


Τεχνολογικό Εκπαιδευτικό Ίδρυμα Κρήτης



Σχολή Τεχνολογικών Εφαρμογών  
Τμήμα Εφαρμοσμένης Πληροφορικής & Πολυμέσων



Πτυχιακή εργασία

Τίτλος: Αλγόριθμοι μάθησης μηχανής για  
αποδοτική διαχείριση συστημάτων ηλεκτρικής  
ενέργειας

Μαραγκάκης Γρηγόριος (ΑΜ: 2829)

Επιβλέπων καθηγητής : Κουναλάκης Τσαμπίκος

Επιτροπή αξιολόγησης : Κουναλάκης Τσαμπίκος,  
Τριανταφυλλίδης Γεώργιος, Βιδάκης Νικόλαος

Ημερομηνία αξιολόγησης : 5 Απριλίου 2013

## Ευχαριστίες

Θα ήθελα να ευχαριστήσω ιδιαίτερα τον επιβλέποντα καθηγητή μου κ. Κουναλάκη Τσαμπίκο, για την αγαστή συνεργασία και βοήθεια που μου παρείχε σε όποιες δυσκολίες αντιμετώπισα μέχρι την ολοκλήρωση της πτυχιακής μου εργασίας. Θερμές ευχαριστίες απευθύνω στους καθηγητές κ. Μανόλη Καραπιδάκη και κ. Γιώργο Τριανταφυλλίδη για τις πολύτιμες γνώσεις και συμβουλές που μου παρείχαν. Τέλος θα ήθελα να ευχαριστήσω την οικογένειά μου και το Τζέρι για την αμέριστη συμπαράσταση και υποστήριξη που μου προσέφεραν όλα αυτά τα χρόνια.

## **Abstract**

The purpose of this paper is the demonstration of machine learning algorithms on efficient management of power systems. This model achieves immediate evaluation of safety and supply to the network, combining modern methodologies. Technical approach and solutions to this problem are performed by multiple types of artificial neural networks (ANN) and support vector machines (SVM). Throughout this paper, I focused on Artificial Intelligence oriented techniques aiming at the assistance, improvement of service's, power grid performance, and controllability of safety levels to an electricity provider. The obtained results prove the performance of the proposed methodology in terms of reliability and computation time.

## Σύνοψη

Σκοπός της εργασίας αυτής είναι η μελέτη για την αποδοτική διαχείριση συστημάτων ηλεκτρικής ενέργειας με χρήση ευφυών αλγορίθμων μάθησης. Το προτεινόμενο μοντέλο επιτυγχάνει την άμεση αξιολόγηση της ασφάλειας και τροφοδοσίας του δικτύου, συνδυάζοντας σύγχρονες μεθοδολογίες. Οι τεχνικές προσέγγισης και επίλυσης του προβλήματος εστιάζουν στη χρήση πολλαπλών ειδών τεχνητών νευρωνικών δικτύων (TNN) και support vector machines (SVM). Στη παρούσα μελέτη επικεντρώθηκαν σε τεχνικές Τεχνητής Νοημοσύνης, στοχεύοντας στην ενίσχυση και βελτίωση των υπηρεσιών ενός παρόχου ηλεκτρικής ενέργειας, στις επιδόσεις του δικτύου τροφοδοσίας, καθώς και στη δυνατότητα ελέγχου των επιπέδων ασφάλειας. Τα ληφθέντα αποτελέσματα αναδεικνύουν την απόδοση της προτεινόμενης μεθοδολογίας από άποψη αξιοπιστίας και χρόνου υπολογισμού.

## Πίνακας Περιεχομένων

|   |    |
|---|----|
| 1. Εισαγωγή.....  | 1  |
| 1.1 Περίληψη.....   | 1  |
| 1.2 Κίνητρο για την Διεξαγωγή της Εργασίας .....                        | 1  |
| 1.3 Σκοπός και Στόχοι.....  | 2  |
| 1.4 Δομή .....  | 2  |
| 2. Μεθοδολογία Υλοποίησης .....   | 4  |
| 2.1 Μέθοδος Ανάλυσης & Ανάπτυξης Συστήματος .....                       | 4  |
| 2.1.1 Αλγόριθμοι .....  | 5  |
| 2.2 Θεωρίες .....   | 8  |
| 2.2.1 Τεχνητά νευρωνικά δίκτυα.....                                     | 9  |
| 2.2.2 Τεχνητή νοημοσύνη .....   | 15 |
| 2.2.3 Self-Organizing Maps .....  | 19 |
| 2.2.4 Learning Vector Quantization.....                                 | 24 |
| 2.2.5 Μηχανική Μάθηση.....  | 25 |
| 2.2.6 Οικογένειες Αλγορίθμων Μηχανικής Μάθησης.....                     | 29 |
| 2.2.7 Support vector machines .....                                     | 38 |
| 2.3 Μοντέλα .....   | 41 |
| 2.3.1 Μηχανική μάθηση σε ηλεκτρολογικές και ηλεκτρονικές εφαρμογές..... | 42 |
| 3. Σχέδιο Δράσης για την εκπόνηση της εργασίας.....                     | 43 |
| 3.1 State of the Art .....  | 43 |
| 3.2 Σηματικοί στόχοι για την ολοκλήρωση του συστήματος.....             | 44 |
| 3.2.1 Προτεινόμενο Χρονοδιάγραμμα(Gantt Chart) .....                    | 45 |
| 4. Κύριο Μέρος .....  | 46 |
| 4.1 Ανάλυση Προβλήματος.....  | 46 |
| 4.1.1 Προβλήματα υπολογιστικής ισχύς .....                              | 46 |

|   |    |
|---|----|
| 4.1.2 Προβλήματα στην επεξεργασία της βάσης δεδομένων.....        | 48 |
| 4.1.4 Προβλήματα παραγωγής, γνώσης και αναγνώρισης.....           | 52 |
| 4.1.5 Απαιτήσεις Συστήματος.....                                  | 52 |
| 4.2 Σχεδιασμός Υλοποίησης.....                                    | 52 |
| 4.3 Υλοποίηση.....  | 54 |
| 4.3.1 Περιγραφή βάσης δεδομένων.....                              | 55 |
| 4.3.2 Περιγραφή υλοποίησης του συστήματος.....                    | 56 |
| 4.3.2 Αναλυτικό διάγραμμα ροής της κατασκευής του συστήματος..... | 62 |
| 5. Αποτελέσματα.....  | 63 |
| 5.1 Συμπεράσματα.....   | 70 |
| 5.2 Περιβαλλοντολογικές επιπτώσεις.....                           | 70 |
| 5.3 Μελλοντική Εργασία και Επεκτάσεις.....                        | 71 |
| Βιβλιογραφία.....   | 72 |

## Πίνακας Εικόνων

|   |    |
|---|----|
| Εικόνα 1: Ένα απλό διάγραμμα ροής, το οποίο απεικονίζει τον αλγόριθμο ελέγχου και επισκευής μιας λάμπας η οποία δεν δουλεύει. ....  | 5  |
| Εικόνα 2: Τεχνητό Νευρωνικό Δίκτυο .....  | 13 |
| Εικόνα 3: Το ρομπότ AIBO .....  | 15 |
| Εικόνα 4: Ένα self-organizing map που δείχνει το Κογκρέσο των ΗΠΑ κατά τη διάρκεια ψήφοφορίας, η οποία οπτικοποιείται σε Synapse. Τα δύο πρώτα κουτιά δείχνουν την ομαδοποίηση και τις αποστάσεις, ενώ τα υπόλοιπα δείχνουν τα επίπεδα στοιχεία. .... | 20 |
| Εικόνα 5: Μια απεικόνιση της εκπαίδευσης ενός self organizing map. ....   | 22 |
| Εικόνα 6: Μονοδιάστατος self organizing map έναντι ανάλυσης κύριων συνιστωσών (principal component analysis) (PCA) για την προσέγγιση των δεδομένων. ....   | 23 |
| Εικόνα 7: Ένα παράδειγμα learning vector quantization. ....   | 24 |
| Εικόνα 8: Μηχανική μάθηση.....  | 27 |
| Εικόνα 9: Ένα Bayesian δίκτυο το οποίο εγκαθιδρύει τις σχέσεις μεταξύ γεγονότων σχετικά με τον τομέα ασφάλισης αυτοκινήτου. ....  | 29 |
| Εικόνα 10: Το δέντρο απόφασης για τα δεδομένα του fisheriris. ....  | 31 |
| Εικόνα 11: Διαδοχική κάλυψη σφαιρικού σχήματος.....   | 32 |
| Εικόνα 12: Γενετικός αλγόριθμος.....  | 34 |
| Εικόνα 13: Παράδειγμα δέντρου απόφασης που παράγεται με τη χρήση του Weka bagging αλγορίθμου. ....  | 35 |
| Εικόνα 14: Προσαρμογή του γραμμικού ταξινομητή. Επάνω σειρά: without forgetting, .....  | 36 |
| Εικόνα 15: Το μέσο τετραγωνικό σφάλμα με την μέθοδο της Συσσωρευμένης Γενίκευσης. .   | 37 |
| Εικόνα 16: Εξελικτική βελτιστοποίηση για ένα toy problem με την βοήθεια της κωδικοποίησης διόρθωσης λαθών εξόδου. ....  | 38 |
| Εικόνα 17: Παράδειγμα εμφάνισης του φαινομένου του υπερταϊριάσματος στους ταξινομητές SVM. ....   | 40 |
| Εικόνα 18: Πρόβλεψη εξόδου του ηλιακού ενεργειακού στο Μπέρκλεϊ, Καλιφόρνια (ΗΠΑ). 42   |    |
| Εικόνα 19: Χρονοδιάγραμμα εκπόνησης πτυχιακής.....  | 45 |
| Εικόνα 20: Ο ιντερνετικός κολλοσός, Google. ....  | 47 |
| Εικόνα 21: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) των τάσεων .....   | 48 |
| Εικόνα 22: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) των τάσεων .....  | 48 |
| Εικόνα 23: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) των ενεργών φορτίων .  | 49 |
| Εικόνα 24: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) των ενεργών φορτίων .   | 49 |
| Εικόνα 25: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) της ενεργού παραγωγής  | 50 |
| Εικόνα 26: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) της ενεργού παραγωγής .   | 50 |
| Εικόνα 27: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) της ενεργού ισχύος κόμβων. ....  | 51 |
| Εικόνα 28: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) της ενεργού ισχύος κόμβων. ....   | 51 |

|  |    |
|--|----|
| Εικόνα 37:Διάγραμμα υλοποίησης. ....   | 53 |
| Εικόνα 38:Εκπαίδευση συστήματος με Back propagation. ....  | 56 |
| Εικόνα 39:Μοντέλο SVM σε δύο διαστάσεις. ....  | 58 |
| Εικόνα 40:Εκπαίδευση συστήματος με self organizing maps.....   | 59 |
| Εικόνα 41:Ένας χάρτης του κόσμου, όπου οι χώρες έχουν χρωματιστεί με το χρώμα που περιγράφει τον τύπο της φτώχειας τους (ο χρωματισμός επετεύχθει με την βοήθεια του SVM). ....    | 60 |
| Εικόνα 42:Εκπαίδευση συστήματος με learning vector quantization. ....  | 61 |
| Εικόνα 43:Codewords σε διασδιάστατο χώρο. Τα διανύσματα εισόδου σημειώνονται με x, τα codewords σημειώνονται με κόκκινο κύκλο, και οι Voronoi περιοχές χωρίζονται με γραμμές. .... | 61 |
| Εικόνα 44: Αναλυτική περιγραφή των βημάτων που ακολουθήθηκαν για την κατασκευή του συστήματος. ....  | 62 |



## Λίστα Πινάκων

|   |    |
|---|----|
| Πίνακας 1: Πίνακας με τις πιο σπουδαίες στιγμές στην ιστορία της Τεχνητής Νοημοσύνης. | 18 |
| Πίνακας 2: Πίνακας αποτελεσμάτων με τη μέθοδο SMO του αλγορίθμου SVM.....             | 64 |
| Πίνακας 3: Πίνακας αποτελεσμάτων με τη μέθοδο LS του αλγορίθμου SVM. ....             | 65 |
| Πίνακας 4: Πίνακας αποτελεσμάτων του αλγορίθμου back propagation.....                 | 67 |
| Πίνακας 5: Πίνακας αποτελεσμάτων learning vector quantization. ....                   | 68 |
| Πίνακας 6: Πίνακας αποτελεσμάτων self organizing maps. ....                           | 69 |
| Πίνακας 7: Συγκεντρωτικός πίνακας αποτελεσμάτων με τα καλύτερα ποσοστά επιτυχίας...   | 69 |

## 1. Εισαγωγή

Η παρούσα πτυχιακή εργασία, επικεντρώνεται στο τομέα της Πληροφορικής του τμήματος Εφαρμοσμένης Πληροφορικής & Πολυμέσων καθώς συνδυάζει τεχνολογίες λογισμικού οι οποίες ανήκουν στον κλάδο των ευφυών συστημάτων. Στόχος είναι η λήψη απόφασης για το εάν ένα οποιοδήποτε σύστημα ηλεκτρικής ενέργειας είναι ικανό να ανταπεξέλθει στο φόρτο εργασίας που απαιτεί μια σύγχρονη κοινωνία χωρίς να καταρεύσει. Πιο συγκεκριμένα χρησιμοποιείται η βάση δεδομένων IEEE 50 generators δυναμικής σταθερότητας η οποία περιλαμβάνει 4000 δείγματα, ικανά για να εξάγουμε τα επιθυμητά αποτελέσματα. Για τον λόγο του μεγάλου όγκου δεδομένων, σχεδιάστηκε ένα ιδιαίτερα ευφύες σύστημα το οποίο είναι ικανό να λειτουργήσει σε πραγματικό χρόνο χρησιμοποιώντας αλγορίθμους Τεχνητής Νοημοσύνης και πιο συγκεκριμένα μηχανικής μάθησης (machine learning algorithms).

### 1.1 Περίληψη

Το αντικείμενο της παρούσας πτυχιακής είναι ανάδειξη ενός σύγχρονου και πρωτοποριακού συστήματος το οποίο συνδυάζει καινοτόμες τεχνολογίες με στόχο την αξιολόγηση της σταθερότητας των υπηρεσιών που μπορεί να προσφέρει μία επιχείρηση παροχής ηλεκτρισμού. Αρχικά επιλέγεται η βάση δεδομένων η οποία έπειτα από εκτενή επεξεργασία εισάγεται σε ένα τεχνητό νευρωνικό δίκτυο. Αυτό με τη σειρά του ξεκινά την εκπαίδευση προσθέτοντας σε κάθε επανάληψη τις απαραίτητες παραμέτρους εξάγοντας στο τέλος ένα ποσοστό επιτυχίας. Το ποσοστό αυτό συμβολίζει το κατά πόσο το σύστημα είναι σε θέση να ανταποκριθεί στο μεγάλο φόρτο εργασίας χωρίς να οδηγηθεί σε αστάθεια. Με πανομοιότυπο τρόπο, αλλά με καλύτερα αποτελέσματα λειτουργεί ο αλγόριθμος support vector machine (SVM). Η αρχιτεκτονική SVM παίρνει ένα σύνολο δεδομένων εισόδου και προβλέπει, για κάθε δεδομένη είσοδο, ποια από τις δύο δυνατές καταστάσεις (stable or unstable) αποτελεί την έξοδο, καθιστώντας το έτσι ένα μη-γραμμικό δυαδικό ταξινομητή. Οι αλγόριθμοι στους οποίους έγινε αναφορά συμβάλουν στη διόρθωση τυχόν σφαλμάτων κατά την υλοποίηση εξάγοντας ταυτοχρόνως πληροφορίες οι οποίες μπορεί να είναι ελλατωματικές προκαλώντας αστάθεια στο σύστημα.

### 1.2 Κίνητρο για την Διεξαγωγή της Εργασίας

Το κίνητρο για την διεξαγωγή της εργασίας ήταν αρχικά η δημιουργία ενός πρωτοποριακού και σύγχρονου συστήματος το οποίο θα διαχειρίζεται καινοτόμα θέματα της επιστήμης υπολογιστών. Μία αρκετά ενδιαφέρουσα και ιδιαίτερα ελκυστική τεχνολογία είναι η μηχανική μάθηση, μια περιοχή της τεχνητής νοημοσύνης η οποία αφορά αλγορίθμους και μεθόδους που επιτρέπουν στους υπολογιστές να «μαθαίνουν». Έτσι λοιπόν θέλησα να μάθω

πώς είναι δυνατόν ένας υπολογιστής να μπορεί να μαθαίνει αλλά και να διορθώνεται από τα σφάλματά του χωρίς να έχει την στοιχειώδη λογική.

Η ραγδαία εξέλιξη της τεχνολογίας έχει επιφέρει σημαντικές αλλαγές στην ποιότητα υπηρεσίας που παρέχεται στους καταναλωτές. Για τον λόγο αυτό οι απαιτήσεις του κοινού είναι τεράστιες και οι επιχειρήσεις είναι υποχρεωμένες να προσφέρουν τις καλύτερες υπηρεσίες τους. Η έρευνα λοιπόν που έκανα εγώ αφορά το κατά πόσο μια επιχείρηση παροχής ηλεκτρισμού είναι σε θέση να ανταπεξέλθει στο τεράστιο φόρτο εργασίας που απαιτεί μια σύγχρονη κοινωνία χωρίς να οδηγηθεί σε blackout.

### **1.3 Σκοπός και Στόχοι**

Σκοπός της εργασίας είναι η χρήση ευφώνων αλγορίθμων μάθησης οι οποίοι θα διαχειρίζονται αποτελεσματικά, συστήματα ηλεκτρικής ενέργειας με στόχο την άμεση αξιολόγηση της ασφάλειας και τροφοδοσίας του δικτύου. Με την διαδικασία αυτή εμπλουτίζονται οι γνώσεις μου εξασκώντας παράλληλα το κομμάτι της έρευνας και ανάπτυξης καινοτόμων τεχνολογιών οι οποίες συνδράμουν στην εξέλιξη της επιστήμης υπολογιστών. Επιπροσθέτως στοχεύω στην δημοσίευση της παρούσας εργασίας στον ευρύτερο διεπιστημονικό τομέα με σκοπό την αναγνωρισιμότητα ή ακόμη και τη συνέχιση του έργου που ξεκίνησα. Έχοντας επιτύχει τα παραπάνω τότε το σύστημα θα μπορεί να γίνει εμπορικά διαθέσιμο για την άμεση εκτίμηση της σταθερότητας οποιασδήποτε επιχείρησης παροχής ηλεκτρισμού.

### **1.4 Δομή**

Η δομή της παρούσας πτυχιακής εργασίας αποτελεί την διάρθρωση ενός συνόλου καθώς και το σύνολο που χαρακτηρίζεται από μία τέτοια διάρθρωση. Η βασική ιδέα έγκειται στο κατακερματισμό σε μεμονομένα τμήματα-κεφάλαια έτσι ώστε να μπορέσει να γίνει καλύτερη επεξεργασία. Αρχικά στο κεφάλαιο 2 με τίτλο «Μεθοδολογία Υλοποίησης» γίνεται περιγραφή των παραδοχών και μεθόδων ανάπτυξης και ανάλυσης της πτυχιακής. Περιγράφονται επίσης οι αλγόριθμοι που χρησιμοποιήθηκαν για την κατασκευή του συστήματος μάθησης καθώς και τα θεωρητικά μοντέλα πάνω στα οποία βασίζεται ολόκληρο το εγχείρημα. Στη συνέχεια ακολουθεί το κεφάλαιο 3 «Σχέδιο δράσης για την εκπόνηση του συστήματος», το οποίο ασχολείται με την βιβλιογραφική αναζήτηση της τεχνολογίας αιχμής (state of the art) και την υλοποίηση του σχεδίου δράσης για την εκπόνηση της εργασίας. Έπειτα στο κεφάλαιο 4 «Κύριο Μέρος» γίνεται αναφορά στην ανάλυση του προβλήματος, στις απαιτήσεις του συστήματος, καθώς επίσης και στο σχεδιασμό της υλοποίησης. Πιο συγκεκριμένα η ανάλυση του προβλήματος περιλαμβάνει με λεπτομέρεια όλες εκείνες τις δυσκολίες που προέκυψαν κατά τη διάρκεια κατασκευής του συστήματος και πως αυτές κατάφεραν να αντιμετωπιστούν με πλήρη επιτυχία. Οι απαιτήσεις συστήματος αφορούν όλους εκείνους τους περιορισμούς που θα πρέπει να ικανοποιεί μια μηχανή προκειμένου να μπορέσει να ανταπεξέλθει πλήρως στο τεράστιο φόρτο εργασίας. Ο σχεδιασμός υλοποίησης

είναι ίσως ένα από τα πιο σημαντικά σημεία στη διαδικασία κατασκευής καθώς συνδυάζει το πειραματικό με το θεωρητικό κομμάτι. Συνεπώς για την ορθότερη κατανόηση της όλης ιδέας κρίθηκε απαραίτητος ο σχεδιασμός της διαδικασίας υλοποίησης μέσα σε 4 απλά βήματα. Τελευταίο στάδιο αποτελεί η υλοποίηση στην οποία περιγράφεται αναλυτικά η λειτουργία κάθε αλγορίθμου που χρησιμοποιήθηκε για την περάτωση του συστήματος. Στο κεφάλαιο 5 «Αποτελέσματα», παρατίθενται αναλυτικά πινακάκια με τα ποσοστά επιτυχίας που εξήγαγε ο κάθε αλγόριθμος καθώς επίσης και τα ωφέλη που μπορεί να αποκομίσει κανείς από αυτή την έρευνα. Επακόλουθο των αποτελεσμάτων αποτελούν τα συμπεράσματα, τα οποία βοηθούν στην τελική λήψη της βέλτιστης απόφασης. Τέλος, πραγματοποιείται αναφορά στις μελλοντικές επεκτάσεις οι οποίες θα οδηγήσουν το σύστημα στην αρτιότερη βελτιστοποίησή του.

## 2. Μεθοδολογία Υλοποίησης

Μεθοδολογία είναι ένα σύνολο μεθόδων, άρχων και κανόνων για την ρύθμιση ενός δεδομένου γνωστικού αντικειμένου όπως στις τέχνες και τις επιστήμες. Η διαδικασία υλοποίησης ενός έργου ξεκινάει με τον καθορισμό του. Παράλληλα ελέγχεται η εφικτότητα του έργου σε τεχνικό, λειτουργικό, οικονομικό, και διοικητικό επίπεδο. Η τεχνική εφικτότητα περιλαμβάνει την τεχνολογία και την τεχνογνωσία που είναι διαθέσιμες για την υλοποίηση του έργου, η λειτουργική την εκτίμηση ανταπόκρισης του έργου στους επιδιωκόμενους σκοπούς, η οικονομική το κατά πόσο το έργο έχει θετική αξία (κέρδος). Η εφικτότητα συμπεριφοράς προσωπικού περιλαμβάνει τις επιδράσεις του έργου στην ποιότητα εργασίας, καθώς επίσης και στην εύκολη εισαγωγή και ενσωμάτωση του έργου στην καθημερινότητα της επιχείρησης. [1]

### 2.1 Μέθοδος Ανάλυσης & Ανάπτυξης Συστήματος

Από την ανάθεση μέχρι και την ολοκλήρωση της παρούσας πτυχιακής εργασίας, χρειάστηκε να αντιμετωπιστούν και να επιλυθούν πολλαπλά προβλήματα από το πρώτο μέχρι και το τελευταίο στάδιό της. Συνοπτικά η εργασία χωρίζεται σε τρεις κύριους τομείς εκ των οποίων ο καθένας είναι άρρηκτα συνδεδεμένος με τον άλλο και όλοι μαζί συμβάλλουν στην ομαλή λειτουργία του συστήματος.

Σε πρώτο στάδιο γεννήθηκε η ιδέα του πειράματος που οδήγησε στη συλλογή τεράστιου όγκου πληροφοριών χρήσιμων για την κατανόηση και εμπέδωση του προβλήματος. Έτσι ύστερα από εκτενή μελέτη και έρευνα καταλήγουμε στην βάση δεδομένων πάνω στην οποία θα στηθεί ολόκληρο το σύστημα. Λόγω του τεράστιου όγκου δεδομένων που εμπεριέχονται στην βάση δεδομένων κρίνεται απαραίτητη η δημιουργία ευφυούς συστήματος διαχείρισής της το οποίο θα εκμεταλλεύεται στο έπακρο τον υπολογιστικό χώρο και χρόνο.

Στη συνέχεια η πληροφορία εισέρχεται στο σύστημα το οποίο διαχειρίζονται τρεις διαφορετικοί κάθε φορά αλγόριθμοι. Οι αλγόριθμοι που αναλαμβάνουν να διαχειριστούν τη βάση δεδομένων χωρίζονται σε δύο μεγάλες κατηγορίες. Η πρώτη αναφέρεται στη θεωρία των τεχνητών νευρωνικών δικτύων και η δεύτερη στη θεωρία των support vector machines. Θα τις δούμε αναλυτικότερα και τις δυο σε επόμενα κεφάλαια. Συνεπώς στην κατηγορία των τεχνητών νευρωνικών δικτύων ανήκουν οι εξής αλγόριθμοι: feed-forward backpropagation, self organizing maps και learning vector quantization, οι οποίοι λειτουργούν με παρόμοια λογική, εξάγοντας όμως διαφορετικά αποτελέσματα. Οι τρεις αυτοί αλγόριθμοι εκπαιδεύουν το σύστημα μέσα από μια διαδικασία ανατροφοδότησης και επανεκπαίδευσης των διαφόρων δειγμάτων τους.

Η δεύτερη κατηγορία όπως αναφέρθηκε βασίζεται στην αρχιτεκτονική των support vector machines (SVM). Παίρνει δηλαδή ένα σύνολο δεδομένων εισόδου και προβλέπει, για κάθε δεδομένη είσοδο, ποια από τις δύο δυνατές καταστάσεις (stable or unstable) αποτελεί την έξοδο. Η ταξινόμηση των δειγμάτων πρέπει να είναι σαφής και να παρέχει μοναδικά χαρακτηριστικά ικανά για την ορθή λήψη απόφασης. Μέσω χρήσης και έρευνας των

παραπάνω αλγορίθμων προέκυψε το τελικό αποτέλεσμα, το οποίο είναι ιδιαίτερα ικανοποιητικό και ρεαλιστικό. Οι παραπάνω αλγόριθμοι δεν είναι μόνο διαφορετικοί στη λειτουργία τους, αλλά και στο αποτέλεσμα που παρέχουν καθώς στηρίζονται σε διαφορετικές ο καθένας θεωρίες. Η ανάλυση για το υπόβαθρο πάνω στο οποίο στηρίζεται ο καθένας τους θα πραγματοποιηθεί σε επόμενο κεφάλαιο.

### 2.1.1 Αλγόριθμοι

Ως αλγόριθμος ορίζεται μια πεπερασμένη σειρά ενεργειών, αυστηρά καθορισμένων και εκτελέσιμων σε πεπερασμένο χρόνο, που στοχεύουν στην επίλυση ενός προβλήματος. Πιο απλά αλγόριθμο ονομάζουμε μία σειρά από εντολές που έχουν αρχή και τέλος, είναι σαφείς και εκτελέσιμες που σκοπό έχουν την επίλυση κάποιου προβλήματος.

Η λέξη αλγόριθμος προέρχεται από μία μελέτη του Πέρση μαθηματικού του 8ου αιώνα μ.Χ. Αλ Χουαρίζμι (Abu Ja'far Mohammed ibn Musa Al-Khowarismi), η οποία περιείχε συστηματικές τυποποιημένες λύσεις αλγεβρικών προβλημάτων και αποτελεί ίσως την πρώτη πλήρη πραγματεία άλγεβρας. Πέντε αιώνες αργότερα η μελέτη μεταφράστηκε στα Λατινικά και άρχισε με τη φράση "Algorithmi dixit ...." (ο Αλγόριθμος λέει ...). Έτσι η λέξη αλγόριθμος καθιερώθηκε αργά τα επόμενα χίλια χρόνια με την έννοια «συστηματική διαδικασία αριθμητικών χειρισμών». Τη σημερινή της σημασία την οφείλει στη γρήγορη ανάπτυξη των ηλεκτρονικών υπολογιστών στα μέσα του 20ου αιώνα.



Εικόνα 1: Ένα απλό διάγραμμα ροής, το οποίο απεικονίζει τον αλγόριθμο ελέγχου και επισκευής μιας λάμπας η οποία δεν δουλεύει.

Η έννοια του αλγορίθμου γίνεται ευκολότερα αντιληπτή με το παρακάτω παράδειγμα. Αν κάποιος επιθυμεί να γευματίσει θα πρέπει να εκτελέσει κάποια συγκεκριμένα βήματα: να συγκεντρώσει τα υλικά, να προετοιμάσει τα σκεύη μαγειρικής, να παρασκευάσει το φαγητό, να στρώσει το τραπέζι, να ετοιμάσει τη σαλάτα, να γευματίσει, να καθαρίσει το τραπέζι και να πλύνει τα πιάτα. Προφανώς, η προηγούμενη αλληλουχία οδηγεί στο επιθυμητό αποτέλεσμα. Δεν είναι όμως η μοναδική για την επίτευξη του σκοπού, αφού μπορεί να αλλάξει η σειρά των βημάτων (π.χ. πρώτα να ετοιμάσει τη σαλάτα και μετά να στρώσει το τραπέζι). Ωστόσο το νόημα είναι πως η κατάτμηση μιας σύνθετης εργασίας σε διακριτά βήματα που εκτελούνται διαδοχικά, είναι ο πιο πρακτικός τρόπος επίλυσης πολλών προβλημάτων.

Οι αλγόριθμοι είναι σημαντικοί γιατί σχετίζονται άμεσα με τον τρόπο με τον οποίο οι υπολογιστές επεξεργάζονται δεδομένα και παράγουν πληροφορίες. Ένα πρόγραμμα υπολογιστών είναι ουσιαστικά ένας αλγόριθμος που λέει στον υπολογιστή ποια συγκεκριμένα βήματα να εκτελέσει (σε ποια συγκεκριμένη σειρά) προκειμένου να επιτευχθεί ένας συγκεκριμένος στόχος, όπως π.χ. ο υπολογισμός των μισθών των υπαλλήλων ή η εκτύπωση των έλεγχων των μαθητών. Κατά συνέπεια, ένας αλγόριθμος μπορεί να θεωρηθεί οποιαδήποτε ακολουθία εντολών που μπορεί να εκτελεσθεί από μια υπολογιστική μηχανή (turing). Χαρακτηριστικά, όταν ένας αλγόριθμος συνδέεται με την επεξεργασία πληροφοριών, τα δεδομένα διαβάζονται από μια συσκευή εισόδου, γράφονται σε μια συσκευή εξόδου, και / ή αποθηκεύονται για την περαιτέρω χρήση. Τα αποθηκευμένα στοιχεία θεωρούνται ως τμήμα της εσωτερικής κατάστασης του συστήματος που εκτελεί τον αλγόριθμο. Για οποιαδήποτε τέτοια υπολογιστική διαδικασία, ο αλγόριθμος πρέπει να οριστεί αυστηρά: να είναι ορισμένος για όλες τις πιθανές περιστάσεις που θα μπορούσαν να προκύψουν. Δηλαδή οποιαδήποτε υπό όρους βήματα πρέπει να εξεταστούν συστηματικά, και σε κάθε περίπτωση τα κριτήρια πρέπει να είναι σαφή (και υπολογίσιμα). Επειδή ένας αλγόριθμος είναι ένας ακριβής κατάλογος βημάτων ακριβείας, η σειρά του υπολογισμού θα είναι σχεδόν πάντα κρίσιμη για τη λειτουργία του αλγόριθμου. Οι εντολές συνήθως απαριθμούνται ρητά, και περιγράφονται σαν να ξεκινούν "από την κορυφή" και πηγαίνοντας "προς στο κατώτατο σημείο", μια ιδέα που περιγράφεται τυπικά με τον όρο της "ροής ελέγχου". Μέχρι τώρα, σε αυτήν η συζήτηση για την τυποποίηση του αλγορίθμου, έχουμε δεχθεί ως βάση τον διαδικαστικό προγραμματισμό. Αυτή είναι και η πιο κοινή αντίληψη, η οποία προσπαθεί να περιγράψει ένα έργο με διακεκριμένα, "μηχανικά" μέσα. Μοναδικός σε αυτήν την αντίληψη των αλγορίθμων είναι ο ρόλος της λειτουργίας ανάθεσης (ο καθορισμός της τιμής μιας μεταβλητής) ο οποίος προέρχεται από τη ιδέα "της μνήμης" σαν πρόχειρο τετράδιο.

