

ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΥΠΟΣΤΗΡΙΞΗΣ ΑΠΟΦΑΣΕΩΝ (ΕΡΓΑ.Σ.Υ.Α)

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Πρόβλεψη ζήτησης στην HB BODY ABEE με χρήση νευρωνικών δικτύων

Ματθαίος Παπαδόπουλος



Επιβλέπων Καθηγητής: Αθανάσιος Μυγδαλάς

Εξεταστική Επιτροπή: Καθηγητής Αθανάσιος Μυγδαλάς
Λέκτορας Μιχάλης Δούμπος
Λέκτορας Ηλίας Κοσματόπουλος

XANIA 2005

ΠΕΡΙΕΧΟΜΕΝΑ

ΕΥΧΑΡΙΣΤΙΕΣ	4
ΠΡΟΛΟΓΟΣ.....	5
ΕΙΣΑΓΩΓΗ	6
ΚΕΦΑΛΑΙΟ 1^ο	7
1. Σύντομη Ιστορική Αναδρομή στα Νευρωνικά Δίκτυα.....	7
1. 1 Πρώτες προσπάθειες	8
1. 2 Νέες πολλά υποσχόμενες τεχνολογίες	9
1. 3 Περίοδος απογοητεύσεων και δυσφήμισης.....	10
1. 4 Ανανέωση	11
1. 5 Ανάκαμψη	12
1. 6 Σήμερα	13
ΚΕΦΑΛΑΙΟ 2^ο	15
2. 1 Νευρωνικά Δίκτυα – Βασικές Αρχές.....	15
2. 2 Βιολογικά Νευρωνικά Δίκτυα	16
2. 3 Αναλογία με το ανθρώπινο μυαλό	20
2. 4 Τεχνητά Νευρωνικά Δίκτυα	22
2. 4. 1 Βασικά Συστατικά Τεχνητών Νευρωνικών Δικτύων	24
2. 4. 2 Τοπολογίες και αρχιτεκτονικές	29
2. 5 Πολυεπίπεδα Νευρωνικά Δίκτυα	32
2. 5. 1 Αλγόριθμοι μάθησης πολυστρωματικών ΤΝΔ	33
2. 6 Αλγόριθμος μάθησης με οπισθόδρομη διάδοση.....	34
2. 6. 1 Ψευδοκώδικας.....	35
2. 6. 2 Μαθηματική προσέγγιση	36
2. 7 Εφαρμογές τεχνητών νευρωνικών δικτύων	37
ΚΕΦΑΛΑΙΟ 3^ο	41
3. 1 Γιατί μελετάμε την πρόβλεψη	41
3. 2 Ποιος πρέπει να κάνει προβλέψεις	41

3. 3 Μέθοδοι πρόβλεψης	42
3. 4 Ταξινόμηση προβλέψεων	46
3. 5 Νευρωνικά αντί για παραδοσιακές μεθόδους πρόβλεψης.....	48
3. 6 Πρόβλεψη χρονοσειρών με νευρωνικά δίκτυα.....	52
3. 7 Πρόβλεψη ζήτησης με βάση τη μοντελοποίηση και τον έλεγχο της εφοδιαστικής αλυσίδας	53
ΚΕΦΑΛΑΙΟ 4^ο	56
4. 1 Περιγραφή του προβλήματος	56
4. 1. 1 MATLAB Neural Network Toolbox	56
4. 1. 2 Εκπαίδευση του δικτύου	57
4. 2 Το πρόβλημα	58
4. 2. 1 Η επιχείρηση	58
4. 2. 2 Οι αποθήκες	59
4. 2. 3 Λειτουργία της αποθήκης	60
4. 3 Συγκέντρωση – Επεξεργασία των δεδομένων.....	61
4. 4 Εισαγωγή – Προετοιμασία Δεδομένων στη MATLAB	66
4. 5 Σχολιασμός του κώδικα/ διαδικασίας προγράμματος	67
4. 6 Σχολιασμός των αποτελεσμάτων.....	77
4. 7 Γραφικές απεικονίσεις	79
4. 8 Επεκτάσεις	84
ΠΑΡΑΡΤΗΜΑ Α.....	86
ΠΑΡΑΡΤΗΜΑ Β	87
ΠΑΡΑΡΤΗΜΑ Γ	88
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	90

Ευχαριστίες

Θα ήθελα να ευχαριστήσω ιδιαίτερα τον επιβλέποντα καθηγητή αυτής της διπλωματικής εργασίας, κύριο Αθανάσιο Μυγδαλά, για την ευκαιρία που μου έδωσε να συνεργαστούμε, την καθοδήγηση και τις υποδείξεις του στην περάτωσή της.

Επίσης, τους κυρίους Βασιλειάδη Ηλία, Πασβάτη Νίκο και την κυρία Καμπουρίδου Ελένη από την εταιρία HB BODY A.E καθώς και το υπόλοιπο προσωπικό για την άψογη συνεργασία, τον χρόνο που μου διέθεσαν και τις πολύτιμες συμβουλές τους.

Τέλος, θα πρέπει να ευχαριστήσω τους μεταπτυχιακούς φοιτητές του εργαστηρίου για την τεχνική υποστήριξη που μου παρείχε και ιδιαίτερα τον υποψήφιο διδάκτορα Μαρινάκη Γιάννη για την συνεργασία του.

ΠΡΟΛΟΓΟΣ

Σκοπός αυτής της εργασίας είναι να εξετάσει το κατά πόσο μπορεί να εφαρμοστεί με επιτυχία η θεωρία των τεχνητών νευρωνικών δικτύων στην πρόβλεψη των πωλήσεων. Μία συγκεκριμένη δομή, το δίκτυο εμπρόσθιας διάδοσης που εκπαιδεύονται με τον αλγόριθμο οπισθόδρομης διάδοσης (feed forward back propagation network) αποτελεί την πιο διαδεδομένη αρχιτεκτονική για τις εφαρμογές νευρωνικών δικτύων. Είναι τοπίο συχνά χρησιμοποιούμενο δίκτυο και αυτό με τις περισσότερες εφαρμογές. Δημιουργήσαμε ένα δίκτυο αυτού του είδους για την πρόβλεψη της ζήτησης σε περιβάλλον MATLAB. Χρησιμοποιήσαμε το αντίστοιχο εργαλείο της MATLAB, το Neural Network Toolbox.

Τα νευρωνικά δίκτυα μαθαίνουν με παραδείγματα. Ο χρήστης συλλέγει αντιπροσωπευτικά δεδομένα και στη συνέχεια επιστρατεύει αλγόριθμους εκπαίδευσης για να μάθει το δίκτυο τον τρόπο που εμφανίζονται οι τιμές των δεδομένων. Τα δεδομένα της εφαρμογής μας προέρχονται από την εταιρία HBBODY A.E. Πρόκειται για μία κορυφαία στον τομέα της εταιρία παραγωγής και εμπορίας βιομηχανικών χρωμάτων, παραγώγων τους και συναφών ειδών με έδρα την Θεσσαλονίκη. Τα δεδομένα αφορούν μία περίοδο 24 μηνών. Υπολογίστηκε η συνολική ζήτηση κάθε μήνα για τους 25 πελάτες της Θεσσαλονίκης με τον μεγαλύτερο τζίρο. Τα δεδομένα των πρώτων 18 μηνών αποτελούν τα δεδομένα τις εκπαίδευσης Τα δεδομένα των επόμενων 5 μηνών χρησιμοποιούνται για τον έλεγχο του δικτύου και ο τελευταίος μήνας χρησιμοποιείται σαν είσοδος για την πρόβλεψη της άγνωστης ζήτησης κατά τον 25^ο μήνα.

Τα αποτελέσματα ήταν ενθαρρυντικά για την χρήση των νευρωνικών δικτύων σε προβλήματα πρόβλεψης.

ΕΙΣΑΓΩΓΗ

Αρχικά κάνουμε μία ιστορική αναδρομή στην ανάπτυξη και την χρήση των τεχνητών νευρωνικών δικτύων. Αναφέρουμε τους σημαντικότερους σταθμούς στην δημιουργία και την εφαρμογή τους σε πραγματικά προβλήματα και τις φάσεις από τις οποίες πέρασε η ανάπτυξή τους.

Στη συνέχεια αναφέρουμε στοιχεία σχετικά με τα βιολογικά νευρωνικά δίκτυα από την μελέτη των οποίων άρχισε να αναπτύσσεται και ο τομέας των τεχνητών νευρώνων. Βλέπουμε τα βασικά τους συστατικά και τις λειτουργίες ενώ τα αντιπαραβάλλουμε με τα συστατικά και τις λειτουργίες των τεχνητών δικτύων.

Επικεντρωνόμαστε στην πρόβλεψη της ζήτησης στην εφοδιαστική αλυσίδα. Αναφέρουμε τις σημαντικότερες μεθόδους προβλέψεων και βλέπουμε μέσα από την εξέλιξή τους την εφαρμογή της πρόβλεψης με νευρωνικά δίκτυα και την χρησιμότητα της τελευταίας.

Τέλος περνάμε στο πρόβλημα που κληθήκαμε να επιλύσουμε. Στην περίπτωση της εταιρίας HB BODY. Παρουσιάζουμε το πρόβλημα, περιγράφουμε τον τρόπο με τον οποίο δουλέψαμε για το επιλύσουμε, παρουσιάζουμε και αναλύουμε τα αποτελέσματα της εργασίας μας και τα συμπεράσματά μας.

ΚΕΦΑΛΑΙΟ 1^ο

1. Σύντομη Ιστορική Αναδρομή στα Νευρωνικά Δίκτυα

Οι προσομοιώσεις νευρωνικών δικτύων είναι ένα σχετικά πρόσφατο επίτευγμα. Ο τομέας αυτός όμως προϋπήρχε της εξάπλωσης των ηλεκτρονικών υπολογιστών. Πολλές σημαντικές πρόοδοι έχουν σημειωθεί με την χρήση μη ακριβών μηχανημάτων. Μετά από μία περίοδο ενθουσιασμού ακολούθησε, όπως ήταν αναμενόμενο, μία άλλη απογοήτευσης και μαρασμού. Κατά την διάρκεια αυτής της περιόδου αν και η χρηματοδότηση ήταν χαμηλή και η επαγγελματική υποστήριξη σχεδόν ανύπαρκτη, σημειώθηκαν κάποιες πολύ σημαντικές πρόοδοι από σχετικά λίγους ερευνητές. Αυτοί οι πρωτοπόροι κατάφεραν να αναπτύξουν πειστικές τεχνολογίες οι οποίες ξεπέρασαν τους μέχρι τότε περιορισμούς των *Minsky* και *Papert*. Οι δύο τελευταίοι εξέδωσαν ένα βιβλίο το 1969 στο οποίο συγκεντρωνόταν η απογοήτευση πολλών ερευνητών και έτσι έγινε αποδεκτό από τους περισσότερους χωρίς περαιτέρω ανάλυση. Στα επόμενα χρόνια και μέχρι σήμερα, τα νευρωνικά δίκτυα παρουσιάζονται ιδιαίτερα ελκυστικά με ενδιαφέρουσες εφαρμογές ενώ οι χρηματοδοτήσεις για έρευνα είναι σαφώς καλύτερες.

Για την αρχή των Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ) πρέπει να ανατρέξουμε πάνω από 50 χρόνια στις εργασίες των *McCulloch* και *Pitts* στις αρχές της δεκαετίας του 1940 (1943). Η πρώτη συνεισφορά για τη λειτουργία της μάθησης στα βιολογικά νευρωνικά δίκτυα έγινε από τον *Hebb* το 1949, ο οποίος πρότεινε ότι η μάθηση σε τέτοια δίκτυα είναι αποτέλεσμα σχηματισμού πολλών ομάδων νευρώνων και βασίζεται στην ισχύ των συνάψεων των νευρώνων οι οποίοι ενεργοποιούνται συγχρόνως. Πρωτοπόρος εργασία στον τομέα μάθηση ΤΝΔ επιτεύχθηκε στα τέλη της δεκαετίας του 1950 από τον *Rosenblatt* (1958), που εισήγαγε τα πρότυπα *Perceptrons* καθώς και του *Widrow* το 1959, που έδειξαν με πειραματικές μελέτες ότι τα ΤΝΔ έχουν δυνατότητα μάθησης.

Η λειτουργία πολυστρωματικών (πολυεπίπεδων – multilayered) ΤΝΔ δεν είχε κατανοηθεί ακόμη την περίοδο εκείνη κι έτσι η έρευνα είχε εστιαστεί σε απλά δομημένα πρότυπα *Perceptron*. Ακολούθησαν οι Εκπαιδευόμενες Μηχανές (*learning machines*) στις αρχές του 1960. Το 1969 οι *Minsky* και *Papert* στο θεμελιώδες βιβλίο τους “*Perceptrons*” παρουσίασαν τη θεωρία των μηχανισμών αντίληψης (*perceptrons*) , όπου υποστήριξαν ορθά ότι τα δίκτυα αυτά έχουν περιορισμένες δυνατότητες μάθησης. Τα αποτελέσματα των δύο αυτών ερευνητών και η έλλειψη αλγορίθμων μάθησης είχαν καταστρεπτική επιρροή στην έρευνα στα ΤΝΔ με αποτέλεσμα τη σημαντική κάμψη της ερευνητικής δραστηριότητας και γενικώς του ενδιαφέροντος για τα ΤΝΔ για δεκαπέντε περίπου χρόνια.

Στις αρχές του 1980 επανέρχονται τα ΤΝΔ στο προσκήνιο λόγω κυρίως της συνεχιζόμενης εργασίας του *Hopfield*. Νέοι και ισχυροί αλγόριθμοι μάθησης όπως αυτοί του *Werbos* (1984), του *Parker* (1985) και του *Rumelhart* (1986) ήρθαν να ανατρέψουν τις δυσοίωνες προβλέψεις για τα *Perceptron* και τα ΤΝΔ γενικά.

Η πρόοδος στον τομέα των ολοκληρωμένων κυκλωμάτων μεγάλης κλίμακας (VLSI) και στους παράλληλους υπολογιστές είχαν ως αποτέλεσμα την εντυπωσιακή επανεκδήλωση του ενδιαφέροντος στον τομέα της έρευνας στα ΤΝΔ. Η εξέλιξη στη συνέχεια ήταν ραγδαία και σήμερα τα ΤΝΔ αποτελούν σημαντικό πεδίο βασικής και εφαρμοσμένης έρευνας σε πολλούς τομείς, όπως σε συστήματα αναγνώρισης ταυτότητας και ταξινόμησης προτύπων, την επεξεργασία εικόνας και ομιλίας, τη μηχανική όραση, τη ρομποτική, την ιατρική, τα συστήματα ελέγχου κ. α.

Παλιότερα επικρατούσε η αντίληψη ότι τα νευρωνικά δίκτυα είναι ένα μαύρο κουτί το οποίο μπορεί να εφαρμοστεί επιτυχώς χωρίς να γνωρίζουμε ακριβώς από τι αποτελείται. Αυτό όμως συνεπάγονταν ότι θα έπρεπε να αναπτύσσονται νευρωνικά συστήματα μέσω της μεθόδου δοκιμής και σφάλματος. Το τελευταίο αποδείχτηκε ιδιαιτέρως αναποτελεσματικό.

1. 1 Πρώτες προσπάθειες

Υπήρξαν κάποιες αρχικές προσομοιώσεις που χρησιμοποιούσαν την κοινή λογική. Το 1942, ο *Norbert Wiener* και οι συνεργάτες του έβαζαν τα θεμέλια σε αυτό που αργότερα ονομάστηκε *Cybernetics* και το οποίο ορίζονταν ως έλεγχος και επικοινωνία στα ζώα και στις μηχανές. Κεντρική ιδέα σε αυτό το πρόγραμμα αποτελεί η σκέψη ότι βιολογικοί μηχανισμοί μπορούν να προσεγγιστούν με την μηχανική και τα μαθηματικά.

Με την ανάπτυξη της τεχνητής νοημοσύνης, ο όρος κυβερνητικές μηχανές (*cybernetics*) έγινε λιγότερο δημοφιλής. Την ίδια χρονιά που ο *Weiner* μορφοποιούσε θα λέγαμε τα *cybernetics*, οι *McCulloch* και *Pitts* εξέδιδαν την πρώτη διατριβή πάνω στα τεχνητά νευρωνικά δίκτυα. Το κυριότερο αποτέλεσμα αυτής της ιστορικής εργασίας ήταν το ότι οποιαδήποτε καλά ορισμένη συσχέτιση εισόδου- εξόδου μπορεί να προσεγγιστεί με ένα νευρωνικό δίκτυο. Τα μοντέλα τους ήταν βασισμένα στις γνώσεις τους πάνω στην νευρολογία. Ήταν αντίστοιχα νευροφυσιολόγος και μαθηματικός. Αυτά τα μοντέλα έκαναν πολλές υποθέσεις για το πως λειτουργούν οι νευρώνες. Τα δίκτυά τους βασίζονταν σε απλούς νευρώνες τους οποίους θεωρούσαν δυαδικές συσκευές με καθορισμένα κατώφλια. Τα αποτελέσματα του μοντέλου τους

ήταν απλές λογικές συναρτήσεις όπως «α και β» και «α ή β». Κατάφεραν να μοντελοποιήσουν ένα νευρωνικό δίκτυο με ηλεκτρικά κυκλώματα.

Το 1949 ο *Donald Hebb* εισήγαγε έναν μηχανισμό που θα μπορούσε να λειτουργεί και σε έναν ζωντανό οργανισμό. Οι δυνάμεις συνοχής μεταβάλλονταν έτσι ώστε να ενισχύουν κάθε δυνατή αντιστοιχία στα επίπεδα δραστηριοτήτων μεταξύ των νευρώνων πριν και μετά από κάθε σύναψη. Αυτό στην γλώσσα των νευρωνικών δικτύων, μεταφράζεται ως εξής: το βάρος μιας εισόδου θα πρέπει να προσαρμόζεται για να αντανakλά τη συσχέτιση μεταξύ εισόδου και εξόδου. Τα μαθησιακά σχήματα τα οποία βασίζονται στον μαθησιακό κανόνα του *Hebb* είχαν πάντα σημαντικό ρόλο στην ανάπτυξη νευρωνικών δικτύων. Υποστήριξε για πρώτη φορά ότι κάθε φορά που χρησιμοποιούμε ένα δίκτυο, η ισχύς του και οι δυνατότητές του ενδυναμώνονται.

Μία άλλη προσπάθεια χρησιμοποίησε προσομοιώσεις με ηλεκτρονικό υπολογιστή. Πρεσβεύονταν από δύο ομάδες: *Farley* και *Clark* (1954) και *Rochester, Holland, Haibit* και *Duda* (1956). Οι πρώτοι ήταν ερευνητές της IBM σε στενή επαφή με επιστήμονες της νευρολογίας του πανεπιστημίου McGill, τους οποίους συμβουλευόνταν όποτε τα μοντέλα τους δεν λειτουργούσαν κατά το επιθυμητό. Αυτή η επικοινωνία δημιούργησε μία τάση που υπάρχει μέχρι και σήμερα.

Το 1956, ώθηση στα νευρωνικά δίκτυα αλλά και στην τεχνητή νοημοσύνη γενικότερα έδωσε το Dartmouth Summer Research Project on AI. Ένα από τα αποτελέσματά του ήταν η εστίαση της έρευνας τόσο στην ευφυή πλευρά (AI – τεχνητή νοημοσύνη) όσο και στα κατώτερα επίπεδα επεξεργασίας με νευρώνες στο μυαλό.

1. 2 Νέες πολλά υποσχόμενες τεχνολογίες

Η επιστήμη της νευρολογίας ήταν η μόνη που επηρέασε την ανάπτυξη των νευρωνικών δικτύων. Πολλοί ψυχολόγοι και μηχανικοί συνέβαλαν στην πρόοδο των προσομοιώσεων νευρωνικών δικτύων. Ο John Von Neumann πρότεινε την μίμηση απλών λειτουργιών νευρώνων χρησιμοποιώντας τηλεγραφικούς ηλεκτρονόμους (αναμεταδότες).

Ο *Frank Rosenblatt* (1958), νευροβιολόγος, έστρεψε το ενδιαφέρον και δραστηριοποίησε τον τομέα των νευρωνικών δικτύων όταν σχεδίασε και ανέπτυξε το Perceptron. Το Perceptron είχε τρία επίπεδα με το μεσαίο να είναι το συνδετικό επίπεδο. Αυτό το σύστημα μπορούσε να μάθει να συνδέει, ή καλύτερα να συσχετίζει, ένα δεδομένο εισόδου σε ένα τυχαίο δεδομένο εξόδου. Μπορούσε να ταξινομεί μία συνεχή ροή δεδομένων (τιμών) εισόδου σε μία από δύο ομάδες (κλάσεις). Το perceptron υπολόγιζε ένα σταθμισμένο άθροισμα των τιμών εισόδων,

παρήγαγε ένα κατώφλι και εξήγαγε ένα από τα δύο διαθέσιμα αποτελέσματα. Ήταν το πρώτο τεχνητό νευρωνικό δίκτυο που κατασκευάστηκε και είναι το παλιότερο νευρωνικό δίκτυο που χρησιμοποιείται ακόμα και σήμερα. Το σημαντικότερο αποτέλεσμα της εργασίας του *Rossenblatt*, ήταν η απόδειξη ότι απλές διαδικασίες εκπαίδευσης όπως ο κανόνας εκπαίδευσης του perceptron μπορούσαν να δείξουν αν υπάρχει λύση σε ένα πρόβλημα. Το έναυσμα για την έρευνά του ήταν η λειτουργία του ματιού της μύγας: Η περισσότερη επεξεργασία σχετικά με το που θα πετάξει η μύγα, γίνεται στο μάτι της.

Ένα άλλο σύστημα υπήρξε το ADALINE (ADaptive LInear Element) το οποίο αναπτύχθηκε το 1960 από τους *Bernard Widrow* και *Marcian Hoff* του πανεπιστημίου του Stanford. Το ADALINE ήταν μία αναλογική ηλεκτρονική συσκευή αποτελούμενη από απλά μέρη. Η μέθοδος με την οποία «μάθαινε» ήταν διαφορετική από αυτήν του Perceptron. Χρησιμοποιούσε τον μαθησιακό κανόνα των ελάχιστων μέσων τετραγώνων (Least Mean Squares – LMS). Ανέπτυξαν επίσης και το μοντέλο MADALINE (Multiple ADaptive LInear Elements) το οποίο αποτέλεσε και το πρώτο τεχνητό νευρωνικό δίκτυο που βρήκε εφαρμογή σε πραγματικό πρόβλημα. Πρόκειται για ένα φίλτρο που εξαλείφει την ηχώ στις τηλεφωνικές γραμμές και χρησιμοποιείται εμπορικά μέχρι και σήμερα.

1.3 Περίοδος απογοήτευσης και δυσφήμισης

Οι επιτυχίες που προηγήθηκαν οδήγησαν τους ερευνητές στην υπερβολή σε ότι αφορούσε τις δυνατότητες των νευρωνικών δικτύων και ιδιαίτερα σχετικά με τα ηλεκτρονικά εξαρτήματα που ήταν τότε διαθέσιμα. Η απογοήτευση ήταν έκδηλη τόσο σε ακαδημαϊκό όσο και σε τεχνικό επίπεδο όσο οι – υπερβολικές- προσδοκίες και απαιτήσεις έμεναν ανεκπλήρωτες. Επίσης, καλλιεργήθηκε ο φόβος της επίδρασης που θα μπορούσε να έχει μία σκεπτόμενη μηχανή στον άνθρωπο. Ακόμα και στον κινηματογράφο, η σειρά του *Asimov* για τα ρομπότ φανέρωνε αυτόν τον φόβο «αποκαλύπτοντας» τις συνέπειες στις αξίες και την ηθική των ανθρώπων σε μία εποχή όπου οι μηχανές θα μπορούσαν να αντικαταστήσουν τους ανθρώπους σε όλους τους τομείς.

Το 1969 οι *Marvin Minsky* και *Seymour Papert* έγραψαν ένα βιβλίο στο οποίο γενίκευαν τους περιορισμούς του μονοεπίπεδου Perceptron και για τα πολυεπίπεδα συστήματα. Χαρακτηριστικά, έγραψαν «... την ενστικτώδη κρίση μας ότι η επέκταση (σε πολυεπίπεδα συστήματα) είναι ατελέσφορη». Το σημαντικό αποτέλεσμα του βιβλίου αυτού ήταν να περιοριστούν σε μεγάλο βαθμό οι χρηματοδοτήσεις για την έρευνα σχετικές με προσομοιώσεις με νευρωνικά δίκτυα. Έτσι έπαψαν πολλοί ερευνητές να ασχολούνται με αυτόν τον τομέα

δημιουργώντας μία προκατάληψη και επηρεάζονται αρνητικά και άλλους. Ο λόγος ήταν τα γραμμικώς μη διαχωρίσιμα προβλήματα τα οποία το μονοεπίπεδο perceptron δεν μπορούσε να επιλύσει. Αλλά ακόμα και σε ένα πολυεπίπεδο δίκτυο, δεν μπορούσαν να υπολογίσουν πόσο συνεισφέρει κάθε επίπεδο (ιδιαίτερα αν αυτό δεν είναι το επίπεδο εξόδου) στο σφάλμα που έχει σημειώσει το δίκτυο κατά την εκπαίδευση του εκάστοτε διανύσματος. Και αυτό το συμπέρασμα προέκυψε, παρ' ότι ο *Minsky* μαζί με τον *Dean Edmonds* έφτιαξαν το 1951 τις πρώτες μηχανές μάθησης βασισμένες στα δίκτυα.

1. 4 Ανανέωση

Παρόλο που το ενδιαφέρον είχε ατονήσει και οι χρηματοδοτήσεις ήταν σχεδόν ανύπαρκτες, κάποιοι ερευνητές συνέχισαν να δουλεύουν προσπαθώντας να αναπτύξουν υπολογιστικές μεθόδους βασισμένες στην μορφολογία των νευρωνικών δικτύων για προβλήματα όπως η αναγνώριση προτύπων. Κατά την διάρκεια αυτής της περιόδου, αναπτύχθηκαν πολλά παραδείγματα, αρκετά εκ των οποίων συνεχίζουν να ενισχύονται και να επεκτείνονται ακόμα και στις μέρες μας. Η επιρροή του *Grossberg* (*Steve Grossberg* και *Gail Carpenter* το 1988) γέννησε μία σχολή σκέψης η οποία εξετάζει αλγόριθμους για την αναπαραγωγή ήχων. Ανέπτυξαν τα δίκτυα ART (*Adaptive Resonance Theory networks*) βασισμένα σε βιολογικά αληθοφανή και αρκετά πειστικά μοντέλα. Οι *Anderson* και *Kohonen* ανέπτυξαν ανεξάρτητες συνδυαστικές τεχνικές. Ο *Klopf* το 1972 ανέπτυξε μία βάση για την μάθηση σε τεχνητούς νευρώνες, η οποία στηριζόταν σε μία βιολογική αρχή νευρωνικής μάθησης, την ετερόσταση (*heterostasis*).

Το 1967 ο *Amari* (*A. Shun- Ichi*) ανέπτυξε θεωρητικά μία μαθηματική θεωρία για μία βάση μάθησης (μέθοδος διόρθωσης λαθών) για την προοδευτική αναγνώριση προτύπων. Εν τω μεταξύ, ο *Fukushima* (*F. Kunihiro*) ανέπτυξε ένα πολυεπίπεδο νευρωνικό δίκτυο για μετάφραση χειρόγραφων χαρακτήρων. Το αρχικό δίκτυο εκδόθηκε το 1975 και ονομάστηκε *Cognitron*.

Το 1974 ο *Paul Werbos* ανέπτυξε και χρησιμοποίησε την μέθοδο μάθησης με οπισθόδρομη διάδοση αν και χρειάστηκαν αρκετά χρόνια για να γίνει δημοφιλής μέθοδος. Τα δίκτυα οπισθόδρομης διάδοσης είναι τα πιο γνωστά και αυτά με τις περισσότερες εφαρμογές σήμερα. Στην ουσία πρόκειται για πολυεπίπεδο *Perceptron*, διαφορετική συνάρτηση εκκίνησης στον τεχνητό νευρώνα και έναν πιο στιβαρό και ικανό κανόνα μάθησης. Αν και πρωτοαναπτύχθηκε από τον *Werbos*, ανακαλύφθηκε εκ νέου από τον *Parker* και έγινε ιδιαίτερος γνωστός από τους *Rumelhart*, *Hinton* και *Williams*.

1. 5 Ανάκαμψη

Η πρόοδος στα τέλη της δεκαετίας του 1970 και στις αρχές του 1980 ήταν πολύ σημαντική και οδήγησε σε αναζωπύρωση του ενδιαφέροντος για τα νευρωνικά δίκτυα. Πολλοί παράγοντες βοήθησαν σε αυτό. Για παράδειγμα, περιεκτικά, διεξοδικά βιβλία και συνέδρια παρείχαν ένα forum για ανθρώπους από διάφορους τομείς με εξειδικευμένες τεχνικές γλώσσες και η ανταπόκριση σε συνέδρια και εκδόσεις ήταν θετική. Υπήρξε αυξημένο ενδιαφέρον λόγω της αυξημένης κινητικότητας και διάφορα πανεπιστημιακά μαθήματα βοήθησαν στο να γίνει περισσότερο κατανοητή η σχετική τεχνολογία. Εμφανίστηκαν ακαδημαϊκά προγράμματα και εισήχθησαν σχετικά μαθήματα στα μεγαλύτερα πανεπιστήμια Ευρώπης και Αμερικής. Το ενδιαφέρον τώρα εστιάζεται στα επίπεδα των χρηματοδοτήσεων σε Ασία, Ευρώπη και Αμερική. Όσο αυτές οι χρηματοδοτήσεις είναι διαθέσιμες, εμφανίζονται στην αγορά νέες εφαρμογές στην βιομηχανία και την οικονομία.

Το 1982 ο *John Hopfield* υποστήριξε ότι ένα δίκτυο λογικών μονάδων οι οποίες παρουσιάζουν αυξημένη συνδεσιμότητα μπορεί να αναλυθεί αν θεωρηθεί ως ένα φυσικό δυναμικό σύστημα το οποίο περικλείει μία «ενέργεια». Η διαδικασία κατά την οποία το δίκτυο ξεκινά με ένα τυχαίο αρχικό επίπεδο και καταλήγει σε ένα σταθερό τελικό επίπεδο, μπορεί να παρομοιαστεί με ένα σύστημα το οποίο μπαίνει σε κατάσταση ελάχιστης ενέργειας. Αυτή η προσέγγιση των δικτύων με διαδρομές ανατροφοδότησης στις συνδέσεις τους απέφερε πολλούς καρπούς και βοήθησε στην ανάμιξη των φυσικών με τα δίκτυα καθώς τα μαθηματικά μοιάζουν πολύ με αυτά του μοντέλου Ising- spin των μαγνητικών φαινομένων στα υλικά. Η προσέγγιση του *Hopfield* δεν είχε σκοπό να απλοποιήσει το μυαλό, αλλά να δημιουργήσει χρήσιμες συσκευές. Με σαφήνεια και μαθηματική ανάλυση, κατάφερε να δείξει πως μπορούν να δουλέψουν αυτά τα δίκτυα και τι μπορούν να κάνουν.

Ένα μοντέλο παρόμοιο με αυτό του *Hopfield* είχε εισάγει προηγουμένως ο *Little*, αλλά η έμφαση δίνονταν στις αναλογίες των συστημάτων περιστροφής (spin) και όχι τόσο στην ενέργεια.

Παράλληλα, σε ένα συνέδριο στο Κιότο (US-Japan Joint Conference on Cooperative/Competitive Neural Networks) ανακοινώθηκε ότι η Ιαπωνία ξεκινά τις προσπάθειες 5^{ης} γενιάς. Τα περιοδικά μεταφέραν την είδηση δημιουργώντας τον φόβο ότι η Αμερική δεν θα έπρεπε να μείνει πίσω. Έτσι επέστρεψαν οι χρηματοδοτήσεις και το ενδιαφέρον περισσότερων ερευνητών στον τομέα των νευρωνικών δικτύων.

