουν, έτσι ώστε να αναγνωρίζει και να διαχωρίζει παρόμοιες "λανθασμένες εισόδους", οι οποίες πιθανόν δίνονται ταυτόχρονα.

Καθώς αυξάνεται η πολυπλοκότητα ενός προβλήματος, επιβάλλεται να αυξάνεται και ο αριθμός και η πολλαπλότητα των πηγών γνώσης - πληροφορίας. Η διαχείρισή τους σε αυτή την περίπτωση, γίνεται εξαιρετικά δύσκολη. Ωστόσο, υπάρχουν κάποιοι βασικοί κανόνες που ακολουθούνται για την πιο απλή και πιο αποτελεσματική παρουσίαση της πληροφορίας στο δίκτυο. Αυτοί είναι:

i) Είσοδοι που παρουσιάζουν ομοιότητες παρουσιάζονται στο δίκτυο να ανήκουν στην ίδια κατηγορία. Αξιοπίστα κριτήρια για την ομοιότητα μεταξύ δύο διανυσμάτων εισόδου, είναι η Ευκλείδεια απόσταση και το Εσωτερικό γινόμενο των διανυσμάτων. Αυτά θεωρούνται αρκετά, εφ' όσον το πρώτο δηλώνει τη διανυσματική διαφορά τους και το δεύτερο την προβολή του ενός πάνω στο άλλο.

ii) Δεδομένα με πολύ μεγάλες διαφορές πρέπει να κωδικοποιούνται με τέτοιο τρόπο, ώστε οι διαφορές αυτές να είναι φανερές.

iii) Πληροφορίες που αφορούν το περιβάλλον και είναι γνωστές από πριν, δίνονται για να το διευκολύνουν. Αυτό οδηγεί στη δημιουργία "δικτύων με ειδικευμένη δομή" (Specialized structure), τα οποία είναι πολύ πιο γρήγορα, με πολύ λιγότερες ελεύθερες παραμέτρους (δηλ. νευρικές συνάψεις). Έτσι, είναι πιο ευέλικτα κατά την εκπαίδευση και συνεπώς, με καλύτερα αποτελέσματα γενίκευσης της νεοαποκτηθείσας γνώσης.



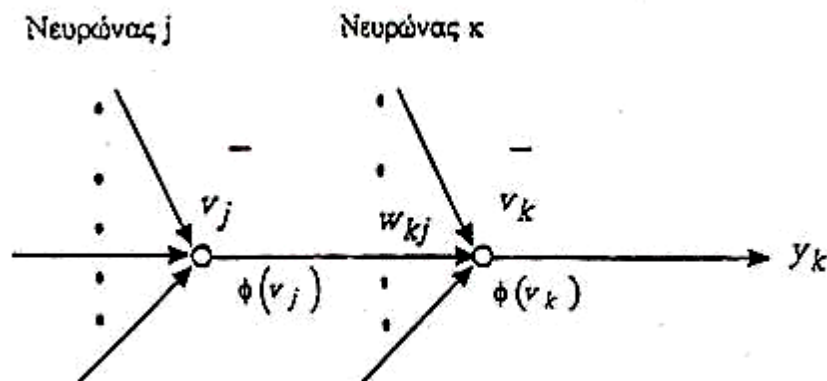
## 1.8.2 Διαδικασία εκπαίδευσης

Η εκπαίδευση ορίζεται ως:

*η λειτουργία κατά την οποία οι ελεύθερες παράμετροι του δικτύου προσαρμόζονται μέσω μίας συνεχούς διέγερσης από το περιβάλλον μέσα στο οποίο βρίσκονται. Η μέθοδος με την οποία πραγματοποιείται, καθορίζεται από τον τρόπο με τον οποίο αλλάζουν οι τιμές των βαρών για την απαιτούμενη προσαρμογή τους.*

Τα στάδια που ακολουθούνται στην εκπαίδευση είναι:

1. Το νευρωνικό δίκτυο αρχικά διεγείρεται από το περιβάλλον
2. Γίνονται αλλαγές στις τιμές των βαρών
3. Το NN αποκρίνεται στο περιβάλλον του με κάποια νέα συμπεριφορά



Σχήμα 1.11: Προσυναπτική - Μετασυναπτική Διαδικασία

Από το παραπάνω σχήμα, αν  $w_{kj}$ , είναι η τιμή του βάρους της σύναψης τη χρονική στιγμή  $n$ , η διόρθωση του ίδιου βάρους την ίδια χρονική στιγμή,  $\Delta w_{kj}(n)$ , που οδηγεί στο νέο βάρος  $w_{kj}(n+1)$ , δίνεται από τη σχέση:

$$\Delta w_{kj}(n) = w_{kj}(n+1) - w_{kj}(n) \quad (1.10)$$

Η διόρθωση των βαρών πραγματοποιείται για τους νευρώνες όλων των στρωμάτων με επαναληπτική διαδικασία. Στην ιδανικότερη περίπτωση μετά από κάθε επανάληψη, το σύστημα αποκτά όλο και περισσότερη γνώση του περιβάλλοντός του.

Οι αλγόριθμοι εκπαίδευσης ποικίλουν, τόσο ως προς τη μέθοδο με την οποία γίνεται η αλλαγή των βαρών, όσο και ως προς τον τρόπο με τον οποίο σχετίζεται το δίκτυο με το περιβάλλον του. Πρακτικά ενδιαφέρον έχουν όμως οι διαφορές μεταξύ των αλγορίθμων, ως προς την ταχύτητα εκμάθησης.

Θεμελιώδεις κανόνες για τους διάφορους αλγόριθμους εκπαίδευσης είναι οι εξής:

- ❖ Εκμάθηση μέσω διόρθωσης σφάλματος (Error-correction learning)
- ❖ Ανταγωνιστική εκμάθηση (Competitive learning)
- ❖ Αλγόριθμος Hebbian (Hebbian learning)
- ❖ Αλγόριθμος Boltzmann ( Boltzmann learning)

Οι αλγόριθμοι ανταγωνιστικής εκμάθησης και Hebbian, στηρίζονται σε φυσικά νευροβιολογικά φαινόμενα, ενώ ο αλγόριθμος Boltzmann, στη θεωρία πληροφοριών και τη θερμοδυναμική.

Στην παρούσα εργασία, χρησιμοποιείται αλγόριθμος διόρθωσης σφάλματος.

Αν  $y_k(n)$  είναι η έξοδος του νευρώνα  $k$  τη χρονική στιγμή  $n$  και  $d_k(n)$  η αντίστοιχη επιθυμητή έξοδος, τότε το σφάλμα είναι:

$$e_k(n) = d_k(n) - y_k(n) \quad (1.11)$$

Η μέθοδος αυτή ελαχιστοποιεί τη συνάρτηση κόστους, έτσι ώστε η απόκριση του δικτύου να προσεγγίζει κατά το δυνατόν καλύτερα τη συνάρτηση εισόδου - εξόδου. Για το σκοπό αυτό παίρνουμε τη συνάρτηση του μέσου τετραγωνικού σφάλματος, ως συνάρτηση κόστους:

$$j = \frac{1}{2} E \left[ \sum_k e_k^2(n) \right] \quad (1.12)$$

όπου το  $E$  δηλώνει στατιστική μέση τιμή. Η ελαχιστοποίηση αυτής της συνάρτησης γίνεται με τη μέθοδο της κατιούσας κλίσης, ενώ ο παράγοντας  $\frac{1}{2}$  έχει εισαχθεί για ευκολία στους υπολογισμούς, κατά την παραγωγή της στατιστικής μέσης τιμής του

συνολικού τετραγωνικού σφάλματος  $J$ , ως προς τις παραμέτρους του δικτύου. Εξαιτίας όμως της δυσκολίας που εμφανίζεται, καθώς απαιτείται γνώση στατιστικών χαρακτηριστικών της εισόδου, η συνάρτηση που τελικά ελαχιστοποιείται είναι η εξής:

$$e(n) = \frac{1}{2PN} \sum_{i=1}^P \sum_{k=1}^N e_{ki}^2(n) \quad (1.13)$$

όπου  $N$  = το πλήθος των νευρώνων του στρώματος εξόδου και  $P$  = το πλήθος των διανυσμάτων εκπαίδευσης

Γραφικά, η παραπάνω συνάρτηση κόστους είναι μια πολυδιάστατη επιφάνεια ως προς τα συναπτικά βάρη, γνωστή ως "επιφάνεια σφάλματος". Σχετικά με αυτή διακρίνονται οι εξής περιπτώσεις:

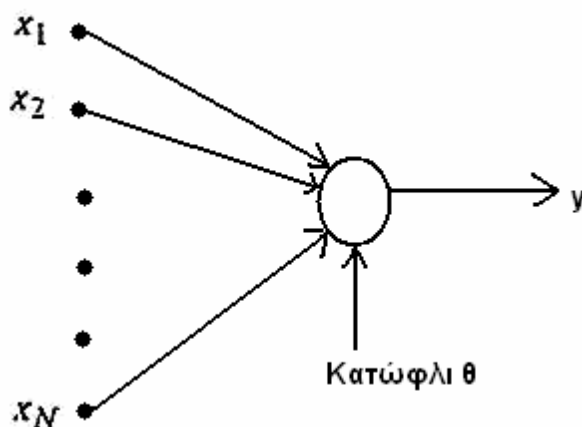
- Αν το δίκτυο αποτελείται από γραμμικές μονάδες επεξεργασίας (γραμμική συνάρτηση ενεργοποίησης), η επιφάνεια σφάλματος παρουσιάζει ένα και μοναδικό ελάχιστο, γεγονός που εξασφαλίζει, εκτός από τη μοναδικότητα της λύσης, και μεγάλη ταχύτητα σύγκλισης.
- Αν αποτελείται από μη γραμμικούς νευρώνες (μη γραμμική συνάρτηση ενεργοποίησης), τότε η επιφάνεια σφάλματος εμφανίζει εκτός από το μοναδικό ολικό ελάχιστο και πολλαπλά τοπικά ελάχιστα, τα οποία μπερδεύουν το δίκτυο και δυσκολεύουν την εκμάθηση.

Η εκπαίδευση ξεκινά από κάποιο σημείο της επιφάνειας σφάλματος, που ορίζουν κάποιες αρχικές τιμές των βαρών και εξελίσσεται με στόχο την εύρεση του ολικού ελαχίστου και στις δύο περιπτώσεις. Ωστόσο, για μη γραμμικούς νευρώνες στην επιφάνεια σφάλματος των οποίων εντοπίζονται και τοπικά ελάχιστα, είναι πολύ πιθανή η παγίδευση του δικτύου κατά την εκπαίδευση σε ένα από αυτά έτσι ώστε να αποκλείεται η επιθυμητή σύγκλιση στο ολικό της ελάχιστο.

## ΚΕΦΑΛΑΙΟ 2: ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ “PERCEPTRON” ΕΝΟΣ ΚΑΙ ΠΟΛΛΩΝ ΕΠΙΠΕΔΩΝ (SINGLE-LAYER & MULTILAYER)

### 2.1 Το μοντέλο “PERCEPTRON”

Το "PERCEPTRON", είναι η απλούστερη μορφή νευρωνικού δικτύου, και βρίσκει εφαρμογή στην ταξινόμηση (Classification), γραμμικά διαχωρίσιμων προτύπων. Διακρίνεται για την ιδιαίτερη δυνατότητά του να εκπαιδεύεται και να γενικεύει κατά την εφαρμογή της αποκτηθείσας γνώσης του, μέσω ενός συνόλου παραδειγμάτων εκμάθησης που όμως δεν ανήκουν στο σύνολο εκπαίδευσης. Στην απλούστερη μορφή του, αποτελείται μόνο από ένα νευρώνα με συναπτικά βάρη και κατώφλι, όπως ακριβώς στο παρακάτω σχήμα.



Σχήμα 2.1: “Perceptron” ενός στρώματος

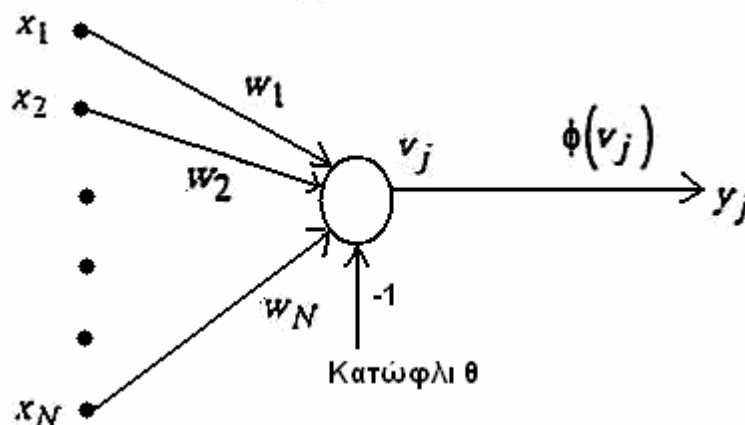
Ο αλγόριθμος που χρησιμοποιείται για την προσαρμογή των βαρών του δημιουργήθηκε από τον Rosenblatt (1958,1962), ο οποίος απέδειξε ότι το "perceptron" συγκλίνει πάντα όταν τα πρότυπα εκπαίδευσης είναι γραμμικά διαχωρίσιμα. Το "perceptron" ενός νευρώνα διαχωρίζει μόνο δύο κατηγορίες. Για περισσότερες, συνίσταται η χρήση περισσότερων νευρώνων.

## 2.2 Περιγραφή Λειτουργίας του “PERCEPTRON”

Στην απλούστερη μορφή του το "perceptron" αποτελείται από ένα νευρώνα, τα συναπτικά βάρη, το κατώφλι, τον αθροιστή και τη συνάρτηση ενεργοποίησης, σύμφωνα με την οποία δίνει έξοδο +1 για θετική είσοδο και -1 για αρνητική είσοδο.

Αν τα συναπτικά βάρη του "perceptron" είναι  $w_1, w_2, \dots, w_n$ ,  $x_1, x_2, \dots, x_n$  οι αντίστοιχες είσοδοι και  $\theta$  το κατώφλι, η έξοδος του αθροιστή θα είναι:

$$v = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (2.1)$$

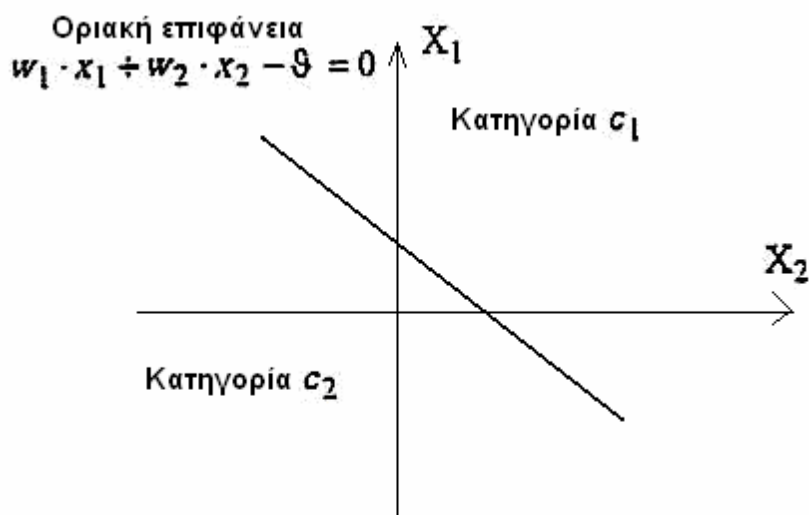


Σχήμα 2.2: Διάγραμμα ροής του "Perceptron"

Το perceptron καλείται να ταξινομήσει τις παραπάνω εισόδους σε μία από τις δύο κατηγορίες C1 ή C2. Η έξοδος του τελικά, θα είναι ίση με +1 αν η είσοδος ανήκει στην C1 κατηγορία, και -1 αν ανήκει στη C2. Το υπερεπίπεδο που διαχωρίζει τις δύο κατηγορίες ορίζεται από τη σχέση:

$$\sum_{i=1}^n w_i \cdot x_i - \theta = 0 \quad (2.2)$$

ενώ παριστάνεται ως εξής:



Σχήμα 2.3: Οριακή επιφάνεια προβλήματος ταξινόμησης δύο διαστάσεων.

Έπειτα από την τοποθέτηση της οριακής επιφάνειας, η οποία για δυσδιάστατα διανύσματα είναι ευθεία, το perceptron μπορεί να ταξινομήει ένα σημείο, που βρίσκεται πάνω από την οριακή επιφάνεια, στην τάξη  $c_1$ , και ένα που βρίσκεται κάτω από αυτήν στην τάξη  $c_2$ . Ο ρόλος του κατωφλίου είναι να μετατοπίζει, ανάλογα με την τιμή του, την οριακή επιφάνεια από την αρχή των αξόνων όταν αυτό είναι επιθυμητό.

### 2.3 Αλγόριθμος Σύγκλισης “PERCEPTRON”

Ο αλγόριθμος σύγκλισης "perceptron", βασίζεται στη διόρθωση σφάλματος και μεταβάλλει τα συναπτικά βάρη μέσω μιας επαναληπτικής διαδικασίας.

Αν  $x^p$  το  $p$ -οστό διάνυσμα εισόδου:  $x^p = [-1, x_1^p, x_2^p, \dots, x_N^p]^T$ , και  $w = [\theta, w_1, w_2, \dots, w_N]^T$

η έξοδος του αθροιστή θα είναι:

$$v^p = w^T \cdot x^p \quad (2.3)$$

Θέτοντας  $v^p = 0 \Rightarrow w^T \cdot x^p = 0$ , βρίσκουμε το οριακό επίπεδο μεταξύ των δύο κατηγοριών. Αν  $X_1 \in C_1$  και  $X_2 \in C_2$ , όπου  $X_1$  και  $X_2$  τα δύο γραμμικώς

διαχωρίσιμα υποσύνολα των διανυσμάτων εκμάθησης, τότε υπάρχει διάνυσμα  $w$  τέτοιο ώστε:

$$w^T \cdot x^P \geq 0, \quad \forall x^P \in C_1$$

$$w^T \cdot x^P \leq 0, \quad \forall x^P \in C_2$$

Ο αλγόριθμος που προτάθηκε από τον Rosenblatt περιγράφεται ως εξής:

*Αν τα υποσύνολα του συνόλου εκμάθησης είναι γραμμικώς διαχωρίσιμα, και οι είσοδοι που δίνονται σε ένα Perceptron ενός στρώματος, ανήκουν σε ένα από αυτά, το Perceptron συγκλίνει μετά από  $n_0$  επαναλήψεις όταν  $wn_0 = w(n_0 + 1) = w(n_0 + 2) = \dots$ , όπου*

$$n_0 \leq n_{max}$$

Ακολουθεί η βήμα προς βήμα συνοπτική απεικόνιση του αλγορίθμου.

Έστω  $x^P = [-1, x_1^P, x_2^P, \dots, x_N^P]^T$  η είσοδος,  $w = [\theta, w_1, w_2, \dots, w_N]^T$  το διάνυσμα βαρών,  $\theta$  το κατώφλι,  $y(x^P)$  η έξοδος του συστήματος,  $d(x^P)$  η επιθυμητή έξοδος και  $n$  ο ρυθμός εκμάθησης με  $0 \leq \eta \leq 1$ . Τότε έχουμε:

- Βήμα 1 - Ορισμός αρχικών βαρών του perceptron (Initialization).
- Βήμα 2 - Ενεργοποίηση. Δίνονται η είσοδος και η επιθυμητή έξοδος.
- Βήμα 3 - Υπολογισμός της πραγματικής εξόδου.

Η έξοδος του perceptron δίνεται από τη σχέση:

$$y(x^P) = \text{sgn} [w^T(n) \cdot x^P] \quad (2.4)$$

όπου,  $\text{sgn}$  η συνάρτηση προσήμου (Signum Function) και  $w^T(n)$  η τιμή του διανύσματος των βαρών στη  $n$ -οστή επανάληψη.

- Βήμα 4 - Προσαρμογή των βαρών.

Η νέα τιμή του βάρους δίνεται από τη σχέση:

$$w(n+1) = w(n) + \eta [d(x^P) - y(x^P)] \cdot x^P \quad (2.5)$$

□ Βήμα 5 - Επανάληψη της διαδικασίας.

Η διαδικασία επαναλαμβάνεται ξεκινώντας από το δεύτερο βήμα.

## **2.4 PERCEPTRON πολλών στρωμάτων (Multilayer)**

Τα perceptron με ένα στρώμα εισόδου, έχουν περιορισμένες δυνατότητες στην επίλυση πολύπλοκων προβλημάτων εξαιτίας του γραμμικού διαχωρισμού των κατηγοριών του συνόλου εκμάθησης που απαιτείται, ενώ επιπλέον οι χρόνοι σύγκλισης γίνονται πολύ μεγάλοι εάν κάποιο διάνυσμα στην είσοδο διαφέρει πολύ σε μέγεθος από τα υπόλοιπα. Γι' αυτό στις περισσότερες περιπτώσεις χρησιμοποιούνται Perceptrons πολλών στρωμάτων (MLP, Multilayer Perceptrons), όπως χρησιμοποιήθηκαν και στην παρούσα εργασία.

Τα MLP εκπαιδεύονται συνήθως με τον αλγόριθμο της αντίστροφης διάδοσης (Back-propagation), ο οποίος βασίζεται στη διόρθωση του μέσου τετραγωνικού σφάλματος και αποτελεί εξέλιξη του αλγορίθμου ελαχίστων μέσων τετραγώνων (LMS, Least Mean Square).

Τα βασικά χαρακτηριστικά των MLP είναι:

1. Οι συναρτήσεις των νευρώνων τους είναι μη γραμμικές και κυρίως συνεχείς και παραγωγίσιμες, σε αντίθεση με το αρχικά προτεινόμενο Perceptron. Συνήθως χρησιμοποιούνται σιγμοειδείς συναρτήσεις όπως η λογιστική και η συνάρτηση  $\tanh(x)$ . Από αυτές τις δύο, η λογιστική προσομοιώνει καλύτερα τη λειτουργία των φυσικών νευρώνων.
2. Το δίκτυο αποτελείται από ένα ή περισσότερα κρυμμένα στρώματα, τα οποία του προσδίδουν χαρακτηριστική ευελιξία καθώς έχουν την ικανότητα να αποσπών σταδιακά, σημαντικές πληροφορίες για τις ιδιότητες της εισόδου.
3. Παρουσιάζουν μεγάλο βαθμό συνεκτικότητας εξαιτίας των συνάψεων.
4. Χαρακτηρίζονται από αιτιατές και χωρίς ανάδραση εξισώσεις. Η έξοδός τους δηλαδή, είναι συνάρτηση αποκλειστικά και μόνο της παρούσας εισόδου.



Αναφέροντας τις ιδιαίτερες ικανότητες των MLP, ας σημειωθεί ότι ένα τέτοιο δίκτυο δύο στρωμάτων μπορεί να εκτελεί όλες τις λογικές συναρτήσεις, ενώ αν προστεθεί ανάδραση, το σύστημα αποτελεί μία αξιόπιστη προσομοίωση ηλεκτρονικού υπολογιστή.

Οι Hush και Horne, συνιστούν τη χρήση περισσότερων στρωμάτων όπου αυτό είναι πραγματικά απαραίτητο. Για παράδειγμα, όταν ένα MLP δύο στρωμάτων απαιτεί για την εκπαίδευσή του περισσότερους νευρώνες, είναι προτιμότερο να χρησιμοποιούνται περισσότερα στρώματα, π.χ. τρία με μικρότερο αριθμό νευρώνων. Αυτά δίνουν και καλύτερα αποτελέσματα. Με βάση αυτή την θεωρία στην παρούσα εργασία επιλέχθηκαν δύο hidden layers για την υλοποίηση του νευρωνικού δικτύου.

Από τα παραπάνω, γίνεται εμφανές ότι η επιλογή μεγέθους του δικτύου είναι εξαιρετικά δύσκολη κατά το σχεδιασμό τους, καθώς μικρό μέγεθος μπορεί να αποδειχθεί ανεπαρκές για την επίλυση του προβλήματος, ενώ ένα πολύ μεγάλο μέγεθος, να δώσει χειρότερα αποτελέσματα εξαιτίας των πολλών βαθμών ελευθερίας.

Μέθοδοι οι οποίες έχουν αναπτυχθεί για τον καθορισμό του μεγέθους ενός τεχνητού νευρωνικού δικτύου είναι οι εξής:

- Επιλογή μεγέθους, έπειτα από δοκιμές εκπαίδευσης δικτύων διαφορετικού αριθμού νευρώνων και δομής και σύγκριση της εξόδου τους με την επιθυμητή έξοδο ξεκινώντας από το μικρότερο δυνατό δίκτυο.
- Προσπάθεια αύξησης του μεγέθους, προσθέτοντας νευρώνες ανάλογα με τις ανάγκες του προβλήματος κατά τη διάρκεια της εκπαίδευσης και
- Μέθοδος κατά την οποία ξεκινώντας με αφετηρία δίκτυο μεγάλου μεγέθους, προχωρούμε καταστρέφοντας τις συνάψεις, που συνεισφέρουν ελάχιστα ή καθόλου στη διαδικασία εκμάθησης. Το ερώτημα που γεννάται σε αυτή την τελευταία περίπτωση, αφορά το ανώτερο όριο του μεγέθους του δικτύου.

***Γενικά, για ένα πλήρως συνδεδεμένο (full-connected) MLP δύο κρυμμένα στρώματα είναι αρκετά, ενώ ο συνολικός αριθμός των νευρώνων που τα αποτελούν είναι συνήθως ανάλογος του μεγέθους του συνόλου εκπαίδευσης, χωρίς όμως να ξεπερνά τον αριθμό των διανυσμάτων εκπαίδευσης***

Κάτι τέτοιο θα είχε ως αποτέλεσμα την σίγουρη απομνημόνευση των δεδομένων εκπαίδευσης από το δίκτυο.

Τέλος, σημειώνεται ότι για την προσέγγιση γραμμικών συναρτήσεων προτείνεται η χρήση γραμμικών νευρώνων (γραμμική συνάρτηση ενεργοποίησης), ενώ για μη γραμμικές συναρτήσεις προτείνονται μη γραμμικοί νευρώνες (μη γραμμική

συνάρτηση ενεργοποίησης). Επίσης, τα δίκτυα με κατώφλι δείχνουν γενικά να αποδίδουν καλύτερα.

## 2.5 Μειονεκτήματα των MLP – Εφαρμογές

Τα κυριότερα μειονεκτήματα των MLP είναι:

- Η δύσκολη θεωρητική τους ανάλυση, εξαιτίας της μη γραμμικότητας, της υψηλής συνεκτικότητας και του έντονου παραλληλισμού που παρουσιάζουν και
- Η απουσία μιας άμεσης και ολοκληρωμένης εικόνας της διαδικασίας εκμάθησης, που οφείλεται στην παρουσία κρυμμένων στρωμάτων.

