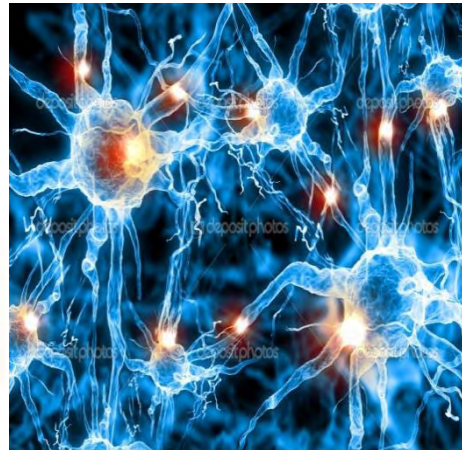




ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

Διατμηματικό Πρόγραμμα Μεταπτυχιακών Σπουδών

«Πληροφορική και Υπολογιστική Βιοιατρική»



Τίτλος πτυχιακής εργασίας:

**Νευρωνικά Δίκτυα και Μηχανική Μάθηση
Εφαρμογές στη Βιοπληροφορική & στο Παγκόσμιο Ιστό**

Σπουδαστές: Λελοβίτη Σοφία – Δημολίτσα Θεοδώρα

Επιβλέπων καθηγητής: Δωρόθεος Αγγέλης

Η συναρπαστική νέα προσπάθεια για να κάνουμε τους υπολογιστές να σκέφτονται...μηχανή με νόηση, με πλήρη και κυριολεκτική έννοια. (Haygeland,1985)

Η μελέτη του πως μπορούμε να κάνουμε τους υπολογιστές να κάνουν πράγματα στα οποία, προς το παρόν, οι άνθρωποι είναι καλύτεροι. (Rich και Knight,1991)

Περίληψη

Η έρευνα πάνω σε θέματα που αφορούν τεχνητά νευρωνικά δίκτυα άρχισε με την κατανόηση της λειτουργίας του εγκεφάλου και την εισαγωγή της ιδέας των νευρώνων στις αρχές του αιώνα, σε συνδυασμό με την συνειδητοποίηση, που ακολούθησε έπειτα, ότι ο ανθρώπινος εγκέφαλος επεξεργάζεται δεδομένα τελείως διαφορετικά από έναν ηλεκτρονικό υπολογιστή. Οι νευρώνες γενικά είναι επεξεργαστές πολύ πιο αργοί από τις λογικές πύλες των υπολογιστών. Παρ' όλα αυτά, όμως, ο εγκέφαλος με την υψηλή πολυπλοκότητά του και το σύστημα παράλληλης επεξεργασίας που διαθέτει, με τη δυνατότητα να οργανώνει τους νευρώνες, επιτελεί τις επεξεργασίες πολύ πιο γρήγορα και από τον ταχύτερο ηλεκτρονικό υπολογιστή παρουσιάζοντας τεράστιες δυνατότητες όσο αφορά την επεξεργασία δεδομένων και διεκπεραίωση διαφόρων εργασιών. Η κατασκευή μηχανών ικανών να μαθαίνουν από την εμπειρία έχει αποτελέσει για πολύ καιρό αντικείμενο τόσο φιλοσοφικών όσο και τεχνικών συζητήσεων. Η τεχνική πτυχή των συζητήσεων έχει λάβει μια τεράστια ώθηση από την εμφάνιση των ηλεκτρονικών υπολογιστών που έχουν καταδείξει ότι οι μηχανές μπορούν να επιδείξουν ένα σημαντικό επίπεδο ικανότητας μάθησης, αν και τα όρια αυτής της ικανότητας δεν έχουν ακόμα σαφώς καθοριστεί.

Η ύπαρξη αξιόπιστων συστημάτων εκμάθησης είναι αναγκαία, δεδομένου ότι υπάρχουν πολλά προβλήματα για τα οποία δεν υπάρχει διαθέσιμο κάποιο μαθηματικό πρότυπο που να τα περιγράφει, οπότε και δεν μπορούν να λυθούν από τις κλασικές τεχνικές προγραμματισμού. Είναι επομένως φυσικό να ρωτήσει κανείς αν ένας υπολογιστής μπορεί να εκπαιδευτεί να αναγνωρίζει το γράμμα 'Α' από παραδείγματα, εξάλλου αυτός δεν είναι και ο τρόπος που ο άνθρωπος μαθαίνει να διαβάζει; Θα αναφερθούμε σε αυτήν την προσέγγιση για την επίλυση του προβλήματος ως μεθοδολογία μηχανικής μάθησης.