Οι αλγόριθμοι μπορούν να υλοποιηθούν από προγράμματα ηλεκτρονικών υπολογιστών, μολοντί συχνά σε περιορισμένες μορφές. Ένα λάθος στον σχεδιασμό ενός αλγορίθμου για την λύση ενός προβλήματος μπορεί να οδηγήσει σε αποτυχίες/βλάβες στο εφαρμοσμένο πρόγραμμα. Οι αλγόριθμοι δεν υλοποιούνται μόνο ως προγράμματα υπολογιστών, αλλά συχνά επίσης και με άλλα μέσα, όπως π.χ. σε ένα βιολογικό νευρικό δίκτυο, ή σε ένα ηλεκτρονικό κύκλωμα, ή σε μια μηχανική συσκευή. Η ανάλυση και η μελέτη των αλγορίθμων είναι ένας τομέας της επιστήμης της πληροφορικής, και ασκείται συχνά αφαιρετικά (χωρίς τη χρήση μιας συγκεκριμένης γλώσσας προγραμματισμού ή άλλη εφαρμογή). Από αυτή την άποψη, μοιάζει με άλλους μαθηματικούς τομείς, συγκεκριμένα στο ότι η εστίαση της ανάλυσης είναι πάνω στις βασικές αρχές του αλγορίθμου, και όχι σε

οποιαδήποτε ιδιαίτερη εφαρμογή του. Ένας τρόπος απεικόνισης ένας αλγόριθμου είναι το γράψιμο του ψευδοκώδικα. Άλλοι τρόποι είναι: με ελεύθερο κείμενο , με φυσική γλώσσα περιγράφοντας τα βήματα και με λογικό διάγραμμα .

Στην παρούσα πτυχιακή εργασία χρησιμοποιούνται τέσσερις αλγόριθμοι οι οποίοι διαχειρίζονται αποτελεσματικά, συστήματα ηλεκτρικής ενέργειας με στόχο την άμεση αξιολόγηση της ασφάλειας και τροφοδοσίας του δικτύου.

Ο αλγόριθμος feed-forward backpropagation. Το νευρωνικό δίκτυο είναι ένα δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες, νευρώνια), διασυνδεδεμένους μεταξύ τους. Κάθε τέτοιος κόμβος δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί έναν υπολογισμό με βάση αυτές τις εισόδους και παράγει μία έξοδο. Η εν λόγω έξοδος είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου. Υπάρχουν τρεις τύποι νευρώνων: οι νευρώνες εισόδου, οι νευρώνες εξόδου και οι υπολογιστικοί νευρώνες ή κρυμμένοι νευρώνες. Οι νευρώνες εισόδου δεν επιτελούν κανέναν υπολογισμό, μεσολαβούν απλώς ανάμεσα στις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες. Οι νευρώνες εξόδου διοχετεύουν στο περιβάλλον τις τελικές αριθμητικές εξόδους του δικτύου. Οι υπολογιστικοί νευρώνες πολλαπλασιάζουν κάθε είσοδό τους με το αντίστοιχο συναπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Το άθροισμα αυτό τροφοδοτείται ως όρισμα στη συνάρτηση ενεργοποίησης, την οποία υλοποιεί εσωτερικά κάθε κόμβος. Η τιμή που λαμβάνει η συνάρτηση για το εν λόγω όρισμα είναι και η έξοδος του νευρώνα για τις τρέχουσες εισόδους και βάρη.

Μια άλλη προσέγγιση βασίζεται στην θεωρία των support vector machines (SVMs). Στη μηχανική μάθηση, τα support vector machines (SVMs) εποπτεύονται μοντέλα μάθησης με συνδεδεμένους αλγόριθμους μάθησης οι οποίοι αναλύουν δεδομένα και αναγνωρίζουν πρότυπα, που χρησιμοποιούνται για την ταξινόμηση και την ανάλυση παλινδρόμησης. Η βασική SVM παίρνει ένα σύνολο δεδομένων εισόδου και προβλέπει, για κάθε δεδομένη είσοδο, ποια από τις δύο πιθανές καταστάσεις αποτελεί την έξοδο, καθιστώντας το ένα μη-γραμμικό δυαδικό ταξινομητή. Λαμβάνοντας υπόψη ένα σύνολο παραδειγμάτων εκπαίδευσης, ένας αλγόριθμος SVM χτίζει ένα μοντέλο που εκχωρεί νέα δείγματα σε μία από τις καταστάσεις. Ένα μοντέλο SVM είναι μια αναπαράσταση των δειγμάτων ως σημεία στο χώρο, τα οποία χαρτογραφούνται έτσι ώστε τα δείγματα διαφορετικών κατηγοριών να μπορούν να διαχωρίζονται όσο το δυνατόν καλύτερα. Εκτός από την εκτέλεση γραμμικής ταξινόμησης, τα SVMs μπορούν να εκτελέσουν το ίδιο αποτελεσματικά και την μη-γραμμική ταξινόμηση.

Ο αλγόριθμος self organizing maps(SOMs). Έχει εκπαιδευτεί χρησιμοποιώντας μάθηση χωρίς επίβλεψη για την παραγωγή ενός χαμηλού διαστάσεων (συνήθως δύο διαστάσεων), ευδιάκριτου στην αναπαράσταση χώρου εισόδου των δειγμάτων εκπαίδευσης, που ονομάζεται χάρτης. Ο αυτο-οργανώμενος χάρτης είναι διαφορετικός από τα άλλα τεχνητά νευρωνικά δίκτυα, με την έννοια ότι χρησιμοποιεί μια συνάρτηση γειτονιάς για να διατηρήσει τις τοπολογικές ιδιότητες του χώρου εισόδου. Ο στόχος της μάθησης στα self organizing maps (SOMs) είναι να προκαλέσει διάφορα μέρη του δικτύου να ανταποκριθούν με παρόμοιο τρόπο σε ορισμένα πρότυπα εισόδου. Αυτό οφείλεται εν μέρει από το πόσο οι οπτικές, ακουστικές ή άλλες αισθητήριες πληροφορίες χειρίζονται σε χωριστά τμήματα του εγκεφαλικού φλοιού στον ανθρώπινο εγκέφαλο.

Ο τελευταίος αλγόριθμος ονομάζεται Learning vector quantization (LVQ) και είναι ένας πρωτότυπος αλγόριθμος που βασίζεται στην μάθηση με επίβλεψη και αφορά τη



διαδικασία κβαντισμού διανυσμάτων διαφόρων συστημάτων. Έχει ως κύρια βάση του τα τεχνητά νευρωνικά δίκτυα και μπορεί να περιγραφεί πιο απλά ως εξής: για κάθε σημείο δεδομένων, το πρωτότυπο το οποίο είναι πλησιέστερα προς την είσοδο, σύμφωνα με ένα δεδομένο μέτρο απόστασης ανακηρύσσεται νικητής και στη συνέχεια προσαρμόζεται στη συγκεκριμένη θέση, δηλαδή ο νικητής πλησιάζει αν ταξινομεί σωστά το σημείο δεδομένων ή απομακρύνεται, εφόσον κατατάξει το σημείο δεδομένων λανθασμένα.

## 2.2 Θεωρίες

Μια θεωρία, με τη γενική έννοια, είναι μια αναλυτική δομή, σχεδιασμένη για να εξηγήσει ένα σύνολο από παρατηρήσεις. Μια θεωρία έχει δυο λειτουργίες: αναγνωρίζει το σύνολο αυτό των διακεκριμένων παρατηρήσεων, ως μια ομάδα φαινομένων, και διατυπώνει ισχυρισμούς για την υποκείμενη πραγματικότητα που επιφέρει ή προκαλεί την ομάδα αυτών των παρατηρήσεων. Ο όρος χρησιμοποιείται συχνά στην καθομιλουμένη αναφερόμενος σε οποιαδήποτε επεξηγηματική σκέψη, ακόμα και φαντασιόπληκτες ή κερδοσκοπικές, αλλά στην ακαδημαϊκή του χρήση χρησιμοποιείται για ιδέες που ικανοποιούν κάποιες βασικές απαιτήσεις για το είδος των παρατηρήσεων, τις μεθόδους κατηγοριοποίησής τους, και τη συνέπεια της θεωρίας στην εφαρμογή της σε μέλη της κάθε κατηγορίας. Οι απαιτήσεις αυτές ποικίλουν ανάμεσα σε διαφορετικά πεδία γνώσης, αλλά γενικά οι θεωρίες αναμένεται να είναι χρηστικές και φειδωλές: δηλαδή μια θεωρία θα πρέπει να είναι το απλούστερο δυνατό εργαλείο που μπορεί να χρησιμοποιηθεί για να εξηγήσει ικανοποιητικά τη δεδομένη ομάδα φαινομένων.

Οι θεωρίες είναι διαφορετικές από τα θεωρήματα: τα θεωρήματα συνεπάγονται από θεωρίες σύμφωνα με κάποιο τυπικό σύστημα κανόνων, γενικά σαν πρώτο βήμα στη δοκιμή ή εφαρμογή της θεωρίας σε μια συγκεκριμένη κατάσταση. Οι θεωρίες είναι αφηρημένες και εννοιολογικές, και επομένως δεν θεωρούνται ποτέ ως σωστές ή λανθασμένες. Αντίθετα, στηρίζονται ή προκαλούνται από παρατηρήσεις στον κόσμο. Είναι αυστηρά δοκιμαστικές, με την έννοια ότι προτείνονται ως αλήθεια, αλλά αναμένεται ότι ικανοποιούν προσεκτική εξέταση για διερεύνηση της πιθανότητας λανθασμένων συμπερασμάτων, ή λανθασμένων παρατηρήσεων. Μερικές φορές οι θεωρίες διαψεύδονται, δηλαδή υπάρχει ένα συγκεκριμένο σύνολο παρατηρήσεων που αντικρούει κάποια στοιχειώδη υπόθεση της θεωρίας. Συχνότερα οι θεωρίες ανασκευάζονται ώστε να συμμορφώνονται με τις νέες παρατηρήσεις, είτε περιορίζοντας την κατηγορία φαινομένων στα οποία εφαρμόζεται η θεωρία, είτε αλλάζοντας τους ισχυρισμούς. Ενίοτε μια θεωρία παραμερίζεται από τους επιστήμονες επειδή δεν γίνεται να εξεταστούν οι ισχυρισμοί της αναλυτικά. Οι ισχυρισμοί αυτοί μπορεί να συνεχιστούν στην λαϊκή φαντασία σε μια τέτοια περίπτωση, μέχρι να ανακαλυφθεί κάποιος τρόπος εξέτασης που είτε διαψεύδει είτε ενισχύει τη θεωρία.[8]

### 2.2.1 Τεχνητά νευρωνικά δίκτυα

Νευρωνικό δίκτυο ονομάζεται ένα κύκλωμα διασυνδεδεμένων νευρώνων. Στην περίπτωση βιολογικών νευρώνων, πρόκειται για ένα τμήμα νευρικού ιστού. Στην περίπτωση τεχνητών νευρώνων, πρόκειται για ένα αφηρημένο αλγοριθμικό κατασκεύασμα το οποίο εμπίπτει στον τομέα της υπολογιστικής νοημοσύνης, όταν στόχος του νευρωνικού δικτύου είναι η επίλυση κάποιου υπολογιστικού προβλήματος, ή της υπολογιστικής νευροεπιστήμης, όταν στόχος είναι η υπολογιστική προσομοίωση της λειτουργίας των βιολογικών νευρωνικών δικτύων με βάση κάποιο μαθηματικό μοντέλο τους.

Το νευρωνικό δίκτυο είναι ένα δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες, νευρώνια), διασυνδεδεμένους μεταξύ τους. Είναι εμπνευσμένο από το Κεντρικό Νευρικό Σύστημα (ΚΝΣ), το οποίο προσπαθεί να προσομοιώσει.

Οι νευρώνες είναι τα δομικά στοιχεία του δικτύου. Κάθε τέτοιος κόμβος δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί έναν υπολογισμό με βάση αυτές τις εισόδους και παράγει μία έξοδο. Η εν λόγω έξοδος είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου. Υπάρχουν τρεις τύποι νευρώνων: οι νευρώνες εισόδου, οι νευρώνες εξόδου και οι υπολογιστικοί νευρώνες ή κρυμμένοι νευρώνες. Οι νευρώνες εισόδου δεν επιτελούν κανέναν υπολογισμό, μεσολαβούν απλώς ανάμεσα στις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες. Οι νευρώνες εξόδου διοχετεύουν στο περιβάλλον τις τελικές αριθμητικές εξόδους του δικτύου. Οι υπολογιστικοί νευρώνες πολλαπλασιάζουν κάθε είσοδό τους με το αντίστοιχο συναπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Το άθροισμα αυτό τροφοδοτείται ως όρισμα στη συνάρτηση ενεργοποίησης, την οποία υλοποιεί εσωτερικά κάθε κόμβος. Η τιμή που λαμβάνει η συνάρτηση για το εν λόγω όρισμα είναι και η έξοδος του νευρώνα για τις τρέχουσες εισόδους και βάρη. Εάν  $x_{ki}$  είναι η  $i$ -οστή είσοδος του  $k$  νευρώνα,  $W_{ki}$ : το  $i$ -οστό συναπτικό βάρος του  $k$  νευρώνα και  $\phi(\cdot)$  η συνάρτηση ενεργοποίησης του νευρωνικού δικτύου, τότε η έξοδος  $y_k$  του  $k$  νευρώνα δίνεται από την εξίσωση:

$$y_k = \phi \left( \sum_{i=0}^N x_{ki} W_{ki} \right)$$

Στον  $k$ -οστό νευρώνα υπάρχει ένα συναπτικό βάρος  $W_{k0}$  με ιδιαίτερη σημασία, το οποίο καλείται **πόλωση** ή **κατώφλι** (bias, threshold). Η τιμή της εισόδου του είναι πάντα η μονάδα,  $X_{k0}=1$ . Εάν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο από την τιμή αυτή, τότε ο νευρώνας ενεργοποιείται. Εάν είναι μικρότερο, τότε ο νευρώνας παραμένει ανενεργός. Η ιδέα προέκυψε από τα βιολογικά νευρικά κύτταρα

Όπως είναι φανερό, οι αριθμοί οι οποίοι συναποτελούν το διάνυσμα εισόδου (κάθε στοιχείο του διανύσματος τροφοδοτείται κατά τη λειτουργία του δικτύου σε έναν νευρώνα εισόδου), αλλά και οι αριθμοί οι οποίοι συναποτελούν το διάνυσμα εξόδου (κάθε στοιχείο του οποίου εμφανίζεται, μετά το πέρας του ολικού υπολογισμού, σε έναν νευρώνα εξόδου), περιγράφουν χαρακτηριστικά του προς επίλυση προβλήματος. Συνήθως αυτό που μας ενδιαφέρει είναι το δίκτυο να απεικονίζει με ορθό τρόπο διανύσματα εισόδου σε κατάλληλα διανύσματα εξόδου, το πρόβλημα δηλαδή είναι η υλοποίηση μίας συνάρτησης πολλαπλών μεταβλητών, κατά κανόνα περίπλοκης και με άγνωστο ακριβή τύπο. Τέτοιες απεικονίσεις έχουν εφαρμογή σε ποικιλία τομέων της επιστήμης και της τεχνολογίας, αφού λειτουργούν

ως αριθμητικά μοντέλα για πολλά διαφορετικά ζητήματα. Το ίδιο δίκτυο μπορεί να υλοποιήσει άπειρες διαφορετικές απεικονίσεις, μία για κάθε διαφορετική επιλογή συνόλου συναπτικών βαρών.

Το κύριο χαρακτηριστικό των νευρωνικών δικτύων είναι η εγγενής ικανότητα μάθησης. Ως μάθηση μπορεί να οριστεί η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα (π.χ. η σταδιακή προσέγγιση μίας συνάρτησης). Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, μίας επαναληπτικής διαδικασίας σταδιακής προσαρμογής των παραμέτρων του δικτύου (συνήθως των βαρών και της πόλωσής του) σε τιμές κατάλληλες ώστε να επιλύεται με επαρκή επιτυχία το προς εξέταση πρόβλημα. Αφού ένα δίκτυο εκπαιδευτεί, οι παράμετροί του συνήθως «παγώνουν» στις κατάλληλες τιμές και από εκεί κι έπειτα είναι σε λειτουργική κατάσταση. Το ζητούμενο είναι το λειτουργικό δίκτυο να χαρακτηρίζεται από μία ικανότητα γενίκευσης: αυτό σημαίνει πως δίνει ορθές εξόδους για εισόδους καινοφανείς και διαφορετικές από αυτές με τις οποίες εκπαιδεύτηκε.

Η συνάρτηση ενεργοποίησης μπορεί να είναι βηματική (step transfer function), γραμμική (linear transfer function), μη γραμμική (non-linear transfer function), στοχαστική (stochastic transfer function).

**Η βηματική συνάρτηση ενεργοποίησης μπορεί να είναι:**

$$\phi(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

ή οποιαδήποτε άλλη βηματική συνάρτηση.

Η βηματική συνάρτηση δεν θεωρείται χρήσιμη ως συνάρτηση ενεργοποίησης στα ΤΝΔ (Τεχνητά Νευρωνικά Δίκτυα), καθώς σύμφωνα με τον απειροστικό λογισμό έχει το βασικό μειονέκτημα να είναι η παράγωγός της ίση με μηδέν. Έτσι προέκυψε η ανάγκη συναρτήσεων ενεργοποίησης που η γραφική τους παράσταση τους να μοιάζει με τη βηματική, αλλά ταυτόχρονα να είναι συνεχείς και παραγωγίσιμες σε όλο το πεδίο ορισμού τους.

**Η γραμμική συνάρτηση ενεργοποίησης μπορεί να είναι:**

$$\phi(x) = x$$

ή οποιαδήποτε άλλη γραμμική συνάρτηση.

**Η μη γραμμική συνάρτηση ενεργοποίησης μπορεί να είναι η σιγμοειδής συνάρτηση. Οι τυπικές σιγμοειδείς είναι δύο:**

Λογιστική σιγμοειδής:

$$\phi(x) = \frac{1}{1 + e^x}$$

Υπερβολική εφαπτομένη:

$$\phi(x) = \tanh x$$

Τα τελευταία χρόνια έχει υπάρξει μία έκρηξη ενδιαφέροντος για τα νευρωνικά δίκτυα καθώς εφαρμόζονται με μεγάλη επιτυχία σε ένα ασυνήθιστα μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, όπως τα χρηματοοικονομικά, η ιατρική, η επιστήμη μηχανικού, η γεωλογία, η φυσική, η ρομποτική, η επεξεργασία σήματος κτλ. Στην πραγματικότητα, τα νευρωνικά δίκτυα εισάγονται οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου. Η σαρωτική αυτή επιτυχία, μπορεί να αποδοθεί σε δύο βασικά στοιχεία: την ισχύ και την ευχρηστία.[14]

**Ισχύς:** Τα νευρωνικά δίκτυα είναι πολύ εξελιγμένες τεχνικές μη γραμμικής μοντελοποίησης, ικανές να μοντελοποιήσουν εξαιρετικά πολύπλοκες λειτουργίες. Η γραμμική μοντελοποίηση υπήρξε ευρέως διαδεδομένη για πολύ καιρό, δεδομένου ότι στα γραμμικά μοντέλα εφαρμόζονται πολύ γνωστές στρατηγικές βελτιστοποίησης. Στις συνήθειες, όμως, περιπτώσεις όπου η γραμμική προσέγγιση δεν ήταν έγκυρη, τα μοντέλα αυτά αποτύγχαναν αναλόγως. Τα νευρωνικά δίκτυα βέβαια, αν και επιτρέπουν τη μη γραμμικότητα μέσω χρήσης μη γραμμικών συναρτήσεων ενεργοποίησης, μεταθέτουν με τη σειρά τους το πρόβλημα στο ζήτημα της διάστασης (του πλήθους των διαφορετικών εισόδων και εξόδων), το οποίο αποτελεί αγκάθι στις προσπάθειες μοντελοποίησης μη γραμμικών συναρτήσεων με μεγάλο αριθμό μεταβλητών.

**Ευχρηστία:** Τα νευρωνικά δίκτυα εκπαιδεύονται με παραδείγματα. Ο χρήστης συγκεντρώνει αντιπροσωπευτικά δεδομένα και στη συνέχεια, καθώς τα τροφοδοτεί συστηματικά στο δίκτυο μέσω των κατάλληλων αλγορίθμων εκπαίδευσης, το δίκτυο «αντιλαμβάνεται» αυτομάτως τη δομή των δεδομένων και η «γνώση» αυτή εκφράζεται ως κατάλληλες επιλογές συναπτικών βαρών. Επομένως το τελικό αποτέλεσμα της εκπαίδευσης με ένα συγκεκριμένο σύνολο παραδειγμάτων είναι ο προσδιορισμός των κατάλληλων βαρών του δικτύου. Ο χρήστης χρειάζεται να έχει κάποιες ουσιαστικές γνώσεις σχετικά με τον τρόπο επιλογής και προετοιμασίας των δεδομένων, τον τρόπο εκλογής του κατάλληλου νευρωνικού δικτύου και στο πως θα ερμηνευτούν τα αποτελέσματα. Παρά ταύτα, το επίπεδο των γνώσεων του χρήστη που απαιτούνται για μια επιτυχημένη εφαρμογή των νευρωνικών δικτύων, είναι πολύ χαμηλότερο συγκριτικά με κάποια περίπτωση που θα χρησιμοποιούνταν ορισμένες πιο παραδοσιακές, μη γραμμικές στατιστικές μέθοδοι.

Τα νευρωνικά δίκτυα είναι εφαρμόσιμα σχεδόν σε κάθε κατάσταση στην οποία ισχύει μια σχέση μεταξύ μεταβλητών πρόβλεψης (ανεξάρτητες, εισροές) και προβλεπόμενες μεταβλητές (εξαρτημένες, εκροές), ακόμα και όταν αυτή η σχέση είναι πολύ περίπλοκη για να αποδοθεί με τους συνηθισμένους όρους της «συσχέτισης» ή των «διαφόρων ομάδων». Ενδεικτικά αντιπροσωπευτικά παραδείγματα προβλημάτων στα οποία η ανάλυση των νευρωνικών δικτύων έχει εφαρμοστεί με επιτυχία είναι τα εξής:

**Ιατρική διάγνωση:** Ένα ευρύ φάσμα ιατρικά συσχετιζόμενων ενδείξεων, όπως ο συνδυασμός της καρδιακής συχνότητας, τα επίπεδα των διαφόρων ουσιών στο αίμα, ο ρυθμός της αναπνοής μπορούν να παρακολουθηθούν. Η εκδήλωση μιας συγκεκριμένης ιατρικής κατάστασης, γίνεται να συσχετιστεί με ένα πολύπλοκο συνδυασμό μεταβολών σε ένα υποσύνολο μεταβλητών που παρακολουθούνται. Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την αναγνώριση αυτού του προτύπου πρόβλεψης, ώστε να χορηγηθεί η

κατάλληλη θεραπεία.

Χρηματιστηριακές προβλέψεις: Οι διακυμάνσεις των τιμών των μετοχών και των χρηματιστηριακών δεικτών είναι ακόμα ένα παράδειγμα ενός πολύπλοκου, πολυδιάστατου, αλλά και σε ορισμένες περιπτώσεις εν μέρει ντετερμινιστικού φαινομένου. Τα νευρωνικά δίκτυα χρησιμοποιούνται από πολλούς τεχνικούς αναλυτές, ώστε να κάνουν προβλέψεις σχετικά με τις τιμές των μετοχών, βασιζόμενοι σε ένα μεγάλο αριθμό παραγόντων, όπως δηλαδή, τις προηγούμενες επιδόσεις άλλων αποθεμάτων και διαφόρων οικονομικών δεικτών.

Πιστωτική ανάθεση: Μια ποικιλία από κομμάτια πληροφοριών, τα οποία είναι συνήθως γνωστά για ένα απαιτούμενο δάνειο. Για παράδειγμα, η ηλικία του αιτούντος, η εκπαίδευση, το επάγγελμα και πολλά άλλα στοιχεία που μπορεί να είναι διαθέσιμα. Μετά την εκπαίδευση ενός νευρωνικού δικτύου σε ιστορικά δεδομένα η ανάλυση μπορεί να εκτοπίσει τα πιο κατάλληλα και σχετικά χαρακτηριστικά και να τα χρησιμοποιήσει για την ταξινόμηση των αιτούντων ως χαμηλού ή υψηλού κινδύνου.

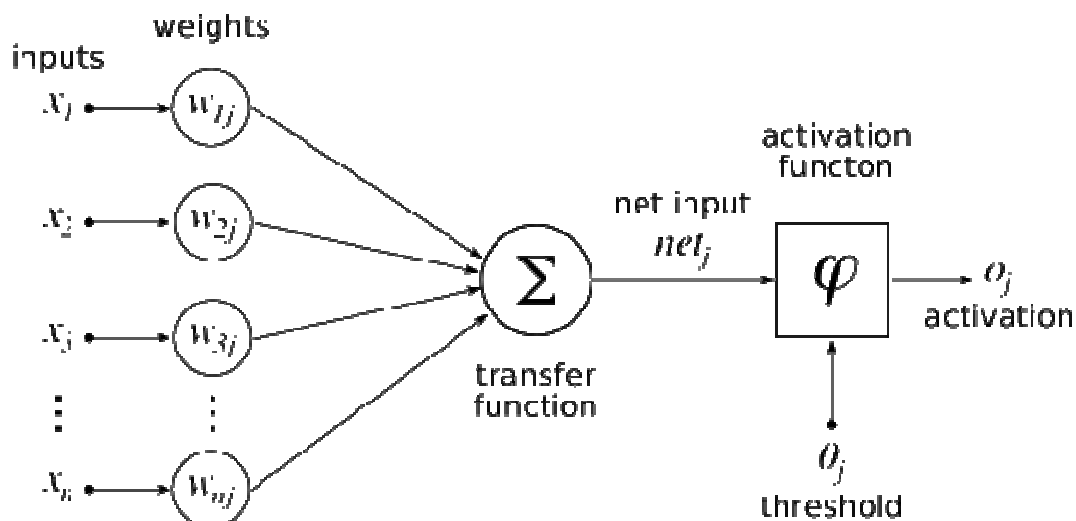
Παρακολούθηση της κατάστασης των μηχανημάτων: Τα νευρωνικά δίκτυα μπορούν να συμβάλλουν στη μείωση του κόστους με την εξασφάλιση της πρόσθετης εμπειρογνομosύνης για τον προγραμματισμό προληπτικής συντήρησης των μηχανημάτων. Ένα νευρωνικό δίκτυο, λοιπόν, μπορεί να εκπαιδευτεί με τέτοιο τρόπο, ώστε να διακρίνει από τους ήχους τους οποίους παράγει μια μηχανή είτε αν εκτελεί κανονικά τις λειτουργίες της, είτε βρίσκεται στα πρόθυρα εμφάνισης οποιασδήποτε δυσλειτουργίας. Μετά από αυτήν την περίοδο εκπαιδευτικής κατάρτισης, η εμπειρία του ίδιου δικτύου είναι δυνατό να χρησιμοποιηθεί με σκοπό την προειδοποίηση ενός τεχνικού για κάποια επικείμενη βλάβη προτού συμβεί και ενδεχομένως προκαλέσει πολυδάπανες και απρόβλεπτες χρονικές καθυστερήσεις.

Συστήματα διαχείρισης κινητήρα: Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την ανάλυση των εισροών που δέχονται οι αισθητήρες ενός κινητήρα. Το νευρωνικό δίκτυο ελέγχει μια ποικιλία παραμέτρων με τις οποίες λειτουργεί ο κινητήρας, προκειμένου να επιτευχθεί ένας συγκεκριμένος στόχος. Για παράδειγμα, το δίκτυο αυτό επιχειρεί την ελαχιστοποίηση της κατανάλωσης των καυσίμων.

Τα νευρωνικά δίκτυα αναπτύχθηκαν μέσα από τις διεξαγωγές ερευνών της Τεχνητής Νοημοσύνης. Προσπάθειες, δηλαδή, μίμησης της ανοχής σε βλάβες και τη δυνατότητα εξόρυξης γνώσης μέσα από βιολογικά νευρωνικά συστήματα, μοντελοποιώντας τη δομή των χαμηλών επιπέδων του εγκεφάλου. Στη συνέχεια, από το κύριο μέρος της έρευνας της Τεχνητής Νοημοσύνης που έγινε το 1960-1980, προήλθαν τα Έμπειρα Συστήματα (Expert Systems). Τα συστήματα αυτά έχουν βασιστεί σε ένα μοντέλο λογικής διεργασίας υψηλού επιπέδου, το οποίο δημιουργήθηκε από τον τρόπο με τον οποίο έχει δομηθεί η συλλογιστική διεργασία των ανθρώπων σχετικά με το χειρισμό των συμβόλων. Έγινε γρήγορα εμφανές πως αυτά τα συστήματα αν και ήταν πολύ χρήσιμα σε κάποιους τομείς, απέτυχαν να συλλάβουν καίριες πτυχές της ανθρώπινης νοημοσύνης. Σύμφωνα με μια πτυχή της μελέτης, το γεγονός αυτό οφειλόταν στην αποτυχία τους να μιμηθούν τη βασική δομή του εγκεφάλου. Προκειμένου να αναπαραχθεί νοημοσύνη, κρίνεται απαραίτητη η δημιουργία συστημάτων με παρόμοια τεχνική.

Ο εγκέφαλος αποτελείται κατά κύριο λόγο από ένα ευρύ φάσμα νευρώνων (10.000.000.000 κατά προσέγγιση), οι οποίοι είναι μαζικά διασυνδεδεμένοι με ένα μέσο όρο από διάφορες χιλιάδες διασυνδέσεις ανά νευρώνα. Κάθε νευρώνας είναι ένα εξειδικευμένο κύτταρο το οποίο έχει τη δυνατότητα μετάδοσης ενός ηλεκτροχημικού σήματος. Ο νευρώνας έχει μια διακλαδωτική διάρθρωση εισροών, τους δενδρίτες (dendrites), ένα κυτταρικό σώμα

και μια διακλαδωτική δομή εκροών (τον άξονα). Οι άξονες ενός κυττάρου συνδέονται με τους δενδρίτες ενός άλλου, μέσω μιας σύναψης. Όταν, λοιπόν, ένας άξονας ενεργοποιηθεί, πυροδοτεί ένα ηλεκτροχημικό σήμα κατά μήκος του άξονα. Ένας νευρώνας εκτελεί αυτή τη διαδικασία μόνο όταν το συνολικό σήμα το οποίο λήφθηκε από τους δενδρίτες, υπερβεί ένα συγκεκριμένο επίπεδο, δηλαδή, το κατώτατο όριο βολής (firing threshold).



Εικόνα 2:Τεχνητό Νευρωνικό Δίκτυο

Η ισχύς ενός σήματος που λαμβάνεται από ένα νευρώνα, εξαρτάται από την αποτελεσματικότητα των συνάψεων. Κάθε σύναψη περιέχει ένα κενό με νευροδιαβιβαστές χημικών ουσιών (neurotransmitter chemicals) που είναι σε ετοιμότητα για μετάδοση ενός μηνύματος. Ο Donald Hebb, ένας από τους πιο σημαντικούς ερευνητές στα νευρολογικά συστήματα, έθεσε ως ζήτημα πως η μάθηση συνιστάται κυρίως από τη μεταβολή της ισχύος των συναπτικών συνδέσμων.

Ως παράδειγμα τίθεται το πείραμα του Ραβλον για την Κλασική Εξάρτηση. Η κλασική εξάρτηση είναι μια μορφή συνειρμικής μάθησης, η οποία παρουσιάστηκε για πρώτη φορά από τον Ivan Pavlov και περιλαμβάνει την παρουσίαση ενός ουδέτερου ερεθίσματος μαζί με κάποιο σημαντικό ερέθισμα. Ο Ραβλον πειραματιζόμενος με σκύλους, παρατήρησε πως ορισμένα ερεθίσματα, όπως ο ήχος των βημάτων του εκτροφέα που πλησίαζε ή ο ήχος ενός κουδουνιού κατά την προσφορά της τροφής ενεργοποιούσε την έκκριση σιέλου, όπως ακριβώς την ενεργοποιούσε η διατροφή. Με την επανάληψη του πειράματος δημιουργήθηκε ένα καινούριο ανακλαστικό. Ο νέος αυτός τρόπος διασύνδεσης μεταξύ δύο ερεθισμάτων έγινε γνωστός ως εξαρτημένο ανακλαστικό (conditioned reflex) και η διαδικασία ονομάστηκε κλασική εξάρτηση και μέσω αυτής επέρχεται σημαντική αλλαγή της συμπεριφοράς.