Μέχρι το 1985 το Αμερικανικό Ινστιτούτο Φυσικής (American Institute of Physics) είχε καθιερώσει μία ετήσια συνάντηση με θέμα «Neural Networks for Computing» και το 1987 το ινστιτούτο ηλεκτρολόγων και ηλεκτρονικών μηχανικών (Institute of Electrical and Electronic Engineering – IEEE), διοργάνωσε το πρώτο διεθνές συνέδριο για τα νευρωνικά δίκτυα συγκεντρώνοντας πάνω από 1800 συμμετοχές.

Το 1989 κατά την ομιλία του στη συνάντηση για τα νευρωνικά δίκτυα σε θέματα άμυνας, ο *Bernard Widrow* ανέφερε ότι βρισκόμαστε στον 4^ο παγκόσμιο πόλεμο καθώς ο 3^{ος} δεν συνέβη ποτέ. Τα πεδία των μαχών ήταν το παγκόσμιο εμπόριο και οι κατασκευές. Το 1990, το πρόγραμμα για την έρευνα στην ανανέωση των μικρών επιχειρήσεων του τμήματος άμυνας της Αμερικής, καθόρισε 16 τομείς οι οποίοι ήταν άμεσα σχετιζόμενοι με τα νευρωνικά δίκτυα και άλλους 13, όπου τα νευρωνικά δίκτυα θα μπορούσαν κατά πάσα πιθανότητα να έχουν εφαρμογές.

Η ανάλυση των νευρωνικών δικτύων πέρα από την τεχνολογική πρόοδο, μπορεί αν αποδοθεί και σε μία γενικότερη τάση των φυσικών επιστημών να εξετάσουν μια πιο ευρεία ομάδα συστημάτων όπως είναι τα χαοτικά φαινόμενα, τα fractals κλπ. Η φυσική προσπαθεί παραδοσιακά να δώσει ερμηνείες θεωρώντας ότι υπάρχει ένα απλό παγκόσμιο μοντέλο για πολλά από αυτά τα συστήματα. Αυτό το μοντέλο ανάλογα με την περίπτωση περιγράφεται από διαφορετική μαθηματική εξίσωση. Πολλοί ερευνητές μέχρι και τις μέρες μας καλούνται να αντιμετωπίσουν την πολυπλοκότητα των δυναμικών συστημάτων. Υποθέτουν ότι θα πρέπει να εξετάσουμε τα μοντέλα αυτά μακροσκοπικά θεωρώντας ότι αποτελούνται από ένα μεγάλο αριθμό στοχαστικών στοιχείων τα οποία δρουν ταυτόχρονα και αρμονικά.

1. 6 Σήμερα

Η σημερινή εποχή είναι μία μεταβατική περίοδος για την τεχνολογία νευρωνικών δικτύων. Σε όλους τους τομείς γίνεται λόγος για την χρήση νευρωνικών δικτύων, καθώς και η φύση από μόνη της αποδεικνύει ότι αυτά λειτουργούν και λειτουργούν καλά. Το μέλλον της έρευνας θα πρέπει να εστιαστεί στην ανάπτυξη τεχνητών δικτύων καθώς μέχρι πριν από λίγα χρόνια όλες οι

προσπάθειες αφορούσαν την απόδειξη της αποτελεσματικότητας και της λειτουργίας τους. Τα νευρωνικά δίκτυα, λόγω των περιορισμένων υπολογιστικών δυνατοτήτων τους, χρειάζονταν πολύ χρόνο για να εκπαιδευτούν σωστά.

Έχει σημειωθεί σημαντική πρόοδος στον τομέα των νευρωνικών δικτύων και ως αποτέλεσμα, συγκεντρώνεται αυξημένο ενδιαφέρον και υψηλά επίπεδα χρηματοδοτήσεων σε σχετικές έρευνες για ανάπτυξη νέων μοντέλων και εφαρμογών. Φαίνεται πιθανή η ανάπτυξη νέων εμπορικών μοντέλων πλέον αυτών που ήδη υπάρχουν και χρησιμοποιούνται. Η έρευνα επεκτείνεται σε όλο και περισσότερα μέτωπα. Μικροεπεξεργαστές (chips) βασισμένοι σε νευρωνικά δίκτυα, κάνουν την εμφάνισή τους και περισσότερο πολύπλοκα προβλήματα βρίσκουν λύσεις μέσω των νευρωνικών. Πιο συγκεκριμένα, για να βγει ένα νευρωνικό δίκτυο από το εργαστήριο και να χρησιμοποιηθεί στην βιομηχανία, χρειάζεται να χρησιμοποιηθούν ειδικά chips. Οι εταιρίες δουλεύουν πάνω στην τεχνολογία αυτών των αναλογικών, ψηφιακών και οπτικών νευρωνικών chips. Προσπαθούν να κατασκευάσουν έναν μεταγλωττιστή που θα παράγει ένα νευρωνικό δίκτυο (Application Specific Integrated Circuit – ASIC). Αυτοί δεν είναι τίποτα άλλο από ψηφιακά chips που μοιάζουν με νευρωνικά δίκτυα. Τα οπτικά chips είναι μία τεχνολογία πολλά υποσχόμενη αλλά θα χρειαστεί να περάσουν αρκετά χρόνια ακόμη μέχρι να βρουν εμπορικά εκμεταλλεύσιμες εφαρμογές.

ΚΕΦΑΛΑΙΟ 2^ο

2. 1 Νευρωνικά Δίκτυα – Βασικές Αρχές

Τα νευρωνικά δίκτυα (τεχνητά νευρωνικά συστήματα) είναι μία τεχνολογία επεξεργασίας πληροφοριών, εμπνευσμένη από τη μελέτη του μυαλού και του νευρικού συστήματος του ανθρώπου. Σαν τεχνολογία επεξεργασίας πληροφοριών, τα νευρωνικά δίκτυα δέχονται διάφορα δεδομένα εισόδου (inputs), εκτελούν μία σειρά πράξεων πάνω σε αυτά και παράγουν ένα ή περισσότερα δεδομένα εξόδου (outputs). Με αυτήν την έννοια, λειτουργούν ακριβώς όπως και μία υπορουτίνα.

Όταν μιλάμε για ηλεκτρονικούς υπολογιστές, μία περιοχή τοπικού δικτύου (LAN) συνδέει διάφορους υπολογιστές σε ένα συσχετιζόμενο λειτουργικό σύνολο. Μέσα στο μυαλό, οι νευρώνες- οι στοιχειώδεις υπολογιστικές μονάδες- συνδέονται μεταξύ τους σε ένα ενιαίο λειτουργικό σύνολο επίσης.

Μία ειδοποιός διαφορά των νευρωνικών δικτύων από άλλες τεχνολογίες (βάσεις δεδομένων, έμπειρα συστήματα, γλώσσες προγραμματισμού) είναι στον τρόπο με τον οποίο επεξεργάζονται τα δεδομένα εισόδου. Παρουσιάζονται στο δίκτυο παραδείγματα δεδομένων εισόδου και των αντίστοιχων αναμενόμενων δεδομένων εξόδου. Καθώς δίνουμε όλο και περισσότερα παραδείγματα για το πώς πρέπει να αντιδράσει το δίκτυο σε διάφορα δεδομένα εισόδου, το δίκτυο μορφοποιείται έτσι ώστε να αντικατοπτρίζει τις σχέσεις μεταξύ των δεδομένων εισόδου και εξόδου.

Η πραγματική διαδικασία, είναι ότι ο κατασκευαστής του δικτύου επιλέγει μία συγκεκριμένη βασική αρχιτεκτονική για το δίκτυο βάση της οποίας θα επιλυθεί το πρόβλημα. Σ' αυτήν την αρχιτεκτονική εισάγονται ως παραδείγματα διάφορες ομάδες δεδομένων. Χρησιμοποιεί αυτά τα δεδομένα για να επινοήσει μία έξοδο (πραγματική έξοδος). Η πραγματική έξοδος του δικτύου συγκρίνεται στη συνέχεια με την επιθυμητή έξοδο, με την απάντηση δηλαδή που θα έπρεπε να είχε δώσει το δίκτυο. Η διαφορά μεταξύ αυτών των δύο ποσοτήτων είναι το σφάλμα. Το σφάλμα χρησιμοποιείται έτσι ώστε να διαφοροποιούνται οι διάφορες παράμετροι στην βασική αρχιτεκτονική του δικτύου, έτσι ώστε την επόμενη φορά που θα έχει αυτήν την είσοδο το δίκτυο να παράγει με μεγαλύτερη ακρίβεια τη σωστή έξοδο. Αυτή η διαδικασία επαναλαμβάνεται πολλές φορές για κάθε ομάδα δεδομένων που χρησιμοποιείται για την εκπαίδευση του δικτύου.

2. 2 Βιολογικά Νευρωνικά Δίκτυα

Ο άνθρωπος δεν είναι γρήγορος ούτε ακριβής στους υπολογισμούς του. Αντιθέτως, ένας σύγχρονος υπολογιστής είναι πολύ πιο ικανός να εκτελεί πολύπλοκες πράξεις. Σε πολλούς τομείς όμως η ανθρώπινη ικανότητα υπερτερεί κατά πολύ της ικανότητας ενός υπολογιστή. Για παράδειγμα ο άνθρωπος αναγνωρίζει πολύ πιο εύκολα αντικείμενα και κατανοεί τις σχέσεις μεταξύ τους μέσα στο φυσικό περιβάλλον έστω κι αν αυτά είναι παραμορφωμένα ή δεν είναι εξ' ολοκλήρου ορατά.

Η ικανότητα της μάθησης μέσω εμπειρίας συνεπώς είναι από τα κύρια χαρακτηριστικά της ανθρώπινης ευφυΐας. Η ανθρώπινη μνήμη έχει την ικανότητα να αποθηκεύει μεγάλη ποσότητα και ποικιλία γνώσης και να συσχετίζει πληροφορίες πολύ γρήγορα και χωρίς ιδιαίτερη προσπάθεια. Σε αντίθεση με ο υπολογιστής, ο οποίος έχει την ικανότητα να απομνημονεύει τεράστιες ποσότητες πληροφοριών αλλά δυσκολεύεται να τις εκμεταλλευτεί. Αυτή η ανωτερότητα σε ορισμένους τομείς της ανθρώπινης ικανότητας σε σχέση με αυτήν ενός υπολογιστή οφείλεται σε δύο κυρίως λόγους. Η έλλειψη κατάλληλου λογισμικού εμποδίζει την προσαρμοστικότητα της ανθρώπινης ικανότητας στην επεξεργασία πληροφοριών. Μια δεύτερη εξήγηση, είναι το γεγονός ότι ο ανθρώπινος εγκέφαλος και οι υπολογιστές λειτουργούν εντελώς διαφορετικά. Ο άνθρωπος είναι πολύ πιο έξυπνος από τον υπολογιστή γιατί ο άνθρωπος εγκέφαλος χρησιμοποιεί μια αρχιτεκτονική που είναι πολύ πιο κατάλληλη να αντιμετωπίσει τη φυσική επεξεργασία πληροφοριών. Ο εγκέφαλος είναι ένας ισχυρότατος υπολογιστής που αποτελείται από 109 απλές μονάδες επεξεργασίας (νευρώνες) καθένας από τους οποίους επικοινωνεί με χιλιάδες άλλους. Από κάθε νευρώνα ξεκινούν χιλιάδες ίνες οι οποίες συναντούν ίνες από άλλους νευρώνες σε σημεία που αποκαλούνται συνάψεις.

Ο άνθρωπος εγκέφαλος χρησιμοποιεί δομή μαζικού παραλληλισμού (massively parallel) ή παράλληλης κατανεμημένης εργασίας (parallel distributed). Η σύγχρονη πληροφορική δείχνει ιδιαίτερο ενδιαφέρον σε υπολογιστές με κατανεμημένη αρχιτεκτονική που καλούνται «συνδετικοί» και η εφαρμογή των ΤΝΔ γενικά καλείται συνδετισμός.

Τα τεχνητά νευρωνικά δίκτυα είναι ανεπεξέργαστα ηλεκτρονικά μοντέλα τα οποία βασίζονται στην νευρωνική δομή του ανθρώπινου μυαλού. Το μυαλό βασικά μαθαίνει από την εμπειρία. Το ανθρώπινο μυαλό ως μοντέλο, υπόσχεται έναν λιγότερο τεχνικό τρόπο για να παράγουμε μηχανικές λύσεις. Ακόμα και απλές εγκεφαλικές λειτουργίες κάποιων ζώων είναι πολύ πιο προηγμένες από κάποιες δυνατότητες ηλεκτρονικών υπολογιστών. Οι υπολογιστές



μπορούν για παράδειγμα να πραγματοποιούν πολύπλοκους μαθηματικούς υπολογισμούς, αλλά δεν είναι σε θέση να αναγνωρίζουν απλά πρότυπα, πόσο μάλλον να γενικεύουν αυτά τα πρότυπα του παρελθόντος για πράξεις στο μέλλον.

Η πρόοδος στην βιολογική έρευνα είναι σε θέση να μας δώσει μία κατανοητή εικόνα σχετικά με τον φυσικό μηχανισμό σκέψης. Η έρευνα αυτή αποκαλύπτει ότι το μυαλό αποθηκεύει πληροφορίες ως πρότυπα. Κάποια από αυτά είναι ιδιαίτερα πολύπλοκα και μας επιτρέπουν να αναγνωρίζουμε πρόσωπα όταν τα βλέπουμε από διαφορετικές γωνίες. Αυτή η διαδικασία της αποθήκευσης πληροφοριών ως πρότυπα και της χρησιμοποίησης αυτών στην επίλυση προβλημάτων δημιουργεί νέες προοπτικές στον τομέα του προγραμματισμού και των υπολογιστών. Ο τομέας αυτός δεν χρησιμοποιεί πλέον τον παραδοσιακό προγραμματισμό, αλλά εμπεριέχει την δημιουργία πολλών παράλληλων δικτύων και την εκπαίδευση τους για την επίλυση συγκεκριμένων προβλημάτων. Χρησιμοποιεί επίσης όρους άγνωστους στον παραδοσιακό προγραμματισμό όπως συμπεριφορά, αντίδραση, αυτο-οργάνωση, μάθηση, εκπαίδευση, γενίκευση, λήθη.

Ο ακριβής τρόπος λειτουργίας του ανθρώπινου μυαλού αποτελεί ακόμα και σήμερα μυστήριο. Κάποιες εκφάνσεις όμως αυτής της διαδικασίας είναι γνωστές. Πιο συγκεκριμένα, το βασικότερο στοιχείο του ανθρώπινου μυαλού είναι ένας τύπος κυττάρου το οποίο σε αντίθεση με τα υπόλοιπα κύτταρα του σώματος δεν αναπαράγεται. Από το γεγονός ότι αυτό το μέρος του ανθρώπινου σώματος είναι το μόνο που δεν αντικαθίσταται παροδικά, υποθέτουμε ότι αυτά τα κύτταρα είναι οι μηχανισμοί που μας κάνουν ικανούς να θυμόμαστε, να σκεφτόμαστε, να μαθαίνουμε και να εφαρμόζουμε διάφορες εμπειρίες μας στις ενέργειές μας. Αυτά τα κύτταρα ο αριθμός των οποίων είναι περίπου 100 δισεκατομμύρια, είναι γνωστά ως **νευρώνες**. Καθένας από τους νευρώνες μπορεί να συνδέεται με 200.000 άλλους νευρώνες αν και το σύννηθες είναι μόνο 1.000 με 10.000. Η δύναμη του ανθρώπινου μυαλού προέρχεται από τον μεγαλειώδη αυτό αριθμό των νευρώνων και τις πολλαπλάσιες διασυνδέσεις τους. Προέρχεται όμως και από τον γενετικό προγραμματισμό και την μάθηση.


Κάθε νευρώνας είναι ένα εξειδικευμένο κύτταρο το οποίο μπορεί να απελευθερώσει ηλεκτροχημικά σήματα. Έχει σε έναν κλάδο την δομή εισόδου (*δενδρίτες*), το σώμα του κυττάρου και μία διακλάδωση με την δομή εξόδου (*άξονας*). Ο άξονας ενός νευρώνα συνδέεται με τους δενδρίτες ενός άλλου νευρώνα μέσω των *συνάψεων*. Όταν ένας νευρώνας ενεργοποιηθεί, απελευθερώνει ένα ηλεκτροχημικό σήμα κατά μήκος του άξονα. Το σήμα περνάει μέσω των συνάψεων σε άλλους νευρώνες οι οποίοι ενδέχεται να διεγερθούν και να απελευθερώσουν αντίστοιχα ενέργεια. Ένας νευρώνας απελευθερώνει ενέργεια μόνο στην περίπτωση όπου το συνολικό σήμα που λαμβάνει στο σώμα του κυττάρου του από τους δενδρίτες θα ξεπεράσει ένα

ορισμένο επίπεδο (κατώφλι). Στα δύο σχήματα που ακολουθούν, παρουσιάζονται γραφικές απεικονίσεις βιολογικών νευρωνικών δικτύων και των μερών τους.



Η ισχύς του σήματος που λαμβάνει ένας νευρώνας (συνεπώς και η πιθανότητα να απελευθερώσει ενέργεια) εξαρτάται από τη δραστικότητα των συνάψεων. Κάθε σύναψη έχει ένα κενό με χημικούς νευρομεταφορείς, συγκροτημένους για να μεταφέρουν το σήμα μέσω του κενού. Ένας από τους πιο σημαντικούς ερευνητές, ο Donald Hebb, υποστήριζε ότι η μάθηση έχει πρωταρχικά να κάνει με την αλλοίωση της ισχύος των διασυνδέσεων μέσω των συνάψεων. Για παράδειγμα, στο κλασικό πείραμα με τον σκύλο, όπου ένα κουδούνι χτυπά λίγο πριν

προσφερθεί φαγητό στον σκύλο, ο σκύλος γρήγορα συνδέει τον χτύπο του κουδουνιού με το φαγητό. Στην περίπτωση αυτή οι συνάψεις που συνδέουν την ακουστική ικανότητα με την αίσθηση της πείνας ενισχύονται με αποτέλεσμα να εκκρίνει σίελο ο σκύλος κάθε φορά που ακούει το κουδούνι.



Αναλυτικότερα, τα σήματα μεταβιβάζονται μεταξύ των νευρώνων μέσω ηλεκτρικών παλμών κατά μήκος του άξονα. Οι παλμοί προσκρούουν στους ακροδέκτες του αρχικού νευρώνα που ονομάζονται συνάψεις. Αυτές βρίσκονται κατά κύριο λόγο σε μία σειρά διακλαδώσεων που ξεκινούν από το κύριο κυτταρικό σώμα, τους δενδρίτες. Κάθε παλμός που φτάνει σε σύναψη, ξεκινά την απελευθέρωση μικρής ποσότητας χημικής ουσίας η οποία λέγεται «νευροπομπός – neurotransmitter». Αυτή η ουσία ταξιδεύει μέσα από τις σχισμές των συνάψεων και παραλαμβάνεται από τις συνάψεις των δενδριτών του νευρώνα παραλήπτη. Η χημική αυτή ουσία δεσμεύεται από μοριακά «εργοστάσια», ξεκινώντας μια αλλαγή στο δυναμικό των δενδριτικών μεμβρανών. Αυτή η αλλαγή στο δυναμικό εξυπηρετεί στο να αυξηθεί ή να μειωθεί η πόλωση στην συναπτική μεμβράνη του νευρώνα δέκτη. Στην πρώτη περίπτωση, το δυναμικό αναστέλλει την παραγωγή παλμών από τον αρχικό νευρώνα ενώ στην δεύτερη ενθαρρύνει την παραγωγή παλμών. Το μέγεθος και ο τύπος του δυναμικού που παράγεται εξαρτάται από πολλούς παράγοντες όπως η γεωμετρία των συνάψεων και το είδος του νευροπομπού. Κάθε δυναμικό ταξιδεύει κατά μήκος του δενδρίτη του και εξαπλώνεται σε όλο το σώμα του νευρώνα φτάνοντας τελικά στην βάση του άξονα, το ύψωμα. Ο αρχικός νευρώνας αθροίζει ή ενοποιεί τα αποτελέσματα χιλιάδων τέτοιων δυναμικών σε όλους τους δενδρίτες τους και μέσα στον χρόνο. Αν το συνολικό δυναμικό στο ύψωμα του άξονα υπερβαίνει μία συγκεκριμένη τιμή, ένα

κατώφλι, ο νευρώνας παράγει ένα δυναμικό το οποίο ταξιδεύει κατά μήκος του άξονα. Αυτό στη συνέχεια δίνει το έναυσμα σε μία ακολουθία παρόμοιων γεγονότων στους νευρώνες που βρίσκονται μετά τον αρχικό.


Καταλήγοντας, από έναν πολύ μεγάλο αριθμό από απλές υπολογιστικές μονάδες (κάθε μία από τις οποίες υπολογίζει ένα σταθμισμένο άθροισμα των εισόδων της και απελευθερώνει ένα δυαδικό σήμα αν ο αριθμός υπερβαίνει ένα συγκεκριμένο όριο) το ανθρώπινο μυαλό καταφέρνει πολύπλοκες ενέργειες. Φυσικά υπάρχει πολύ μεγάλη πολυπλοκότητα σε ότι αφορά το ανθρώπινο μυαλό και τις λειτουργίες του για την οποία δεν έγινε λόγος, αλλά είναι ενδιαφέρον το γεγονός ότι τα τεχνητά νευρωνικά δίκτυα μπορούν να επιτύχουν αξιόλογα αποτελέσματα χρησιμοποιώντας μοντέλα που δεν είναι πολύ περισσότερο πολύπλοκα από αυτό που περιγράφηκε.

2. 3 Αναλογία με το ανθρώπινο μυαλό

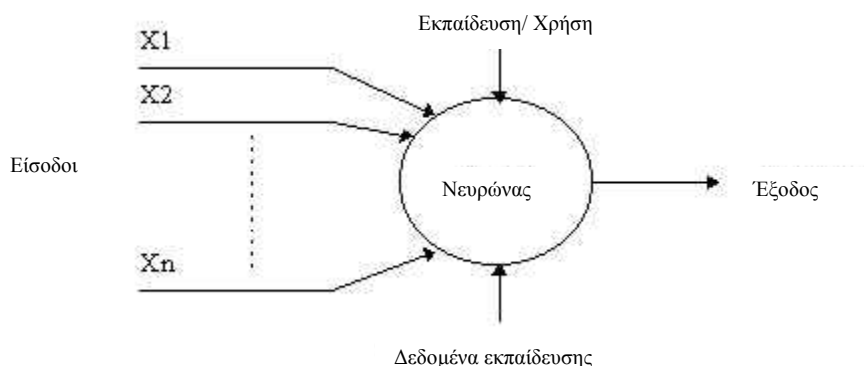
Οι νευρώνες είναι από μόνοι τους πολύπλοκοι. Έχουν πολλά μέρη, υποσυστήματα και μηχανισμούς ελέγχου. Μεταβιβάζουν πληροφορίες μέσω ηλεκτροχημικών οδών. Υπάρχουν πάνω από εκατό διαφορετικές κλάσεις νευρώνων, ανάλογα με τα κριτήρια της κατηγοριοποίησής τους. Οι νευρώνες μαζί με τις διασυνδέσεις τους μορφοποιούν μία διαδικασία η οποία δεν είναι δυαδική, είναι ασταθής και δεν είναι συγχρονισμένη. Η πολυπλοκότητά τους δεν έχει σχέση με τους σημερινούς ηλεκτρονικούς υπολογιστές αλλά ούτε καν με τα τεχνητά νευρωνικά δίκτυα.

Τα τεχνητά νευρωνικά δίκτυα προσπαθούν να αναπαράγουν μόνο τα πιο βασικά στοιχεία των φυσικών νευρώνων που είναι πολύπλοκοι, ευπροσάρμοστοι και ισχυροί οργανισμοί. Το κάνουν με έναν τρόπο πρωτόγονο. Για τον προγραμματιστή ή τον δημιουργό λογισμικού όμως ο οποίος προσπαθεί να λύσει προβλήματα, τα νευρωνικά δίκτυα δεν αποσκοπούσαν ποτέ στο να αναπαράγουν τεχνητά τους φυσικούς νευρώνες. Πρόκειται μόνο για μηχανές και έναν νέο τρόπο επίλυσης προβλημάτων.

Για να συντάξουμε αυτά τα δίκτυα, αρχικά προσπαθούμε να συνάγουμε τα ιδιαίτερα χαρακτηριστικά των νευρώνων και των διασυνδέσεών τους. Επειδή όμως η γνώση μας πάνω στους νευρώνες είναι ελλιπής και οι υπολογιστικές μας δυνατότητες περιορισμένες, τα μοντέλα τεχνητών νευρώνων είναι απαραίτητως εξιδανικεύσεις των πραγματικών δικτύων νευρώνων. Μία τέτοια εξιδανίκευση φαίνεται στην παρακάτω εικόνα.



Ένας τεχνητός νευρώνας είναι μια διάταξη με πολλές εισόδους και μία έξοδο. Ο νευρώνας έχει δύο στάδια λειτουργίας: το στάδιο της εκπαίδευσης και το στάδιο της χρήσης. Κατά την εκπαίδευση το νευρωνικό δίκτυο μαθαίνει να διεγείρεται ή όχι ανάλογα με τα δεδομένα εισόδου. Κατά την χρήση, όταν εντοπιστεί μία γνωστή (διδασκτέα) είσοδος, η αντίστοιχη έξοδος γίνεται η παρούσα έξοδος του δικτύου. Αν η είσοδος δεν ανήκει σε κάποια από αυτές που χρησιμοποιήθηκαν κατά την εκπαίδευση, χρησιμοποιείται ο κανόνας με το κατάλληλο κατώφλι για την παραγωγή της κατάλληλης εξόδου.



Όλα τα βιολογικά νευρωνικά δίκτυα αποτελούνται όπως έχουμε δει από τα ίδια τέσσερα βασικά τμήματα: τους δενδρίτες, το σώμα, τον άξονα και τις συνάψεις. Οι δενδρίτες είναι τριχοειδείς απολήξεις του σώματος που δρουν σαν κανάλια εισόδου. Οι εισοδοί λαμβάνονται από τις συνάψεις με άλλους νευρώνες. Το σώμα επεξεργάζεται τις εισόδους και παράγει την έξοδο η οποία μεταφέρεται σε άλλους νευρώνες μέσω του άξονα και των συνάψεων.

Κάθε δίκτυο έχει διάφορες εισόδους. Κάθε είσοδος πολλαπλασιάζεται με ένα βάρος διασύνδεσης. Στην απλούστερη περίπτωση αυτά τα γινόμενα αθροίζονται και τροφοδοτούν την συνάρτηση μεταφοράς, η οποία παράγει ένα αποτέλεσμα και τελικά την έξοδο του δικτύου.

2. 4 Τεχνητά Νευρωνικά Δίκτυα

Οι νευρώνες ενός τεχνητού νευρωνικού δικτύου (ΤΝΔ) είναι διατεταγμένοι κατά τρόπο ώστε πολλοί από αυτούς να επεξεργάζονται τα δεδομένα ταυτόχρονα. Κάθε νευρώνας στέλνει σήματα διέγερσης (activation) ή αποδιέγερσης (deactivation) σε άλλους νευρώνες. Η κατάσταση ενεργοποίησής του εξαρτάται από τα σήματα που λαμβάνει από νευρώνες με τους οποίους συνδέεται. Για τις συνδέσεις χρησιμοποιείται και ο νευροβιολογικός όρος συνάψεις. Ο συνδυασμός του μεγάλου αριθμού τεχνητών νευρώνων δίνει ένα πολύ ισχυρό μηχανισμό με μεγάλες δυνατότητες μάθησης και παραγωγής συμπερασμάτων.

Τα ΤΝΔ είναι ουσιαστικά συμπλέγματα που περιέχουν απλά μη γραμμικά στοιχεία ή νευρώνες. Προσδιορίζονται από τη δομή τους, τον τρόπο επικοινωνίας με το περιβάλλον, τη διαδικασία εκπαίδευσής τους και τη συμπεριφορά τους κατά την επεξεργασία των δεδομένων. Τα ΤΝΔ χωρίζονται σε δύο κατηγορίες:

- (1) τα *στατικά δίκτυα* που δεν περιέχουν στοιχεία με μνήμη αλλά μπορούν να έχουν ως εισόδους προηγούμενες τιμές των εισόδων
- (2) τα *δυναμικά δίκτυα* με στοιχεία μνήμης που είναι ιδιαίτερα κατάλληλα για την προτυποποίηση μη γραμμικών δυναμικών συστημάτων.

Τα ΤΝΔ αποτελούνται από κυκλώματα που περιέχουν κόμβους που αλληλοσυνδέονται με διάφορες αρχιτεκτονικές. Οι συντελεστές διασύνδεσης, ή βάρη του δικτύου, είναι αρχικά άγνωστα και στόχος της εκμάθησης είναι η συστηματική εύρεσή τους ελαχιστοποιώντας κάποιο μέτρο του σφάλματος μεταξύ της επιθυμητής και της πραγματικής εξόδου του δικτύου.

Τα βήματα που ακολουθούμε για την ανάπτυξη ενός ΤΝΔ, είναι:

- 1) Συλλογή των δεδομένων: Το πρώτο βήμα είναι να συγκεντρώσουμε όλα τα κατάλληλα δεδομένα σε ένα μέρος. Η διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου προϋποθέτει την εκτίμηση όλων των εν δυνάμει χρήσιμων πληροφοριών σχετικά με το πρόβλημα και τη χρησιμοποίηση αυτών για την πρόβλεψη μίας συγκεκριμένης συμπεριφοράς ή άλλων χαρακτηριστικών. Για λόγους δημιουργίας ομάδων εκμάθησης και δοκιμής, όλα αυτά τα δεδομένα πρέπει να είναι συγκεντρωμένα σε ένα μέρος. Η όλη διαδικασία είναι παρόμοια με αυτήν που απαιτείται στην ανάπτυξη στατιστικών μοντέλων. Μερικές φορές κάποια πληροφορία μπορεί να ληφθεί σε ένα σημείο, να απομονωθεί από τον κυρίως όγκο και να αρχειοθετηθεί. Αν

αυτή η πληροφορία κρίνεται κατάλληλη και σχετική, θα πρέπει να επανεναχθεί στον κύριο όγκο δεδομένων.

2) Χωρισμός των δεδομένων σε ομάδες εκπαίδευσης (εκμάθησης) και δοκιμής: Λόγω του ότι τα νευρωνικά δίκτυα μαθαίνουν από την προηγούμενη εμπειρία, είναι χρήσιμο να τα τροφοδοτήσουμε με την εμπειρία και με κάποιον τρόπο να διαπιστώσουν κατά πόσο έχουν «μάθει» ή «απομνημονεύσει» αυτά που τους έχουμε δείξει. Αν δεν διαχωρίσουμε τα δεδομένα, δε θα μπορέσουμε να καταλάβουμε αν το δίκτυο έχει απλά απομνημονεύσει τα δεδομένα ή έχει μάθει κάτι για τις σχέσεις δεδομένων εισόδου – εξόδου. Η απλή και στεία απομνημόνευση οδηγεί σε φτώχη ανταπόκριση σε είσοδο νέων δεδομένων. Ανάλογα με το πρόβλημα, ορισμένα νευρωνικά δίκτυα δεν μαθαίνουν σωστά αν τα δεδομένα δεν είναι κατάλληλα κατανεμημένα ανάμεσα στις πιθανές εξόδους. Έτσι θα πρέπει να επιλέγουμε προσεκτικά τα δεδομένα που θα χρησιμοποιηθούν για την εκπαίδευση του δικτύου. Σαν γενικό κανόνα, μπορούμε να αναφέρουμε ότι όσο περισσότερα δεδομένα για εκπαίδευση έχουμε, τόσο πιο ικανοποιητικά θα αποδίδει το δίκτυο.