Η παρούσα διπλωματική εργασία αφιερώνεται στον καθηγητή μας κ.Δωρόθεο Αγγέλη!

Περιεχόμενα

Κεφάλαιο 1

1.0 Νευρωνικά δίκτυα.....	8
1.1 Ορισμός.....	8
1.2 Εισαγωγή- βασικές έννοιες.....	8
1.3 Ανασκόπηση.....	10
1.4 Πλεονεκτήματα νευρωνικών δικτύων.....	11
1.5 Η λειτουργία του εγκεφάλου.....	13
1.6 Περιγραφή ενός νευρώνα.....	15
1.7 Παρουσία γνώσης –πληροφορίας στην είσοδο τεχνητού νευρώνα.....	18
1.7.1 Ορισμός γνώσης- μορφής δεδομένων.....	18
1.8 Εκπαίδευση νευρωνικών δικτύων.....	19
1.8.1 Εκπαίδευση με επίβλεψη.....	20
1.8.2 Μη εποπτευόμενη εκπαίδευση.....	21
1.9 Νευρωνικά δίκτυα Perceptron.....	22
1.9.1 Εισαγωγή.....	22
1.9.2 Ορισμός.....	22

Κεφάλαιο 2

2.0 Μηχανική μάθηση.....	25
2.1 Βασικές έννοιες- ορισμοί.....	25
2.2 Διαδικασίες μάθησης.....	26
2.3 Μάθηση με εκπαιδευτή.....	27
2.4 Μάθηση χωρίς εκπαιδευτή.....	28
2.5 Εργασίες μάθησης.....	31
2.5.1 Σύσχέτιση προτύπων.....	31
2.5.2 Αναγνώριση προτύπων.....	32
2.5.3 Προσέγγιση συνάρτησης.....	34

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

2.5.4 Έλεγχος.....	36
<u>Κεφάλαιο 3</u>	
3.0 Οικογένειες αλγορίθμων μηχανικής μάθησης.....	38
3.1 Μάθηση κατά Bayes.....	38
3.2 Μάθηση βασισμένη σε δένδρα απόφασης.....	39
3.3 Αυτόματη εκμάθηση κανόνων.....	39
3.4 Μάθηση βασισμένη σε στιγμιότυπα.....	40
3.5 Μάθηση βασισμένη σε τεχνητά νευρωνικά δίκτυα.....	41
3.6 Μάθηση βασισμένη σε γενετικούς αλγορίθμους.....	41
3.7 Μετά- μάθηση.....	42
3.8 Μάθηση σε μικρή κλίμακα.....	43
3.8.1 Ορισμός.....	43
3.8.2 Προβλήματα μάθησης μικρής κλίμακας.....	43
3.9 Μάθηση σε μεγάλη κλίμακα.....	44
3.9.1 Ορισμός.....	44
3.9.2 Προβλήματα μάθησης μεγάλης κλίμακας.....	45
<u>Κεφάλαιο 4</u>	
4.1 Μέθοδοι πυρήνα.....	48
4.1.1 Ορισμός.....	48
4.1.2 Βασικές έννοιες.....	48
4.1.3 Περιγραφή.....	49
4.1.4 Μετατροπή των αλγορίθμων σε μεθόδους πυρήνα.....	54
4.2 Support Vector Machines.....	55
4.2.1 Ορισμός.....	55
4.3 Αλγόριθμος κατηγοριοποίησης δεδομένων.....	56
4.4 Θεώρημα Representer.....	60
4.4.1 Γενικευμένη εφαρμοστικότητα του θεωρήματος Representer.....	61

Κεφάλαιο 5

5.1 Φίλτρα Kalman.....	62
5.2 Το διακριτό φίλτρο Kalman	64
5.3 Η λειτουργία του αλγορίθμου.....	64
5.4 Υλοποίηση Φίλτρου Kalman.....	66
5.5 Εκτεταμένο φίλτρο Kalman	67
5.6 Γενικά για την μέθοδο ICA.....	68
5.7 Αλγόριθμοι υλοποίησης της μεθόδου ICA.....	70
5.7.1 Αλγόριθμοι που βασίζονται σε τεχνικές HOS.....	70
5.7.2 Αλγόριθμοι που βασίζονται στην εξέλιξη των συνιστωσών στο χρόνο.....	72