Παρ' όλα αυτά, βρίσκουν εφαρμογή σε μια τεράστια ποικιλία προβλημάτων που καλύπτουν σχεδόν όλους τους τομείς του σύγχρονου τρόπου ζωής. Οι σημαντικότερες από αυτές τις εφαρμογές είναι:

- Αναγνώριση ομιλίας
- Αναγνώριση χειρόγραφων χαρακτήρων
- Αναγνώριση προτύπων
- Αυτόματος έλεγχος
- Ιατρική διάγνωση, κυρίως όσον αφορά τη διάγνωση καρδιακών επεισοδίων
- Ανίχνευση σήματος ραντάρ και αναγνώριση στόχου

Επιπλέον, υπάρχει και μια σειρά συνεχώς αναπτυσσόμενων εφαρμογών, σε τομείς όπως:

- Αεροναυπηγική
- Αυτοκινητοβιομηχανία
- Αμυντικά συστήματα

- Ηλεκτρονική
- Διασκέδαση-Εικόνα-Ήχος-Κινηματογράφος
- Στρατηγική ασφαλίσεων
- Τραπεζικό σύστημα και οικονομία
- Εκμετάλλευση πετρελαίου και παραγώγων του
- Ρομποτική
- Τηλεπικοινωνίες
- Μεταφορές

## ΚΕΦΑΛΑΙΟ 3: Ο ΑΛΓΟΡΙΘΜΟΣ BACK PROPAGATION

### 3.1 Περιγραφή του αλγορίθμου Αντίστροφης Διάδοσης (BACK PROPAGATION)

Τα MLP, όπως ήδη έχει αναφερθεί, έχουν τη δυνατότητα να επιλύουν ποικίλα και δύσκολα προβλήματα, όταν βασίζονται στον αλγόριθμο αντίστροφης διάδοσης (back-propagation). Ο αλγόριθμος αυτός αποτελεί γενίκευση του αλγορίθμου ελαχίστων μέσων τετραγώνων (Least Mean Square - LMS Algorithm) και έχει σκοπό την ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος μεταξύ της υπολογισμένης από το σύστημα και της επιθυμητής εξόδου. Η εκπαίδευση των νευρωνικών δικτύων, ανάγεται ουσιαστικά στην εύρεση κατάλληλων βαρών για τις συνάψεις. Έτσι, το δίκτυο εκπαιδεύεται επιλέγοντας αρχικά μικρές τυχαίες τιμές για τα βάρη και τα κατώφλια και παρουσιάζοντας στη συνέχεια το σύνολο των παραδειγμάτων επαναληπτικά. Οι τιμές των βαρών αναπροσαρμόζονται σε κάθε επανάληψη, αποσπώντας χαρακτηριστικά των διανυσμάτων εισόδου ώσπου να επιτευχθεί σύγκλιση των βαρών. Στην περίπτωση αυτή η συνάρτηση κόστους (δηλ. το μέσο τετραγωνικό σφάλμα), μειώνεται κάτω από ένα επιτρεπτό όριο.

Η μέθοδος αυτή αποτελείται από δύο μέρη που συνίστανται σε δύο περάσματα μέσα από τα στρώματα του δικτύου:

- α) Την απ' ευθείας διάδοση, κατά την οποία ένα διάνυσμα εφαρμόζεται στην είσοδο του δικτύου και το αποτέλεσμα διαδίδεται από στρώμα σε στρώμα φτάνοντας ως την τελική έξοδο του δικτύου και
- β) Την αντίστροφη διάδοση, στην οποία οφείλεται το όνομά της μεθόδου η οποία πραγματοποιείται ως εξής:

Υπολογίζεται το σφάλμα, δηλαδή η διαφορά μεταξύ επιτευχθείσας και επιθυμητής εξόδου. Στη συνέχεια, το σήμα του σφάλματος διαδίδεται προς τα πίσω συντελώντας στη μεταβολή των τιμών των βαρών.

Οι μεταβλητές που χρησιμοποιεί ο αλγόριθμος, και οι αντίστοιχοι συμβολισμοί τους είναι οι εξής:

$U_{l,j}$  → , Έξοδος του κόμβου  $j$  του στρώματος  $l$

$w_{1,i,j}$  → , Συναπτικό βάρος που συνδέει τον κόμβο  $i$  του στρώματος  $l-1$  με τον κόμβο του στρώματος  $l$

$\vec{x}_p$  → ,  $p$ -οστό πρότυπο του συνόλου εκπαίδευσης

$U_{0,i}$  → ,  $i$ -οστή συντεταγμένη του διανύσματος εισόδου

$d_j(\vec{x}_p)$  → , Επιθυμητή έξοδος του κόμβου  $j$  για το  $p$ -οστό πρότυπο του συνόλου εκπαίδευσης

$N_l$  → , Αριθμός κόμβων του στρώματος  $l$

$L$  → , Πλήθος στρωμάτων

$P$  → , Πλήθος διανυσμάτων εκπαίδευσης

Σημειώνεται ότι  $l = 0$  είναι το στρώμα εισόδου. Επομένως, αν  $\vec{x}_p$  η είσοδος, τότε

$$U_{0,j} = x_j^p, \quad \text{η } j\text{-οστή συντεταγμένη της τρέχουσας εισόδου.}$$

Επίσης, τα κατώφλια ορίζονται ως το πρώτο στοιχείο του διανύσματος εισόδου κάθε στρώματος. Συνεπώς, επειδή η τιμή της εισόδου που αντιστοιχεί στο κατώφλι θεωρείται ίση με ένα, θεωρείται  $U_{l,0} = 1$  για κάθε στρώμα  $l$ . Τέλος, συμβολίζονται με  $w_{l,j,0}$ , οι τιμές των κατωφλίων.

Με βάση τα παραπάνω, καταλήγουμε στο συμπέρασμα ότι η έξοδος του στρώματος  $l$  δίνεται από τη σχέση:

$$U_{l,j} = \varphi\left(\sum_{i=0}^{N_{l-1}} w_{l,j,i} \cdot u_{l-1,i}\right), \quad 0 \leq j \leq N_L \quad (3.1)$$

όπου  $\varphi$  μια μη γραμμική, συνεχής, γνησίως αύξουσα και παραγωγίσιμη συνάρτηση, όπως η σιγμοειδής λογιστική συνάρτηση ή η συνάρτηση υπερβολικής εφαπτομένης, οι οποίες χρησιμοποιούνται ως επί το πλείστον.

Στόχος του αλγορίθμου αυτού είναι η ελαχιστοποίηση της συνάρτησης του μέσου τετραγωνικού σφάλματος:

$$J_w = \sum_{p=0}^P J_p(w) \quad (3.2)$$

Το μέσο τετραγωνικό σφάλμα εξαρτάται από τις ελεύθερες παραμέτρους του δικτύου, δηλαδή τα συναπτικά βάρη, τα οποία και αναπροσαρμόζονται επαναληπτικά. Αν

$$J_p(w) = \frac{1}{2} \sum_{q=1}^{N_L} (U_{L,q}(\vec{x}_p) - d_p(\vec{x}_p))^2 \quad (3.3)$$

όπου  $N_L$  ο αριθμός νευρώνων του στρώματος εξόδου, τότε η μεταβολή στα βάρη περιγράφεται ως εξής:

$$W_{lji}(k+1) = W_{lji}(k) - n \frac{\partial J_w}{\partial w_{lji}} = w_{lji}(k) - n \sum_{p=1}^P \frac{\partial J_w}{\partial w_{lji}} \quad (3.4)$$

όπου, η παράγωγος υπολογίζεται στο  $w(k)$ , που παριστάνει την τιμή του  $w$  την  $k$ -οστή επανάληψη. Με η συμβολίζεται ο ρυθμός εκμάθησης, ενώ  $n$  παράγωγος, υπολογίζεται από τον κανόνα της παραγωγίσισης κατά μέρη:

$$\frac{\partial J_p(w)}{\partial W_{l,j,i}} = \frac{\partial J_p(w)}{\partial U_{l,j}} \cdot \frac{\partial U_{l,j}}{\partial W_{l,j,i}} \quad (3.5)$$

όπου,

$$\frac{\partial U_{l,j}}{\partial W_{l,j,i}} = \frac{\partial}{\partial W_{l,j,i}} [\varphi(\sum_{m=0}^{N_{l-1}} w_{ljm} \cdot u_{p-1,m})] = \varphi' \cdot (\sum_{m=0}^{N_{l-1}} w_{ljm} \cdot u_{l-1,m}) \cdot \frac{\partial}{\partial W_{l,j,i}} (\sum_{m=0}^{N_{l-1}} w_{ljm} \cdot u_{l-1,m}) = \varphi' \cdot (\sum_{m=0}^{N_{l-1}} w_{ljm} \cdot u_{l-1,m}) \cdot u_{l-1,j} \quad (3.6)$$

Στη συνέχεια υπολογίζεται η παράγωγος του  $J_p$  ως προς το  $U_{l,j}$ , η οποία δηλώνει την ευαισθησία της συνάρτησης  $J_p$  ως προς την έξοδο  $U_{l,j}$  του νευρώνα του στρώματος που επιδρά στη συνάρτηση  $J_p$  μέσω όλων των κόμβων του επόμενου στρώματος:

$$\frac{\partial J_p(w)}{\partial U_{l,j}} = \sum_{m=1}^{N_{l+1}} \frac{\partial J_p(w)}{\partial U_{l+1,m}} \cdot \frac{\partial U_{l+1,m}}{\partial U_{l,j}} = \sum_{m=1}^{N_{l+1}} \frac{\partial J_p(w)}{\partial U_{l+1,m}} \cdot \frac{\partial}{\partial U_{l,j}} [\varphi \sum_{q=0}^{N_l} w_{l+i,m,q} \cdot U_{l,q} = \sum_{q=0}^{N_l} w_{l+i,m,q} \cdot U_{l,q} \cdot w_{l+1,m,j} \quad (3.7)$$

Η διαδικασία συνεχίζεται για την παράγωγο  $\frac{\partial J_p(w)}{\partial U_{l+1,m}}$  ώσπου να φτάσουμε στο στρώμα εξόδου, όπου εφαρμόζεται η οριακή συνθήκη:


$$\frac{\partial J_p(w)}{\partial U_{L,j}} = -e_p = U_{L,j}(\vec{x}_p) - d_j(\vec{x}_p) = U_{L,j}(p) - d_j(p)$$

Παρατηρούμε λοιπόν, ότι η διόρθωση της τιμής του βάρους  $w_{ji}$  του στρώματος  $l$  στην  $p$ -οστή επανάληψη, δηλαδή, κατά την παρουσίαση διανύσματος  $p$   $\vec{x}_p$  στην είσοδο του δικτύου, περιγράφεται από τη σχέση:

$$\begin{pmatrix} \text{διόρθωση Βάρους} \\ \Delta w_{l,j,i}(p) \end{pmatrix} = \begin{pmatrix} \text{ρυθμός εκμάθησης} \\ n \end{pmatrix} \cdot \begin{pmatrix} \text{τοπική παράγωγος} \\ \delta_j(p) \end{pmatrix} \cdot \begin{pmatrix} \text{σημα εισόδου} \\ \text{νευρώνα } j \\ \varphi(U_i(p)) \end{pmatrix}$$

Όταν ο νευρώνας  $j$  ανήκει στο στρώμα εξόδου, η τοπική παράγωγος δίνεται από τη σχέση:

$$\delta_j(p) = (U_{L,j}(p) - d_j(p)) \cdot \varphi' U_j(p) \quad (3.8)$$




Σχήμα 3.1: Διάγραμμα ροής για τον νευρώνα  $j$  όταν αυτός ανήκει στο στρώμα εξόδου.

Όταν ο νευρώνας  $j$  ανήκει σε κρυμμένο στρώμα, η τοπική παράγωγος είναι:

$$\delta_j(p) = \varphi' U_j(p) \cdot \sum_k \delta_k(p) \cdot w_{kj}(p) \quad (3.9)$$

Συνεπώς, ο υπολογισμός των τοπικών παραγώγων εξαρτάται από το σταθμισμένο άθροισμα των τιμών των  $\delta$  των νευρώνων που ανήκουν στο επόμενο στρώμα  $l+1$ , και συνδέονται με το νευρώνα  $j$ .



Σχήμα 3.2: Διάγραμμα ροής για το νευρώνα  $j$  όταν αυτός ανήκει σε κρυμμένο στρώμα.

Η λογική, με την οποία πραγματοποιείται η μεταβολή στα συναπτικά βάρη, είναι αυτή της μέγιστης κλίσης (Steepest Descent). Οι διαφορές ελαττώνονται όσο προσεγγίζεται η ελάχιστη τιμή του σφάλματος και μηδενίζονται όταν επιτευχθεί η ελάχιστη τιμή. Οι τιμές των βαρών ελαττώνονται όταν η κλίση της συνάρτησης σφάλματος αυξάνει (αύξουσα συνάρτηση) και αυξάνονται όταν αυτή μειώνεται (φθίνουσα συνάρτηση).

Συνοπτικά, στην απ' ευθείας διάδοση υπολογίζεται η έξοδος του δικτύου και η διαφορά της από την επιθυμητή έξοδο, χωρίς οι τιμές των βαρών να αλλάζουν. Ενώ, στην αντίστροφη διάδοση, υπολογίζεται αρχικά, η τοπική παράγωγος για κάθε νευρώνα του στρώματος εξόδου, και στη συνέχεια με τη βοήθεια αυτών, υπολογίζονται και οι αλλαγές των αντίστοιχων βαρών. Έπειτα, από τις παραγώγους του στρώματος εξόδου υπολογίζονται οι τιμές των παραγώγων του προηγούμενου στρώματος και των αντίστοιχων βαρών κ.ο.κ. Η διαδικασία συνεχίζεται από στρώμα σε στρώμα έως το αρχικό, και αφού ενημερωθούν όλες οι συνάψεις με τις κατάλληλες αλλαγές στα βάρη τους, επαναλαμβάνεται μέχρι το σφάλμα να φτάσει σε ένα επιθυμητό όριο.



Σημαντική για την όλη διαδικασία είναι η επιλογή κατάλληλου ρυθμού εκμάθησης η (Learning Rate Parameter), ο οποίος παίρνει τιμές στο διάστημα (0, 1]. Οι παράγοντες που λαμβάνονται υπ' όψη είναι αλληλοσυγκρουόμενοι, καθώς:

- Μικρή τιμή του η έχει σαν αποτέλεσμα μικρές αλλαγές στα βάρη γεγονός που εξασφαλίζει την ευστάθεια, οδηγεί όμως σε επιβράδυνση της διαδικασίας εκμάθησης.
- Μεγάλη τιμή του η επιταχύνει την εκπαίδευση. Εξαιτίας των μεγάλων αλλαγών στα βάρη, ωθείται το δίκτυο σε αστάθεια.

Η επιλογή του ρυθμού εκμάθησης μπορεί να γίνει με διάφορους τρόπους. Έτσι, είναι δυνατό η τιμή του να είναι ίδια για όλο το δίκτυο ή ακόμη και κάθε βάρος ή στρώμα να έχουν το δικό τους ρυθμό εκμάθησης. Συνήθως, η τελική επιλογή γίνεται έπειτα από πολλές δοκιμές, ωστόσο ένας κανόνας είναι να δίνεται στο η τιμή αντιστρόφως ανάλογη του μέσου μεγέθους των διανυσμάτων κάθε κόμβου.

Μια πολύ καλή μέθοδος με την οποία επιτυγχάνεται αύξηση του ρυθμού εκμάθησης, με αποφυγή της αστάθειας, είναι η εισαγωγή ενός συντελεστή αδρανείας α (Momentum Constant).

Έτσι, η βασική σχέση για τη διόρθωση του βάρους  $w_{ji}$  παίρνει τη μορφή:

$$\Delta w_{l,j,i}(p) = \alpha \Delta w_{ji}(p-1) + n \delta_j(p) \cdot \varphi(U_i(p)) \quad (3.10)$$

όπου  $\varphi(U_i(p))$ , είναι η έξοδος του νευρώνα i που προηγείται του j και συνδέεται με αυτόν μέσω του βάρους  $w_{ji}$ . Από την παραπάνω σχέση, είναι εμφανές ότι η τιμή του βάρους τείνει να αλλάξει προς τη γενική κατεύθυνση του δικτύου, χωρίς να ταλαντώνεται σε κάθε αλλαγή της  $\frac{\partial J_p(w)}{\partial w_{l,j,i}}$ .

Πιο συγκεκριμένα:

- ✓ Όταν η  $\frac{\partial J_p(w)}{\partial w_{l,j,i}}$  έχει το ίδιο πρόσημο σε διαδοχικές επαναλήψεις, η εισαγωγή της σταθεράς α επιταχύνει τη διαδικασία εκμάθησης, ενώ όταν έχει διαφορετικό πρόσημο σε κάθε επανάληψη, το α συντελεί στην ευστάθεια του δικτύου.
- ✓ Η σταθερά αδρανείας α βοηθά τα βάρη να κινούνται προς τις καλύτερες τιμές τους, όταν το δίκτυο βρίσκεται σε μια επίπεδη περιοχή της επιφάνειας σφάλματος, όπου η κλίση είναι  $\frac{\partial J_p(w)}{\partial w_{l,j,i}}$ . Τότε, σε περίπτωση όπου α=0, θα προέκυπτε  $EQ \Delta w_{ji}(p)=0$
- ✓ Η σταθερά αυτή συντελεί στην αποφυγή παγίδευσης του συστήματος σε τοπικό ελάχιστο της επιφάνειας σφάλματος.

Άλλη μέθοδος που χρησιμοποιείται για μεγαλύτερη αξιοπιστία και επιτάχυνση του δικτύου, είναι ο προσαρμοζόμενος ρυθμός εκμάθησης (Adaptive Learning Rate).

Έτσι, όταν  $\frac{J_n(w)}{J_{n-1}(w)} \geq z$

- όπου  $z$ , αριθμός μεγαλύτερος της μονάδας - τότε η τιμή του ρυθμού εκμάθησης μειώνεται,

πολλαπλασιαζόμενη με μια τιμή  $k_1 < 1$  :

$$n_{new} = k_1 \cdot n_{old} \quad (3.11)$$

Αν όμως  $\frac{J_n(w)}{J_{n-1}(w)} \leq z$ , τότε η τιμή του ρυθμού εκμάθησης αυξάνει, καθώς πολλαπλασιάζετε με έναν αριθμό  $k_2 < 1$  :

$$n_{new} = k_2 \cdot n_{old} \quad (3.12)$$

Η παραπάνω διαδικασία, επιτρέπει την αύξηση του ρυθμού εκμάθησης, σε τέτοιο βαθμό ώστε το δίκτυο να μαθαίνει χωρίς το μέσο τετραγωνικό σφάλμα να αυξάνεται. Με τον τρόπο αυτό, η βέλτιστη τιμή του ρυθμού εκμάθησης καθορίζεται από τις τοπικές συνθήκες που επικρατούν κάθε φορά. Αυξάνεται σε περίπτωση ευστάθειας του συστήματος και σύγκλιση του δικτύου και ελαττώνεται αντίστοιχα, σε ανεκτό βαθμό, όταν η τιμή του είναι αρκετά μεγάλη και δεν οδηγεί σε μείωση του σφάλματος.

## 3.2 Εκπαίδευση Προτύπου και Εκπαίδευση κατά Ομάδες

Ο αλγόριθμος Back-Propagation μπορεί να πραγματοποιηθεί με δύο τρόπους όσον αφορά τον τρόπο παρουσίασης των στοιχείων της εκπαίδευσης:

- ✓ Προτύπου (Pattern), και
- ✓ Κατά ομάδες (Batching)

### 3.2.1 Εκπαίδευση προτύπου

Στην εκπαίδευση προτύπου (Pattern mode), η προσαρμογή των βαρών γίνεται μετά την παρουσίαση του κάθε προτύπου στο δίκτυο. Πιο συγκεκριμένα, για  $P$  διανύσματα

εκπαίδευσης,  $[x_1 \cdot d(1)], [x_2 \cdot d(2)], \dots, [x_N \cdot d(N)]$ , δίνεται αρχικά το ζεύγος  $[x_1 \cdot d(1)]$  και εκτελείται τόσο η απ' ευθείας όσο και η αντίστροφη μετάδοση προσαρμόζοντας τα βάρη ανάλογα με το σφάλμα. Στη συνέχεια, δίνεται το δεύτερο ζεύγος,  $[x_2 \cdot d(2)]$  και επαναλαμβάνεται η παραπάνω διαδικασία.

Τα βήματα αυτά πραγματοποιούνται επαναληπτικά για όλο το σύνολο των διανυσμάτων εισόδου - επιθυμητής εξόδου.

Η μέση τιμή  $\Delta w_{l,j,i}$ , της αλλαγής του βάρους  $w_{ji}$  είναι:

$$\begin{aligned} \Delta w_{l,j,i} &= \frac{1}{2} \sum_{p=1}^p \Delta w_{l,j,i}(p) \\ &= -\frac{n}{p} \sum_{p=1}^p \frac{\partial J_p}{\partial w_{l,j,i}(p)} = -\frac{n}{p} \sum_{p=1}^p e_j(p) \cdot \frac{\partial e_j(p)}{\partial w_{l,j,i}(p)} \end{aligned} \quad (3.13)$$

όπου,  $e_j(p) = d_j(p) - U_{L,j}(p)$  και  $n$  ο ρυθμός εκμάθησης.

### 3.2.2 Εκπαίδευση κατά ομάδες

Με τη μέθοδο αυτή, η προσαρμογή των βαρών γίνεται μετά το πέρασμα όλων των στοιχείων των διανυσμάτων εκπαίδευσης. Έτσι, η μέση τιμή  $\mathcal{E}_{av}$  του μέσου τετραγωνικού σφάλματος (SSE, Sum-Squared Error) είναι:

$$\mathcal{E}_{av} = \frac{1}{2P} \sum_{p=1}^p \sum_{j=1}^{N_L} (e_j(p))^2 \quad (3.14)$$

Ενώ, η αλλαγή βάρους για την κατά ομάδες εκπαίδευση (Batching mode) είναι:

$$\Delta w_{l,j,i} = -n \frac{\partial \mathcal{E}_{av}}{\partial w_{j,i}} = -\frac{n}{p} \sum_{p=1}^p e_j(p) \cdot \frac{\partial e_j(p)}{\partial w_{j,i}} \quad (3.15)$$

Συγκρίνοντας τις δύο μεθόδους:

- ✓ κατά την διαδικασία προτύπου, η παρουσίαση των δειγμάτων γίνεται με τρόπο τυχαίο και η αλλαγή των βαρών πραγματοποιείται μετά από κάθε παράδειγμα, ως στοχαστική διαδικασία. Η στοχαστικότητα αυτή που τη χαρακτηρίζει συμβάλλει σημαντικά στην ευελιξία του συστήματος, καθώς μειώνει τις πιθανότητες παγίδευσης του δικτύου κατά την εκπαίδευση σε τοπικό ελάχιστο
- ✓ η εκπαίδευση με την κατά ομάδες διαδικασία επιτρέπει υπολογισμούς με μεγαλύτερη ακρίβεια, κυρίως στις περιπτώσεις όπου το σύνολο των παραδειγμάτων εκμάθησης (Training set) είναι πολύ μεγάλο.

### 3.3 Συνθήκες τερματισμού της εκπαίδευσης

Η διαδικασία αλλαγής των βαρών πραγματοποιείται επαναληπτικά μέχρι το δίκτυο να καταλήξει σε ελάχιστο της επιφάνειας σφάλματος. Αυτό πρακτικά είναι δύσκολο καθώς όσο πιο σύνθετο είναι το πρόβλημα, τόσο πιο σύνθετη γίνεται και η αρχιτεκτονική του νευρωνικού δικτύου που χρειάζεται για την επίλυσή του, με συνέπεια συχνά η εκπαίδευση να καθίσταται εξαιρετικά χρονοβόρα. Έτσι, υπάρχουν κάποια κριτήρια, τα οποία όταν ικανοποιούνται μπορούν να σημάνουν το τέλος της εκπαίδευσης.

Τα κριτήρια αυτά, ή αλλιώς οι συνθήκες τερματισμού, είναι:

1. Η ελαχιστοποίηση της τιμής της κλίσης της επιφάνειας σφάλματος. Στην περίπτωση αυτή μπορεί να θεωρηθεί ότι ο αλγόριθμος τερματίστηκε, αφού εξ' ορισμού η κλίση στο ελάχιστο σημείο της επιφάνειας σφάλματος είναι 0.
2. Η πτώση της τιμής της συνάρτησης  $J(w)$  του μέσου τετραγωνικού σφάλματος κάτω από κάποιο προκαθορισμένο όριο.
3. Ο τερματισμός της εκπαίδευσης μετά από συγκεκριμένο αριθμό επαναλήψεων, χωρίς όμως σε αυτή την περίπτωση να εξασφαλίζεται και η ταυτόχρονη σύγκλιση του δικτύου.
4. Η ικανότητα του δικτύου να γενικεύει. Αυτό αποτελεί και το πιο αξιόπιστο κριτήριο τερματισμού του αλγορίθμου, ενώ η μέθοδος τερματισμού που αντιστοιχεί είναι γνωστή ως "Cross-Validation".

Σύμφωνα μ' αυτή, καθώς το δίκτυο εκπαιδεύεται, παρακολουθείται η συμπεριφορά του σε σχέση με ένα σύνολο διανυσμάτων που χρησιμοποιούνται για δοκιμή και τα οποία δεν ανήκουν στο σύνολο εκπαίδευσης. Με την εξέλιξη της εκπαίδευσης,

παρατηρούμε ότι αρχικά η συμπεριφορά του δικτύου ως προς τα διανύσματα αυτά φαίνεται να βελτιώνεται, κάποια στιγμή όμως αρχίζει να χειροτερεύει. Πρόκειται για τη λεγόμενη περίπτωση κορεσμού του δικτύου, όπου παραπέρα αύξηση του αριθμού των νευρώνων οδηγεί στην υπερεκπαίδευσή του, με συνέπεια την απομνημόνευση των διανυσμάτων του συνόλου εκπαίδευσης. Αυτό, άλλωστε, συνεπάγεται και την κακή συμπεριφορά του συστήματος ως προς οποιοδήποτε άλλο σύνολο διανυσμάτων που παρουσιάζεται στην είσοδό του κατά τη διαδικασία της προσομοίωσης.

Σε αυτό το σημείο, λοιπόν, επιβάλλεται να τερματιστεί ο αλγόριθμος εκμάθησης για μια σωστότερη και πιο ολοκληρωμένη επίλυση του προβλήματος.