Πρόσφατες έρευνες στη γνωστική επιστήμη και ιδιαίτερα στον τομέα της ασυνείδητης επεξεργασίας πληροφοριών, απέδειξαν περαιτέρω την τεράστια ικανότητα του ανθρώπινου μυαλού να καταλήγει σε απλές συνδιακυμάνσεις εισροών-εκροών, από εξαιρετικά πολύπλοκα ερεθίσματα. Επομένως, από ένα τεράστιο αριθμό ιδιαίτερα απλών

μονάδων εργασίας, ο εγκέφαλος κατορθώνει την εκτέλεση εξαιρετικά πολύπλοκων καθηκόντων. Παρουσιάζει, μάλιστα, μεγάλο ενδιαφέρον το γεγονός ότι τα τεχνητά νευρωνικά δίκτυα έχουν την ικανότητα να επιτύχουν τόσο αξιολόγια αποτελέσματα χρησιμοποιώντας ένα μοντέλο όχι και τόσο πολύπλοκο.

Μια από τις πιο βασικές ιδιότητες των Νευρωνικών Δικτύων είναι η ικανότητά τους για εκπαίδευση. Η εκπαίδευση αυτή επιτυγχάνεται μέσω της ανταλλαγής τιμών και βαρών, που αποσκοπεί στη βαθμιαία σύλληψη της πληροφορίας η οποία στη συνέχεια θα είναι διαθέσιμη προς ανάκτηση. Υπάρχουν, βέβαια, πολλοί αλγόριθμοι που η εφαρμογή τους έχει στόχο την προσαρμογή των τιμών των βαρών ενός Τεχνητού Νευρωνικού Δικτύου. Όλες οι μέθοδοι μάθησης μπορούν να καταταχθούν σε δύο κατηγορίες : τη μάθηση με επίβλεψη (supervised learning) και τη μάθηση χωρίς επίβλεψη (unsupervised learning).

**Μάθηση με επίβλεψη:** Η μάθηση αυτή είναι μια διαδικασία η οποία συνδυάζει έναν εξωτερικό εκπαιδευτή και τη συνολική ή γενικευμένη πληροφορία. Κάποιες από τις μεθόδους οι οποίες συγκαταλέγονται σε αυτή την κατηγορία είναι η μάθηση με διόρθωση σφάλματος, η στοχαστική μάθηση. Παραδείγματα τα οποία αντιπροσωπεύουν την μάθηση με επίβλεψη συμπεριλαμβάνουν αποφάσεις για το πότε θα πρέπει να σταματήσει η διαδικασία εκπαίδευσης, αποφάσεις αναφορικά με τη συχνότητα παρουσίασης στο δίκτυο τα πρότυπα εκπαίδευσης και η παρουσίαση προόδου του δικτύου. Η μάθηση με επίβλεψη χωρίζεται σε δύο ακόμα κατηγορίες: στη δομική (structural) και στην προσωρινή (temporal) εκμάθηση. Οι αλγόριθμοι οι οποίοι βρίσκονται στην πρώτη κατηγορία, χρησιμοποιούνται για την εύρεση της βέλτιστης σχέσης μεταξύ εισόδων και εξόδων για κάθε ξεχωριστό ζευγάρι προτύπων. Παραδείγματα της δομικής εκμάθησης αποτελούν η αναγνώριση και η κατηγοριοποίηση προτύπων, ενώ παραδείγματα της προσωρινής εκμάθησης η πρόβλεψη και ο έλεγχος.

**Μάθηση χωρίς επίβλεψη:** Οι αλγόριθμοι της εν λόγω μάθησης αναφέρονται ως αυτό-οργανώμενοι (self-organized) και είναι διαδικασίες οι οποίες δεν απαιτούν να είναι παρών ένας «εξωτερικός» δάσκαλος ή επιβλέπων. Βασίζονται, μάλιστα, μόνο σε τοπική πληροφορία καθ' όλη τη διάρκεια της εκπαίδευσης του Τεχνητού Νευρωνικού Δικτύου. Οι συγκεκριμένοι αλγόριθμοι οργανώνουν τα δεδομένα και ανακαλύπτουν τις σημαντικές συλλογικές ιδιότητες. Για παράδειγμα, αλγόριθμοι εκπαίδευσης χωρίς επίβλεψη είναι ο αλγόριθμος Hebbian, ο διαφορικός αλγόριθμος Hebbian και ο Min-Max αλγόριθμος.

Κατά κύριο λόγο οι περισσότερες διαδικασίες εκπαίδευσης είναι off line. Όταν χρησιμοποιείται όλο το δείγμα για προτύπων για την τροποποίηση των τιμών των βαρών, πριν της τελικής χρήσης του δικτύου ως εφαρμογή, τότε ονομάζεται off line εκπαίδευση. Οι αλγόριθμοι εκπαίδευσης off line έχουν την απαίτηση να βρίσκονται στην εκπαίδευση του δικτύου παρόντα όλα τα πρότυπα. Το γεγονός αυτό αποκλείει την πιθανότητα εισαγωγής νέων πληροφοριών μέσω νέων προτύπων. Βέβαια, υπάρχουν και Τεχνητά Νευρωνικά Δίκτυα τα οποία δεν αποκλείουν την εισαγωγή νέας πληροφορίας, μετά την τελική τους μοντελοποίηση. Αν παρουσιαστεί ανάγκη εισαγωγής νέου προτύπου στο δίκτυο, μπορεί να γίνει απευθείας χωρίς τον κίνδυνο να χαθεί κανένα μέρος της αρχικής πληροφορίας. Το πλεονέκτημα των δικτύων που χρησιμοποιούν off line διαδικασίες εκπαίδευσης επικεντρώνεται κυρίως στη δυνατότητα να δίνουν καλύτερες λύσεις σε δύσκολα προβλήματα[7]

### 2.2.2 Τεχνητή νοημοσύνη

Ο όρος τεχνητή νοημοσύνη (ΑΝ, εκ του Artificial Intelligence) αναφέρεται στον κλάδο της επιστήμης υπολογιστών ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, κατανόηση από συμφραζόμενα, επίλυση προβλημάτων κλπ. Ο Τζον Μακάρθι όρισε τον τομέα αυτόν ως «επιστήμη και μεθοδολογία της δημιουργίας νοούντων μηχανών».

Η ΤΝ αποτελεί σημείο τομής μεταξύ πολλών πεδίων όπως της επιστήμης υπολογιστών, της ψυχολογίας, της φιλοσοφίας, της νευρολογίας, της γλωσσολογίας και της επιστήμης μηχανικών, με στόχο τη σύνθεση ευφυούς συμπεριφοράς, με στοιχεία συλλογιστικής, μάθησης και προσαρμογής στο περιβάλλον, ενώ συνήθως εφαρμόζεται σε μηχανές ή υπολογιστές ειδικής κατασκευής. Διαιρείται στη συμβολική τεχνητή νοημοσύνη, η οποία επιχειρεί να εξομοιώσει την ανθρώπινη νοημοσύνη αλγοριθμικά χρησιμοποιώντας σύμβολα και λογικούς κανόνες υψηλού επιπέδου, και στην υποσυμβολική τεχνητή νοημοσύνη, η οποία προσπαθεί να αναπαράγει την ανθρώπινη ευφυΐα χρησιμοποιώντας στοιχειώδη αριθμητικά μοντέλα που συνθέτουν επαγωγικά νοήμονες συμπεριφορές με τη διαδοχική αυτοοργάνωση απλούστερων δομικών συστατικών («συμπεριφορική τεχνητή νοημοσύνη»), προσομοιώνουν πραγματικές βιολογικές διαδικασίες όπως η εξέλιξη των ειδών και η λειτουργία του εγκεφάλου («υπολογιστική νοημοσύνη»), ή αποτελούν εφαρμογή στατιστικών μεθοδολογιών σε προβλήματα ΤΝ.



Εικόνα 3: Το ρομπότ AIBO

Η διάκριση σε συμβολικές και υποσυμβολικές προσεγγίσεις αφορά τον χαρακτήρα



των χρησιμοποιούμενων εργαλείων, ενώ δεν είναι σπάνια η σύζευξη πολλαπλών προσεγγίσεων (διαφορετικών συμβολικών, υποσυμβολικών, ή ακόμα συμβολικών και υποσυμβολικών μεθόδων) κατά την προσπάθεια αντιμετώπισης ενός προβλήματος. Με βάση τον επιθυμητό επιστημονικό στόχο η ΤΝ κατηγοριοποιείται σε άλλου τύπου ευρείς τομείς, όπως επίλυση προβλημάτων, μηχανική μάθηση, ανακάλυψη γνώσης, συστήματα γνώσης κλπ. Επίσης υπάρχει επικάλυψη με συναφή επιστημονικά πεδία όπως η μηχανική όραση, η επεξεργασία φυσικής γλώσσας, η ρομποτική κλπ.

Η λογοτεχνία και ο κινηματογράφος επιστημονικής φαντασίας από τη δεκαετία του 1920 μέχρι σήμερα έχουν δώσει στο ευρύ κοινό την αίσθηση ότι η ΤΝ αφορά την προσπάθεια κατασκευής μηχανικών ανδρειδών ή αυτοσυνειδητών προγραμμάτων υπολογιστή (ισχυρή ΤΝ), επηρεάζοντας μάλιστα ακόμα και τους πρώτους ερευνητές του τομέα. Στην πραγματικότητα οι περισσότεροι επιστήμονες της τεχνητής νοημοσύνης προσπαθούν να κατασκευάσουν λογισμικό ή πλήρεις μηχανές οι οποίες να επιλύουν με αποδεκτά αποτελέσματα ρεαλιστικά υπολογιστικά προβλήματα οποιουδήποτε τύπου (ασθενής ΤΝ), αν και πολλοί πιστεύουν ότι η εξομοίωση ή η προσομοίωση της πραγματικής ευφυΐας, η ισχυρή ΤΝ, πρέπει να είναι ο τελικός στόχος.

Κατά τη δεκαετία του 1940 εμφανίστηκε η πρώτη μαθηματική περιγραφή τεχνητού νευρωνικού δικτύου, με πολύ περιορισμένες δυνατότητες επίλυσης αριθμητικών προβλημάτων. Καθώς ήταν εμφανές ότι οι ηλεκτρονικές υπολογιστικές συσκευές που κατασκευάστηκαν μετά τον Β' Παγκόσμιο Πόλεμο ήταν ένα τελείως διαφορετικό είδος μηχανής από ό,τι προηγήθηκε, η συζήτηση για την πιθανότητα εμφάνισης μηχανών με νόηση ήταν στην ακμή της. Το 1950 ο μαθηματικός Άλαν Τούρινγκ, πατέρας της θεωρίας υπολογισμού και προπάτορας της τεχνητής νοημοσύνης, πρότεινε τη δοκιμή Τούρινγκ· μία απλή δοκιμασία που θα μπορούσε να εξακριβώσει αν μία μηχανή διαθέτει ευφυΐα. Η τεχνητή νοημοσύνη θεμελιώθηκε τυπικά ως πεδίο στη συνάντηση ορισμένων επιφανών Αμερικανών επιστημόνων του τομέα το 1956 (Τζον Μακάρθι, Μάρβιν Μίνσκυ, Κλοντ Σάνον κλπ). Τη χρονιά αυτή παρουσιάστηκε για πρώτη φορά και το Logic Theorist, ένα πρόγραμμα το οποίο στηριζόταν σε συμπερασματικούς κανόνες τυπικής λογικής και σε ευρετικούς αλγόριθμους αναζήτησης για να αποδεικνύει μαθηματικά θεωρήματα.

Επόμενοι σημαντικοί σταθμοί ήταν η ανάπτυξη της γλώσσας προγραμματισμού LISP το 1958 από τον Μακάρθι, δηλαδή της πρώτης γλώσσας συναρτησιακού προγραμματισμού η οποία έπαιξε πολύ σημαντικό ρόλο στη δημιουργία εφαρμογών ΤΝ κατά τις επόμενες δεκαετίες, η εμφάνιση των γενετικών αλγορίθμων την ίδια χρονιά από τον Φρίντμπεργκ και η παρουσίαση του βελτιωμένου νευρωνικού δικτύου perceptron το '62 από τον Ρόσενμπλατ. Κατά τα τέλη της δεκαετίας του '60 όμως άρχισε ο χειμώνας της ΤΝ, μία εποχή κριτικής, απογοήτευσης και υποχρηματοδότησης των ερευνητικών προγραμμάτων καθώς όλα τα μέχρι τότε εργαλεία του χώρου ήταν κατάλληλα μόνο για την επίλυση εξαιρετικά απλών προβλημάτων. Στα μέσα του '70 ωστόσο προέκυψε μία αναθέρμανση του ενδιαφέροντος για τον τομέα λόγω των εμπορικών εφαρμογών που απέκτησαν τα έμπειρα συστήματα, μηχανές ΤΝ με αποθηκευμένη γνώση για έναν εξειδικευμένο τομέα και δυνατότητα ταχείας εξαγωγής λογικών συμπερασμάτων, τα οποία συμπεριφέρονται όπως ένας άνθρωπος ειδικός στον αντίστοιχο τομέα. Παράλληλα έκανε την εμφάνισή της η γλώσσα λογικού προγραμματισμού Prolog η οποία έδωσε νέα ώθηση στη συμβολική ΤΝ, ενώ στις αρχές της δεκαετίας του '80 άρχισαν να υλοποιούνται πολύ πιο ισχυρά και με περισσότερες εφαρμογές νευρωνικά δίκτυα, όπως τα πολυεπίπεδα perceptron και τα δίκτυα Hopfield. Ταυτόχρονα οι γενετικοί αλγόριθμοι και άλλες συναφείς μεθοδολογίες αναπτύσσονταν πλέον από κοινού, κάτω από την ομπρέλα

του εξελικτικού υπολογισμού.

Κατά τη δεκαετία του '90, με την αυξανόμενη σημασία του Internet, ανάπτυξη γνώρισαν οι ευφυείς πράκτορες, αυτόνομο λογισμικό TN τοποθετημένο σε κάποιο περιβάλλον με το οποίο αλληλεπιδρά, οι οποίοι βρήκαν μεγάλο πεδίο εφαρμογών λόγω της εξάπλωσης του Διαδικτύου. Οι πράκτορες στοχεύουν συνήθως στην παροχή βοήθειας στους χρήστες τους, στη συλλογή ή ανάλυση γιγάντιων συνόλων δεδομένων ή στην αυτοματοποίηση επαναλαμβανόμενων εργασιών (π.χ. βλέπε διαδικτυακό ρομπότ), ενώ στους τρόπους κατασκευής και λειτουργίας τους συνοψίζουν όλες τις γνωστές μεθοδολογίες TN που αναπτύχθηκαν με το πέρασμα του χρόνου. Έτσι σήμερα, όχι σπάνια, η TN ορίζεται ως η επιστήμη που μελετά τη σχεδίαση και υλοποίηση ευφύων πρακτόρων.

Επίσης τη δεκαετία του '90 η TN, κυρίως η μηχανική μάθηση και η ανακάλυψη γνώσης, άρχισε να επηρεάζεται πολύ από τη θεωρία πιθανοτήτων και τη στατιστική. Τα μευζιανά δίκτυα είναι η εστίαση αυτής της νέας μετακίνησης που παρέχει τις συνδέσεις με τα πιο σχολαστικά θέματα της στατιστικής και της επιστήμης μηχανικών, όπως τα πρότυπα Markov και τα φίλτρα Kalman. Αυτή η νέα πιθανοκρατική προσέγγιση έχει αυστηρά υποσυμβολικό χαρακτήρα, όπως και οι τρεις μεθοδολογίες οι οποίες κατηγοριοποιούνται κάτω από την ετικέτα της υπολογιστικής νοημοσύνης: τα νευρωνικά δίκτυα, ο εξελικτικός υπολογισμός και η ασαφής λογική.

Ακολουθούν οι πιο σπουδαίες στιγμές στην ιστορία της TN:

| Χρόνος | Εξέλιξη   |
|--------|---|
| 1950   | Ο Άλαν Τούρινγκ περιγράφει τη δοκιμή Τούρινγκ, που επιδιώκει να εξετάσει την ικανότητα μιας μηχανής να συμμετάσχει απρόσκοπτα σε μια ανθρώπινη συνομιλία.   |
| 1951   | Τα πρώτα προγράμματα TN γράφονται για τον υπολογιστή Ferranti Mark I στο Πανεπιστήμιο του Μάντσεστερ: ένα πρόγραμμα που παίζει ντάμα από τον Κρίστοφερ Στράκλι και ένα που παίζει σκάκι από τον Ντίτριχ Πρίνζ.                              |
| 1956   | Ο Τζον Μακάρθι πλάθει τον όρο «Τεχνητή Νοημοσύνη» ως κύριο θέμα της διάσκεψης του Ντάρτμουθ.  |
| 1958   | Ο Τζον Μακάρθι εφευρίσκει τη γλώσσα προγραμματισμού Lisp.   |
| 1965   | Ο Έντουαρτ Φάιγκενμπαουμ ξεκινά το Dendral, μια δεκαετή προσπάθεια ανάπτυξης λογισμικού που θα συμπεράνει τη μοριακή δομή οργανικών ενώσεων χρησιμοποιώντας ενδείξεις επιστημονικών οργάνων. Ήταν το πρώτο έμπειρο σύστημα (expert system). |
| 1966   | Ιδρύεται το Εργαστήριο Μηχανικής Νοημοσύνης στο Εδιμβούργο – το πρώτο από μια σημαντική σειρά εγκαταστάσεων που οργανώνονται από τον Ντόναλντ Μίτσι και άλλους.   |
| 1970   | Αναπτύσσεται το Planner και χρησιμοποιείται στο SHRDLU, μια εντυπωσιακή   |

|      |  |
|------|--|
|      | επίδειξη αλληλεπίδρασης μεταξύ ανθρώπου και υπολογιστή.  |
| 1971 | Ξεκινά η εργασία πάνω στο σύστημα αυτόματης απόδειξης θεωρημάτων Boyer-Moore στο Εδιμβούργο.   |
| 1972 | Η γλώσσα προγραμματισμού Prolog αναπτύσσεται από τον Αλάν Κολμεροέρ.   |
| 1973 | Ρομπότ συναρμολόγησης «Φρέντι» στο Εδιμβούργο: ένα ευπροσάρμοστο σύστημα συναρμολόγησης που ελέγχεται από υπολογι.   |
| 1974 | Ο Τέντ Σόρτλιφ γράφει τη διατριβή του για το πρόγραμμα MYCIN (Στάνφορντ), το οποίο κατέδειξε μια πολύ πρακτική προσέγγιση στην ιατρική διάγνωση που βασίζεται σε κανόνες, ενώ λειτουργεί ακόμα και με παρουσία αβεβαιότητας. Αν και δανείστηκε από το DENDRAL, οι δικές του συνεισφορές επηρέασαν έντονα το μέλλον των έμπειρων συστημάτων, ένα μέλλον με πολλαπλές εμπορικές εφαρμογές. |
| 1991 | Η εφαρμογή σχεδίασης ενεργειών DART χρησιμοποιείται αποτελεσματικά στον Α' Πόλεμο του Κόλπου και ανταμείβει 30 χρόνια έρευνας στην ΤΝ του Αμερικανικού Στρατού.  |
| 1994 | Ντίκμανς και Ντάιμλερ-Μπενζ οδηγούν περισσότερο από 1000 km σε μια εθνική οδό του Παρισιού υπό συνθήκες βαρείας κυκλοφορίας και σε ταχύτητες ως και 130 km/ώρα. Επιδεικνύουν αυτόνομη οδήγηση σε ελεύθερες παρόδους, οδήγηση σε συνοδεία, αλλαγή παρόδων και αυτόματη προσπέραση άλλων οχημάτων.   |
| 1997 | Ο υπολογιστής Deep Blue της IBM κερδίζει τον παγκόσμιο πρωταθλητή σκακιού Γκάρι Κασπάροφ.  |
| 1998 | Κυκλοφορεί ο Φέρμι της Tiger Electronics και γίνεται η πρώτη επιτυχημένη εμφάνιση ΤΝ σε οικιακό περιβάλλον.  |
| 1999 | Η Sony λανσάρει το AIBO, που είναι ένα από τα πρώτα αυτόνομα κατοικίδια ΤΝ.  |
| 2004 | Η DARPA ξεκινά το πρόγραμμα DARPA Grand Challenge («Μεγάλη Πρόκληση DARPA»), που προκαλεί τους συμμετέχοντες να δημιουργήσουν αυτόνομα οχήματα για ένα χρηματικό βραβείο.  |

**Πίνακας 1: Πίνακας με τις πιο σπουδαίες στιγμές στην ιστορία της Τεχνητής Νοημοσύνης.**

Η συμβατική τεχνητή νοημοσύνη εμπλέκει μεθόδους μηχανικής μάθησης (machine learning), που χαρακτηρίζονται από αυστηρούς μαθηματικούς αλγόριθμους και στατιστικές μεθόδους ανάλυσης. Διακρίνεται σε:

**Έμπειρα ή Εξειδικευμένα συστήματα** (Expert systems), που εφαρμόζουν προγραμματισμένες ρουτίνες λογικής, σχεδιασμένες αποκλειστικά για μία συγκεκριμένη εργασία, προκειμένου να εξαχθεί κάποιο συμπέρασμα. Για το σκοπό αυτό, διεξάγεται επεξεργασία μεγάλων ποσοτήτων γνωστών πληροφοριών.

**Λογική κατά περίπτωση** (Case based reasoning). Η επίλυση ενός προβλήματος βασίζεται

στην προηγούμενη επίλυση παρόμοιων προβλημάτων.

**Μπαϋεσιανά δίκτυα** (Bayesian networks). Βασίζονται στη στατιστική ανάλυση για τη λήψη αποφάσεων.

**Συμπεριφορική τεχνητή νοημοσύνη** (Behavior based AI). Μέθοδος τεμαχισμού της λογικής διαδικασίας και στη συνέχεια χειροκίνητης οικοδόμησης του αποτελέσματος.

Η υπολογιστική τεχνητή νοημοσύνη βασίζεται στη μάθηση μέσω επαναληπτικών διαδικασιών (ρύθμιση παραμέτρων). Η μάθηση βασίζεται σε εμπειρικά δεδομένα και σε μη-συμβολικές μεθόδους. Διακρίνεται σε:

**Τεχνητά νευρωνικά δίκτυα** (Artificial neural networks) με πολύ ισχυρές δυνατότητες αναγνώρισης προτύπων (pattern recognition). Προσομοιάζουν τη λειτουργία των νευρώνων των εμβίων όντων.

**Συστήματα Ασαφούς λογικής** (Fuzzy logic systems). Αποτελούν τεχνικές λήψης απόφασης κάτω από αβεβαιότητα. Βασίζονται στην ύπαρξη μη-αυστηρά διαχωρισμένων καταστάσεων, των οποίων η βαρύτητα λαμβάνεται υπόψη κατά περίπτωση. Υπάρχουν ήδη πολλές εφαρμογές των τεχνικών αυτών.


**Εξελικτική υπολογιστική** (Evolutionary computation). Η ανάπτυξή τους προέκυψε από τη μελέτη των έμβιων οργανισμών και αφορούν σε έννοιες όπως του πληθυσμού, της μετάλλαξης και της φυσικής επιλογής (επιβίωση του πιο προσαρμοσμένου) για την ακριβέστερη επίλυση ενός προβλήματος. Οι μέθοδοι αυτοί μπορούν να διακριθούν περαιτέρω σε εξελικτικούς αλγόριθμους (evolutionary algorithms) και σε νοημοσύνης σμήνους (swarm intelligence), όπως πχ οι αλγόριθμοι που προσομοιάζουν τη συμπεριφορά μίας κοινωνίας μηρυγκιών.[5]

### 2.2.3 Self-Organizing Maps

Ένας self-organizing map (SOM) ή self-organizing feature map (SOFM) είναι ένα είδος τεχνητών νευρωνικών δικτύων (ΤΝΔ), που έχει εκπαιδευτεί χρησιμοποιώντας μη επιβλεπόμενη μάθηση για την παραγωγή ενός χαμηλού διαστάσεων (συνήθως δύο διαστάσεων), που ονομάζεται χάρτης. Οι self-organizing maps είναι διαφορετικοί από τα άλλα τεχνητά νευρωνικά δίκτυα, με την έννοια ότι χρησιμοποιούν μια συνάρτηση γειτονιάς για να διατηρήσουν τις τοπολογικές ιδιότητες της εισόδου. Αυτό κάνει τα SOMs χρήσιμα για την οπτικοποίηση σε μικρές διαστάσεις τμημάτων που προέρχονται από μεγάλες διαστάσεις δεδομένων, όπως ακριβώς συμβαίνει και με την πολυδιάστατη κλιμάκωση. Το μοντέλο περιγράφηκε για πρώτη φορά ως ένα τεχνητό νευρωνικό δίκτυο από τον φινλανδό καθηγητή Teuvo Kohonen, και μερικές φορές ονομάζεται Kohonen map ή network.[13]

Όπως τα περισσότερα τεχνητά νευρωνικά δίκτυα, τα SOMs λειτουργούν με δύο τρόπους: την εκπαίδευση και την χαρτογράφηση. Η «εκπαίδευση» χτίζει το χάρτη χρησιμοποιώντας παραδείγματα εισόδου (μια ανταγωνιστική διαδικασία, που ονομάζεται επίσης vector quantization), ενώ η «χαρτογράφηση» ταξινομεί αυτόματα ένα νέο διάνυσμα εισόδου. Ένα self-organizing map αποτελείται από συστατικά που ονομάζονται κόμβοι ή νευρώνες. Συσχετιζόμενο με κάθε κόμβο είναι ένα διάνυσμα βάρους της ίδιας διάστασης όπως του διανύσματος εισόδου και μία θέση στο χώρο του χάρτη. Η συνήθης διάταξη των

κόμβων είναι ένα δισδιάστατο σε κανονική απόσταση με ένα εξαγωνικό ή ορθογώνιο πλέγμα. Ο self-organizing map περιγράφει μια χαρτογράφηση από έναν υψηλότερο διαστάσεων χώρο εισόδου σε ένα χαμηλότερο διαστάσεων χάρτη. Η διαδικασία για την τοποθέτηση ενός φορέα από τα δεδομένα, πάνω στο χάρτη είναι να βρει τον κόμβο με το πλησιέστερο (μικρότερη μετρική απόσταση) διάνυσμα βάρους στο διανυσματικό χώρο των δεδομένων. Ενώ είναι τυπικό να θεωρούν αυτού του είδους τη δομή του δικτύου που σχετίζεται με τα feedforward δίκτυα όπου οι κόμβοι είναι συνδεδεμένοι, αυτού του είδους η αρχιτεκτονική είναι θεμελιωδώς διαφορετική σε διάταξη και σε κίνητρα.[16]



**Εικόνα 4:** Ένα self-organizing map που δείχνει το Κογκρέσο των ΗΠΑ κατά τη διάρκεια ψηφοφορίας, η οποία οπτικοποιείται σε Synapse. Τα δύο πρώτα κουτιά δείχνουν την ομαδοποίηση και τις αποστάσεις, ενώ τα υπόλοιπα δείχνουν τα επίπεδα στοιχεία.

Χρήσιμες επεκτάσεις περιλαμβάνουν τη χρήση τοροειδούς πλεγμάτων όπου οι αντίθετες ακμές συνδέονται χρησιμοποιώντας μεγάλο αριθμό κόμβων. Έχει αποδειχθεί ότι ενώ τα self-organizing maps με μικρό αριθμό κόμβων συμπεριφέρονται με έναν τρόπο που είναι παρόμοιος με τον K-means, μεγαλύτερα self-organizing maps αναδιατάσσουν δεδομένα με έναν τρόπο που είναι θεμελιωδώς τοπολογικός σε χαρακτήρα. Είναι επίσης σύνηθες να χρησιμοποιούν το U-Matrix. Η τιμή του U-Matrix ενός συγκεκριμένου κόμβου είναι η μέση απόσταση μεταξύ του κόμβου και του πλησιέστερου από τους γείτονές του. Σε ένα τετράγωνο πλέγμα, για παράδειγμα, θα μπορούσαμε να εξετάσουμε τους πλησιέστερους 4 ή 8 κόμβους (Von Neumann και Moore, αντίστοιχα), ή έξι κόμβους σε ένα εξαγωνικό πλέγμα. Μεγάλα self-organizing maps εμφανίζουν ιδιότητες που είναι αναδυόμενες. Σε χάρτες που αποτελούνται από χιλιάδες κόμβους, είναι δυνατό να εκτελέσει λειτουργίες του συμπλέγματος στο ίδιο το χάρτη.

Ο στόχος της μάθησης σε ένα self-organizing map είναι να προκαλέσει διαφορετικά μέρη του δικτύου να ανταποκριθούν με παρόμοιο τρόπο σε ορισμένα πρότυπα εισόδου. Αυτό


οφείλεται εν μέρει από το πόσο οπτικά, ακουστικά ή με άλλες αισθητήριες πληροφορίες χειρίζονται σε ξεχωριστά τμήματα του εγκεφαλικού φλοιού στον ανθρώπινο εγκέφαλο. Τα βάρη των νευρώνων αρχικοποιούνται είτε σε μικρές τυχαίες τιμές ή δειγματοποιούνται εξίσου από τον υποχώρο ο οποίος εκτείνεται από τα δύο μεγαλύτερα κύρια συστατικά ιδιοδιανύσματα. Με την τελευταία εναλλακτική λύση, η μάθηση είναι πολύ πιο γρήγορη, διότι τα αρχικά βάρη δίνουν μια καλή προσέγγιση του SOM βάρους. Το δίκτυο πρέπει να τροφοδοτείται από ένα μεγάλο αριθμό διανυσμάτων που αντιπροσωπεύουν, όσο το δυνατόν πλησιέστερα, τα είδη των διανυσμάτων που αναμένονται κατά τη διάρκεια της χαρτογράφησης(mapping). Τα παραδείγματα συνήθως χορηγούνται αρκετές φορές ως επαναλήψεις. Η εκπαίδευση χρησιμοποιεί ανταγωνιστική μάθηση. Όταν ένα διάνυσμα εκπαίδευσης τροφοδοτείται στο δίκτυο, υπολογίζεται η Ευκλείδεια απόστασή του σε όλα τα διανύσματα βάρους. Ο νευρώνας των οποίων το βάρος του διανύσματος είναι πιο όμοιο προς την είσοδο ονομάζεται best matching unit (BMU). Τα βάρη των BMU και των νευρώνων που βρίσκονται κοντά στο πλέγμα SOM ρυθμίζονται σύμφωνα με το διάνυσμα εισόδου. Το μέγεθος της μεταβολής μειώνεται με τον χρόνο και με την απόσταση (εντός του πλέγματος) από το BMU. Ο τύπος για ένα νευρώνα με βάρος διανύσματος  $W_v(s)$  είναι:

$$W_v(s+1) = W_v(s) + \Theta(u,v,s) \alpha(s) (D(t) - W_v(s)),$$

όπου  $s$  είναι ο δείκτης βήματος,  $t$  ένας δείκτης μέσα στο δείγμα εκπαίδευσης,  $u$  είναι ο δείκτης της BMU για το  $D(t)$ ,  $\alpha(s)$  είναι ένας μονοτονικά μειούμενος συντελεστής μάθησης και  $D(t)$  είναι το διάνυσμα εισόδου, το  $v$  υποτίθεται ότι θα επισκέπτετε όλα τους νευρώνες για κάθε τιμή του  $s$  και  $t$ . Ανάλογα με τις εφαρμογές, το  $t$  μπορεί να σαρώσει τα δεδομένα εκπαίδευσης συστηματικά, να κληρώνεται από το σύνολο των δεδομένων (δειγματοληψία εκκίνησης), ή να εφαρμόζει κάποια άλλη μέθοδο δειγματοληψίας (όπως την jackknifing). Η συνάρτηση  $\Theta(u,v,s)$  εξαρτάται από την απόσταση μεταξύ του πλέγματος της BMU (νευρώνα  $u$ ) και του νευρώνα  $v$ . Στην απλούστερη μορφή της είναι 1 για όλους τους νευρώνες κοντά στη BMU και 0 για τους άλλους, αλλά μια συνάρτηση Gauss είναι μια κοινή επιλογή, επίσης. Ανεξάρτητα από τη λειτουργική μορφή, η συνάρτηση συρρικνώνεται με το χρόνο. Στην αρχή, όταν η γειτονιά είναι ευρεία, το self-organizing λαμβάνει χώρα σε παγκόσμια κλίμακα. Όταν η γειτονιά έχει συρρικνωθεί σε μόλις ένα ζευγάρι νευρώνων, τα βάρη συγκλίνουν με τις τοπικές εκτιμήσεις. Σε ορισμένες εφαρμογές ο συντελεστής μάθησης  $\alpha$  και η συνάρτηση  $\Theta$  μειώνονται σταθερά με την αύξηση του  $s$ , ενώ σε άλλες (ιδίως εκείνων όπου το  $t$  σαρώνει το σύνολο δεδομένων εκπαίδευσης) μειώνονται με σταδιακή τάση, μία φορά κάθε  $T$  βήματα. Η διαδικασία αυτή επαναλαμβάνεται για κάθε διάνυσμα εισόδου για ένα (συνήθως μεγάλο) αριθμό κύκλων  $\lambda$ . Το δίκτυο συνεχίζει να συνδέει τους κόμβους εξόδου με τις ομάδες ή τα πρότυπα στο σύνολο δεδομένων εισόδου. Αν αυτά τα πρότυπα μπορούν να ονομαστούν, τα ονόματα μπορούν να συνδεθούν με τους σχετικούς κόμβους στο εκπαιδευμένο δίκτυο.