Κεφάλαιο 6

6.0 Εφαρμογές μηχανικής μάθησης.....	73
6.1 Βιοπληροφορική	73
6.1.2 Πεδία της Βιοπληροφορικής.....	75
6.1.3 Ανάλυση Δεδομένων Γονιδιακής Έκφρασης και Σχεδιασμός Φαρμάκων ...	76
6.1.4 Υπολογιστικές τεχνικές στο σχεδιασμό φαρμάκων.....	77
6.1.5 Γενετικοί αλγόριθμοι.....	77
6.1.6 Παράδειγμα αλγόριθμου Adaboost (adaptive boosting).....	78
Παραδείγματα.....	79
6.2 Παγκόσμιος Ιστός.....	81
6.2.1 Ανακάλυψη Γνώσης από Δεδομένα Ηλεκτρονικής Αλληλογραφίας.....	83
6.2.2 Εξόρυξη δεδομένων (data mining) και κατηγορικά δεδομένα.....	84
6.2.3 Αλγόριθμοι και τεχνικές εξόρυξης δεδομένων απο ροές δεδομένων στον παγκόσμιο ιστό.....	85
6.2.4 Παράδειγμα.....	88
Συμπεράσματα.....	95
Βιβλιογραφία.....	100

Εισαγωγή

Το παρόν εγχειρίδιο πραγματεύεται δύο εξαιρετικά αναπτυσσόμενους τομείς της τεχνητής νοημοσύνης. Τα νευρωνικά δίκτυα και την μηχανική μάθηση. Οι τομείς αυτοί αφενός παρουσιάζουν εξαιρετικό επιστημονικό ενδιαφέρον παρέχοντας και συνδυάζοντας γνώση από διάφορα επιστημονικά πεδία, αφετέρου χρησιμοποιούνται για την επίλυση ποικίλων προβλημάτων σε πάρα πολλούς τομείς (στατιστική, μαθηματικά, ρομποτική, φυσική, κοινωνικές επιστήμες, ψυχολογία, ανθρωπολογία και άλλα).

Στόχος του πονήματος αυτού είναι να παρουσιαστούν με όσο το δυνατόν μεγαλύτερη σαφήνεια και πληρότητα τα βασικά χαρακτηριστικά των νευρωνικών δικτύων και της μηχανικής μάθησης. Κατά συνέπεια, το έργο αυτό απευθύνεται στον αναγώστη που θέλει να έχει μια σφαιρική και ολική εικόνα του θέματος όσο πιο συνοπτικά και με σχετική πληρότητα γίνεται, αποκτώντας το κατάλληλο θεωρητικό υπόβαθρο για μεταγενέστερη ενασχόληση. Αξίζει να σημειωθεί, ότι ιδιαίτερη προσοχή δίνεται στον τομέα της μηχανικής μάθησης που εδράζεται στην λειτουργία των νευρωνικών δικτύων αλλά παρουσιάζει τεράστια ποικιλία εφαρμογών καθιστώντας την από τους ταχύτερα εξελισσόμενους επιστημονικούς κλάδους.

Κεφάλαιο 1

Εισαγωγή

Στο κεφάλαιο αυτό θα ασχοληθούμε με το πεδίο έρευνας των νευρωνικών δικτύων. Θα παρουσιάσουμε το βασικό θεωρητικό υπόβαθρο αυτού του εξαιρετικά ενδιαφέροντος πεδίου ώστε ο αναγνώστης να πάρει μια καλή πρώτη εντύπωση πάνω στο θέμα αυτό. Πιο συγκεκριμένα, θα αναφερθούμε στο τι είναι ένα νευρωνικό δίκτυο, από που ξεκίνησε η όλη ιδέα, πως λειτουργεί ένας νευρώνας, τα πλεονεκτήματα τους που τα κατέστησαν τόσο σημαντικά στον τομέα της τεχνητής νοημοσύνης καθώς επίσης θα αναφερθούμε στον τρόπο εκπαίδευσης τους και θα παρουσιάσουμε τα νευρωνικά δίκτυα perceptron. (Raul Rojas, Neural Networks - A Systematic Introduction, Springer-Verlag, Berlin, 1996.)