3) Μετατροπή των δεδομένων σε κατάλληλες εισόδους: Τα νευρωνικά δίκτυα δέχονται μόνο αριθμητικά δεδομένα. Τα περισσότερα νευρωνικά δίκτυα δουλεύουν με εισόδους που κυμαίνονται μεταξύ 0 και 1 ή -1 και 1. Τα αριθμητικά δεδομένα θα πρέπει να τοποθετούνται σε μία από τις παραπάνω κλίμακες και να εισάγονται απ' ευθείας στο δίκτυο. Τα ποιοτικά δεδομένα θα πρέπει αρχικά να μετατρέπονται σε αριθμητικά, να ποσοτικοποιούνται.

4) Επιλογή, εκπαίδευση και δοκιμή του δικτύου: Η επιλογή του κατάλληλου δικτύου από άποψη αρχιτεκτονικής και παραμέτρων, έχει άμεσο αντίκτυπο στην απόδοση του δικτύου. Η οπισθόδρομη διάδοση (back propagation) έχει εξελιχθεί καθολικά σε ένα τυπικό παράδειγμα δικτύου για μοντελοποίηση, πρόβλεψη και ταξινόμηση. Η επιλογή της βέλτιστης αρχιτεκτονικής οπισθόδρομης διάδοσης είναι σημαντική υπόθεση και αποτελεί έναν τομέα στον οποίο διεξάγονται ενδιαφέρουσες έρευνες. Μερικά από τα ερωτήματα που θα πρέπει να απαντηθούν, είναι πόσα κρυμμένα επίπεδα, πόσοι νευρώνες σε κάθε επίπεδο, ποια συνάρτηση μεταφοράς, ποιος κανόνας εκμάθησης ποιος ο ρυθμός μάθησης κα.

Ανάλογα με τα δεδομένα, η εκπαίδευση του δικτύου μπορεί να είναι μία πολύ αργή διαδικασία. Κατά τη διαδικασία δοκιμής, τα αντίστοιχα δεδομένα χρησιμοποιούνται για να διαπιστωθεί πόσο καλά ανταποκρίνεται το δίκτυο σε δεδομένα που δεν έχει ξανασυναντήσει. Ένα σωστά δομημένο και εκπαιδευμένο δίκτυο, θα πρέπει να έχει παρόμοιους χρόνους και επίπεδα απόδοσης στα δεδομένα μάθησης και στα δεδομένα δοκιμής. Αν η απόδοση είναι κατά πολύ διαφορετική, θα πρέπει να προβούμε σε διορθωτικές ενέργειες στην αρχιτεκτονική, τη σύνθεση ή το μέγεθος των ομάδων δεδομένων.

5) Αναπτύσσοντας το δίκτυο: Μετά την ανάπτυξη του δικτύου, με ποιόν τρόπο θα κάνουμε το δίκτυο μέρος μιας εφαρμογής;

Κάποιες εφαρμογές απαιτούνται απαντήσεις «άσπρο και μαύρο» ή πιο σωστά δυαδικές. Αυτές οι εφαρμογές περιλαμβάνουν αναγνώριση κειμένου, λόγου ή εικόνας. Μετατρέπουν πραγματικά δεδομένα σε διακριτές τιμές. Οι τιμές αυτές περιορίζονται σε γνωστές ομάδες όπως είναι οι χαρακτήρες ASCII ή οι 50.000 πιο γνωστές ή συχνά χρησιμοποιούμενες λέξεις. Λόγω αυτού του περιορισμού, τα δίκτυα των συγκεκριμένων εφαρμογών δεν αθροίζουν απλά τα δεδομένα εισόδου αλλά μπορεί να χρησιμοποιούν και τις δυαδικές ιδιότητες των εισόδων τύπου «ή» και «και». Αυτές οι λειτουργίες μπορούν να ενσωματωθούν στις συναρτήσεις μεταφοράς και στα αθροίσματα των εισόδων.

Άλλα δίκτυα χρησιμοποιούνται όταν οι έξοδοι δεν περιορίζονται σε κάποιες γνωστές τιμές. Αυτά μπορούν να δώσουν έναν συγκεκριμένο πεπερασμένο αριθμό αποκρίσεων. Εφαρμογές αυτού του τύπου βρίσκονται πίσω από την ευφυΐα των κινήσεων ρομποτικών μηχανισμών. Για να το επιτύχουν αυτό δέχονται τις εισόδους, αθροίζουν τα δεδομένα και παράγουν την έξοδο εφαρμόζοντας για παράδειγμα μία υπερβολική εφαπτομένη σαν συνάρτηση μεταφοράς. Υπάρχουν και οι εφαρμογές κατά τις οποίες αθροίζονται οι είσοδοι και συγκρίνονται τα αθροίσματα με ένα κατώφλι. Στη συνέχεια παράγεται μία από τις δύο πιθανές εξόδους (0 ή 1). Κάποιες φορές η εφαρμογή απαιτείται η έξοδος να είναι -1 ή 1 οπότε κανονικοποιούνται κατάλληλα τα αποτελέσματα. Μερικές συναρτήσεις συγκεντρώνουν στοιχεία μέσα στον χρόνο και τα χρησιμοποιούν στη συνέχεια σαν δεδομένα εισόδου, δημιουργώντας έτσι δίκτυα που η λειτουργία τους έχει άμεση σχέση με τον χρόνο.

Έχοντας μία γενική εικόνα για τα τεχνητά νευρωνικά δίκτυα, μπορούμε να μελετήσουμε τις λεπτομέρειες που τα αφορούν. Πριν επεκταθούμε όμως στα διάφορα είδη δικτύων, ας δούμε αναλυτικότερα ποια είναι τα βασικά συστατικά τους και οι επιμέρους λειτουργίες τους.


2. 4. 1 Βασικά Συστατικά Τεχνητών Νευρωνικών Δικτύων

Όπως έχουμε ήδη δει, τα τεχνητά νευρωνικά δίκτυα είναι μία μεγάλη ομάδα αρχιτεκτονικών παράλληλης επεξεργασίας οι οποίες χρησιμοποιούνται σε συγκεκριμένα είδη πολύπλοκων προβλημάτων. Δεν θα πρέπει να συγχέουμε τις αρχιτεκτονικές αυτές με τις κοινές διαρθρωτικές δομές παράλληλης επεξεργασίας, οι οποίες εφαρμόζονται σε πολλές επάλληλες υπολογιστικές μονάδες σε διάφορες τοπολογίες.

Συστατικό 1. Παράγοντες βάρους: Ένας νευρώνας δέχεται συνήθως ένα μεγάλο αριθμό εισόδων. Κάθε είσοδος έχει το δικό της σχετικό βάρος το οποίο προσδίδει στην είσοδο την επιρροή που χρειάζεται στην αθροιστική συνάρτηση του υπό επεξεργασία στοιχείου. Τα βάρη αυτά λειτουργούν με τον ίδιο τρόπο όπως και οι δυνάμεις των συνάψεων στους βιολογικούς νευρώνες. Και στις δύο περιπτώσεις κάποιες εισόδους είναι πιο σημαντικές από άλλες και έχουν μεγαλύτερη επιρροή στο υπό επεξεργασία στοιχείο καθώς κάνουν διάφορους συνδυασμούς για να παράγουν την απόκριση του δικτύου.

Τα βάρη είναι προσαρμοσμένοι παράγοντες σε ένα δίκτυο, οι οποίοι καθορίζουν την ένταση κάθε σήματος εισόδου όπως αυτό καταγράφεται από τον τεχνητό νευρώνα. Είναι μία μονάδα μέτρησης της συνδετικής δύναμης της εισόδου. Αυτές οι δυνάμεις μπορούν να τροποποιηθούν σαν αντίδραση σε διάφορες ομάδες δεδομένων εκπαίδευσης ανάλογα με την αρχιτεκτονική του δικτύου ή μέσω του μαθησιακού κανόνα που χρησιμοποιείται.

Η διάταξη ενός τεχνητού νευρώνα παρουσία των βαρών στις εισόδους, φαίνεται στην εικόνα:



Συστατικό 2. Αθροιστική συνάρτηση: Το πρώτο βήμα κατά την λειτουργία ενός στοιχείου επεξεργασίας είναι υπολογίσει το σταθμισμένο άθροισμα όλων των εισόδων. Από μαθηματική άποψη, οι εισόδους και τα αντίστοιχα βάρη είναι διανύσματα που μπορούν να αναπαρασταθούν ως (i_1, i_2, \dots, i_n) και (w_1, w_2, \dots, w_n) . Το συνολικό σήμα εισόδου είναι το εσωτερικό γινόμενο αυτών των δύο διανυσμάτων. Αυτή η πολύ απλή αθροιστική συνάρτηση προκύπτει ως εξής: πολλαπλασιάζουμε κάθε στοιχείο του διανύσματος i με το αντίστοιχο στοιχείο του διανύσματος w . Στη συνέχεια προσθέτουμε όλα αυτά τα γινόμενα. Η είσοδος1= $i_1 \times w_1$, η είσοδος2= $i_2 \times w_2$ κλπ προσθέτονται ως είσοδος1+είσοδος2 κλπ. Το αποτέλεσμα είναι ένας απλός αριθμός και όχι διάνυσμα.

Γεωμετρικά, το εσωτερικό γινόμενο δύο διανυσμάτων μπορεί να ληφθεί ως μέτρο της ομοιότητάς τους. Αν τα διανύσματα είναι συγγραμμικά, το εσωτερικό γινόμενο είναι μέγιστο. Αν είναι αντίθετα, το εσωτερικό γινόμενο είναι ελάχιστο.

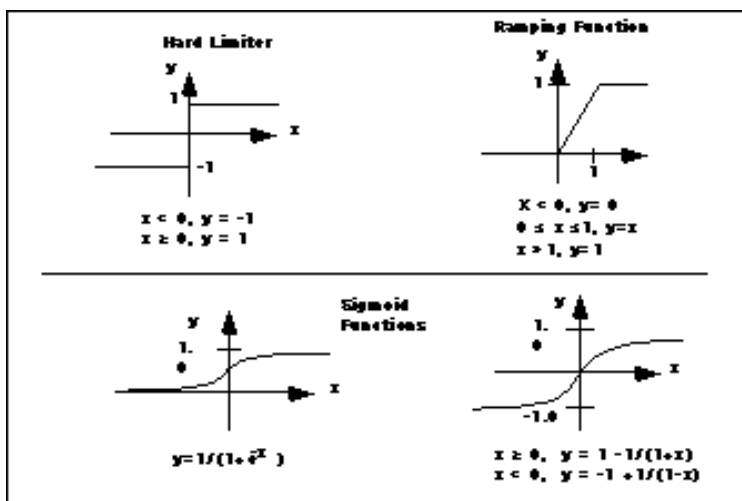
Η αθροιστική συνάρτηση μπορεί να είναι και πιο πολύπλοκη. Οι τιμές των μεταβλητών εισόδου και των βαρών τους μπορούν να συνδυαστούν με πολλούς τρόπους πριν εισαχθούν στη συνάρτηση μεταφοράς. Παράλληλα με το απλό άθροισμα γινομένων, η αθροιστική συνάρτηση μπορεί να επιλέγει το ελάχιστο, το μέγιστο, το ποιο συχνά εμφανιζόμενο, το γινόμενο ή άλλους αλγόριθμους κανονικοποίησης. Η επιλογή του συγκεκριμένου αλγορίθμου που συνδυάζει τις εισόδους του νευρώνα έχει να κάνει κυρίως με την αρχιτεκτονική του δικτύου και την εφαρμογή.

Κάποιες συναρτήσεις εκτελούν μία επιπλέον πράξη πριν περάσουν τα στοιχεία στην συνάρτηση μεταφοράς. Αυτή η πράξη ονομάζεται συχνά συνάρτηση ενεργοποίησης. Ο λόγος για τον οποίο χρησιμοποιούμε την συνάρτηση ενεργοποίησης, είναι για να έχουνε χρονική διαφορά μεταξύ των αποτελεσμάτων της αθροιστικής συνάρτησης. Οι συναρτήσεις ενεργοποίησης περιορίζονται όμως στο πεδίο της έρευνας ακόμη. Πολλά δίκτυα χρησιμοποιούν μία συνάρτηση ενεργοποίησης – ταυτότητα, που είναι σαν να μην χρησιμοποιούσαν καθόλου. Επιπροσθέτως, αυτή η συνάρτηση μπορεί να είναι μέρος όλου του δικτύου και όχι κάθε στοιχείου χωριστά.

Συστατικό 3. Συνάρτηση μεταφοράς: Το αποτέλεσμα της συνάρτησης μεταφοράς, το οποίο είναι συνήθως ένα σταθμισμένο άθροισμα, μετατρέπεται σε χρήσιμο αποτέλεσμα χρησιμοποιώντας έναν αλγόριθμο που ονομάζεται συνάρτηση μεταφοράς. Σε αυτήν τη φάση, το άθροισμα μπορεί να συγκρίνεται με ένα κατώφλι και σύμφωνα με το αποτέλεσμα της σύγκρισης να παράγεται η έξοδος. Αν το άθροισμα είναι μεγαλύτερο από το κατώφλι, εκπέμπεται ένα σήμα ενώ σε αντίθετη περίπτωση δεν υπάρχει σήμα ή υπάρχει και είναι ανασταλτικό. Και οι δύο αυτές αντιδράσεις είναι σημαντικές.

Το κατώφλι, η συνάρτηση μεταφοράς, είναι συνήθως μη γραμμική. Οι γραμμικές συναρτήσεις αποκλείονται γιατί δίνουν αποτέλεσμα που είναι αναλογικό των εισόδων. Οι γραμμικές συναρτήσεις λοιπόν δεν είναι ιδιαίτερα χρήσιμες. Αυτό ήταν και το πρόβλημα των πρώτων δικτύων όπως αναφέρουν στο βιβλίο “Perceptrons” οι Minsky και Papert.

Η συνάρτηση μεταφοράς θα μπορούσε να είναι κάτι τόσο απλό όπως ο διαχωρισμός του αν το σταθμισμένο άθροισμα είναι θετικό ή αρνητικό. Το δίκτυο θα μπορούσε να παράγει 0 και 1 ή 1 και -1 ή οποιονδήποτε άλλον αριθμητικό συνδυασμό. Η συνάρτηση τότε θα ήταν βηματική. Στο σχήμα που ακολουθεί φαίνονται διάφορα παραδείγματα συναρτήσεων μεταφοράς.



Ένα άλλο είδος συνάρτησης μεταφοράς, η κεκλιμένη συνάρτηση, μπορεί να αντικατοπτρίζει την είσοδο μέσα σε ένα ορισμένο εύρος και να λειτουργεί σαν βηματική εκτός του εύρους αυτού. Πρόκειται για μία γραμμική συνάρτηση η οποία αποκόπτει τις ελάχιστες και μέγιστες τιμές και μετατρέπεται έτσι σε μη γραμμική.

Μία άλλη επιλογή είναι η σιγμοειδής συνάρτηση. Αυτή παίρνει την ελάχιστη και μέγιστη τιμή στις ασύμπτωτες. Ονομάζεται σιγμοειδής όταν το πεδίο τιμών της είναι από 0 έως 1 και υπερβολική εφαπτομενική όταν το πεδίο τιμών της είναι από -1 έως 1. Από μαθηματική άποψη, αυτές οι συναρτήσεις έχουν το εξαιρετικό χαρακτηριστικό ότι και η συνάρτηση και οι παράγωγοί της είναι συνεχείς. Η επιλογή μιας τέτοιας συνάρτησης λειτουργεί συνήθως καλά και είναι αυτή που χρησιμοποιείται ευρέως. Υπάρχουν και άλλες συναρτήσεις μεταφοράς που η χρήση τους όμως περιορίζεται σε συγκεκριμένες αρχιτεκτονικές νευρωνικών δικτύων.

Πριν εφαρμόσουμε την συνάρτηση μεταφοράς, μπορεί να προσθέσουμε ομοιόμορφα κατανομημένο θόρυβο. Η πηγή και η ποσότητα του θορύβου εξαρτάται από την εφαρμογή και τον τρόπο εκπαίδευσης. Αυτός ο θόρυβος ονομάζεται θερμοκρασία των τεχνητών νευρώνων. Το όνομα αυτό προκύπτει από το φυσικό φαινόμενο κατά το οποίο η ικανότητα των ανθρώπων να σκέπτονται επηρεάζεται από μεταβολές της θερμοκρασίας. Ηλεκτρονικά, αυτό επιτυγχάνεται με την παρουσία θορύβου. Αν θέλουμε να μιμηθούμε καλύτερα την φύση, χρησιμοποιούμε Gaussιανή πηγή θορύβου. Ο Gaussιανός θόρυβος είναι παρόμοιος με τον ομοιόμορφα κατανομημένο θόρυβο με μόνη διαφορά ότι η κατανομή των τυχαίων αριθμών στο εύρος της θερμοκρασίας έχει την μορφή καμπάνας. Η χρήση θορύβου είναι ακόμα υπό έρευνα και δεν εφαρμόζεται στα περισσότερα παραδείγματα.

Συστατικό 4. Διαβαθμίσεις και όρια: Μετά από την συνάρτηση μεταφοράς, οι έξοδοι μπορούν να περάσουν από μία διαδικασία διαβάθμισης και περιορισμού. Κατά την διαβάθμιση πολλαπλασιάζεται ένας διαβαθμιστικός παράγοντας με την τιμή της μεταφοράς και μετά

προστίθεται ένας αντισταθμιστικός παράγοντας. Ο περιορισμός εξασφαλίζει το ότι η τιμή της εξόδου δεν θα υπερβαίνει κάποια άνω και κάτω όρια. Αυτός ο περιορισμός είναι επιπλέον αυτού της βηματικής συνάρτησης μεταφοράς που ενδεχομένως χρησιμοποιήσαμε. Οι παραπάνω δύο διαδικασίες χρησιμοποιούνται κυρίως σε τοπολογίες κατά τις οποίες δοκιμάζονται βιολογικά νευρωνικά μοντέλα.

Συστατικό 5. Συνάρτηση εξόδου: Όπως ακριβώς και στα βιολογικά δίκτυα, κάθε στοιχείο επεξεργασίας μπορεί να εκπέμψει μόνο ένα σήμα εξόδου το οποίο μπορεί να κατευθύνει σε πολλούς άλλους νευρώνες. Συνήθως η έξοδος έχει άμεση σχέση με το αποτέλεσμα της συνάρτησης μεταφοράς. Σε ορισμένες τοπολογίες όμως περιορίζεται το αποτέλεσμα της συνάρτησης μεταφοράς ενσωματώνοντας ανταγωνισμό μεταξύ γειτονικών μονάδων επεξεργασίας. Οι νευρώνες μπορούν να ανταγωνίζονται εκτός κι αν έχουν μεγάλη ισχύ. Σε πρώτο επίπεδο ο ανταγωνισμός έχει να κάνει με τον καθορισμό του νευρώνα που θα είναι ενεργός ή αυτού που θα δώσει την έξοδο. Σε ένα δεύτερο επίπεδο, ανταγωνιστικές εισοδοί καθορίζουν ποιο στοιχείο θα συμμετέχει στη διαδικασία μάθησης ή προσαρμογής.

Συστατικό 6. Συνάρτηση σφάλματος και προς τα πίσω διαδιδόμενη τιμή: Στα περισσότερα δίκτυα υπολογίζεται η διαφορά μεταξύ της πραγματικής τιμής της εξόδου και της επιθυμητής. Αυτό το αρχικό, ανεπεξέργαστο σφάλμα τροποποιείται από την συνάρτηση σφάλματος έτσι ώστε να ταιριάζει στην εκάστοτε αρχιτεκτονική του δικτύου. Τα περισσότερα δίκτυα χρησιμοποιούν αυτό το σφάλμα απ' ευθείας, ενώ άλλα υψώνουν το σφάλμα στο τετράγωνο, διατηρώντας το πρόσημο, ή στον κύβο και άλλα το τροποποιούν όπως ταιριάζει στην κάθε περίπτωση. Το σφάλμα αυτό μεταδίδεται στη συνέχεια στην συνάρτηση εκπαίδευσης ενός άλλου στοιχείου. Αυτό το σφάλμα λέγεται τρέχον σφάλμα.

Το τρέχον σφάλμα συνήθως διαδίδεται προς τα πίσω, σε προηγούμενο δηλαδή επίπεδο. Αυτό το σφάλμα μπορεί όπως είπαμε να είναι η πραγματική τιμή του σφάλματος, μία διαβαθμισμένη με κάποιον τρόπο (συνήθως με την παράγωγο της συνάρτησης μεταφοράς) τιμή του σφάλματος ή κάποια άλλη επιθυμητή τιμή ανάλογα με το δίκτυο. Κανονικά αυτή η προς τα πίσω διαδιδόμενη τιμή πολλαπλασιάζεται με τα βάρη των εισόδων για να τα τροποποιήσει κατάλληλα πριν τις επόμενες εισόδους.

Συστατικό 7. Συνάρτηση εκπαίδευσης (μάθησης): Ο σκοπός της συνάρτησης εκπαίδευσης είναι να τροποποιεί τα βάρη των μεταβλητών διασυνδέσεων των εισόδων κάθε στοιχείου επεξεργασίας σύμφωνα με κάποιον αλγόριθμο για νευρωνικά δίκτυα. Αυτή μπορεί να ονομαστεί και συνάρτηση προσαρμογής ή λειτουργία μάθησης.

Η λειτουργία ενός ΤΝΔ και η γνώση που είναι αποθηκευμένη σε αυτό τροποποιούνται μέσω της μεταβολής των βαρών των συνδέσεων (συνάψεων) κατά τη μάθηση του δικτύου. Μετά την

εκπαίδευση του δικτύου καμία μεταβολή των βαρών δεν επιτρέπεται. Η διαδικασία μάθησης αποτελεί βασική συνιστώσα του αντικειμένου των ΤΝΔ. Διακρίνονται δύο τεχνικές μάθησης:

- Η μάθηση με εποπτεία ή επίβλεψη (supervised learning) που ενσωματώνει μια εξωτερική πηγή (π. χ τον εκπαιδευτή) ή γενική γνώση για το σύστημα και
- Η μάθηση χωρίς εποπτεία (unsupervised learning) όπου δεν υπάρχει εξωτερική γνώση αναφοράς αλλά εξαρτάται από τοπικές πληροφορίες και εσωτερικά δεδομένα.

Στην περίπτωση μάθησης με εποπτεία παρέχεται στο δίκτυο υπό μάθηση η επιθυμητή έξοδος για κάθε είσοδο ώστε το δίκτυο να μαθαίνει τις σωστές συσχετίσεις μεταξύ εισόδων και εξόδων. Στην κατηγορία αυτή ανήκουν τα πρότυπα perceptron και ADALINE (παράρτημα Α). Τη σημαντικότερη θέση εδώ έχει ο αλγόριθμος μάθησης οπισθόδρομης διάδοσης (back propagation). Ο αλγόριθμος αυτός προσαρμόζει τα βάρη διασύνδεσης σε δίκτυα πολλαπλών στρωμάτων με βάση τη διάδοση ενός μέτρου του σφάλματος μεταξύ της επιθυμητής και της πραγματικής εξόδου του δικτύου από την έξοδο προς την είσοδο του δικτύου.


Για τη μάθηση χωρίς εποπτεία δεν παρέχεται στο δίκτυο καμία πληροφορία σχετική με την επιθυμητή έξοδο που αντιστοιχεί σε κάθε είσοδο. Αντίθετα, το δίκτυο αυτό – οργανώνεται και μαθαίνει να αποκρίνεται με διαφορετικό τρόπο σε διαφορετικά χαρακτηριστικά της εισόδου. Χαρακτηριστική εφαρμογή της κατηγορίας αυτής είναι τα δίκτυα ανίχνευσης χαρακτηριστικών και ομαδοποίησης δεδομένων. Παραδείγματα αλγορίθμων μάθησης χωρίς εποπτεία είναι ο αλγόριθμος του Hebb και ο αλγόριθμος της ανταγωνιστικής μάθησης.

2. 4. 2 Τοπολογίες και αρχιτεκτονικές

Ένα επίσης σημαντικό θέμα σε ότι αφορά τα τεχνητά νευρωνικά δίκτυα είναι οι πολλοί τρόποι κατά τους οποίους οι νευρώνες μπορούν να συνδυαστούν δημιουργώντας διαφορετικά κάθε φορά συμπλέγματα. Στο ανθρώπινο μυαλό, τα συμπλέγματα αυτά εμφανίζονται με τέτοιο τρόπο ώστε οι πληροφορίες να επεξεργάζονται δυναμικά, διαδραστικά και αυτο- οργανωτικά. Τα βιολογικά νευρωνικά δίκτυα είναι κατασκευασμένα σε τρισδιάστατο επίπεδο από πολλά μικροσκοπικά συστατικά. Αυτοί οι νευρώνες μπορούν να σχηματίσουν απεριόριστους διαφορετικούς συνδυασμούς. Δεν συμβαίνει το ίδιο και στους τεχνητούς νευρώνες. Ολοκληρωμένα κυκλώματα που χρησιμοποιούν την σύγχρονη τεχνολογία υπάρχουν σε δισδιάστατο επίπεδο με περιορισμένους συνδυασμούς για τους νευρώνες. Αυτός ο φυσικός περιορισμός έχει να κάνει με τους τύπους και το πεδίο δράσης των τεχνητών νευρωνικών δικτύων.

Οι διάφοροι συνδυασμοί των τεχνητών νευρώνων (που είναι απλοί και περιορισμένοι σε σχέση με τα βιολογικά ανάλογά τους) έχουν να κάνουν με την ύπαρξη επιπέδων τα οποία συνδέονται μεταξύ τους. Το επόμενο σημαντικό θέμα είναι ο τρόπος με τον οποίο συνδέονται αυτά τα επίπεδα που περιέχουν τους νευρώνες σε ένα τεχνητό νευρωνικό δίκτυο.

Όλα τα τεχνητά νευρωνικά δίκτυα έχουν παρόμοια δομή. Η δομή αυτή αναπαρίσταται στο σχήμα που ακολουθεί. Όπως βλέπουμε, κάποιοι νευρώνες επικοινωνούν με το εξωτερικό περιβάλλον απ' όπου και λαμβάνουν τα δεδομένα εισόδου. Άλλοι νευρώνες παράγουν την έξοδο και την εξάγουν στο περιβάλλον. Όλοι οι υπόλοιποι νευρώνες ενός δικτύου δεν είναι ορατοί.



Ένα δίκτυο όμως δεν είναι μόνο ένα σύνολο νευρώνων. Ένας από τους πιο εύκολους τρόπους για να σχεδιάσει κάποιος μία δομή είναι να δημιουργήσει επίπεδα με τα διάφορα στοιχεία. Ένα λειτουργικό δίκτυο λοιπόν, αποτελείται από τους νευρώνες αυτούς οι οποίοι διατάσσονται σε επίπεδα, τις συνδέσεις μεταξύ αυτών των επιπέδων και το άθροισμα των συναρτήσεων μεταφοράς.


Αν και υπάρχουν ωφέλιμα δίκτυα με ένα μόνο επίπεδο ή ακόμα και ένα μόνο στοιχείο, οι περισσότερες εφαρμογές απαιτούν τουλάχιστον τρία επίπεδα: ένα επίπεδο εισόδου, ένα κρυφό επίπεδο και ένα επίπεδο εξόδου.

Ανάλογα με την τοπολογία της διασύνδεσης των διαφόρων επιπέδων και της αλληλεπίδρασης των διαφόρων κόμβων ενός δικτύου, δηλαδή την αρχιτεκτονική του ΤΝΔ, υπάρχουν οι παρακάτω κατηγορίες ΤΝΔ:

- ΤΝΔ τύπου Hopfield όπου οι κόμβοι ενός επιπέδου επιδρούν με τους κόμβους του ίδιου, του αμέσως επόμενου ή και του προηγούμενου

- ΤΝΔ πρόσθιας τροφοδότησης (feedforward networks), στα οποία η πληροφορία μεταδίδεται από τα χαμηλότερα στα υψηλότερα στρώματα
- Δίκτυα με ανατροφοδότηση (feedback networks), στα οποία υπάρχει τουλάχιστον ένας κλειστός βρόχος
- Συμμετρικά αυτό – συσχετιστικά δίκτυα (symmetric auto – associative networks) όπου τόσο οι συνδέσεις όσο και τα βάρη τους είναι συμμετρικά

Στα παρακάτω σχήματα φαίνονται ένα κοινό παράδειγμα ΤΝΔ πολλαπλών στρωμάτων με πρόσθια τροφοδότηση και ένα ΤΝΔ τύπου Hopfield, που περιέχει διασυνδέσεις μεταξύ των νευρώνων στο ίδιο στρώμα καθώς και στα προηγούμενα στρώματα. Το δίκτυο αυτό αποτελείται από ένα μοναδικό στρώμα εισόδου που είναι συγχρόνως και στρώμα εξόδου.




Τα δίκτυα αυτά μαθαίνουν από εμπειρία και όχι με αναλυτική προτυποποίηση, έχουν την ικανότητα να γενικεύουν όμοιες εισόδους με όμοιες εξόδους και μπορούν να πραγματοποιήσουν αυθαίρετη μη – γραμμική σχέση μεταξύ εισόδων και εξόδων έχοντας κατανεμημένη τοπολογία που είναι έμφυτα παράλληλη.

Υπάρχουν πολλές παραλλαγές νευρωνικών μοντέλων, κάποιες από τις οποίες περιγράψαμε. Τα **πολυεπίπεδα** δίκτυα και τα δίκτυα συνάρτησης ακτινικής βάσης χρησιμοποιούνται στην προσέγγιση συναρτήσεων. Τα επαναλαμβανόμενα (recurrent) δίκτυα τα οποία είναι πολυεπίπεδα δίκτυα με μηχανισμούς ανατροφοδότησης, έχουν εσωτερικές καταστάσεις και γι' αυτό είναι κατάλληλα για μοντελοποίηση δυναμικών συστημάτων, ελεγκτές και πρόβλεψη χρονοσειρών.

Ένας από τους λόγους για τους οποίους τα πολυεπίπεδα δίκτυα είναι τόσο δημοφιλή, είναι η μαθησιακή τους ικανότητα. Με την συγκέντρωση αριθμητικών δεδομένων και την εκπαίδευση του δικτύου, μπορούμε να έχουμε το δίκτυο που θα πραγματοποιεί την συνάρτηση που αναμένουμε. Επίσης, ένα κατάλληλα εκπαιδευμένο δίκτυο μπορεί να είναι σε μεγάλο βαθμό γενικό με αποτέλεσμα να αποδίδει ικανοποιητικά σε δεδομένα εισόδου στα οποία δεν έχει εκπαιδευτεί (άγνωστα δεδομένα).

Κάθε νευρώνας σε ένα νευρωνικό δίκτυο ενεργεί αυτόνομα. Έτσι μπορούμε να έχουμε μεγάλες απαιτήσεις όσον αφορά την παράλληλη επεξεργασία.