Κατά τη διάρκεια της χαρτογράφησης, θα υπάρξει ένας νευρώνας νικητής: ο νευρώνας του οποίου το βάρος κείται πλησιέστερα προς το διάνυσμα εισόδου. Αυτό μπορεί απλά να προσδιοριστεί με τον υπολογισμό της Ευκλείδειας απόστασης μεταξύ του διανύσματος εισόδου και του διανύσματος βάρους. Ενώ η αντιπροσώπευση των δεδομένων εισόδου έχει τονιστεί σε αυτή την ενότητα, θα πρέπει να σημειωθεί ότι κάθε είδους αντικείμενο που μπορεί να αναπαρασταθεί ψηφιακά, το οποίο έχει ένα κατάλληλο μέτρο απόστασης που το συνδέει, και στο οποίο οι αναγκαίες λειτουργίες για την εκπαίδευση είναι


δυνατές μπορεί να χρησιμοποιηθεί για την κατασκευή ενός self-organizing map. Αυτό περιλαμβάνει πίνακες, συνεχείς συναρτήσεις ή ακόμη και άλλα self-organizing maps.



Εικόνα 5:Μια απεικόνιση της εκπαίδευσης ενός self organizing map.

Υπάρχουν δύο τρόποι για να ερμηνεύσει κανείς ένα self organizing map. Επειδή κατά τη διάρκεια της εκπαίδευσης τα βάρη του συνόλου της γειτονιάς κινούνται στην ίδια κατεύθυνση, όμοια αντικείμενα τείνουν να διεγείρουν τους γειτονικούς νευρώνες. Ως εκ τούτου, το SOM απεικονίζει ένα σημασιολογικό χάρτη όπου τα όμοια δείγματα χαρτογραφούνται μεταξύ τους και τα ανόμοια ξεχωριστά. Αυτό μπορεί να οπτικοποιηθεί με ένα U-Matrix (Ευκλείδεια απόσταση μεταξύ των διανυσμάτων βάρους των γειτονικών κυττάρων) του SOM.

Ο άλλος τρόπος είναι να σκεφτούμε τα νευρωνικά βάρη ως δείκτες για το χώρο εισόδου. Σχηματίζουν μια διακριτή προσέγγιση της κατανομής των δειγμάτων εκπαίδευσης. Περισσότεροι νευρώνες οδηγούνται σε περιοχές με υψηλή συγκέντρωση του δείγματος εκπαίδευσης και λιγότεροι όπου τα δείγματα είναι σπάνια. Τα self organizing maps μπορούν να θεωρηθούν ως μη γραμμική γενίκευση της ανάλυσης κυρίων συνιστωσών (Principal components analysis) (PCA). Έχει αποδειχθεί ότι, χρησιμοποιώντας τόσο τεχνητά όσο και πραγματικά γεωφυσικά δεδομένα, τα SOMs έχουν πολλά πλεονεκτήματα έναντι των συμβατικών μεθόδων. Αρχικά, τα SOMs δεν ήταν ικανά για να λύσουν ένα πρόβλημα βελτιστοποίησης. Παρ'όλα αυτά, έχουν γίνει διάφορες προσπάθειες να τροποποιηθεί ο ορισμός του self organizing map και να διατυπωθεί ένα πρόβλημα βελτιστοποίησης που δίνει παρόμοια αποτελέσματα. Για παράδειγμα, οι ελαστικοί χάρτες χρησιμοποιούν τη μηχανική μεταφορά της ελαστικότητας για την προσέγγιση κύριων πολλαπλοτήτων.



**Εικόνα 6:Μονοδιάστατος self organizing map έναντι ανάλυσης κύριων συνιστωσών (principal component analysis) (PCA) για την προσέγγιση των δεδομένων.**

Εναλλακτικές μέθοδοι οι οποίες χρησιμοποιούν self organizing map(SOM) αναφέρονται παρακάτω:

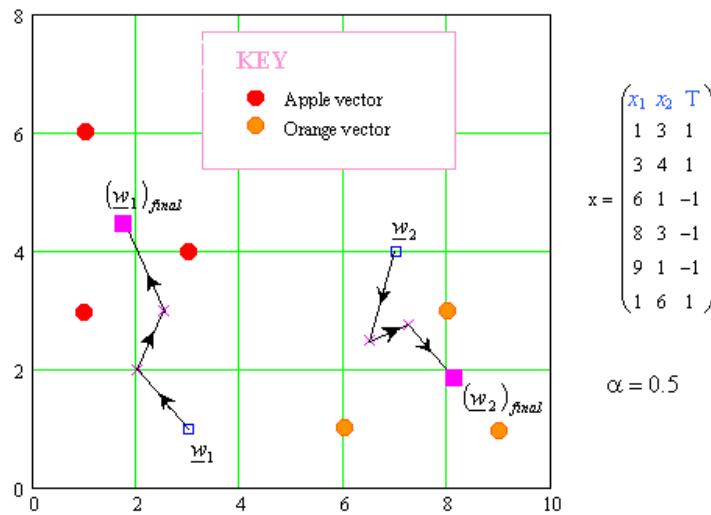
- Ο παραγωγικός τοπογραφικός χάρτης (GTM) είναι μια πιθανή εναλλακτική λύση για τα SOMs. Υπό την έννοια ότι ένας GTM απαιτεί ρητώς μια ομαλή και συνεχή χαρτογράφηση από το χώρο εισόδου προς το χώρο του χάρτη, είναι τοπολογικά διατηρήσιμη. Ωστόσο, σε μια πρακτική έννοια, αυτό το μέτρο τοπολογικής διατήρησης εκλείπει.
- Ο time adaptive self-organizing map (TASOM) είναι μια επέκταση του βασικού SOM. Η TASOM χρησιμοποιεί προσαρμοστικούς δείκτες μάθησης. Περιλαμβάνει επίσης μία παράμετρο κλιμακώσεως για να κάνει το δίκτυο αναλλοίωτο στην κλιμάκωση, στη μετάφραση και περιστροφή του χώρου εισόδου. Η TASOM και οι παραλλαγές του έχουν χρησιμοποιηθεί σε διάφορες εφαρμογές, όπως προσαρμοστική ομαδοποίηση, πολυεπίπεδο κατώφλι, προσέγγιση του χώρου, και την ενεργό διαμόρφωση περιγράμματος. Επιπλέον, ένα δυαδικό δέντρο ή TASOM BTASOM, που μοιάζει με ένα δυαδικό δέντρο έχει προταθεί, όπου ο αριθμός των επιπέδων του και ο αριθμός των κόμβων του είναι προσαρμοσμένα με το περιβάλλον του.
- Ο growing self-organizing map (GSOM) είναι μια αυξανόμενη παραλλαγή του SOM. Ο GSOM αναπτύχθηκε για να αντιμετωπίσει το θέμα της αναγνώρισης ενός χάρτη μεγέθους SOM. Ξεκινά με ένα ελάχιστο αριθμό κόμβων (συνήθως τέσσερις) και επεκτείνεται σε νέους κόμβους σύμφωνα με την ευρετική μέθοδο. Χρησιμοποιώντας μια τιμή που ονομάζεται παράγοντας εξάπλωσης, ο αναλυτής δεδομένων έχει τη δυνατότητα να ελέγχει την ανάπτυξη του GSOM.
- Οι ελαστικοί χάρτες δανείζονται από την παρεμβολή spline την ιδέα της ελαχιστοποίησης της ελαστικής ενέργειας. Στην μάθηση, ελαχιστοποιεί το άθροισμα των τετραγωνικών και της ενέργειας με το least squares approximation error. [10]



### 2.2.4 Learning Vector Quantization

Στην Επιστήμη των Υπολογιστών, η εκμάθηση διανυσματικής κβάντισης (Learning Vector Quantization) (LVQ), είναι ένας πρωτότυπος αλγόριθμος που βασίζεται στην εκπαίδευση με επίβλεψη. Η εκμάθηση διανυσματικής κβάντισης είναι η επίβλεψη συστημάτων με τρόπο που μοιάζει με αυτά του κβαντισμού φορέα.

Η LVQ μπορεί να θεωρηθεί ως μια ειδική περίπτωση ενός τεχνητού νευρωνικού δικτύου, πιο συγκεκριμένα, εφαρμόζει μία winner-take-all Hebbian μάθηση. Είναι ένας πρόδρομος για τα self organizing maps (SOM) και σχετίζεται με Νευρωνικά φυσικού αερίου, καθώς και με τον k-Nearest Neighbor αλγόριθμο (k-NN). Η LVQ εφευρέθηκε από τον Τεονο Kohonen.



Εικόνα 7: Ένα παράδειγμα learning vector quantization.

Ένα σύστημα LVQ αντιπροσωπεύεται από πρωτότυπα  $W = (w(i), \dots, w(n))$ , τα οποία ορίζονται στο χώρο των χαρακτηριστικών παρατηρούμενων δεδομένων. Στους αλγορίθμους εκπαίδευσης winner-take-all ένας καθορίζει, για κάθε σημείο δεδομένων, το πρωτότυπο το οποίο είναι πλησιέστερα στην είσοδο, σύμφωνα με ένα δεδομένο μέτρο απόστασης. Η θέση αυτού του λεγόμενου winner πρωτοτύπου εν συνεχεία προσαρμόζεται, δηλαδή ο winner πλησιάζει αν ταξινομεί σωστά το σημείο δεδομένων ή απομακρύνεται, εφόσον κατατάσσει το σημείο δεδομένων λανθασμένα. Ένα πλεονέκτημα της LVQ είναι ότι δημιουργεί πρωτότυπα που είναι εύκολο να ερμηνευτούν από ειδικούς στον αντίστοιχο τομέα εφαρμογής. Συστήματα LVQ μπορούν να εφαρμοστούν σε πολυ-ταξικά προβλήματα ταξινόμησης με έναν φυσικό τρόπο. Ένα βασικό ζήτημα στο LVQ είναι η επιλογή του κατάλληλου μέτρου της απόστασης ή ομοιότητας για την εκπαίδευση και ταξινόμηση. Πρόσφατα, έχουν αναπτυχθεί τεχνικές που προσαρμόζουν ένα μέτρο απόστασης κατά τη διάρκεια της εκπαίδευσης του συστήματος. Η τεχνική LVQ μπορεί να είναι μια πηγή μεγάλης βοήθειας στην ταξινόμηση των εγγράφων κειμένων.

### 2.2.5 Μηχανική Μάθηση

Η μηχανική μάθηση (machine learning) είναι μια περιοχή της τεχνητής νοημοσύνης η οποία αφορά αλγορίθμους και μεθόδους που επιτρέπουν στους υπολογιστές να «μαθαίνουν». Με τη μηχανική μάθηση καθίσταται εφικτή η κατασκευή προσαρμόσιμων (adaptable) προγραμμάτων υπολογιστών τα οποία λειτουργούν με βάση την αυτοματοποιημένη ανάλυση συνόλων δεδομένων και όχι τη διαίσθηση των μηχανικών που τα προγραμμάτισαν. Η μηχανική μάθηση επικαλύπτεται σημαντικά με τη στατιστική, αφού και τα δύο πεδία μελετούν την ανάλυση δεδομένων. Είναι, μία περιοχή της τεχνητής νοημοσύνης, που ασχολείται με την ανάπτυξη αλγορίθμων που λαμβάνουν ως είσοδο εμπειρικά δεδομένα, όπως μετρήσεις από αισθητήρες ή βάσεις δεδομένων. Ο αλγόριθμος έχει σχεδιαστεί για να εντοπίζει πολύπλοκες σχέσεις που υποτίθεται ότι είναι χαρακτηριστικά του παρόντος μηχανισμού που δημιούργησε τα δεδομένα, και να χρησιμοποιεί αυτά τα πρότυπα για να κάνει προβλέψεις πάνω σε καινούρια. Τα δεδομένα μπορούν να θεωρηθούν ως στιγμιότυπα των πιθανών σχέσεων μεταξύ των παρατηρούμενων μεταβλητών. Ο αλγόριθμος ενεργεί σαν ένας μηχανισμός μάθησης που μελετά ένα τμήμα των παρατηρούμενων δεδομένων (που ονομάζονται δείγματα των δεδομένων) για να συλλάβει τα χαρακτηριστικά ενδιαφέροντος του αγνώστου δείγματος, και να τα χρησιμοποιήσει ως γνώσεις που έχει μάθει έτσι ώστε να λάβει έξυπνες αποφάσεις που βασίζονται σε νέα δεδομένα εισόδου.

Το 1959, ο Arthur Samuel όρισε τη μηχανική μάθηση ως « πεδίο μελέτης που δίνει στους υπολογιστές τη δυνατότητα να μαθαίνουν χωρίς να είναι ρητά προγραμματισμένοι ». Ο Tom M. Mitchell παρείχε, πιο επίσημο ορισμό: «Ένα πρόγραμμα υπολογιστή πρόκειται να μάθει από την εμπειρία  $E$  σε σχέση με κάποια κατηγορία εργασιών  $T$  και την μέτρησης της επίδοσης  $P$ , αν η απόδοσή της σε εργασίες της  $T$ , όπως μετράται από την  $P$ , βελτιώνεται με την εμπειρία  $E$  ».

Μία βασική δυσκολία είναι ότι το σύνολο όλων των πιθανών συμπεριφορών που παρέχουν όλες τις πιθανές εισόδους είναι (στις περισσότερες περιπτώσεις πρακτικού ενδιαφέροντος) πολύ μεγάλο για να συμπεριληφθεί στο σετ των δειγμάτων . Ως εκ τούτου, ο μηχανισμός πρέπει να γενικεύει τα παραδείγματα έτσι ώστε να παράγει μία χρήσιμη εξόδο από νέες εισόδους δεδομένων. Η Οπτική αναγνώριση χαρακτήρων, στην οποία οι έντυποι χαρακτήρες αναγνωρίζονται αυτόματα με βάση προηγούμενα παραδείγματα, είναι ένα κλασικό παράδειγμα της μηχανικής μάθησης μηχανής.[6]

Γενίκευση σε αυτό το πλαίσιο είναι η ικανότητα ενός αλγορίθμου να εκτελεί με ακρίβεια τα νέα, μη ορατά δείγματα αφού πρώτα έχει εκπαιδευτεί στην εκμάθηση ενός συνόλου δεδομένων. Ο βασικός στόχος της μηχανικής μάθησης είναι να γενικεύει από την εμπειρία της. Τα παραδείγματα εκπαίδευσης προέρχονται από κάποια γενικά άγνωστη κατανομή πιθανότητας και ο «μαθητής» πρέπει να τους αποσπάσει κάτι πιο γενικό, κάτι σχετικά με τη διανομή, που του επιτρέπει να παράγει χρήσιμες προβλέψεις σε νέες περιπτώσεις.

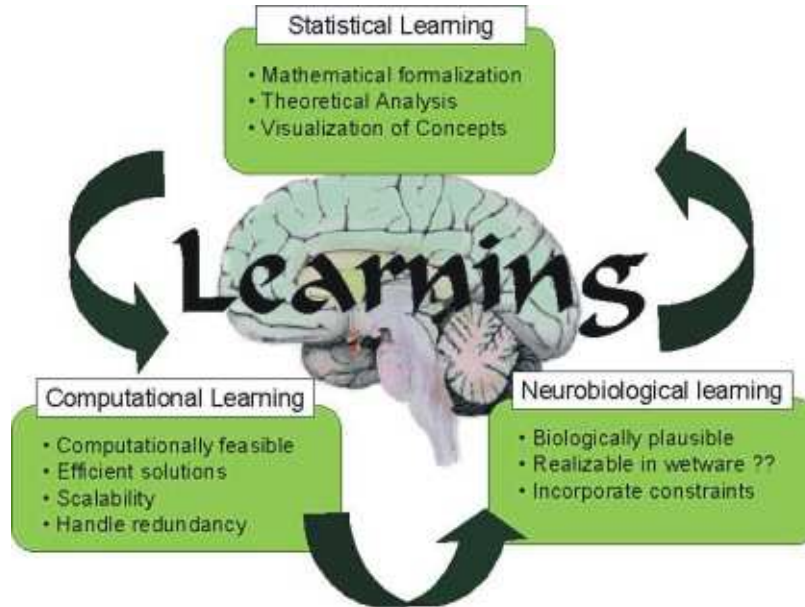
Το πρώτο στάδιο της σχεδίασης ενός συστήματος μηχανικής μάθησης συνίσταται στον προσδιορισμό της γνώσης που θα χρησιμοποιηθεί κατά την εκπαίδευσή του. Θα πρέπει να σημειωθεί πως οι όποιες επιλογές ακολουθηθούν, θα έχουν άμεση επίδραση στην απόδοση του συστήματος. Μια από τις σημαντικότερες επιλογές που μπορούν να γίνουν ως προς το είδος της παρεχόμενης γνώσης είναι το κατά πόσο προσφέρει η τελευταία στο σύστημα μηχανικής μάθησης άμεση πληροφόρηση ως προς την υπό εκμάθηση έννοια (concept), η

έμμεση, αναγκάζοντάς το να προβεί το ίδιο στην ανακάλυψή της, εκ του αποτελέσματος του σταδίου της εκπαίδευσης. Επίσης, ιδιαίτερη σημασία στην ποιότητα του σώματος εκπαίδευσης αποδίδεται στην κατανομή των παραδειγμάτων από τα οποία θα αντληθεί η γνώση από το σύστημα μηχανικής μάθησης, καθώς θα πρέπει να είναι όμοια με την αντίστοιχη κατανομή των περιπτώσεων που θα χρησιμοποιηθούν κατά τον έλεγχο της απόδοσης, ακόμα δε περισσότερο κατά τη λειτουργία του. Μια από τις πλέον συνήθεις μορφές αναπαράστασης των παραδειγμάτων είναι η διανυσματική: Κάθε παράδειγμα εκπαίδευσης, ή στιγμιότυπο (instance) όπως έχει επικρατήσει να αποκαλείται κυρίως στα προβλήματα ταξινόμησης, αποτελείται από ένα σύνολο χαρακτηριστικών (attributes ή features), μετρήσιμων δηλαδή ποσοτήτων που έχουν επιλεγεί με τέτοιο τρόπο από τα δεδομένα εκπαίδευσης, ώστε το σύστημα μηχανικής μάθησης να μπορέσει να εκμαιεύσει από τις τιμές τους τη γνώση που χρειάζεται. Ανάλογα με το είδος της πληροφορίας που κωδικοποιεί ένα χαρακτηριστικό, αυτό μπορεί να είναι συνεχές (continuous) – π.χ. ένας πραγματικός ή ακέραιος αριθμός, ή ονομαστικό (nominal), το οποίο λαμβάνει ένα προκαθορισμένο σύνολο διακριτών τιμών, αριθμητικών ή συμβολικών. Με αυτόν τον τρόπο, έχοντας επιλέξει  $I$  χαρακτηριστικά, απεικονίζουμε το χώρο του προβλήματος μας σε έναν  $I$ -διάστατο χώρο, το χώρο των στιγμιότυπων (instance space), αντιστοιχώντας κάθε στιγμιότυπο εκπαίδευσης σε ένα διάνυσμα  $I$  διαστάσεων.

Επόμενο στάδιο στη σχεδίαση του συστήματος αποτελεί ο τρόπος με τον οποίο θα διαχειριστεί το τελευταίο τη γνώση που αποκομίζει κατά την εκπαίδευση, με σκοπό την αποδοτικότερη λειτουργία του. Υιοθετώντας το μοντέλο της διανυσματικής αναπαράστασης, αναζητούμε ουσιαστικά μια συνάρτηση  $f'$  η οποία προσεγγίζει όσο το δυνατόν περισσότερο μια ιδανική συνάρτηση με την οποία δύναται να μοντελοποιηθεί το πρόβλημα, τη συνάρτηση στόχο (target function)  $f$ . Οι δύο συναρτήσεις έχουν ελεύθερη μεταβλητή ένα τυχαίο διάνυσμα  $x$ , πεδίο ορισμού το χώρο των στιγμιότυπων και σύνολο τιμών το οποίο καθορίζεται από την εκάστοτε εφαρμογή. Έτσι, η επίλυση ενός προβλήματος μηχανικής μάθησης ανάγεται στην επίλυση ενός προβλήματος προσέγγισης των τιμών μιας συνάρτησης (function approximation). Ανάλογα με το είδος της γνώσης που παρέχεται για εκπαίδευση, διαιρούμε το πεδίο της μηχανικής μάθησης σε δύο μεγάλες κατηγορίες: στη μάθηση με επίβλεψη (supervised learning), η οποία έρχεται σε αντιδιαστολή με τη μάθηση χωρίς επίβλεψη (unsupervised learning). Στην πρώτη περίπτωση, η διαδικασία της μάθησης «καθοδηγείται» από τα στιγμιότυπα εκπαίδευσης υπό την έννοια ότι υποδεικνύουν στον αλγόριθμο μάθησης την τιμή της συνάρτησης στόχου που επιδιώκει να προσεγγίσει. Στην κατηγορία αυτή ανήκουν τα λεγόμενα προβλήματα ταξινόμησης (classification learning), στα οποία το αποτέλεσμα της κατηγοριοποίησης αποτελεί χαρακτηριστικό των στιγμιότυπων εκπαίδευσης και η τιμή του για κάθε στιγμιότυπο συμπεριλαμβάνεται στα δεδομένα εκπαίδευσης. Ένα παράδειγμα προβλημάτων ταξινόμησης είναι και αυτό που εξετάζει η παρούσα εργασία.[12]

Αντίθετα, στην περίπτωση της μάθησης χωρίς επίβλεψη, ο αλγόριθμος καλείται να ανακαλύψει δομικούς σχηματισμούς στα στιγμιότυπα εκπαίδευσης, βάσει κριτηρίων τα οποία δεν του παρέχονται άμεσα. Παραδείγματα προβλημάτων που εντοπίζονται σε αυτήν την περιοχή είναι: η ομαδοποίηση οντοτήτων (clustering), όπου επιχειρείται ομαδοποίηση των στιγμιότυπων σε κλάσεις τις οποίες θα συμπεράνει ο αλγόριθμος, στηριζόμενος στην ομοιότητα των μελών κάθε ομάδας, η αριθμητική πρόβλεψη (numeric prediction), κατά την οποία δεν αναζητείται η κατηγορία ενός στιγμιότυπου αλλά μια αριθμητική ποσότητα, και η αποκάλυψη συσχετίσεων (association discovery), αντικείμενο της οποίας αποτελεί η

αναζήτηση ενδιαφερουσών δομών στα στιγμιότυπα εκπαίδευσης μέσω της ταυτόχρονης πρόβλεψης της τιμής περισσότερων του ενός χαρακτηριστικών.



Εικόνα 8:Μηχανική μάθηση

Ολοκληρώνοντας τη σύντομη αυτή αναφορά στις θεμελιώδεις έννοιες της μηχανικής μάθησης, κρίνεται σκόπιμη η παρουσίαση ενός συνόλου παραγόντων καθοριστικής σημασίας για τη σχεδίαση ενός αποδοτικού συστήματος. Από τους πλέον σημαντικούς θεωρείται η ικανότητα γενίκευσης (generalization ability) που χαρακτηρίζει ένα τέτοιο σύστημα, η ικανότητά του δηλαδή να χρησιμοποιεί την εμπειρία που απέκτησε από τα στιγμιότυπα εκπαίδευσης όσο το δυνατόν αποτελεσματικότερα επί του συνόλου των άγνωστων στιγμιότυπων ελέγχου. Εν γένει, ισχύει ότι, εφόσον η υπόθεση στην οποία κατέληξε το σύστημα μετά την εκπαίδευσή του (η αναπαράσταση δηλαδή της εμπειρίας που απέκτησε) είναι συνεπής (consistent) με την πλειοψηφία των στιγμιότυπων εκπαίδευσης, τότε θα είναι σε μεγάλο βαθμό συνεπής και με τα άγνωστα στιγμιότυπα που θα κληθεί να διαχειρισθεί κατά την κανονική λειτουργία του (στιγμιότυπα ελέγχου). Θα πρέπει να δοθεί ιδιαίτερη προσοχή ωστόσο στο να μην παρερμηνευθεί η παραπάνω πρόταση, καθώς η περίπτωση μιας υπόθεσης η οποία είναι απόλυτα συνεπής με την πλειοψηφία των στιγμιότυπων εκπαίδευσης ενέχει τον κίνδυνο της εκμάθησης των πλέον ασήμαντων λεπτομερειών που είναι δυνατόν να παρατηρηθούν σ' αυτά, με αποτέλεσμα η απόδοση του συστήματος να παρουσιάζεται ιδιαίτερα χαμηλή στα μη παρατηρηθέντα στιγμιότυπα. Το παραπάνω φαινόμενο είναι γνωστό ως φαινόμενο του υπερταυριάζματος (overfitting). Επιχειρώντας έναν πιο τυπικό ορισμό του φαινομένου, θα λέμε πως: Μια υπόθεση  $h$  υπερταυριάζει (overfits) των δεδομένων εκπαίδευσης όταν υπάρχει μια διαφορετική υπόθεση  $h'$  τέτοια ώστε, η  $h$  να παρουσιάζει μικρότερο σφάλμα από την  $h'$  επί των δεδομένων εκπαίδευσης, ενώ ταυτόχρονα η  $h'$  να παρουσιάζει μικρότερο σφάλμα από την  $h$  επί ολόκληρης της κατανομής των δεδομένων (εκπαίδευσης και ελέγχου). Μπορούμε να διακρίνουμε τους παράγοντες που συμβάλλουν στην ικανότητα γενίκευσης ενός συστήματος σε δύο κατηγορίες: σε αυτούς που σχετίζονται

με την ποιότητα της παρεχόμενης εμπειρίας στον αλγόριθμο μάθησης (σώμα εκπαίδευσης) και σε αυτούς που σχετίζονται με το μηχανισμό αξιοποίησης της πληροφορίας αυτής (αναζήτηση της βέλτιστης υπόθεσης). Καθοριστική σημασία στην ποιότητα του σώματος εκπαίδευσης φέρει η ορθή επιλογή των χαρακτηριστικών τα οποία θα συστήσουν το χώρο του προβλήματος, καθώς μέσω αυτών καθίσταται δυνατή η αναπαράσταση της γνώσης που απαιτείται για την αποδοτική λειτουργία του συστήματος. Στην περίπτωση για παράδειγμα ενός συστήματος ταξινόμησης εγγράφων, ο σχεδιαστής επιδιώκει την επιλογή των χαρακτηριστικών εκείνων που μπορούν να εγγυηθούν το διαχωρισμό του χώρου του προβλήματος σε όσο το δυνατόν πιο απομακρυσμένες μεταξύ τους περιοχές, κάθε μια εκ των οποίων να αποτελείται από στιγμιότυπα της ίδιας κατηγορίας. Επίσης, απαραίτητη θεωρείται, όπως ήδη αναφέραμε, η ομοιότητα της κατανομής των στιγμιότυπων εκπαίδευσης με την κατανομή των στιγμιότυπων που θα συναντήσει το σύστημα κατά τη διάρκεια της λειτουργίας του. Ο παράγοντας αυτός ωστόσο σχετίζεται άμεσα με το μέγεθος του σώματος εκπαίδευσης, το οποίο αποτελεί ένα περιορισμένο δείγμα του χώρου του προβλήματος.

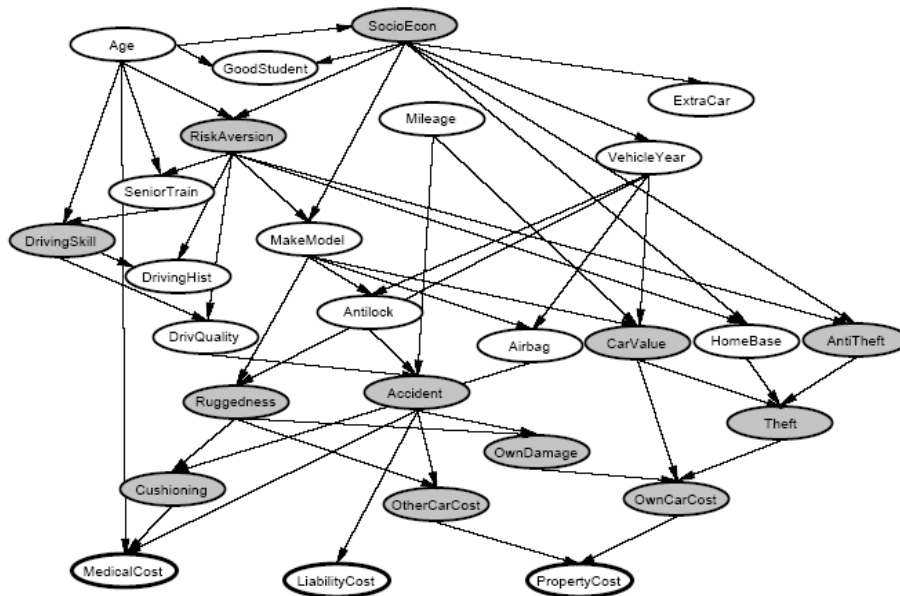
Ιδιαίτερη προσοχή θα πρέπει επίσης να δοθεί στην ορθότητα των δεδομένων που χρησιμοποιούνται για την εκπαίδευση, καθώς δεν είναι σπάνια η περίπτωση παρείσφρησης σφαλμάτων στις τιμές των χαρακτηριστικών κάποιων στιγμιότυπων. Το φαινόμενο αυτό ονομάζεται θόρυβος (noise) και συναντάται κατά τη συλλογή δεδομένων από πειραματικές μετρήσεις, αλλά και γενικότερα, όπου επεμβαίνει ο ανθρώπινος παράγοντας στη δημιουργία δεδομένων εκπαίδευσης. Όπως είναι αναμενόμενο, η εκτεταμένη παρουσία θορύβου οδηγεί στον αποπροσανατολισμό του αλγορίθμου μάθησης και στην επιλογή μιας υποβέλτιστης υπόθεσης, ελάχιστα συνεπούς με τα δεδομένα ελέγχου. Αυτό ωστόσο δε συμβαίνει και στην περίπτωση που παρουσιάζεται θόρυβος της ίδιας μορφής και στα δεδομένα αξιολόγησης, οπότε χρειάζεται να μοντελοποιηθεί και αυτός, καθώς ανάγεται πλέον σε «χαρακτηριστικό» του συγκεκριμένου προβλήματος μάθησης. Παρόμοιο φαινόμενο είναι και αυτό της απουσίας τιμών (missing values), περιπτώσεων δηλαδή όπου οι τιμές ορισμένων χαρακτηριστικών δεν αναφέρονται για κάποια από τα στιγμιότυπα. Όσον αφορά τέλος στους παράγοντες εκείνους που υποβοηθούν το μηχανισμό που υιοθετείται για την προσέγγιση της συνάρτησης στόχου, συνοψίζονται στην Αρχή της Ελάχιστης Περιγραφής (Minimum Description Length Principle ή MDL), σύμφωνα με την οποία: Η καλύτερη θεωρία που είναι δυνατόν να εξαχθεί από ένα σώμα δεδομένων είναι η μικρότερη δυνατή, η οποία απαιτεί συνάμα τη μικρότερη ποσότητα πληροφορίας που μοντελοποιεί τις εξαιρέσεις που είναι σχετικές με τη θεωρία αυτή. Η παραπάνω αρχή, γνωστή και ως «το ξυράφι του Occam» (Occam's Razor), υποστηρίζει ουσιαστικά πως οι απλούστερες θεωρίες είναι προτιμότερες από τις πιο περίπλοκες. Στην περίπτωση της μηχανικής μάθησης, είναι άμεσα συνυφασμένη με την ικανότητα της γενίκευσης που πρέπει να διακρίνει μια εξαγόμενη υπόθεση, καθώς έχει παρατηρηθεί ότι προσεγγίσεις που είναι επιρρεπείς στον κίνδυνο του υπερταϊριάσματος τείνουν να παράγουν ιδιαίτερα πολύπλοκες υποθέσεις, υποβαθμίζοντας έτσι την απόδοση του συστήματος.