1.0 Νευρωνικά δίκτυα

1.1 Ορισμός

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 κατασκευάσμα 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. (Mitchell, 1997; Simon Haykin 1993)

1.2 Εισαγωγή-βασικές έννοιες

Η όλη ιδέα και η σύλληψη της επιστήμης των τεχνητών νευρωνικών δικτύων βασίζεται στην δομή του ανθρώπινου εγκεφάλου ο οποίος αποτελείται από εκατομμύρια νευρώνες με σκοπό να εκτελούνται όλες οι ανθρώπινες λειτουργίες βασικές και μη (όραση, γραφή, κίνηση, αντίληψη, απόκριση σε ερεθίσματα, αναγνώριση πρωτοτύπων). Βασική αρχή της επιστήμης αυτής βασίστηκε στο γεγονός ότι ο ανθρώπινος εγκέφαλος εκτελεί τους υπολογισμούς με τελείως διαφορετικό τρόπο από έναν συμβατικό υπολογιστή. Ο εγκέφαλος είναι ένας εξαιρετικά πολύπλοκος μη γραμμικός παράλληλος υπολογιστής. Έχει την δυνατότητα να οργανώνει τα δομικά του στοιχεία, γνωστά ως νευρώνες, με τρόπο ώστε να εκτελούν συγκεκριμένους υπολογισμούς με ταχύτητα πολλαπλάσια συγκριτικά με τον γρηγορότερο ψηφιακό υπολογιστή που μπορεί να υπάρξει.

Ένα χαρακτηριστικό παράδειγμα είναι η ανθρώπινη όραση. Ο εγκέφαλος είναι ο κύριος αποδέκτης των ερεθισμάτων που δέχεται ο άνθρωπος και ανάλογα με το τι βλέπει αντιδρά ανάλογα. Το θέμα εδώ είναι ότι επεξεργάζεται τα όποια ερεθίσματα συναντά με ταχύτητα σχεδόν αμελητέα και μη αντιληπτή για εμάς (περίπου 100 με 200 ns) την ίδια στιγμή που εργασίες πολύ μικρότερου βαθμού πολυπλοκότητας απαιτούν πολύ μεγαλύτερους χρόνους εκτέλεσης από ένα ισχυρό υπολογιστή. Ένα ακόμη πολύ ενδιαφέρον παράδειγμα είναι οι νυχτερίδες οι οποίες

χρησιμοποιούν ένα είδος σόναρ για να μετακινηθούν στο σκοτάδι. Δεν βλέπουν τόσο καλά και ζουν σχεδόν αποκλειστικά το βράδυ, γι' αυτό και πρέπει να στηρίζονται σε άλλες μεθόδους "πλοήγησης" κατά την πτήση εκτός της όρασης. Οι νυχτερίδες στέλνουν σήματα ηχούς στο περιβάλλον και λαμβάνουν πίσω τις αντανάκλασεις αυτές, ξέροντας έτσι τι βρίσκεται γύρω τους. Οι πολύπλοκοι νευρωνικοί υπολογισμοί που απαιτούνται για την εξαγωγή όλων αυτών των πληροφοριών πραγματοποιούνται, από τον επουσιώδη από άποψη μεγέθους εγκέφαλο της νυχτερίδας, με τέτοια ακρίβεια που θα ζήλευαν όλα τα προηγμένα ραντάρ. Το πως τα καταφέρνει ο ανθρώπινος εγκέφαλος ή ακόμα και ο εγκέφαλος της νυχτερίδας αποτελεί ένα εξαιρετικά ενδιαφέρον επιστημονικό πεδίο μελέτης νευρώνων-εγκεφάλου. *Littlestone & Warmuth (1994)*

Ο ανθρώπινος εγκέφαλος είναι το τελικό προϊόν της αλληλοεπικάλυψης τριών εγκεφάλων οι οποίοι εμφανίστηκαν διαδοχικά στη διάρκεια της εξέλιξης των σπονδυλωτών. Από κάτω προς τα πάνω -στη βάση του κρανίου- υπάρχει ο αρχαιότερος εγκέφαλος, ο ρομβοειδής, ειδικευμένος στις ενστικτώδεις ακούσιες λειτουργίες (επαγρύπνηση, αναπνοή, κυκλοφορία του αίματος, μυϊκός τόνος). Αποτελείται από τον προμήκη μυελό -τμήματα του νωτιαίου μυελού που εισέρχονται στον εγκέφαλο-, τη γέφυρα και την παρεγκεφαλίδα. Ακολουθεί ο μεσεγκέφαλος ή μέσος εγκέφαλος, ένα μικρό τμήμα του εγκεφάλου το οποίο παχαίνει στη ραχιαία περιοχή σχηματίζοντας την οπτική στέγη, το ζευγάρι πυρήνων που σχηματίζουν την οπτική ταινία. Ακολουθεί ο προσεγκέφαλος ή πρόσθιος εγκέφαλος, το πιο πρόσφατο ιστορικά απόκτημα του εγκεφάλου μας