2. 5 Πολυεπίπεδα Νευρωνικά Δίκτυα



Στην εικόνα φαίνεται ένα δίκτυο τριών επιπέδων. Τα δεδομένα εισάγονται από την αριστερή πλευρά και τα αποτελέσματα εξάγονται από τη δεξιά. Η αρίθμηση των επιπέδων ξεκινά την πλευρά του επιπέδου εισόδου και το πρώτο επίπεδο είναι αυτό της εισόδου των δεδομένων. Το δεύτερο είναι το κρυφό επίπεδο και το τρίτο είναι το επίπεδο εξόδου. Οι νευρώνες σε κάθε επίπεδο ονομάζονται από τον αύξοντα αριθμό ή την ονομασία του επιπέδου. Για παράδειγμα ένας νευρώνας στο επίπεδο εξόδου ονομάζεται νευρώνας εξόδου. Μπορεί να υπάρχουν και περισσότερα κρυφά επίπεδα. Δύο συνεχόμενα επίπεδα συνδέονται μεταξύ τους με βάρη. Τα επίπεδα που δεν είναι συνεχόμενα, δεν συνδέονται μεταξύ τους. Επίσης, δεν συνδέονται μεταξύ τους νευρώνες που ανήκουν στο ίδιο επίπεδο και δεν υπάρχουν βάρη που ανατροφοδοτούν την είσοδο με τα δεδομένα της εξόδου. Αυτό όπως είδαμε είναι ένα δίκτυο πρόσθιας τροφοδότησης και με τέτοια δίκτυα θα ασχοληθούμε στη συνέχεια. Εμείς θα μετράμε και το επίπεδο εισόδου για την ονομασία του δικτύου. Επομένως, το δίκτυο της εικόνας έχει τρία επίπεδα.

Κάποια δίκτυα έχουν διασυνδέσεις και μεταξύ των νευρώνων του ίδιου επιπέδου. Αυτό συμβαίνει κυρίως στο επίπεδο εξόδου και καλείται και ανταγωνισμός. Για παράδειγμα, σε μία εφαρμογή αναγνώρισης χαρακτήρων, αν η πιθανότητα να είναι ένας χαρακτήρας «ρ» είναι 0,85 και η πιθανότητα να είναι ο χαρακτήρας «φ» είναι 0,65, το δίκτυο θα πρέπει να μπορεί να

επιλέγει τη μεγαλύτερη πιθανότητα και να ακυρώσει τις υπόλοιπες. Στην παρακάτω εικόνα φαίνεται ένα απλό δίκτυο με ανατροφοδότηση και ανταγωνισμό.




2. 5. 1 Αλγόριθμοι μάθησης πολυστρωματικών ΤΝΔ

Ο αλγόριθμος μάθησης ενός νευρώνα με μη γραμμική παραγωγίσιμη βαθμίδα, είναι σχετικά απλός. Ένα πολυστρωματικό ΤΝΔ αποτελείται όπως έχουμε πει από το στρώμα εισόδου, το στρώμα εξόδου και ένα ή περισσότερα ενδιάμεσα κρυφά στρώματα. Δεν είναι όμως γνωστός εκ των προτέρων ο αριθμός των νευρώνων που απαιτούνται σε κάθε στρώμα και συνεπώς απαιτείται κάποιος πειραματισμός για να βρεθεί ο ελάχιστος αριθμός των νευρώνων που αποδίδει τα επιθυμητά αποτελέσματα.

Για τον έλεγχο διεργασιών, είναι αυτονόητο ότι βασικό κριτήριο είναι η ελαχιστοποίηση τόσο του αριθμού των στρωμάτων όσο και του αριθμού των νευρώνων σε κάθε στρώμα. Για τα περισσότερα πρακτικά προβλήματα, έχει αποδειχθεί ότι ένα κρυφό επίπεδο αρκεί και ο αριθμός των νευρώνων είναι περιορισμένος.

Το πρόβλημα της μάθησης με εποπτεία ενός σύνθετου ΤΝΔ με πολλαπλά στρώματα, ουσιαστικά μεταφράζεται σε πρόβλημα εύρεσης ενός ευσταθούς επαναληπτικού αλγορίθμου που θα προσαρμόζει τα βάρη των διασυνδέσεων των νευρώνων στα διάφορα στρώματα συστηματικά με δεδομένα τις επιθυμητές και τις πραγματικές τιμές του δικτύου μόνο.

2. 6 Αλγόριθμος μάθησης με οπισθόδρομη διάδοση



Για να εκπαιδεύσουμε ένα νευρωνικό δίκτυο, θα πρέπει να προσαρμόσουμε τα βάρη κάθε μονάδας με τρόπο τέτοιο ώστε το σφάλμα μεταξύ της πραγματικής και της αναμενόμενης τιμής να είναι ελάχιστο. Αυτό προϋποθέτει ότι το δίκτυο θα υπολογίζει την παράγωγο των σφαλμάτων ως προς τα βάρη (EW). Με άλλα λόγια, θα πρέπει να εκτιμά την μεταβολή του σφάλματος καθώς αυξάνεται ή μειώνεται ελάχιστα κάθε βάρος. Η πιο διαδεδομένη μέθοδος υπολογισμού του EW είναι ο αλγόριθμος οπισθόδρομης διάδοσης.

Ο αλγόριθμος αυτός γίνεται πιο εύκολα κατανοητός αν όλες οι μονάδες του δικτύου είναι γραμμικές. Αρχικά υπολογίζεται ο ρυθμός σύμφωνα με τον οποίο αλλάζει το σφάλμα όσο μεταβάλλεται το επίπεδο ενεργητικότητας της μονάδας (EA). Για τις μονάδες εξόδου, το EA δεν είναι άλλο από την διαφορά της πραγματικής από την επιθυμητή τιμή. Για να υπολογιστεί το EA για μία μονάδα στο επίπεδο πριν από αυτό της εξόδου, αρχικά καθορίζονται όλα τα βάρη μεταξύ του νευρώνα στο κρυμμένο επίπεδο και του νευρώνα στο επίπεδο εξόδου με τον οποίο συνδέεται. Στη συνέχεια πολλαπλασιάζουμε αυτά τα βάρη με τα EA των μονάδων εξόδων και προσθέτουμε τα γινόμενα. Το άθροισμα αυτό ισοδυναμεί με το EA του συγκεκριμένου νευρώνα. Αφού ολοκληρώσουμε τον υπολογισμό των EA όλων των νευρώνων για το προτελευταίο επίπεδο, κατ' αντίστοιχο τρόπο υπολογίζουμε και τα EA για τους νευρώνες των υπόλοιπων κρυμμένων επιπέδων προχωρώντας με κατεύθυνση αντίθετη από αυτήν με την οποία μεταδίδονται οι πληροφορίες μέσα στο δίκτυο. Από αυτό προκύπτει και το όνομα «οπισθόδρομη διάδοση». Από την στιγμή που το EA για έναν νευρώνα έχει υπολογιστεί και είναι γνωστό, υπολογίζουμε το EW

για κάθε σύνδεση απ' όπου εισέρχονται πληροφορίες στον νευρώνα. Το EW είναι το γινόμενο του EA και τις δραστηριότητας μέσω της σύνδεσης απ' όπου εισέρχονται οι πληροφορίες.

Για μη γραμμικούς νευρώνες, ο αλγόριθμος έχει ένα επιπλέον βήμα. Πριν αρχίσει η οπισθόδρομη διάδοση, το EA μετατρέπεται σε EI, δηλαδή στον ρυθμό με τον οποίο το σφάλμα αλλάζει όσο μεταβάλλεται η συνολική είσοδος στον νευρώνα.

2. 6. 1 Ψευδοκώδικας

Ο αλγόριθμος εκπαίδευσης θα πρέπει να περιέχει τα παρακάτω βήματα:

Επαναλάβανε

Για κάθε παράμετρο εισόδου

Εκπαίδευσε σύμφωνα με την συγκεκριμένη παράμετρο

Τέλος βρόχου

Μέχρι το σφάλμα να είναι αποδεκτώς χαμηλό

Πριν εξετάσουμε το κρίσιμο βήμα «εκπαίδευσε σύμφωνα με την παράμετρο» ας σχολιάσουμε κάποια άλλα σημεία. Αρχικά, θα πρέπει να έχει εξασφαλιστεί μία καθορισμένη ροή δεδομένων εισόδου με μορφή διανυσμάτων. Εναλλακτικά, μπορούν να παρουσιάζονται τα διανύσματα με τυχαία σειρά. Η δεύτερη εκδοχή είναι περισσότερο ρεαλιστική. Από την εμπειρία όμως, ξέρουμε ότι η εκπαίδευση είναι πιο γρήγορη αν τα διανύσματα είναι με κάποια τάξη και παρουσιάζονται με αυτήν τη σειρά. Θα πρέπει επίσης να ξεκαθαρίσουμε τι εννοούμε με τον όρο «αποδεκτό σφάλμα». Μία πρώτη λογική θα ήταν να εξασφαλίσουμε ότι οι νευρώνες εξόδου θα δίνουν αποκρίσεις στο σωστό διάστημα από ένα ζεύγος $[0, 0,5]$, $[0,5, 1]$, όπως το σωστό καθορίζεται από την αναμενόμενη τιμή. Μία δεύτερη προσέγγιση θα ήταν να επιλέξουμε μία μικρή τιμή όπως το 0,001 την οποία δεν θα πρέπει να υπερβαίνει το σφάλμα.

Το κυρίως βήμα της εκπαίδευσης μπορεί να αναλυθεί στις παρακάτω ενέργειες:

1. Παρουσίαση του διανύσματος στο επίπεδο εισόδου
2. Οι νευρώνες των κρυμμένων επιπέδων προσδιορίζουν την έξοδο σύμφωνα με το πρότυπο
3. Οι νευρώνες του επιπέδου εξόδου παράγουν την έξοδο χρησιμοποιώντας το αποτέλεσμα του βήματος (2)

Τα βήματα 1-3 λέγονται και βήματα πρόσθιας διάδοσης καθώς η ροή είναι από την είσοδο προς την έξοδο

4. Εφαρμογή της εξόδου του προτύπου στο επίπεδο εξόδου
5. Υπολογισμός των EA στους νευρώνες εξόδου

6. Εκπαίδευση κάθε νευρώνα σύμφωνα με την μέγιστη κατάβαση (gradient descent)
 7. Υπολογισμός του ΕΑ για κάθε νευρώνα κρυμμένου επιπέδου
 8. Χρήση του ΕΑ του βήματος (7) για την εκπαίδευση σύμφωνα με την βαθμιαία κατάβαση
- Το βήμα (7) προϋποθέτει την οπισθόδρομη διάδοση των ΕΑ από τους νευρώνες εξόδου στους νευρώνες των κρυμμένων επιπέδων. Αυτό λοιπόν είναι το βήμα οπισθόδρομης διάδοσης. Τα δίκτυα τα οποία εκπαιδεύονται με αυτόν τον αλγόριθμο, ονομάζονται συνήθως πολυεπίπεδα perceptrons (MLP).

2. 6. 2 Μαθηματική προσέγγιση

Κάθε σύνδεση μεταξύ των νευρώνων χαρακτηρίζεται από έναν αριθμό, το βάρος της σύνδεσης. Έστω W_{ij} το βάρος της σύνδεσης του νευρώνα u_i με τον νευρώνα u_j . Μπορούμε να αναπαραστήσουμε το πρότυπο των διασυνδέσεων στο δίκτυο με το διάνυσμα των βαρών W . Στοιχεία του διανύσματος αυτού είναι τα βάρη W_{ij} . Υπάρχουν δύο είδη συνδέσεων: οι διεγερτικές και οι ανασταλτικές. Θετική τιμή βάρους συμβολίζει διεγερτική σύνδεση ενώ αρνητική τιμή φανερώνει ανασταλτική σύνδεση. Το πρότυπο των συνδέσεων χαρακτηρίζει την αρχιτεκτονική του δικτύου.

Ένας νευρώνας που βρίσκεται στο επίπεδο εξόδου του δικτύου ενεργεί σε δύο βήματα:

- Αρχικά υπολογίζει την συνολική σταθμισμένη είσοδο x_j από την εξίσωση:

$$X_j = \sum_i y_i \times W_{ij}, \text{ } y_i \text{ είναι το επίπεδο δραστηριότητας του } i \text{ οστού νευρώνα στο προηγούμενο}$$

επίπεδο και W_{ij} είναι το βάρος της σύνδεσης μεταξύ του i οστού και του j οστού νευρώνα

- Στη συνέχεια υπολογίζεται το επίπεδο δραστηριότητας y_j χρησιμοποιώντας κάποια συνάρτηση για την συνολική σταθμισμένη είσοδο. Συνήθως χρησιμοποιούμε την σιγμοειδή συνάρτηση:

$$y_j = \frac{1}{1 + e^{-x_j}}$$

Αφού υπολογιστούν όλα τα επίπεδα δραστηριότητας των νευρώνων εξόδου, το δίκτυο υπολογίζει το σφάλμα E ως εξής:

$$E = \frac{1}{2} \sum_i (y_i - d_i)^2, \text{ } y_i \text{ είναι το επίπεδο δραστηριότητας του } i \text{ οστού νευρώνα στο τελευταίο}$$

επίπεδο και d_i η επιθυμητή έξοδος του i οστού νευρώνα

Ο αλγόριθμος οπισθόδρομης διάδοσης αποτελείται από 4 βήματα:

1. Υπολογισμός των EA_j : $EA_j = \frac{\partial E}{\partial y_j} = y_j - d_j$
2. Υπολογισμός των EI_j : $EI_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \times \frac{dy_j}{dx_j} = EA_j y_j (1 - y_j)$
3. Υπολογισμός των EW_{ij} : $EW_{ij} = \frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial x_j} \times \frac{\partial x_j}{\partial W_{ij}} = EI_j y_i$
4. Υπολογισμός των EA_i : $EA_i = \frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \times \frac{\partial x_j}{\partial y_i} = \sum_j EI_j W_{ij}$

Με τα βήματα (2) και (4) μπορούμε να μετατρέπουμε τα EA ενός επιπέδου νευρώνων σε EA του προηγούμενου επιπέδου. Η διαδικασία επαναλαμβάνεται μέχρι να πάρουμε τα EA όσων προηγούμενων επιπέδων χρειάζεται κάθε φορά. Όταν γνωρίζουμε το EA ενός νευρώνα, ακολουθούμε τα βήματα (2) και (3) για να υπολογίσουμε τα EW των συνδέσεων εισόδου σε αυτόν.

2. 7 Εφαρμογές τεχνητών νευρωνικών δικτύων

Τα νευρωνικά δίκτυα λόγω του ότι βασίζονται στους νευρώνες, τις διασυνδέσεις τους και τις συναρτήσεις μεταφοράς, υπάρχουν ομοιότητες μεταξύ των διαφορετικών δομών και αρχιτεκτονικών τους. Η πλειάδα των παραλλαγών τους πηγάζει από τους διαφορετικούς κανόνες μάθησης και τους τρόπους που αυτοί τροποποιούν την τοπολογία των δικτύων. Παρακάτω παραθέτουμε πέντε κατηγορίες νευρωνικών δικτύων στις οποίες ανήκουν οι περισσότερες εφαρμογές. Ο διαχωρισμός αυτός δεν είναι αποκλειστικός, απλά βοηθά να ξεκαθαρίσουμε την σύγχυση σε ότι αφορά τις διαφορετικές αρχιτεκτονικές και την καταλληλότητα της κάθε μίας για συγκεκριμένες εφαρμογές. Έτσι λοιπόν, έχουμε νευρωνικά δίκτυα για:

- Πρόβλεψη
- Ταξινόμηση
- Συσχετισμό δεδομένων
- Αντίληψη δεδομένων
- Φιλτράρισμα δεδομένων

Στον πίνακα που ακολουθεί φαίνονται οι διαφορές αυτών των κατηγοριών και οι τοπολογίες που εμφανίζονται σε κάθε κατηγορία. Αυτός ο πίνακας είναι περισσότερο ένας οδηγός και δεν συμπεριλαμβάνει ειδικές περιπτώσεις.

Τύπος Δικτύου	Δίκτυα	Χρήση Δικτύου
Πρόβλεψη	- Οπισθόδρομης διάδοσης - Κανόνας Delta -Επεκτάσεις κανόνα Delta -Κατευθυνόμενη τυχαία αναζήτηση -Νευρωνικά ανώτερης σειράς -Αυτοοργανωτικός χάρτης οπισθόδρομης διάδοσης	Χρήση τιμών εισόδου για την παραγωγή εξόδου (επιλογή των καλύτερων μετοχών, πρόβλεψη του καιρού, αναγνώριση ανθρώπων με κίνδυνο εμφάνισης καρκίνου)
Ταξινόμηση	-Πιθανοτικό νευρωνικό δίκτυο - Αντίθετη διάδοση	Χρήση τιμών εισόδου για τον καθορισμό της τάξης (αν είναι το γράμμα Α η είσοδος, αν η άμορφη μάζα στο βίντεο είναι αεροπλάνο και τι είδος αεροπλάνου)
Συσχέτιση δεδομένων	-Hopfield -Μηχανή Boltzmann -Δίκτυο Hamming -Αμφίδρομη σχετική μνήμη -Χρονική αναγνώριση προτύπων	Όπως την ταξινόμηση αλλά αναγνωρίζει δεδομένα που περιέχουν σφάλμα (αναγνώριση των χαρακτήρων που σκανάρονται αλλά και της περίπτωσης μη καλής λειτουργίας του σκάνερ)
Αντίληψη Δεδομένων	-Αυτοοργανωτικός χάρτης -Δίκτυο προσαρμοστικής αντήχησης	Ανάλυση των εισόδων έτσι ώστε να συναχθούν σχέσεις ομαδοποίησης (εξαγωγή από μια βάση δεδομένων των ονομάτων αυτών που είναι πολύ πιθανό να αγοράσουν συγκεκριμένο προϊόν)
Φιλτράρισμα Δεδομένων	-Αναδιακίνηση	Εξομάλυνση σήματος εισόδου(εξάλειψη του θορύβου σε τηλεφωνική γραμμή)

Τα νευρωνικά δίκτυα μεταβάλλονται καθώς περνούν από το πεδίο της ακαδημαϊκής έρευνας στον πραγματικό κόσμο, όπου οι χρήστες θέλουν απλά να κάνουν την δουλειά τους με αυτά τα εργαλεία. Πολλά από τα δίκτυα που χρησιμοποιούνται είναι αρκετά ακριβή, αλλά οι χρήστες δεν είναι απόλυτα ικανοποιημένοι τις περισσότερες φορές γιατί επιθυμούν να έχουν διαθέσιμα εργαλεία που μπορούν να τους λύνουν τα προβλήματα στο έπακρο. Τα δίκτυα που υπάρχουν όμως, έχουν ακρίβεια 85- 90% και οι εφαρμογές που ανέχονται τόσο μεγάλο σφάλμα είναι λίγες.

Οι κυριότεροι τομείς όπου τα νευρωνικά δίκτυα βρίσκουν εφαρμογή, είναι:

- Η επεξεργασία γλώσσας (μετατροπή προφορικού λόγου σε γραπτό, φωνητικές εντολές, αυτόματη μετάφραση ή αντιγραφή, αναγνώριση φωνής, βοηθήματα σε κωφούς ή σε άτομα με ειδικές ικανότητες)
- Αναγνώριση χαρακτήρων (μετατροπή χειρόγραφων, υπογραφών κλπ σε ηλεκτρονική μορφή)
- Συμπίεση εικόνων/ δεδομένων (συμπίεση και αποσυμπίεση δεδομένων σε πραγματικό χρόνο)
- Αναγνώριση προτύπων (επεξεργασία - προγραμματισμός αισθητήρων/ ανιχνευτών, έλεγχος ποιότητας, διαγνώσεις στην ιατρική)

- Επεξεργασία σήματος
- Έλεγχος πολύπλοκων συστημάτων
- Οικονομία

Η οικονομία είναι ο τομέας που θα μας απασχολήσει περισσότερο, καθώς έχουμε να κάνουμε με μία εφαρμογή νευρωνικών δικτύων σε παραγωγική/ εμπορική επιχείρηση.

Αφού τα νευρωνικά δίκτυα είναι πολύ καλά στο να αναγνωρίζουν τάσεις και πρότυπα στα δεδομένα, είναι πολύ καλά σε τομείς πρόβλεψης όπως:

- Πρόβλεψη πωλήσεων/ ζήτησης
- Βιομηχανικός έλεγχος διαδικασιών
- Έρευνα πελατών
- Επικύρωση στοιχείων
- Διαχείριση κινδύνου
- Marketing

Στον τομέα των επιχειρήσεων λοιπόν, τα νευρωνικά δίκτυα χρησιμοποιούνται περισσότερο σε οικονομικές και λογιστικές αναλύσεις. Σχεδόν όλες οι εφαρμογές τεχνητών νευρωνικών δικτύων ταιριάζουν σε κάποιο τμήμα μιας επιχείρησης ή σε μία οικονομική ανάλυση.

Υπάρχει και η δυνατότητα χρήσης των νευρωνικών δικτύων στον εντοπισμό πόρων και τον προγραμματισμό. Επίσης, μπορούν να χρησιμοποιηθούν στην προσπέλαση βάσεων δεδομένων, δηλαδή στον εντοπισμό συγκεκριμένων στοιχείων από τα δεδομένα που υπάρχουν αποθηκευμένα σε μία βάση. Υπάρχουν και κάποιες άλλες εφαρμογές τεχνητών νευρωνικών δικτύων σε τομείς της οικονομίας.

Η διαδικασία έγκρισης δανείου σε δανειολήπτες περιλαμβάνει την συμπλήρωση διάφορων εντύπων τα οποία θα βοηθήσουν τον υπεύθυνο να αποφασίσει. Τα δεδομένα από αυτά τα έντυπα που έχουν χρησιμοποιηθεί κατά το παρελθόν, χρησιμοποιούνται για να εκπαιδευτεί ένα δίκτυο έτσι ώστε να είναι σε θέση να δώσει θετική ή αρνητική απάντηση για την χορήγηση ενός δανείου. Πιστωτικά ιδρύματα χρησιμοποιούν παρόμοιες τεχνικές οπισθόδρομης διάδοσης για να καθορίσουν πιστωτικά όρια και πιστωτικούς κινδύνους.

Στον τομέα του άμεσου marketing εφαρμόζονται νευρωνικά δίκτυα σε βάσεις δεδομένων, έτσι ώστε να αυξηθούν οι τηλεφωνικές παραγγελίες, μειώνοντας τα τηλεφωνήματα σε ακατάλληλες ώρες για συγκεκριμένες πληθυσμιακές ομάδες.

Ειδικότερα τα προβλήματα πρόβλεψης μπορούν να χωριστούν σε δύο κατηγορίες. Σε προβλήματα ταξινόμησης και σε προβλήματα παλινδρόμησης. Στην ταξινόμηση, το ζητούμενο είναι να αποφανθούμε σε ποια από ορισμένες διακριτές ομάδες ανήκουν οι διατάξεις δεδομένων εισόδου. Οι εφαρμογές έχουν να κάνουν με εκχώρηση ή όχι πίστωσης, με εντοπισμό ασθενειών,

αναγνώριση υπογραφής. Σε όλες αυτές τις περιπτώσεις η έξοδος είναι μία καθαρά μονοσήμαντη μεταβλητή. Οι πιο γνωστές περιπτώσεις είναι αυτές όπου οι διαφορετικές κλάσεις είναι δύο αλλά η επίλυση προβλημάτων με περισσότερες κλάσεις είναι επίσης εφικτή.

Στα προβλήματα παλινδρόμησης ο στόχος είναι να προβλέψουμε την τιμή μιας συνεχούς μεταβλητής όπως είναι η τιμή μιας μετοχής για την επόμενη μέρα, η κατανάλωση καυσίμου ενός αυτοκινήτου, τα έσοδα του επόμενου χρόνου κλπ. Σε αυτές τις περιπτώσεις η έξοδος είναι μία απλή αριθμητική τιμή.

ΚΕΦΑΛΑΙΟ 3^ο

3. 1 Γιατί μελετάμε την πρόβλεψη

Στη διοίκηση και τη διαχείριση των μεγάλων οργανισμών η ανάγκη για σχεδιασμό και έλεγχο είναι ιδιαίτερα επιτακτική, γιατί ο χρόνος που απαιτείται για μία διοικητική απόφαση κυμαίνεται από αρκετά χρόνια, όπως συμβαίνει στην περίπτωση της κατασκευής ενός εργοστασίου παραγωγής ηλεκτρικής ενέργειας, ως λίγες μόνο μέρες ή ώρες όπως συμβαίνει στην περίπτωση του προσδιορισμού των επιπέδων παραγωγής και αποθεμάτων. Πληροφορίες που προέρχονται από αναφορές σχετικά με μελλοντικά γεγονότα, αποτελούν συνήθως κρίσιμη εισροή στο ευρύ φάσμα των διαχειριστικών και διευθυντικών αποφάσεων, αφού οι αποφάσεις για τα σημερινά σχέδια εξαρτώνται από τις μελλοντικές προσδοκίες. Επομένως η ικανότητα πρόβλεψης των μελλοντικών γεγονότων με ακρίβεια, είναι ένα απαραίτητο μέρος του σημερινού πολύπλοκου διευθυντικού έργου και του ελέγχου.

3. 2 Ποιος πρέπει να κάνει προβλέψεις

Οι προβλέψεις αποτελούν αριθμητικούς υπολογισμούς των μελλοντικών επιπέδων των πωλήσεων, της ζήτησης, των επενδύσεων, του κόστους των εξαγωγών, των τιμών για μία εταιρεία, μία βιομηχανία, έναν φορέα της οικονομίας ή τη συνολική οικονομία.

Ο σκοπός της πρόβλεψης είναι να βοηθήσει τη διεύθυνση να προγραμματίσει τις απαιτήσεις για marketing, πρώτες ύλες, προσωπικού, παραγωγή, υπηρεσίες, απόκτηση κεφαλαίου και δημιουργία εγκαταστάσεων, τις βραχυχρόνιες απαιτήσεις για χρηματοδότηση κλπ. Οι έξυπνες, επιστημονικές και καλά προετοιμασμένες προβλέψεις θα πρέπει να είναι αρκετά ακριβείς, ώστε να επιτρέπουν καλύτερο σχεδιασμό και έλεγχο απ' ό,τι θα γινόταν χωρίς αυτές.

Σκοπός της πρόβλεψης είναι, ανάμεσα σε άλλα, να βελτιωθεί ο σχεδιασμός και ο έλεγχος. Οι ακριβείς προβλέψεις μπορεί να μειώσουν τις απώλειες που οφείλονται σε απούλητα αποθέματα, σε αποθηκευμένα ημικατεργασμένα προϊόντα που δεν έφτασαν στο στάδιο της διάθεσης ενώ θα μπορούσαν να είχαν πουληθεί, σε κόστος που οφείλεται σε περιορισμένη παραγωγική ικανότητα ή κόστος από μη ικανοποιητικές μεθόδους παραγωγής.

Ποιος είναι αυτός μέσα σε μία επιχείρηση ο οποίος θα ασχοληθεί με την προσπάθεια της πρόβλεψης; Εκείνοι που θα ασχοληθούν είναι οι υπεύθυνοι για τον επιχειρηματικό σχεδιασμό και έλεγχο, καθώς και αυτοί που ανήκουν στο προσωπικό στήριξης του επιτελείου της εταιρείας και διαθέτουν γνώσεις σύγχρονων μεθόδων πρόβλεψης. Επομένως εκείνοι που θα αναλάβουν - τυπικά- να προετοιμάσουν προβλέψεις θα είναι εκείνοι που έχουν εξασκηθεί καλά στην πρόβλεψη και κατέχουν υπεύθυνες θέσεις στον τομέα λήψης αποφάσεων, καθώς και όσοι βοηθούν αυτούς που παίρνουν τις αποφάσεις. Για να κάνει πρόβλεψη ένα άτομο, συχνά θα πρέπει να μελετήσει εσωτερικά δεδομένα του παρελθόντος. Ένα σύνολο από χρονικά ταξινομημένες παρατηρήσεις σε σχέση με μία μεταβλητή κατά τη διάρκεια διαχρονικών ή ισόχρονων περιόδων, ονομάζεται χρονοσειρά. Οι τεχνικές που αναλύουν τη μεταβλητότητα στη χρονοσειρά αναφέρονται ως μέθοδοι χρονοσειρών.

3. 3 Μέθοδοι πρόβλεψης

Οι μέθοδοι πρόβλεψης που ασχολούνται με την παραγωγή αριθμητικών εκτιμήσεων ποικίλουν από σχετικά απλές ως πολύ σύνθετες και απαιτητικές τεχνικές. Στην πλειοψηφία τους οι τεχνικές αυτές είναι ποσοτικές. Υπάρχουν όμως και χρήσιμες ποιοτικές προσεγγίσεις.

Ο κινητός μέσος όρος είναι η μέθοδος, όπου κάθε σημείο ενός κινητού μέσου μιας χρονοσειράς είναι ο αριθμητικός μέσος ενός αριθμού διαδοχικών παρατηρήσεων της σειράς. Ο κινητός μέσος όρος συχνά χρησιμοποιείται για την πρόβλεψη περιορισμένων εμπορικών συναλλαγών που γίνονται κυρίως στα πλαίσια του προγράμματος ελέγχου των αποθεμάτων.

Αν έχουμε i παρατηρήσεις για την τιμή μιας μεταβλητής και w_i είναι το βάρος (η ποσοτική έκφραση της σημαντικότητας) που δίδεται στην i παρατήρηση, τότε - εφ' όσον τα βάρη είναι κανονικοποιημένα- η πρόβλεψη της τιμής της μεταβλητής ένα βήμα μπροστά στο χρόνο, είναι:

$$\begin{aligned}\hat{y}_{t+1} &= w_0 y_t + w_1 y_{t-1} + w_2 y_{t-2} + \dots + w_{k-1} y_{t-k+1}, k \leq t = \\ &= \sum_{i=0}^{k-1} w_i y_{t-i}\end{aligned}$$

Η πρόβλεψη για p βήματα μπροστά, θα είναι αντίστοιχα:

$\hat{y}_{t+p} = \hat{y}_{t+1}, p \geq 1$. Ο μέσος που υπολογίζεται με τον παραπάνω τρόπο ονομάζεται κινητός, γιατί κάθε φορά που εισάγεται μια νέα παρατήρηση, τα βάρη «κινούνται» ένα βήμα μπροστά.

Σημειώνουμε εδώ ότι γενικά ισχύει:

y_t είναι η τιμή της μεταβλητής την στιγμή t ,

\hat{y}_t είναι η πρόβλεψη, η εκτιμώμενη τιμή, για την μεταβλητή y_t και

$e = y_t - \hat{y}_t$ είναι το σφάλμα που προκύπτει από την χρήση της \hat{y} για την πρόβλεψη της τιμής της y .

Η μέθοδος της εκθετικής εξομάλυνσης είναι μία ευέλικτη τεχνική της προβολής της τάσης, όπου στις παρατηρήσεις παρελθόντων ετών δίνονται διαφορετικές σταθμίσεις κατά τον υπολογισμό της πρόβλεψης. Η μέθοδος είναι παρόμοια με τη μέθοδο του κινητού μέσου όρου, όμως επιτρέπει στους προβλέποντες να διορθώσουν προγενέστερες ανακρίβειες στις προβλέψεις. Με άλλα λόγια, η μέθοδος αυτή έχει το πλεονέκτημα της διενέργειας μιας απλής, επικαιροποιημένης πρόβλεψης, η οποία είναι όμοια με την παλαιότερη πρόβλεψη, πλέον κάποια δηλωμένη αναλογία προβλεπτικού σφάλματος για την προηγούμενη περίοδο. Οι μέθοδοι της εκθετικής εξομάλυνσης χρησιμοποιούνται συνήθως για την πρόβλεψη μεγάλου αριθμού μεγεθών, όπως στην περίπτωση του σχεδιασμού αναγκών σε υλικά, τον έλεγχο πωλήσεων, τις προβλέψεις περιθωρίων κέρδους και άλλα οικονομικά δεδομένα.