## 2.2.6 Οικογένειες Αλγορίθμων Μηχανικής Μάθησης

Στη βιβλιογραφία συναντάται μια μεγάλη ποικιλία αλγορίθμων μηχανικής μάθησης, οι οποίοι μπορούν να χωριστούν σε κατηγορίες με βασικό κριτήριο τα είδη των προβλημάτων που χειρίζονται. Στην υποενότητα αυτή θα επιχειρήσουμε μια σύντομη, ποιοτική παρουσίαση των διαφορετικών οικογενειών αλγορίθμων μηχανικής μάθησης που έχουν αναπτυχθεί. Αναλυτικότερη παρουσίαση των αλγορίθμων που χρησιμοποιήθηκαν στην εργασία θα ακολουθήσει στις επόμενες υποενότητες.

### Μάθηση κατά Bayes

Η Μάθηση κατά Bayes αποτελεί μια ιδιαίτερα δημοφιλή προσέγγιση για την επαγωγική κατασκευή ταξινομητών, αφενός διότι εκπορεύεται από τον οικείο χώρο του Πιθανοτικού Λογισμού, αφετέρου διότι έχει επιδείξει σημαντικά αποτελέσματα σε ένα ευρύτατο φάσμα εφαρμογών. Η λειτουργία αυτής της κατηγορίας αλγορίθμων στηρίζεται στην υπόθεση ότι η υπό εκμάθηση έννοια σχετίζεται άμεσα με την κατανομή των πιθανοτήτων που παρουσιάζουν τα στιγμιότυπα του προβλήματος αναφορικά με την κλάση στην οποία ανήκουν. Ως βασικότερα πλεονεκτήματα της προσέγγισης αυτής μπορούμε να αναφέρουμε:



Εικόνα 9: Ένα Bayesian δίκτυο το οποίο εγκαθιδρύει τις σχέσεις μεταξύ γεγονότων σχετικά με τον τομέα ασφάλισης αυτοκινήτου.

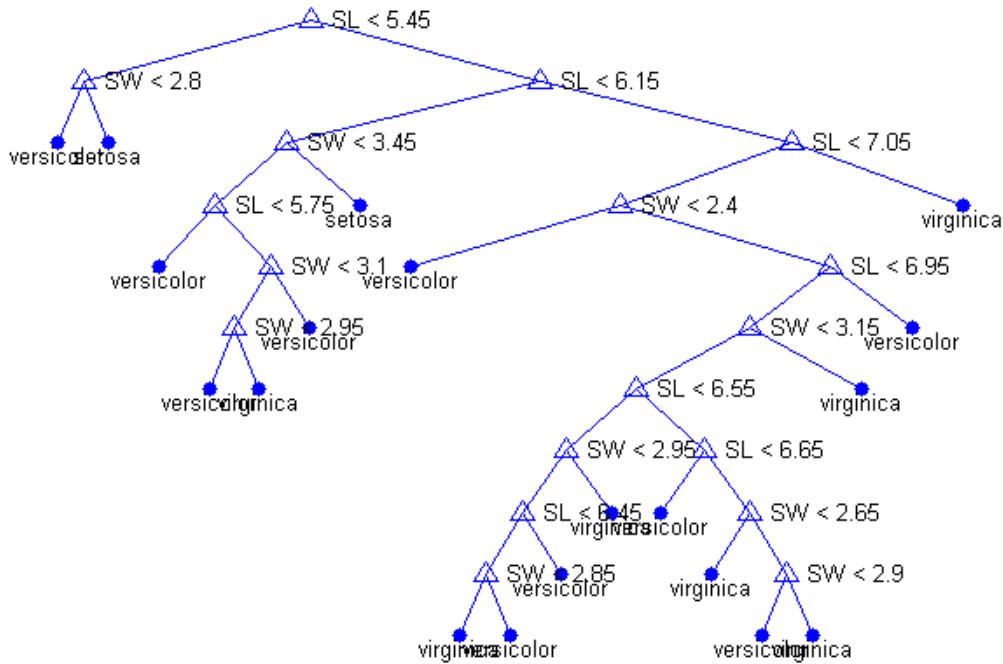
- Τη δυνατότητα αξιολόγησης των υποθέσεων στις οποίες καταλήγει ο αλγόριθμος μάθησης, μέσω της συσχέτισης ενός βαθμού εμπιστοσύνης της ορθότητάς τους, που αντιστοιχεί στην υπολογισθείσα πιθανότητα να είναι συνεπείς με την πλειοψηφία των παρατηρούμενων δεδομένων. Το χαρακτηριστικό αυτό συνεισφέρει στην παραγωγή εύρωστων μοντέλων, που εξασφαλίζουν ότι η αλήθεια μιας υπόθεσης δεν αμφισβητείται από μεμονωμένες περιπτώσεις

στιγμιότυπων για τις οποίες η υπόθεση κρίνεται ασυνεπής.

- Τη συμβολή της στη βαθύτερη κατανόηση και ανάλυση αλγορίθμων μάθησης οι οποίοι δε χειρίζονται απ' ευθείας πιθανότητες. Ένα χαρακτηριστικό παράδειγμα της ιδιότητας αυτής αποτελεί η μελέτη της επαγωγικής προδιάθεσης (inductive bias) ενός αλγορίθμου, του συνόλου των υποθέσεων δηλαδή στις οποίες στηρίζεται ο αλγόριθμος, ώστε να παράγει ένα μοντέλο ικανό να γενικεύει τις υποθέσεις στις οποίες κατέληξε κατά το χειρισμό άγνωστων στιγμιότυπων.
- Την παροχή ενός μέτρου σύγκρισης έναντι άλλων μεθόδων μηχανικής μάθησης, καθώς οι αλγόριθμοι της κατηγορίας αυτής εγγυώνται τη βέλτιστη επίλυση ενός προβλήματος, δεδομένου ενός συνόλου υποθέσεων που απλοποιούν την κατασκευή του μοντέλου.

### **Μάθηση βασισμένη σε Δένδρα Απόφασης**

Μια επίσης ευρέως χρησιμοποιούμενη μέθοδος μηχανικής μάθησης είναι και εκείνη που βασίζεται σε δένδρα απόφασης, κατά την οποία επιχειρείται η προσέγγιση μιας άγνωστης διακριτής συνάρτησης στόχου, ακολουθώντας την τεχνική του «διαίρει και βασίλευε» (Divide and Conquer). Ο χώρος του προβλήματος κατατμήνεται σε περιοχές από στιγμιότυπα που φέρουν την ίδια τιμή ως προς κάποιο χαρακτηριστικό, μια διαδικασία που επαναλαμβάνεται αναδρομικά, αναπαριστώντας με τον τρόπο αυτό το παραγόμενο μοντέλο ως δένδρο απόφασης. Οι εσωτερικοί κόμβοι ενός τέτοιου δένδρου αντιστοιχούν στη σύγκριση της τιμής ενός χαρακτηριστικού κάποιου στιγμιότυπου με μια σταθερά. Τα φύλλα του δένδρου αντιπροσωπεύουν την απόφαση του μοντέλου για την ταξινόμηση του εν λόγω στιγμιότυπου, η οποία μπορεί να έχει τη μορφή της κλάσης στην οποία αυτό ανήκει, ενός συνόλου κλάσεων, ή ακόμα και μιας πιθανοτικής κατανομής επί του συνόλου των κλάσεων στις οποίες θα μπορούσε να αποδοθεί.



Εικόνα 10: Το δέντρο απόφασης για τα δεδομένα του fisheriris.

Βάσει της παραπάνω αναπαράστασης, ένα άγνωστο στιγμιότυπο ακολουθεί τη διαδρομή από τη ρίζα προς κάποιο φύλλο του δένδρου, καθοδηγούμενο από το αποτέλεσμα των ελέγχων που διεξάγονται στους εσωτερικούς κόμβους από τους οποίους πέρασε. Κατ' ουσίαν, ένα δένδρο απόφασης αναπαριστά μια διάζευξη συζευγμένων περιορισμών επί ενός συνόλου δεδομένων απόφασης. Η διαδρομή από τη ρίζα προς κάποιο φύλλο αντιστοιχεί σε σύζευξη περιορισμών στις τιμές των χαρακτηριστικών ενός στιγμιότυπου που θα πρέπει να ισχύουν ταυτόχρονα για την απόδοση της απόφασης που αναφέρεται στο φύλλο. Στα θετικά σημεία της μεθόδου αυτής συγκαταλέγονται:


- Η ευρωστία που επιδεικνύει αναφορικά με το θόρυβο που ενδέχεται να παρουσιαστεί στα δεδομένα που απαρτίζουν το χώρο του προβλήματος.
- Η ανοχή στην απουσία τιμών (missing values), σε κάποια χαρακτηριστικά του σώματος εκπαίδευσης.
- Η χρήση ακόμα και συνεχών (μη διακριτών) χαρακτηριστικών και η προσέγγιση μη διακριτών συναρτήσεων στόχου, μέσω εξειδικευμένων τεχνικών που αναλαμβάνουν τη διακριτοποίησή τους (discretization), τη διαδικασία δηλαδή της μετατροπής συνεχών αριθμητικών χαρακτηριστικών σε ονομαστικά.
- Η δυνατότητα μεταφοράς του παραγόμενου μοντέλου από δένδρο απόφασης σε ένα σύνολο κανόνων συμπερασμού (if – then rules), προς διευκόλυνση της κατανόησής του.

### Αυτόματη Εκμάθηση Κανόνων

Μια συγγενική μεθοδολογία επαγωγικής κατασκευής ταξινομητών με αυτή των δένδρων απόφασης αποτελεί η αυτόματη εκμάθηση κανόνων, χαρακτηριστική για την ικανότητά της να παράγει ιδιαίτερα εύληπτα μοντέλα με τη μορφή κανόνων συμπερασμού



(if-then rules). Ένας μεγάλος αριθμός αλγορίθμων αυτής της οικογένειας μαθαίνουν κανόνες Κατηγορηματικής Λογικής Πρώτης Τάξης (First order Horn Clauses), που μπορούν να εκφραστούν ως προγράμματα PROLOG. Για το λόγο αυτό, η συγκεκριμένη περιοχή της μηχανικής μάθησης συναντάται στη βιβλιογραφία και ως Επαγωγικός Λογικός Προγραμματισμός (Inductive Logic Programming ή ILP). Όπως ήδη αναφέραμε, κανόνες συμπερασμού μπορούν εύκολα να προκύψουν από την εκμάθηση ενός δένδρου απόφασης και τη μετατροπή του σε κανόνες προτασιακής λογικής.



Εικόνα 11: Διαδοχική κάλυψη σφαιρικού σχήματος

Μια εναλλακτική προσέγγιση, ικανή να δώσει ένα κατά πολύ απλούστερο σύνολο κανόνων από την προηγούμενη, βασίζεται στη στρατηγική της εκμάθησης ενός κανόνα και της απομάκρυνσης από το σώμα εκπαίδευσης όλων των στιγμιότυπων τα οποία καλύπτει, η οποία επαναλαμβάνεται μέχρις ότου η ακρίβεια του συστήματος φθάσει μια επιθυμητή τιμή. Για την αποφυγή του φαινομένου του υπερταϊριάσματος, η τιμή αυτή για την ακρίβεια ταξινόμησης των στιγμιότυπων εκπαίδευσης είναι συνήθως χαμηλότερη του 100%. Οι αλγόριθμοι που ακολουθούν την παραπάνω προσέγγιση ονομάζονται Ακολουθιακοί Αλγόριθμοι Κάλυψης (Sequential Covering Algorithms).

### Μάθηση βασισμένη σε Στιγμιότυπα

Πρόκειται για μια ιδιαίτερα απλή προσέγγιση του προβλήματος της μηχανικής μάθησης, η οποία παρουσιάζει ωστόσο μια θεμελιώδη διαφορά με όλες τις υπόλοιπες οικογένειες αλγορίθμων: Ένας αλγόριθμος μάθησης βασισμένος σε στιγμιότυπα στερείται του σταδίου της εκπαίδευσης. Αντ' αυτού, ο αλγόριθμος αρκείται στην απλή απομνημόνευση όλων των στιγμιότυπων εκπαίδευσης που του παρέχονται, τα οποία χρησιμοποιεί μόνο όταν

κληθεί να αποφανθεί για ένα άγνωστο στιγμιότυπο. Η απόφαση αυτή λαμβάνεται με βάση την ομοιότητα του αγνώστου στιγμιότυπου με τα αποθηκευμένα. Για το λόγο αυτό, έχει επικρατήσει το είδος αυτό της μάθησης να αποκαλείται «νωχελική μάθηση» (lazy learning). Ο έλεγχος ομοιότητας δύο στιγμιότυπων επιτυγχάνεται με τη χρήση μιας συνάρτησης απόστασης, η οποία επιλέγεται κατ' αναλογία με τη φύση του εκάστοτε προβλήματος. Από τα παραπάνω, γίνεται αντιληπτό ότι οι αλγόριθμοι της κατηγορίας αυτής δεν κατασκευάζουν ένα καθολικό μοντέλο που να αναπαριστά τη γνώση που απέκτησαν από τα δεδομένα της εκπαίδευσης, αλλά ο προσδιορισμός της συνάρτησης στόχου γίνεται τοπικά, με κάθε ταξινόμηση ενός άγνωστου στιγμιότυπου, αντλώντας πληροφορίες από τα χαρακτηριστικά της ομάδας στιγμιότυπων με τα οποία συγγενεύει.

Αυτή ακριβώς η διαφοροποίηση της συγκεκριμένης κατηγορίας αλγορίθμων αποτελεί ένα από τα σημαντικότερα πλεονεκτήματα και συνάμα μειονεκτήματά τους. Ο τοπικός προσδιορισμός της συνάρτησης στόχου κατά την ταξινόμηση κάθε στιγμιότυπου κρίνεται επιθυμητός όταν μια συνάρτηση στόχου, καθολικά συνεπής με το σώμα εκπαίδευσης, είναι ιδιαίτερα περίπλοκη. Ωστόσο, η μεταφορά του προσδιορισμού της συνάρτησης στόχου στο στάδιο της λήψης της απόφασης έχει ως αποτέλεσμα την αύξηση του κόστους ταξινόμησης νέων στιγμιότυπων, τόσο ως προς τον χρόνο που απαιτείται όσο και ως προς την υπολογιστική πολυπλοκότητα. Ο παράγοντας αυτός μπορεί σε κάποιο βαθμό να αντισταθμισθεί χρησιμοποιώντας τεχνικές ευρετηριοποίησης των στιγμιότυπων εκπαίδευσης. Σημαντικό χαρακτηριστικό επίσης για την αποτελεσματικότητα των αλγορίθμων αυτών αποτελεί η επιλογή της συνάρτησης απόστασης, αλλά και των χαρακτηριστικών εκείνων που θα χρησιμοποιηθούν κατά την εύρεση της ομάδας συγγενών στιγμιότυπων, καθώς ενδέχεται ένα μικρό υποσύνολο των χαρακτηριστικών να είναι αρκετό, ενώ η χρήση περισσότερων να κριθεί επιζήμια για την ικανότητα γενίκευσης της μεθόδου. Τέλος, οι εν λόγω αλγόριθμοι χαρακτηρίζονται εν γένει για την αστάθειά τους στην ύπαρξη θορύβου στα δεδομένα εκπαίδευσης. Κυριότεροι εκπρόσωποι της κατηγορίας αυτής είναι οι αλγόριθμοι των  $k$  κοντινότερων γειτόνων ( $k$  Nearest Neighbors ή  $k$ -NN), της τοπικής παλινδρόμησης με βάρη (Locally Weighted Regression), καθώς και η μέθοδος της συλλογιστικής βασισμένης σε περιπτώσεις (Case-Based Reasoning).


### **Μάθηση βασισμένη σε Τεχνητά Νευρωνικά Δίκτυα**

Χαρακτηριστικός εκπρόσωπος της μηχανικής μάθησης είναι τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks ή A.N.N.s), τα οποία επιδιώκουν να μιμηθούν τη λειτουργία του σχηματισμού των νευρώνων που συναντώνται στα βιολογικά συστήματα μάθησης. Κατ' αντιστοιχία λοιπόν με το βιολογικό τους ανάλογο, τα τεχνικά νευρωνικά δίκτυα αποτελούνται από ένα σύνολο πολύπλοκα διασυνδεδεμένων απλούστερων μονάδων, διατεταγμένων συνήθως σε επίπεδα. Η δε εκμάθηση της συνάρτησης στόχου αντιστοιχεί ουσιαστικά στην αναζήτηση των συνδέσμων μεταξύ ενός νευρώνα του επιπέδου  $i$  και των νευρώνων του επόμενου επιπέδου  $i+1$ . Τα τεχνητά νευρωνικά δίκτυα διακρίνονται για την ικανότητά τους να προσεγγίζουν τόσο διακριτές όσο και συνεχείς, πραγματικές, ακόμα και διανυσματικές συναρτήσεις στόχου, για την ευρωστία τους όσον αφορά την παρείσφρηση θορύβου στα δεδομένα εκπαίδευσης, καθώς και για την ταχύτητά τους κατά την ταξινόμηση

άγνωστων στιγμιοτύπων. Απαιτούν ωστόσο μεγάλους χρόνους εκπαίδευσης, ενώ τις περισσότερες φορές το εξαγόμενο μοντέλο δεν παρέχεται σε καταληπτή μορφή.

### Μάθηση βασισμένη σε Γενετικούς Αλγορίθμους

Ο φυσικός κόσμος αποτελεί πηγή έμπνευσης και αυτής της κατηγορίας αλγορίθμων μάθησης, η οποία βασίζεται στη διαδικασία της αναπαραγωγής των ζώντων οργανισμών. Στην προκειμένη περίπτωση, η προσέγγιση της συνάρτησης στόχου ξεκινά με ένα σύνολο αρχικών υποθέσεων που συνήθως αναπαρίστανται ως ακολουθίες δυαδικών ψηφίων. Το σύνολο αυτό εξελίσσεται συνεχώς με τη χρήση των διαδικασιών της διασταύρωσης (crossover) και της μεταλλαγής (mutation), όροι δανεισμένοι από τη βιολογία, που υποδηλώνουν ότι μια «νέα γενιά» υποθέσεων προκύπτει από την προηγούμενή της, μέσω της συγχώνευσης χαρακτηριστικών παλαιότερων υποθέσεων αλλά και της μεταλλαγής αυτών σε νέα χαρακτηριστικά. Κάθε βήμα της εξελικτικής αυτής διαδικασίας περιλαμβάνει την επιλογή ενός υποσυνόλου με τις πιο «υγιείς» υποθέσεις, οι οποίες θα αποτελέσουν το υλικό για την «αναπαραγωγή» και το σχηματισμό μιας νέας γενιάς.



Εικόνα 12:Γενετικός αλγόριθμος

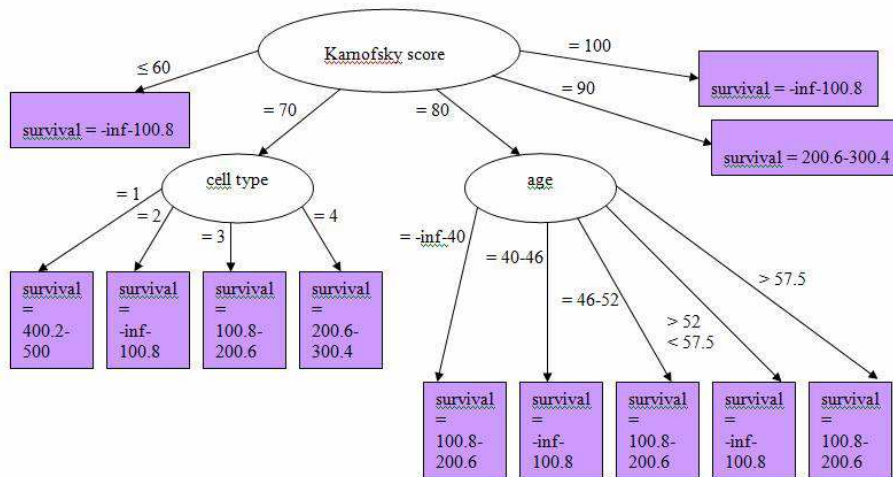
Οι γενετικές μέθοδοι κρίνονται ιδανικές για τη χρήση τους σε χώρους υποθέσεων που περιέχουν περίπλοκους σχηματισμούς που αλληλεπιδρούν μεταξύ τους με τρόπο που καθιστά ιδιαίτερα δύσκολη τη μοντελοποίησή τους. Επίσης, ο μεγάλος βαθμός παραλληλίας που εγγενώς τις χαρακτηρίζει, επιτρέπει την εκτέλεσή τους σε παράλληλα συστήματα, επιταχύνοντας κατά πολύ το στάδιο της εκπαίδευσης τους. Κλάδο της περιοχής αυτής αποτελεί και ο λεγόμενος Γενετικός Προγραμματισμός (Genetic Programming), που περιλαμβάνει την επιβλεπόμενη ή μη εξέλιξη ενός αρχικού προγράμματος, μέσω της

διασταύρωσης και της μεταλλαγής που αναφέρθηκαν παραπάνω. Ουσιαστικά, ο ρόλος του προγραμματιστή περιορίζεται στην παροχή του αρχικού προγράμματος και στον καθορισμό της εξελικτικής πορείας που θα ακολουθηθεί.

### Μέτα-Μάθηση (Meta-Learning)

Όπως ήδη αναφέραμε σε προηγούμενη ενότητα, η αποδοτικότητα ενός μοντέλου που παράγεται από αλγόριθμους μάθησης καθορίζεται τόσο από το μέγεθος και την ποιότητα του σώματος εκπαίδευσης, όσο και από την καταλληλότητα του χρησιμοποιούμενου αλγορίθμου μάθησης, παράγοντες οι οποίοι είναι κατά γενική ομολογία δύσκολο να προσδιορισθούν. Μια εναλλακτική προσέγγιση επιδιώκει να αυξήσει την αξιοπιστία ενός συστήματος μηχανικής μάθησης, επιστρατεύοντας την «εμπειρία» περισσότερων του ενός μοντέλων – «ειδικών» (experts), από τον κατάλληλο συνδυασμό των οποίων προκύπτει η τελική απόφασή, αναφορικά με ένα άγνωστο στιγμιότυπο του προβλήματος. Στην περιοχή αυτή της μηχανικής μάθησης, η οποία ονομάζεται Μέτα-Μάθηση (Meta-Learning), συγκαταλέγονται οι ακόλουθες μεθοδολογίες συνδυασμού μοντέλων:


- Bagging: Η μέθοδος αυτή συνίσταται στην παραγωγή ενός αριθμού μοντέλων, προερχόμενων από έναν κοινό αλγόριθμο μάθησης, χρησιμοποιώντας όμως διαφορετική διαμέριση του σώματος εκπαίδευσης για κάθε ένα εξ αυτών. Για τη λήψη απόφασης ακολουθείται συνήθως η πλειοψηφική λογική. Κάθε μοντέλο αποφαινεται για την κλάση ενός άγνωστου στιγμιότυπου (αν θεωρήσουμε για παράδειγμα ένα σύστημα ταξινόμησης), με την τελική απόφαση του συστήματος να συμπίπτει με την απόφαση της πλειοψηφίας.



Εικόνα 13: Παράδειγμα δέντρου απόφασης που παράγεται με τη χρήση του Weka bagging αλγορίθμου.

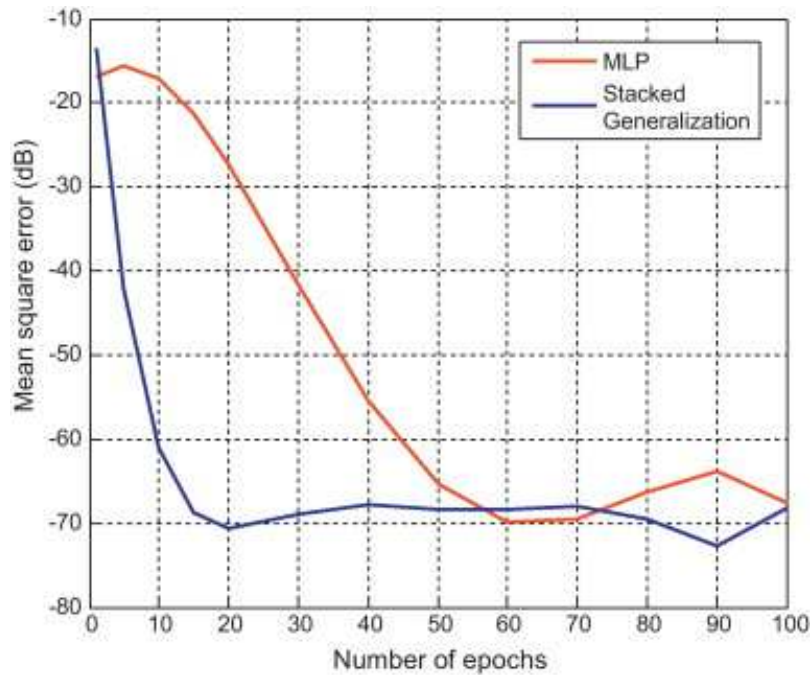
- Boosting: Παρόμοια διαδικασία με την προηγούμενη εφαρμόζεται και στην περίπτωση της Προώθησης (Boosting), με τη διαφορά ότι τα μοντέλα που συστήνουν την επιτροπή των

ειδικών παράγονται διαδοχικά, προκειμένου κάθε καινούριο μοντέλο να επηρεάζεται άμεσα από την απόδοση των προηγούμενων του, επιδιώκοντας να αποφύγει λανθασμένες αποφάσεις που ενδεχομένως προηγήθηκαν. Επίσης, οι αποφάσεις των επιμέρους μοντέλων λαμβάνονται υπ' όψη με διαφορετική βαρύτητα, ανάλογα με την αποδοτικότητά τους.



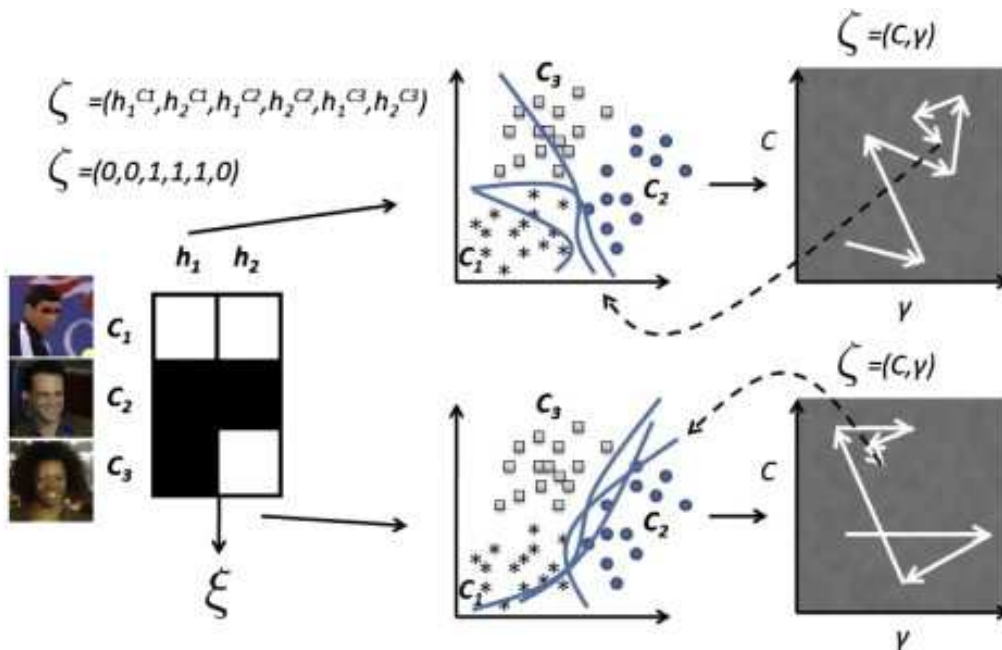
Εικόνα 14: Προσαρμογή του γραμμικού ταξινομητή. Επάνω σειρά: without forgetting,

- **Stacking:** Η μέθοδος της Συσσωρευμένης Γενίκευσης (Stacked Generalization ή Stacking) κάνει χρήση ενός συνόλου μοντέλων που, σε αντίθεση με τις προσεγγίσεις που παρουσιάστηκαν ως τώρα, προέρχονται από διαφορετικούς αλγορίθμους μάθησης. Επίσης, η λήψη της τελικής απόφασης δεν προϋποθέτει πλέον την υιοθέτηση της απόφασης της πλειοψηφίας ή τη ζυγισμένη εκτίμηση των επιμέρους αποφάσεων, αλλά κάνει χρήση ενός μοντέλου – προέδρου, το οποίο μαθαίνει ποιο από τα μέλη της επιτροπής θα πρέπει να εμπιστεύεται σε κάθε περίπτωση. Πρόκειται ουσιαστικά για την επίλυση ενός νέου προβλήματος μάθησης, με δεδομένα τις αποφάσεις των μελών της επιτροπής (που ονομάζονται μοντέλα μηδενικού επιπέδου – level 0 inducers), καθώς και την πραγματική τιμή της συνάρτησης στόχου, για τα στιγμιότυπα ενός υποσυνόλου του σώματος εκπαίδευσης του αρχικού προβλήματος που δε χρησιμοποιήθηκαν κατά την εκπαίδευση των μοντέλων αυτών. Το μοντέλο που παράγεται κατά το δεύτερο αυτό στάδιο, το οποίο εκτελεί χρέη προέδρου, ονομάζεται μοντέλο πρώτου επιπέδου (level 1 inducer).



Εικόνα 15: Το μέσο τετραγωνικό σφάλμα με την μέθοδο της Συσσωρευμένης Γενίκευσης.

- Κωδικοποίηση Διόρθωσης Λαθών Εξόδου (Error-Correcting Output Codes): Η τεχνική αυτή χρησιμοποιείται για τη βελτίωση της απόδοσης των αλγορίθμων μηχανικής μάθησης στην περίπτωση προβλημάτων πολλών κλάσεων. Ένα πρόβλημα  $n$  κλάσεων αποσυντίθεται σε ένα σύνολο ανεξάρτητων ισάριθμων προβλημάτων δύο κλάσεων, για κάθε ένα εκ των οποίων εκπαιδεύεται ένας αλγόριθμος μάθησης. Επίσης, οι κλάσεις του αρχικού προβλήματος κωδικοποιούνται σε ακολουθίες δυαδικών ψηφίων. Κατά την ταξινόμηση ενός άγνωστου στιγμιότυπου αποφαινόνται όλα τα μοντέλα, βγάζοντας ως έξοδο 0 ή 1 ανάλογα με το εάν ανήκει ή όχι στην κλάση που έχουν μάθει. Έτσι, σχηματίζεται μια ακολουθία δυαδικών ψηφίων για το προς ταξινόμηση στιγμιότυπο, το οποίο τελικά ανατίθεται στην κλάση εκείνη που η δυαδική της αναπαράσταση έχει τη μικρότερη απόσταση με την δυαδική αναπαράσταση που του αντιστοιχήθηκε. Ολοκληρώνοντας τη σύντομη αναφορά μας στις διαφορετικές οικογένειες αλγορίθμων μηχανικής μάθησης που έχουν αναπτυχθεί, θα επικεντρώσουμε εν συνεχεία την προσοχή μας στα χαρακτηριστικά των αλγορίθμων εκείνων που χρησιμοποιήθηκαν για την εκπόνηση της παρούσας εργασίας.



Εικόνα 16: Εξελικτική βελτιστοποίηση για ένα toy problem με την βοήθεια της κωδικοποίησης διόρθωσης λαθών εξόδου.

### 2.2.7 Support vector machines

Θα ολοκληρώσουμε την παρουσίαση των αλγορίθμων μάθησης που χρησιμοποιήθηκαν στην παρούσα εργασία με τις Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines ή SVMs), ένα είδος συγκερασμού γραμμικών μοντέλων και μάθησης βασισμένης σε στιγμιότυπα. Στόχος του αλγορίθμου αυτού είναι η επιλογή ενός μικρού αριθμού στιγμιότυπων εκπαίδευσης από κάθε κλάση, των διανυσμάτων υποστήριξης (support vectors), που συνορεύουν στο χώρο του προβλήματος με στιγμιότυπα άλλων κλάσεων. Τα επιλεγμένα στιγμιότυπα χρησιμοποιούνται για την κατασκευή μιας γραμμικής συνάρτησης διάκρισης (discriminant function), ικανής να τα διαχωρίσει όσο το δυνατόν περισσότερο. Τα συστήματα ταξινόμησης που βασίζονται στον αλγόριθμο αυτό αποτελούν σήμερα μια από τις δημοφιλέστερες προσεγγίσεις στο χώρο της κατηγοριοποίησης κειμένου, λόγω της ευρωστίας, της αποτελεσματικότητας και της ταχύτητας που επιδεικνύουν, αλλά και της ικανότητάς τους να παράγουν μη γραμμικές επιφάνειες απόφασης, καθιστώντας έτσι υπολογιστικά εφικτή την επίλυση ενός μεγάλου αριθμού πρακτικών προβλημάτων μάθησης που δεν μπορούν να αντιμετωπιστούν από γραμμικά μοντέλα. Εν συνεχεία θα αναπτύξουμε τα βασικά σημεία της θεωρίας των SVMs, στην απλή περίπτωση ενός προβλήματος ταξινόμησης δύο γραμμικά διαχωρίσιμων κλάσεων.