Αξιολογώντας τα παραπάνω κριτήρια, σημειώνουμε ότι τα τρία πρώτα είναι πολύ πιθανό να οδηγήσουν σε πρόωρο τερματισμό, ενώ αντίθετα το τελευταίο όχι μόνο δεν οδηγεί σε πρόωρο τερματισμό, αλλά επιπλέον βελτιώνει την ικανότητα γενίκευσης του δικτύου.

Στην παρούσα διπλωματική εργασία, για τον τερματισμό της εκπαίδευσης χρησιμοποιείται συνδυασμός των παραπάνω κριτηρίων, με έμφαση στον τερματισμό της εκπαίδευσης σύμφωνα με τη μέθοδο “Cross- Validation”.

### **3.4 Μέθοδοι βελτίωσης του BACK-PROPAGATION**

Εκτός από την εισαγωγή της σταθεράς ροπής  $a$  και τη χρήση προσαρμοζόμενου ρυθμού εκμάθησης  $\eta$ , υπάρχουν και κάποιες άλλες μέθοδοι βελτίωσης του αλγορίθμου Back-Propagation, όπως :

1. Η χρήση περιττής συνάρτησης ως συνάρτηση ενεργοποίησης, καθώς έχει αποδειχθεί ότι σ' αυτή την περίπτωση ένα MLP μαθαίνει γρηγορότερα. Μια τέτοια συνάρτηση είναι και η συνάρτηση υπερβολικής εφαπτομένης,  $\tanh(x)$ , η οποία χρησιμοποιείται και στη συγκεκριμένη διπλωματική εργασία.
2. Η κωδικοποίηση των δεδομένων σε διάστημα της μορφής  $(\beta+\epsilon, \gamma-\epsilon)$  όπου  $\beta$  και  $\gamma$  τα όρια της συνάρτησης ενεργοποίησης στο  $-\infty$  και στο  $+\infty$  αντίστοιχα και  $\epsilon$  ένας μικρός θετικός αριθμός  $[x_2 \cdot d(2)]$ .
3. Η χρήση αρχικών τιμών για τα συναπτικά βάρη, που ανήκουν σε μικρό διάστημα, ώστε να μην οδηγηθεί το σύστημα σε πρόωρο κορεσμό, εξαιτίας μεγάλων τιμών και πιθανών μεγάλων διαφορών μεταξύ τους.

Αν οι αρχικές τιμές των βαρών είναι τέτοιες ώστε να οδηγούν σε μεγάλες τιμές της εισόδου της συνάρτησης ενεργοποίησης, η έξοδος της θα είναι περίπου -1 ή +1, πράγμα που σημαίνει ότι το δίκτυο βρίσκεται σε κατάσταση πρόωρου κορεσμού.

Πρόωρος κορεσμός (Premature saturation) σημαίνει ότι το μέσο τετραγωνικό σφάλμα παραμένει σταθερό κατά τη διάρκεια κάποιων διαδοχικών επαναλήψεων, με αποτέλεσμα τη σημαντική επιβράδυνση του δικτύου. Ωστόσο, κατά την κωδικοποίηση των τιμών το σχετικό διάστημα δεν πρέπει να είναι υπερβολικά μικρό, επειδή τότε θα είχε ως αποτέλεσμα η παράγωγος  $\frac{\partial J}{\partial w}$  να παίρνει πολύ μικρές τιμές, γεγονός που ισοδυναμεί με μικρές αλλαγές στα βάρη και επομένως χρονοβόρα διαδικασία εκμάθησης.

Προσοχή πρέπει να δοθεί στην περίπτωση εσφαλμένου κορεσμού (Incorrect Saturation), που λαμβάνει χώρα όταν η έξοδος της συνάρτησης ενεργοποίησης είναι +1, ενώ η επιθυμητή έξοδος είναι -1 (ή αντίστροφα). Σε αυτή την περίπτωση η προσαρμογή των βαρών είναι πρακτικά ανύπαρκτη, ενώ ο νευρώνας δύσκολα ξεφεύγει από αυτή την κατάσταση.

4. Η παρουσίαση των διανυσμάτων εκπαίδευσης στο δίκτυο. Στην περίπτωση του pattern mode, θα πρέπει να είναι τυχαία.

5. Η πρόσδοση στο δίκτυο όσο το δυνατόν περισσότερης πληροφορίας σχετικής με το περιβάλλον. Με τον τρόπο αυτό διευκολύνεται περισσότερο το σύστημα στην προσπάθεια προσέγγισης της άγνωστης συνάρτησης μεταξύ εισόδου και επιθυμητής εξόδου, που πραγματοποιεί κατά την εκπαίδευση. Επίσης, μειώνονται σημαντικά οι χρόνοι εκπαίδευσης.

### 3.5 Μειονεκτήματα του BACK-PROPAGATION

Η μέθοδος του αλγόριθμου Back-Propagation είναι η πιο συχνά χρησιμοποιούμενη διαδικασία εκπαίδευσης, αφού μπορεί και προσφέρει ικανοποιητικές λύσεις σε ποικίλα και δύσκολα προβλήματα. Ωστόσο, παρουσιάζει και κάποια μειονεκτήματα, τα οποία αξίζει να σημειωθούν:

A. Εμφανίζει αργή σύγκλιση. Αυτό οφείλεται σε δύο αιτίες:

i) Στην ύπαρξη επιπέδων τμημάτων μεγάλης έκτασης στην επιφάνεια σφάλματος, όπου η παράγωγος της συνάρτησης του μέσου τετραγωνικού σφάλματος ως προς τις ελεύθερες παραμέτρους του δικτύου (δηλ. τα συναπτικά βάρη) είναι πολύ μικρή, με

αποτέλεσμα την αργή προσαρμογή τους. Επιπλέον, εξαιτίας της μικρής τιμής της παραγώγου, τα τμήματα αυτά μπορούν να θεωρηθούν ως ελάχιστα της επιφάνειας σφάλματος και έτσι να τερματιστεί πρόωρα η εκπαίδευση.

ii) Στην υπερβολικά μεγάλη κλίση της επιφάνειας σφάλματος σε κάποια άλλα σημεία, τα οποία οδηγούν σε ακριβώς αντίθετο με πριν αποτέλεσμα. Οι τιμές των βαρών σε αυτή την περίπτωση μεταβάλλονται σημαντικά σε κάθε επανάληψη και είναι πιθανό το ελάχιστο να υπερπηδηθεί.

B. Είναι αρκετά μεγάλη η πιθανότητα παγίδευσης του συστήματος σε τοπικό ελάχιστο. Κατά κανόνα, τα MLP χρησιμοποιούνται για επίλυση μη γραμμικών προβλημάτων, τα οποία υπαγορεύουν τη σύνθεση νευρωνικών δικτύων από μη γραμμικούς νευρώνες, όπου η επιφάνεια σφάλματος παρουσιάζει παραπάνω από ένα ελάχιστα. Σε περίπτωση που το σύστημα παγιδευτεί σε τοπικό ελάχιστο που δεν απέχει πολύ από το ολικό, τότε μπορεί να θεωρηθεί ότι επιτεύχθηκε σύγκλιση χωρίς μεγάλο σφάλμα. Στην αντίθετη όμως περίπτωση, το αποτέλεσμα δε μπορεί να κριθεί ικανοποιητικό. Η εκπαίδευση επαναλαμβάνεται με διαφορετικό αριθμό νευρώνων, στρωμάτων, αρχικών τιμών για τα βάρη και διαφορετικό ρυθμό εκμάθησης, χωρίς όμως και αυτό να εγγυάται τη σύγκλιση του δικτύου σε ολικό ελάχιστο .

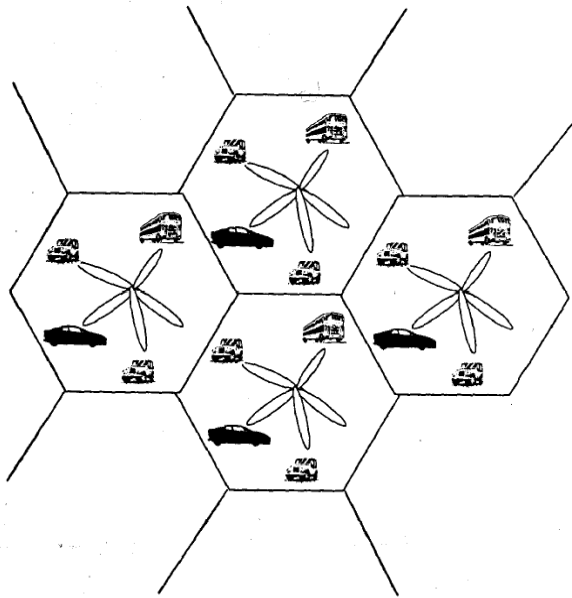
## ΚΕΦΑΛΑΙΟ 4:

# ΕΦΑΡΜΟΓΕΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΚΙΝΗΤΕΣ ΕΠΙΚΟΙΝΩΝΙΕΣ

### 4.1 Εισαγωγή


Τα νέα ασύρματα συστήματα, όπως οι κυψελωτές επικοινωνίες, τα προσωπικά συστήματα επικοινωνιών (*Personal Communications Systems - PCSs*) και τα προσωπικά δίκτυα επικοινωνιών (*Personal Communications Networks - PCNs*), θα πρέπει να ικανοποιούν όλο και περισσότερο την απαίτηση για κάλυψη, χωρητικότητα και ποιότητα υπηρεσιών. Για τον λόγο αυτό χρειαζόμαστε πιο ισχυρά εργαλεία, για να βελτιώσουμε τις διαφορετικές απαιτήσεις των νέων επικοινωνιακών συστημάτων που γίνονται όλο και πιο σημαντικές. Το επιστημονικό πεδίο της διαδικασίας ή του αλγορίθμου επεξεργασίας σήματος (*array signal processing*), όπου τα πλεονεκτήματα της τεχνικής επεξεργασίας σήματος συνδέονται με την αρχή λειτουργίας των συστοιχιών των κεραιών, προσφέρει ορισμένες πολλά υποσχόμενες καινοτομίες. Οι ικανότητες των ήδη υπάρχοντων ασύρματων συστημάτων περιορίζονται από μη σταθερή επεξεργασία σήματος και δεν μπορούν να ανταπεξέλθουν σε προβλήματα όπως η παρεμβολή μεταξύ των καναλιών (*cochannel interference – CCI*). Το πρόβλημα αυτό είναι ο πιο σοβαρός παράγοντας περιορισμού της χωρητικότητας των καναλιών επικοινωνίας. Καθώς ο αριθμός των χρηστών (*users*) αυξάνεται, κυρίως σε πυκνοκατοικημένες περιοχές, η πιθανότητα των παρεμβολών του ενός χρήστη με τον άλλον αυξάνεται. Οπότε οι τεχνικές πολλαπλής πρόσβασης χρησιμοποιούνται για να αυξάνουν τον αριθμό των χρηστών που ένα σύστημα μπορεί να εξυπηρετήσει. Ωστόσο, υπάρχουν ακόμα ορισμένοι περιορισμοί, όπως η διαθεσιμότητα του εύρους ζώνης (*Bandwidth - BW*) στην πολλαπλή πρόσβαση με διαίρεση συχνότητας (*Frequency Division Multiple Access - FDMA*) στα αναπτυγμένα συστήματα κινητών τηλεφώνων ή ο χρόνος στην πολλαπλή πρόσβαση με διαίρεση χρόνου (*Time Division Multiple Access – TDMA(IS - 136)*) ή ο αριθμός των καλών – σωστών κωδικών στα συστήματα με πολλαπλή πρόσβαση με διαίρεση κώδικα (*Code Division Multiple Access – CDMA(IS - 95)*). Ο πιο αποτελεσματικός τρόπος για να αυξήσουμε την χωρητικότητα ενός κυψελωτού συστήματος επικοινωνιών είναι η επαναχρησιμοποίηση της συχνότητας. Με την επαναχρησιμοποίηση της ίδιας συχνότητας σε δύο διαφορετικές κυψέλες είναι αρκετά ευδιάκριτοι οι χρήστες, οπότε οι χρήστες της μιας κυψέλης δεν παρεμβάλλονται με τους χρήστες της άλλης κυψέλης και το *cochannel interference* περιορίζεται, όπως φαίνεται στο σχήμα 4.1.





**Σχήμα 4.1:** Γεωμετρία κυψέλης για κυψελωτές και κινητές επικοινωνίες.

Η παρεμβολή περιορίζει επίσης και την χωρητικότητα στα προσωπικά συστήματα επικοινωνιών που βασίζονται στις δορυφορικές επικοινωνίες. Στους δορυφόρους που βρίσκονται στις γεωστατικές τροχιές υπάρχει παρεμβολή μεταξύ τους όπως επίσης και στους δορυφόρους που βρίσκονται σε χαμηλές τροχιές (*Low Earth Orbits – LEO*). Υπάρχουν επίσης σήματα στενής και ευρείας ζώνης (*narrowband & broadband interference*) τα οποία δυνητικά δημιουργούν προβλήματα παρεμβολών σε συστήματα GPS. Συνεπώς, η απόρριψη των παρεμβολών είναι πολύ σημαντική και ο τρόπος για να αυξήσουμε την χωρητικότητα ενός συστήματος ορίζοντα σε μικρότερες μεταξύ τους αποστάσεις τις ομοκαναλικές κυψέλες δεν απαιτεί υψηλό κόστος. Για την λύση αυτού του προβλήματος, πρώτον χρησιμοποιούμε τον **αλγόριθμο της διεύθυνσης άφιξης των σημάτων (*Direction of Arrival – DOA*)**, ο οποίος μας βοηθά να εντοπίζουμε τα σήματα και τους κινητούς χρήστες που παρεμβάλλονται μεταξύ τους (*cochannel mobile users*). Δεύτερον, μπορεί να χρησιμοποιηθεί μια συστοιχία κεραιών, για να κατευθύνει την ακτινοβολούμενη δέσμη προς τους κινητούς χρήστες που μας ενδιαφέρουν και να ακυρώσει – μηδενίσει τις άλλες δέσμες – πηγές που αποτελούν τις παρεμβολές – παράσιτα όταν όλες οι δέσμες βρίσκονται στην ίδια συχνοτική θυρίδα (*frequency slot*), όπως φαίνεται στο σχήμα 4.2. Επιπλέον η Ομοσπονδιακή Επιτροπή Επικοινωνιών (*Federal Communications Commission – FCC*), πρότεινε 911 υπηρεσίες για την παροχή των οποίων απαιτείται η θέση του χρήστη να είναι περίπου εντός 125 μέτρων ή λιγότερο. Για να πετύχει αυτό, θα πρέπει να εφαρμοστούν οι τεχνικές ευρέσεως της θέσης του σήματος.



**Σχήμα 4.2:** Συστοιχία κεραιών εκτελώντας beamforming για κινητές επικοινωνίες.

Ταυτόχρονα, οι αλγόριθμοι επίλυσης, όπως ο αλγόριθμος *Multiple Signal Classification - MUSIC* και ο αλγόριθμος *ESPRIT*, μπορούν να χρησιμοποιηθούν για να εκτελέσουν την εύρεση διεύθυνσης ή την γωνία άφιξης των σημάτων για τους κινητούς χρήστες. Ένα όμως μειονέκτημα αυτών των αλγορίθμων είναι η δυσκολία της υλοποίησης τους σε πραγματικό χρόνο διότι έχουν πολύπλοκους υπολογισμούς. Από την άλλη μεριά, τα νευρωνικά δίκτυα, λόγω του ότι έχουν την ικανότητα πολύ γρήγορων υπολογισμών, μπορούν να αποδίδουν αποτελέσματα σε πραγματικό χρόνο. Αυτό οδηγεί σε ακριβή εκτίμηση της θέσης του κινητού χρήστη σε μικρό σταθερό διάστημα της τάξης των 100 nsec (με την προϋπόθεση ότι το νευρωνικό έχει εκπαιδευτεί πρώτα off-line). Αυτό καθιστά ικανό το σύστημα να εκτιμήσει την διεύθυνση πολλαπλών χρηστών, ακόμα και αν αυτοί κινούνται. Επιπρόσθετα, τα νευρωνικά επιτυγχάνουν υψηλό βαθμό σύγκλισης στον μηχανισμό της προσαρμογής δέσμης (*adaptive beamforming*) αναδεικνύοντας τις επιθυμητές διευθύνσεις και ακυρώνοντας τις ανεπιθύμητες, επειδή τα βάρη της συστοιχίας των κεραιών μπορούν να υπολογιστούν σε πραγματικό χρόνο.

## 4.2 Προσαρμοζόμενη συστοιχία κεραιών επεξεργασίας σήματος (*Adaptive Antenna Array Processing*)

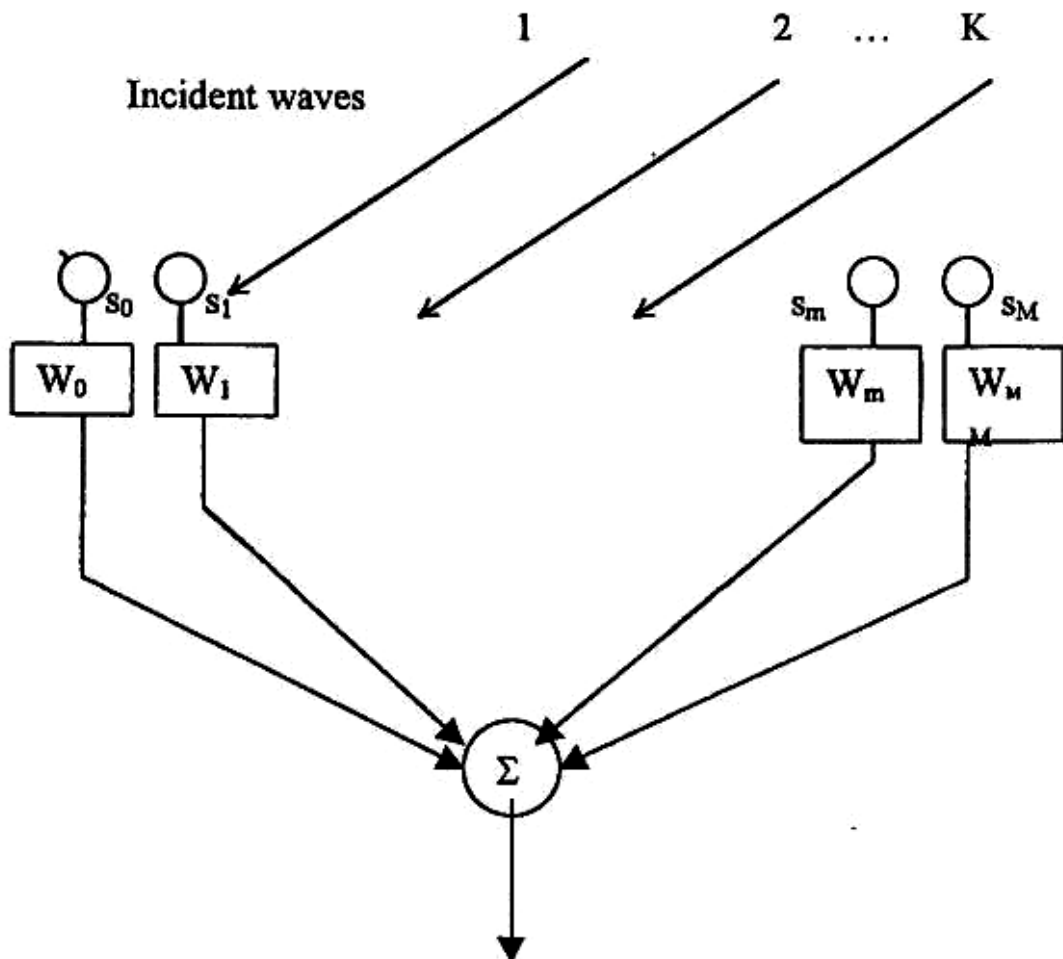
Μια συστοιχία κεραιών αποτελείται από αισθητήρες, οι οποίοι διαχωρίζονται μεταξύ τους και των οποίων η έξοδος τροφοδοτεί το δίκτυο των βαρών ή το δίκτυο του διαμορφωτή δέσμης (*beamforming*). Μπορούμε να υποθέσουμε ότι τα προσπίπτοντα σήματα συγκροτούνται από ένα πεπερασμένο αριθμό επιπέδων κυμάτων. Επιπλέον, οι αισθητήρες υποτίθεται ότι είναι ολόιδια ιστροπικά στοιχεία. Μπορούμε να τους

διατάξουμε σε οποιοδήποτε γεωμετρικό σχηματισμό, κυρίως γραμμικό ή επίπεδο ή κυκλικό.

Υποθέτουμε μια συστοιχία κεραιών που αποτελείται από  $M$  στοιχεία, όπως φαίνεται στο σχήμα 4.3. Έστω  $K$  ( $K < M$ ) τα στενής ζώνης επίπεδα κύματα, κεντραρισμένα στην συχνότητα  $\omega$ , τα οποία κατευθύνονται στην συστοιχία από διάφορες διευθύνσεις – γωνίες πρόσπτωσης ( $\theta_1, \theta_2, \dots, \theta_K$ ).

Χρησιμοποιώντας μιγαδική έκφραση για το σήμα, το λαμβανόμενο σήμα στο  $i$ -οστό στοιχείο δίνεται από την σχέση:

$$x_i(t) = \sum_{m=1}^k S_m(t) e^{-j(i-1)km} + n_i(t) \quad \text{όπου } i = 1, 2, \dots, M \quad (4.1)$$



**Σχήμα 4.3:** Προσπίπτοντα κύματα  $s_m$  γραμμικής προσαρμοστικής συστοιχίας κεραιών με βάρη  $W_m$  όπου  $s_m(t)$  είναι το σήμα του  $m$ -οστού κύματος,  $n_i(t)$  είναι το σήμα θορύβου που λαμβάνεται από τον  $i$ -οστό αισθητήρα.

**Στην παρούσα εργασία δεν προστέθηκε θόρυβος.** Ο κυματάριθμος  $km$  δίνεται από την σχέση:

0 sin( )

$$K_m = \frac{\omega_0 d}{c} \sin(\vartheta_m) \quad 4.2$$

όπου  $d$  είναι η απόσταση μεταξύ των στοιχείων και  $c$  είναι η ταχύτητα του φωτός στον ελεύθερο χώρο. Χρησιμοποιώντας διανύσματα μπορούμε να γράψουμε την συστοιχία εξόδου με την μορφή πινάκων:

$$X_t = AS_t + N_t \quad 4.3$$

όπου  $\mathbf{X}(t)$ ,  $\mathbf{S}(t)$  και  $\mathbf{N}(t)$  δίνονται από τις σχέσεις:

$$X_{(t)} = [x_1(t) x_2(t) \dots x_M(t)] \quad 4.4$$

$$N_{(t)} = [n_1(t) n_2(t) \dots n_M(t)] \quad 4.5$$

$$S_{(t)} = [s_1(t) s_2(t) \dots s_M(t)] \quad 4.6$$

όπου με [...]Τ παριστάνουμε τον ανάστροφο πίνακα και ο  $\mathbf{A}$  είναι ένας πίνακας  $M \times K$  διαστάσεων και ορίζεται από την σχέση:

$$A = [\alpha(\theta_1) \alpha(\theta_2) \dots \alpha(\theta_k)] \quad 4.7$$

με  $\alpha(\theta_i)$  το διάνυσμα οδήγησης (*steering vector*) της συστοιχίας προς την διεύθυνση  $\theta_i$ :

$$a(\theta_i) = [1 e^{-jk_i} e^{-j2k_i} \dots e^{-j(M-1)k_i}] \quad 4.8$$

Αν υποθέσουμε ότι τα σήματα θορύβου ( $n_i, i=1:M$ ) λαμβάνονται από διαφορετικούς αισθητήρες, τότε αυτά είναι στατιστικά ανεξάρτητα από τον λευκό θόρυβο (*white noise*) που έχει διακύμανση  $\sigma^2$ , ενώ παράγουν έναν χωρικό πίνακα συσχέτισης (*spatial correlation matrix*)  $\mathbf{R}$ , που δίνεται από την σχέση:

$$R = E\{x_{(t)} x^H(t)\} = APA^H + \sigma^2 I = \sum_{i=1}^M \lambda_i e_i e_i^H \quad 4.9$$

όπου  $P = E\{S(t)S^H(t)\}$  ο πίνακας των σημάτων συσχέτισης. Με τον συμβολισμό “H” παριστάνουμε τον ανάστροφο συζυγή πίνακα και με “I” παριστάνουμε τον μοναδιαίο. Να σημειώσουμε στο σημείο αυτό πως ο πίνακας  $\mathbf{P}$  είναι διαστάσεων  $K \times K$ , ενώ ο  $\mathbf{R}$  είναι διαστάσεων  $M \times M$ . Επίσης

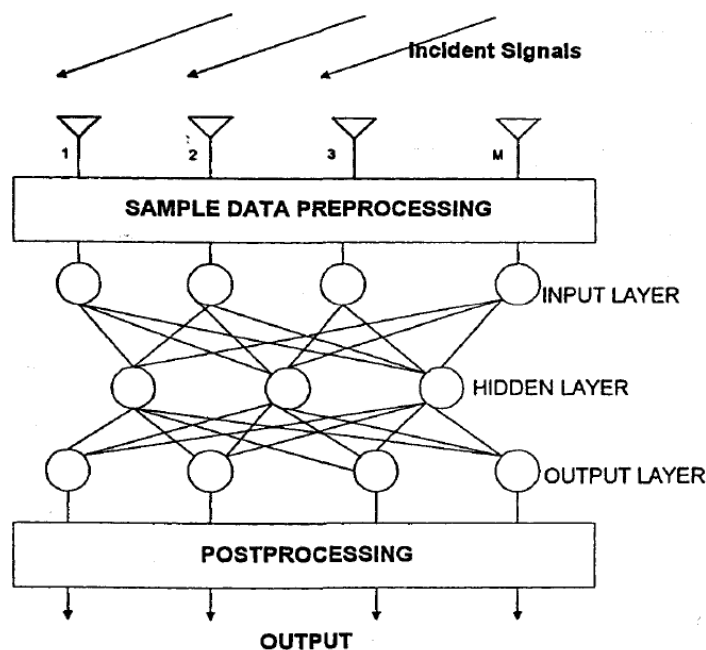
$\lambda_1 \geq \lambda_2 \geq \lambda_k \geq \lambda_k + 1 \dots \geq \lambda_M = \sigma^2$ , είναι οι χαρακτηριστικές ρίζες του πίνακα  $\mathbf{R}$  και  $e_i$  είναι το ορθοκανονικό χαρακτηριστικό διάνυσμα.