Από την στιγμή της γέννησης, ο εγκέφαλος έχει ήδη σημαντική δομή και τη δυνατότητα να κατασκευάζει δικούς του κανόνες συμπεριφοράς, μέσω αυτού που αποκαλούμε «εμπειρία». Η εμπειρία συσσωρεύεται με την πάροδο του χρόνου και μεγάλο μέρος της εξέλιξης του εγκεφάλου λαμβάνει χώρα στα δύο πρώτα έτη. Ο χαρακτηρισμός ενός νευρικού συστήματος ως «εξελισσόμενο» είναι συνυφασμένος με την έννοια της πλαστικότητας και περιλαμβάνει την δυνατότητα να προσαρμόζεται ανάλογα με το περιβάλλον του, κάτι που το καθιστά αναντικατάστατο και εξαιρετικά κρίσιμο για την διαίωσιση και ομαλή εξέλιξη των ειδών.

Συμπερασματικά, στην πλέον γενική μορφή του, ένα νευρωνικό δίκτυο είναι μια μηχανή σχεδιασμένη ώστε να μοντελοποιεί τον τρόπο με τον οποίο ο εγκέφαλος εκτελεί μια συγκεκριμένη εργασία ή λειτουργία. Το δίκτυο αυτό υλοποιείται συνήθως με τη χρήση ηλεκτρονικών συστατικών ή προσομοιώνεται με τη χρήση λογισμικού σ' έναν υπολογιστή. Στην παρούσα εργασία θα επικεντρωθούμε σε μια σημαντική κατηγορία νευρωνικών δικτύων τα οποία εκτελούν χρήσιμους υπολογισμούς αφού εκπαιδευτούν μέσω μιας διαδικασίας μάθησης. Για να πετύχουν καλύτερη απόδοση, τα νευρωνικά δίκτυα χρησιμοποιούν τεράστιο αριθμό απλών διασυνδεδεμένων μεταξύ τους υπολογιστικών κυττάρων, τα οποία αποκαλούνται «νευρώνες» ή «μονάδες επεξεργασίας». (Carbonell, 1987; Mitchell, 1997; Witten & Frank, 2000).

Παρακάτω διατυπώνεται ο ακόλουθος ορισμός ενός νευρωνικού δικτύου ως προσαρμόσιμη μηχανή.

Ένα νευρωνικό δίκτυο είναι ένας τεράστιος παράλληλος επεξεργαστής με κατανεμημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από τη φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση και να τη καθιστά διαθέσιμη για χρήση. Μοιάζει με τον ανθρώπινο εγκέφαλο σε δύο σημεία:

1) Το δίκτυο προσλαμβάνει τη γνώση από το περιβάλλον του, μέσω μιας διαδικασίας μάθησης.

2) Η ισχύς των συνδέσεων μεταξύ των νευρώνων, που αποκαλείται συναπτικό βάρος χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτάται.

1.3 Ανασκόπηση

Από την αρχαιότητα ακόμη οι άνθρωποι ενδιαφέρονταν να κατανοήσουν τον ανθρώπινο εγκέφαλο και πως αυτός λειτουργεί. Στα χρόνια των Αιγυπτίων ανάγεται ιστορικά η έρευνα του εγκεφάλου, σύμφωνα με τον Edwin Smith – βρήκε έναν πάπυρο, αντίγραφο ενός προηγούμενου που χρονολογείται στο 2500-3000 πΧ. Στον πάπυρο αυτό γίνονταν αναφορές για ασθενείς με τραύματα στο κρανίο και τον εγκέφαλο καθώς επίσης και κάποιες προσπάθειες εντοπισμού ορισμένων λειτουργιών στον φλοιό του εγκεφάλου. Ωστόσο όμως γενέθλια μέρα των νευροεπιστημών θεωρείται η 18/05/1861, όπου ο Γάλλος γιατρός, ανατόμος και ανθρωπολόγος Pierre Paul Broca διατυπώνει την πιο επαναστατική θεωρία για τη λειτουργία του εγκεφάλου: «μιλάμε με το αριστερό ημισφαίριο». Στις επόμενες δεκαετίες παρατηρήθηκε μια έκρηξη πάνω στην έρευνα για τον εγκέφαλο. Η πληθώρα των ερωτημάτων που είχαν συσσωρευτεί ταξινομήθηκαν σε τρεις κατηγορίες:

1) Κατώτερο ή βασικό επίπεδο: ερωτήματα για τη μορφή και λειτουργία του νευρικού συστήματος και των δομικών μονάδων τους, των νευρώνων.