Υιοθετώντας το μοντέλο της διανυσματικής αναπαράστασης του χώρου ενός προβλήματος, θεωρούμε ένα σύνολο  $n$  διανυσμάτων εκπαίδευσης, διάστασης  $l+1$ , έστω  $X = \{\bar{x}_1, \dots, \bar{x}_i, \dots, \bar{x}_n\}$ , όπου  $\bar{x}_i = [a_0, a_1, \dots, a_{l-1}, a_l]$  με τα  $a_0, a_1, \dots, a_{l-1}$  να αποτελούν τα  $l$  χαρακτηριστικά του χώρου  $S$  και με  $y_i \in \{-1, 1\}$  την κλάση στην οποία το  $i$ -οστό στιγμιότυπο ανήκει. Λόγω της γραμμικής διαχωρισιμότητας των κλάσεων που υποθέσαμε, μπορούμε να

βρούμε ένα υπερεπίπεδο  $\Pi$  το οποίο να διαχωρίζει κατά βέλτιστο τρόπο τα διανύσματα εκπαίδευσης, με εξίσωση  $\vec{w} \cdot \vec{x} + b = 0$ , όπου  $\vec{w}$  το κανονικό διάνυσμα του  $\Pi$ ,  $\bullet$  το εσωτερικό γινόμενο δυο διανυσμάτων και  $|b|/\|\vec{w}\|$  η κατακόρυφη απόσταση της αρχής του συστήματος συντεταγμένων από το  $\Pi$ . Βάσει των παραπάνω, για το τυχαίο διάνυσμα εκπαίδευσης  $x_i$  θα ισχύουν οι ακόλουθες σχέσεις:

$$\vec{w} \cdot \vec{x}_i + b \geq 1, \text{ αν } y_i = 1 \quad (1)$$

$$\vec{w} \cdot \vec{x}_i + b \leq -1, \text{ αν } y_i = -1 \quad (2)$$

οι οποίες εκφράζονται ισοδύναμα ως εξής:

$$y_i (\vec{w} \cdot \vec{x}_i + b) - 1 \geq 0 \quad (3)$$

Ας εστιάσουμε πλέον την προσοχή μας στα διανύσματα εκπαίδευσης που ικανοποιούν την ισότητα της σχέσης (1): Αν τα θεωρήσουμε σαν σημεία του 1-διάστατου χώρου  $S$ , αυτά θα βρίσκονται στο υπερεπίπεδο  $\Pi 1$ :  $\vec{w} \cdot \vec{x} + b = 1$ , με  $\vec{w}$  το κανονικό του διάνυσμα και με  $|1 - b|/\|\vec{w}\|$  την κατακόρυφη απόσταση της αρχής του συστήματος συντεταγμένων από το  $\Pi 1$ . Ομοίως, τα σημεία του  $S$  που ικανοποιούν την ισότητα της (2) θα βρίσκονται στο υπερεπίπεδο  $\Pi 2$ :  $\vec{w} \cdot \vec{x} + b = -1$ , με  $\vec{w}$  το κανονικό διάνυσμά του και με  $|-1 - b|/\|\vec{w}\|$  την κατακόρυφη απόσταση της αρχής του συστήματος συντεταγμένων από το  $\Pi 2$ . Τα προαναφερθέντα διανύσματα εκπαίδευσης καλούνται διανύσματα υποστήριξης (support vectors), ενώ η απόσταση μεταξύ των δύο υπερεπιπέδων που σχηματίζουν, ίση με  $2/\|\vec{w}\|^2$ , μεγιστοποιείται όταν το  $\|\vec{w}\|^2$  ελαχιστοποιηθεί. Θα πρέπει τέλος να σημειώσουμε ότι για την περίπτωση που εξετάζουμε, στην περιοχή που ορίζεται από τα  $\Pi 1$  και  $\Pi 2$ , και που ονομάζεται περιθώριο (margin), δεν αντιστοιχίζεται κανένα διάνυσμα εκπαίδευσης. Αποδεικνύεται [Vapnik 1995, Burges 1998] ότι η ελαχιστοποίηση της νόρμας του διανύσματος  $\vec{w}$  μπορεί να επιτευχθεί μέσω της συνάρτησης:

$$F(\vec{a}) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j (\vec{x}_i \cdot \vec{x}_j) y_i y_j \quad (4)$$

όπου  $\vec{x}_i$  ένα διάνυσμα εκπαίδευσης, και  $\vec{a}$  ένα διάνυσμα πολλαπλασιαστών Lagrange, με τα στοιχεία του θετικά,  $a_j \geq 0$ . Ένα διάνυσμα  $\vec{x}_j$  καλείται διάνυσμα υποστήριξης όταν η αντίστοιχη παράμετρος  $a_j$  είναι αυστηρά μεγαλύτερη του μηδενός. Έχοντας υπολογίσει τα διανύσματα υποστήριξης κατά την εκπαίδευση του αλγορίθμου, έστω  $r$  στον αριθμό, η ταξινόμηση ενός αγνώστου στιγμιότυπου  $\vec{x}$  συνίσταται στον υπολογισμό της τιμής της συνάρτησης:

$$f(\vec{x}) = \text{sign}\{\vec{w} \cdot \vec{x} + b\}, \text{ όπου } (5)$$

$$\vec{w} = \sum_{i=1}^r a_i y_i x_i$$

Εάν η υπόθεση της γραμμικής διαχωρισιμότητας των κλάσεων δεν ισχύει, αναγκάζομαστε να χαλαρώσουμε τους περιορισμούς των σχέσεων (1) και (2), επιτρέποντας σε κάποια διανύσματα εκπαίδευσης να βρίσκονται μεταξύ των υπερεπιπέδων  $\Pi 1$  και  $\Pi 2$ . Στην προκειμένη περίπτωση, η ποσότητα που θα πρέπει να ελαχιστοποιηθεί είναι η:

$$\|\vec{w}\|^2 + c \sum_{i=1}^n \xi_i \quad (6)$$




υπό τον περιορισμό ότι:  $y_i (\bar{w} \cdot \vec{x}_i + b) \geq 1 - \xi_i$ , με  $\xi_i \geq 0$ .

Η παράμετρος  $\xi_i$  επιτρέπει στο αντίστοιχο διάνυσμα εκπαίδευσης να βρεθεί στην περιοχή του περιθωρίου εφόσον είναι μεγαλύτερη του μηδενός, ενώ η παράμετρος  $c$ , η οποία πρέπει να προσδιοριστεί από το χρήστη, εκφράζει την αυστηρότητα που αναμένεται να επιδείξει ο αλγόριθμος στην ανοχή στιγμιότυπων στο περιθώριο, κατά την εύρεση του βέλτιστου υπερεπιπέδου. Όπως και στην περίπτωση των γραμμικά διαχωρίσιμων κλάσεων, μπορούμε να μεγιστοποιήσουμε τη συνάρτηση  $F(\vec{a})$ , υπό τον περιορισμό  $0 \leq a_i \leq c$  αντί του  $a_i \geq 0$ , ένα πρόβλημα το οποίο συναντάται στη βιβλιογραφία ως πρόβλημα τετραγωνικής βελτιστοποίησης με περιορισμούς (constrained quadratic optimization problem), επιλύσιμο μέσω γενικευμένων τετραγωνικών προγραμματιστικών τεχνικών ή ακόμα και εξειδικευμένων στην περιοχή των SVMs [Platt 1998]. Καθοριστική σημασία για την ικανότητα γενίκευσης του αλγορίθμου φέρει η επιλογή της παραμέτρου  $c$ , καθώς όσο μεγαλύτερη είναι η τιμή της, τόσο πιο αυστηρό είναι το επαγόμενο μοντέλο στον προσδιορισμό ενός υπερεπιπέδου ικανού να διαχωρίσει σωστά την πλειοψηφία των διανυσμάτων εκπαίδευσης, ακόμα και αυτών εντός του περιθωρίου.

Μεγάλες τιμές του  $c$  επομένως καθιστούν πιθανή την εμφάνιση, σε σχετικά μικρό βαθμό, του φαινομένου του υπερταιριάσματος (overfitting), ιδιαίτερα όταν η διάσταση του χώρου είναι μεγάλη και τα διανύσματα εκπαίδευσης απομακρύνονται μεταξύ τους. Το γεγονός αυτό φαίνεται πως έρχεται σε αντίθεση τόσο με τη γραμμικότητα του μοντέλου, όσο και με τη φύση του αλγορίθμου, καθώς το φαινόμενο του υπερταιριάσματος μπορεί να παρατηρηθεί μόνο αν προστεθούν ή αφαιρεθούν στο μοντέλο διανύσματα υποστήριξης, με αποτέλεσμα να αλλάξει το υπερεπίπεδο μέγιστου περιθωρίου. Στο σημείο αυτό θα πρέπει να τονίσουμε ότι το προαναφερθέν ενδεχόμενο θεωρείται σχετικά σπάνιο να παρατηρηθεί σε έναν ταξινομητή SVM, αφού τα διανύσματα υποστήριξης αποτελούν ένα πολύ μικρό ποσοστό των διανυσμάτων εκπαίδευσης, όχι όμως και εντελώς απίθανο.

Ας θεωρήσουμε για παράδειγμα την περίπτωση δύο γραμμικά διαχωρίσιμων κλάσεων, με τα διανύσματα εκπαίδευσης να μπορούν να αναπαρασταθούν στο χώρο των δύο διαστάσεων (σχήμα 2.2), και τις κλάσεις να απέχουν πολύ μεταξύ τους.



Εικόνα 17: Παράδειγμα εμφάνισης του φαινομένου του υπερταιριάσματος στους ταξινομητές SVM.

Στην κάπως εξεζητημένη αυτή περίπτωση, παρατηρούμε ότι όλα τα διανύσματα εκπαίδευσης αποτελούν διανύσματα υποστήριξης, με αποτέλεσμα το υπερεπίπεδο μέγιστου περιθωρίου να είναι μια οριζόντια γραμμή στο μέσο του χώρου που ορίζουν οι δύο κλάσεις και μάλιστα ανεξάρτητη της τιμής του  $c$ . Αν ωστόσο υπεισέλθει θόρυβος στα δεδομένα εκπαίδευσης το επαγόμενο μοντέλο ενδέχεται να αλλάξει δραματικά. Στην προκειμένη περίπτωση, η προσθήκη τεσσάρων ακόμα διανυσμάτων εκπαίδευσης στο μέσο του χώρου δεν επιφέρει καμία ουσιαστική αλλαγή στη συμπεριφορά του αλγορίθμου, αν επιλεγεί μικρή τιμή για το  $c$ , καθώς τον κάνει ανεκτικό σε μικρό αριθμό σφαλμάτων εκπαίδευσης. Μεγάλη τιμή του  $c$  ωστόσο θα ωθήσει τον αλγόριθμο να ταξινομήσει όσο το δυνατόν περισσότερα διανύσματα εκπαίδευσης σωστά, οδηγώντας στο διαγώνιο διαχωρισμό του επιπέδου, όπως φαίνεται στο σχήμα, που απέχει πολύ από τον επιθυμητό. Όπως απέδειξαν οι Boser, Guyon και Vapnik [1992], ο υπό εξέταση αλγόριθμος είναι εφαρμόσιμος και στην περίπτωση που η συνάρτηση διάκρισης δεν είναι γραμμική ως προς τα δεδομένα εκπαίδευσης. Αυτό που απαιτείται είναι ο μετασχηματισμός του χώρου του προβλήματος σε έναν άλλο χώρο, μεγαλύτερης ή και άπειρης διάστασης μέσω μιας απεικόνισης  $\Phi : S \rightarrow H$ . Ο υπολογισμός όμως των εσωτερικών γινομένων των τύπων (4) και (5) σε ένα χώρο απείρων διαστάσεων ( $\Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j)$ ), ο οποίος καθίσταται ομολογουμένως προβληματικός, μπορεί να αποφευχθεί αν χρησιμοποιηθεί μια συνάρτηση πυρήνα  $K$ , τέτοια ώστε:  $K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j)$ . Εφαρμόζοντας το τέχνασμα αυτό, επιτυγχάνουμε την κατασκευή μιας μηχανής διανυσμάτων υποστήριξης σ' ένα χώρο απείρων διαστάσεων, ανάγοντας τη μη γραμμική επιφάνεια διάκρισης του αρχικού χώρου  $S$  σε γραμμική, χωρίς να εισάγουμε επιπλέον υπολογιστικό φόρτο στο σύστημα.

Ένα ακόμα πλεονέκτημα των SVMs είναι η ικανότητά τους να χειρίζονται πολύ μεγάλους χώρους χαρακτηριστικών, καθιστώντας το στάδιο της επιλογής χαρακτηριστικών, που συνήθως προηγείται αυτού της εκπαίδευσης, περιττό. Επίσης, αξιοσημείωτη είναι και η ανεκτικότητα που παρουσιάζουν όσον αφορά στο πλήθος των στιγμιοτύπων εκπαίδευσης, ιδιαίτερα όταν αυτό διαφέρει μεταξύ των δύο κλάσεων, καθώς τα SVMs δεν επιδιώκουν να ελαχιστοποιήσουν το σφάλμα των δεδομένων εκπαίδευσης, αλλά να τα διαχωρίσουν αποτελεσματικά σε ένα χώρο μεγάλης διάστασης. Όσον αφορά τέλος στους χρόνους εκπαίδευσης και ελέγχου του αλγορίθμου, αυτοί αποδεικνύονται κάπως αυξημένοι, ιδιαίτερα όταν η διάσταση του χώρου είναι μεγάλη, ή όταν η συνάρτηση διάκρισης δεν είναι γραμμική.

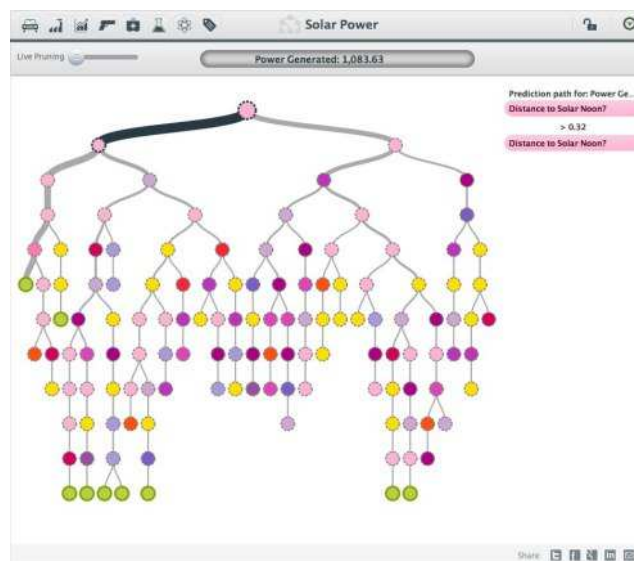
### 2.3 Μοντέλα

Τα μοντέλα που χρησιμοποιήθηκαν στο σύστημά μας βασίζονται στον τομέα της Τεχνητής Νοημοσύνης. Η Τεχνητή Νοημοσύνη αναφέρεται στον κλάδο της επιστήμης υπολογιστών ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, κατανόηση από συμφραζόμενα, επίλυση προβλημάτων κλπ. Το σύστημα που περιγράφεται στην παρούσα πτυχιακή στοχεύει στην εξαγωγή συμπερασμάτων χρήσιμων για την λήψη απόφασης της ασφάλειας και σταθερότητας που μπορεί να προσφέρει μία σύγχρονη

επίχειρηση παροχής ηλεκτρισμού. Οι αλγόριθμοι που περιγράφονται και χρησιμοποιούνται ποικίλλουν, αλλά όλοι τους στηρίζονται στην τεχνική της μηχανικής μάθησης.

### 2.3.1 Μηχανική μάθηση σε ηλεκτρολογικές και ηλεκτρονικές εφαρμογές

Η επιστήμη ηλεκτρολόγου μηχανικού (επίσης ηλεκτρική εφαρμοσμένη μηχανική) ασχολείται με προβλήματα που συνδέονται με τα μεγάλης κλίμακας ηλεκτρικά συστήματα, όπως η μετάδοση ισχύος και ο έλεγχος μηχανών, ενώ η συναφής επιστήμη ηλεκτρονικού μηχανικού εξετάζει τα μικρής κλίμακας ηλεκτρονικά συστήματα, συμπεριλαμβανομένων των ηλεκτρονικών υπολογιστών και των ολοκληρωμένων κυκλωμάτων. Οι ηλεκτρολόγοι μηχανικοί ασχολούνται συνήθως με τη διαβίβαση της ηλεκτρικής ενέργειας, ενώ οι ηλεκτρονικοί ασχολούνται κυρίως με τη χρησιμοποίηση της ηλεκτρικής ενέργειας για να διαβιβάσουν πληροφορίες. Ο συγκεκριμένος τομέας έγινε αρχικά ένα ευπροσδιόριστο επάγγελμα προς τα τέλη του 19ου αιώνα με την εξάπλωση και εμπορευματοποίηση των δικτύων τηλεπικοινωνιών και ηλεκτροδότησης. Ο τομέας καλύπτει ευρύτερα μια σειρά από πολλές εφαρμογές, συμπεριλαμβανομένων εκείνων που εξετάζουν την ισχύ, την οπτικοηλεκτρονική, την ηλεκτρονική, τον αυτοματισμό, τους υπολογιστές, την τεχνητή νοημοσύνη, την επεξεργασία σήματος και τις τηλεπικοινωνίες. Στην παρούσα πτυχιακή εργασία συνδυάζεται το μοντέλο της μηχανικής μάθησης με αυτό της επιστήμης ηλεκτρικής εφαρμοσμένης μηχανικής, με στόχο την αξιολόγηση ενός συστήματος παροχής ηλεκτρισμού. Αυτό επιτυγχάνεται με την επεξεργασία πραγματικών δεδομένων από ηλεκτρολογικές και ηλεκτρονικές μετρήσεις. Για το λόγο αυτό το σύστημα είναι ιδιαίτερα ρεαλιστικό και ανταποκρίνεται πλήρως στα σημερινά δεδομένα που επιτάσσει μια σύγχρονη κοινωνία. [15]



Εικόνα 18: Πρόβλεψη εξόδου του ηλιακού ενεργειακού στο Μπέρκλεϊ, Καλιφόρνια (ΗΠΑ).

### 3. Σχέδιο Δράσης για την εκπόνηση της εργασίας

Ο όρος "τεχνολογία αιχμής" (state of the art) αναφέρεται στο υψηλότερο επίπεδο της γενικής ανάπτυξης, όπως μιας συσκευής, τεχνικής, ή επιστημονικού πεδίου που επιτυγχάνεται σε ένα συγκεκριμένο χρόνο. Αναφέρεται επίσης στο επίπεδο ανάπτυξης (ως μιας συσκευής, διαδικασίας, μεθόδου, τεχνικής, ή επιστήμης) το οποίο επετεύχθει σε μια οποιαδήποτε στιγμή στο χρόνο, ως αποτέλεσμα των χρησιμοποιούμενων κοινών μεθοδολογιών.

Η προέλευση της έννοιας έλαβε χώρα στις αρχές του εικοστού αιώνα. Αν και οι επιστήμονες που εργάστηκαν σε διαφορετικά θέματα τέχνης είχαν ήδη κάνει κάποια εργασία, η πραγματική εφαρμογή της ιδέας πίσω από αυτόν τον όρο ήταν σε ένα βιβλίο για τους αεροστροβίλους που δημοσιεύθηκε το 1910. Ο όρος «state of the art» χρησιμοποιήθηκε για πρώτη φορά σε λογοτεχνικό έργο και την πάροδο του χρόνου η χρήση του αυξήθηκε σε όλους τους τομείς όπου η τέχνη κατείχε σημαντικό ρόλο. Σε αυτήν την σύνδεση έχει αναφερθεί από το συγγραφέα ότι: «Παρά το γεγονός ότι οι συγγραφείς του 18ου αιώνα δεν χρησιμοποίησαν τον όρο, υπήρχε πράγματι στην πράξη μια συλλογή από την επιστήμη και τη μηχανική γνώση και εμπειρία που μπορεί να χαρακτηριστεί ως τεχνολογία αιχμής για εκείνη την εποχή". Στις προηγούμενες γραφές και τα λογοτεχνικά έργα του 19ου αιώνα, δεν υπάρχει καμία απόδειξη της χρήσης του «state of the art». Μπορεί να θεωρηθεί ως ένα πρόσφατο επίτευγμα, δεδομένου ότι δεν χρησιμοποιείται πλέον για να παρέχει μια περιγραφή των πληροφοριών και πρακτικών. Για την ώρα, η έννοια της τεχνολογία αιχμής μπορεί να χρησιμοποιηθεί για την ενσωμάτωση νέας γνώσης και εμπειρίας στον σημερινό κόσμο. [9]

#### 3.1 *State of the Art*

Η μηχανική μάθηση θεωρείται ως η κορυφαία τεχνολογία αιχμής που συναντά κανείς στην επιστήμη υπολογιστών. Είναι ένα επιστημονικό πεδίο που βοηθά στην αντιμετώπιση του ζητήματος: "Πώς μπορούμε να προγραμματίσουμε συστήματα τα οποία θα μαθαίνουν μόνα τους και θα βελτιώνονται με την εμπειρία;". Κατά την τελευταία δεκαετία, η μηχανική μάθηση μας έχει δώσει self-driving αυτοκίνητα, πρακτικές αναγνώρισης ομιλίας, αποτελεσματική αναζήτηση στο διαδίκτυο, και μια πολύ καλύτερη κατανόηση του ανθρώπινου γονιδιώματος. Καθίσταται εφικτή η κατασκευή προσαρμόσιμων (adaptable) προγραμμάτων τα οποία λειτουργούν με βάση την αυτοματοποιημένη ανάλυση συνόλων δεδομένων και όχι τη διαίσθηση των μηχανικών που τα προγραμματίσαν. Η μηχανική μάθηση είναι τόσο διάχυτη, σήμερα, που ίσως χρησιμοποιείται δεκάδες φορές την ημέρα, χωρίς να το γνωρίζουμε. Πολλοί ερευνητές, επίσης, θεωρούν ότι είναι ο καλύτερος τρόπος για την επίτευξη προόδου προς την κατανόηση του ανθρώπινου εγκεφάλου. Μελετάμε τη μάθηση από πολλά είδη εμπειρίας, όπως η μάθηση να προβλέψουμε ποιοί ασθενείς θα ανταποκριθούν στις όποιες θεραπείες, αναλύοντας την εμπειρία που έχει συλληφθεί σε βάσεις δεδομένων από ιατρικά αρχεία. Μελετάμε επίσης τα ρομπότ που μαθαίνουν πώς να πλοηγούνται επιτυχώς με βάση την εμπειρία που συγκεντρώνουν από αισθητήρες καθώς περιφέρονται στο περιβάλλον, όπως και τις ενισχύσεις υπολογιστή για την επιστημονική ανακάλυψη, που συνδυάζουν αρχικές επιστημονικές υποθέσεις με νέα πειραματικά δεδομένα

για να παράγουν αυτόματα εξευγενισμένες υποθέσεις που ταιριάζουν καλύτερα στα δεδομένα που παρατηρήθηκαν.

### 3.2 Σηματικοί στόχοι για την ολοκλήρωση του συστήματος


Οι στόχοι που θέτουμε στην πτυχιακή εργασία είναι ικανοί να αναδείξουν και να εξελίξουν το σύστημα σε καινοτόμο και πρωτοποριακό. Για το λόγο αυτό θα πρέπει να είναι ξεκάθαροι και να ανταποκρίνονται πλήρως στις απαιτήσεις που επιβάλει μία σύγχρονη κοινωνία. Έτσι καθίσταται επιτακτική ανάγκη η χρήση του όρου «τεχνολογία αιχμής» (state of the art), προκειμένου το παραγόμενο αποτέλεσμα να ικανοποιεί πλήρως τις προσδοκίες και τον σκοπό υλοποίησης του θέματος.

Η πρώτη ενέργεια που πρέπει να γίνει είναι η εισαγωγή στην επιστημονική περιοχή του θέματος. Μέσα από μια διαδικασία έρευνας και μελέτης καθορίζεται η βασική βιβλιογραφία και τα βήματα που πρέπει να ακολουθηθούν για την εκπόνηση της εργασίας. Στη συνέχεια εμβαθύνουμε στις βασικές γνώσεις που είναι απαραίτητες για την ευρύτερη προσέγγιση του θέματος. Πραγματοποιείται αναζήτηση σχετικών δημοσιευμένων επιστημονικών άρθρων και άλλων αναφορών από διεθνείς βάσεις δεδομένων. Έπειτα γίνεται επιλογή των μεθόδων και εργαλείων για την σωστή οργάνωση και ανάπτυξη του τεχνικού μέρους του θέματος, το οποίο αποτελεί και τον πυρήνα της πτυχιακής. Αυτό περιλαμβάνει πειράματα, υπολογισμούς, ανάπτυξη αλγορίθμων κλπ. Η οργάνωση και παρουσίαση των αποτελεσμάτων αποτελούν έναν από τους σημαντικότερους παράγοντες για την επίτευξη του στόχου μας. Τέλος η συγγραφή της πτυχιακής εργασίας είναι ουσιώσης αφού σε αυτή στηρίζεται ο αναγνώστης για να εκτιμήσει τα αποτελέσματά της. Η επιχειρηματολογία που αναπτύσσεται αποσκοπεί σε κάτι συγκεκριμένο και όχι αόριστο.

Οι στόχοι για την επιτυχή εκπόνηση της εργασίας παρατίθενται στην παρακάτω λίστα:

- Εισαγωγή στην επιστημονική περιοχή του θέματος
- Μελέτη της βασικής βιβλιογραφίας
- Βιβλιογραφική επισκόπηση της τεχνολογικής αιχμής
- Μεθοδολογική προσέγγιση
- Ανάπτυξη του τεχνικού μέρους
- Ανάλυση των αποτελεσμάτων και συμπεράσματα
- Συγγραφή

### 3.2.1 Προτεινόμενο Χρονοδιάγραμμα(Gantt Chart)



Εικόνα 19: Χρονοδιάγραμμα εκπόνησης πτυχιακής.

## 4. Κύριο Μέρος

Το κεφάλαιο αυτό ασχολείται με το κύριο μέρος της πτυχιακής, δηλαδή με την ανάλυση του προβλήματος, την σχεδίαση και υλοποίηση της λύσης του θέματος. Για τον λόγο αυτό συντείνει στη μεγαλύτερη εξοικείωση με το πρόβλημα και την υιοθέτηση κάποιας ή κάποιων θεωρητικών ερμηνειών του προβλήματος. Ο συνδυασμός όλων των προαναφερθέντων κεφαλαίων σχετικά με μοντέλα, θεωρίες και αλγορίθμους συμβάλει στην ανάδειξη ενός καινοτόμου και πρωτοποριακού συστήματος το οποίο είναι σε θέση να διαχειρίζεται αποδοτικά συστήματα ηλεκτρικής ενέργειας με στόχο την άμεση αξιολόγηση της ασφάλειας και τροφοδοσίας ενός δικτύου παροχής ηλεκτρισμού.

### 4.1 Ανάλυση Προβλήματος

Η ανάλυση του προβλήματος αποτελεί ίσως ένα από τα σημαντικότερα κεφάλαια της πτυχιακής εργασίας. Με την σύλληψη της ιδέας δημιουργίας του συστήματος επήλθε άμεσα και πληθώρα δυσκολιών, οι οποίες δεν ήταν εμφανής με την πρώτη ματιά. Έτσι κρίθηκε αναγκαία η εύρεση ευφυούς λύσης η οποία επήλθε έπειτα από εκτεταμένες προσπάθειες και πειράματα.

Το έναυσμα της εκκίνησης δόθηκε εξαιτίας της μεγάλης ζήτησης που λαμβάνει ο τομέας της μηχανικής μάθησης. Σκοπός είναι η δημιουργία ενός συστήματος το οποίο θα δέχεται ως είσοδο πραγματικές τιμές (ρεύματα, τάσεις, φορτία κ.α) και μέσα από μία διαδικασία εκπαίδευσης θα εξάγει αποτελέσματα σχετικά με την σταθερότητα (ασφάλεια) που μπορεί να προσφέρει μια εταιρία παροχής ηλεκτρισμού. Με άλλα λόγια το σύστημα θα απαντάει στο ερώτημα: «Θα οδηγηθούμε σε blackout (απώλεια ηλεκτρικού ρεύματος), ναι ή όχι ?». Ένα ιδιαίτερα κρίσιμο και ενδιαφέρον ερώτημα ειδικά στις μέρες μας όπου το καταναλωτικό κοινό απαιτεί άριστη ποιότητα υπηρεσιών χωρίς απώλειες. Ιδιαίτερα σοβαρό θέμα τέθηκε με την υπολογιστική ισχύ που απαιτούσε το σύστημα, εξαιτίας του τεράστιου όγκου πληροφοριών που έπρεπε να διαχειριστεί. Αυτός ήταν ένας παράγοντας σημαντικής καθυστέρησης για την εξαγωγή των αποτελεσμάτων.

#### 4.1.1 Προβλήματα υπολογιστικής ισχύς

Εξαιτίας του τεράστιου όγκου δεδομένων το σύστημα καθυστερούσε σημαντικά στην λήψη απόφασης για την ασφάλεια του δικτύου. Για τον λόγο αυτό χρειάστηκε αναβάθμιση των μονάδων του ηλεκτρονικού υπολογιστή ούτως ώστε να μπορεί να εξάγει αποτελέσματα σε πραγματικό χρόνο. Επιπρόσθετα παρενέβη στις ρυθμίσεις της κύριας μνήμης προκειμένου να δοθεί μεγαλύτερη προτεραιότητα στην εκπαίδευση του συστήματος σε σχέση με άλλες διεργασίες που έτρεχαν εκείνη τη δεδομένη στιγμή. Η ραγδαία εξέλιξη της τεχνολογίας έχει καταφέρει να κάνει αντιληπτό ότι τα σημερινά υπολογιστικά προβλήματα απαιτούν ένα

σύγχρονο και ευέλικτο σύστημα για να διεκπαιρεύσει τις εκάστοτε ανάγκες επίλυσης.

Χαρακτηριστικό παράδειγμα αποτελεί η δημοσίευση του ιντερνετικού κολλοσού με αφορμή το θάνατο του Νιλ Άρμστρονγκ, του πρώτου ανθρώπου που περπάτησε στη Σελήνη, στις 25 Αυγούστου, η Google σκέφτηκε ότι θα ήταν ενδιαφέρον να εξηγήσει στο κοινό τα άλματα που έχει κάνει ο κόσμος των ηλεκτρονικών υπολογισμών από το 1969 μέχρι τις μέρες μας. Σύμφωνα με δημοσίευση της λοιπόν όταν ένας χρήστης κάνει μία απλή αναζήτηση στη Google, η υπολογιστική ισχύς που δαπανάται είναι ίση περίπου με εκείνη που κατανάλωσε ολόκληρο το πρόγραμμα «Απόλλων» της NASA, που είχε ως στόχο τις αποστολές και την προσεδάφιση ανθρώπων στη Σελήνη. Τονίζει μάλιστα ότι δεν αναφέρεται μόνο στις πτήσεις αυτές καθαυτές. Αντιθέτως η ισοδυναμία αφορά τη συνολική υπολογιστική ισχύ που χρειάστηκε το πρόγραμμα. Συμπεριλαμβάνει δηλαδή και τις διαδικασίες σχεδιασμού και εκτέλεσης ολόκληρου του 11ετους προγράμματος, το οποίο είχε συνολικά 17 αποστολές.




Εικόνα 20:Ο ιντερνετικός κολλοσός, Google.

Με αυτή την αναφορά φαίνεται ξεκάθαρα το τεράστιο φόρτο εργασίας που πρέπει να αντιμετωπίσει ένας συμβατός υπολογιστής για την εκπαίδευση του συστήματος. Είναι ιδιαίτερα σημαντικό καθώς πρόκειται για πραγματικά δεδομένα τα οποία μέσα από σωστή μελέτη και ανάλυση θα οδηγήσουν στην μελλοντική εμπορική εκμετάλευσή του.