### 4.3 Νευρωνικό Δίκτυο Βασισμένο στην Εύρεση Διεύθυνσης

Μέχρι τώρα, διάφοροι αλγόριθμοι, όπως ο MUSIC, όπως ο αλγόριθμος της ελάχιστης διακύμανσης με την ελάχιστη απόκριση παραμόρφωσης (Minimum Variance Distortionless Response – MVDR) και όπως ο αλγόριθμος της ελάχιστης νόρμας (Minimum Norm – MinNorm), έχουν εφαρμοστεί επιτυχώς στο πρόβλημα της

εκτίμησης της διεύθυνσης άφιξης των σημάτων. Αυτό επιτυγχάνεται με τον εντοπισμό και την ιχνηλάτηση των πηγών που ακτινοβολούν με την προσθήκη θορύβου, ασυσχέτιστων και συσχετισμένων σημάτων. Η καλύτερη ανάλυση είναι ότι οι τεχνικές αυτές έχουν την ικανότητα να βασίζονται σε ισχυρές υπολογιστικές προσεγγίσεις, περιλαμβάνοντας την χαρακτηριστική λύση του πίνακα συσχέτισης από τα δεδομένα μιας συστοιχίας κεραιών. Από την άλλη πλευρά, οι νευρωνικοί beamformers έχουν το πλεονέκτημα της γρήγορης σύγκλισης και μπορούν εύκολα να προσδιορίσουν την γωνία άφιξης του σήματος και να αφήσουν την κεραία να ιχνηλατήσει το σήμα σε πραγματικό χρόνο.

Το πρόβλημα της DOA είναι προσεγγίσιμο, με την σχεδίαση ενός μοντέλου, χρησιμοποιώντας ένα κατάλληλο τεχνητό εκπαιδευμένο NN με ζεύγη εισόδων – εξόδων. Το δίκτυο είναι πλέον ικανό να εκτιμήσει ή να προβλέψει τις εξόδους που δεν περιλαμβάνονται στην φάση της εκμάθησης δια μέσου της γενίκευσης. Στον δικό μας πρόβλημα επιλέξαμε ένα RBF – NN, όπως φαίνεται στο σχήμα 4.4 με τα τμήματα προεπεξεργασίας στην είσοδο και τα τμήματα μεταεπεξεργασίας στην έξοδο.



**Σχήμα 4.4:** NN βασισμένο στην προσαρμοζόμενη συστοιχία επεξεργασίας σήματος

### 4.3.1 Αρχιτεκτονική Νευρωνικού Δικτύου


Η αρχιτεκτονική που χρησιμοποιείται σε ιδιαίτερα προβλήματα αποτελείται από τρία επίπεδα (σχήμα 4.5):

- i. το επίπεδο εισόδου (*input layer*) (κόμβοι αισθητήρων)

ii. το κρυμμένο επίπεδο υψηλών διαστάσεων (*hidden layer*)

iii. το επίπεδο εξόδου.

Ο μετασχηματισμός από τον χώρο εισόδου στην μονάδα του κρυμμένου επιπέδου είναι μη – γραμμικός, ενώ ο μετασχηματισμός από το κρυμμένο επίπεδο στον χώρο εξόδου είναι γραμμικός.



**Σχήμα 4.5:** Αρχιτεκτονική τριών επιπέδων RBF – NN που χρησιμοποιείται για εύρεση της διεύθυνσης άφιξης των σημάτων

Η συστοιχία εκτελεί την απεικόνιση (*mapping*)  $G : R^k \rightarrow C^M$  από τον χώρο της DOA,  $\{\theta = [\theta_1, \theta_2, \dots, \theta_K]\}$  στον χώρο εξόδου των αισθητήρων  $\{s = [s_1, s_2, \dots, s_M]\}$ , δηλαδή:

$$s_m = \sum_{k=1}^K a_k e^{i(m \frac{\omega_0}{c} d \sin \theta_k + a_k)} \quad 4.10$$

Αυτό σημαίνει πως για κάθε τυχαίο σήμα  $s_m$ , υπάρχει μια γωνία άφιξης  $\theta_m$ .  $K$  είναι ο αριθμός των σημάτων,  $M$  είναι ο αριθμός των στοιχείων της γραμμικής στοιχειοκεραίας,  $a_k$  είναι το μιγαδικό πλάτος του  $k$  – οστού σήματος. Τέλος,  $a_k$  είναι η αρχική φάση και  $\omega_0$  η αρχική συχνότητα.

Ένα NN χρησιμοποιείται για να εκτελέσει την ανάστροφη απεικόνιση  $F : C^M \rightarrow R^k$ . Το δίκτυο θα εκπαιδευτεί με  $N$  ομάδες δεδομένων εισόδου που παράγονται από την σχέση (4.3), οπότε μπορούμε να συνδέσουμε τα διανύσματα εξόδου  $s(1), s(2), \dots, s(N)$  με τα αντίστοιχα διανύσματα της DOA  $\theta_1, \theta_2, \dots, \theta_N$ . Τα

διανύσματα  $\mathbf{s}$  υπολογίζονται διαμέσου του hidden layer και στην συνέχεια οι τιμές των κόμβων εξόδου έχουν υπολογιστεί με βάση το άθροισμα των τιμών των εξόδων του hidden layer. Οπότε, μπορούμε να γράψουμε για την ομάδα των δεδομένων  $\{(s_{(i)}, \theta_{(i)}, i) = 1, 2, \dots, N\}$ :

$$\theta_k(j) = \sum_{i=1}^N w_i^k b(\|s_{(j)} - s_{(i)}\|^2) \text{ 'οπου } k = 1, \dots, K \text{ και } j = 1, \dots, N \quad 4.11$$

όπου  $w_i^k$  αντιπροσωπεύει το βάρος (*weight*) από τον  $i$  – οστό κόμβο του hidden layer προς τον  $k$  – οστό κόμβο του επιπέδου εξόδου, όταν στην είσοδο του δικτύου δοθεί η  $j$  – οστή ομάδα δεδομένων του. Χρησιμοποιώντας την Γκαουσιανή εξίσωση μπορούμε την παραπάνω σχέση να την γράψουμε:

$$\theta_k(j) = \sum_{i=1}^N w_i^k e^{-\frac{\|s_{(j)} - s_{(i)}\|^2}{\sigma_g^2}} \quad 4.12$$

όπου η παράμετρος  $\sigma_g^2$  ελέγχει την επίδραση κάθε βασικής εξίσωσης.

### 4.3.2 Είσοδος Νευρωνικού Δικτύου

Αρχικά, παράγουμε τα διανύσματα εξόδου της στοιχειοκεραίας που προκύπτουν από τα προσπίπτοντα κύματα. Επειδή στο πρόβλημα της DOA η αρχική φάση  $\alpha$  των σημάτων δεν περιέχει πληροφορίες για την διεύθυνση άφιξης των σημάτων, την αποκλείουμε από τα δεδομένα εκπαίδευσης (*training data*). Στη συνέχεια μετασχηματίζονται σε κατάλληλα διανύσματα εισόδου που παρουσιάζονται στο δίκτυο. Ο μετασχηματισμός των διανυσμάτων γίνεται με βάση τον πίνακα συσχέτισης που προκύπτει από το συνολικό πλήθος των προσπίπτοντων σημάτων και τα διανύσματα οδήγησης της κεραίας. Συνεπώς το  $m$  – οστό στοιχείο του πίνακα συσχέτισης το οποίο παριστάνει την συσχέτιση μεταξύ του σήματος στο  $m$  – οστό και στο  $m'$  – οστό στοιχείο της κεραίας και περιγράφεται από το γινόμενο των δύο σημάτων είναι:

$$R_{mm'} = \sum_{k=1}^K p_k e^{1(m-m')\omega_0 d \sin \theta / c} + \delta R_{mm} \quad 4.13$$

όπου  $p_k$  αντιπροσωπεύει την ισχύ του  $k$  – οστού σήματος. Επειδή για  $m = m'$ , το  $R_{mm}$  δεν μεταφέρει καμιά πληροφορία για την DOA ( $R_{mm} = \sum_{k=1}^K p_k$ ), οπότε μπορούμε να ανακατατάξουμε τα υπόλοιπα στοιχεία σε ένα νέο διάνυσμα εισόδου,  $\mathbf{b}$ , το οποίο μπορούμε να το ορίσουμε ως:

$$\mathbf{b} = [R_{21}, R_{31}, \dots, R_{M1}, R_{12}, R_{32}, \dots, R_{M2}, \dots, R_{1M}, R_{2M} \dots R_{M(M-1)}) \quad 4.14$$

Παρατηρούμε πως το διάνυσμα  $\mathbf{b}$  έχει  $M(M-1)$  στοιχεία εισόδου. Απαιτείται διπλάσιος αριθμός κόμβων για το νευρωνικό δίκτυο, διότι οι αριθμοί έχουν πραγματικό και φανταστικό μέρος. Ο συνολικός αριθμός των κόμβων εισόδου που

χρειαζόμαστε είναι  $2M(M-1)$ . Οι διαστάσεις του hidden layer είναι ισοδύναμες με τον αριθμό των Γκαουσιανών εξισώσεων  $L$  οι οποίες μπορούν να επιλεγούν να είναι ίσες με  $N$ . Προφανές είναι ότι ο αριθμός των κόμβων εξόδου, θα είναι ίσος με τον αριθμό των σημάτων  $K$ . Στην συνέχεια κανονικοποιούμε το διάνυσμα εισόδου  $\mathbf{b}$  ως προς το μέτρο του:

$$= \mathbf{b} / \|\mathbf{b}\| \quad 4.15$$

## 4.4 Διαδικασία εκπαίδευσης του Νευρωνικού Δικτύου και αποτελέσματα

### 4.4.1 Εκπαίδευση Νευρωνικού Δικτύου

Σκοπός μας ήταν η δημιουργία δεδομένων εκπαίδευσης με βάση τον αριθμό των στοιχείων της κεραίας, τον αριθμό των σημάτων και το πλήθος των θέσεων, ως προς την γωνία των σημάτων. Έτσι παραμετροποιώντας τα παραπάνω θεωρήσαμε πως έχουμε μια κεραία  $M$  στοιχείων, όπου αυτά απέχουν μεταξύ τους απόσταση  $d$ . Το πλήθος των σημάτων είναι  $K$  και αυτών την διεύθυνση άφιξης πρέπει να προσδιορίσουμε. Για την δημιουργία των *training sets* θεωρούμε  $N$  διαφορετικούς συνδυασμούς γωνιών άφιξης των  $K$  σημάτων. Η διαδικασία με την οποία δημιουργήσαμε τα δεδομένα και τα απαραίτητα βήματα για την εκπαίδευση του NN, συνοψίζεται στα παρακάτω βήματα:

1. Αρχικά δημιουργήσαμε τα διανύσματα εξόδου:

$$\begin{aligned} \bar{S}(1) &\rightarrow \{S_1(1), S_2(1), S_3(1), \dots, S_M(1)\} \\ \bar{S}(2) &\rightarrow \{S_1(2), S_2(2), S_3(2), \dots, S_M(2)\} \\ &\dots\dots\dots \\ \bar{S}(N) &\rightarrow \{S_1(N), S_2(N), S_3(N), \dots, S_M(N)\} \end{aligned}$$

χρησιμοποιώντας την σχέση:

$$S_i(n) = \sum_{k=1}^K s_m \exp[-j(m-1)\beta d \cos\theta_m] \quad 4.16$$

όπου το  $m$  μεταβάλλεται από 1 έως  $M$  (max αριθμός στοιχείων κεραίας),  $S_m$  είναι η ισχύς του σήματος και το  $n$  μεταβάλλεται από 1 έως  $N$ , δηλαδή τα training sets. Η παραπάνω σχέση προέρχεται από την σχέση (4.3).

2. Στην συνέχεια για κάθε ένα από τα παραπάνω διανύσματα εξόδου, υπολογίζουμε τον πίνακα συσχέτισης. Για τον υπολογισμό του μπορούμε να χρησιμοποιήσουμε την



σχέση (4.13), η οποία προέρχεται από την (4.9). Τα στοιχεία των πινάκων συσχέτισης (που είναι τριών διαστάσεων) δίνονται από την σχέση:

$$R_{mm} \cdot (m, m', n) \sum_{k=1}^K p_k \exp[j(\omega_0 k - (m - m')\omega_0 d \cos \theta_m)] \quad 4.17$$

και τελικά ο πίνακας συσχέτισης είναι:

$$R_{(n)} = \begin{pmatrix} R_{11}(n) & R_{12}(n) & \dots & R_{1M}(n) \\ R_{21}(n) & R_{22}(n) & \dots & R_{2M}(n) \\ \vdots & \vdots & \ddots & \vdots \\ R_{M1}(n) & R_{M2}(n) & \dots & R_{MM}(n) \end{pmatrix} \quad 6.18$$

Στον πίνακα αυτό βρίσκονται οι όροι

$$R_{11}(n) = \sum_{k=1}^K p_k, R_{22}(n) = \sum_{k=1}^K p_k, \dots, R_{MM}(n) = \sum_{k=1}^K p_k$$

οι οποίοι δεν περιέχουν καμιά πληροφορία για την διεύθυνση άφιξης των σημάτων, άρα κρίνονται περιττοί.

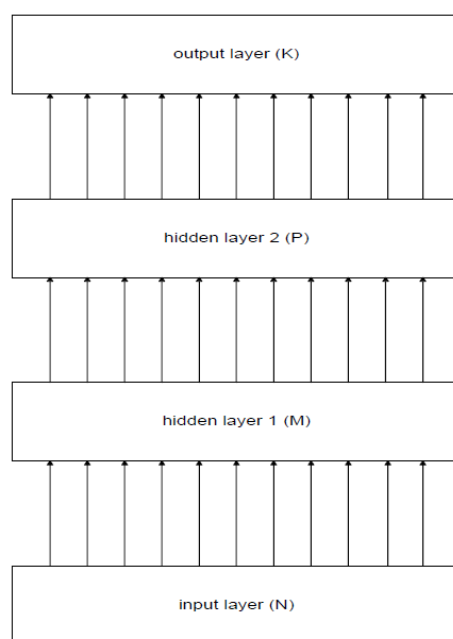
**3.** Στην συνέχεια, υπολογίσαμε τα στοιχεία του διανύσματος  $\mathbf{b}(\mathbf{n})$ , τα οποία είναι ένα διάνυσμα διαστάσεων  $M(M-1)$ , δεν περιέχει τα διαγώνια στοιχεία του πίνακα συσχέτισης (σχέση 4.18) και αποτελεί διάνυσμα γραμμή. Υπολογίζεται από την σχέση (4.14)

**4.** Ακολούθησε η δημιουργία των training set χρησιμοποιώντας την σχέση (4.15), στην οποία κάθε training set αποτελείται από πραγματικούς και φανταστικούς αριθμούς και από τις γωνίες άφιξης των σημάτων ( $\theta(\mathbf{n})$ ). Τα διανύσματα  $z(n)$  που προέκυψαν είναι αυτά που θα χρησιμοποιηθούν στο input layer του νευρωνικού δικτύου και αποτελούν αυτά με τα οποία θα υπολογίσουμε τα βάρη και θα γίνουν οι αντίστοιχες διορθώσεις των βαρών των νευρώνων από τους κόμβους του hidden layer προς τους κόμβους εξόδου.

Στο παράρτημα Β παραθέτουμε όλους τους αλγορίθμους εκπαίδευσης οι οποίοι υλοποιήθηκαν στην τεχνική γλώσσα προγραμματισμού MATLAB.

Η παραπάνω μεθοδολογία της RBF – NN έχει ένα πολύ βασικό πλεονέκτημα έναντι των άλλων προσεγγίσεων **δεν απαιτεί την εκπαίδευση του δικτύου με όλους τους πιθανούς συνδυασμούς των διανυσμάτων εισόδου**

Το νευρωνικό δίκτυο με το οποίο έγιναν όλοι οι υπολογισμοί δίνεται από το παρακάτω block διάγραμμα:



**Σχήμα 4.6:** Block Διάγραμμα Νευρωνικού Δικτύου

όπου με  $N$ ,  $M$ ,  $P$  και  $K$  παριστάνονται οι κόμβοι στα αντίστοιχα επίπεδα του NN. Το λογισμικό προσομοίωσης των NN περιείχε ορισμένους δείκτες όπως:

1. Learning rate, που εκφράζει τον ρυθμό εκπαίδευσης που τον είχαμε θέσει ως default σε όλα τα layers εκτός από το πρώτο που το θέσαμε Kohonen.
2. Learning rule, που εκφράζει τον ρυθμό με τον οποίο γίνεται η εκπαίδευση από το ένα layer στο άλλο. Από το input στο πρώτο hidden είχαμε  $K - \text{means}$  και σε όλες τις υπόλοιπες διασυνδέσεις Delta rule
3. Summation, αποτελεί τον τρόπο με τον οποίο θα μεταφέρονται τα data καθενός perceptron από το ένα layer στο άλλο και το είχαμε θέσει στο sum.
4. Transfer, αποτελεί τον τύπο της εξίσωσης ενεργοποίησης (activation function) σε κάθε ένα layer και χρησιμοποιήθηκε η Radial Basis Function από το input στο πρώτο hidden και η υπερβολική εφαπτομένη (tanh) σε όλα τα υπόλοιπα.
5. RMS error, ανάλογα με την τιμή που προέκυπτε έδειχνε το πόσο καλά είχε εκπαιδευτεί το νευρωνικό δίκτυο.

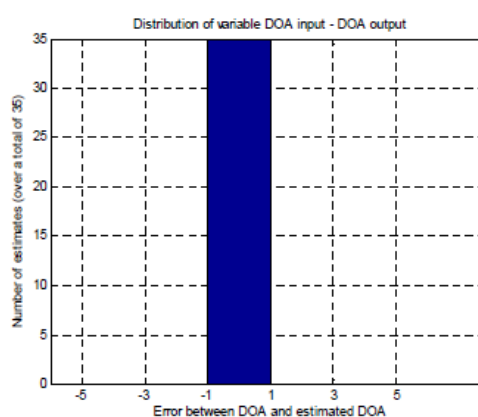
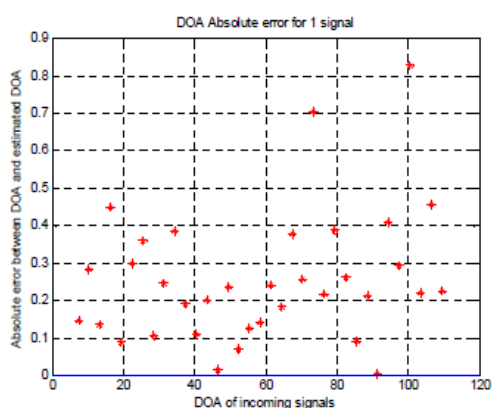
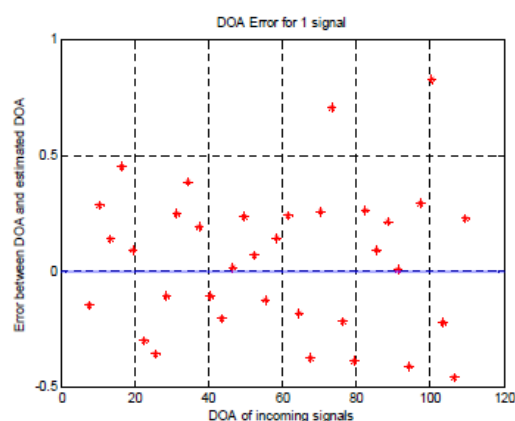
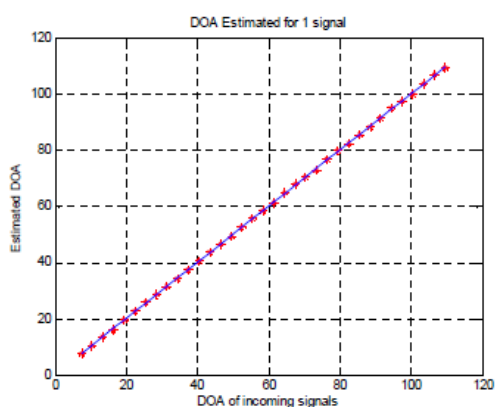
Επίσης στο επίπεδο εισόδου χρησιμοποιήσαμε 40 perceptrons, στα δύο hidden layers 57, ενώ στο επίπεδο εξόδου όσο ήταν το σύνολο των σημάτων.

Τέλος να αναφέρουμε πως τα λογισμικά τα οποία χρησιμοποιήθηκαν για την υλοποίηση της παραπάνω διαδικασίας και όλης της εργασίας ήταν: το **MATLAB version 7.0.1** και το **Neural Works Professional II/PLUS**

#### 4.4.2 Αποτελέσματα για ένα σήμα

Αρχικά υπολογίστηκαν με πρόγραμμα που δομήθηκε στο λογισμικό MATLAB, τα ζεύγη των τιμών εισόδου – εξόδου για το training set του NN. Χρησιμοποιήθηκαν 120 ομάδες δεδομένων για το training set και η διάρκεια εκπαίδευσης με το λογισμικό Neural Works Professional II/PLUS διήρκεσε περίπου 5 min.

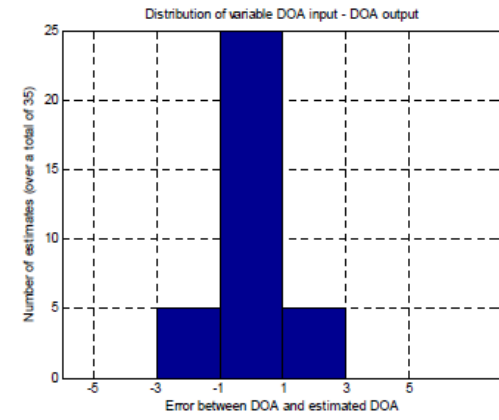
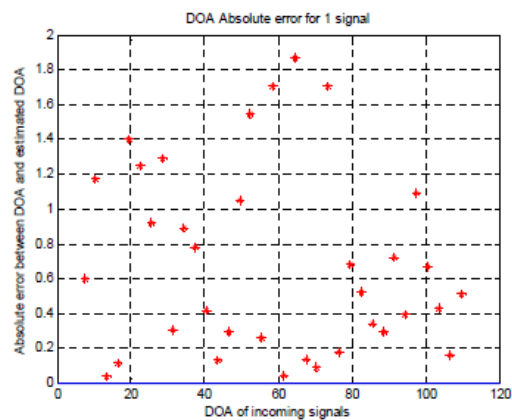
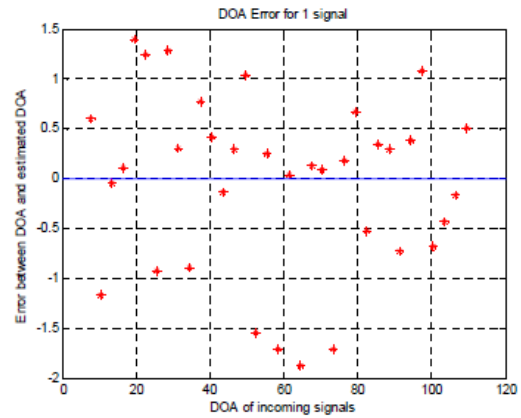
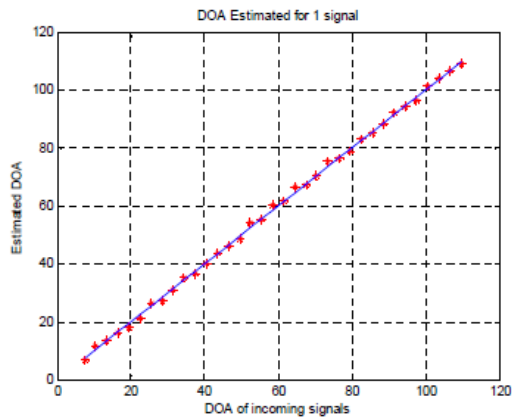
□ Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 1$ .



Μέση τιμή κατανομής (*mean*) = 0.0503


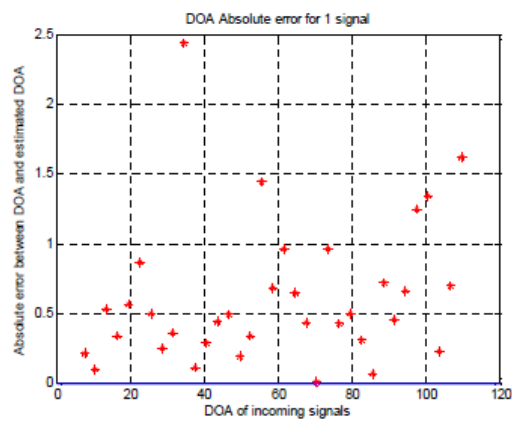


Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 0.3078

□ Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,7\lambda$ . Πλήθος σημάτων άφιξης  $K = 1$ .



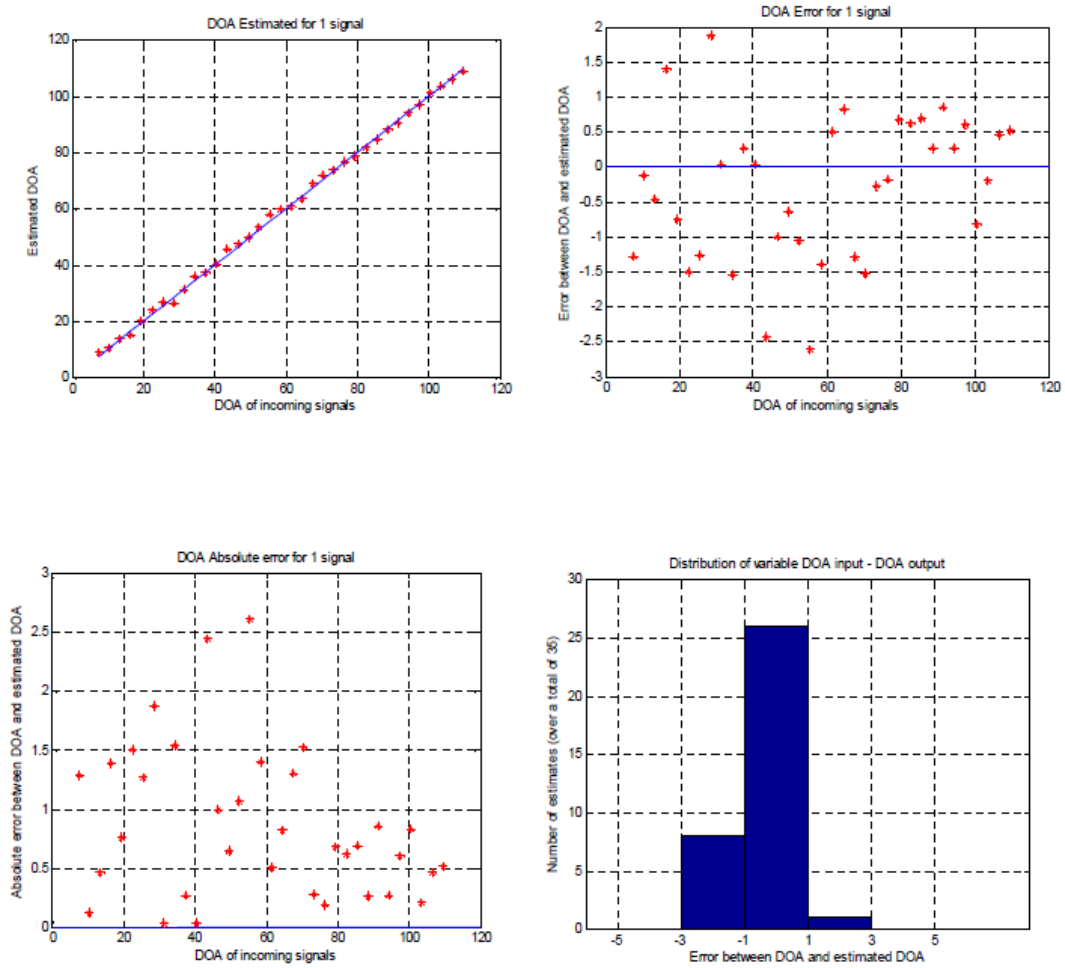
Μέση τιμή κατανομής (*mean*) =  $-0.0274$   
 Τυπική απόκλιση της μεταβλητής (*standard deviation*) =  $0.878$

□ Στοιχειοκεραία με  $M = 12$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 1$ .