Εδώ κάθε νέα πρόβλεψη (για την στιγμή $t+1$) μπορεί να θεωρηθεί σαν ένας σταθμισμένος μέσος της προηγούμενης πρόβλεψης (για την στιγμή t) και της νέας παρατήρησης (την στιγμή t) με βάρος (σταθερά εξομάλυνσης) α στην νεότερη παρατήρηση και $1 - \alpha$ στην παλιότερη πρόβλεψη. Οι τιμές του α κυμαίνονται μεταξύ 0 και 1 ($0 \leq \alpha \leq 1$). Επομένως,

(νέα πρόβλεψη) = $(1 - \alpha) \times$ (παλιά πρόβλεψη) + $\alpha \times$ (νέα παρατήρηση) ή

$$\hat{y}_{t+1} = (1 - \alpha) \hat{y}_t + \alpha y_t = \hat{y}_t - \alpha \hat{y}_t + \alpha y_t = \hat{y}_t + \alpha (y_t - \hat{y}_t) = \hat{y}_t + \alpha e_t$$

Οι μέθοδοι διαχωρισμού χρονοσειρών χρησιμοποιούνται ευρέως για την ταυτοποίηση των συστηματικών συνιστωσών μιας χρονοσειράς, όπως είναι η τάση, ο κύκλος και η εποχικότητα, καθώς και οι μη συστηματικές ή τυχαίες συνιστώσες. Για την προβολή της τάσης, μια μαθηματική έκφραση, δηλαδή μια ευθεία γραμμή, ή μια αργά μεταβαλλόμενη αλγεβρική μορφή, για τη χρονοσειρά προβάλλεται στο μέλλον. Το εποχικό πρότυπο ταυτοποιείται με τον καθορισμό των εποχικών δεικτών για κάθε μήνα ή τρίμηνο ενός έτους. Κατόπιν τα πρότυπα αυτά προβάλλονται στο μέλλον. Η κυκλική πρόβλεψη προετοιμάζεται από άλλες συστηματικές προβολές ή με οικονομικά κριτήρια. Κατά την πρόβλεψη, η μη συστηματική διακύμανση συνήθως υποτίθεται ότι είναι μηδέν.

Μια μέθοδος για την πρόβλεψη εποχικών διακυμάνσεων είναι γνωστή ως Census II ή μεταβλητή X 11. Πρόκειται για μια αναλυτική μέθοδο πρόβλεψη εποχικών διακυμάνσεων στις

τιμές πολλών μεγεθών. Αναλύει μεταβολές στα εποχικά υποδείγματα διαχρονικά και παρέχει πρόβλεψη των μεταβαλλόμενων εποχικών δεικτών κατά ένα έτος μπροστά. Η μέθοδος αυτή χρησιμοποιείται για την απαλλαγή από την εποχικότητα και την πρόβλεψη μηνιαίων και τριμηνιαίων χρονοσειρών.

Τα μοντέλα παλινδρόμησης είναι διαδικασίες εκτίμησης γραμμικών ή πολυωνυμικών σχέσεων, ή πολλαπλών γραμμικών σχέσεων. Τα μοντέλα αυτά εκφράζουν τις σχέσεις που υπάρχουν ανάμεσα στις μεταβλητές, οι οποίες αποτελούν αντικείμενο πρόβλεψης των ερμηνευτικών μεταβλητών που σχετίζονται με αυτές. Οι μέθοδοι αυτές είναι πολύ χρήσιμες όταν υπάρχουν στη διάθεσή μας τα κατάλληλα ιστορικά δεδομένα, τα σχετικά με τους κυρίαρχους παράγοντες που προκαλούν τις διακυμάνσεις στις τιμές των μεταβλητών που πρόκειται να προβλεφθούν.

Στην ανάλυση της παλινδρόμησης η μαθηματική μορφή της σχέσης μεταξύ της μεταβλητής απόκρισης y (εξαρτημένη μεταβλητή) και των ανεξάρτητων μεταβλητών x_k , ορίζεται ως:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon$$

Τα β είναι καθορισμένες σταθερές που ονομάζονται παράμετροι παλινδρόμησης και ε είναι ο όρος του σφάλματος. Η παραπάνω σχέση μας λέει ότι η συμπεριφορά της y μπορεί να μοντελοποιηθεί ως ένα αιτιοκρατικό ή ντετερμινιστικό μέρος συν ένα στοχαστικό ή τυχαίο μέρος. Το αιτιοκρατικό μέρος $\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$ εξηγεί ή καλύτερα προβλέπει την τιμή της y . Η συμπεριφορά της y που δεν μπορεί να ερμηνευτεί με το αιτιοκρατικό στοιχείο, σχετίζεται με τον στοχαστικό όρο ε .

Οι μεταβλητές x μπορεί να είναι οτιδήποτε, ακόμα και συναρτήσεις άλλων μεταβλητών x . Για παράδειγμα, οι x , x^2 και $\log(x)$ μπορούν να εμφανίζονται στο ίδιο μοντέλο. Τα επόμενα 3 παραδείγματα είναι γραμμικά μοντέλα παλινδρόμησης:

$$y = \beta_0 + \beta_1 x + \beta_2 x_2 + \varepsilon$$

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 x_1 x_2 + \varepsilon$$

$$y = \beta_0 + \beta_1 x_1^{1/2} + \beta_3 x_2 + \beta_4 \log(x_2) + \varepsilon$$

Πολλά μοντέλα μπορούν να μετατραπούν σε γραμμικά. Για παράδειγμα, το μοντέλο

$$y = \beta_0 x \beta_1^x + \varepsilon \text{ μπορεί να μετατραπεί στο}$$

$$\log(y) = \log(\beta_0) + x \log(\beta_1) + \log(\varepsilon)$$

Μια επέκταση των υποδειγμάτων παλινδρόμησης αποτελούν τα συστήματα πολλών εξισώσεων που εκφράζουν τις δυναμικές αλληλοσυσχετίσεις μιας οικονομίας, ενός τομέα της οικονομίας ή μιας βιομηχανίας. Τα συστήματα αυτά ονομάζονται οικονομετρικά μοντέλα και χρησιμοποιούνται για την εξήγηση και την πρόβλεψη της συμπεριφοράς των ενδογενών μεταβλητών στο μοντέλο. Τα οικονομετρικά μοντέλα είναι αιτιοκρατικά συστήματα στα οποία οι

εξισώσεις θεωρούνται ότι εκφράζουν αιτιακές σχέσεις που ικανοποιούν τις αρχές της οικονομικής θεωρίας. Τυπικές εφαρμογές τέτοιων υποδειγμάτων περιλαμβάνουν συστήματα πρόβλεψης των πωλήσεων μεγάλων οργανισμών, επιχειρήσεων και κρατικών τομέων, καθώς και για κλάδους ή ολόκληρη τη βιομηχανία. Στα αυτοπαλινδρόμα μοντέλα η τιμή της y εξαρτάται από εκφράσεις των προηγούμενων τιμών της ίδιας της y . Ένα παράδειγμα τέτοιου μοντέλου είναι:

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_3 y_{t-3} + \dots + \phi_p y_{t-p} + \varepsilon_t.$$

Το ϕ_i είναι οι παράμετροι αυτοπαλινδρόμησης για την στιγμή $t - i$ και ε_t είναι η μη κανονική διακύμανση την στιγμή t , η οποία δεν συσχετίζεται με τις παρελθούσες τιμές της y_t .

Τα μικρά συστήματα εξισώσεων αποτελούν επίσης παραδείγματα τεχνικών οικονομετρικής μοντελοποίησης. Ας υποθέσουμε ότι κάποιος θέλει να προβλέψει την τιμή και την ποσότητα που θα πουληθεί για ένα ευρέως χρησιμοποιούμενο προϊόν. Μία προσέγγιση είναι να θεωρήσει ξεχωριστά την ποσότητα που θα ζητηθεί από την ποσότητα που θα διατεθεί. Ενδέχεται η ποσότητα που θα ζητηθεί να εξαρτάται από δύο πράγματα. Από την παρούσα τιμή και από την ποσότητα που απαιτήθηκε στην προηγούμενη στιγμή. Ομοίως, η ποσότητα που θα διατεθεί μπορεί να εξαρτάται από την παρούσα τιμή και το παρόν κόστος εργασίας. Για να συνδέσει αυτές τις παραμέτρους, ο οικονομολόγος μπορεί να θεωρήσει ότι μία καλή λύση θα ήταν το σημείο όπου η ποσότητα που θα ζητηθεί ισούται με την ποσότητα που θα διατεθεί. Τα παραπάνω εκφράζονται σε ένα σύστημα εξισώσεων ως εξής:

$$\begin{aligned} (\text{παρούσα απαιτούμενη ποσότητα}) &= \\ &= A_1(\text{παρούσα τιμή}) + B_1(\text{ποσότητα που απαιτούνταν}) + C_1 \\ (\text{παρούσα διαθέσιμη ποσότητα}) &= A_2(\text{παρούσα τιμή}) + B_2(\text{κόστος εργασίας}) + C_2 \\ (\text{ποσότητα που απαιτείται}) &= (\text{διαθέσιμη ποσότητα}) \end{aligned}$$

Τα C είναι όροι σφάλματος για την περίπτωση όπου οι εξισώσεις δεν ισχύουν απόλυτα. Δηλαδή τα δεύτερα μέλη των εξισώσεων μπορεί να είναι καλοί εκτιμητές αλλά όχι και ακριβώς ίσες ποσότητες με τα πρώτα μέλη.

Οι μέθοδοι φιλτραρίσματος χρονοσειρών και οι διαδικασίες Box – Jenkins αποτελούν δυναμικές επεκτάσεις της εκθετικής εξομάλυνσης και των μεθόδων διαχωρισμού. Οι τεχνικές αυτές χρησιμοποιούν τις πιο πρόσφατες παρατηρήσεις ως τιμές έναρξης και αναλύουν τα σφάλματα πρόβλεψης προκειμένου να καθορίσουν τις κατάλληλες προσαρμογές για τις μελλοντικές χρονικές περιόδους. Οι μέθοδοι αυτές είναι εξαιρετικά σύνθετες, απαιτούν πολύ χρόνο στον ηλεκτρονικό υπολογιστή και μερικές φορές αποδεικνύονται πολυέξοδες στη χρησιμοποίησή τους. Οι προβλέψεις Box – Jenkins είναι αποδεδειγμένα πολύ ακριβείς για μερικές ομάδες δεδομένων χρονοσειρών. Εν τούτοις, απλούστερες τεχνικές που απαιτούν

λιγότερα δεδομένα, έχουν αποδειχθεί επιτυχείς σε πολλές εφαρμογές των προβλέψεων στην πράξη.

Οι ποιοτικές προβλέψεις περιλαμβάνουν τη χρήση αξιολογικής κρίσης στην ανάλυση και πρόβλεψη μελλοντικών γεγονότων. Η πρόβλεψη του κύκλου απαιτεί γνώσεις που έχουν αποκτηθεί από μεταβολές στις οικονομικές μεταβλητές κατά το παρελθόν. Η προσέγγιση των προπορευόμενων δεικτών απαιτεί χρονοσειρές που μετρούν την οικονομική δραστηριότητα, της οποίας η εξέλιξη σε οποιαδήποτε κατεύθυνση συνήθως προηγείται μιας άλλης χρονοσειράς. Για παράδειγμα η αύξηση των αδειών οικοδομής αποτελεί ένδειξη ότι θα ακολουθήσουν μεταβολές στις πωλήσεις διαρκούς οικιακού εξοπλισμού. Οι πίνακες διάχυσης (diffusion) χρησιμοποιούνται στην κυκλική ανάλυση για να μετρήσουν την εξάπλωση μιας κυκλικής στροφής σε όλη την έκταση της οικονομίας ή τμήματος αυτής. Προπορευόμενοι δείκτες, πίνακες διάχυσης και άλλες ενδείξεις της ποιοτικής κυκλικής ανάλυσης χρησιμοποιούνται κατά την πρόβλεψη ζήτησης προϊόντων ανά τύπο.

Η τεχνική Delphi χρησιμοποιεί την υποκειμενική κρίση των ειδικών για να προβλέψει τις τεχνολογικές μεταβολές, τη ζήτηση και τις μακροπρόθεσμες αλλαγές στην επιχειρηματική δραστηριότητα.

3. 4 Ταξινόμηση προβλέψεων

Αν μία πρόβλεψη προετοιμαστεί τον Δεκέμβριο ενός χρόνου για μία ενέργεια που θα γίνει τον Ιούνιο της επόμενης χρονιάς, ο χρονικός ορίζοντας της πρόβλεψης λέγεται ότι είναι έξι μήνες. Χρονικός ορίζοντας (lead time) της πρόβλεψης ονομάζεται η απόσταση σε χρόνο ανάμεσα στο σημείο στο οποίο γίνεται η πρόβλεψη και το χρονικό σημείο στο οποίο αυτή αναφέρεται. Ο χρόνος αυτός μπορεί να χρησιμοποιηθεί ως βάση στην ταξινόμηση των προβλέψεων.

Έτσι, οι προβλέψεις μπορούν να ταξινομηθούν ως βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες. Για την ταξινόμηση των προβλέψεων, πρέπει να λαμβάνεται υπόψη ο ρυθμός μεταβολής των χρονοσειρών καθώς και ο χρονικός ορίζοντας της πρόβλεψης.

ΜΕΘΟΔΟΙ ΠΡΟΒΛΕΨΗΣ		
ΜΕΘΟΔΟΣ	ΠΕΡΙΓΡΑΦΗ	ΕΦΑΡΜΟΓΕΣ
Κινητός μέσος όρος	Τεχνική προεκβολής που βασίζεται στον μέσο όρο παρατηρήσεων του παρελθόντος	Προβλέψεις μικρού εύρους για δραστηριότητες που χρειάζονται μεγάλο αριθμό μεγεθών πχ έλεγχος αποθεμάτων, τιμολόγηση και χρονική κατανομή παραγωγής
Εκθετική εξομάλυνση	Οι προβλέψεις είναι σταθμισμένοι συνδυασμοί παρατηρηθεισών και προβλεφθεισών τιμών του παρελθόντος. Περισσότερο βάρος δίδεται στα πιο πρόσφατα δεδομένα	Όπως και στην προηγούμενη περίπτωση
Μέθοδοι διαχωρισμού	Η μέθοδος προϋποθέτει την ύπαρξη σχέσης μεταξύ του χρόνου και της μεταβλητής που θα προβλεφθεί. Η χρονοσειρά διαχωρίζεται σε συστηματικές και μη συστηματικές συνιστώσες	Για προβλέψεις μεγάλου εύρους σχετικές με τη δημιουργία νέων εγκαταστάσεων τον προγραμματισμό νέων προϊόντων κλπ. Προβλέψεις μικρού εύρους σχετικά με τη διαφήμιση, τον προγραμματισμό, τα αποθέματα, τα χρηματοοικονομικά δεδομένα και τον προγραμματισμό παραγωγής
Παλινδρομική ανάλυση	Ερμηνευτική πρόβλεψη που υποθέτει την ύπαρξη σχέσης μεταξύ της εξαρτημένης και μιας ή περισσότερων ερμηνευτικών μεταβλητών	Πρόβλεψη μικρού και μεσαίου εύρους για καθιερωμένα προϊόντα και υπηρεσίες. Παραγωγή, marketing, προσωπικό και χρηματοοικονομικές αποφάσεις
Οικονομετρικά μοντέλα	Σύστημα ερμηνευτικών εξισώσεων που περιλαμβάνει εξωγενείς και ενδογενείς μεταβλητές	Βραχυχρόνια και μεσοπρόθεσμη πρόβλεψη για τη ζήτηση προϊόντων, το κόστος, τις τιμές, τις δαπάνες και τα έσοδα
Αναπροσαρμοσμένο φιλτράρισμα	Επέκταση της εκθετικής εξομάλυνσης και χρησιμοποιεί μια επαναληπτική προσέγγιση	Βραχυχρόνια και μεσοπρόθεσμη πρόβλεψη για τα κέρδη, τις τιμές, τα

	για τον προσδιορισμό των καλύτερων συντελεστών στάθμισης	αποθέματα και τον έλεγχο της παραγωγής
Τεχνικές Box - Jenkins	Δεν υποθέτει την ύπαρξη προτύπου στα δεδομένα. Χρησιμοποιείται μια επαναληπτική προσέγγιση για την ανεύρεση του πιο χρήσιμου μοντέλου μεταξύ των μοντέλων μιας γενικότερης τάξης	Οι ίδιες όπως παραπάνω
Οικονομικοί δείκτες	Κυκλικά σημεία στροφής μεταξύ ύψους πωλήσεων και αποθεμάτων μπορούν να προβλεφθούν με την εξέταση της συμπεριφοράς τους κατά τους επιχειρησιακούς κύκλους του παρελθόντος	Πρόβλεψη τέτοιων κυκλικών σημείων πάνω στις πωλήσεις, τη ζήτηση και τη γενικότερη επιχειρηματική δραστηριότητα
Μέθοδοι Delphi	Χρησιμοποιεί την υποκειμενική κρίση των ειδικών για να προβλέψει μελλοντικές εξελίξεις στην οικονομία και τους τομείς της	Χρησιμοποιείται για την πρόβλεψη τεχνολογικών μεταβολών, της ζήτησης και της επιχειρηματικής δραστηριότητας
Αναθεωρημένη πρόβλεψη	Χρησιμοποιεί γραμμική διορθωτική διαδικασία για την αναθεώρηση προβλέψεων και τη βελτίωση της ακρίβειας	Βελτίωση της ακρίβειας της πρόβλεψης μοντέλων προεκβολών και άλλων

3. 5 Νευρωνικά αντί για παραδοσιακές μεθόδους πρόβλεψης

Τα νευρωνικά δίκτυα προσεγγίζουν διαφορετικά το πρόβλημα της πρόβλεψης σε σχέση με τις παραδοσιακές υπολογιστικές μεθόδους. Οι συμβατικές μηχανές χρησιμοποιούν μία αλγοριθμική προσέγγιση. Δηλαδή ακολουθούν συγκεκριμένες οδηγίες για να λύσουν το πρόβλημα. Αυτό περιορίζει τις δυνατότητές τους σε προβλήματα που είδη καταλαβαίνουμε και γνωρίζουμε πώς να λύσουμε. Απλώς κάνουν πολύπλοκους και ταυτόχρονους υπολογισμούς σε μικρό σχετικά χρόνο. Θα θέλαμε όμως οι υπολογιστές να είναι χρήσιμοι και σε περιπτώσεις τις οποίες δεν ξέρουμε πώς ακριβώς να χειριστούμε.

Τα νευρωνικά δίκτυα επεξεργάζονται τις πληροφορίες με παρόμοιο τρόπο με αυτόν του ανθρώπινου μυαλού. Μαθαίνουν με παραδείγματα και από την εμπειρία και δεν μπορούν να προγραμματιστούν για να εκτελούν μία συγκεκριμένη εργασία. Τα παραδείγματα θα πρέπει να επιλεγούν προσεκτικά γιατί αν είναι ακατάλληλα θα χαθεί πολύτιμος χρόνος ή, ακόμα χειρότερα, το δίκτυο θα έχει εκπαιδευτεί και θα λειτουργεί λανθασμένα. Ένα μειονέκτημα είναι το γεγονός ότι η λειτουργία του δικτύου μπορεί να είναι απρόβλεπτη, γιατί βρίσκει μόνο του τον τρόπο για να λύσει το πρόβλημα που του δίδεται.

Οι υπολογιστές από την άλλη, ακολουθούν ορισμένα βήματα για να λύσουν το πρόβλημα. Αυτά τα βήματα προκύπτουν από οδηγίες/ εντολές οι οποίες μοντελοποιούνται και στη συνέχεια μετατρέπονται σε κώδικα μηχανής για να τις καταλάβει ο υπολογιστής. Οι μηχανές λοιπόν είναι άκρως προβλέψιμες. Αν κάτι πάει στραβά, θα είναι λόγω σφάλματος στο λογισμικό ή βλάβης της μηχανής.

Τα νευρωνικά δίκτυα και οι υπολογιστές δεν ανταγωνίζονται μεταξύ τους, αλλά αλληλοσυμπληρώνονται. Υπάρχουν εργασίες περισσότερο κατάλληλες για υπολογιστές όπως οι αριθμητικές πράξεις και άλλες εργασίες κατάλληλες για νευρωνικά δίκτυα. Υπάρχουν όμως και πολλές εργασίες οι οποίες απαιτούν έναν συνδυασμό νευρωνικών δικτύων και ηλεκτρονικών υπολογιστών. Συνήθως ένας υπολογιστής χρησιμοποιείται για να επιβλέπει την λειτουργία του νευρωνικού δικτύου επιτυγχάνοντας ακόμα μεγαλύτερη αποτελεσματικότητα.

Τα έμπειρα συστήματα αποτελούν μία επέκταση των παραδοσιακών υπολογιστικών μηχανών. Είναι γνωστά και σαν υπολογιστές πέμπτης γενιάς. Οι προσπάθειες γενίκευσης των έμπειρων συστημάτων ανέδειξε πολλά προβλήματα. Όσο η πολυπλοκότητα του προβλήματος αυξάνεται, το σύστημα απαιτεί πολλούς υπολογιστικούς πόρους και γίνεται πολύ αργό. Τα έμπειρα συστήματα λειτουργούν ικανοποιητικά μόνο σε περιπτώσεις όπου λειτουργούν σε πολύ στενά όρια με πολλούς περιορισμούς.

Η πρώτη γενιά χρησιμοποιούσε καλώδια και διακόπτες, η δεύτερη οφείλεται στην ανάπτυξη των κρυσταλλολυχνιών- τρανζίστορ. Η τρίτη γενιά χρησιμοποιούσε εξελιγμένα κυκλώματα και γλώσσες ανώτερου επιπέδου όπως COBOL, Fortran και C. Η τέταρτη γενιά είχε να κάνει με τις γεννήτριες κώδικα και η πέμπτη με την τεχνητή νοημοσύνη. Τυπικά, τα έμπειρα συστήματα αποτελούνται από δύο μέρη. Μία βάση γνώσης και μία μηχανή συμπερασμάτων. Η μηχανή αυτή είναι γενική. Χειρίζεται τη διάταξη διασύνδεσης με το χρήστη, τα εξωτερικά αρχεία, την πρόσβαση στο πρόγραμμα και το χρονοδιάγραμμα. Η βάση περιέχει όλες τις πληροφορίες τις σχετικές με το συγκεκριμένο πρόβλημα. Αυτή η γνώση δίνει την δυνατότητα στον ειδικό να καθορίσει τους κανόνες που διέπουν μία διαδικασία. Ο ειδικός αυτός δεν είναι απαραίτητο να καταλαβαίνει ή να γνωρίζει τον παραδοσιακό προγραμματισμό. Θα πρέπει να ξέρει τι ακριβώς

θέλει να κάνει ο υπολογιστής και τον τρόπο με τον οποίο δουλεύει ένας μηχανισμός έμπειρου συστήματος. Ο μηχανισμός είναι μέρος της μηχανής και καθορίζει στον υπολογιστή πώς θα βάλει σε εφαρμογή τις επιθυμίες του χρήστη. Αυτό προκύπτει από το έμπειρο σύστημα καθεαυτό. Προγραμματίζει με λίγα λόγια τον εαυτό του. Ο προγραμματισμός αυτός είναι απαραίτητος για να καθοριστούν οι κανόνες της εφαρμογής. Η διαδικασία καθορισμού κανόνων είναι πολύπλοκη και απαιτεί έναν έμπειρο άνθρωπο που γνωρίζει τις σχετικές με το πρόβλημα λεπτομέρειες.

Στον πίνακα συγκρίνονται τα έμπειρα συστήματα με τα τεχνητά νευρωνικά δίκτυα:

Χαρακτηριστικά	Έμπειρα Συστήματα Αρχιτεκτονικής von Neumann	Τεχνητά Νευρωνικά Δίκτυα
Επεξεργαστές	VLSI (παραδοσιακοί επεξεργαστές)	Ποικιλία τεχνολογιών, αναπτυσσόμενος κλάδος
Μνήμη	Ξεχωριστή	Ξεχωριστή
Προσέγγιση επεξεργασίας	Σειριακή, επεξεργάζεται έναν κανόνα ξεχωριστά	Πολλαπλή, παράλληλη, ταυτόχρονη επεξεργασία
Συνδέσεις	Προγραμματιζόμενα εξωτερικά	Αυτοπρογραμματιζόμενα δυναμικά
Αυτομάθηση	Αλγοριθμική, με μετατροπή παραμέτρων	Συνεχώς προσαρμοζόμενα
Ανοχή σφαλμάτων	Καμία χωρίς ειδικούς επεξεργαστές	Σημαντική από τη φύση των διασυνδεδεμένων νευρώνων
Χρήση νευροβιολογίας στον σχεδιασμό	Καμία	Περιορισμένη
Προγραμματισμός	Βάσει κανόνων, πολύπλοκος	Αυτοπρογραμματιζόμενα, θα πρέπει να είναι σωστό το δίκτυο
Ταχύτητα	Απαιτούνται μεγάλοι επεξεργαστές	Απαιτούνται πολλά ειδικά κατασκευασμένα chips

Τα έμπειρα συστήματα γνώρισαν μεγάλη επιτυχία. Η τεχνητή νοημοσύνη αντιμετωπίζει προβλήματα όσον αφορά την όραση, την αναγνώριση και την σύνθεση συνεχούς λόγου και την μηχανική μάθηση. Είναι όμως και απόλυτα εξαρτημένη από την ταχύτητα του επεξεργαστή που χρησιμοποιεί.

Τα νευρωνικά δίκτυα προσπαθούν να προσφέρουν ένα εργαλείο το οποίο προγραμματίζει τον εαυτό του και μαθαίνει/ εκπαιδεύεται από μόνο του. Είναι δομημένα για να παρέχουν την δυνατότητα να λύνουν προβλήματα χωρίς την παρουσία ή την συνεργασία κάποιου ειδικού αλλά και χωρίς να χρειάζεται να τα προγραμματίζει κάποιος. Μπορούν να αγνοήσουν στοιχεία στα δεδομένα που κανείς δεν γνωρίζει ότι υπάρχουν.

Στον πίνακα που ακολουθεί συγκεντρώνονται οι βασικές διαφορές μεταξύ των δύο προσεγγίσεων:

Χαρακτηριστικά	Συμβατικοί Υπολογιστές και Έμπειρα Συστήματα	Τεχνητά Νευρωνικά Δίκτυα
Στυλ επεξεργασίας	Σειριακή	Παράλληλη
Συναρτήσεις	Λογικές μέσω: Κανόνων Αντίληψης Υπολογισμών	Εμπειρικές μέσω: Εικόνων Προτύπων Ελέγχου
Μέθοδος Μάθησης	Διδακτική (με κανόνες)	Εμπειρική (με παραδείγματα)
Εφαρμογές	Λογιστική, επεξεργασία κειμένου, μαθηματικά, επενδύσεις, ψηφιακές επικοινωνίες	Επεξεργασία αισθητήρων, αναγνώριση φωνής, φωνητικές εντολές, αναγνώριση προτύπων, αναγνώριση κειμένου/ χαρακτήρων

Παρόλα τα πλεονεκτήματα των νευρωνικών δικτύων έναντι των συμβατικών υπολογιστών και των έμπειρων συστημάτων, δεν αποτελούν ολοκληρωμένες λύσεις. Εκπαιδεύονται και ως εκ τούτου δεν παύουν να πέφτουν σε σφάλματα. Δεν είναι συμπαγή όπως ένα πρόγραμμα ηλεκτρονικού υπολογιστή εξουδετερωμένου από σφάλματα. Ακόμα και όταν έχει αναπτυχθεί το δίκτυο, δεν μπορεί να πει κανείς με βεβαιότητα ότι αυτό είναι το βέλτιστο δίκτυο.

Τα νευρωνικά δίκτυα απαιτούν για την λειτουργία τους κάποιες προϋποθέσεις από τους χρήστες. Αυτές περιλαμβάνουν μία διάταξη δεδομένων με τις πληροφορίες που χαρακτηρίζουν το πρόβλημα και που πρέπει να είναι αρκετά ώστε να χρησιμοποιηθεί ένα μέρος για την εκπαίδευση και ένα για την εξέταση της καλής λειτουργίας του δικτύου. Επίσης, θα πρέπει το πρόβλημα να είναι κατανοητό ώστε να αποφασιστεί μία αρχική δομή για το δίκτυο, οι συναρτήσεις και η μέθοδος εκπαίδευσης. Θα πρέπει ο χρήστης να έχει κατανοήσει τον τρόπο λειτουργίας των εργαλείων. Τέλος, θα πρέπει να υπάρχει διαθέσιμη η κατάλληλη υπολογιστική δύναμη για την σύντομη και απρόσκοπτη επεξεργασία των δεδομένων.

Όταν πληρούνται αυτές οι προϋποθέσεις, τα νευρωνικά δίκτυα προσφέρουν την ευκαιρία να επιλυθούν προβλήματα σε τομείς όπου οι παραδοσιακοί επεξεργαστές αδυνατούν λόγω υπολογιστικής δύναμης ή λόγω της μεθοδολογίας βήμα - βήμα που ακολουθούν. Με λίγα λόγια, τα νευρωνικά δίκτυα προσφέρουν έναν μοναδικό τρόπο επίλυσης προβλημάτων ενώ δημιουργούν τις δικές τους ανάγκες. Η μεγαλύτερη ανάγκη τους είναι ότι οι διαδικασίες που

ακολουθούν δεν είναι απλά λογικές. Βασίζονται και στην εμπειρία και την αίσθηση για το πώς θα δημιουργηθεί ένα δίκτυο.

3. 6 Πρόβλεψη χρονοσειρών με νευρωνικά δίκτυα

Η πρόβλεψη είναι ένας από τους πιο πολλά υποσχόμενους τομείς εφαρμογής των τεχνητών νευρωνικών δικτύων. Η μοντελοποίηση κατά την πρόβλεψη έχει σχέση με τη δημιουργία μαθηματικών σχέσεων μεταξύ διαφόρων συνεχών δεδομένων εισόδου και τυπικά μίας ή και περισσότερων μεταβλητών εξόδου. Στην πρόβλεψη, οι μεταβλητές εισόδου αποτελούνται από παραδείγματα των προς πρόβλεψη δεδομένων σε διάφορες στιγμές στο παρελθόν. Οι τεχνολογίες που χρησιμοποιούνται ως επί το πλείστον σε αυτές τις διαδικασίες είναι τεχνικές γραμμικής και πολυωνυμικής παλινδρόμησης, αυτοπαλινδρόμα μοντέλα, κινητός μέσος όρος (ARMA, ARIMA), τεχνικές Box – Jenkins, αναγνώριση προτύπων, προσέγγιση συναρτήσεων και συνδυαστική βελτιστοποίηση. Όπου μπορούν να χρησιμοποιηθούν οι παραπάνω τεχνικές, μπορούν να χρησιμοποιηθούν και τα νευρωνικά δίκτυα.

Ο Smolensky ορίζει το δυναμικό νευρωνικό δίκτυο με οπισθόδρομη διάδοση ως εξής:

$$u_i(t+1) = F\left[\sum_k W_{ki} G(u_k(t))\right]$$

όπου $U_i(t)$ είναι η ενεργοποίηση της μονάδας i στο χρόνο t , η F είναι μία μη γραμμική σιγμοειδής συνάρτηση μεταφοράς, G είναι μία μη γραμμική συνάρτηση κατωφλιού και W_{ki} είναι η το βάρος (συντελεστής σύνδεσης) από τη μονάδα k στη μονάδα i . Αυτή η σχέση μπορεί να χρησιμοποιηθεί για την πρόβλεψη μελλοντικών τιμών μεταβλητών.

Στα προβλήματα πρόβλεψης χρονοσειρών, ο στόχος είναι να εκτιμήσουμε την τιμή μιας μεταβλητής η οποία αλλάζει με τον χρόνο, χρησιμοποιώντας προηγούμενες τιμές της μεταβλητής αυτής ή άλλων σχετικών. Τυπικά, η μεταβλητή είναι συνεχής έτσι που η πρόβλεψη να είναι μία ειδική περίπτωση παλινδρόμησης. Μπορούμε όμως να κάνουμε προβλέψεις και για μη συνεχείς μεταβλητές, όπως στην περίπτωση της ταξινόμησης.