### 4.1.2 Προβλήματα στην επεξεργασία της βάσης δεδομένων

Σε αυτή την παράγραφο θα αναλυθεί το πρόβλημα που αντιμετωπίστηκε κατά τη διάρκεια επεξεργασίας των δεδομένων. Αρχικά θα πρέπει να γίνει αναφορά στο πλήθος των δειγμάτων, το οποίο ανέρχεται στα 4000 διανύσματα. Ένας αριθμός ιδιαίτερος μεγάλος και δύσκολος στο χειρισμό του. Επίσης το κάθε δείγμα αποτελείται από 42919 τιμές όπως τάσεις, ενεργά φορτία, ενεργή παραγωγή, γωνίες κ.α. Όπως είναι φυσικό ο αριθμός των εγγραφών απαιτεί την δημιουργία ενός εφυσού συστήματος προκειμένου να μπορέσει να φέρει εις πέρας το δύσκολο αυτό έργο. Συνεπώς κρίθηκε αναγκαία η απεικόνιση όλων αυτών των αριθμών καθώς ο άνθρωπος από τη φύση του αντιλαμβάνεται ευκολότερα και καλύτερα τις εικόνες από τους αριθμούς. Ενδεικτικά παραθέτονται τα γραφικά στοιχεία που οδήγησαν στην ορθή κατανόηση του όγκου πληροφοριών:




Εικόνα 21: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) των τάσεων .




Εικόνα 22: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) των τάσεων .

Η Ηλεκτρική τάση, ή απλώς τάση, είναι η τιμή της διαφοράς του ηλεκτρικού δυναμικού μεταξύ δύο σημείων. Μπορεί να είναι θετική, αρνητική ή μηδέν και έχει διαστάσεις ενέργειας προς ηλεκτρικό φορτίο. Η διαφορά του ηλεκτρικού δυναμικού είναι η αιτία της εξαναγκασμένης κατευθυνόμενης κίνησης (ροής) των ηλεκτρικών φορτίων μέσα σε αγωγούς, ημιαγωγούς και ρευστά με ελεύθερα κινούμενα ιόντα (πχ ηλεκτρολυτικό διάλυμα, φωτεινές επιγραφές νέον), είναι δηλαδή η αιτία του ηλεκτρικού ρεύματος. Στις εικόνες 21 και 22 φαίνεται να υπάρχει ομοιότητα ανάμεσα στις μέγιστες και ελάχιστες τιμές των τάσεων.

Αυτό οφείλεται κυρίως στο γεγονός ότι η βάση δεδομένων παρέχει μετρήσεις από δίκτυα υψηλής τάσης με αποτέλεσμα οι τιμές να κυμαίνονται στα ίδια περίπου επίπεδα.




Εικόνα 23: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) των ενεργών φορτίων .




Εικόνα 24: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) των ενεργών φορτίων .

Με τον όρο ηλεκτρικό φορτίο εννοούμε μια ιδιότητα ορισμένων υποατομικών σωματιδίων, η οποία καθορίζει τις μεταξύ τους ηλεκτρομαγνητικές αλληλεπιδράσεις. Ένα υλικό σώμα που έχει ηλεκτρικό φορτίο, επηρεάζεται και δημιουργεί ηλεκτρομαγνητικό πεδίο. Το ηλεκτρικό φορτίο είναι μία ποσότητα που διατηρείται, δηλαδή σε οποιαδήποτε αλληλεπίδραση ο ολικός αριθμός των φορτίων πριν και μετά από αυτήν, διατηρείται σταθερός. Το ηλεκτρικό φορτίο είναι μία ποσότητα που είναι κβαντισμένη. Δηλαδή υπάρχει μόνο σε διακριτές οντότητες, ακέραια πολλαπλάσια του θεμελιώδους φορτίου του ηλεκτρονίου ( $e^-$ ) για το αρνητικό φορτίο και του πρωτονίου για το θετικό. Το ενεργό ηλεκτρικό φορτίο είναι το φορτίο που διατηρεί τις παραπάνω ιδιότητες αλλά παράλληλα παράγει και έργο. Στη φυσική, το έργο είναι το γινόμενο μιας δύναμης επί τη μετατόπιση του σημείου εφαρμογής της. Εναλλακτικά, μπορεί να ειπωθεί ότι είναι η ενέργεια που μια δύναμη μεταφέρει σε ένα κινούμενο σώμα. Στις εικόνες 23 και 24 παρατηρούμε μια πολύ μικρή διαφορά ανάμεσα στις μέγιστες και ελάχιστες τιμές των δειγμάτων. Αυτό είναι λογικό διότι διαφορετικό έργο παράγουν τα αρνητικά φορτισμένα σωματίδια από τα αντίστοιχα θετικά.




Εικόνα 25: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) της ενεργού παραγωγής .




Εικόνα 26: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) της ενεργού παραγωγής .

Η παραγωγή ηλεκτρικής ενέργειας είναι η διαδικασία της παραγωγής ηλεκτρικής ενέργειας από πηγές ενέργειας. Η ηλεκτρική ενέργεια παράγεται συνήθως σε ένα σταθμό παραγωγής ενέργειας από ηλεκτρομηχανικές γεννήτριες, κυρίως από τους κινητήρες που τροφοδοτούνται από τη θερμότητα καύσης χημικής ή πυρηνικής σχάσης, αλλά και με άλλα μέσα, όπως η κινητική ενέργεια των ρεόντων υδάτων και του αέρα. Άλλες πηγές ενέργειας περιλαμβάνουν ηλιακά φωτοβολταϊκά και γεωθερμική ενέργεια. [17] Στις εικόνες 25 και 26 φαίνεται ξεκάθαρα η διαφορά στις τιμές των δειγμάτων, καθώς η παραγωγή ηλεκτρικής ενέργειας είναι σαφέστατα μεγαλύτερη όταν τροφοδοτηθεί με μεγάλες τιμές φορτίων. Η παραγωγή ηλεκτρικής ενέργειας το 2009 ήταν 20.053 TWh, δηλαδή περίπου το 11% της ηλιακής ενέργειας που δέχεται η γη σε μία ώρα (174.000 TWh). Η παραγωγή ηλεκτρικής ενέργειας επιτυγχάνεται με την εκμετάλλευση διαφόρων πρωτογενών πηγών ενέργειας και παρουσιάζει μεγάλες διαφοροποιήσεις από χώρα σε χώρα, ανάλογα με τους διαθέσιμους εγχώριους Ενεργειακούς Πόρους, την Ενεργειακή Πολιτική της χώρας, τις γεωλογικές, γεωφυσικές και κλιματολογικές ιδιαιτερότητες αυτής.



Εικόνα 27: Σύγκριση ανάμεσα στα μέγιστα (ασφαλή και μη ασφαλή) της ενεργού ισχύος κόμβων.



Εικόνα 28: Σύγκριση ανάμεσα στα ελάχιστα (ασφαλή και μη ασφαλή) της ενεργού ισχύος κόμβων.

Κόμβος ονομάζεται το σημείο στο οποίο συντρέχουν περισσότεροι από δύο αγωγοί. Στην εικόνα 27 φαίνεται ότι όλες οι τιμές είναι θετικές κάτι το οποίο μας οδηγεί στο συμπέρασμα ότι η φορά κίνησης του ηλεκτρικού ρεύματος είναι προς μία κατεύθυνση(συμβατικά προς τα δεξιά). Αντίστοιχα στην εικόνα 28 η ροή του ηλεκτρικού ρεύματος είναι αντίθετη από αυτή του σχήματος 27(συμβατικά προς τα αριστερά). Επιπρόσθετα στα σημεία αυτά παράγεται έργο, δηλαδή δημιουργείται ενέργεια η οποία παραμένει επ άπειρο διατηρήσιμη (Αρχή Διατήρησης Ενέργειας(A.Δ.Ε)). Συνήθως σε κάθε κύκλωμα χρειάζεται να υπολογίζουμε σε κάθε συσκευή την ένταση του ηλεκτρικού ρεύματος που τη διαρρέει, την τάση που εφαρμόζεται στα άκρα της, την ισχύ που μεταφέρεται στη συσκευή και άλλα. Για τον υπολογισμό όλων αυτών των πληροφοριών σε ένα κύκλωμα χρησιμοποιούμε συνήθως τους νόμους του Ωμ και τους κανόνες του Κίρχοφ γνωρίζοντας την αντίσταση των συσκευών (και των αγωγών, αν δεν είναι αμελητάια) και την ηλεκτρεργετική δύναμη της πηγής ή των πηγών.

#### **4.1.4 Προβλήματα παραγωγής, γνώσης και αναγνώρισης.**

Σε αυτό το σημείο αναφέρεται η χρήση των αλγορίθμων που θα παράγουν γνώση και αποτέλεσμα στο σύστημά μας, γι αυτό άλλωστε χαρακτηρίζεται και κομβικό σημείο σύμφωνα με την αρχική ιδέα που έχει τεθεί.

Κάθε αντικείμενο έχει πλέον περάσει την διαδικασία επεξεργασίας και βρίσκεται στο στάδιο της εξαγωγής συμπερασμάτων. Εξαιτίας της φύσης των δεδομένων όπως είναι φυσικό απαιτείται τεράστια επεξεργαστική ισχύς. Για τον λόγο αυτό τα δεδομένα έχουν περάσει από εκτεταμένο φιλτράρισμα προκειμένου να γίνει ευκολότερο το έργο των αλγορίθμων. Επιπρόσθετα η σωστή επιλογή των ρυθμίσεων που απαιτεί κάθε αλγόριθμος είναι ένας από τους σημαντικότερους παράγοντες για την ορθή λειτουργία του.

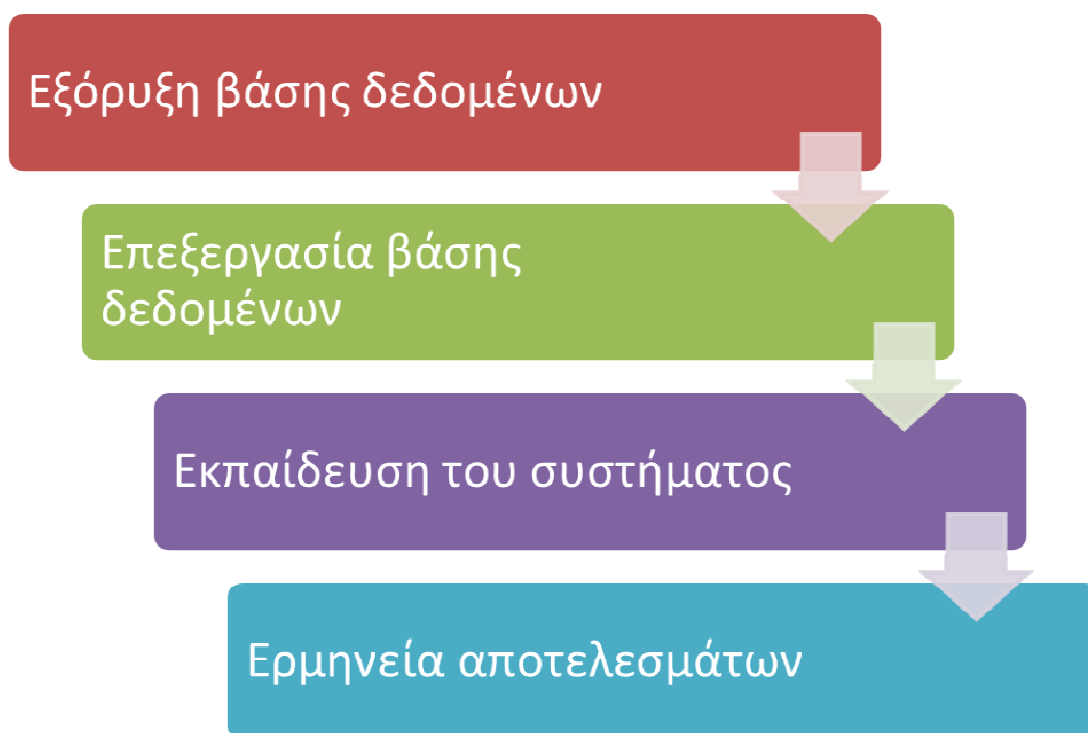
#### **4.1.5 Απαιτήσεις Συστήματος**

Σε αυτό το κεφάλαιο αναφέρονται οι απαιτήσεις που θα πρέπει να πληρή ο υπολογιστής προκειμένου να μπορέσει να εκτελέσει τις λειτουργίες του περιγραφόμενου συστήματος. Ο σπουδαιότερος ίσως παράγοντας είναι αυτός της κάλυψης υπολογιστικής ισχύς που δύναται να προσφέρει η μηχανή. Συνεπώς οι ελάχιστες απαιτήσεις για την ομαλή λειτουργία του συστήματος είναι οι ακόλουθες:

- Οποιοδήποτε λειτουργικό σύστημα (είτε 32-bit είτε 64-bit) το οποίο είναι συμβατό με το πρόγραμμα Matlab της Mathworks.
- Έκδοση Matlab νεότερη της R2008b.
- 2πύρηνο επεξεργαστή με ταχύτητα 1GHz.
- Μνήμη RAM στα 2GB.

## **4.2 Σχεδιασμός Υλοποίησης**

Για τον σχεδιασμό της υλοποίησης κρίθηκε αναγκαίο όπως ήταν φυσικό η κατάτμιση της εργασίας σε διαχειρίσιμους τομείς. Έτσι προκύπτει το ακόλουθο σχέδιο:



Εικόνα 29: Διάγραμμα υλοποίησης.

Στο διάγραμμα της εικόνας 45, φαίνεται η διαδικασία υλοποίησης για την ολοκλήρωση της εργασίας. Στο πρώτο στάδιο αντιλαμβάνεται κανείς την σπουδαιότητα ολόκληρου του εγχειρήματος που πρόκειται να ακολουθήσει. Η ανακάλυψη γνώσης από την βάση δεδομένων ή αλλιώς η εξόρυξη δεδομένων είναι η εξεύρεση μιας (ενδιαφέρουσας, αυτονόητης, μη προφανής και πιθανόν χρήσιμης) πληροφορίας ή προτύπων από μεγάλες βάσεις δεδομένων με χρήση αλγορίθμων ομαδοποίησης ή κατηγοριοποίησης και των αρχών της στατιστικής, της τεχνητής νοημοσύνης, της μηχανικής μάθησης και των συστημάτων βάσεων δεδομένων. Στόχος της εξόρυξης δεδομένων είναι η πληροφορία που θα εξαχθεί και τα πρότυπα που θα προκύψουν να έχουν δομή κατανοητή προς τον άνθρωπο έτσι ώστε να τον βοηθήσουν να πάρει τις κατάλληλες αποφάσεις. Ο όρος εξόρυξη δεδομένων είναι μία έννοια που συνήθως παραπέμπει σε κάθε είδος φόρμας με μεγάλη ποσότητα δεδομένων ή επεξεργασία δεδομένων (συλλογή, εξαγωγή δεδομένων, warehouse, ανάλυση δεδομένων και στατιστικής) αλλά επίσης γενικεύεται σε κάθε είδος συστήματος υποστήριξης αποφάσεων συμπεριλαμβανομένου της τεχνητής νοημοσύνης, της εκμάθησης μηχανής και της επιχειρηματικής ευφυΐας. Στην ορθή χρήση του όρου η λέξη κλειδί είναι η ανακάλυψη, που ορίζεται ως η ανίχνευση κάτι καινούριου. Ο πραγματικός στόχος της εξόρυξης δεδομένων είναι η αυτόματη ή ημιαυτόματη ανάλυση μεγάλων ποσοτήτων δεδομένα για την εξαγωγή κάποιου ενδιαφέροντος προτύπου που ήταν άγνωστο μέχρι εκείνη τη στιγμή, όπως ομάδες από εγγραφές δεδομένων (συσταδοποίηση), ασυνήθιστες εγγραφές (anomaly detection) και εξαρτήσεις (κανόνες συσχετίσεων). Αυτό συνήθως συμπεριλαμβάνει τη χρήση βάσης δεδομένων όπως χωρικά ευρετήρια. Αυτά τα πρότυπα ύστερα μπορούν να θεωρηθούν ως μία περιγραφή των δεδομένων εισαγωγής και να χρησιμοποιηθούν για περαιτέρω ανάλυση ή για παράδειγμα στην εκμάθηση μηχανής και στην προγνωστική ανάλυση. Για παράδειγμα, η

εξόρυξη δεδομένων θα μπορούσε να προσδιορίσει πολλαπλά σύνολα στα δεδομένα, τα οποία μπορούν να χρησιμοποιηθούν μετά για να εξασφαλίσουν περισσότερο ακριβή αποτελέσματα από ένα σύστημα υποστήριξης αποφάσεων. Παρότι η συλλογή δεδομένων και η προετοιμασία δεδομένων, αλλά και η ερμηνεία των αποτελεσμάτων και εκθέσεων δεν αποτελούν μέρος της εξόρυξης δεδομένων, παρ' όλα αυτά ανήκουν στην ανακάλυψη γνώσης από βάσεις δεδομένων σαν κάποια επιπρόσθετα βήματα. [11] Η διαδικασία ανακάλυψης γνώσης από βάσεις δεδομένων(KDD) συνήθως ορίζεται από τα εξής στάδια:

1. Συλλογή
2. Προεπεξεργασία
3. Μετασχηματισμός
4. Εξόρυξη δεδομένων
5. Ερμηνεία/Αξιολόγηση.

Η επεξεργασία δεδομένων αφορά τη συλλογή, την ταξινόμηση, την καταχώρηση, τη μετα-βολή, την αποθήκευση, την αναζήτηση, και την ανάκτηση δεδομένων με ή χωρίς τη βοήθεια του ηλεκτρονικού υπολογιστή για την παραγωγή πληροφοριών. Επειδή τα δεδομένα είναι πιο χρήσιμα όταν παρουσιάζονται ορθά και κατατοπιστικά, τα συστήματα επεξεργασίας δεδομένων συχνά αναφέρονται ως συστήματα πληροφοριών. Παρ' όλα αυτά, οι όροι είναι σχεδόν συνώνυμοι, επιτελώντας παρόμοιες μετατροπές. Τα συστήματα επεξεργασίας δεδομένων όπως αυτό που περιγράφεται στην παρούσα πτυχιακή εργασία χειρίζονται συνήθως τα αρχικά δεδομένα ως πληροφορίες. Η επεξεργασία δεδομένων είτε μπορεί είτε δεν μπορεί να διακριθεί από τη μετατροπή δεδομένων, όταν η διαδικασία είναι απλώς η μετατροπή των δεδομένων σε άλλη μορφή, και δεν συνεπάγεται καμία χειραγώγηση δεδομένων. Το στάδιο αυτό είναι ίσως το πιο απαιτητικό από θέμα χρόνου καθώς απαιτεί εκταταμένο και ενδελεχή έλεγχο καθ' όλη τη διάρκεια της επεξεργασίας.

Ακολουθεί η εκπαίδευση του συστήματος, ο πυρήνας ολόκληρης της εργασίας. Η διαδικασία μάθησης μηχανής αποτελεί ίσως ένα από κορυφαία επιτεύγματα της σύγχρονης επιστήμης υπολογιστών. Όπως έχει ήδη αναφερθεί αφορά αλγορίθμους και μεθόδους που επιτρέπουν στους υπολογιστές να «μαθαίνουν». Απαιτεί την λιγότερη προσπάθεια από την μεριά του χρήστη καθώς το περισσότερο μέρος το έχει αναλάβει ο υπολογιστής.

Η αξιολόγηση ή ερμηνεία των αποτελεσμάτων αποτελεί το καταληκτικό κομμάτι της παρούσας εργασίας. Ιδιαίτερο ενδιαφέρον έχει η ερμηνεία της διαδικασίας στον φυσικό κόσμο, κάτι που ίσως κεντρίζει το ενδιαφέρον και σε ανθρώπους που δεν έχουν την παραμικρή ιδέα επί του θέματος που πραγματεύεται η εργασία. Τέτοιοι παράγοντες θα μπορούσαν να είναι οι επιπτώσεις στην υγεία του ανθρώπου, στη φύση και πολλά άλλα.

### **4.3 Υλοποίηση**

Υλοποίηση του συστήματος είναι η διαδικασία της συνάθροισης-συλλογής οντοτήτων(αντικειμένων), υλικών ή αφηρημένων, τα οποία αποτελούν σύνολο και το κάθε στοιχείο αλληλεπιδρά ή συσχετίζεται με τουλάχιστον ένα ακόμη στοιχείο του συνόλου. Κάθε αντικείμενο που δε συσχετίζεται / αλληλεπιδρά με κανένα στοιχείο του συστήματος δεν αποτελεί μέρος του συστήματος. Ένα υποσύστημα είναι ένα σύνολο στοιχείων το οποίο

αποτελεί σύστημα από μόνο του αλλά και μέρος του όλου συστήματος. Έπειτα από τον σχεδιασμό και την κατανόηση του προβλήματος ακολουθεί η μετατροπή σε πράξη και σε υλική πραγματικότητα, δηλαδή, "παίρνει σάρκα και οστά", του αρχικού εγχειρήματος.

### 4.3.1 Περιγραφή βάσης δεδομένων

Πρόκειται για την βάση δεδομένων IEEE 50 generators με 145 buses. Υπάρχουν 4000 δείγματα στο καθένα από τα οποία αντιστοιχούν 9 χαρακτηριστικές τιμές, με την τελευταία να υποδηλώνει εάν το δείγμα είναι σταθερό ή όχι. Οι χαρακτηριστικές τιμές είναι οι ακόλουθες:

1. Voltages
2. Active Load
3. Active Production
4. Active Power-Branches
5. Angles
6. Reactive Load
7. Reactive Power-Branches
8. Reactive Production
9. Security Status

Αναλυτικότερα: Τα voltages αφορούν τις τάσεις που αναπτύσσονται μεταξύ των ηλεκτρικών φορτίων του συστήματος. Το active load αφορά το ενεργό φορτίο, δηλαδή το φορτίο εκείνο που παράγει έργο. Η active production είναι η ενεργός παραγωγή ηλεκτρικού ρεύματος. Τα active power branches αφορούν τα σημεία εκείνα στο δίκτυο που βρίσκονται πάνω σε βρόγχους και παράγουν έργο. Οι τιμές των angles αφορούν τις μετρήσεις στις γωνίες. Το reactive load αφορά το άεργο φορτίο, δηλαδή το φορτίο εκείνο το οποίο δεν παράγει έργο. Τα reactive power branches αφορούν τα σημεία εκείνα στο δίκτυο που βρίσκονται πάνω σε βρόγχους και δεν παράγουν έργο. Το reactive production είναι η άεργος παραγωγή ηλεκτρικού ρεύματος. Τέλος το security status αναφέρεται στο γεγονός της σταθερότητας των δειγμάτων. Με 1 σημειώνονται τα σταθερά και με 0 τα μη σταθερά.

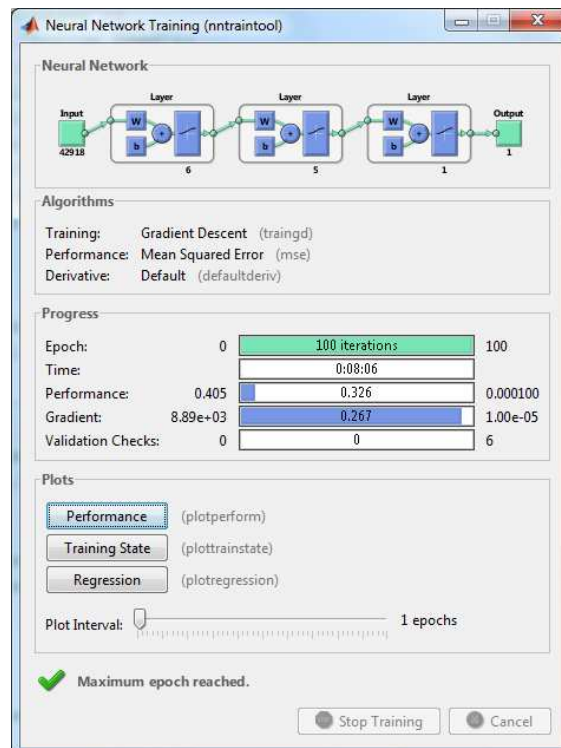
Οι 4 αλγόριθμοι χρησιμοποιούν περίπου την ίδια φιλοσοφία υλοποίησης. Αρχικά φορτώνουμε στο Matlab την database και χωρίζουμε τα δεδομένα μας σε δύο πίνακες, stable και unstable. Για την εκπαίδευση του δικτύου θα πρέπει να είμαστε σε θέση να ελέγξουμε τα παραγόμενα αποτελέσματα με αυτά που είχαμε πριν ξεκινήσει η διαδικασία. Γι' αυτό λοιπόν οφείλουμε να διαχωρίσουμε τα δεδομένα σε σετ ελέγχου και σετ εκπαίδευσης. Επομένως κρατάμε το 20% για τον έλεγχο-ταυτοποίηση και αφήνουμε το 80% για την πλήρη εκπαίδευση.



### 4.3.2 Περιγραφή υλοποίησης του συστήματος

Αρχικά για την υλοποίηση του μοντέλου θα πρέπει το υπολογιστικό σύστημα να πληρή τις προϋποθέσεις που αναφέρονται σε προηγούμενη παράγραφο προκειμένου να εξάγουμε τα επιθυμητά αποτελέσματα. Εφόσον γίνουν οι απαραίτητοι έλεγχοι συμβατότητας το σύστημα είναι πλέον σε θέση να ξεκινήσει την εκπαίδευσή του.

Ο πρώτος αλγόριθμος που θα εκπαιδεύσει το σύστημα είναι ο back propagation. Ο back propagation μια συντομογραφία του όρου «backward propagation of errors» είναι μια κοινή μέθοδος της εκπαίδευσης τεχνητών νευρωνικών δικτύων. Πρόκειται για μια επιβλεπόμενη μέθοδο εκμάθησης, και είναι μια γενίκευση του κανόνα δέλτα. Απαιτεί ένα σύνολο δεδομένων εισόδου για την επιθυμητή έξοδο, που αποτελούν το σύνολο εκπαίδευσης. Είναι πιο χρήσιμο για feed-forward δίκτυα (δίκτυα που δεν έχουν καμία ανατροφοδότηση). Η εκπαίδευση του δικτύου πραγματοποιείται με την εντολή newff. Γενικά τα feed forward δίκτυα αποτελούνται από N στρώματα χρησιμοποιώντας τη συνάρτηση βάρους dotprod,την συνάρτηση εισόδου netsum καθώς και τις λειτουργίες μεταφοράς. Το πρώτο στρώμα έχει βάρη που προέρχονται από την είσοδο. Κάθε επόμενο στρώμα έχει βάρη που προέρχονται από το προηγούμενο στρώμα. Όλα τα στρώματα έχουν biases. Το τελευταίο στρώμα αποτελεί την έξοδο του δικτύου.




Εικόνα 30: Εκπαίδευση συστήματος με Back propagation.

Τα βάρη καθώς επίσης και τα biases αρχικοποιούνται με τις εντολές `net.inputweights{1,1}.initFcn='rands'` και `net.biases{1}.initFcn='rands'` αντίστοιχα. Η προσαρμογή γίνεται με την εκπαίδευση η οποία αναβαθμίζει κάθε φορά τις εκάστοτε

παραμέτρους. Η εκπαίδευση πραγματοποιείται με την εντολή `train` η οποία δέχεται σαν παραμέτρους το `net`, το `trainingset` και το `target`. Η πρώτη παράμετρος αφορά τις ρυθμίσεις που έχουμε ήδη κάνει στο δίκτυο μας όπως βάρη, επαναλήψεις, biases. Η δεύτερη παράμετρος αφορά το σετ εκπαίδευσης, το σετ δηλαδή το οποίο θα ειχασθεί στο σύστημα προκειμένου να πραγματοποιηθεί ολόκληρη η διαδικασία εκπαίδευσης και εξόδου των αποτελεσμάτων. Η τρίτη παράμετρος χρησιμοποιείται για την ανάδειξη των στόχων του δικτύου. Με άλλα λόγια θέτουμε στο σύστημα το ιδανικό αποτέλεσμα στο οποίο θα θέλαμε να φτάσει. Επιπρόσθετα συναντάμε την εντολή `sim` η οποία κάνει προσομοίωση του δικτύου μαζί με το σετ ελέγχου. Τέλος υπολογίζεται βάση των αποτελεσμάτων της εκπαίδευσης το ποσοστό επιτυχίας του συστήματος.

Ο δεύτερος αλγόριθμος που θα αναλάβει την εκπαίδευση του δικτύου είναι ο `support vector machine`. Τα μοντέλα SVM έχουν αποδειχθεί πολύ αποδοτικά στην επίλυση προβλημάτων ταξινόμησης που εμφανίζονται σε πραγματικές πρακτικές εφαρμογές. Όπως είδαμε, η υλοποίηση των μοντέλων αυτών βασίζεται στον τετραγωνικό προγραμματισμό. Γενικά τα προβλήματα που αντιμετωπίζονται από ένα μοντέλο SVM καλύπτουν όλες τις δυνατές περιπτώσεις προβλημάτων ταξινόμησης δύο κλάσεων, όπως αυτές περιγράφονται παρακάτω:

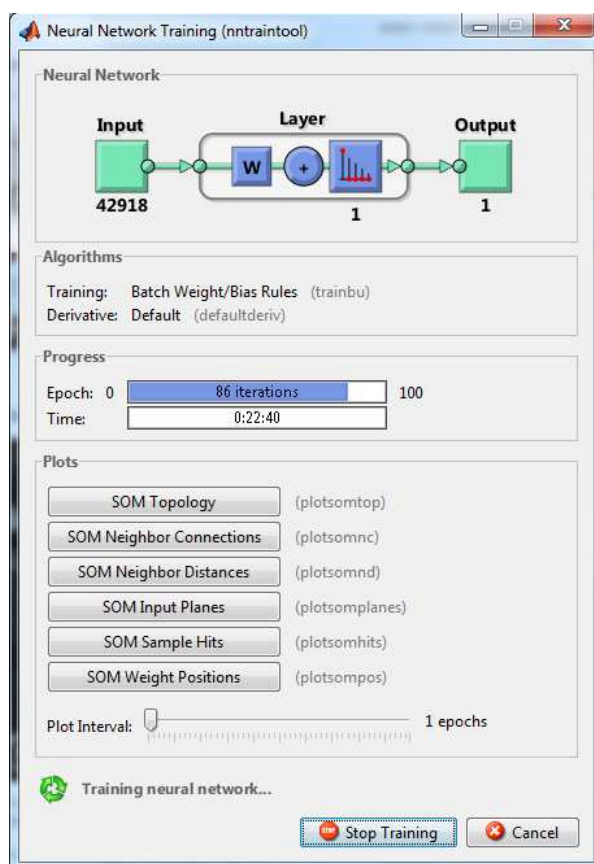
1. Γραμμικά διαχωρίσιμες κλάσεις. Στην περίπτωση αυτή το μοντέλο χρησιμοποιεί τη γραμμική συνάρτηση πυρήνα  $k(x,y) = x^T y$  (ουσιαστικά δηλαδή δεν χρησιμοποιεί συνάρτηση πυρήνα) και ο περιορισμός  $\lambda_i \leq C$  δεν υπάρχει. Μπορούμε να πούμε ότι  $C = \infty$ .
2. Μη γραμμικά διαχωρίσιμες κλάσεις. Εδώ μπορούμε να χρησιμοποιήσουμε είτε τη γραμμική συνάρτηση είτε κάποια μη γραμμική συνάρτηση πυρήνα ανάλογα με το ποιός τύπος συνάρτησης θεωρούμε ότι είναι ο καταλληλότερος για τον καλύτερο δυνατό διαχωρισμό των κλάσεων. Χρησιμοποιούμε τον περιορισμό  $\lambda_i \leq C$ , όπου το όριο  $C$  ορίζεται από το χρήστη. Μεγάλη τιμή του ορίου αυτού σημαίνει ότι απαιτούμε λίγες λάθος ταξινομήσεις ενώ μικρή τιμή σημαίνει ότι δεν δίνουμε μεγάλη βαρύτητα στις λάθος ταξινομήσεις.



Εικόνα 31: Μοντέλο SVM σε δύο διαστάσεις.