Μέση τιμή κατανομής (*mean*) = -0.1847  
 Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 0.7793

□ Στοιχειοκεραία με  $M = 12$  στοιχεία, ισαπέχοντα κατά  $d = 0,7\lambda$ . Πλήθος σημάτων άφιξης  $K = 1$ .



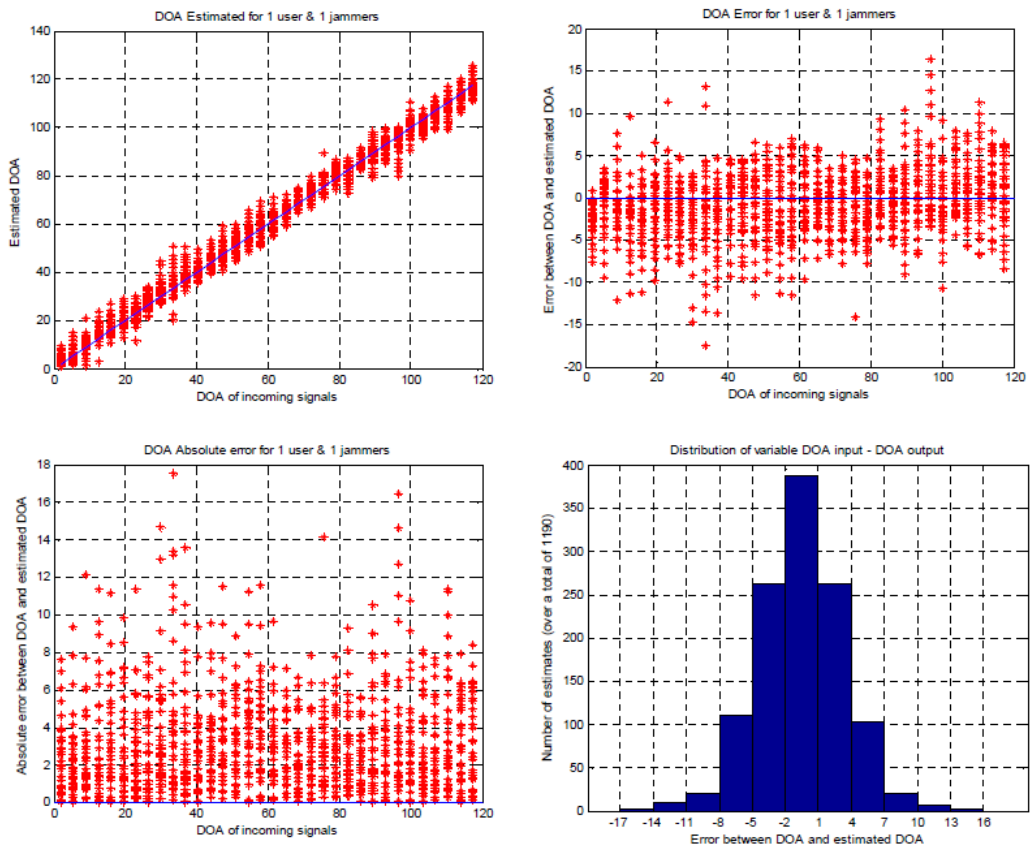
Μέση τιμή κατανομής (*mean*) = -0.2521

Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 0.9160

#### 4.4.3 Αποτελέσματα για δύο σήματα (ένας user και ένας jammer)





□ Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 2$ .

i. user και jammer ίδιο πλάτος



Μέση τιμή κατανομής (*mean*) = -0.615  
Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 3.9757

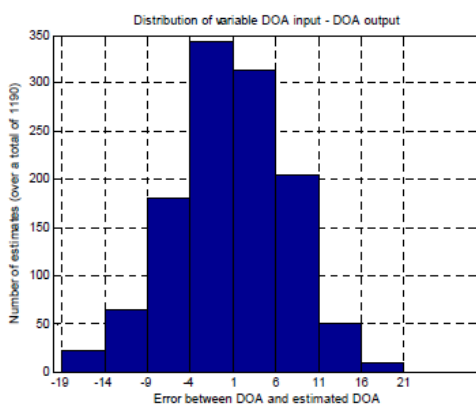



ii. ανίχνευση του υψηλότερης ισχύος σήματος κατά 20 dB



Μέση τιμή κατανομής (*mean*) = 0.096  
 Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 1.3592



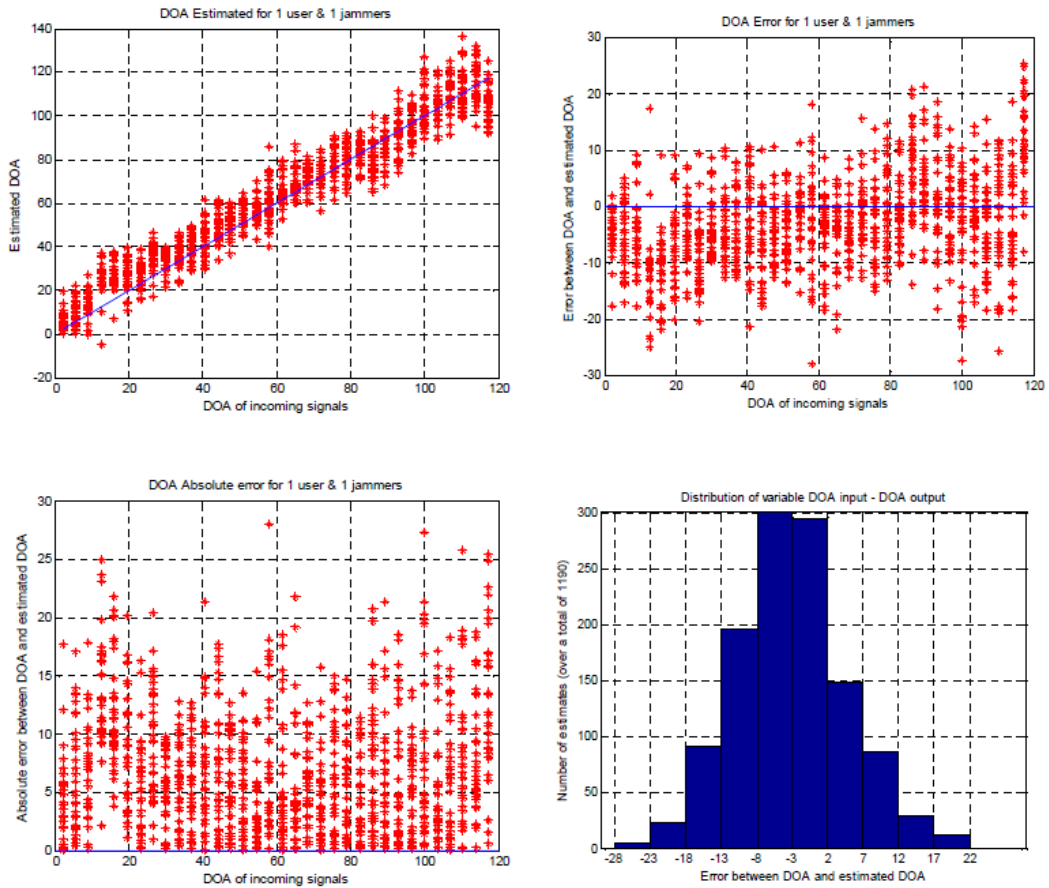
iii. ανίχνευση του χαμηλότερης ισχύος σήματος κατά 20 dB



Μέση τιμή κατανομής (*mean*) = 0.6886  
Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 6.5511

□ Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,7\lambda$ . Πλήθος σημάτων άφιξης  $K = 2$ .

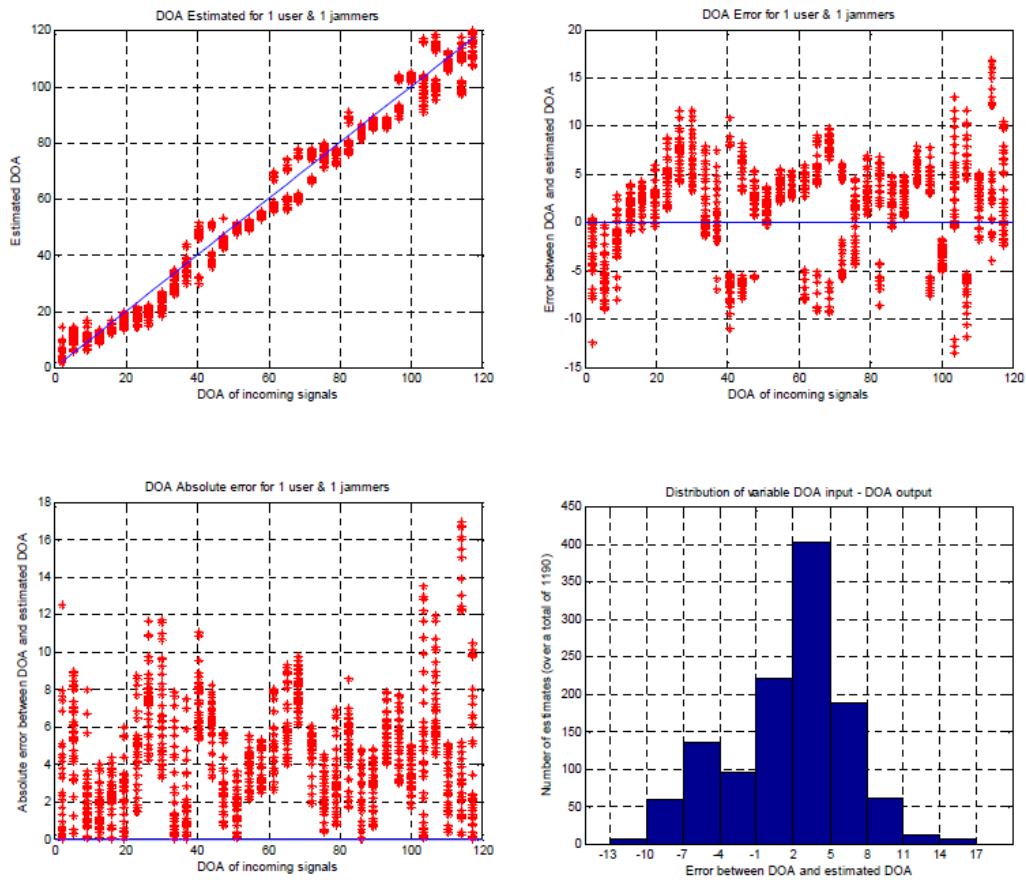
i. user και jammer ίδιο πλάτος



Μέση τιμή κατανομής (*mean*) = -3.0868

Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 8.0268

ii. ανίχνευση του υψηλότερης ισχύος σήματος κατά 20 dB



Μέση τιμή κατανομής (*mean*) = 0.4226





Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 3.518

iii. ανίχνευση του χαμηλότερης ισχύος σήματος κατά 20 dB

Η ανίχνευση του μικρότερης ισχύος σήματος απέτυχε, σε όλες τις περιπτώσεις με τις οποίες έγινε το test των εκπαιδευμένων νευρωνικών δικτύων.

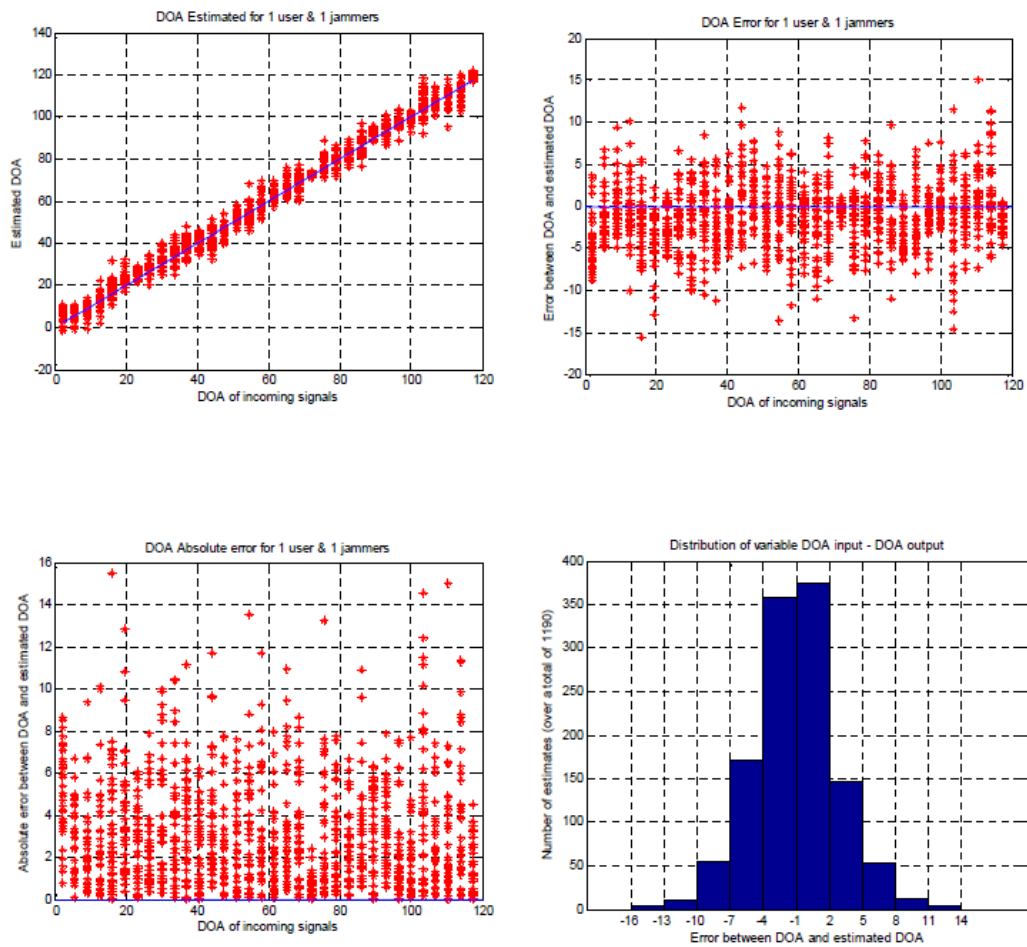
□ Στοιχειοκεραία με  $M = 12$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 2$ .

i. user και jammer ίδιο πλάτος



Μέση τιμή κατανομής (*mean*) = -1.8954  
Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 8.8788

ii. ανίχνευση του υψηλότερης ισχύος σήματος κατά 20 dB



Μέση τιμή κατανομής (*mean*) = -1.0344



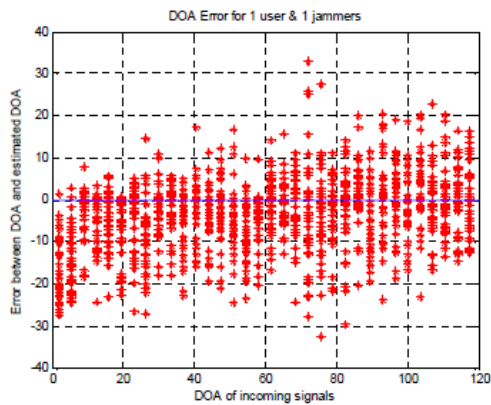

Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 3.8594

iii. ανίχνευση του χαμηλότερης ισχύος σήματος κατά 20 dB

Όπως και στην προηγούμενη, έτσι και σ' αυτή την περίπτωση το δίκτυο αποτυγχάνει να ανιχνεύσει το ασθενέστερο σήμα

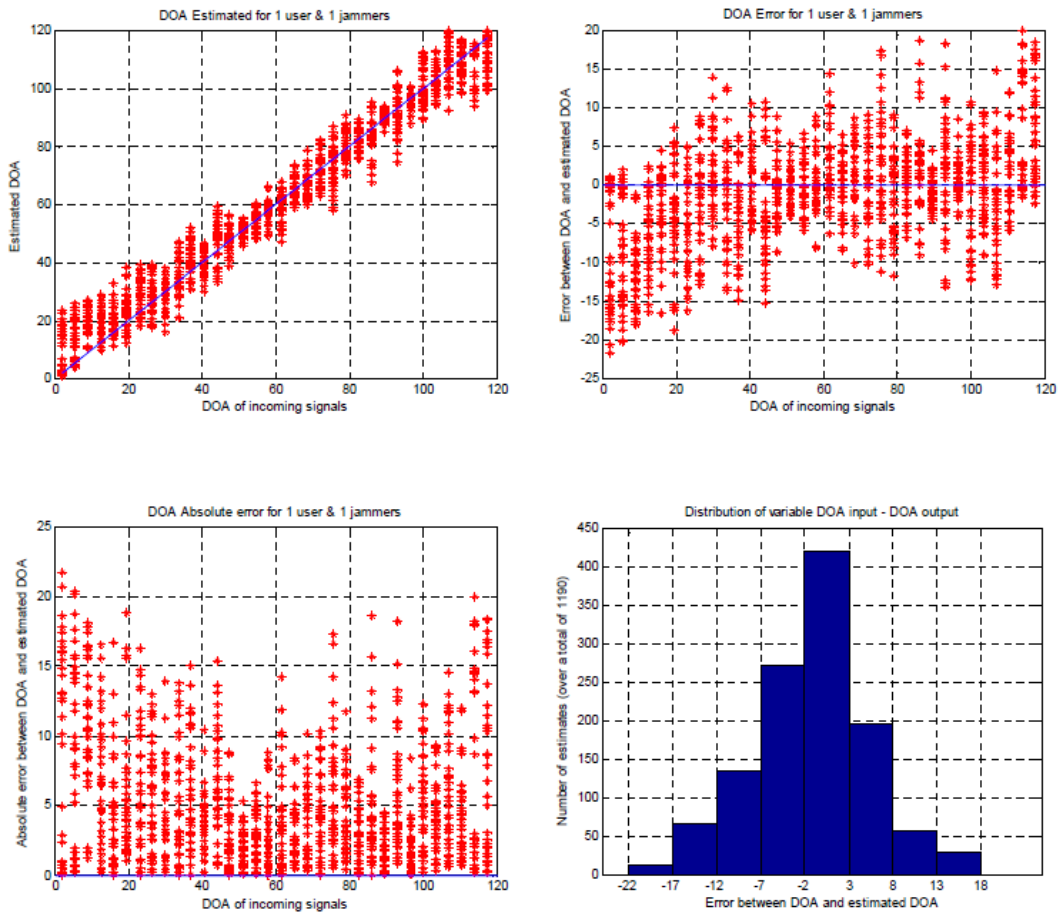
□ Στοιχειοκεραία με  $M = 12$  στοιχεία, ισαπέχοντα κατά  $d = 0,7\lambda$ . Πλήθος σημάτων άφιξης  $K = 2$ .

i. user και jammer ίδιο πλάτος



Μέση τιμή κατανομής (*mean*) = -3.2307  
 Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 8.877

ii. ανίχνευση του υψηλότερης ισχύος σήματος κατά 20 dB



Μέση τιμή κατανομής (*mean*) = -1.0814

Τυπική απόκλιση της μεταβλητής (*standard deviation*) = 6.7839

iii. ανίχνευση του χαμηλότερης ισχύος σήματος κατά 20 dB

Όπως και στην προηγούμενη, έτσι και σ' αυτή το δίκτυο αποτυγχάνει να ανιχνεύσει το ασθενέστερο σήμα.

## ΚΕΦΑΛΑΙΟ 5:

# ΜΕΛΕΤΗ ΔΙΑΜΟΡΦΩΣΗΣ ΔΕΣΜΗΣ ΤΗΣ ΕΚΠΕΜΠΟΜΕΝΗΣ ΑΚΤΙΝΟΒΟΛΙΑΣ (Beamforming) ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

### 6.1 Εισαγωγή

Το επόμενο μεγάλο βήμα στα ασύρματα δίκτυα είναι οι λεγόμενες έξυπνες κεραιές. Με τις έξυπνες κεραιές, επιτυγχάνεται κατευθυντική μετάδοση ισχύος προς τον χρήστη που εξυπηρετείται και έτσι η ισχύς μετάδοσης επικεντρώνεται σε μια συγκεκριμένη κατεύθυνση. Στα συμβατικά χρησιμοποιούμενα συστήματα μετάδοσης, έχουμε ομοιοκατευθυντική εκπομπή ισχύος. Η έξυπνη κεραία αποτελείται από μια σειρά από συμβατικές κεραιές. Το συνολικό διάγραμμα ακτινοβολίας της κεραιάς μπορεί να μεταβάλλεται δυναμικά. Σε μια έξυπνη κεραία, αποτελούμενη από μια σειρά από συμβατικές ομοιοκατευθυντικές στοιχειοκεραίες τοποθετημένες κατά μήκος μιας γραμμής, το συνολικό διάγραμμα ακτινοβολίας μπορεί να μεταβάλλεται δυναμικά, με την προϋπόθεση ότι τα πλάτη και οι φάσεις των ρευμάτων διέγερσης των στοιχειοκεραίων μεταβάλλονται κατάλληλα. Κάθε διάγραμμα ακτινοβολίας αντιστοιχιστεί σε ένα διάνυσμα χωρικής διαμόρφωσης, το οποίο μπορεί να στρέφει τον κύριο κατευθυντικό λοβό προς ένα συγκεκριμένο χρήστη. Με αυτή τη μέθοδο χωρικής διαμόρφωσης της ισχύος εκπομπής, ανάλογα με τη στιγμιαία θέση των χρηστών, όλη η ισχύς επικεντρώνεται προς τις κατευθύνσεις των χρηστών. Η δυνατότητα των έξυπνων κεραιών να κατευθύνουν την μετάδοση προς την κατεύθυνση κάθε χρήστη οδηγεί στη δημιουργία “χωρικών” καναλιών, δίνοντας έτσι υπόσταση στην ιδέα της πολλαπλής πρόσβασης στο χώρο (*Space Division Multiple Access, SDMA*). Η μέθοδος SDMA μπορεί να συνδυαστεί με οποιαδήποτε άλλη μέθοδο πολλαπλής πρόσβασης και να επιφέρει τεράστια οφέλη στην χωρητικότητα του συστήματος. Για παράδειγμα, εάν συνδυαστεί με TDMA, τότε η ίδια χρονόθυρίδα μπορεί να χρησιμοποιηθεί για ταυτόχρονη μετάδοση σε αρκετούς χρήστες στην ίδια κυψέλη. Η θέση, το εύρος και το σχετικό μέγεθος των λοβών είναι συνάρτηση των πλατών και φάσεων των ρευμάτων που διεγείρουν κάθε στοιχείο της κεραιάς. Έτσι, κάθε διάγραμμα εκπομπής αντιστοιχίζεται σε ένα διάνυσμα διαστάσεων

$$M \times 1, \underline{u} = (u_1, u_2, \dots, u_M)^T$$

, όπου τα  $\{U_i\}_{i=1}^M$  είναι μιγαδικοί αριθμοί και  $U_i^H U_i = 1$ , ώστε να εξασφαλίζεται σταθερή ισχύς εκπομπής. Οι συμβολισμοί  $(\cdot)^T$  και  $(\cdot)^H$  ορίζουν το ανάστροφο και ανάστροφο συζυγές ενός διανύσματος. Η θέση κάθε χρήστη σε σχέση με το σημείο πρόσβασης και η ποιότητα του καναλιού του προσδιορίζεται από το  $M \times 1$  χωρικό



διάνυσμα θέσης του,  $a$ . Εάν το σήμα μεταδίδεται μόνο με μια απευθείας (*Line-of-sight, LOS*) διαδρομή, τότε το χωρικό διάνυσμα θέσης ταυτίζεται με την φυσική θέση του χρήστη. Συνήθως όμως, το σήμα ακολουθεί πολλαπλές διαδρομές λόγω ανακλάσεων και περιθλάσεων, οπότε εμφανίζεται στο δέκτη σε πολλαπλές εκδοχές με διαφορετική χρονική καθυστέρηση μεταξύ τους και με διαφορετική ισχύ. Σε αυτήν την περίπτωση η συνάρτηση μεταφοράς του καναλιού από την κεραία  $m$  στο χρήστη είναι

$$h_m = \sum_{\lambda=1}^L \beta_\lambda \delta(t - \tau_\lambda + \tau_\lambda^m) \quad ( )$$

λείναι ο αριθμός των διαδρομών,  $\beta_\lambda$  το πλάτος της  $\lambda$  συνιστώσας,  $\tau_\lambda$  η χρονική καθυστέρηση της διαδρομής σχετικά με το στοιχείο της στοιχειοκεραίας που θεωρείται ως σημείο αναφοράς και  $\delta(t)$  η κρουστική συνάρτηση. Ο παράγοντας  $\tau_\lambda^m = \frac{d}{c} (m - 1) \cos\theta_\lambda$  παριστάνει τη χρονική καθυστέρηση μεταξύ του  $m$ -οστού στοιχείου της κεραίας και του σημείου αναφοράς, όπου  $d$  είναι η απόσταση μεταξύ δυο κεραιών,  $\theta_\lambda$  η γωνία της  $\lambda$  διαδρομής και  $c$  η ταχύτητα διάδοσης του ηλεκτρομαγνητικού κύματος. Τότε, το χωρικό διάνυσμα θέσης υπολογίζεται ως υπέρθεση πολλών συνιστωσών, κάθε μία από τις οποίες αντιστοιχεί σε μια διαδρομή. Η  $m$ -συνιστώσα του διανύσματος δίνεται ως:

$$a_m = \sum_{\lambda=1}^L \beta_\lambda^* \exp(-j2\pi f_c (-\tau_\lambda + \tau_\lambda^m)) \quad 5.1$$

όπου  $f_c$  είναι η συχνότητα φέροντος. Ας υποθέσουμε ότι προς στιγμήν στο κανάλι υπάρχει ένας χρήστης,  $a$  είναι το διάνυσμα θέσης του χρήστη,  $u$  το διάνυσμα χωρικής διαμόρφωσής του και  $p$  η ισχύς μετάδοσης. Εάν  $D$  είναι το μεταδιδόμενο σύμβολο για αυτόν τον χρήστη, τότε το λαμβανόμενο σήμα στο δέκτη του χρήστη μπορεί να εκφραστεί ως

$$r = \sqrt{p}(\underline{a}^H \underline{u})D + z \quad 5.2$$

$r$

όπου  $z$  είναι ο θόρυβος, η διασπορά του οποίου είναι  $\sigma^2$ . Έστω ότι τα χαρακτηριστικά των  $L$  διαδρομών (γωνίες, εξασθενήσεις, χρονικές καθυστερήσεις) είναι γνωστά στο Σ.Π. Τότε, ο λόγος σήματος προς θόρυβο στο δέκτη είναι:

$$SNR = \frac{P(\underline{u}^H H \underline{u})}{\sigma^2} \quad 5.3$$

όπου ο  $M \times M$  πίνακας  $H$  ορίζεται ως

$$H = \sum_{\lambda_1}^L \sum_{\lambda_2}^L \xi_{\lambda_1} \xi_{\lambda_2}^* \underline{v}(\theta_{\lambda_1}) \underline{v}^H(\theta_{\lambda_2}) \quad 5.4$$

Με  $\xi_{\lambda} = \beta_{\lambda} \exp(-j2\pi f_c \tau_{\lambda})$  και  $\underline{v}(\cdot)$  το  $M \times 1$  διάνυσμα οδήγησης της κεραίας, του οποίου η  $m$  συνιστώσα είναι  $v_{(\theta_{\lambda})}^m = \exp(-j2\pi f_c \tau_{\lambda}^m)$ .