Είναι σύνηθες να προβλέπουμε την τιμή της μεταβλητής χρησιμοποιώντας παρελθούσες τιμές της ίδιας μεταβλητής (αποβλέποντας σε χρονικά άλματα για την τιμή της μεταβλητής). Όταν έχει παραχθεί η επόμενη τιμή, μπορεί να τροφοδοτήσει το δίκτυο έτσι ώστε για τις επόμενες τιμές που θα προβλεφθούν να χρησιμοποιηθεί και αυτή. Με αυτόν τον τρόπο μπορούμε να προβάλλουμε την τιμή της μεταβλητής πολλά βήματα μπροστά στο χρόνο. Προφανώς, η αποτελεσματικότητα της προβολής στο χρόνο εξασθενεί όσο πιο πολλά βήματα μπροστά

προσπαθούμε να προβλέψουμε. Για πολλά βήματα μπροστά, καλό είναι να εκπαιδεύουμε το δίκτυο εκ νέου και με τις νέες τιμές τις προηγούμενες της στιγμής που θέλουμε να προβλέψουμε.

Οποιοδήποτε δίκτυο μπορεί να χρησιμοποιηθεί για την πρόβλεψη χρονοσειρών αρκεί να είναι κατάλληλο για παλινδρόμηση ή ταξινόμηση ανάλογα με τη φύση του προβλήματος. Τις περισσότερες φορές, η μεταβλητή εξόδου είναι αυτή που χρησιμοποιείται και σαν είσοδος στο δίκτυο (με τις κατάλληλες παρελθούσες τιμές). Ο σχηματισμός του δικτύου μπορεί να απαιτεί διαφορετικές κάθε φορά εργασίες όσον αφορά την προ- επεξεργασία των δεδομένων αλλά η εκπαίδευση και η χρήση του δικτύου δεν παρουσιάζει ουσιαστικές διαφορές.

Το πιο δύσκολο στα προβλήματα πρόβλεψης είναι η επιλογή των δεδομένων που θα χρησιμοποιηθούν για εκπαίδευση, για εξέταση αλλά και αυτά που θα εξαιρεθούν. Ξέρουμε ποιες τιμές θα είναι στην είσοδο και ποια έξοδο αναμένουμε να πάρουμε. Το τελευταίο ειδικά είναι πάντα γνωστό, ιδιαίτερα κατά την μάθηση με επίβλεψη. Η επιλογή όμως των εισόδων είναι πολύ πιο δύσκολη. Κι αυτό γιατί δεν ξέρουμε ποια δεδομένα είναι πραγματικά χρήσιμα. Η επιλογή μιας καλής διάταξης δεδομένων είναι πολύπλοκη, λόγω κάποιων παραγόντων όπως η πολυδιάστατη φύση που προσδίδουν στο πρόβλημα οι διαφορετικές διατάξεις δεδομένων, η αλληλεξάρτηση των μεταβλητών και ο περιορισμένος αριθμός μεταβλητών που είναι συνήθως διαθέσιμες.

3. 7 Πρόβλεψη ζήτησης με βάση τη μοντελοποίηση και τον έλεγχο της εφοδιαστικής αλυσίδας

Η ζήτηση είναι πολύ σημαντικό μέγεθος σχετικά με τον προγραμματισμό δρομολογίων. Καθορίζει σε μεγάλο βαθμό την επιλογή της διαδρομής. Η ζήτηση ταυτίζεται με τις παραγγελίες: όταν ένας πελάτης παραγγέλλει μία ορισμένη ποσότητα – έστω X - από ένα συγκεκριμένο προϊόν, η ζήτηση αυτού του πελάτη για το συγκεκριμένο προϊόν είναι X μονάδες προϊόντος. Η ικανοποίηση της ζήτησης είναι απαραίτητη και αυτονόητη προϋπόθεση για την απόφαση σχετικά με τη βέλτιστη διαδρομή. Οι πελάτες θα πρέπει να παραλαμβάνουν την ποσότητα που έχουν παραγγείλει. Υπεισέρονται και περιορισμοί σε ότι αφορά τον χρόνο παράδοσης, την απόσταση που διανύεται, την ποιότητα της εξυπηρέτησης, τη χωρητικότητα των οχημάτων και των αποθηκών κλπ.

Η ζήτηση είναι ένα από τα μεγέθη που εισάγονται σαν δεδομένα σε έναν αλγόριθμο προσδιορισμού βέλτιστης διαδρομής. Η γνώση της τιμής της μεταβλητής αυτής είναι πολύ σημαντική. Ειδικότερα σε περιπτώσεις δυναμικών προβλημάτων η ζήτηση ενδέχεται να μην είναι επακριβώς γνωστή από την αρχή, αλλά να αναπροσαρμόζεται ανάλογα με τα νέα δεδομένα

(ακυρώσεις παραγγελιών, νέοι πελάτες κλπ). Αφού η τιμή της ζήτησης μπορεί να μεταβάλλεται μέσα στο δυναμικό περιβάλλον του πραγματικού χρόνου, θα πρέπει να την προσεγγίσουμε με όσο το δυνατόν μεγαλύτερη ακρίβεια (μικρότερο σφάλμα). Σκοπός μας είναι οι διαδρομές που θα επιλέξουμε να είναι κατά το δυνατόν βέλτιστες, υπό την έννοια ότι δεν θα απαιτούνται δραματικές διορθωτικές ενέργειες ως αποτέλεσμα αναπροσαρμογών στα δεδομένα.

Στην περίπτωση μας τα δεδομένα εισόδου για την μοντελοποίηση και τον έλεγχο προέρχονται από προβλέψεις της ζήτησης, λαμβανομένης υπόψη της αβεβαιότητας των προβλέψεων αυτών. Το δύσκολο κομμάτι, αυτό που αποτελεί την πρόκληση, είναι η εφαρμογή της θεωρίας πρόβλεψης ζήτησης στην εφοδιαστική αλυσίδα. Ένας από τους σημαντικότερους λόγους ανεπιτυχούς μοντελοποίησης, είναι ο μικρός όγκος δεδομένων που μπορούμε να συλλέξουμε από τις επιχειρήσεις. Τις περισσότερες φορές όμως, τα πολύπλοκα προβλήματα δεν απαιτούν πολύπλοκες λύσεις.

Τα συστήματα της επιχειρησιακής έρευνας και της διαχείρισης της εφοδιαστικής αλυσίδας έχουν συνήθως ποσοτικό και ποιοτικό προσανατολισμό. Οι μέθοδοι πρόβλεψης που βασίζονται στο παρελθόν, είναι αναλυτικές και βασίζονται σε στατιστικά στοιχεία για την κατανάλωση. Είναι είτε γραφικές είτε μαθηματικές μέθοδοι. Οι μέθοδοι πρόβλεψης που βασίζονται στο μέλλον, χρησιμοποιούν υπάρχουσες πληροφορίες (του παρόντος) για το μέλλον. Παραδείγματα τέτοιων πληροφοριών είναι οι προσφορές, οι επιβεβαιωμένες παραγγελίες, οι παραγγελίες μέσω συμβολαίου και οι συνεντεύξεις σχετικά με τη συμπεριφορά των καταναλωτών.

Οι δυσκολίες στη μοντελοποίηση είναι στενά συνδεδεμένες με τα δεδομένα. Μπορεί να μην υπάρχουν αρκετά δεδομένα ή μπορεί να μην είναι ικανοποιητικής ποιότητας. Επίσης, η διάκριση μεταξύ συστηματικών και τυχαίων αλλαγών στη διαδικασία της ζήτησης προκαλούν προβλήματα.

Η καθημερινή διαδικασία ζήτησης παρουσιάζει δραματικές συστηματικές μεταβολές από μία περίοδο σε άλλη. Αυτές οι μεταβολές μπορεί να οφείλονται σε παρεμβαλλόμενες περιόδους διακοπών/ αργιών, σε διαφορετικές πολιτικές προώθησης πωλήσεων και άλλες συστηματικές αιτίες. Οι συστηματικές μεταβολές θεωρούνται συχνά ακραίες παρατηρήσεις. Θεωρητικά, οι συστηματικές μεταβολές μοντελοποιούνται εύκολα αλλά απαιτούν πολλή δουλειά. Αν οι προβλέψεις γίνονται σε εβδομαδιαία ή καλύτερα μηνιαία βάση, οι αλλαγές αυτές αναμένεται να είναι λιγότερο έντονες.

Οι φυσικές μεταβολές που συμβαίνουν από μία μέρα σε άλλη μέσα σε έναν μήνα, είναι πολύ πιο δύσκολο να μοντελοποιηθούν (να εκφραστούν με μαθηματικές σχέσεις) σε σύγκριση με τις αθροιστικές διαδικασίες που είναι μηνιαίες.

Είναι πιθανόν τα διαθέσιμα δεδομένα για μοντελοποίηση, να μην περιλαμβάνουν πληροφορίες ή περιπτώσεις όπου τα αποθέματα δεν επαρκούν για την κάλυψη της ζήτησης. Στην μηνιαία προσέγγιση υπάρχει χρόνος για να προσαρμοστούμε στο τρέχον επίπεδο ζήτησης. Έτσι τα μηνιαία δεδομένα αναμένεται να συγκλίνουν με μεγαλύτερη ακρίβεια στην πραγματική ζήτηση απ' ότι τα καθημερινά δεδομένα.

Λόγω των παραπάνω προτιμούμε να δουλεύουμε με μηνιαία δεδομένα ή ακόμα και εβδομαδιαία, αν και αυτή η προσέγγιση μειώνει τον αριθμό των παρατηρήσεων. Αν θέλουμε να βελτιώσουμε την αποτελεσματικότητα στο τέλος κάθε ημέρας, θα πρέπει να λάβουμε υπόψη και καθημερινά δεδομένα. Αυτό γίνεται αναπροσαρμόζοντας τη μηνιαία πρόβλεψη με βάση τις εισερχόμενες πληροφορίες για κάθε ημέρα.

ΚΕΦΑΛΑΙΟ 4^ο

4. 1 Περιγραφή του προβλήματος

Εμείς για την πρόβλεψη της ζήτησης θα αναπτύξουμε ένα νευρωνικό δίκτυο πρόσθιας διάδοσης που εκπαιδεύεται με οπισθόδρομη διάδοση (feedforward backpropagation network). Για να το κάνουμε αυτό, θα χρησιμοποιήσουμε το προγραμματιστικό περιβάλλον της MATLAB. Ειδικότερα, το MATLAB Neural Network Toolbox. Πρόκειται για ένα λογισμικό σχεδιασμένο να λειτουργεί στο περιβάλλον της MATLAB και να αναπτύσσει δίκτυα για την βιομηχανία, την εκπαίδευση και την έρευνα. Στην επόμενη παράγραφο, αναπτύσσουμε τα βασικά πλεονεκτήματα για τα οποία επιλέξαμε αυτήν την προσέγγιση.

4. 1. 1 MATLAB Neural Network Toolbox

Το εργαλείο της MATLAB για τα νευρωνικά δίκτυα είναι μία από τις 15 εφαρμογές λογισμικών οι οποίες έχουν σχεδιαστεί για να τρέχουν μέσα από το περιβάλλον αυτό. Παρέχει στον χρήστη τα μέσα για να αναπτύσσει διάφορα νευρωνικά δίκτυα και να αναλύει γραφικά τόσο την διαδικασία εκπαίδευσης, όσο και τα αποτελέσματα.


Οι συναρτήσεις που περιέχει αυτό το εργαλείο είναι στενά συνδεδεμένες με την MATLAB και δεν μπορούν να λειτουργήσουν εκτός αυτής. Αποτελείται από έναν μεγάλο αριθμό .M αρχείων. Αυτά τα αρχεία είναι ο δεδομένος τρόπος γραφής και τα εκτελέσιμα αρχεία τα οποία είναι γραμμένα σε ASCII.

Το εργαλείο αυτό δεν κατασκευάστηκε για να παρέχει έναν καθορισμένο αριθμό νευρωνικών δικτύων και λειτουργιών τους. Αντιθέτως, λόγω της ραγδαίας ανάπτυξης του τομέα των νευρωνικών δικτύων, παρέχει στον χρήστη όλα τα απαραίτητα εργαλεία για την ανάπτυξη και την εξερεύνηση των λειτουργιών των δικτύων έτσι ώστε να ανακαλύψει ο χρήστης ποιο δίκτυο ή ποιος τρόπος εκπαίδευσης είναι κατάλληλος για κάθε εφαρμογή.

Τα .M αρχεία που συγκροτούν το εργαλείο είναι γενικά τριών κατηγοριών. Καθορισμού της συνάρτησης μεταφοράς για την προσομοίωση του δικτύου, καθορισμού μαθησιακών κανόνων για την ενημέρωση των παραμέτρων του δικτύου και καθορισμού της συνάρτησης εκπαίδευσης για την εκπαίδευση του δικτύου σύμφωνα με τα δεδομένα.

Η συνάρτηση μεταφοράς για έναν νευρώνα παρέχει τον τρόπο σύμφωνα με τον οποίο οι είσοδοι του συγκεκριμένου νευρώνα μετατρέπονται στην επιθυμητή έξοδο. Η πιο συχνά

χρησιμοποιούμενη συνάρτηση μεταφοράς είναι η λογαριθμική σιγμοειδής η οποία χρησιμοποιείται για να διαβαθμίσει ένα εύρος από $-\infty$ έως $+\infty$ σε 0 έως 1. Επειδή δε είναι διαφορίσιμη, χρησιμοποιείται κυρίως σε δίκτυα οπισθόδρομης διάδοσης. Αν και υπάρχει μεγάλη ποικιλία συναρτήσεων για να χρησιμοποιήσει ο χρήστης, μπορεί να κατασκευάσει μόνος του μία που θα ανταποκρίνεται πλήρως στο συγκεκριμένο πρόβλημα που θέλει να επιλύσει.



Οι μαθησιακοί κανόνες είναι σχεδιασμένοι για να αλλάζουν τα βάρη και τις παραμορφώσεις του σήματος στον νευρώνα. Ο χρήστης μπορεί και εδώ να κατασκευάσει τον δικό του κανόνα ή να συνδυάσει κανόνες για να επιτύχει το επιθυμητό αποτέλεσμα. Το εργαλείο παρέχει επίσης και κάποιες επεκτάσεις του αλγορίθμου οπισθόδρομης διάδοσης όπως η χρήση της ορμής, μία μέθοδος η οποία βελτιώνει τα αρχικά βάρη και η χρήση ενός προσαρμοσμένου ρυθμού μάθησης.

Οι συναρτήσεις εκπαίδευσης, όπως είναι φυσικό, είναι διαφορετικές από το ένα στάδιο της εκπαίδευσης στο άλλο. Όλες όμως απαιτούν παρόμοιες πληροφορίες για την εκπαίδευση. Χρειάζονται ένα αρχικό βάρος ή μάλλον καλύτερα έναν πίνακα βαρών, ένα διάνυσμα αρχικών παραμορφώσεων, έναν πίνακα από διανύσματα εισόδων, τα αντίστοιχα διανύσματα εξόδων, τον ρυθμό μάθησης και άλλα στοιχεία για την διαδικασία της εκπαίδευσης. Η συνάρτηση εκπαίδευσης επιστρέφει νέα βάρη και παραμορφώσεις όταν τελειώσει η εκπαίδευση. Αυτό συμβαίνει όταν η τιμή του σφάλματος έχει πέσει κάτω από ένα καθορισμένο όριο ή όταν έχει συμπληρωθεί ο αριθμός των χρονικών περιόδων στις οποίες το δίκτυο εκπαιδεύεται.

4. 1. 2 Εκπαίδευση του δικτύου

Το δίκτυο περνάει από τρεις φάσεις κατά την εκπαίδευσή του. Την φάση της παρουσίασης των δεδομένων, την φάση της εκπαίδευσης/ μάθησης και την φάση του ελέγχου. Κατά την φάση της παρουσίασης εμφανίζονται τα διανύσματα των εισόδων και υπολογίζονται οι έξοδοι. Κατά τον έλεγχο, συγκρίνονται οι έξοδοι που παρήγαγε το δίκτυο με τις επιθυμητές. Αν όλα τα διανύσματα εισόδου γεννούν τις σωστές εξόδους, η εκπαίδευση σταματά. Αν δεν συμβαίνει αυτό,

η εκπαίδευση συνεχίζεται με την φάση της μάθησης κατά την οποία τα βάρη και οι παραμορφώσεις προσαρμόζονται και ξεκινά εκ νέου η παρουσίαση. Σε πολλές εφαρμογές παρουσιάζονται αρχικά πολλά διανύσματα εισόδων ταυτόχρονα και λαμβάνονται οι αποκρίσεις του δικτύου για κάθε είσοδο ξεχωριστά.

Ένας από τους λόγους για τους οποίους επιλέξαμε να δουλέψουμε με την MATLAB, είναι και η δυνατότητα που προσφέρει για γραφικές αναπαραστάσεις. Μπορούμε να κάνουμε δισδιάστατα και τρισδιάστατα γραφικά. Μπορούμε επίσης να δούμε γραφικά την εξέλιξη της τιμής μιας μεταβλητής. Αυτό είναι ιδιαίτερα χρήσιμο για να βλέπουμε πληροφορίες για το δίκτυο κατά την εκπαίδευσή του. Μπορούμε να παρακολουθούμε έτσι την εκπαίδευση του δικτύου και να αποδώσουμε γραφικά τα αποτελέσματα από τα οποία δεν θα μπορούσαμε να εξάγουμε εύκολα συμπεράσματα αν ήταν σε αριθμητική μορφή.

4. 2 Το πρόβλημα

Το πρόβλημα που θέλουμε να αντιμετωπίσουμε είναι ο προσδιορισμός της ζήτησης για μία επιχείρηση παραγωγής και εμπορίας βιομηχανικών χρωμάτων και συναφών ειδών (υποστρώματα, σιδηρόστοκοι κλπ). Πριν προχωρήσουμε στην ανάλυση όλων των παραμέτρων, ας δούμε κάποια στοιχεία για την επιχείρηση αυτή.

4. 2. 1 Η επιχείρηση

Η εταιρεία HB BODY S.A ιδρύθηκε το 1981 με την επωνυμία ΗΛΙΑΣ ΒΑΣΙΛΕΙΑΔΗΣ ABEE, και έχει ως έδρα την βιομηχανική περιοχή Σίνδου – Θεσσαλονίκης. Η μετονομασία της σε HB BODY S.A έγινε το έτος 2003.

Αντικείμενο της εταιρείας είναι η παραγωγή επιχρισμάτων (παντός είδους αστάρια, χρώματα βιομηχανικά – αυτ/ του, χρώματα οικοδομικά, στόκοι, σιδηρόστοκοι κ.ά.).

Στις υπερσύγχρονες εγκαταστάσεις της στεγάζει η εταιρεία παραγωγές, αποθήκες Ά Υλών, αποθήκες ετοιμών προϊόντων, εργαστήρια έρευνας και ανάπτυξης και διοικητικές υπηρεσίες.

Η εταιρεία HB BODY S.A είναι κατ' εξοχήν εξαγωγική εταιρεία, εξάγοντας τα προϊόντα της σε περισσότερες από 58 χώρες παγκοσμίως.

Η πολύχρονη εμπειρία, η υψηλή τεχνογνωσία, ο πρωτοποριακός χαρακτήρας και η υψηλή ποιότητα των προϊόντων της HB BODY S.A την έχουν καταστήσει μία από τις σημαντικότερες

και ταχύτερα αναπτυσσόμενες εταιρείες του κλάδου. Ας δούμε όμως κάποια γενικά στοιχεία σχετικά με τους αποθηκευτικούς χώρους και τις λειτουργίες τους.

4. 2. 2 Οι αποθήκες

Η εταιρεία HB BODY S.A διαθέτει μια κεντρική αποθήκη ετοιμών προϊόντων στο εργοστάσιο ΣΙΝΔΟΣ Γ΄, μία στην έδρα της εταιρείας στο Καλοχώρι, και μία στο Υποκατάστημα Νοτίου Ελλάδος, ανεξάρτητες μεταξύ τους. Στις τρεις αποθήκες φυλάσσονται τα έτοιμα προϊόντα και εμπορεύματα της εταιρείας, απ' όπου γίνεται και η διακίνησή τους. Αρχή της εταιρείας είναι η διατήρηση αποθεμάτων σε όλα τα προϊόντα και εμπορεύματα για τις ανάγκες της εγχώριας και μερικώς των ξένων αγορών ώστε να καλύπτονται τα αποθέματα ασφαλείας. Σαν απόθεμα ασφαλείας ορίζεται το απόθεμα που ικανοποιεί τις ανάγκες, κατά μέσο όρο, των πωλήσεων για ένα (1) μήνα. Στα προϊόντα σιδηρόστοκου σαν απόθεμα ασφαλείας ορίζεται το απόθεμα που ικανοποιεί τις ανάγκες, κατά μέσο όρο, πωλήσεων για δεκαπέντε (15) μέρες.

Οι αποθήκες Καλοχωρίου και Αθηνών διαθέτουν μεταλλικά ράφια όπου τοποθετούνται προϊόντα και εμπορεύματα σε παλέτες, ενώ στην κεντρική αποθήκη του ΣΙΝΔΟΣ Γ΄ τοποθετούνται σε παλέτες και σε συγκεκριμένους χώρους στο έδαφος.

Αποθήκη Καλοχωρίου:

Ράμπες φορτοεκφόρτωσης:

Είναι πέντε συγκεκριμένα και ειδικά διαμορφωμένα σημεία (με ειδική διαγράμμιση και τη δυνατότητα μετακίνησης παλετοφόρου), όπου τα φορτηγά σταθμεύουν για φορτωθούν ή να ξεφορτωθούν τα προϊόντα.

Η αποθήκη Νοτίου Ελλάδος έχει τους παρακάτω συγκεκριμένους χώρους:

Χώρος έτοιμων παραγγελιών: Εκεί τοποθετούνται οι παραγγελίες που εκτελούνται από το προσωπικό της αποθήκης

Ράμπες φορτοεκφόρτωσης: Είναι δύο συγκεκριμένα και ειδικά διαμορφωμένα σημεία (με ειδική διαγράμμιση και τη δυνατότητα μετακίνησης παλετοφόρου), όπου τα φορτηγά σταθμεύουν για να φορτωθούν ή να ξεφορτωθούν τα προϊόντα.

Χώρος μη διαθέσιμων προϊόντων: Επισημασμένος χώρος όπου φυλάσσονται τα προϊόντα που έχουν υποστεί κάποια φθορά ή θεωρούνται εκτός προδιαγραφών (μη συμμορφούμενα).

Μεταλλικά ράφια αποθήκευσης: Τα ράφια είναι διατεταγμένα σε δώδεκα (12) σειρές, κι έχουν τέτοιο ύψος ώστε να σχηματίζουν τρία (3) επίπεδα. Οι σειρές αριθμούνται από το 1 έως το

12 και τα επίπεδα με τα γράμματα Α Β Γ, όπου Α το επίπεδο του δαπέδου. Το σύνολο των θέσεων αποθήκευσης ή παλετών είναι 1524.

Κεντρική αποθήκη: Η κεντρική αποθήκη ετοιμών προϊόντων διαθέτει τους παρακάτω χώρους:

ΔΙΑΜΕΡΙΣΜΑ Β:

Χώρος προετοιμασίας ετοιμών παραγγελιών: Στο χώρο αυτό συγκεντρώνονται οι παραγγελίες των πελατών και οι παλέτες προϊόντων που πρόκειται να μεταφερθούν στις αποθήκες Καλοχωρίου και Αθηνών για τη εξυπηρέτηση των αναγκών.

Ράμπες φορτοεκφόρτωσης: Πρόκειται για ουσιαστικά ένα σημείο με τρεις ράμπες (ειδική διαγράμμιση), όπου τα φορτηγά σταθμεύουν για να φορτωθούν και να ξεφορτωθούν προϊόντα.

Χώρος μη διαθεσίμων προϊόντων: Επισημασμένος χώρος, όπου φυλάσσονται όλα τα προϊόντα που θεωρούνται εκτός προδιαγραφών (μη συμμορφούμενα).

Χώρος δοκιμαστικών παραγωγών: Επισημασμένος χώρος, όπου φυλάσσονται τα προϊόντα των οποίων ο σχεδιασμός δεν έχει ολοκληρωθεί. Όποια προϊόντα βρίσκονται στο χώρο αυτό σε καμία περίπτωση δεν πρόκειται να χρησιμοποιηθούν για την κάλυψη παραγγελιών.

ΔΙΑΜΕΡΙΣΜΑΤΑ Α Γ Δ Ε Ζ Η Θ Λ:

Χώροι αποθήκευσης ετοιμών προϊόντων: Στα παραπάνω διαμερίσματα αποθηκεύονται τα έτοιμα προϊόντα σε παλέτες. Τα διαμερίσματα αυτά ξεχωρίζουν στο χώρο με τη βοήθεια πράσινης διαγράμμισης στο δάπεδο. Η δυνατότητα αποθήκευσης παλετών σε κάθε σειρά ποικίλει από μία (1) έως δεκατρείς (13). Η σήμανση της κάθε αποθηκευτικής σειράς φέρει το γράμμα του αντίστοιχου διαμερίσματος και τον αύξοντα αριθμό της σειράς.

4. 2. 3 Λειτουργία της αποθήκης

Ο υπεύθυνος του τμήματος δίνει στο τέλος κάθε μήνα την εντολή απογραφής των αποθεμάτων των ετοιμών προϊόντων και εμπορευμάτων που βρίσκονται στις αποθήκες. Καθημερινά τα έτοιμα προϊόντα μεταφέρονται από τους χώρους παραγωγής στις αποθήκες και αφού ελεγχθεί το είδος η ποσότητα και η ποιότητα συσκευασίας, τοποθετούνται στις προκαθορισμένες θέσεις πάντα σύμφωνα με τις ημερομηνίες παραγωγής έτσι ώστε να διατίθενται πρώτα στην αγορά οι ποσότητες του είδους που προϋπήρχαν στην αποθήκη (μέθοδος FIFO). Η μεταφορά των προϊόντων για εφοδιασμό της αποθήκης Καλοχωρίου γίνεται με φορτηγά της εταιρείας ενώ της Αθήνας με φορτηγά ΔΧ. Τα προϊόντα τοποθετούνται στις προκαθορισμένες

θέσεις πάντα σύμφωνα με τις ημερομηνίες παραγωγής έτσι ώστε να διατίθενται πρώτα στην αγορά οι ποσότητες του είδους που προϋπήρχαν στην αποθήκη (μέθοδος FIFO).

Αν τα έτοιμα προϊόντα έχουν υποστεί κάποια φθορά κατά τη μεταφορά τους, ώστε να μην πληρούν τις προδιαγραφές, θεωρούνται μη συμμορφούμενα. Τα προϊόντα αυτά αφού καταμετρηθούν μεταφέρονται στους ειδικούς χώρους μη διαθεσίμων προϊόντων. Το υποκατάστημα Αθηνών επιστρέφει αμέσως τα μη συμμορφούμενα προϊόντα.

Τα φορτηγά που πρόκειται να φορτωθούν είτε είναι ιδιοκτησίας της εταιρείας είτε είναι ξένα, σταθμεύουν σε μία από τις ράμπες φόρτωσης. Τα προϊόντα που πρόκειται να φορτωθούν είναι τοποθετημένα σε παλέτες και τυλιγμένα με διάφανη ελαστική μεμβράνη (stretch film). Οι παλέτες μεταφέρονται στην καρότσα του φορτηγού είτε με παλετοφόρα είτε με κλαρκ. Οι παλέτες τοποθετούνται σε μία σειρά καθ' ύψος στο πάτωμα του φορτηγού και στοιχίζονται ανάλογα με τις διαστάσεις της καρότσας.

Όπως έχουμε δει από τον τρόπο οργάνωσης και λειτουργίας της αποθήκης, είναι απαραίτητος ο μηνιαίος προγραμματισμός για την τήρηση των αποθεμάτων και την ανάλογη οργάνωση της παραγωγής. Τα στοιχεία που έχουμε συλλέξει από το λογιστήριο της επιχείρησης, αφορούν τους 25 πελάτες Θεσσαλονίκης που εμφάνισαν τον μεγαλύτερο τζίρο τα τελευταία 5 χρόνια.

4.3 Συγκέντρωση – Επεξεργασία των δεδομένων

Έχουμε συλλέξει τα παραστατικά πωλήσεων για κάθε πελάτη και για κάθε μέρα του έτους για τα 2 τελευταία χρόνια (Ιανουάριος 2002- Δεκέμβριος 2003). Στα παραστατικά αυτά φαίνονται η επωνυμία του πελάτη, η ημερομηνία της πώλησης, ο κωδικός του είδους, η περιγραφή του προϊόντος, η ποσότητα της παραγγελίας, η αξία και κάποια άλλα οικονομικά στοιχεία. Τα παραστατικά πωλήσεων αναφέρονται σε όλα τα προϊόντα που έχει αγοράσει κάθε πελάτης και είναι συγκεντρωμένες σε αυτά οι πωλήσεις κάθε ημέρας του χρόνου. Ένα παράδειγμα τέτοιου παραστατικού φαίνεται στο ΠΑΡΑΡΤΗΜΑ Α. Παρακάτω παραθέτουμε τον πίνακα των πωλήσεων για το έτος 2002 και για 8 από τους 25 μεγαλύτερους πελάτες της Θεσσαλονίκης (αυτούς με την μεγαλύτερη κατανάλωση). Στον πίνακα εμφανίζεται μόνο ο πρώτος μήνας και οι οκτώ πρώτοι (αλφαβητικά) πελάτες.

Στις τιμές του πίνακα που ακολουθεί έχει γίνει μία ομαδοποίηση αλλά και κάποιες εξαιρέσεις προϊόντων. Η επιχείρηση εμπορεύεται συνολικά 1165 κωδικούς προϊόντων. Σε αυτά συγκαταλέγονται και κάποια προϊόντα όπως σπάτουλες, αναδευτήρες, χάρακες και άλλα τα οποία δεν συμμετέχουν στην μελέτη μας. Τούτο διότι αυτά τα προϊόντα δεν κατασκευάζονται από την

εταιρία, οπότε δεν επιφέρουν καμία αλλαγή στον προγραμματισμό της παραγωγής. Επίσης, είναι είδη τα οποία μπορούν να φυλάσσονται σε αποθήκες για μεγάλο χρονικό διάστημα χωρίς κάποια μεταβολή των χαρακτηριστικών τους που θα τα καθιστούσε μη ποιοτικά.

Αντιθέτως, όλα τα χρώματα, τα σπρέι και τα υποστρώματα θα μπορούσαν να χαρακτηριστούν ως ευπαθή. Αυτό οφείλεται στο ότι πρόκειται για χημικά προϊόντα. Είναι γνωστό ότι ο χρόνος, η θερμοκρασία, η πίεση αποτελούν καταλύτες χημικών αντιδράσεων. Επομένως, η όχι καλή συντήρηση των προϊόντων και η μακροχρόνια παραμονή τους σε αχρηστία (στις αποθήκες), επιφέρουν μεταβολές των ιδιοτήτων τους και των ιδιαίτερων ποιοτικών χαρακτηριστικών τους που τα καθιστούν ανταγωνιστικά. Έτσι ο σωστός προγραμματισμός είναι πολύ σημαντικός για τα προϊόντα αυτά, καθώς η διοίκηση δεν είναι διατεθειμένη να κάνει εκπτώσεις στην ποιότητα των προϊόντων της επιχείρησης.