Στην παρούσα πτυχιακή εργασία η συνάρτηση που καλείται για να κάνει τις παραπάνω ενέργειες είναι αρχικά η `svmtrain` και αργότερα η `svmclassify`. Η πρώτη δέχεται ένα πλήθος από παραμέτρους, με τις κυριότερες από αυτές να είναι το σετ εκπαίδευσης, η μεταβλητή `group` που περιέχει τις καταστάσεις των δειγμάτων εκπαίδευσης και η συνάρτηση `Kernel_Function` η οποία προσδιορίζει τη λειτουργία του πυρήνα που θα καθοδηγήσει τα δεδομένα μέσα στον υποχώρο. Εν συνέχεια η `svmclassify` δέχεται το αποτέλεσμα της προηγούμενης εντολής, που είναι μια δομή του είδους SVM και μαζί με το σετ ελέγχου πραγματοποιεί την ταξινόμηση των δειγμάτων. Τέλος υπολογίζεται το ποσοστό επιτυχίας που μπορεί να προσφέρει το δίκτυο έτσι ώστε να παραμείνει σταθερό.

Μέχρι τώρα τα μοντέλα μάθησης που παρουσιάστηκαν βασίζονταν αποκλειστικά στην έννοια του συναπτικού βάρους για να αναπαραστήσουν την πληροφορία με τη μορφή κάποιας συνάρτησης εισόδου-εξόδου. Η αλλαγή των συναπτικών βαρών μεταξύ των νευρώνων συνεπαγόταν και την τροποποίηση της συνάρτησης αυτής και συνεπώς την αλλαγή της πληροφορίας που φυλάσσεται στο δίκτυο. Η θέση του κάθε νευρώνα μέσα στην αρχιτεκτονική διάταξη του δικτύου δεν έπαιξε κάποιο ρόλο. Σε δίκτυα πολλών στρωμάτων μας ενδιέφερε απλώς ότι ο νευρώνας A βρίσκεται στο στρώμα X, αλλά ακόμη και τότε, η ακριβής θέση του νευρώνα μέσα στο συγκεκριμένο στρώμα δεν είχε ιδιαίτερη σημασία.



Εικόνα 32: Εκπαίδευση συστήματος με self organizing maps.

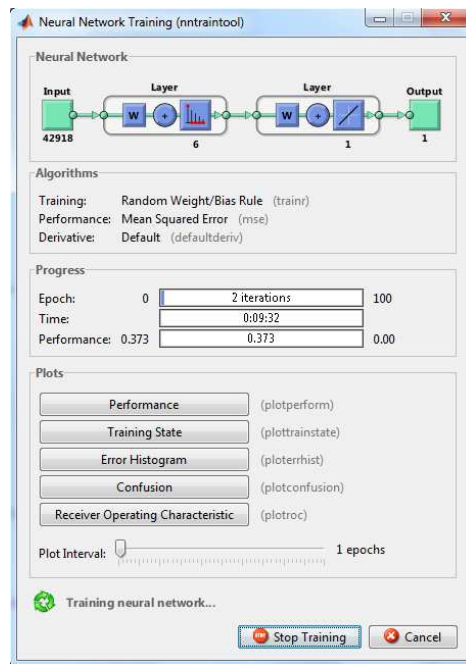
Αντίθετα όμως η τοπολογική πληροφορία, δηλαδή η σχετική διάταξη των νευρώνων στο δίκτυο, εμφανίζεται να παίζει σημαντικό ρόλο σε διάφορα τμήματα του εγκεφάλου που εκτελούν συγκεκριμένες λειτουργίες, όπως την αντίληψη του ήχου, της αφής, της εικόνας, κλπ. Τα τμήματα αυτά διαθέτουν αυστηρή τοπολογική οργάνωση έτσι ώστε οι νευρώνες που διεγείρονται από συναφή ή γειτονικά εξωτερικά ερεθίσματα να βρίσκονται κοντά ο ένας με τον άλλο. Τέτοιες δομές αποτελούνται χάρτες (self-organizing maps). Το δίκτυο SOM ανήκει στη κατηγορία των δικτύων που εκπαιδεύονται χωρίς επίβλεψη (unsupervised learning) σε αντίθεση, πχ. με τον αλγόριθμο back propagation. Έτσι αφού φορτωθεί η βάση δεδομένων χρησιμοποιούμε την εντολή selforgmap για να δημιουργηθεί το δίκτυο SOM.



Εικόνα 33: Ένας χάρτης του κόσμου, όπου οι χώρες έχουν χρωματιστεί με το χρώμα που περιγράφει τον τύπο της φτώχειας τους (ο χρωματισμός επετεύχθει με την βοήθεια του SVM).


Εκ του γεγονότος ότι η αρχιτεκτονική του δικτύου SOM αφορά ένα ανταγωνιστικό δίκτυο, οι νευρώνες «ανταγωνίζονται» μεταξύ τους για το ποιος ταιριάζει καλύτερα στο διάνυσμα εισόδου. Ο νευρώνας που ταιριάζει καλύτερα καλείται νευρώνας νικητής και είναι αυτός που μαζί με την «γειτονιά» του θα κληθούν να εκπαιδεύσουν το σύστημα. Συνεπώς με την βοήθεια της ευκλείδειας απόστασης γίνεται αυτή η επιλογή και επιλέγεται ο νικητής νευρώνας. Επιπρόσθετα παράμετροι που τίθενται κατά τη διάρκεια κλήσης της συνάρτησης selforgmap είναι αυτές του πλήθους των εποχών, του βήματος εκπαίδευσης, της διάστασης του χάρτη και της συνάρτησης τοπογράφησης. Τέλος μετά την ολοκλήρωση της διαδικασίας εκπαίδευσης υπολογίζεται το ποσοστό επιτυχίας που προσέφερε η τρέχουσα αρχιτεκτονική.

Η διανυσματική κβάντιση (learning vector quantization) σχετίζεται με την προσεγγιστική αναπαράσταση πληροφορίας που προέρχεται από ένα συνεχές σύνολο τιμών χρησιμοποιώντας μόνο λίγες χαρακτηριστικές τιμές. Για παράδειγμα η κβάντιση ενός διανύσματος  $\chi = [\chi_1, \chi_1]^T$  στο δισδιάστατο χώρο χρησιμοποιώντας δύο κέντρα  $c_1, c_2$ , θα δημιουργούσε δύο γειτονιές οι οποίες θα διαχωρίζονταν από μία μεσοκάθετο. Η λογική της κβάντισης είναι ίδια όπως και στην μονοδιάστατη περίπτωση: κάθε τιμή  $\chi$  αναπαρίσταται από το κοντινότερο κέντρο. Έτσι στα αριστερά της μεσοκαθέτου βρίσκονται εκείνα τα διανύσματα που είναι σταθερά και δεξιά αυτά που είναι ασταθή. Σε περίπτωση που δεν είχαμε δύο διαστάσεων πρόβλημα αλλά  $n$  διαστάσεων τότε οι γραμμές που θα διαχωρίζαν τις εκάστοτε περιοχές μεταξύ τους καλούνται περιοχές Voronoi. Στη παρούσα πτυχιακή εργασία κάτι ανάλογο λαμβάνει χώρα. Στην προκειμένη περίπτωση έχουμε δύο καταστάσεις, τα σταθερά και τα μη σταθερά διανύσματα.



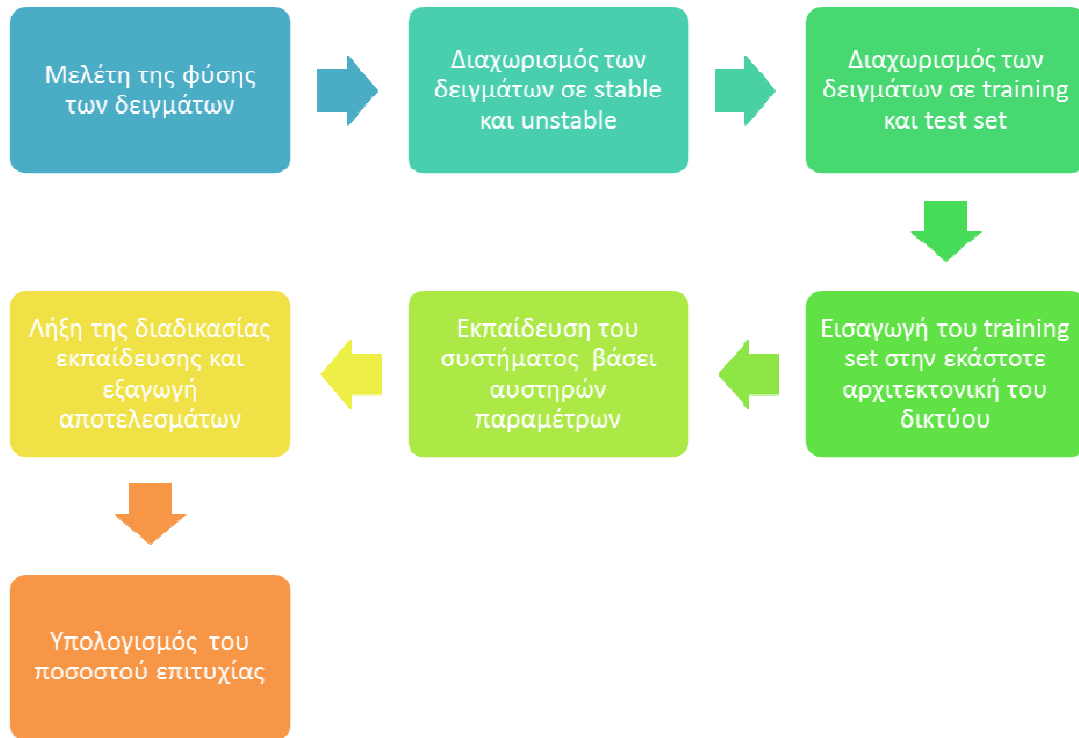
Εικόνα 34: Εκπαίδευση συστήματος με learning vector quantization.

Συνεπώς η εντολή που χρησιμοποιείται στο matlab έτσι ώστε να καλέσουμε ένα δίκτυο της αρχιτεκτονικής learning vector quantization είναι η `lvqnet`. Η συνάρτηση αυτή δέχεται 3 ορίσματα, `hiddenSize` δηλαδή έναν ακέραιο αριθμό που καθορίζει το πλήθος των κρυφών στρωμάτων, `lvqLR` δηλαδή το learning rate (το πόσο γρήγορα θα μαθαίνει) και τελευταίο το `lvqLF` το οποίο αφορά την συνάρτηση πάνω στην οποία θα εκπαιδευτεί το σύστημα μας. Τέλος υπολογίζεται το ποσοστό επιτυχίας που προσέφερε ο συγκεκριμένος αλγόριθμος για την εκπαίδευση του δικτύου.



Εικόνα 35: Codewords σε διασδιάστατο χώρο. Τα διανύσματα εισόδου σημειώνονται με  $x$ , τα codewords σημειώνονται με κόκκινο κύκλο, και οι Voronoi περιοχές χωρίζονται με γραμμές.

### 4.3.2 Αναλυτικό διάγραμμα ροής της κατασκευής του συστήματος



**Εικόνα 36:** Αναλυτική περιγραφή των βημάτων που ακολουθήθηκαν για την κατασκευή του συστήματος.

Όπως είναι φανερό από την εικόνα 52 ακολουθείται μια αυστηρή διαδικασία για την τελική λήψη της απόφασης. Οποιαδήποτε παρέκκλιση από το παραπάνω διάγραμμα θα οδηγήσει σε εσφαλμένα αποτελέσματα. Η μελέτη της φύσης των δειγμάτων είναι ίσως από τα σημαντικότερα στάδια καθώς αποτελεί το σημείο εκείνο στο οποίο γίνεται η αφομοίωση και εμπέδωση των δεδομένων που πρόκειται να επεξεργαστούν. Εν συνεχεία πραγματοποιείται ο διαχωρισμός των 4000 δειγμάτων σε ασφαλή και μη. Ένα δείγμα θεωρείται ασφαλές-σταθερό εάν ικανοποιεί το παρακάτω κριτήριο:

If  $f_{\min} > 49\text{Hz}$  and  $df/dt < 0.4 \text{ Hz/s}$   
 then the vector is secure  
 else it is insecure [15]

Απόρροια του προηγούμενου βήματος αποτελεί το παρών, το οποίο ξεχωρίζει τα δείγματα εκείνα τα οποία θα υποστούν εκπαίδευση (3200). Τα υπόλοιπα 800 αποτελούν το test set, δηλαδή τον τελικό έλεγχο. Πλέον το δίκτυο είναι σε θέση να δεχτεί το set εκπαίδευσης και να ξεκινήσει την διαδικασία βάσει πάντα των παραμέτρων που έχουν αναφερθεί σε προηγούμενες παραγράφους. Τέλος υπολογίζεται το ποσοστό επιτυχίας επί τοις εκατό (%) που δημιούργησε ο εκάστοτε αλγόριθμος.

## 5. Αποτελέσματα

Στο κεφάλαιο των Αποτελεσμάτων ομαδοποιούνται τα ευρήματα της έρευνας, υποστηριζόμενα από πίνακες, γραφήματα, και στατιστικούς ελέγχους. Για την υλοποίηση του συστήματος έγινε ενδελεχής έρευνα στις διάφορες τεχνολογίες που είναι διαθέσιμες και οι οποίες θα μπορούσαν να προσφέρουν το περιβάλλον ανάπτυξης της εφαρμογής. Εξετάστηκαν αρκετές πλατφόρμες και έγινε εκτίμηση των πλεονεκτημάτων και μειονεκτημάτων που παρουσίαζε η κάθε μία. Η καταγραφή των αποτελεσμάτων πραγματοποιήθηκε για κάθε αλγόριθμο ξεχωριστά προκειμένου να μην δημιουργηθεί σύγχυση στη τελική λήψη απόφασης. Με κόκκινο χρώμα σημειώνονται οι εκάστοτε αλλαγές στις επιμέρους παραμέτρους, ενώ με πράσινο οι βέλτιστες επιδόσεις.

Αρχικά παρατίθενται τα αποτελέσματα που εξήγαγε ο αλγόριθμος των SVM. Οι πίνακες 2 και 3 αφορούν δύο διαφορετικές τεχνικές προσέγγισης του προβλήματος. Στον πίνακα 2 φαίνονται τα αποτελέσματα της συνάρτησης sequential minimal optimization (SMO) η οποία ελαχιστοποιεί τα προβλήματα one-norm σε ιδιαίτερα γρήγορο χρονικό διάστημα. Χρησιμοποιεί 4 διαφορετικές kernel functions τις Multilayer Perceptron kernel, Polynomial kernel, Gaussian Radial Basis Function και Quadratic kernel. Όπως είναι φανερό και από το πινακάκι ο Quadratic kernel πετυχαίνει το υψηλότερο ποσοστό επιτυχίας σε σχέση με τους υπόλοιπους τρεις. Αυτό οφείλεται στη φύση του τετραγωνικού ταξινομητή-πυρήνα και στη λειτουργία που παρέχει μέσα στο σύστημα.

| Kernel Function                    | Tolerance KKT | KKT Violation Level | Iterations | Ποσοστό Επιτυχίας |
|------------------------------------|---------------|---------------------|------------|-------------------|
| mlp — Multilayer Perceptron kernel | 1e-5          | .08                 | 44500      | 86,5%             |
| mlp — Multilayer Perceptron kernel | 1e-1          | .05                 | 44500      | 86,5%             |
| mlp — Multilayer Perceptron kernel | 1e-8          | .05                 | 44500      | 86,5%             |
| mlp — Multilayer Perceptron kernel | 1e-5          | .05                 | 80000      | 86,5%             |
| mlp — Multilayer Perceptron kernel | 1e-5          | .05                 | 25000      | 86,5%             |



Πτυχιακή Εργασία Τμήματος Εφαρμοσμένης Πληροφορικής & Πολυμέσων

|  |      |     |       |     |
|--|------|-----|-------|-----|
| polynomial —<br>Polynomial kernel          | 1e-5 | .02 | 44500 | 50% |
| polynomial —<br>Polynomial kernel          | 1e-1 | .05 | 44500 | 50% |
| polynomial —<br>Polynomial kernel          | 1e-8 | .05 | 44500 | 50% |
| polynomial —<br>Polynomial kernel          | 1e-5 | .05 | 80000 | 50% |
| polynomial —<br>Polynomial kernel          | 1e-5 | .05 | 25000 | 50% |
| rbf — Gaussian<br>Radial Basis<br>Function | 1e-5 | .05 | 44500 | 50% |
| rbf — Gaussian<br>Radial Basis<br>Function | 1e-1 | .05 | 44500 | 50% |
| rbf — Gaussian<br>Radial Basis<br>Function | 1e-8 | .05 | 44500 | 50% |
| rbf — Gaussian<br>Radial Basis<br>Function | 1e-5 | .05 | 80000 | 50% |
| rbf — Gaussian<br>Radial Basis<br>Function | 1e-5 | .05 | 25000 | 50% |
| quadratic —<br>Quadratic kernel            | 1e-5 | .08 | 44500 | 96% |
| quadratic —<br>Quadratic kernel            | 1e-8 | .05 | 44500 | 96% |
| quadratic —<br>Quadratic kernel            | 1e-5 | .05 | 80000 | 96% |
| quadratic —<br>Quadratic kernel            | 1e-5 | .05 | 25000 | 96% |

Πίνακας 2: Πίνακας αποτελεσμάτων με τη μέθοδο SMO του αλγορίθμου SVM.

Έπειτα ακολουθεί η δεύτερη τεχνική προσέγγιση που ονομάζεται least-squares (LS). Χρησιμοποιεί τις ίδιες kernel functions με του SMO αλλά διαφέρει σημαντικά στα ποσοστά επιτυχίας. Η βέλτιστη τιμή της παρούσας τεχνικής αγγίζει το 99.375%, κάτι το οποίο αποτελεί και το μέγιστο ποσοστό επιτυχίας του συστήματος που πραγματεύεται η πτυχιακή εργασία. Η συνάρτηση που πραγματοποιεί το συγκεκριμένο ποσοστό είναι η quadratic kernel. Ιδιαίτερα υψηλό ποσοστό λαμβάνει και η polynomial kernel η οποία υλοποιείται βάσει της ακόλουθης μαθηματικής συνάρτησης:  $k(x,y)=(ax^T y + c)^d$ .

| kernel function                      | Ποσοστό Επιτυχίας |
|--------------------------------------|-------------------|
| quadratic — Quadratic kernel         | 99.375%           |
| rbf — Gaussian Radial Basis Function | 50%               |
| polynomial — Polynomial kernel       | 99,125%           |
| mlp — Multilayer Perceptron kernel   | 59,25%            |

Πίνακας 3: Πίνακας αποτελεσμάτων με τη μέθοδο LS του αλγορίθμου SVM.

Εν συνεχεία ακολουθεί ο αλγόριθμος back propagation, ο οποίος αποτελεί μια γενίκευση του κανόνα δέλτα. Παρατηρούμε ότι μόλις μειώσουμε σημαντικά το learning rate αυξάνεται το ποσοστό επιτυχίας στο 63.125%. Αυτό μας οδηγεί στο συμπέρασμα ότι το σύστημα χρειάζεται περισσότερο χρόνο για να «μάθει», από ότι αρχικά είχε διαπιστωθεί. Η επόμενη αξιοσημείωτη περίπτωση δημιουργείται όταν αυξήσουμε τον αριθμό των Layers από [3,4,1] σε [7,5,1]. Εξαιτίας του τεράστιου όγκου δεδομένων το δίκτυο χρειάζεται περισσότερα επίπεδα προκειμένου να μπορέσει να ανταποκριθεί επιτυχώς και να μην οδηγηθεί σε σφάλμα (Minimum gradient reached).

| Epochs | Learning rate | Goal | Layers  | Transfer functions       | Training functions | Ποσοστό Επιτυχίας(%)     |
|--------|---------------|------|---------|--------------------------|--------------------|--------------------------|
| 500    | 0.03          | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 100    | 0.03          | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 800    | 0.03          | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 500    | 0.003         | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 500    | 0.0003        | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 63.125                   |
| 500    | 0.3           | 1e-3 | [3,3,1] | [logsig, logsig, logsig] | traingd            | Minimum gradient reached |
| 500    | 0.03          | 1e-5 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 500    | 0.03          | 1e-1 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 500    | 0.03          | 1e-8 | [3,3,1] | [logsig, logsig, logsig] | traingd            | 50                       |
| 500    | 0.03          | 1e-3 | [5,4,1] | [logsig, logsig, logsig] | traingd            | 78.5                     |

**Πτυχιακή Εργασία Τμήματος Εφαρμοσμένης Πληροφορικής & Πολυμέσων**

---

|     |        |      |         |                              |         |       |
|-----|--------|------|---------|------------------------------|---------|-------|
| 100 | 0.03   | 1e-3 | [3,4,1] | [logsig, logsig,<br>logsig]  | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [logsig, logsig,<br>logsig]  | traingd | 68.37 |
| 100 | 0.03   | 1e-3 | [6,5,1] | [logsig, logsig,<br>logsig]  | traingd | 23.75 |
| 100 | 0.0003 | 1e-3 | [6,5,1] | [logsig, logsig,<br>logsig]  | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [tansig, logsig,<br>logsig]  | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [logsig, tansig,<br>logsig]  | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [logsig, logsig,<br>tansig]  | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [purelin,<br>logsig, logsig] | traingd | 50    |
| 100 | 0.03   | 1e-3 | [7,5,1] | [purelin,<br>tansig, logsig] | traingd | 50    |

**Πίνακας 4: Πίνακας αποτελεσμάτων του αλγορίθμου back propagation.**

Όσον αφορά τον αλγόριθμο learning vector quantization παρατηρούμε ότι τα ποσοστά παραμένουν σχεδόν τα ίδια ανεξαρτήτως ρυθμίσεων. Παρόλα αυτά όμως φαίνεται μια άνοδος κατά τη διάρκεια εφαρμογής της συνάρτησης learnlv2 και της μείωσης των εποχών απο 250 σε 100. Αυτό σημαίνει ότι το δίκτυό μας καταφέρνει να εκπαιδευτεί σε λιγότερες εποχές από αυτές που αρχικά είχαμε τοποθετήσει με την learnlv2 να είναι υπεύθυνη για την σωστή ρύθμιση των βαρών στα επιμέρους layers.

| Epochs | Hidden size | Learning rate | Learning function | Ποσοστό Επιτυχίας(%) |
|--------|-------------|---------------|-------------------|----------------------|
| 250    | 6           | 0.7           | learnlv2          | 50                   |
| 250    | 3           | 0.7           | learnlv2          | 52                   |
| 250    | 6           | 0.04          | learnlv2          | 47                   |
| 250    | 6           | 0.7           | learnlv1          | 58                   |
| 100    | 6           | 0.7           | learnlv2          | 61                   |
| 100    | 6           | 0.005         | learnlv2          | 50                   |
| 100    | 6           | 0.005         | learnlv1          | 50                   |

Πίνακας 5: Πίνακας αποτελεσμάτων learning vector quantization.

Ένα δίκτυο της αρχιτεκτονικής self organizing maps έχει σαν στόχο να προκαλέσει στα διαφορετικά τμήματα του δικτύου την ταυτόχρονη απόκριση σε πιθανά πρότυπα εισόδου. Στον πίνακα 6 παρατηρούμε ότι το ποσοστό επιτυχίας αγγίζει το 59% εξαιτίας της αύξησης του πλήθους των εποχών. Αυτό μας οδηγεί αβίαστα στο συμπέρασμα ότι το δίκτυο χρειάζεται περισσότερο χρόνο για την πλήρη εκπαίδευσή του. Εδώ θα πρέπει να τονιστεί ότι παρά τις αλλαγές και τις επανηλημένες προσπάθειες για καλύτερα αποτελέσματα το σύστημα δεν ανταποκρινόταν σημαντικά σε καμία.

| Epochs | Learning rate | Dimensions | Cover steps | Initial Neighbor | Topology function | Distance function | Ποσοστό Επιτυχίας(%) |
|--------|---------------|------------|-------------|------------------|-------------------|-------------------|----------------------|
| 100    | 0.009         | [1 1]      | 50          | 3                | hextop            | linkdist          | 52                   |
| 200    | 0.03          | [1 1]      | 30          | 3                | hextop            | linkdist          | 59                   |
| 50     | 0.3           | [1 1]      | 100         | 3                | hextop            | linkdist          | 55                   |
| 400    | 0.09          | [1 1]      | 80          | 3                | hextop            | linkdist          | 50                   |

**Πίνακας 6:Πίνακας αποτελεσμάτων self organizing maps.**

| Αλγόριθμος                   | Ποσοστό Επιτυχίας(%) |
|------------------------------|----------------------|
| Back Propagation             | 78.5                 |
| Support Vector Machines      | 99.375               |
| Learning Vector Quantization | 61                   |
| Self Organizing Maps         | 59                   |

**Πίνακας 7:Συγκεντρικός πίνακας αποτελεσμάτων με τα καλύτερα ποσοστά επιτυχίας.**

## 5.1 Συμπεράσματα

Το συμπέρασμα το οποίο εξάγεται από την ολοκλήρωση της παρούσας εργασίας είναι ότι ο στόχος της δημιουργίας ενός σύγχρονου και πρωτοποριακού συστήματος το οποίο συνδυάζει καινοτόμες τεχνολογίες για την αξιολόγηση της σταθερότητας υπηρεσιών που μπορεί να προσφέρει μία επιχείρηση παροχής ηλεκτρισμού, είναι πλέον σε θέση να ανταποκριθεί στις πραγματικές συνθήκες. Η χρήση μεθόδων βάσει της τρέχουσας τεχνολογίας αιχμής καθιστά το σύστημα ιδιαίτερος ελκυστικό προς τον επιστημονικό κόσμο. Καταληκτικά η αρχιτεκτονική που εκτόξευσε το σύστημα στο μεγαλύτερο ποσοστό επιτυχίας είναι η support vector machine. Αυτό κυρίως οφείλεται στην κατασκευή του αλγορίθμου και στην πολύπλοκη συνάρτηση που αυτό υλοποιεί.

## 5.2 Περιβαλλοντολογικές επιπτώσεις

Η τεχνολογία έχει επηρεάσει την κοινωνία και το περιβάλλον της με διάφορους τρόπους. Σε κάποιες κοινωνίες η τεχνολογία έχει βοηθήσει να αναπτυχθούν πιο προηγμένες οικονομίες (συμπεριλαμβανομένης της σημερινής παγκόσμιας οικονομίας) και έχει κάνει δυνατή την άνοδο μιας τάξης που διαθέτει ελεύθερο χρόνο. Πολλές τεχνολογικές διαδικασίες παράγουν ανεπιθύμητα προϊόντα, με τη διαδικασία που είναι γνωστή ως ρύπανση, και εξαντλούν τους φυσικούς πόρους σε βάρος της γης και του περιβάλλοντός της. Ποικίλες εφαρμογές της τεχνολογίας επηρεάζουν τις αξίες μιας κοινωνίας και συχνά θέτει νέες ηθικές ερωτήσεις. Παραδείγματα είναι η ανάπτυξη της αντίληψης της αποτελεσματικότητας στα πλαίσια της ανθρώπινης παραγωγικότητας, ενός όρου που αρχικά είχε εφαρμοστεί μόνο σε μηχανές, και η αμφισβήτηση των παραδοσιακών προτύπων. Θέτει, επίσης, νέα θέματα ηθικής, όπως αυτό της κλωνοποίησης ανθρώπινων όντων. Η ένταση της βιομηχανικής δραστηριότητας επηρέασε αρνητικά το περιβάλλον, περιόρισε τους φυσικούς πόρους και δημιούργησε νέα ήθη και συμπεριφορές. Τα τελευταία 30 χρόνια, όμως, η τεράστια ανάπτυξη των αστικών κέντρων, η βιομηχανική ανάπτυξη, οι πολεμικοί εξοπλισμοί, η γενικότερη κρίση των κοινωνικών αξιών ευαισθητοποίησαν την ανθρωπότητα σχετικά με τους κινδύνους που διατρέχει το περιβάλλον. Ωστόσο, η τεχνολογική πρόοδος στο σύνολό της δε μπορεί να απορριφθεί. Η τεχνολογία δεν αποτελείται μόνο από γνώσεις, τεχνικές και μεθόδους που οι άνθρωποι χρησιμοποιούν, αλλά και από τη συμπεριφορά τους που σχετίζεται με τη χρήση και εφαρμογή τους. Η εφαρμογή ενός συστήματος σαν αυτό που περιγράφεται στην εργασία δεν αποτελεί κίνδυνο για το περιβάλλον καθώς δεν έρχεται ούτε σε άμεση αλλά ούτε σε έμμεση επαφή μαζί του. Αφορά απλά και μόνο την αξιολόγηση συστημάτων και υπηρεσιών ηλεκτρικής ενέργειας (Δ.Ε.Η) για την ομαλότερη και σταθερότερη λειτουργία του δικτύου που καλύπτουν. Αυτό λοιπόν που χρειάζεται είναι σύνεση και ορθολογισμός κατά την αξιοποίηση των φυσικών πόρων και τη χρήση των τεχνολογικών μεθόδων προκειμένου φύση και άνθρωπος να πορεύονται εναρμονισμένα.

### ***5.3 Μελλοντική Εργασία και Επεκτάσεις***

Στο μέλλον οι επεκτάσεις του συστήματος μπορούν να εφαρμοστούν σε πολλούς τομείς. Αρχικά θα μπορούσαν να χρησιμοποιηθούν πιο σύγχρονοι αλγόριθμοι οι οποίοι θα βελτιστοποιούσαν το αποτέλεσμα σε συντομότερο χρονικό διάστημα. Επίσης η εφαρμογή διαδραστικού περιβάλλοντος πάνω στο οποίο ο χρήστης θα μπορεί να επιλέγει ανάλογα με τις ανάγκες και απαιτήσεις του, αλγορίθμους αλλά και βάσεις δεδομένων που θα ικανοποιούν την τρέχουσα ζήτηση των καταναλωτών. Με άλλα λόγια μια εφαρμογή η οποία θα προσαρμόζεται στις εκάστοτε οικονομικές και κοινωνικές ανάγκες. Τέλος, στόχος είναι η δημιουργία ενός αυτόνομου συστήματος το οποίο θα βοηθάει τον άνθρωπο ως συμβουλευτική αυτοματοποιημένη μηχανή και σε καμία περίπτωση δεν θα τον αντικαθιστά. Παρόλα αυτά θα πραγματοποιεί σε πραγματικό χρόνο αξιολόγηση αλλά και εντοπισμό των πιθανών λαθών που θα συμβούν στο δίκτυο ηλεκτρικής ενέργειας.



## Βιβλιογραφία

- [1] <http://www.new-media.gr/uploads/methodologia.pdf>.
- [2] Dennett, Daniel (1995). *Darwin's Dangerous Idea*. New York: Touchstone/Simon & Schuster. ISBN 0-684-80290-2.
- [3] Computer science pioneer Samuel D. Conte dies at 85 July 1, 2002
- [4] Bowden, B. V. (1970), "The Language of Computers", *American Scientist* 58: 43–53, Bibcode 1970AmSci..58...43B, retrieved 2008-05-17.
- [5] Howe, J. (November 1994). "Artificial Intelligence at Edinburgh University: a Perspective". Retrieved 30 August 2007.
- [6] Harnad, Stevan (2008), "The Annotation Game: On Turing (1950) on Computing, Machinery, and Intelligence", in Epstein, Robert; Peters, Grace, *The Turing Test Sourcebook: Philosophical and Methodological Issues in the Quest for the Thinking Computer*, Kluwer.
- [7] [el.wikipedia.org/wiki/Νευρωνικό\\_δίκτυο](http://el.wikipedia.org/wiki/Νευρωνικό_δίκτυο)
- [8] Matson, Ronald, "Comparing scientific laws and theories", *Biology*, Kennesaw State University.
- [9] [en.wikipedia.org/wiki/State\\_of\\_the\\_art](http://en.wikipedia.org/wiki/State_of_the_art)
- [10] [en.wikipedia.org/wiki/Self-organizing\\_map](http://en.wikipedia.org/wiki/Self-organizing_map)
- [11] [el.wikipedia.org/wiki/Εξόρυξη\\_δεδομένων](http://el.wikipedia.org/wiki/Εξόρυξη_δεδομένων)
- [12] Louis WEHENKEL, *Machine Learning Approaches to Power System Security Assessment*
- [13] Emmanouil M. Voumvoulakis and Nikos D. Hatziargyriou, *A Particle Swarm Optimization Method for Power System Dynamic Security Control*
- [14] G.Sideratos,I.Vitellas,N.Hatziargyriou, *A load forecasting hybrid method for an isolated power system*
- [15] E.S. Karapidakis, *Machine learning for frequency estimation of power systems*
- [16] Kohonen, Teuvo (1982). "Self-Organized Formation of Topologically Correct Feature Maps". *Biological Cybernetics* 43 (1): 59–69.
- [17] *Pearl Street Station: The Dawn of Commercial Electric Power*