## 5.2 Γενικά για τις «έξυπνες κεραίες»

Οι έξυπνες κεραίες έχουν την δυνατότητα να μεταβάλλουν το διάγραμμα ακτινοβολίας τους, ανάλογα με το ηλεκτρομαγνητικό τους περιβάλλον, έτσι ώστε να συγκεντρώνουν την εκπεμπόμενη ενέργεια στην διεύθυνση που επιθυμείται, αν λειτουργούν ως κεραίες εκπομπής ή να αναδεικνύουν το σήμα που απαιτείται, περιορίζοντας ταυτόχρονα τις παρεμβολές από ανεπιθύμητα σήματα άλλων διευθύνσεων, αν λειτουργούν ως κεραίες λήψης. Για να πετύχει αυτόν τον σκοπό, μία έξυπνη κεραία αποτελείται από πολλά πανομοιότυπα στοιχεία (κεραίες) καταναμημένα στο χώρο, τα οποία δίνουν διαφορετικά σήματα μεταξύ τους, ανάλογα με τα προσπίπτοντα πεδία στην κεραία. Η δυνατότητα της κεραίας να μεταβάλλει το διάγραμμα ακτινοβολίας της, προκύπτει από μία προσαρμοστική διαδικασία αλγόριθμο), σύμφωνα με την οποία κάθε στιγμή υπολογίζεται ένα διάνυσμα μιγαδικών συντελεστών (βαρών), το οποίο πολλαπλασιάζει τις τιμές των τάσεων των στοιχείων της κεραίας. Ο πολλαπλασιασμός αυτός μεταβάλλει τα πλάτη και τις φάσεις των τάσεων που προκύπτουν πρωτογενώς στην έξοδο των στοιχείων. Αθροίζοντας αυτές τις κατάλληλα τροποποιημένες εξόδους των στοιχείων, μπορεί να δημιουργηθεί το επιθυμητό διάγραμμα ακτινοβολίας της κεραίας, με σχηματισμό κύριου λοβού στην διεύθυνση του σήματος που μας ενδιαφέρει και μηδενισμούς στις διευθύνσεις όπου υπάρχουν ισχυροί παρεμβολείς ή άλλα ανεπιθύμητα σήματα. Με αυτόν τον τρόπο, μειώνεται δραστικά η επίδραση της συνολικά «άχρηστης πληροφορίας» που προσπίπτει στην κεραία και αναδεικνύονται τα σήματα που ενδιαφέρουν τον λήπτη με τον καλύτερο δυνατό τρόπο. Το κυριότερο λοιπόν στοιχείο ενός συστήματος έξυπνης κεραίας, είναι η προσαρμοστική διαδικασία, η οποία θα καθορίσει την επιλογή του ιδανικότερου διανύσματος βαρών και συνεπώς την συνολική απόδοση της κεραίας στην εξάλειψη των ανεπιθύμητων σημάτων.

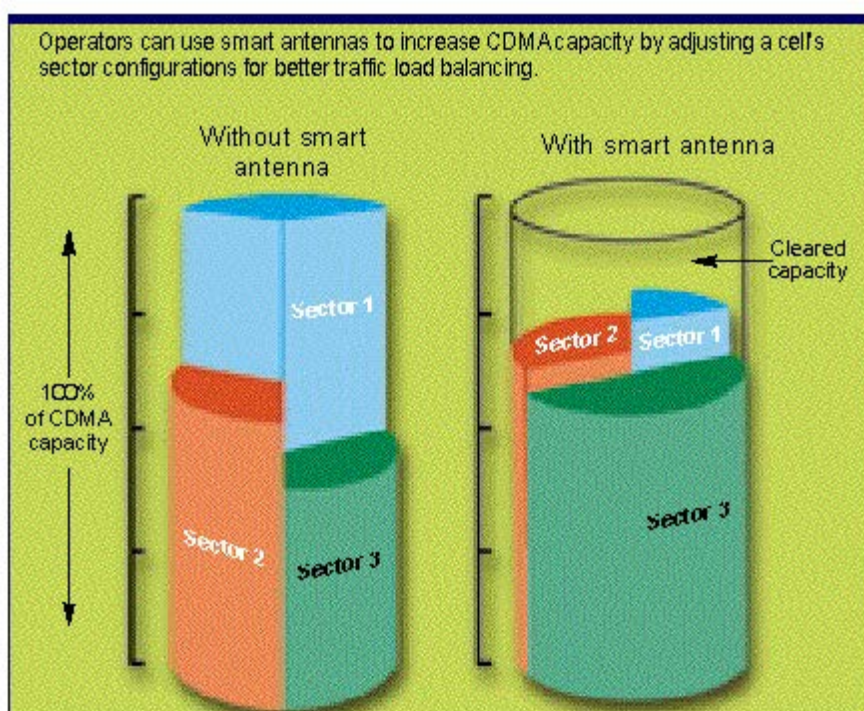
Την λογική αυτή εφαρμόσαμε σ' αυτήν την εργασία προσαρμόζοντας την σε νευρωνικό δίκτυο.

Παλαιότερα, γινόταν χρήση αναλογικών προσαρμοστικών τεχνικών. Ένα εγγενές μειονέκτημα αυτών των τεχνικών, ήταν ο περιορισμός που επέβαλε το κριτήριο του Rayleigh στην δυνατότητα διακρισιμότητας των σημάτων. Το κριτήριο αυτό αναφέρει ότι για να μπορούν να διακριθούν δύο εισερχόμενα κύματα ως προς την διεύθυνση άφιξής τους από μία κεραία λήψης, χρειάζεται μία κεραία της οποίας το φυσικό μέγεθος να είναι αντιστρόφως ανάλογο της γωνιακής διαφοράς των δύο σημάτων κατά την πρόσπτωση στην κεραία. Συνεπώς, το φυσικό μέγεθος της κεραίας καθορίζει

την γωνιακή διακρισιμότητα μίας αναλογικής προσαρμοστικής διαδικασίας. Η έλευση της ψηφιακής τεχνολογίας, ξεπέρασε το εμπόδιο αυτό, με την προϋπόθεση της ύπαρξης επαρκούς ισχύος των προσπίπτοντων σημάτων.


Η χρήση των έξυπνων στοιχειοκεραιών στα κινητά τηλεπικοινωνιακά συστήματα προσφέρει τη δυνατότητα εκμετάλλευσης της χωρικής διαφορικής λήψης (*spatial diversity*), γεγονός που βελτιώνει την αποδοτικότητα εύρους ζώνης. Γενικά μια έξυπνη στοιχειοκεραία αποτελείται από έναν αριθμό στοιχείων που συνδυάζονται μέσω ενός δικτύου διαμόρφωσης του διαγράμματος ακτινοβολίας (*beamforming network*) που καθορίζει τα σχετικά πλάτη και τις σχετικές φάσεις των στοιχείων. Αυτό το δίκτυο μπορεί να υλοποιηθεί χρησιμοποιώντας τεχνολογία RF ή τεχνολογία ψηφιακής επεξεργασίας σήματος πραγματικού χρόνου ή υβριδικές λύσεις.

Χρησιμοποιώντας μια έξυπνη στοιχειοκεραία (*Smart Antenna System – SAS*) επιτυγχάνεται χαμηλότερη κατανάλωση ισχύος του κινητού τερματικού, μεγαλύτερο βεληνεκές, μείωση της διασυμβολικής παρεμβολής (*intersymbol interference*), υψηλότερος ρυθμός μετάδοσης δεδομένων και ευκολία ολοκλήρωσης στο υπάρχον κυψελωτό σύστημα. Ειδικά για σταθμούς βάσεις τα συστήματα έξυπνων κεραιών μέσω της ικανότητας του χωρικού διαχωρισμού σημάτων μπορούν να υποστηρίξουν την ανάθεση πολλαπλών κινητών χρηστών που επικαλύπτονται στο πεδίο του χρόνου και των συχνοτήτων σε ένα κοινό κανάλι επικοινωνίας. Αυτή η τεχνική είναι γνωστή ως πολλαπλή πρόσβαση με χωρισμό χώρου (*Spatial Division Multiple Access – SDMA*) και αυξάνει τη χωρητικότητα του συστήματος (σχήμα 5.1). Επιπλέον η τοποθέτηση έξυπνων στοιχειοκεραιών στους σταθμούς βάσης, αν και αυξάνει το κόστος ανά σταθμό μπορεί να αυξήσει την περιοχή κάλυψης κάθε κυψέλης και να μειώσει το συνολικό κόστος του συστήματος δραματικά, πολλές φορές κατά περισσότερο από 50% χωρίς υποβάθμιση της ποιότητας υπηρεσίας.



**Σχήμα 5.1:** Σύγκριση χωρητικότητας CDMA συστημάτων χωρίς και με τη χρήση έξυπνης στοιχειοκεραίας.

Οι κεραίες των σταθμών βάσης μέχρι τώρα ήταν ομοιοκατευθυντικές ή χωρισμένες σε τομείς (*sectored*). Αυτό μπορεί να θεωρηθεί ως σπατάλη ισχύος καθώς το μεγαλύτερο κομμάτι της ακτινοβολεί σε κατευθύνσεις διαφορετικές από τον χρήστη. Επιπλέον η ισχύς που ακτινοβολείται σε διαφορετικές κατευθύνσεις εκλαμβάνεται ως παρεμβολή από τους άλλους χρήστες. Αντίθετα η έξυπνη κεραία έχει όχι μόνο την ικανότητα να προσαρμόζεται στο περιβάλλον στο οποίο λειτουργεί (σχήμα 5.2), αλλά επίσης μπορεί να συνεργάζεται με εξελιγμένα κυκλώματα επεξεργασίας σήματος. Αυτό το γεγονός καθιστά αναγκαία την ανάπτυξη τεχνικών ολοκλήρωσης κυκλωμάτων DSP με κεραίες που λειτουργούν σε υψηλότερες συχνότητες. Η επιτυχημένη ολοκλήρωση των δύο αυτών τεχνολογιών μειώνει το μέγεθος και βελτιώνει την απόδοση του τηλεπικοινωνιακού συστήματος.



**Σχήμα 5.2:** Χωρισμός τομέων κάλυψης ανά κυψέλη με χρήση (α) συμβατικής και (β) έξυπνης κεραίας.

### 5.2.1 Επίπεδα ευφυΐας (*levels of intelligence*).


Τα επίπεδα ευφυΐας ενός συστήματος έξυπνης κεραίας διακρίνονται στα παρακάτω **Μεταβαλλόμενος λοβός** (*switched lobe - SL*). Είναι η απλούστερη τεχνική και υλοποιείται με μια βασική λειτουργία μεταβολής ανάμεσα σε ξεχωριστές κατευθυντικές κεραίες ή σε ξεχωριστές κατευθυντικές κεραίες ή σε προσχεδιασμένες δέσμες μιας στοιχειοκεραίας. Η υλοποίηση που παρέχει τη βέλτιστη απόδοση όσον αφορά την λαμβανόμενη ισχύ προτιμάται εξ' αιτίας της υψηλότερης κατευθυντικότητας. Σε σύγκριση με την συμβατική κεραία επιτυγχάνεται κάποιο κέρδος. Τέτοια κεραία θα είναι ευκολότερο να ενσωματωθεί σε υπάρχοντα κυψελωτά

δίκτυα σε σχέση με πιο πολύπλοκες προσαρμοζόμενες κεραίες, αλλά προσφέρει περιορισμένη βελτίωση.

**Στοιχειοκεραίες δυναμικής μεταβολής φάσης (*Dynamically Phased Array - DPA*).** Χρησιμοποιώντας έναν αλγόριθμο κατεύθυνσης άφιξης (*Direction of Arrival - DoA*) για λαμβανόμενο σήμα από τον χρήστη, είναι δυνατός ο συνεχής εντοπισμός ενώ μπορεί να θεωρηθεί ως μια γενίκευση της αρχής του μεταβαλλόμενου λοβού. Επίσης σε αυτή την περίπτωση μεγιστοποιείται η λαμβανόμενη ισχύς. Αυτό το επίπεδο ευφυΐας χρησιμοποιήθηκε στην παρούσα εργασία.

**Προσαρμοστικές στοιχειοκεραίες (*Adaptive Array - AA*).** Σε αυτήν την περίπτωση ένας αλγόριθμος DoA προστίθεται για τον εντοπισμό της κατεύθυνσης των πηγών των παρεμβολών (άλλοι χρήστες). Το διάγραμμα ακτινοβολίας προσαρμόζεται ώστε να εξουδετερώνει τους παρεμβολείς. Επίσης με χρήση ειδικών αλγορίθμων και τεχνικών χωρικής διαφορικής λήψης το διάγραμμα ακτινοβολίας μπορεί να τροποποιηθεί ώστε να λαμβάνει σήματα πολλαπλών δρόμων τα οποία μπορούν να συνδυαστούν. Αυτές οι τεχνικές μεγιστοποιούν το λόγο σήματος προς παρεμβολή (*Signal to Interference Ratio - SIR*). Αυτό το επίπεδο ευφυΐας χρησιμοποιήθηκε στην παρούσα εργασία.


Τα συμβατικά κινητά συστήματα συνήθως χρησιμοποιούν κάποια μορφή διαφορικής λήψης (χωρική ή πολοτική). Οι προσαρμοστικές κεραίες μπορούν να θεωρηθούν ως ένα εξελιγμένο σχήμα διαφορικής λήψης. Οι στοιχειοκεραίες μεταβολής φάσης θα έχουν μεγαλύτερη βελτίωση στο κέρδος από τις κεραίες μεταβαλλόμενου λοβού καθώς όλα τα στοιχεία μπορούν να χρησιμοποιηθούν για συνδυασμό διαφορικής λήψης (*diversity combine*)



**Σχήμα 5.3:** Επίπεδα «ευφυΐας» για έξυπνες κεραίες.

## 5.2.2 Βελτιώσεις, πλεονεκτήματα και μειονεκτήματα συστημάτων έξυπνων κεραιών.

Σε σχέση με τις κεραιές που χρησιμοποιούνται έως σήμερα οι έξυπνες κεραιές παρέχουν αρκετές βελτιώσεις και πλεονεκτήματα. Αυτά αναφέρονται παρακάτω: **Αύξηση χωρητικότητας.** Ο κύριος λόγος για το αυξανόμενο ενδιαφέρον για τις έξυπνες κεραιές είναι η αύξηση της χωρητικότητας. Σε πυκνοκατοικημένες περιοχές οι παρεμβολές από τους άλλους χρήστες είναι η κύρια πηγή θορύβου για τα κινητά συστήματα. Οι έξυπνες κεραιές βελτιώνοντας το χρήσιμο λαμβανόμενο επίπεδο σήματος και μειώνοντας το επίπεδο παρεμβολής βελτιώνουν το SIR. Ειδικότερα η προσαρμοστική στοιχειοκεραία προσφέρει σημαντική βελτίωση και πειραματικά στοιχεία δείχνουν βελτίωση κατά 10 dB. Σε συστήματα TDMA η βελτίωση του SIR προσφέρει τη δυνατότητα μειωμένων αποστάσεων μεταξύ των κυψελών που χρησιμοποιούν την ίδια συχνότητα. Ένα παράδειγμα φαίνεται στο σχήμα 5.4, όπου η παραδοσιακή ομαδοποίηση των επτά κυψελών έχει μειωθεί σε ομαδοποίηση τριών κυψελών. Αυτό οδηγεί σε βελτίωση της χωρητικότητας κατά 7/3. Προσομοιώσεις σε GSM δίκτυα έχουν δείξει βελτίωση της χωρητικότητας κατά 300%. Συστήματα που βασίζονται σε CDMA (IS-95, UMTS) έχουν ως βασική πηγή θορύβου τις παρεμβολές από άλλους χρήστες εξ' αιτίας του γεγονότος ότι οι διασπειρόμενοι κώδικες (*spreading codes*) δεν είναι ιδανικά ορθογώνιοι. Προσομοιώσεις έχουν δείξει βελτίωση της χωρητικότητας κατά 5 φορές για CDMA συστήματα.



**Σχήμα 5.4:** Απόσταση κυψελών με επαναχρησιμοποίηση συχνότητας (a) με χρήση συμβατικής κεραιάς και (b) με χρήση έξυπνης κεραιάς.

**Αύξηση βεληνεκούς σε αγροτικές και αραιοκατοικημένες περιοχές.** Η ραδιοκάλυψη αποτελεί το σημαντικότερο κριτήριο για την τοποθέτηση σταθμών βάσεις. Επειδή οι έξυπνες κεραιές είναι περισσότερο κατευθυντικές από τις παραδοσιακές κεραιές,

αύξηση του βεληνεκούς είναι εφικτή. Αυτό σημαίνει ότι οι σταθμοί βάσης μπορούν να τοποθετηθούν πιο μακριά ο ένας από τον άλλο, κάτι που αποτελεί μια πιο οικονομική λύση.

**Νέες υπηρεσίες.** Με τη χρήση έξυπνων κεραιών το δίκτυο θα έχει πρόσβαση σε χωρικές πληροφορίες για τους χρήστες. Αυτή η πληροφορία μπορεί να χρησιμοποιηθεί για τον προσδιορισμό της θέσης των χρηστών με πολύ μεγαλύτερη ακρίβεια από ότι στα υπάρχοντα δίκτυα παραδοσιακή ομαδοποίηση των χρηστών με πολύ μεγαλύτερη ακρίβεια από ότι στα υπάρχοντα δίκτυα (ακρίβεια 125 m RMS έχει τεθεί ως προδιαγραφή από τον Αμερικάνικο Οργανισμό Τηλεπικοινωνιών (FCC). Η υπηρεσία αυτή θα είναι ιδιαίτερα χρήσιμη σε κλίσεις έκτατης ανάγκης.

**Ασφάλεια.** Η υποκλοπή συνδιάλεξης είναι πολύ δυσκολότερη όταν χρησιμοποιούνται έξυπνες κεραιές, καθώς ο υποκλοπέας πρέπει να βρίσκεται στην ίδια κατεύθυνση με το χρήστη όσον αφορά το σταθμό βάσης.

**Μειωμένη διάδοση πολλαπλών δρόμων.** Χρησιμοποιώντας μια στενή δέσμη κεραιάς στο σταθμό βάσης η διάδοση πολλαπλών δρόμων μπορεί να μειωθεί. Η πραγματική μείωση εξαρτάται από τη διαμόρφωση εδάφους και δεν είναι πάντα σημαντική. Παρά το ότι οι εξισωτές καναλιών (*channel equalizers*) και οι δέκτες RAKE συχνά αντιμετωπίζουν επιτυχώς το πρόβλημα αυτό, είναι πιθανόν ότι η επιτυχία τους δεν θα είναι ίδια σε συνδέσεις πολύ μεγάλης ταχύτητας. Κατά συνέπεια η μείωση στη διάδοση πολλαπλών δρόμων μπορεί να διευκολύνει τη σχεδίαση μελλοντικών modems.

Παρά τα πλεονεκτήματα που προσφέρονται από τις έξυπνες κεραιές υπάρχουν μειονεκτήματα που στην πλειοψηφία τους σχετίζονται με το κόστος.

**Πολυπλοκότητα πομποδέκτη.** Είναι προφανές ότι ένας πομποδέκτης που χρησιμοποιεί έξυπνη κεραία είναι πολύ πιο πολύπλοκος από ένα παραδοσιακό πομποδέκτη σταθμού βάσης. Η κεραία θα χρειάζεται ξεχωριστές συνδέσεις με τον πομποδέκτη για κάθε ένα από τα στοιχεία καθώς και ακριβή ρύθμιση σε πραγματικό χρόνο. Επίσης η διαδικασία σύνθεσης των λοβών της στοιχειοκεραίας απαιτεί σημαντικό υπολογιστικό φόρτο ειδικά στην περίπτωση προσαρμοστικών κεραιών. Αυτό σημαίνει ότι ένας σταθμός βάσης με έξυπνες κεραιές πρέπει να διαθέτει πολύ δυνατούς επεξεργαστές και συστήματα ελέγχου. Κατά συνέπεια οι σταθμοί βάσης με έξυπνες κεραιές θα είναι πολύ πιο ακριβοί από τους παραδοσιακούς σταθμούς βάσης.

**Διαχείριση εξοπλισμού (resource management).** Αν και οι έξυπνες κεραιές στηρίζονται κυρίως στην τεχνολογία RF, απαιτούν βελτιωμένες λειτουργίες δικτύων όπως η διαχείριση εξοπλισμού και κινητικότητας (*mobility management*). Όταν μια νέα σύνδεση δημιουργείται ή μια υπάρχουσα σύνδεση ανατίθεται σε ένα νέο σταθμό βάσης καμία γωνιακή πληροφορία δεν είναι διαθέσιμη στο νέο σταθμό βάσης, ο οποίος χρειάζεται κάποιο εναλλακτικό τρόπο για να εντοπίσει το χρήστη. Αυτό μπορεί να επιτευχθεί επιτρέποντας στο σταθμό βάσης να σαρώνει την κυψέλη συνεχώς με μία δέσμη ανίχνευσης η οποία θα ψάχνει για υποψήφιους για νέα σύνδεση u942 . ανάθεση από άλλη κυψέλη. Μια άλλη δυνατότητα είναι η χρήση ενός εξωτερικού συστήματος για εντοπισμό θέσης (π.χ. GPS). Όπως εξηγήθηκε νωρίτερα η μέθοδος SDMA

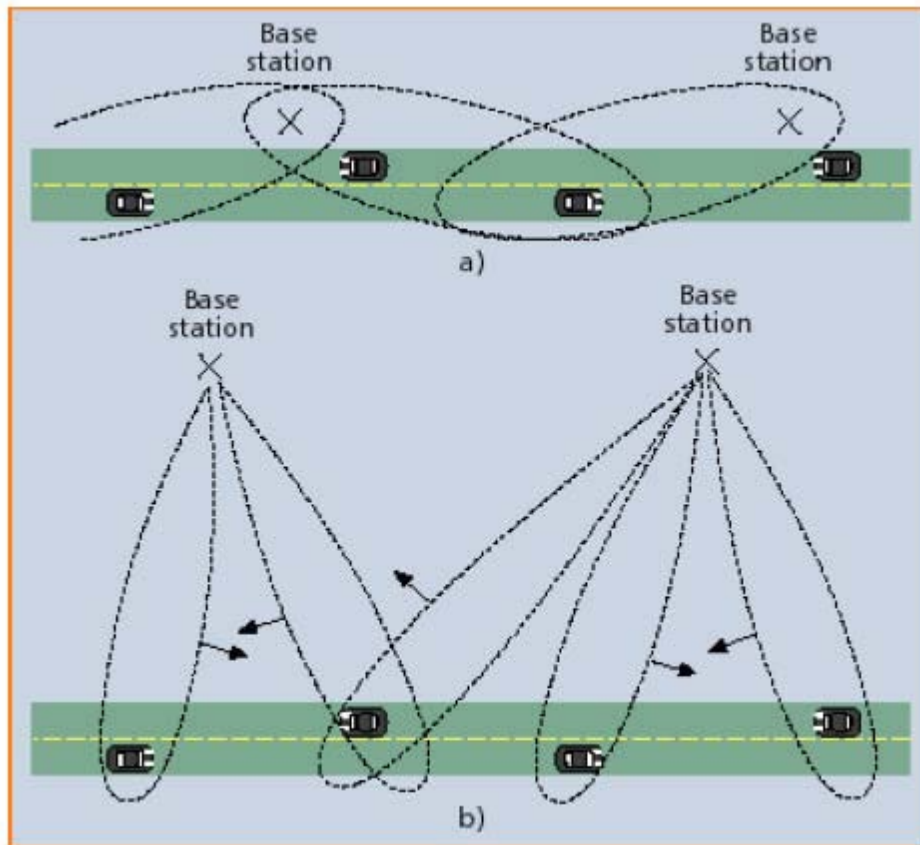
εξυπηρετεί διαφορετικούς χρήστες που χρησιμοποιούν το ίδιο φυσικό κανάλι επικοινωνίας στην ίδια κυψέλη και διαχωρίζονται μόνο από την γωνία. Σε περίπτωση που δύο χρήστες έχουν την ίδια ακριβώς γωνία, ένας από αυτούς πρέπει γρήγορα να μετακινηθεί σε άλλο κανάλι ώστε η σύνδεση να μην διακοπεί. Αυτό σημαίνει ότι σε συστήματα που χρησιμοποιούν SDMA θα υπάρχουν πολύ περισσότερες αναθέσεις στην ίδια κυψέλη (*intracell handovers*) σε σχέση με τα παραδοσιακά συστήματα TDMA ή CDMA.