ΗΜΕΡ/Α	ΜΕΡΑ	ΠΕΛΑΤΗΣ							
2002		ΠΕΛ1	ΠΕΛ2	ΠΕΛ3	ΠΕΛ4	ΠΕΛ5	ΠΕΛ6	ΠΕΛ7	ΠΕΛ8
1/1/2002	2	0	0	0	0	0	0	0	0
2/1/2002	3	0	0	0	0	0	0	0	0
3/1/2002	4	0	0	0	0	0	0	0	0
4/1/2002	5	0	0	0	58	36	0	0	0
5/1/2002	6	0	0	0	0	0	0	0	0
6/1/2002	7	0	0	0	0	0	0	0	0
7/1/2002	1	0	0	0	4	24	0	0	0
8/1/2002	2	202	21	0	0	75	0	0	0
9/1/2002	3	0	0	0	0	0	0	0	0
10/1/2002	4	0	0	0	0	0	0	0	0
11/1/2002	5	0	0	0	0	0	36	0	0
12/1/2002	6	0	0	0	0	0	0	0	0
13/1/2002	7	0	0	0	0	0	0	0	0
14/1/2002	1	0	0	0	0	2	0	0	0
15/1/2002	2	0	0	0	0	0	0	0	0
16/1/2002	3	42	0	4	129	27	0	0	0
17/1/2002	4	0	0	0	0	0	4	0	0
18/1/2002	5	1	0	0	0	57	0	0	0
19/1/2002	6	0	0	0	0	0	0	0	0
20/1/2002	7	0	0	0	0	0	0	0	0
21/1/2002	1	0	0	0	0	0	0	0	0
22/1/2002	2	0	0	0	0	0	0	0	21
23/1/2002	3	0	0	0	0	0	0	0	0
24/1/2002	4	31	0	0	59	17	0	0	3
25/1/2002	5	0	0	0	0	0	0	0	0
26/1/2002	6	0	0	0	0	0	0	0	0
27/1/2002	7	0	0	0	0	0	0	0	0
28/1/2002	1	17	0	0	8	0	0	0	0
29/1/2002	2	3	0	3	6	0	0	0	0

30/1/2002	3	0	0	195	0	8	0	0	0
31/1/2002	4	0	0	0	42	0	34	0	0
SUM		296	21	202	306	246	74	0	24

Όπως είναι φυσικό, δεν έχουμε κάθε μέρα πωλήσεις. Για τον λόγο αυτό έχουμε ομαδοποιήσει τις πωλήσεις σε μηνιαίες ποσότητες. Δηλαδή τα στοιχεία που χρησιμοποιούμε, είναι η μηνιαία ζήτηση κάθε προϊόντος για κάθε πελάτη της επιχείρησης. Όπως έχουμε ήδη πει, μελετήσαμε την συμπεριφορά των μόνο των 25 μεγαλύτερων πελατών από τη Θεσσαλονίκη.

Μία άλλη ομαδοποίηση που κάνουμε, είναι η εξής. Η εταιρία εμπορεύεται όπως είπαμε έναν μεγάλο αριθμό κωδικών. Στα παραστατικά πωλήσεων αναγράφεται κάθε κωδικός ξεχωριστά. Επειδή όμως αυτό που κυρίως μας ενδιαφέρει στην εργασία αυτή είναι η πρόβλεψη της ζήτησης για την βελτιστοποίηση της αποθήκευσης και της μεταφοράς των προϊόντων στους πελάτες και όχι τόσο ο προγραμματισμός της παραγωγής, έχουμε ομαδοποιήσει τους κωδικούς αυτούς.

Πιο αναλυτικά, στα παραστατικά πωλήσεων φαίνεται ο αριθμός των τεμαχίων που αγόρασε κάθε πελάτης από κάθε κωδικό προϊόντος. Κάθε τεμάχιο έχει διαφορετικές διαστάσεις. Τα τεμάχια τοποθετούνται σε κιβώτια τα οποία εναποθέτονται εν συνεχεία στις παλέτες. Έχουμε μετατρέψει λοιπόν τον αριθμό των τεμαχίων σε αριθμό κιβωτίων που έχει αγοράσει κάθε πελάτης. Για την μετατροπή αυτή χρησιμοποιήσαμε πίνακα, μέρος του οποίου υπάρχει στο ΠΑΡΑΡΤΗΜΑ Β τον οποίο μας έδωσε ο υπεύθυνος της αποθήκης. Στον πίνακα αυτό περιέχονται στοιχεία σχετικά με τις διαστάσεις και τους τύπους των χαρτοκιβωτίων, τον αριθμό των τεμαχίων που τοποθετούνται σε κάθε παλέτα, τον τύπο της παλέτας που χρησιμοποιείται, τον αριθμό των κιβωτίων σε κάθε σειρά της παλέτας, το βάρος των κιβωτίων, τα κιβώτια ανά παλέτα, το βάρος και το ύψος κάθε παλέτας. Τα στοιχεία αυτά είναι πολύ σημαντικά για τον προγραμματισμό τόσο της αποθήκης όσο και των δρομολογίων των φορτηγών της εταιρίας.

Στους πίνακες που ακολουθούν, φαίνεται η ζήτηση για κάθε πελάτη και για κάθε μήνα των ετών 2002 και 2003. Οι ποσότητες εκφράζονται σε αριθμό κιβωτίων.

ΜΗΝΑΣ	ΠΕΛΑΤΗΣ									
	ΠΕΛ1	ΠΕΛ2	ΠΕΛ3	ΠΕΛ4	ΠΕΛ5	ΠΕΛ6	ΠΕΛ7	ΠΕΛ8	ΠΕΛ9	ΠΕΛ10
1	296	21	202	306	246	74	0	24	33	67
2	155	52	370	153	119	34	74	60	97	112

3	307	47	283	85	186	42	12	67	1	64
4	371	0	92	200	131	53	42	53	88	88
5	184	27	173	141	51	43	11	36	131	80
6	292	0	421	184	200	41	11	54	41	72
7	336	47	217	201	162	60	21	44	99	59
8	142	22	307	158	27	9	5	28	26	71
9	462	66	201	197	155	65	22	46	47	91
10	303	43	158	180	126	25	25	49	21	50
11	392	18	75	209	83	61	22	51	159	71
12	157	0	153	458	95	0	6	29	0	46
13	409	23	158	87	98	54	36	69	166	91
14	363	89	339	98	118	70	27	22	0	24
15	182	0	104	111	113	24	25	58	67	52
16	316	26	218	125	100	105	0	32	5	76
17	220	23	227	264	102	46	32	39	135	42
18	442	54	176	144	83	22	42	33	11	84
19	375	33	137	361	114	33	37	50	42	68
20	286	75	253	32	70	370	84	15	35	67
21	312	95	80	30	100	70	60	60	70	85
22	280	47	42	78	40	270	45	60	69	44
23	310	77	50	93	50	290	80	36	68	75
24	215	90	190	80	290	215	90	90	80	0

ΜΗΝΑΣ	ΠΕΛΑΤΗΣ								
	ΠΕΛ11	ΠΕΛ12	ΕΛ13	ΠΕΛ14	ΠΕΛ15	ΠΕΛ16	ΠΕΛ17	ΠΕΛ18	ΠΕΛ19
1	80	7	39	0	31	14	0	14	7
2	103	54	55	50	218	32	25	19	43
3	133	43	25	36	18	5	16	57	112
4	237	75	30	27	80	41	10	51	7
5	144	5	50	24	38	17	0	29	78
6	231	45	38	27	54	18	19	18	28
7	259	54	18	49	57	26	0	31	123
8	147	67	36	24	82	35	0	55	31
9	166	22	40	31	44	19	18	47	56
10	217	57	32	20	100	26	33	57	32
11	186	53	10	38	67	9	26	30	21
12	305	0	35	1	70	0	2	13	16
13	55	33	33	18	61	0	27	40	57
14	139	34	6	17	0	0	0	52	0
15	103	78	27	0	45	26	16	46	20
16	67	65	33	56	34	6	10	45	12
17	286	48	28	44	74	0	15	64	103

18	157	81	36	44	81	37	0	23	35
19	166	15	31	48	47	18	0	28	0
20	188	90	30	30	78	42	26	13	33
21	167	63	80	27	95	31	9	65	28
22	169	50	34	75	36	13	0	69	60
23	91	100	30	90	87	27	26	3	100
24	198	51	50	63	0	24	0	89	75

ΜΗΝΑΣ	ΠΕΛΑΤΗΣ					
	ΠΕΛ20	ΠΕΛ21	ΠΕΛ22	ΠΕΛ23	ΠΕΛ24	ΠΕΛ25
1	65	5	28	12	0	185
2	56	56	35	0	0	192
3	16	0	26	22	0	204
4	41	49	37	24	0	321
5	51	43	30	13	0	238
6	47	42	25	15	0	291
7	42	44	36	12	0	349
8	58	0	34	0	61	232
9	63	70	48	0	26	299
10	49	77	21	20	67	297
11	45	0	118	0	37	184
12	0	79	5	18	64	233
13	32	24	22	0	32	171
14	68	0	31	13	60	197
15	32	29	24	0	50	215
16	51	0	38	31	32	214
17	91	49	57	4	93	239
18	63	0	26	40	51	283
19	56	0	41	0	56	233
20	81	100	100	0	40	282
21	100	2	57	49	30	320
22	38	0	61	40	60	130
23	52	64	118	40	80	325
24	0	0	80	0	86	0

4. 4 Εισαγωγή – Προετοιμασία Δεδομένων στη MATLAB

Για την εφαρμογή των νευρωνικών δικτύων στο πρόβλημά μας θα χρησιμοποιήσουμε την MATLAB 6.5 Release 13. Όπως έχουμε πει, η MATLAB έχει πολλές ενσωματωμένες δυνατότητες για την δημιουργία και την εκπαίδευση νευρωνικών δικτύων. Θα χρησιμοποιήσουμε αρκετές από τις προσφερόμενες συναρτήσεις και πιο συγκεκριμένα, αυτές που αφορούν τα feed forward δίκτυα (δίκτυα εμπρόσθιας διάδοσης).

Πριν ξεκινήσουμε την εφαρμογή, πρέπει να αποφασίσουμε πώς θα χρησιμοποιήσουμε τα δεδομένα που έχουμε. Θα πρέπει να χρησιμοποιήσουμε ένα μέρος από αυτά για την εκπαίδευση του δικτύου και τα υπόλοιπα για να ελέγξουμε την σωστή λειτουργία του. Συνηθίζεται να χρησιμοποιούμε το 70% των δεδομένων για εκπαίδευση και το 30% για έλεγχο. Διατηρώντας αυτήν την αναλογία, θα χρησιμοποιήσουμε τα δεδομένα των μηνών 1 – 18 για την εκπαίδευση του δικτύου και τα δεδομένα των μηνών 19 – 24 για τον έλεγχο της ορθής λειτουργίας του.

Για την εύκολη επεξεργασία των δεδομένων πριν την εισαγωγή τους στο δίκτυο, έχουμε φτιάξει ένα πρόγραμμα στην MATLAB. Ο κώδικας του προγράμματος φαίνεται παρακάτω. Σημειώνουμε εδώ ότι ολόκληρος ο κώδικας του προγράμματος που έχουμε κατασκευάσει και χρησιμοποιούμε στην εφαρμογή, παρατίθεται στο ΠΑΡΑΡΤΗΜΑ Γ. Στην παρούσα αναφορά, παραθέτουμε και σχολιάζουμε τον κώδικα τμηματικά.


4. 5 Σχολιασμός του κώδικα/ διαδικασίας προγράμματος

Μέρος 1^ο: Εισαγωγή και επεξεργασία των δεδομένων

```
A = xlsread('data.xls');
B=max(A);
[m,n]=size(A);
for i=1:m
    for j=1:n
        N(i,j)=A(i,j)/B(j);
    end
end
```

Αρχικά φορτώνουμε τα δεδομένα και τα καταχωρούμε σε μεταβλητές – πίνακες με τρόπο που να μας βολεύει για την εφαρμογή. Ο A είναι ένας 24x25 πίνακας που περιέχει όλα τα δεδομένα. Δηλαδή ο A αποτελείται από την ζήτηση για κάθε μήνα και κάθε πελάτη για τα έτη 2002, 2003. Με άλλα λόγια ο A περιέχει τις τιμές των μεταβλητών του προβλήματος.

Τα στοιχεία του A δεν είναι στην μορφή που θέλουμε για την εφαρμογή του προβλήματος. Οι τιμές της μεταβλητής πρέπει να κυμαίνονται μεταξύ του 0 και του 1. Αυτό συμβαίνει γιατί χρησιμοποιούμε λογαριθμική σιγμοειδή συνάρτηση μεταφοράς:




Για να επιτύχουμε αυτήν την κανονικοποίηση, διατρέχουμε κάθε στήλη του πίνακα A, εντοπίζουμε το μεγαλύτερο στοιχείο (τα μεγαλύτερα στοιχεία κάθε στήλης αποθηκεύονται στο 25x1 διάνυσμα B) και κατόπιν διαιρούμε με αυτό όλες τις τιμές της αντίστοιχης στήλης. Το αποτέλεσμα το αποθηκεύουμε σε έναν άλλο 24x25 πίνακα, τον N. Όλες οι πράξεις από αυτό το σημείο και μετά, γίνονται με τον πίνακα N. Μέρος του πίνακα αυτού έτσι όπως τον υπολογίζει η MATLAB, φαίνεται παρακάτω:

Array Editor: N							
File Edit View Web Window Help							
Numeric format: shortG		Size: 24		by 25			
	1	2	3	4	5	6	7
1	0.65778	0.23596	0.47981	0.66812	1	0.62712	
2	0.57333	0.58427	0.87886	0.33406	0.48374	0.28814	
3	0.77778	0.52809	0.67221	0.18559	0.7561	0.35593	0.16
4	0.85333	0	0.21853	0.43668	0.53252	0.44915	0.56
5	0.48	0.30337	0.41093	0.30786	0.20732	0.36441	0.14
6	0.97333	0	1	0.40175	0.81301	0.34746	0.14
7	0.54667	0.52809	0.51544	0.43886	0.65854	0.50847	0.28
8	1	0.24719	0.72922	0.34498	0.10976	0.076271	0.067
9	0.56	0.74157	0.47743	0.43013	0.63008	0.55085	0.2
10	0.67333	0.48315	0.3753	0.39301	0.5122	0.21186	0.33
11	0.80222	0.20225	0.17815	0.45633	0.3374	0.51695	0.2
12	0.42667	0	0.36342	1	0.38618	0	0.081
13	0.90889	0.25843	0.3753	0.18996	0.39837	0.45763	0.48
14	0.80667	1	0.80523	0.21397	0.47967	0.59322	0.36

Βήμα 2^ο : Δημιουργία του δικτύου

```
net=newff([0 1;0 1;0 1],[3 3 1],{'logsig' 'logsig' 'purelin'},'traingd');
net=init(net); %network initialization
```

Το δίκτυο που θα δημιουργήσουμε, είναι ένα δίκτυο εμπρόσθιας μετάδοσης των δεδομένων το οποίο χρησιμοποιεί αλγόριθμο μάθησης οπισθόδρομης διάδοσης. Η γενική μορφή αυτού του δικτύου, είναι:




Στο δίκτυο του σχήματος, βέβαια, ως συνάρτηση μεταφοράς χρησιμοποιείται η εφαπτομενική σιγμοειδής.

Σε ότι αφορά την αρχιτεκτονική του δικτύου, μετά από δοκιμές έχουμε καταλήξει στα εξής συμπεράσματα.

- Τέσσερα επίπεδα: Ένα επίπεδο εισόδου, δύο κρυφά επίπεδα και ένα επίπεδο εξόδου


- Τρεις (3) νευρώνες σε κάθε κρυμμένο επίπεδο
- Ένας (1) νευρώνας στο επίπεδο εξόδου
- Συνάρτηση ενεργοποίησης των νευρώνων του κρυμμένου επιπέδου επιλέγουμε την λογαριθμική σιγμοειδή



Log-Sigmoid Transfer Function

Η συνάρτηση μεταφοράς υπολογίζει την έξοδο του νευρώνα ανάλογα με την είσοδο από το δίκτυο. Παίρνει σαν όρισμα το διάνυσμα εισόδου και επιστρέφει τις αντίστοιχες τιμές εξόδου κατανεμημένες μεταξύ των τιμών 0 και 1.

- Συνάρτηση ενεργοποίησης του νευρώνα εξόδου, επιλέγουμε τη συνάρτηση purelin της MATLAB που είναι γραμμική συνάρτηση:



- Συνάρτηση μεταφοράς, επιλέγουμε όπως είπαμε την λογαριθμική σιγμοειδή συνάρτηση
- Συνάρτηση εκπαίδευσης επιλέγουμε την traingd, δηλαδή τον αλγόριθμο μέγιστης κατάβασης.

Η συνάρτηση εκπαίδευσης αναπροσαρμόζει τις τιμές των βαρών και των παραμορφώσεων σύμφωνα με την βαθμιαία κατάβαση. Τα αρχικά βάρη είναι τυχαίες τιμές που γεννά ο αλγόριθμος και αυτός είναι ο λόγος για τυχόν διαφορετικά τελικά αποτελέσματα, κυρίως όταν το πρόγραμμα τρέξει σε διαφορετικούς υπολογιστές. Η διαφορά δεν θα πρέπει να είναι πολύ μεγάλη βέβαια. Η εκπαίδευση του δικτύου συμβαίνει με τις ακόλουθες εξ' ορισμού παραμέτρους. Η συνάρτηση αυτή εκπαιδεύει οποιοδήποτε δίκτυο, αρκεί τα βάρη, οι είσοδοι και η συναρτήσεις μεταφοράς να είναι παραγωγίσιμες. Για τον υπολογισμό των παραγώγων σε ότι αφορά την απόδοση, χρησιμοποιείται ο αλγόριθμος οπισθόδρομης διάδοσης. Η εκπαίδευση σταματά όταν ένα από τα ακόλουθα συμβεί: έχει επιτευχθεί ο μέγιστος αριθμός περιόδων/ επαναλήψεων, έχει περάσει ο μέγιστος χρόνος, η απόδοση έχει φτάσει στον στόχο.

- Τα βάρη βελτιώνονται με την χρήση της συνάρτησης των μέσων τετραγώνων των σφαλμάτων (MSE – Mean Square Error). Αυτή η συνάρτηση μετράει την απόδοση του δικτύου σύμφωνα με τον μέσο των τετραγώνων των σφαλμάτων.
- Η συνάρτηση μάθησης είναι εξ' ορισμού η learnsgdm.

Αν ζητήσουμε από την MATLAB να μας δώσει τις παραμέτρους του δικτύου, τυπώνονται οι εξής πληροφορίες:

Neural Network object:

architecture:

numInputs: 1
 numLayers: 3
 biasConnect: [1; 1; 1]
 inputConnect: [1; 0; 0]
 layerConnect: [0 0 0; 1 0 0; 0 1 0]
 outputConnect: [0 0 1]
 targetConnect: [0 0 1]

numOutputs: 1 (read-only)
 numTargets: 1 (read-only)
 numInputDelays: 0 (read-only)
 numLayerDelays: 0 (read-only)

subobject structures:

inputs: {1x1 cell} of inputs
 layers: {3x1 cell} of layers
 outputs: {1x3 cell} containing 1 output
 targets: {1x3 cell} containing 1 target
 biases: {3x1 cell} containing 3 biases
 inputWeights: {3x1 cell} containing 1 input weight
 layerWeights: {3x3 cell} containing 2 layer weights

functions:

adaptFcn: 'trains'
 initFcn: 'initlay'
 performFcn: 'mse'
 trainFcn: 'traingd'

parameters:


adaptParam: .passes
 initParam: (none)
 performParam: (none)
 trainParam: .epochs, .goal, .lr, .max_fail,
 .min_grad, .show, .time

weight and bias values:

IW: {3x1 cell} containing 1 input weight matrix
 LW: {3x3 cell} containing 2 layer weight matrices
 b: {3x1 cell} containing 3 bias vectors

other: userdata: (user stuff)

Το σχεδιάγραμμα του δικτύου της εφαρμογής μας, είναι:



Βλέπουμε ότι στο επίπεδο εισόδου υπάρχει ένα διάνυσμα με 3 στοιχεία. Είναι η τιμή της ζήτησης για τρεις μήνες των δεδομένων μας και για κάθε πελάτη. Αυτό το σημείο θα το αναλύσουμε παρακάτω όπου θα αναφερθούμε στην προσαρμογή των δεδομένων στην εκπαίδευση του δικτύου.

Υπάρχουν 2 κρυμμένα επίπεδα με τρεις νευρώνες το κάθε ένα και η συνάρτηση ενεργοποίησης κάθε νευρώνα είναι η λογαριθμική σιγμοειδής. Στο επίπεδο εξόδου υπάρχει ένας μόνο νευρώνας με συνάρτηση ενεργοποίησης την γραμμική συνάρτηση pureline.

Η εντολή *init* αρχικοποιεί όλες τις παραμέτρους του δικτύου.

Βήμα 3^ο : Προσαρμογή των δεδομένων

Δεδομένα Εκπαίδευσης

```
%TRAIN DATA
%TRAIN INPUTS
for i=1:m-8
    for j=1:n
        C{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
    end
end

a=1;
for k=1:(m-8)*n
    for b=1:3
        NUM(b,a,k)=C{k}(b,a); %TRAIN INPUTS
    end
end

%TRAIN TARGETS
for i=4:m-5
    for j=1:n
        T(i,j)=N(i,j); %TRAIN TARGETS
    end
end
for i=3:-1:1
    T(i,:)=[];
end
T=T';
end
```

Τα δεδομένα που έχουμε συγκεντρώσει είναι σχετικά με τα δύο τελευταία έτη 2002 και 2003. Τα δεδομένα αυτά δεν κρίνονται αρκετά για την εκπαίδευση του νευρωνικού δικτύου. Επιπλέον, η ζήτηση εμφανίζει περιοδικότητα. Όπως έχουμε αναφέρει, τα νευρωνικά δίκτυα δεν ενδείκνυνται γενικά για δεδομένα με περιοδική ζήτηση. Για να παρακάμψουμε αυτό το εμπόδιο, έχουμε επιλέξει μία δομή η οποία θα μας παρέχει εκτός των άλλων περισσότερα σετ δεδομένων.

Επιλέγουμε να έχουμε στην είσοδο τη ζήτηση 3 μηνών και στην έξοδο τη ζήτηση του 4^{ου} κατά σειρά μήνα. Τα ζεύγη λοιπόν που δημιουργούνται, είναι :

Είσοδος	Έξοδος
Μήνες	Μήνας
1,2,3	4
2,3,4	5
3,4,5	6
4,5,6	7
5,6,7	8

Κ.Ο.Κ

Από αυτά τα ζεύγη, τα 400 πρώτα χρησιμοποιούνται για την εκπαίδευση του δικτύου, ενώ τα 125 επόμενα για τον έλεγχο του. Έχουμε δηλαδή συνολικά 525 ζεύγη δεδομένων (εισόδους με αντίστοιχες εξόδους).

Δεδομένα Ελέγχου

```
%TEST DATA
for i=17:m-3
    for j=1:n
        Ct{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
    end
end
for i=16:-1:1
    Ct(i,:)=[];
end
a=1;
for k=1:5*n %125
    for b=1:3
        NUMt(b,a,k)=Ct{k}(b,a); %TEST INPUT
    end
end
for i=20:m
    for j=1:n
        Tt(i,j)=N(i,j); %TEST TARGET
    end
end
for i=19:-1:1
    Tt(i,:)=[];
end
Tt=Tt';
```


Δεδομένα Προσομοίωσης

```

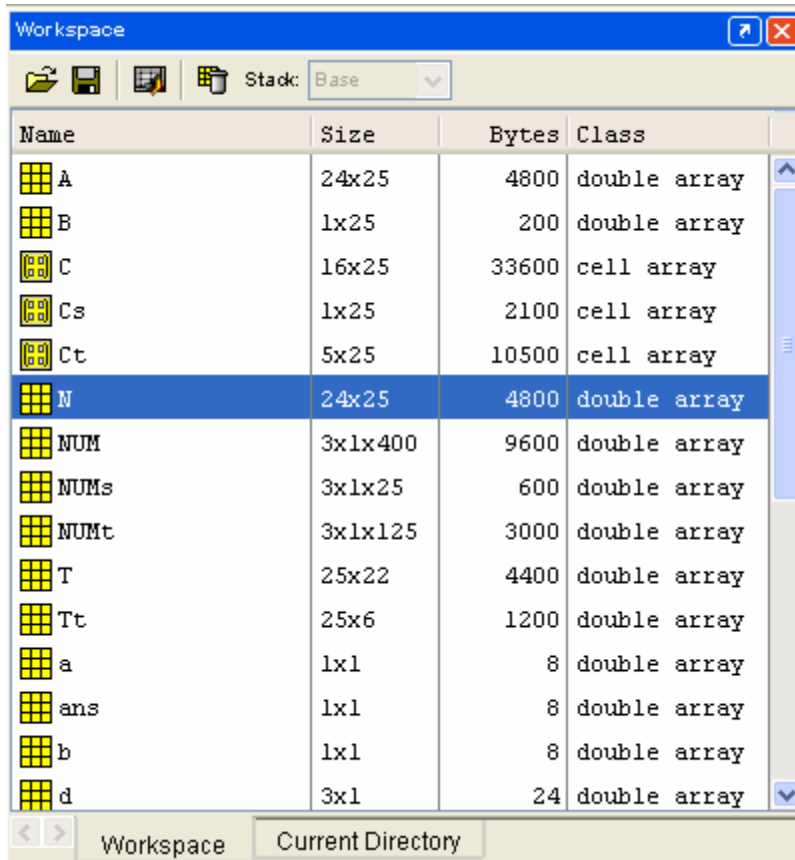
i=m-2;
for j=1:n
    Cs{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
end
for i=21:-1:1
    Cs(i,:)=[];
end
a=1;
for k=1:n %25
    for b=1:3
        NUMs(b,a,k)=Cs{k}(b,a); %SIM INPUT
    end
end
end

```

Αυτή η προσέγγιση ανά τρίμηνο που κάνουμε, είναι ικανοποιητική για την διοίκηση, καθώς όπως είδαμε τα προϊόντα δεν θα πρέπει να μένουν για πολύ καιρό στην αποθήκη. Ένας τριμηνιαίος προγραμματισμός λοιπόν, είναι ικανοποιητικός.

Σημειώνουμε επίσης ότι ο αρχικός πίνακας και το .M αρχείο που περιέχει το πρόγραμμα θα πρέπει να είναι αποθηκευμένα στον ίδιο κατάλογο ο οποίος έχει οριστεί σαν ο κατάλογος εργασίας στην MATLAB. Θα πρέπει να είναι τοποθετημένος στην κορυφή των καταλόγων. Εξ ορισμού, η MATLAB χρησιμοποιεί τον κατάλογο «work». Γι' αυτό είναι καλό να αποθηκεύσουμε το αρχείο αυτό και τον πίνακα A στον φάκελο «work» της MATLAB για να μην έχουμε προβλήματα και διακοπές κατά την εκτέλεση του προγράμματος.

Όλοι αυτοί οι πίνακες που υπολογίστηκαν από την MATLAB, εξάγονται στον χώρο εργασίας της MATLAB και μπορούν στη συνέχεια να χρησιμοποιηθούν από οποιοδήποτε σημείο του προγράμματος ή να εξαχθούν σε αρχείο excel, να χρησιμοποιήσουμε τις τιμές τους για να κάνουμε γραφικές αναπαραστάσεις κλπ. Οι πίνακες αυτοί και τα λοιπά στοιχεία του προγράμματος με την μορφή που εμφανίζονται στον χώρο εργασίας, είναι:



Name	Size	Bytes	Class
A	24x25	4800	double array
B	1x25	200	double array
C	16x25	33600	cell array
Cs	1x25	2100	cell array
Ct	5x25	10500	cell array
N	24x25	4800	double array
NUM	3x1x400	9600	double array
NUMs	3x1x25	600	double array
NUMt	3x1x125	3000	double array
T	25x22	4400	double array
Tt	25x6	1200	double array
a	1x1	8	double array
ans	1x1	8	double array
b	1x1	8	double array
d	3x1	24	double array

Έχουμε χρησιμοποιήσει δευτερεύοντες πίνακες (πίνακες C) για να μπορέσουμε να παίρνουμε τα στοιχεία του N ανά τρία. Οι πίνακες αυτοί είναι πίνακες – κελιά, δηλαδή πίνακες κάθε στοιχείο των οποίων είναι ένας άλλος πίνακας. Συγκεκριμένα, κάθε στοιχείο των C είναι ένας 3x1 πίνακας.

Βήμα 4^ο :Εκπαίδευση του δικτύου

```
%TRAIN NETWORK
for i=1:400
    p=[NUM(:,i)];
    t(i)=T(i);
    [net,tr]=train(net,p,t(i));
end
```

Βήμα 5^ο : Έλεγχος του δικτύου

```
%TEST NETWORK
for i=1:125
    pt=[NUMt(:,i)];
    tt(i)=Tt(i);
    q(i)=sim(net,pt);
end
E=reshape(tt,5,25);
D=reshape(q,5,25);
```

Στο διάνυσμα q αποθηκεύονται οι τιμές για την ζήτηση. Αυτές οι τιμές θα πρέπει να συγκριθούν με τις πραγματικές τιμές (τιμές στόχοι) του διανύσματος tt . Οι πίνακες E και D περιέχουν είναι πίνακες 5×25 οι οποίοι περιέχουν τις τιμές της ζήτησης για τους 25 πελάτες και για τους 5 μήνες (17 – 23) της φάσης του ελέγχου. Οι πίνακες αυτοί φαίνονται παρακάτω:

Πίνακας E με τις τιμές στόχους:

ΠΕΛ1	280	ΠΕΛ2	77	ΠΕΛ3	254	ΠΕΛ4	28	ΠΕΛ5	77	ΠΕΛ6	37 6	ΠΕΛ7	85	ΠΕΛ8	208	ΠΕΛ9	36
	75		64		78		21		93		65		62		85		23
	286		45		37		72		36		27 1		45		44		70
	312		80		46		82		50		29 1		82		35		70
	213		96		181		77		288		21 4		91		155		76

ΠΕΛ10	63	ΠΕΛ11	369	ΠΕΛ12	93	ΠΕΛ13	21 5	ΠΕΛ14	28	ΠΕΛ15	81	ΠΕΛ16	203	ΠΕΛ17	101	ΠΕΛ18	260
	89		62		63		91		24		97		59		48		85
	36		307		49		41		74		37		249		31		37
	78		345		108		35		92		81		406		145		32
	255		204		53		18 7		65		28 1		186		75		196

ΠΕΛ19	37	ΠΕΛ20	80	ΠΕΛ21	388	ΠΕΛ22	98	ΠΕΛ23	156	ΠΕΛ24	34	ΠΕΛ25	70
	28		102		58		57		91		24		81
	62		33		220		57		35		58		33
	97		51		398		11 9		39		79		81
	77		278		164		78		189		81		282

Πίνακας D με τις τιμές της εκπαίδευσης:

ΠΕΛ1	286	ΠΕΛ2	75	ΠΕΛ3	253	ΠΕΛ4	32	ΠΕΛ5	70	ΠΕΛ6	37 0	ΠΕΛ7	84	ΠΕΛ8	15	ΠΕΛ9	35
	312		95		80		30		100		70		60		60		70
	280		47		42		78		40		27 0		45		60		69
	310		77		50		93		50		29 0		80		36		68
	215		90		190		80		290		21 5		90		90		80

ΠΕΛ10	67	ΠΕΛ11	188	ΠΕΛ12	90	ΠΕΛ13	30	ΠΕΛ14	30	ΠΕΛ15	78	ΠΕΛ16	42	ΠΕΛ17	26	ΠΕΛ18	13
	85		167		63		80		27		95		31		9		65
	44		169		50		34		75		36		13		0		69
	75		91		100		30		90		87		27		26		3
	0		198		51		50		63		0		24		0		89

ΠΕΛ19	33	ΠΕΛ20	81	ΠΕΛ21	100	ΠΕΛ22	10 0	ΠΕΛ23	0	ΠΕΛ24	40	ΠΕΛ25	282
	28		100		2		57		49		30		254
	60		38		0		61		40		60		168
	100		52		64		11 8		40		80		171
	75		0		0		80		0		86		282

Οι πίνακες αυτοί προέκυψαν ύστερα από την εκτέλεση των παρακάτω εντολών στην MATLAB:

```
for j=1:25
    E(:,j)=E(:,j)*B(j);
    D(:,j)=D(:,j)*B(j);
end
```

Έχουμε πολλαπλασιάσει δηλαδή τις κανονικοποιημένες τιμές που προκύπτουν ως έξοδοι του δικτύου, με τις τιμές του πίνακα B για να αποκατασταθεί η πραγματική τους τιμή σε ό,τι αφορά την ζήτηση.