**Φυσικό μέγεθος.** Μια στοιχειοκεραία με μεγάλο αριθμό στοιχείων είναι αναγκαία ώστε η έξυπνη κεραία να έχει αποδεκτό κέρδος. Τυπικές στοιχειοκεραίες που αποτελούνται από 6 – 10 οριζόντια διαχωριζόμενα στοιχεία έχουν προταθεί για εξωτερικά περιβάλλοντα κινητών επικοινωνιών. Η αναγκαία απόσταση μεταξύ των στοιχείων είναι 0,4-0,5 μήκη κύματος κι επομένως μια στοιχειοκεραία με οκτώ στοιχεία θα έχει μήκος περίπου 1.2 m στα 900 MHz και 60 cm στα 2 GHz.

### 5.2.3 Σχεδιασμός κάλυψης (*radio planning*).

Οι σταθμοί βάσης πρέπει να είναι ικανοί να διαχωρίζουν τους χρήστες με βάση την γωνία ώστε οι έξυπνες κεραίες να έχουν το επιθυμητό κέρδος. Αυτό σημαίνει ότι μερικές από τις παραδοσιακές στρατηγικές για το σχεδιασμό κάλυψης πρέπει να αναθεωρηθούν. Στα υπάρχοντα δίκτυα οι σταθμοί βάσης είναι συχνά τοποθετημένοι κατά μήκος των αυτοκινητοδρόμων και των σιδηροδρομικών γραμμών. Η χρήση έξυπνων κεραιών επιβάλλει τη μετακίνηση των σταθμών βάσης μακριά από το δρόμο ή τις γραμμές ώστε να βελτιωθεί η ικανότητα διαχωρισμού των χρηστών με βάση τη γωνία (σχήμα 5.5).






**Σχήμα 5.5:** Σχεδιασμός ραδιοκάλυψης με χρήση (a) συμβατικών κεραιών και (b) έξυπνων κεραιών.

### 5.3 Μέθοδος προσαρμογής ελαχίστων (ή μηδενισμών) και μεγίστων εκπομπής (*Adaptive Nulling and Steering*)

Στο σημείο αυτό θα δείξουμε πως τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν επιτυχώς για την επίτευξη χωρικής κατανομής ισχύος (*beamforming*) με προσαρμοζόμενη συστοιχία κεραιών (έξυπνες κεραιές).

Θεωρούμε μια μονοδιάστατη γραμμική κεραία, η οποία αποτελείται από  $M$  στοιχεία όπως φαίνεται στο σχήμα 5.5. Έστω ότι  $K$  είναι ο αριθμός επιπέδων κυμάτων στενής ζώνης, με κεντρική συχνότητα  $\omega_0$  και προσπίπτουν στην συστοιχία της κεραίας με γωνίες άφιξης  $\{\theta_1, \theta_2, \dots, \theta_K\}$ .



Σχήμα 5.5: Μονοδιάστατη γραμμική κεραία

Υπενθυμίζουμε πως οι έξοδοι των στοιχείων μιας κεραίας έχουν την μορφή ενός  $M$  – διαστάσεων διανύσματος:  $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_M]^T$  (5.5)

και ότι τα βάρη των στοιχείων εξόδου μπορούν να περιγραφούν πάλι με ένα  $M$  – διαστάσεων διάνυσμα:  $\mathbf{W} = [w_1 \ w_2 \ \dots \ w_M]^T$  (5.6)

Τα βάρη αυτού του πίνακα είναι οι “διεγέρτες” που απαιτούνται για την τροφοδότηση των στοιχείων της κεραίας για να εκτελέσουν την κατάλληλη οδήγηση (*steering*) του κύριου λοβού. Η έξοδος της κεραίας μπορεί να γραφτεί ως:

$$y(t) = \sum_{i=1}^M w_i^* x_i(t) = \mathbf{W}^H \mathbf{X}(t) \quad 5.7$$

Η μέση ισχύς εξόδου δίνεται από την σχέση:

$$P(W) = E[y(t)y^*(t)] = \mathbf{W}^H \mathbf{R} \mathbf{W} \quad (5.8)$$

όπου ο αστερίσκος εκφράζει τον συζυγή μιγαδικό. Για να πάρουμε τα κατάλληλα βάρη ελαχιστοποιούμε την έξοδο της συστοιχίας της κεραίας, έτσι ώστε τα επιθυμητά σήματα (δηλαδή ο/οι user/s) να περάσουν με συγκεκριμένο κέρδος, ενώ παράλληλα ελαχιστοποιείται η συνεισφορά λόγω του θορύβου και των παρεμβολών. Δηλαδή με άλλα λόγια:

$$\min(\mathbf{W}^H \mathbf{R} \mathbf{W}) \text{ με την προϋπόθεση ότι } \mathbf{W}^H \mathbf{S}_d = r \quad 5.9$$

Στην παραπάνω σχέση, ο πίνακας  $\mathbf{r}$  είναι ένα  $V \times 1$  constraint διάνυσμα, που περιλαμβάνει τα επιθυμητά σήματα και το  $\mathbf{S}_d$  είναι το διάνυσμα οδήγησης προς την διεύθυνση του σήματος που πρόκειται να εξυπηρετηθεί. Ο αλγόριθμος που χρησιμοποιείται για την επίλυση του προβλήματος ελαχιστοποίησης της παραπάνω σχέσης είναι η μέθοδος των πολλαπλασιαστών Lagrange. Σύμφωνα με την μεθοδολογία τα διανύσματα που περιλαμβάνουν τα βέλτιστα βάρη τροφοδοσίας (*optimum weight*) της κεραίας είναι:


$$W_{opt} = R^{-1}S_d[S_d^H R^{-1}S_d]^{-1}r \quad 5.10$$

Επειδή η παραπάνω σχέση δεν είναι πρακτική για υλοποίηση σε πραγματικό χρόνο, ένας αλγόριθμος προσαρμογής θα πρέπει να χρησιμοποιηθεί για να προσαρμόζονται τα βάρη της συστοιχίας των στοιχείων της κεραίας, έτσι ώστε να εντοπίζονται και να ενισχύονται τα επιθυμητά σήματα (*user*) και να ελαχιστοποιούνται ή να απορρίπτονται τα σήματα παρεμβολής (*jammers*). Σ' αυτή την περίπτωση το νευρωνικό δίκτυο καθορίζει κατάλληλα βάρη για την σωστή οδήγηση της κεραίας και την σωστή οδήγηση της κεραίας και την ακύρωση των δεσμών/σημάτων.

## 5.4 Νευρωνικό δίκτυο βασισμένο στην ακύρωση των *jammers* (beamforming) – Αποτελέσματα

### 5.4.1 Αρχιτεκτονική NN για beamforming

Στην παράγραφο αυτή περιγράφεται η διαδικασία σχηματοποίησης δέσμης με την χρήση νευρωνικού δικτύου. Το διάνυσμα [*Woptimum*] και ο πίνακας [*r*] συνδέονται με μια μη γραμμική σχέση (σχέση 5.10), στην οποία περιλαμβάνεται και ο πίνακας συσχέτισης [*R(n)*]. Οπότε μπορεί να προσεγγιστεί χρησιμοποιώντας έναν κατάλληλο αλγόριθμο νευρωνικού δικτύου, όπως αυτή της RBF – NN.

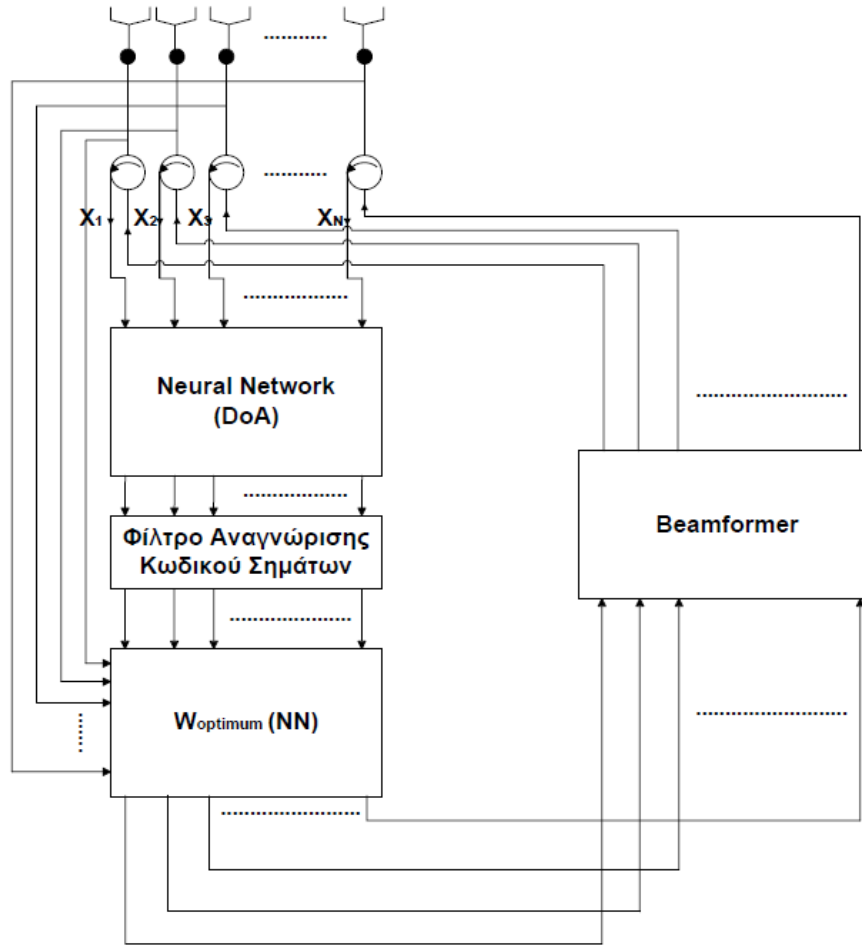


Σχήμα 5.6: Αρχιτεκτονική δικτύου τριών επιπέδων RBF – NN, που χρησιμοποιείται για beamforming

Χρησιμοποιήθηκε η κλασική αρχιτεκτονική RBF – NN με ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και δύο κρυμμένα επίπεδα (σχήμα 5.6). Στην εφαρμογή την οποία πραγματοποιήσαμε για μονοδιάστατη γραμμική στοιχειοκεραία, το επίπεδο εισόδου αποτελείται από  $J = 2M$  κόμβους, για να μπορέσουμε να λάβουμε τόσο το πραγματικό, όσο και το φανταστικό μέρος του διανύσματος εισόδου  $\mathbf{X}(t)$  (σχέση (5.5)). Το επίπεδο εξόδου αποτελείται από  $2M$  κόμβους για να λάβουμε τα διανύσματα εξόδου, που είναι τα βέλτιστα βάρη  $W_{optimum}$ , τα οποία αντιστοιχούν στα ρεύματα τροφοδοσίας της κεραίας και είναι στην γενικότερη περίπτωση μιγαδικοί αριθμοί. Όπως συμβαίνει με τα περισσότερα NN, έτσι και με το RBF – NN το σχεδιάσαμε για να εκτελέσει στο στάδιο της εκπαίδευσης μια αντιστοιχία μεταξύ των ζευγών εισόδου και εξόδου  $(X_t^l, W_{opt}^l)$ ,  $l = 1, 2, \dots, NT$ , όπου το  $NT$  αντιπροσωπεύει το αριθμό των δειγμάτων που περιέχονται στο training set. Η εισαγωγή των κρυμμένων επιπέδων (hidden layer) στο RBF – NN είναι να μετασχηματιστούν τα δεδομένα εισόδου  $\mathbf{X}(t)$  από τον χώρο εισόδου διαστάσεων  $J$ , σε χώρο υψηλότερης διάστασης  $L$ .

#### 5.4.2 Διαδικασία παραγωγής των δεδομένων εκπαίδευσης

Μετά το πέρας της εκπαίδευσης και στην φάση της γενίκευσης (*Generalization*) το δίκτυο δίνει στην έξοδο του τα βέλτιστα βάρη για το κάθε στοιχείο της κεραίας, όταν στην είσοδο του δεχθεί το διάνυσμα των σημάτων των τάσεων εξόδου των στοιχείων των στοιχείων της κεραίας, που προέρχονται από τα προσπίπτοντα κύματα. Προσπαθήσαμε να κάνουμε τις αντίστοιχες διορθώσεις των βαρών των νευρώνων από τους κόμβους του hidden layer προς τους κόμβους output layer. Δηλαδή με άλλα λόγια πήραμε τα αρχικά βάρη του NN, που προέκυψαν από την αρχική εκπαίδευση του δικτύου που την αναλύσαμε στο προηγούμενο κεφάλαιο, και τα βελτιώσαμε, ώστε να μπορέσουμε να **“μηδενίσουμε” τον/τους jammers και να αναδείξουμε τον user.** Στην συνέχεια δίνουμε ένα block διάγραμμα με την αρχιτεκτονική που έχει το δίκτυο που υλοποιήσαμε. Αποτελείται από το νευρωνικό δίκτυο, το δίκτυο που υπολογίζει τα βέλτιστα βάρη και από την διάταξη στην οποία εφαρμόζεται το beamforming.



**Σχήμα 5.7:** Block διάγραμμα με την αρχιτεκτονική που έχει το δίκτυο

Η διαδικασία την οποία ακολουθήσαμε για την παραγωγή των καταλλήλων δεδομένων που απαιτούνται περιγράφεται από τα παρακάτω

1. Αρχικά δημιουργήσαμε τα διανύσματα εξόδου:

$$\begin{aligned} \bar{S}(1) &\rightarrow \{S_1(1), S_2(1), S_3(1) \dots \dots \dots S_M(1)\} \\ \bar{S}(2) &\rightarrow \{S_1(2), S_2(2), S_3(2) \dots \dots \dots S_M(2)\} \\ \bar{S}(NT) &\rightarrow \{S_1(NT), S_2(NT), S_3(NT) \dots \dots \dots S_M(NT)\} \end{aligned}$$

χρησιμοποιώντας την σχέση ( $S_l(l) = \sum_{k=1}^K s_k \exp[-j(m-1)\beta d \cos\theta_m]$ ), η οποία είναι ίδια με την σχέση (5.5). Το  $m$  μεταβάλλεται από 1 έως  $M$  (max αριθμός στοιχείων κεραίας),  $S_k$  είναι η ισχύς του σήματος και το  $l$  μεταβάλλεται από 0 έως  $NT$ , δηλαδή τα training sets.

2. Στην συνέχεια κανονικοποιήσαμε κάθε ένα από τα παραπάνω διανύσματα εξόδου με την νόρμα τους.

3. Στην συνέχεια για κάθε ένα από τα παραπάνω διανύσματα εξόδου, υπολογίζουμε τον πίνακα συσχέτισης, ο οποίος δίνεται από την σχέση 4,17

$R_{mm} \cdot (m, m', n) \sum_{k=1}^K p_k \exp[i(j - (m - m')\omega_0 dc \cos \theta_m)$   
 ) και ο οποίος είναι της μορφής:

$$R(n) = \begin{pmatrix} R_{11}(n) & R_{12}(n) & R_{1M}(n) \\ R_{21}(n) & R_{22}(n) & R_{2M}(n) \\ R_{M1}(n) & R_{M2}(n) & R_{MM}(n) \end{pmatrix}$$


4. Χρησιμοποιώντας τώρα την σχέση (5.10)

$$W_{opt} = R^{-1} S_d [S_d^H R^{-1} S_d]^{-1} r$$

μπορούμε να υπολογίσουμε τα βέλτιστα βάρη  **$W_{optimum}^l, l = 1, 2, \dots, NT$**  και έτσι να παράγουμε τα απαιτούμενα ζεύγη εισόδου – εξόδου από τα δεδομένα εκπαίδευσης ( $(x^l(t), W^l_{opt}), l = 1, 2, \dots, NT$ ).


### 5.4.3 Αποτελεσματα

□ Για ένα σήμα (user): Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 1$  στις 49,5 μοίρες.




□ Για δύο σήματα (ένα user και ένα jammer): Στοιχειοκεραία με  $M = 5$  στοιχεία, ισαπέχοντα κατά  $d = 0,5\lambda$ . Πλήθος σημάτων άφιξης  $K = 2$ .

ί. ο user είναι στις 56,5ο και ο jammer στις 49,5ο (με ίδιο πλάτος)



$$SIR_{\text{output}} \text{ (dB)} = 18,6401 \text{ dB}$$


ii. ο user είναι στις 72,5ο και ο jammer στις 22,5ο (με ίδιο πλάτος)



$$SIR_{\text{output}} \text{ (dB)} = 27,992 \text{ dB}$$

iii. ο user είναι στις 69,5ο και ο jammer στις 89,5ο (jammer μεγαλύτερο πλάτος)





$$SIR_{\text{output}} \text{ (dB)} = 38,5296 \text{ dB}$$

## ΚΕΦΑΛΑΙΟ 6:

### ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ

#### 6.1 Συμπεράσματα για την διεύθυνση άφιξης των σημάτων (DOA)

Αρχικά και προτού αναφέρουμε τα συμπεράσματα που προέκυψαν έχουμε συγκεντρώσει όλα τα στατιστικά αποτελέσματα στους παρακάτω πίνακες, ξεχωριστά για κάθε μια περίπτωση

Αποτελέσματα για ένα σήμα		
Απόσταση μεταξύ των στοιχείων	Στοιχεία Κεραίας	
	M = 5	M = 12
d = 0,5λ	<i>mean</i> = 0.0503 <i>standard deviation</i> = 0.3078	<i>mean</i> = -0.1847 <i>standard deviation</i> = 0.7793
d = 0,7λ	<i>mean</i> = -0.0274 <i>standard deviation</i> = 0.878	<i>mean</i> = -0.2521 <i>standard deviation</i> = 0.916

Αποτελέσματα για δύο σήματα (ένας user και ένας jammer)			
Απόσταση μεταξύ των στοιχείων	Διαφορά πλάτους μεταξύ user & jammer	Στοιχεία Κεραίας	
		M = 5	M = 12
d = 0,5λ	user και jammer ίδιο πλάτος	mean = -0.615 standard deviation = 3.9757	mean = -1.8954 standard deviation = 8.8788
	user μεγαλύτερο πλάτος από jammer κατά 20 dB	mean = 0.096 standard deviation = 1.3592	mean = -1.0344 standard deviation = 3.8594
	jammer μεγαλύτερο πλάτος από user κατά 20 dB	mean = 0.6886 standard deviation = 6.5511	_____
d = 0,7λ	user και jammer ίδιο πλάτος	mean = -3.0868 standard deviation = 8.0268	mean = -3.2307 standard deviation = 8.877
	user μεγαλύτερο πλάτος από jammer κατά 20 dB	mean = 0.4226 standard deviation = 3.518	mean = -1.0814 standard deviation = 6.7839
	jammer μεγαλύτερο πλάτος από user κατά 20 dB	_____	_____

Αρχικά να αναφέρουμε πως η επιλογή του αριθμού των στοιχείων της στοιχειοκεραίας και της απόστασης μεταξύ τους έγινε τυχαία. Να πούμε επίσης πως το δίκτυο που υλοποιήθηκε για όλες τις περιπτώσεις αποτελείται από τέσσερα επίπεδα και πιο συγκεκριμένα από ένα επίπεδο εισόδου (input layer), δύο κρυμμένα επίπεδα (hidden layer) και ένα επίπεδο εξόδου (output layer). Η δε εξίσωση ενεργοποίησης ήταν οι RBF από το input στο πρώτο hidden και η εξίσωση της αντίστροφης διάδοσης (Back Propagation) από το πρώτο hidden στο δεύτερο και από αυτό στο επίπεδο εξόδου. Με την προαναφερθείσα αρχιτεκτονική έγινε η εκπαίδευση όλων των NNs και προέκυψαν τα εξής συμπεράσματα για κάθε μια περίπτωση:

1. Ένα σήμα: παρατηρούμε το νευρωνικό μας δίκτυο να έχει πολύ καλή απόκριση και βρίσκει το σήμα μας με μέση απόκλιση της τάξεως των δύο με τριών μοιρών για κάθε μια θέση που βρίσκεται το σήμα μέσα στην κυψέλη. Αυτό φαίνεται και από τον δείκτη της τυπικής απόκλισης (standard deviation).
2. Δύο σήματα (ένα user και ένα jammer): παρατηρούμε πως η απόκριση του νευρωνικού στις περιπτώσεις όπου η απόσταση μεταξύ των στοιχείων της στοιχειοκεραίας είναι 0,5λ είναι πολύ καλύτερη απ' ό,τι όταν είναι 0,7λ. Αυτό οφείλεται στο γεγονός της παρεμβολής μεταξύ των σημάτων που έρχονται από διαφορετικές γωνίες άφιξης και προσπίπτουν σε διαφορετικά στοιχεία, διότι η

απόσταση 0,7λ είναι αρκετά μεγάλη. Παρόλα αυτά παρατηρούμε πως η απόκλιση, όσον αφορά την γωνία, κυμαίνεται από μηδέν μοίρες όταν ο user είναι μεγαλύτερος από τον jammer κατά 20dB, έως περίπου 20 με 22 μοίρες όταν ο jammer είναι μεγαλύτερος από τον user κατά 20dB. Αυτό φαίνεται και από τον δείκτη της τυπικής απόκλισης (standard deviation).

## **6.2 Συμπεράσματα για την χωρική κατανομή της εκπεμπόμενης ισχύος (Beamforming)**

Σκοπός της διαδικασίας για την χωρική κατανομή της εκπεμπόμενης ισχύος ήταν η απόρριψη του/των jammers και η ανάδειξη/ενίσχυση του user. Παρατηρούμε από τα διαγράμματα ακτινοβολίας τόσο στην περίπτωση ενός σήματος (το οποίο έγινε για να διαπιστώσουμε την εγκυρότητα της μεθόδου με την ενίσχυση του σήματος), όσο και στην περίπτωση που είχαμε έναν user και έναν jammer, το beamforming λειτούργησε πολύ καλά. Εξίσου ικανοποιητικά ήταν και οι τιμές του δείκτη σήματος προς παρεμβολή (SIR = Signal to Interferenc Ratio). Σε όλες τις περιπτώσεις παρατηρούμε πως οι jammers σχεδόν μηδενίζονται, ενώ ο user αναδεικνύεται. Το SIR κυμαίνεται από 9dB έως 40dB.

*Γενικά λοιπόν μπορούμε να συμπεράνουμε τα εξής:*

Ο αλγόριθμος RBF – NN έχει πολύ καλή απόκριση στο πρόβλημα της DOA.

Τα αποτελέσματα είναι αρκετά ικανοποιητικά όσο λιγότερα είναι τα σήματα

Στην περίπτωση πολλών σημάτων παραμένουν αρκετά καλά τα αποτελέσματα.

Μπορεί να υπολογίσει σίγουρα μέχρι 2 σήματα, αλλά και μέχρι 5 για μικρό όμως training set.

Υπήρξε πρόβλημα όσον αφορά το λογισμικό, διότι με τα πολλά δεδομένα που του δίναμε έφτανε σε κορεσμό το δίκτυο.

Δεν έχει καλά αποτελέσματα σε ειδικές περιπτώσεις που το δοκιμάσαμε (όταν οι αποστάσεις μεταξύ των στοιχείων της στοιχειοκεραίας ήταν 0,7λ και ο “jammer” ήταν σε πλάτος (ισχύ μεγαλύτερος από τον “user”).

Στην περίπτωση της διαμόρφωσης της δέσμης της εκπεμπόμενης ακτινοβολίας (beamforming), από τον λόγο SIR που κυμαίνεται μεταξύ 9.5 έως 38.5 dB, συμπεραίνουμε πως ο αλγόριθμος RBF – NN έχει εξίσου καλή απόκριση στο να μηδενίσει τους “jammers” και να ενισχύσει τον “user”.

Άρα η χρήση νευρωνικού δικτύου και συγκεκριμένα ο αλγόριθμος RBF – NN και ο back propagation είναι σε θέση να δώσουν λύση στο πρόβλημα της DOA και να διαμορφώσουν την δέσμη της εκπεμπόμενης ακτινοβολίας.

## ΠΑΡΑΡΤΗΜΑ

### A. Στατιστική Μελέτη

#### A.1 Μέση Τιμή Τυχαίας Μεταβλητής

Θεωρούμε ότι έχουμε τις τιμές και τις αντίστοιχες τους πιθανότητες μίας τυχαίας μεταβλητής. Οι δυνατές αριθμητικές τιμές της τυχαίας μεταβλητής είναι  $x_1, x_2, x_3, \dots$ , με πιθανότητες εμφάνισης  $P(x_1), P(x_2), P(x_3), \dots$ . Καθώς ο αριθμός των μετρήσεων της  $X$  γίνεται πολύ μεγάλος, θα αναμέναμε να βρούμε ότι το γεγονός  $X = x_1$  θα συνέβαινε  $NP(x_1)$  φορές, το γεγονός  $X = x_2$  θα συνέβαινε  $NP(x_2)$  φορές, κλπ. Κατά συνέπεια το αριθμητικό άθροισμα όλων των  $N$  μετρήσεων θα ήταν:

$$x_1 P_{(x_1)} N + x_2 P_{(x_2)} N + \dots = \sum_i x_i P_{(x_i)} \quad (\text{A.1.1})$$

Ο μέσος ή η μέση τιμή όλων αυτών των μετρήσεων και συνεπώς η μέση τιμή της τυχαίας μεταβλητής υπολογίζεται διαιρώντας το άθροισμα στην εξίσωση (A.1.1) με τον αριθμό των μετρήσεων  $N$ . Η μέση τιμή μίας τυχαίας μεταβλητής  $X$  καλείται επίσης *αναμονή* της  $X$  και παριστάνεται είτε με το συμβολισμό  $\bar{X}$  είτε με  $E(X)$ . Θα χρησιμοποιούμε αυτούς τους συμβολισμούς εναλλακτικά. Έτσι, χρησιμοποιώντας το  $m$  για να παραστήσουμε τη μέση τιμή ή αναμονή της  $X$ , από την εξίσωση (A.1.1) έχουμε:

$$\bar{X} \equiv E_{(x)} = m = \sum_i x_i P_{(x_i)} \quad (\text{A.1.2})$$

Για να υπολογίσουμε τη μέση τιμή για μία συνεχή τυχαία μεταβλητή, διαιρούμε το διάστημα της μεταβλητής σε μικρά τμήματα  $\Delta x$ . Τότε από την εξίσωση  $P(x \leq X \leq x + dx) = f(x)dx$  η πιθανότητα η  $X$  να βρίσκεται στο διάστημα μεταξύ  $x_i$  και  $x_i + \Delta x$  είναι  $P(x_i \leq X \leq x_i + \Delta x) = P(x_i)$  και δίνεται προσεγγιστικά από την σχέση:

$$P(x_i) = f(x_i) \Delta x \quad (\text{A.1.3})$$

Αντικαθιστώντας την εξίσωση (A.1.3) στην εξίσωση (A.1.2), έχουμε:

$$m = \sum_i x_i f(x_i) \Delta x \quad (\text{A.1.4})$$

Οριακά, καθώς  $\Delta x \rightarrow 0$  και αντικαθίσταται από το  $dx$ , το άθροισμα της εξίσωσης (A.1.4) γίνεται ολοκλήρωμα:

$$m = \int_{-\infty}^{+\infty} x f_x dx \quad (\text{4.15})$$

Γενικά, η μέση τιμή ή αναμονή μίας συνάρτησης  $g(X)$  της τυχαίας μεταβλητής  $X$  είναι:

$$\overline{g(x)} = E[g(x)] = \int_{-\infty}^{\infty} g(x)f(x)dx \quad (4.16)$$

Αν η συνάρτηση  $g(X)$  είναι η μεταβλητή  $X$  υψωμένη σε δύναμη, δηλαδή  $g(X)=X^n$ , η μέση τιμή  $E(X^n)$  αναφέρεται σαν η  $n$ -οστή ροπή της τυχαίας μεταβλητής. Για το λόγο αυτό η μέση τιμή  $X$  λέγεται επίσης **ροπή πρώτης τάξης** της  $X$ . Αν η τυχαία μεταβλητή  $Z$  είναι συνάρτηση των δύο μεταβλητών  $X$  και  $Y$ , ας πούμε  $Z=w(X,Y)$ , τότε με μία επέκταση όσων έχουμε ήδη αναφέρει μπορεί να δειχθεί ότι:

$$\bar{Z} = \iint_{-\infty}^{\infty} w(x,y)f_{XY}(x,y) dx dy \quad (A.1.7)$$

Ειδικότερα, αν  $Z = XY$ , τότε:

$$\bar{Z} = \int_{-\infty}^{\infty} xy f_{XY}(x,y) dx dy \quad (A.1.8)$$


και αν οι  $X$  και  $Y$  είναι ανεξάρτητες μεταβλητές, τότε:

$$\begin{aligned} \bar{Z} &= \int_{-\infty}^{\infty} xy f_X(x)f_Y(y) dx dy = \int_{-\infty}^{\infty} x f_X(x) dx \int_{-\infty}^{\infty} y f_Y(y) dy = \bar{X}\bar{Y} \\ &= m_x m_y \quad (A.1.9) \end{aligned}$$

## A.2 Διασπορά Τυχαίας Μεταβλητής

Στο σχήμα A.2.1 φαίνονται δυο συναρτήσεις πυκνότητας πιθανότητας  $f(x)$  και  $f'(x)$  για δυο τυχαίες μεταβλητές  $X$  και  $X'$ . Χάριν απλότητας τις έχουμε σχεδιάσει με κάποια γενική μορφή και συμμετρικά γύρω από μία κοινή μέση τιμή  $m$ . Αυτά τα χαρακτηριστικά όμως, δεν είναι ουσιώδη για την αναφορά που θα ακολουθήσει. Μάλλον το σημαντικό σημείο είναι ότι η  $f(x)$  είναι **στενότερη** από την  $f'(x)$ . Ας υποθέσουμε τότε ότι έγιναν πειραματικοί καθορισμοί στις  $X$  και  $X'$  και απέφεραν σαν αριθμητικά γεγονότα τις τιμές  $x$  και  $x'$ . Θα βρίσκαμε σίγουρα ότι το  $x$  θα ήταν κοντύτερα στο  $m$  από ότι το  $x'$  στο  $m$  σχετικά με τη μέση τιμή. Έτσι λοιπόν συγκρίνοντας τις  $X$  και  $X'$ , βρίσκουμε ότι τα γεγονότα της  $X$  έχουν υψηλότερη πιθανότητα να συμβούν σε μικρότερο διάστημα. Με άλλα λόγια αν είχε γίνει ένας

αριθμός καθορισμών των  $X$  και  $X'$ , θα αναμέναμε να βρούμε ότι τα γεγονότα της  $X$  θα συγκεντρώνονταν εγγύτερα γύρω από το  $m$  από ότι στην περίπτωση της  $X'$ .



**Σχήμα A.2.1:** Δυο συναρτήσεις πυκνότητας πιθανότητας που αντιστοιχούν σε τυχαίες μεταβλητές με διαφορετικές διασπορές

Είναι βολικό να έχουμε έναν αριθμό που να εξυπηρετεί στο να εκφράζει ένα μέτρο του "εύρους" μίας συνάρτησης πυκνότητας πιθανότητας. Θα προτείναμε σαν υποψήφιο τη μέση τιμή της  $(X-m)$ , δηλαδή  $\overline{X - m}$ . Ωστόσο,  $\overline{X - m} = 0$ , αφού οι θετικές και αρνητικές συνεισφορές της  $f(x)$  πάνω και κάτω από το  $x$  ακυρώνονται. Μία δεύτερη δυνατότητα είναι  $|\overline{X - m}|$ , αφού λαμβάνοντας την απόλυτη τιμή της  $X - m$  αποφεύγεται η ακύρωση. Ένα χρησιμότερο μέτρο είναι η τετραγωνική ρίζα της μέσης τιμής της  $(X - m)^2$ , δηλαδή της δεύτερης ροπής της  $X - m$ . Αυτή η ροπή δεύτερης τάξης παριστάνεται με το σύμβολο  $\sigma^2$  και καλείται **διασπορά της τυχαίας μεταβλητής**. Έτσι

$$\sigma^2 = E[(X - m)^2] = \int_{-\infty}^{\infty} (X - m)^2 f(x) dx \quad (A. 2.1)$$

Αναπτύσσοντας την ταυτότητα  $(X - m)^2$  στο ολοκλήρωμα της παραπάνω εξίσωσης και ολοκληρώνοντας κάθε όρο ξεχωριστά, βρίσκουμε

$$\sigma^2 = E(X^2) - 2m^2 + m^2 = E(X^2) - m^2 \quad (A. 2.2.)$$

Η ποσότητα  $\sigma$  καθαυτή καλείται **τυπική απόκλιση** και είναι η **μέση τετραγωνική τιμή** της  $(X - m)$ . Αν η μέση τιμή  $m = 0$ , τότε:


$$\sigma^2 = E(X^2) \quad (A. 2.3)$$

### A.3 Η Gaussian Πυκνότητα Πιθανότητας

Η *Gaussian* (καλείται επίσης *κανονική*) συνάρτηση πυκνότητας πιθανότητας είναι μία από τις συναρτήσεις μέγιστης σημασίας διότι πολλά πειράματα που λαμβάνουν χώρα στη φύση χαρακτηρίζονται από τυχαίες μεταβλητές με *Gaussian* πυκνότητα. Η συνάρτηση αυτή είναι σε ειδική συνάφεια με τις τηλεπικοινωνίες, διότι οι τυχαίες μεταβλητές που μας ενδιαφέρουν περιγράφονται, σχεδόν αποκλειστικά, με *Gaussian* συνάρτηση πυκνότητας. Η *Gaussian* συνάρτηση πυκνότητας πιθανότητας ορίζεται από την σχέση:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(x-m)^2/2\sigma^2} \quad (\text{A.3.1})$$

κι απεικονίζεται στο σχήμα A.3.1. Χρησιμοποιώντας τα σύμβολα  $m$  και  $\sigma^2$  στην εξίσωση A.3.1, έχουμε λάβει υπ' όψη ότι  $m$  και  $\sigma^2$  είναι πράγματι η μέση τιμή και η διασπορά που συνδέονται με την  $f(x)$ . Έτσι βρίσκουμε ότι:



Σχήμα A.3.1: Η Gaussian πυκνότητα

πιθανότητας

$$\text{Και } E[(X - m)^2] = \int_{-\infty}^{\infty} \frac{(x-m)^2 e^{-(x-m)^2/2\sigma^2}}{\sqrt{2\pi\sigma^2}} dx = \sigma^2 \quad \text{A.3.2}$$

Μπορεί επίσης να επαληθευτεί ότι:

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad (\text{A.3.3})$$



όπως απαιτείται για μία συνάρτηση πυκνότητας πιθανότητας.

Όπως παρατηρούμε στο σχήμα A.3.1, όταν  $x - m = \pm \sigma$ , δηλαδή στις τιμές του  $x$  που απέχουν από την  $m$  κατά την τυπική απόκλιση, η  $f(x)$  έχει ελαττωθεί στο 0,606 της τιμής κορυφής. Όταν  $x - m = \pm 2\sigma$ , η  $f(x)$  πέφτει στο 0,135 της τιμής κορυφής και στο  $x - m = 3\sigma$  (δεν παρουσιάζεται στο σχήμα), η  $f(x)$  έχει πέσει στο 0,01 της μέγιστης τιμής της.

## B. Κώδικας αλγορίθμων DOA και Beamforming

### B.1 Αλγόριθμος για την DOA

```
Για την περίπτωση με δύο σήματα

M=5; % πλήθος σημειακών πηγών κεραίας;
d=0.5; % απόσταση σημειακών πηγών κεραίας σε μήκη κύματος;
K=2; % πλήθος σημάτων;
fr=2000000000; % συχνότητα σε Hz;
N=120; % θέσεις σημάτων 1&2;

Samp = 1;

theta_var1=0;
theta_var2=0;

l=3*10^8/fr;
dmeter=d*l;

for n=1:1:N-1
    clear theta_var1
    theta_var1=n;
    theta_var1=theta_var1*pi/180;
    clear theta_var2
    for i=1:1:N
        theta_var2(i)=i;
    end
    theta_var2=theta_var2*pi/180;
    clear Sarray
    for k=1:1:N
        for m=1:1:M
            Sarray(k,m)=Samp*(exp((-j)*(m-
1)*(2*pi/l)*dmeter*cos(theta_var1))+exp((-j)*(m-
1)*(2*pi/l)*dmeter*cos(theta_var2(k))));
        end
    end

clear j

P_k_amplitudel=1;
P_k_amplitude2=1;

clear Rsisxet

for k=1:1:N
    for m1=1:1:M
        for m2=1:1:M
            Rsisxet(m1,m2,k)=P_k_amplitudel*exp((j*(m1-
m2)*(2*pi/l)*dmeter*cos(theta_var1)))+P_k_amplitude2*exp((j*(m1-
m2)*(2*pi/l)*dmeter*cos(theta_var2(k))));
        end
    end
end
end
```

```

clear b
clear u

for k=1:1:N
    for m1=1:1:M
        for m2=1:1:M
            u = M*(m2-1)+m1;
            b(1,u,k) = Rsismet(m1,m2,k);
        end
    end
end

clear bb

ind = find(b-2);
bb = b(ind);

clear bbb

L = length(bb)/((M-1)*M);
for g=1:1:L;
    bbb(g,:) = bb((g-1)*20+1:g*20);
end

clear s

for u=1:1:N
    s(u,:)=bbb(u,:)/norm(bbb(u,:));
end

clear s_real
clear s_imag

s_real = real(s);
s_imag = imag(s);

clear s_theta1
clear s_theta2
clear s_theta

s_theta1 = (180/pi).*(theta_var1).*ones(120,1);
s_theta2 = (180/pi).*(theta_var2').*ones(120,1);
s_theta = [s_theta1 s_theta2];

ss = [s_real s_imag s_theta];

fid = fopen('doa_2_gonies_full_train_idio_platos.txt','a');
for k=1:1:N
    fprintf(fid,'%f\t',ss(k,:));
    fprintf(fid,'\n');
end

fprintf(fid,'\n');
fclose(fid);

end

```

## B.2 Αλγόριθμος για το beamforming

```
Για την περίπτωση με δύο σήματα
M=5; πλήθος σημειακών πηγών κεραίας;
d=0.5; απόσταση σημειακών πηγών κεραίας σε μήκη κύματος;
K=2; πλήθος σημάτων;
fr=2000000000; συχνότητα σε Hz;
N=120; θέσεις σημάτων 162;

Samp = 1;

theta_var1=0;
theta_var2=0;

l=3*10^8/fr;
dmeter=d*l;

for n=1:1:N-1

    clear theta_var1
    theta_var1=n;
    theta_var1=theta_var1*pi/180;

    clear theta_var2
    for i=1:1:N
        theta_var2(i)=i;
    end
    theta_var2=theta_var2*pi/180;

    clear Sarray
    for k=1:1:N
        for m=1:1:M
            Sarray(k,m)=Samp*(exp((-j)*(m-
1)*(2*pi/l)*dmeter*cos(theta_var1))+exp((-j)*(m-
1)*(2*pi/l)*dmeter*cos(theta_var2(k))));
        end
    end

    clear S_norm

    for n=1:1:N
        S_norm(n,:)=Sarray(n,:)./norm(Sarray(n,:));
    end

    clear j

    P_k_amplitudel=1;
    P_k_amplitude2=1;

    clear Rsisxet

    for k=1:1:N
        for m1=1:1:M
            for m2=1:1:M
                Rsisxet(m1,m2,k)=P_k_amplitudel*exp((j*(m1-
m2)*(2*pi/l)*dmeter*cos(theta_var1)))+P_k_amplitude2*exp((j*(m1-
m2)*(2*pi/l)*dmeter*cos(theta_var2(k))));
            end
        end
    end
end
```

```

        end
    end
end

clear b
clear u

for k=1:1:N
    for m1=1:1:M
        for m2=1:1:M
            u = M*(m2-1)+m1;
            b(1,u,k) = Rsisket(m1,m2,k);
        end
    end
end

clear bb

ind = find(b-2);
bb = b(ind);

clear bbb

L = length(bb) / ((M-1)*M);

for g=1:1:L;
    bbb(g,:) = bb((g-1)*20+1:g*20);
end

clear s

for u=1:1:N
    s(u,:) = bbb(u,:) ./ norm(bbb(u,:));
end

clear s_real
clear s_imag

s_real = real(s);
s_imag = imag(s);

clear S_d

for m=1:1:M
    for k=1:1:N
        S_d(m,k) = exp((-j)*(m-
1)*(2*pi/1)*dmeter*cos(theta_var1));
    end
end

clear w

for k=1:1:N
    w(:,k) =
inv(Rsisket(:,k))*S_d(:,k)*inv(((S_d(:,k))')*inv(Rsisket(:,k))*S
_d(:,k));
end

```

```

clear ww

for k=1:1:N
    ww(:, :, k) = w(:, :, k).';
end

clear www

ind=find(ww);
www = ww(ind);

clear W

for k=1:1:N
    W(k, :)=www((k-1)*5+1:k*5);
end

clear metro_W
clear max_metro_W
clear w_optimum

for k=1:1:N
    metro_W(k, :) = abs(W(k, :));
    max_metro_W(k, :) = max(metro_W(k, :));
    w_optimum(k, :) = W(k, :)./max_metro_W(k, :);
end

clear w_real
clear w_imag

w_real = real(w_optimum);
w_imag = imag(w_optimum);

ss = [s_real s_imag w_real w_imag];

fid =
fopen('beamforming_2_gonies_full_train_idio_platos.txt', 'a');
for k=1:1:N
    fprintf(fid, '%f\t', ss(k, :));
    fprintf(fid, '\n');
end

fprintf(fid, '\n');
fclose(fid);

end

```

## **ΒΙΒΛΙΟΓΡΑΦΙΑ**

### **A. Βιβλία**

1. C. Christodoulou, M. Georgiopoulos, “*Applications of Neural Networks in Electromagnetic*”, Artech House, 2001.
2. Σ.Σ.Κουρής, “*Στοιχεία θεωρίας κεραιών και διαδόσεως ηλεκτρομαγνητικών κυμάτων*”, Θεσσαλονίκη 1994
3. “MATLAB, Neural network Toolbox user’s Guide”, for Microsoft Windows, The MATHWORKS.
4. C.A.Balanis, *Antenna Theory Analysis and Design, Third Edition*, John Wiley & Sons, 2005
5. P.M.Pozar, *Microwave Engineering, Second Edition*, John Wiley & Sons, 2005
6. H.Taub, D.L.Schilling, *Τηλεπικοινωνιακά Συστήματα, Δεύτερη Έκδοση*, Εκδόσεις Α. Τζιόλα Ε.

### **B. Internet**

7. [http://en.wikipedia.org/wiki/Smart\\_antenna](http://en.wikipedia.org/wiki/Smart_antenna)
8. <http://www.mathworks.com/products/neuralnet/>
9. [http://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/cs11/report.html](http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html)

### **Γ. Αναφορές**

- [1]. McCulloch, W. S., and W. Pitts, "A Logical Calculus of the Ideas Immanent in Nervous Activity," *Bulletin of Mathematical Biophysics*, Vol. 5, 1943, pp. 115-133.
- [2]. Hebb, D. O., *The Organization of Behavior: A Neurophysiological Theory*, New York: Wiley, 1949.
- [3]. Rosenblatt, F., "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain," *Psychological Review*, Vol. 65, 1958, pp. 386-408.
- [4]. Rosenblatt, F., *Principles of Neurodynamics*, Washington, D.C.: Spartan Books, 1962.
- [5]. Widrow, B., and M. A. Hoff, Jr., "Adaptive Switching Circuits," *IRE WESCON Convention Record*, 1960, pp. 96-104.
- [6]. Minsky, M. L., and S. A. Papert, *Perceptrons*, Cambridge, MA: MIT Press, 1969.
- [7]. Grossberg, S., "Adaptive Pattern Classification and Universal Recoding: I. Parallel Development and Coding of Neural Detectors," *Biological Cybernetics*, Vol. 23, 1976a, pp. 121-134.
- [8]. Grossberg, S., "Adaptive Pattern Classification and Universal Recoding: II. Feedback, Expectation, Olfaction, Illusions," *Biological Cybernetics*, Vol. 23, 1976b, pp. 187-202.
- [9]. Kohonen, T., "Correlation Matrix Memories," *IEEE Transactions on Computers*, Vol. C-21, 1972, pp. 353-359.

- [10]. Fukushima, K., "Cognitron: A Self-Organizing Multilayered Neural Network," *Biological Cybernetics*, Vol. 20, 1975, pp. 121-136.
- [11]. Fukushima, K., "Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," *Biological Cybernetics*, Vol. 36, 1980, pp. 193-202.
- [12]. Amari, S., "Dynamics of Pattern Formation in Lateral-Inhibition Type Neural Fields," *Biological Cybernetics*, Vol. 27, 1977, pp. 77-87.
- [13]. Anderson, J. A., "A Simple Neural Network Generating an Interactive Memory," *Mathematical Biosciences*, Vol. 14, 1972, pp. 197-220.
- [14]. Hopfield, J. J., "Neural Networks and Physical Systems with Emergent Collective ' Computational Abilities," *Proceedings of the National Academy of Sciences, USA*, Vol. 79, 1982, pp. 2554-2558.
- [15]. Haykin, S., *Neural Networks: A Comprehensive Foundation*, Englewood Cliffs, NJ: Prentice Hall, 1999.
- [16]. Hertz, J., A. Krogh, and R. G. Palmer, *Introduction to the Theory of Neural Computation*, Reading, MA: Addison-Wesley, 1991.
- [17]. Tou, J. T., and R. C. Gonzalez, *Pattern Recognition Principles*, Reading, MA: Addison-Wesley, 1974.
- [18]. Kohonen, T., *Self-Organisation and Associative Memory* (Second Edition), New York: Springer- Verlag, 1988.
- 167
- [19]. Cybenko, C., "Approximations by Superpositions of Sigmoidal Functions," *Mathematics of Control Signals and Systems*, Vol. 2, 1989, pp. 303-314.
- [20]. Neural Ware Technical Publishing Group, "Neurocomputing," Neuralware Inc., Pittsburgh, PA, 1993.
- [21]. Baum, E. B., and D. Haussler, "What Size Net Gives Valid Generalization," *Neural Computation*, Vol. 1, No. 1, 1989, pp. 151-160.
- [22]. Jacobs, R. A., "Increased Rates of Convergence through Learning Rate Adaptation," *Neural Networks*, 1988, Vol. 1, No. 4, pp. 295-307.
- [23]. Ooyen, A. V., and B. Nienhuis, "Improving Convergence of the Back-Propagation Algorithm," *Neural Networks*, Vol. 5, 1992, pp. 465-471.
- [24]. Demuth, H., and M. Beale, *Neural Network Toolbox for Use with MATLAB, User's Guide* (Fifth Edition), The Math Works, Inc., 1998.
- [25]. Ranganath, H. S., D. E. Kerstetter, and S. R. F. Sims, "Self-Partitioning Neural Networks for Target Recognition," *Neural Networks*, Vol. 8, No. 9, 1995, pp. 1475-1486.
- [26]. Riedmiller, M., and H. Braun, "A Direct Adaptive Method for Faster Back-Propagation Learning: The RPROP Algorithm," *Proceedings of the International Conference on Neural Networks*, 1993.
- [27]. Moody, J. E., and C. J. Darken, "Fast Learning in Networks of Locally Tuned Processing Units", *Neural Computation*, Vol. 1, 1989, pp. 281-294.



- [28]. Kohonen, T., "The Self-Organizing Map," *Proceedings IEEE*, Vol. 78, No. 9, 1990, pp. 1464-1480.
- [29]. Tou, J. T., and R. C. Gonzalez, *Pattern Recognition Principles*, Reading, MA: Addison-Wesley, 1974.
- [30]. Park, J., and I. W. Sandberg, "Universal Approximation Using Radial Basis Function Networks," *Neural Computation*, Vol. 3, 1991, pp. 246-257.
- [31]. Park, J., and I. W. Sandberg, "Approximation and Radial Basis Function Networks", *Neural Computation*, Vol. 5, 1993, pp. 305-316.
- [32]. Gebauer, T., and H. G. Gockler, "Channel-Individual Adaptive Beamforming for Mobile Satellite Communications," *IEEE Journal on Selected Areas in Communications*, Vol. 13, No. 2, 1995, pp. 439-448.
- [33]. Swales, S., et al., "The Performance Enhancement of Multibeam Adaptive Base-Station Antennas for Cellular Land Mobile Radio Systems," *IEEE Transactions on Vehicular Technology*, Vol. 39, No. 1, 1990, pp. 56-67.
- [34]. El Zooghby, A. H., and C. G. Christodoulou, "Optimum Beamforming for Cochannel Interference Nulling in Mobile Satellite Communications", *IEEE Antennas and Propagation Symposium*, Baltimore, MD, July 1996, pp. 552-555.
- [35]. Moozingo, R. A., and T. W. Miller, *Introduction to Adaptive Arrays*, New York, NY: John Wiley, 1980.
- [36]. Jotgenson, M. B., M. Fattouch, and S. T. Nichols, "Applications of Minimum Redundancy Arrays in Adaptive Beamforming," *IEEE Proceedings*, Vol. 138, No. 5, Oct. 1991, pp. 441-447.
- [37]. Gray, S. D., "A Nulling Performance Comparison Between a Single and a Multiple-Aperture Multiple Beam Antenna," *IEEE Transactions on Antennas and Propagation*, Vol. 43, No. 11, 1995, pp. 1319-1324.
- [38]. Naguib, A. F., A. Paulraj and T. Kailath, "Capacity Improvement with Base-Station Arrays in Cellular CDMA," *IEEE Transactions on Vehicular Technology*, Vol. 43, No. 3, Aug. 1994, pp. 691-698.
- [39]. S., I. Claesson and B. Bengtsson, "Adaptive Array Noise Suppression of Speaker Input in Cars," *IEEE Transactions on Vehicular Technology*, Vol. 42, No. 4, 1993, pp. 514-518.
- [40]. Golestaneh, S., H. M. Hafez, and S. Mahmoud, "The Effect of Adjacent Channel Interference on the Capacity of FDMA Cellular Systems," *IEEE Transactions on Vehicular Technology*, Vol. 43, No. 4, 1994, pp. 946-954.
- [41]. Klouche-Djedid, A., and M. Fujita, "Adaptive Array Sensor Processing Applications for Mobile Telephone Communications," *IEEE Transactions on Vehicular Technology*, Vol. 45, No. 3, Aug. 1996, pp.

405-416.

- [42]. Ohgane, T., et al., "An Implementation of a CMA Adaptive Array for High-Speed GMSK Transmission in Mobile Communications," *IEEE Transactions on Vehicular Technology*, Vol. 42, No. 3, p. 282, Aug. 1993, pp. 282-288.
- [43]. Lee W. C. Y., "Applying the Intelligent Cell Concept to PCS," *IEEE Transactions on Vehicular Technology*, Vol. 43, No. 3, 1994, pp. 672-679.
- [44]. Liberti, J., and T. S. Rappaport, "Analytical Results for Capacity Improvements in CDMA," *IEEE Transactions on Vehicular Technology*, Vol. 43, No. 3, 1994, pp. 680-690.
- [45]. Long, L., and Li Yan Da, "Real-Time Computation of the Noise Subspace for the MUSIC Algorithm," *ICASSP*, 1993, Vol. I, pp. 485-488.
- [46]. Goryn D., and M. Kave, "Neural Networks for Narrowband and Wideband Direction Finding," *Proceedings ICASSP*, 1988, pp. 2164-67.
- [47]. Haykin, S. (ed.), *Advances in Spectrum Analysis and Array Processing*, Vol. III, Englewood, Cliffs, NJ: Prentice Hall, 1991.
- [48]. Southall, H. L., J. A. Simmers, and T. H. O' Donnell, "Direction Finding in Phased Arrays With a Neural Network Beamformer," *IEEE Transactions on Antennas and Propagation*, Vol. 43, No. 12, 1995, pp. 1369-1374.
- [49]. El Zooghby, A. H., C. G. Christodoulou, and M. Georgiopoulos, "Performance of Radial Basis Function Networks for Direction of Arrival Estimation with Antenna Arrays," *IEEE Transactions on Antennas and Propagation*, Vol. 45, No. 11, 1997, 1611- 1617.
- [50]. Mulgrew, B., "Applying Radial Basis Functions," *IEEE Signal Processing Magazine*, Vol. 13, No. 2, 1996, pp. 50-65.
- [51]. Haykin, S., *Neural Networks: A Comprehensive Foundation*, New York, NY: Maxwell Macmillan International, 1994.
- [52]. Moody, T. J., and C. J. Darken, "Fast Learning in Networks of Locally Tuned Processing Units," *Neural Computation*, Vol. 1, 1989, p. 281.
- [53]. Wax, M., and T. Kailath, "Detection of Signals by Information Theoretic Criteria," *IEEE Transactions on ASSP*, Vol. 33, 1985, p. 387.
- [54]. Chang, P. R., W. H. Yang, and K. K. Chan, "A Neural Network Approach to MVDR Beamforming Problem," *IEEE Transactions on Antennas and Propagation*, Vol. 40, 1992, pp. 313-322.