4. 6 Σχολιασμός των αποτελεσμάτων

Από τις τιμές των πινάκων, παρατηρούμε ότι το δίκτυο που κατασκευάσαμε είναι κατάλληλο για την πρόβλεψη της ζήτησης στην εφαρμογή μας, καθώς έχει εκπαιδευτεί επαρκώς. Οι τιμές του πίνακα D είναι ικανοποιητικές.

Παρατηρούμε μόνο κάποιες αποκλίσεις σε 5 πελάτες (πελάτες 16, 17, 18, 21 και 25). Οι μεγάλες αποκλίσεις που εμφανίζονται στην ζήτηση των συγκεκριμένων πελατών, μπορεί να εξηγηθεί αν λάβουμε υπ' όψη ότι οι πελάτες αυτοί εμφανίζουν ανομοιομορφη ζήτηση σε σχέση με τους υπόλοιπους μέσα στον χρόνο. Επίσης, σε πολλούς από τους μήνες η ζήτηση είναι μηδενική. Δεν υπάρχει δηλαδή κάποιος κανόνας σύμφωνα με τον οποίο αυξομειώνεται η τιμή της ζήτησης σε αυτούς τους πελάτες.

Πρόκειται για πέντε πελάτες οι οποίοι δεν είναι αυτό που θα ονομάζαμε τακτικοί πελάτες. Αυτό μπορεί να οφείλεται στο γεγονός ότι οι ανάγκες τους δεν είναι συνεχείς ή καλύτερα, οι ανάγκες των πελατών αυτών είναι ανομοιομορφα κατανεμημένες μέσα στον χρόνο και δεν ακολουθούν την εποχικότητα που εμφανίζεται γενικά στους υπόλοιπους. Μάλιστα, σε περιόδους οι οποίες θα λέγαμε ότι είναι αιχμής και στις οποίες στα εργοστάσια δουλεύουν διπλές βάρδιες για να καταφέρουν να καλύψουν την αυξημένη ζήτηση, οι πελάτες αυτοί εμφανίζουν χαμηλή ως μηδενική ζήτηση.

Ακόμα και στην περίπτωση του πελάτη 24, τα αποτελέσματα είναι ικανοποιητικά. Ο πελάτης 24 είναι νέος πελάτης της επιχείρησης. Κατά τους πρώτους μήνες του 2002, η ζήτησή του ήταν μηδενική. Πρωτοεμφανίστηκε στο πελατολόγιο της εταιρίας από τον Αύγουστο του 2002. Επειδή όμως εμφανίζει παρόμοια εποχικότητα στις ανάγκες του σε σχέση με την αγορά, το δίκτυο παρήγαγε ανεκτά αποτελέσματα.

Το παραπάνω γεγονός της εμφάνισης μεγάλων σφαλμάτων στους 5 μη τακτικούς πελάτες, κάνει φανερή την ανάγκη ύπαρξης του ανθρώπου για τον έλεγχο της λειτουργίας των πληροφοριακών συστημάτων. Ένας έμπειρος χρήστης θα μπορούσε να διακρίνει τις τιμές της ζήτησης οι οποίες δεν μπορούν να γίνουν αποδεκτές για κάποιον πελάτη. Η περίπτωση αυτή είναι πολύ χαρακτηριστική για τον πελάτη 25. Οι τιμές που προκύπτουν είναι πολύ μικρές για την ζήτηση που γενικά αυτός εμφανίζει. Η διακύμανση όμως της ζήτησης θα λέγαμε ότι παραμένει η ίδια.

Όπως είναι σημαντική η εμπειρία για να αξιολογήσουμε την λειτουργία του δικτύου και τα αποτελέσματα που από αυτό προκύπτουν, υπάρχουν και άλλοι σημαντικοί παράγοντες. Αυτοί οι

παράγοντες δεν μπορούν να συμπεριληφθούν στην εκπαίδευση του δικτύου, καθώς δεν είναι εύκολο να ποσοτικοποιηθούν. Αναφερόμαστε σε στοιχεία όπως ο ανταγωνισμός, η γενικότερη οικονομική κατάσταση, οι επενδύσεις και η κίνηση στην αγορά. Μόνο ο ανθρώπινος παράγοντας θα μπορούσε να συμπεριλάβει στην εμπειρία του συναφής παράγοντες και να έχει μία πληρέστερη κρίση.

Βήμα 6^ο : Προσομοίωση του δικτύου

```
for i=1:25;
    d=NUMs(:,i);
    r(i)=sim(net,d)
end
for j=1:25
    r(:,j)=r(:,j)*B(j);
end
```

Αφού έχουμε αποδεχτεί το δίκτυο και θεωρούμε ικανοποιητική την εκπαίδευση, μπορούμε να προχωρήσουμε και στο τελικό στάδιο κατά το οποίο ζητούμε από το δίκτυο να παράγει τα αποτελέσματα για τον επόμενο μήνα, τον 25^ο. Ζητούμε δηλαδή να πάρουμε στην έξοδο την πρόβλεψη του δικτύου για τον επόμενο μήνα.

Η πρόβλεψη του δικτύου για τον Ιανουάριο του 2004, είναι λοιπόν η εξής:

ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ	ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ
ΠΕΛ1	323.57	ΠΕΛ14	41.887
ΠΕΛ2	60.433	ΠΕΛ15	153.59
ΠΕΛ3	293.32	ΠΕΛ16	27.89
ΠΕΛ4	329.98	ΠΕΛ17	21.603
ΠΕΛ5	181.13	ΠΕΛ18	67.124
ΠΕΛ6	81.555	ΠΕΛ19	79.825
ΠΕΛ7	54.404	ΠΕΛ20	67.625
ΠΕΛ8	54.049	ΠΕΛ21	67.508
ΠΕΛ9	113.08	ΠΕΛ22	85.388
ΠΕΛ10	84.737	ΠΕΛ23	31.165
ΠΕΛ11	230.13	ΠΕΛ24	78.207
ΠΕΛ12	73.916	ΠΕΛ25	259.37
ΠΕΛ13	39.937		

Οι ποσότητες εκφράζονται σε κιβώτια προϊόντων. Λόγω του φυσικού περιορισμού, δεν μπορούμε να έχουμε δεκαδικό αριθμό προϊόντων. Για τον λόγο αυτό θα στρογγυλοποιήσουμε όλες τις ποσότητες προς τα πάνω. Η τελική ζήτηση λοιπόν έτσι όπως την προβλέπει το νευρωνικό δίκτυο που κατασκευάσαμε, έχει ως εξής:

ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ	ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ	ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ
ΠΕΛ1	324	ΠΕΛ10	85	ΠΕΛ19	80
ΠΕΛ2	61	ΠΕΛ11	230	ΠΕΛ20	68
ΠΕΛ3	294	ΠΕΛ12	74	ΠΕΛ21	68
ΠΕΛ4	330	ΠΕΛ13	40	ΠΕΛ22	86
ΠΕΛ5	182	ΠΕΛ14	42	ΠΕΛ23	32
ΠΕΛ6	82	ΠΕΛ15	154	ΠΕΛ24	79
ΠΕΛ7	55	ΠΕΛ16	28	ΠΕΛ25	260
ΠΕΛ8	54	ΠΕΛ17	22		
ΠΕΛ9	113	ΠΕΛ18	68		

Η πολιτική της εταιρίας είναι να υπολογίζει μία αύξηση της τάξης του 20% σε σχέση με τα δεδομένα του προηγούμενου χρόνου για κάθε πελάτη. Σύμφωνα με αυτήν την φόρμουλα, η ποσότητες για κάθε πελάτη, θα ήταν:

ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ	ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ	ΠΕΛΑΤΗΣ	ΖΗΤΗΣΗ
ΠΕΛ1	491	ΠΕΛ10	109	ΠΕΛ19	68
ΠΕΛ2	28	ΠΕΛ11	66	ΠΕΛ20	38
ΠΕΛ3	190	ΠΕΛ12	40	ΠΕΛ21	29
ΠΕΛ4	104	ΠΕΛ13	40	ΠΕΛ22	26
ΠΕΛ5	118	ΠΕΛ14	22	ΠΕΛ23	30
ΠΕΛ6	65	ΠΕΛ15	73	ΠΕΛ24	38
ΠΕΛ7	43	ΠΕΛ16	0	ΠΕΛ25	205
ΠΕΛ8	83	ΠΕΛ17	32		
ΠΕΛ9	199	ΠΕΛ18	48		

4. 7 Γραφικές απεικονίσεις


Στο σημείο αυτό, θα ήταν καλό να δούμε κάποιες γραφικές παραστάσεις με τα δεδομένα της εκπαίδευσης αλλά και της εφαρμογής (πρόβλεψης). Αντιπαραβάλλοντας τις κατάλληλες ομάδες δεδομένων οπτικοποιημένες, μπορούμε να κατανοήσουμε καλύτερα τα παραπάνω.

Η πρώτη γραφική παράσταση που θα δούμε, αφορά την πρόβλεψη που μας έδωσε το νευρωνικό δίκτυο για τον Ιανουάριο του 2004. Θα συγκρίνουμε τις τιμές που πήραμε για κάθε πελάτη από το νευρωνικό με αυτές που θα υπολογίζαμε σύμφωνα με την φόρμουλα της αύξησης της ζήτησης κατά 20%. Θα αναπαραστήσουμε δηλαδή γραφικά τους δύο τελευταίους πίνακες.

Για να το κάνουμε αυτό, θα εκτελέσουμε στην MATLAB τις παρακάτω εντολές:

```
A=xlsread('graph1');
A1=A(1,:);
A2=A(2,:);
B=(1:1:25);
plot(B,A1,B,A2);grid;xlabel('Customers');ylabel('Demand');title('Compare Methods');
```


Οι πίνακες A1 και A2 είναι οι αντίστοιχοι πίνακες με τη μορφή διανυσμάτων. Ο A1 είναι αυτός με τις τιμές της πρόβλεψης και ο A2 περιέχει τις τιμές που υπολογίσαμε. Η γραφική παράσταση φαίνεται παρακάτω:



Με μπλε χρώμα φαίνονται οι τιμές της πρόβλεψης και με πράσινο οι τιμές που υπολογίσαμε αλγεβρικά για την ζήτηση του 25^{ου} μήνα του υποδείγματός μας. Παρατηρούμε ότι υπάρχουν μεγάλες διαφορές στα αποτελέσματα. Μόνο σε τρεις περιπτώσεις (πελάτες 7, 13, 23) βλέπουμε να συμφωνούν οι δύο μέθοδοι και αυτό τις δύο από τις τρεις φορές όχι απόλυτα. Η τάση πάντως των αποτελεσμάτων, σε γενικές γραμμές, είναι όμοια. Ας δούμε όμως ποια μέθοδος έβγαλε καλύτερα αποτελέσματα σύμφωνα με τα δεδομένα του ίδιου μήνα κατά τα δύο προηγούμενα έτη.

Εισάγουμε άλλους δύο πίνακες διανύσματα στην MATLAB. Ο ένας περιέχει τις τιμές της ζήτησης για τον Ιανουάριο του 2002 και ο άλλος τις τιμές της ζήτησης για τον Ιανουάριο του 2003.

Για την πρόβλεψη του δικτύου, έχουμε:



Με μπλε χρώμα φαίνονται οι τιμές για το 2002, με πράσινο αυτές για το 2003 και με κόκκινο είναι η πρόβλεψη του δικτύου.

Δεν θα κάνουμε γραφική παράσταση για τις τιμές που υπολογίσαμε, καθώς αυτές θα ακολουθούν την πράσινη γραμμή και θα είναι κατά 20% πιο ψηλά στον άξονα της ζήτησης. Παρατηρούμε ότι το δίκτυο δεν έχει παράγει καμία μηδενική τιμή για τον Ιανουάριο του 2005. Αυτό είναι πιθανό να είναι μια αδυναμία του δικτύου αν και ο μήνας Ιανουάριος είναι γενικά μήνας όπου υπάρχει μία μέση τιμή ζήτησης για τους περισσότερους πελάτες. Θα πρέπει ωστόσο ο χρήστης να εξετάσει λίγο καλύτερα τους παράγοντες που δεν μπορούσαν να μοντελοποιηθούν σε ένα νευρωνικό δίκτυο για να κρίνει αν θα πρέπει να εμπιστευτεί την πρόβλεψη. Σε γενικές γραμμές όμως μπορούμε να πούμε ότι το δίκτυο μας δίνει μία ικανοποιητική τάση για τις τιμές της ζήτησης κατά τον Ιανουάριο του 2005.


Στο σημείο αυτό θα πρέπει να τονίσουμε ότι δεν θα πρέπει σε καμία περίπτωση να θεωρηθούν οι τιμές που υπολογίσαμε σύμφωνα με την προσαύξηση του 20% σωστές και από

αυτές να βγάλουμε συμπεράσματα για τις τιμές της πρόβλεψης που έδωσε το δίκτυο στην έξοδό του. Θα πρέπει μόνο να κοιτάζουμε τους πελάτες οι οποίοι εμφανίζουν μεγάλες διαφορές σε αυτές τις δύο τιμές. Κρίνοντας από την πορεία της τιμής της ζήτησης που είχαν κατά την διάρκεια του χρόνου, θα μπορέσουμε να κάνουμε μία πιο ασφαλή πρόβλεψη. Σύμφωνα με αυτό το κριτήριο θα αποφανθούμε και για το ποια από τις δύο μεθόδους δίνει πιο ακριβή αποτελέσματα αν και αυτό δεν είναι το ζητούμενο.

Αυτό που κυρίως μας ενδιαφέρει για να εμπιστευτούμε το δίκτυο, είναι το κατά πόσο αυτό έχει εκπαιδευτεί καλά. Για να το κρίνουμε αυτό, θα ανατρέξουμε στα δεδομένα του ελέγχου. Δηλαδή στους πίνακες E και D.


Στους πίνακες αυτούς περιέχονται όλες οι τιμές του ελέγχου. Όλες οι έξοδοι – στόχοι και οι έξοδοι του δικτύου κατά την εκπαίδευσή του. Θα ασχοληθούμε μόνο με κάποιες χαρακτηριστικές περιπτώσεις.

Όπως έχουμε αναφέρει, ο πελάτης 24 είναι νέος πελάτης, αν και λόγω της κατανομής της ζήτησης του μέσα στον χρόνο εμφανίζει ικανοποιητικές τιμές κατά την εκπαίδευση του δικτύου.



Οι υπόλοιποι πελάτες εμφανίζουν την ίδια ή και καλύτερη αποτελεσματικότητα στα δεδομένα εκπαίδευσής τους. Υπάρχουν και κάποιοι πελάτες για τους οποίους το δίκτυο δεν κατάφερε να

εκπαιδευτεί αρκετά καλά. Μία χαρακτηριστική περίπτωση τέτοιου πελάτη, είναι αυτή του μη τακτικού πελάτη 21. Η γραφική παράσταση γι' αυτόν τον πελάτη, είναι:



4. 8 Επεκτάσεις

Η πρόβλεψη της ζήτησης που πραγματοποιήθηκε από το πρόγραμμα που αναπτύξαμε, είχε σκοπό να βοηθήσει στον προγραμματισμό της παραγωγής αλλά κυρίως στον καλύτερο προγραμματισμό της λειτουργίας των αποθηκών της επιχείρησης και των δρομολογίων των οδηγών.

Όπως έχουμε ήδη πει, οι ποσότητες στις οποίες αναφερόμαστε είναι εκφρασμένες σε κιβώτια προϊόντων. Στον πίνακα του παραρτήματος Ε φαίνονται οι εκφράσεις των τεμαχίων ανά κιβώτιο, των κιβωτίων ανά παλέτα κλπ. Για τον καλύτερο προγραμματισμό των δρομολογίων, χρειαζόμαστε και άλλα στοιχεία όπως:

- Το κάθε φορτηγό μπορεί να πάρει μέχρι 3,5 tn φορτίο. Αυτό σύμφωνα με τον πίνακα σημαίνει ότι μπορεί να έχει φορτίο αποτελούμενο από 6 το πολύ παλέτες. Ας σημειώσουμε εδώ ότι οι πελάτες της Θεσσαλονίκης εξυπηρετούνται όλοι από τα ιδιόκτητα φορτηγά της εταιρίας τα οποία είναι του ίδιου τύπου.
- Ο αριθμός των παλετών είναι μικρός λόγω του ότι το πλάτος τους είναι μεγάλο. Δεν μπορούμε να φορτώσουμε παλέτες δίπλα την μία στην άλλη.
- Στο ύψος δεν έχουμε περιορισμό, καθώς τα προϊόντα είναι βαριά και δεν μπορούμε εκ των πραγμάτων να φτάσουμε σε μεγάλα ύψη φορτίων.

Χρειαζόμαστε επίσης στοιχεία για την κατανάλωση καυσίμου των οχημάτων αλλά και στοιχεία γραφημάτων και δικτύων τα οποία αναπτύσσονται στο επόμενο κεφάλαιο.

Είναι επίσης να αναφέρουμε ότι το πρόγραμμά μας είναι γενικό. Οι διαστάσεις των πινάκων δεν έχουν οριστεί επ' ακριβώς αλλά μέσω μεταβλητών ποσοτήτων. Έχουμε, όπως λέμε, δυναμική καταχώρηση των διαστάσεων των πινάκων με τα δεδομένα. Αυτό μας διευκολύνει να χρησιμοποιήσουμε το δίκτυο προσθέτοντας σε αυτό νέα δεδομένα τα οποία προκύπτουν από τα στατιστικά στοιχεία της εταιρίας με την πάροδο του χρόνου.

Ο χρήστης δεν είναι απαραίτητο να γνωρίζει MATLAB για να προσθέσει δεδομένα στο δίκτυο. Το μόνο που έχει να κάνει είναι να τα προσθέσει στο αρχείο excel. Η MATLAB θα εισάγει τον νέο επανυξημένο πίνακα και θα εκτελέσει όλες τις εντολές σύμφωνα με τα νέα στοιχεία. Θα χρησιμοποιεί πάντα τα δεδομένα των 5 τελευταίων μηνών (πλην του τελευταίου) για τον έλεγχο του δικτύου και τα υπόλοιπα για την εκπαίδευσή του.

Το εκτελέσιμο .M αρχείο μπορεί να τοποθετηθεί στην επιφάνεια εργασίας του υπολογιστή και έτσι να είναι εύκολη η πρόσβαση σε αυτό και η εκτέλεσή του με μία απλή κίνηση. Το μόνο σημείο που θα πρέπει να προσέξουμε, είναι η σωστή εισαγωγή των δεδομένων στο αρχείο

data.xls αλλά και η αποθήκευση του αρχείου και του προγράμματος στην κύρια διαδρομή απ' όπου εκτελεί η MATLAB.

ΠΑΡΑΡΤΗΜΑ Α

ΠΑΡΑΣΤΑΤΙΚΑ ΠΩΛΗΣΕΩΝ									
Περίοδος : [01-01-2003] - [31-12-2003]									
Ημερ. Εκτ. : 22-06-04									
Ημερ. Εξδ. Παρ.	Αριθ. Παρ.	Επωνυμία Πελάτη	Πωλ. Α	Ημ. Πήξ	ΤΙΠΤΑ	Καθαρή Αξία Μεταφορ.	Επιβαρ.	Σύνολο ΦΠΑ	Σύνολο Παρ.
Ομάδα 2	Κωδικός Είδους	Περιγραφή	Ποσότητα	Τιμή Μον	Εκπτ. %				
210203	42	Τιμολ	594	ΠΕΤΡΙΔΗΣ ΧΡΗΣΤΟΣ	02	883,61		153,05	1042,66
19	7700000001	ANTISIL 1L	1	6,00	3,00	30,00			
496010	4960000001	496 AUTOCLEAR 2:1 RAPID 1Lit	3	18,00	7,35	30,00			
96054	4960000005	496 AUTOCLEAR 2:1 RAPID 5Lit	2	8,00	34,00	30,00			
	4410199104	BODYMIX 2K BODYCRYL WHITE 9910	1	6,00	38,00	30,00			
441348	4410392104	BODYMIX 2K BODYCRYL ORANG 9210	1	3,00	42,00	30,00			
24	4410493404	BODYMIX 2K BODYCRYL RED 9340 4L	1	3,00	42,00	30,00			
25	4410391201	BODYMIX 2K BODYCRYL YELL 9120 1	3	18,00	11,50	30,00			
360737	3600700001	BODYFILL 360 1L	1	6,00	7,00	30,00			
900	7260000000	BODYDUR 726 500ml	1	6,00	5,00	30,00			
360748	3600700004	BODYFILL 360 4Lit	1	3,00	27,00	30,00			
29		Σύνολο		77,00					
280203	42	Τιμολ	666	ΠΕΤΡΙΔΗΣ ΧΡΗΣΤΟΣ	02	83,72		15,07	98,79
743015	7430000001	ACRYL FAST 1Lit	2	12,00	4,10	30,00			
743053	7430000005	ACRYL FAST 5L	1	4,00	17,60	30,00			
34		Σύνολο		16,00					
303003	42	Τιμολ	671	ΠΕΤΡΙΔΗΣ ΧΡΗΣΤΟΣ	02	1708,08		307,45	2015,53
37	9500100001	BODY 950 WHITE 1L	2	12,00	3,80	30,00			
38	9990300000	BODY 999 CARTA 300ml	1	12,00	3,00	30,00			
39	2050300003	LP PLUS-SOFT 3 Kg	15	45,00	8,80	35,00			
40	3050300001	BODYFILL 4+1 BEIGE 1L	1	6,00	6,00	30,00			
	7200000020	HARDENER NORMAL 250ml	1	6,00	3,30	30,00			
807743	3070700004	BODYFILL 307 GREY 4:1 L.VOC 4Li	1	3,00	27,00	30,00			
43	7220000001	HARDENER FAST 1L	3	18,00	10,30	30,00			
722058	7220000005	HARDENER FAST 5L	1	4,00	44,00	30,00			
45	7700000001	ANTISIL 1L	1	6,00	3,00	30,00			
767041	7670000001	ECO THINN 1L	2	12,00	2,00	30,00			
767059	7670000005	ECO THINN 5L	2	32,00	8,00	30,00			
96058	4960000005	496 AUTOCLEAR 2:1 RAPID 5Lit	2	12,00	34,00	30,00			
49	4910000001	AUTOCLEAR HS 1Lit	2	12,00	8,80	30,00			
514004	5140000000	SPRAY FILL 400ml	5	60,00	2,35	30,00			
222114	2220100001	BUMPERSOFT 1Kg	1	12,00	5,00	30,00			
52	4410595201	BODYMIX 2K BODYCRYL BLUE 9520 1	2	12,00	11,50	30,00			
53	4410199104	BODYMIX 2K BODYCRYL WHITE 9910	3	9,00	38,00	30,00			
54		Σύνολο		273,00					
030303	42	Τιμολ	672	ΠΕΤΡΙΔΗΣ ΧΡΗΣΤΟΣ	02	31,50		5,67	37,17
57	5100200000	SPRAY BODY 950 BLACK 400ml	2	12,00	2,50	30,00			
510716	5100700000	SPRAY BODY 950 GREY 400ml	1	6,00	2,50	30,00			
59		Σύνολο		18,00					
030303	42	Τιμολ	684	ΠΕΤΡΙΔΗΣ ΧΡΗΣΤΟΣ	02	91,98		16,56	108,54
62	1000700001	BODY HYD GREY 1L	2	12,00	4,20	30,00			
63	2600300001	BODYFILLER 1L	2	12,00	6,75	30,00			
		Σύνολο		24,00					

ΠΑΡΑΡΤΗΜΑ Β

ΚΩΔΙΚΟΣ	ΕΜΠΟΡΙΚΗ ΟΝΟΜΑΣΙΑ	ΚΙΒ.	ΤΕΜ/ΚΙΒ	ΚΙΒΩΤΙΑ/ΠΑΛ.	ΜΗ.	ΠΛ.	ΥΨ.	ΠΑΛΕΤΑ	ΚΙΒΩΤ./Σ.
9400200000	BODY 940 CARTR. 300ml	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
9990300000	BODY 999 CARTR 300ml	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
1150700000	BODY AUTOSEAL SPECIAL CART.300ml	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
1100700000	BODY SEAL CARTR. 300ml.	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
1200200000	SILICONBODY BLACK CARTR. 280ml	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
1200000001	SILICONBODY TR. CARTR. 280ml	401	12	112	205	155	233	ΕΥΡΩΠΑΛΕΤΑ	
2150700001	FERSI 800gr	403	24	36	431	325	189	ΕΥΡΩΠΑΛΕΤΑ	
2150700002	FERSI 1,5Kg	404	12	36	405	272	205	ΕΥΡΩΠΑΛΕΤΑ	
2500600001	BODYFIBER 1.5Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2119800002	BODYSOFT (DAYSON) 1.8Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2119900002	BODYSOFT 1.8Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2090300001	BODY-UNILITE 1L	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2050700002	LP PLUS-SOFT LIGHT GREY 1.5Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2250700002	UNI-FINE 1,5Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
2100300001	UNISOFT 1,5Kg	419	6	72	497	169	159	ΕΥΡΩΠΑΛΕΤΑ	
9600300005	960 WASH PRIMER 5L	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
9100700005	BODY 910 5Kg	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
9300200005	BODY 930 5Kg	421	3	60	526	179	238	1.15 X 1.15	
9320200005	BODY 932 5Kg	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
9890700005	BODY 989 GREY 5L	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
3100300005	BODYFILL 5+1 BEIGE 5L	421	3	32	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
3100700005	BODYFILL 5+1 GREY 5L	421	3	32	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
4220000005	BODYMIX DELUX SICCATIVE 5L	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
9680700005	TOP NC FILLER GREY 5Kg	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
9680300005	TOP NC FILLER YELLOW 5Kg	421	3	40	526	179	238	ΕΥΡΩΠΑΛΕΤΑ	
2500600060	BODYFIBER 750gr	422	12	100	400	267	143	1.15 X 1.15	
2090300000	BODY-UNILITE 500ml	422	12	81	400	267	143	ΕΥΡΩΠΑΛΕΤΑ	
2410600000	NITROSOFT 750gr	422	12	100	400	267	143	1.15 X 1.15	
7310000001	960 ACTIVATOR 1L	427	12	60	350	265	228	ΕΥΡΩΠΑΛΕΤΑ	
7650000001	THINNER EXTRA NITRO 1L	427	12	91	350	265	228	1.15 X 1.15	
7430000005	ACRYL FAST 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
7400000005	ACRYL NORMAL 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
7410000005	ACRYL SLOW 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
7700000005	ANTISIL 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
4910000005	AUTOCLEAR HS 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
4890000005	AUTOCLEAR L.V. 420 HS 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
4900000005	AUTOCLEAR MS 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
4930000005	AUTOCLEAR MS CH 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	
4960000005	AUTOCLEAR MS RAPID 5L	428	4	30	351	351	263	ΕΥΡΩΠΑΛΕΤΑ	

ΠΑΡΑΡΤΗΜΑ Γ

```
A = xlsread('data.xls');

B=max(A);
[m,n]=size(A);
for i=1:m
    for j=1:n
        N(i,j)=A(i,j)/B(j);
    end
end

net=newff([0 1;0 1;0 1],[3 3 1],{'logsig' 'logsig' 'purelin'},'traingd');
net=init(net); %network initialisation

%TRAIN DATA
%TRAIN INPUTS
for i=1:m-8
    for j=1:n
        C{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
    end
end

a=1;
for k=1:(m-8)*n
    for b=1:3

        NUM(b,a,k)=C{k}(b,a); %TRAIN INPUTS
    end
end%-----
%TRAIN TARGETS
for i=4:m-5
    for j=1:n
        T(i,j)=N(i,j); %TRAIN TARGETS
    end
end
for i=3:-1:1
    T(i,:)=[];
end
T=T';
end%-----
%TEST DATA
for i=17:m-3
    for j=1:n
        Ct{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
    end
end
for i=16:-1:1
    Ct(i,:)=[];
end
a=1;
for k=1:5*n %125
    for b=1:3
        NUMt(b,a,k)=Ct{k}(b,a); %TEST INPUT
    end
end
for i=20:m
    for j=1:n
        Tt(i,j)=N(i,j); %TEST TARGET
```



```

        end
    end
    for i=19:-1:1
        Tt(i,:)=[];
    end
    Tt=Tt';%-----

%TRAIN NETWORK
    for i=1:400
        p=[NUM(:,i)];
        t(i)=T(i);
        [net,tr]=train(net,p,t(i));
    end%-----

%TEST NETWORK
    for i=1:125
        pt=[NUMt(:,i)];
        tt(i)=Tt(i);
        q(i)=sim(net,pt);
    end
    E=reshape(tt,5,25);
    D=reshape(q,5,25);
    for j=1:25
        E(:,j)=E(:,j)*B(j);
        D(:,j)=D(:,j)*B(j);
    end

    GE=E(5,:);
    GD=E(5,:);
    %-----
    %PREDICT-SIMULATE
        i=m-2;
        for j=1:n
            Cs{i,j}=[N(i,j);N((i+1),j);N((i+2),j)];
        end
        for i=21:-1:1
            Cs(i,:)=[];
        end
        a=1;
        for k=1:n %25
            for b=1:3
                NUMs(b,a,k)=Cs{k}(b,a); %SIM INPUT
            end
        end
        for i=1:25;
            d=NUMs(:,i);
            r(i)=sim(net,d);
        end
        for j=1:25
            r(:,j)=r(:,j)*B(j);
        end
    %-----

```

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Ροβέρτος – Ε. Κινγκ, Υπολογιστική Νοημοσύνη στον Έλεγχο Συστημάτων, Π. Τραυλός 1998
- [2] Robert R. Trippi, Efraim Turban, Neural Networks in Finance and Investing, Probus 1993
- [3] Leory Marquez, Tim Hill, Reginald Worthley, William Remus, Neural Network Models as an Alternative to Regression, Probus 1993
- [4] Shigeo Abe, Neural Networks and Fuzzy Systems – Theory and Applications, Kluwer Academic Publishers 1997
- [5] Dave Anderson, George McNeill, Artificial Neural Networks Technology, 1992
- [6] Christos Stergiou, Dimitrios Siganos, Neural Networks,
- [7] Neural Networks, StatSoft, 2003
- [8] Howard Demuth, Mark Beale. Neural Network Toolbox for use with MATLAB, The Math Works, Version 4
- [9] Getting Started with MATLAB, The Math Works, Version 5.1
- [10] Heikki N. Koivo, Neural Networks: Basics Using MATLAB Neural Networks Toolbox, 2000
- [11] Lou Mendelssohn, MATLAB Neural Networks Toolbox Technical Analysis of Stocks and Commodities
- [13] Adrian Biran, Moshe Breiner, MATLAB για Μηχανικούς 5, Εκδόσεις TZIOΛΑ 1999
- [14] Θεόδωρος Μόδης, Προβλέψεις: Προσεγγίζοντας Επιστημονικά τα Προμηνύματα του Αύριο, Πανεπιστημιακές Εκδόσεις Κρήτης, 1996
- [15] Σοφία Δημελή, Σύγχρονες Μέθοδοι Ανάλυσης Χρονολογικών Σειρών, Εκδόσεις Κριτική 2003
- [16] Heli Laurikkala, Mikko Ek, Juuso Rantala, Demand Forecasts Based Modeling and Control of Supply Chain
- [17] Nicholas R. Farnum, LaVerne W. Stanton, Quantitative Forecasting Methods, PWS – KENT Publishing Company, Boston 1989
- [18] Chris Chatfield, The Analysis of Time Series(5th Edition), Chapman & Hall, 1996