2) Μέσο επίπεδο: ερωτήματα που σχετίζονται με τους μηχανισμούς των αποκαλούμενων « ανώτερων » ή νοητικών λειτουργιών του εγκεφάλου. (Πως οι διάφοροι οργανισμοί αντιλαμβάνονται τον κόσμο, πως αποθηκεύουν και ανακαλούν πληροφορίες γι' αυτόν, πως μαθαίνουν να τροποποιούν τη συμπεριφορά τους σύμφωνα με την προηγούμενη εμπειρία).

3) Υψηλό επίπεδο: ερωτήματα που αφορούν τη συνείδηση, σκόπιμη συμπεριφορά και την ευφυΐα.

Οι δεκαετίες αυτές χαρακτηρίζονται από μια συνεχή έρευνα πάνω σε όλα αυτά τα ερωτήματα καθώς επίσης και από μια ανάλυση των λειτουργιών του εγκεφάλου με σκοπό την κατανόηση των διεργασιών που σχετίζονται με τον τρόπο σκέψης του ανθρώπου.

Έτσι το 1940, έχουμε την σχεδίαση της πρώτης σκεπτόμενης μηχανής από τον J. Von Neumann. Όμως, αντίθετα με τους McCulloch και Pitts, ο Von Neumann πίστευε ότι οι εγκεφαλικές λειτουργίες δεν μπορούν να προσομοιωθούν με τη χρήση της *δυναμικής γλώσσας* (η γλώσσα του εγκεφάλου δεν είναι γλώσσα μαθηματικών). Από την άλλη μεριά, ο McCulloch ισχυρίστηκε το αντίθετο. Περιέγραψε την λειτουργική οργάνωση του εγκεφαλικού φλοιού με όρους μαθηματικής ανάλυσης. Έτσι, το 1943 κατασκεύασε ένα ηλεκτρονικό σύστημα που προσομοίωνε τον τρόπο σύνδεσης των νευρώνων του εγκεφάλου και το οποίο ήταν σε θέση να εξομοιώνει απλές λογικές συναρτήσεις. Παράλληλα, έγιναν προσπάθειες να κατασκευαστούν μοντέλα νοητικών λειτουργιών, όπως η αναγνώριση προτύπων (*pattern recognition*), η σκόπιμη συμπεριφορά και η λογική σκέψη. Τέθηκαν λοιπόν οι βάσεις ώστε να κατασκευαστούν τα σημερινά σύγχρονα μοντέλα νευρωνικών δικτύων που εμφανίζουν πληθώρα εφαρμογών σε διάφορους τομείς των επιστημών.

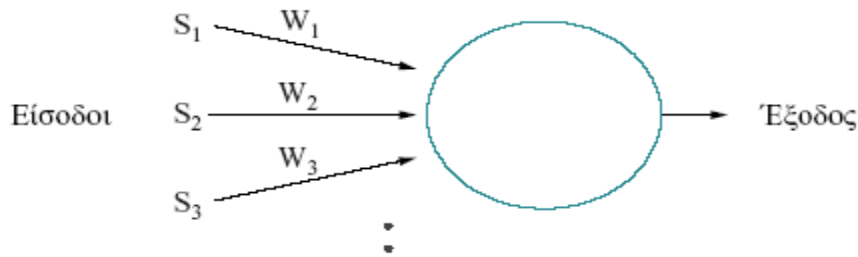
1.4 Πλεονεκτήματα νευρωνικών δικτύων

Τα νευρωνικά δίκτυα παρουσιάζουν τις ακόλουθες χρήσιμες ιδιότητες και δυνατότητες:

1. *Μη γραμμικότητα.* Ένας τεχνητός νευρώνας μπορεί να είναι είτε γραμμικός είτε όχι. Ένα νευρωνικό δίκτυο αποτελείται από διασυνδεδεμένους μη γραμμικούς νευρώνες είναι, από τη φύση του μη γραμμικό. Επιπλέον αυτή η μη γραμμικότητα είναι «ειδικού τύπου» υπό την έννοια ότι είναι κατανομημένη σε όλη την έκταση του δικτύου. Η μη γραμμικότητα καθίσταται ιδιαίτερα σημαντική, κυρίως αν ο υποκείμενος φυσικός μηχανισμός που είναι υπεύθυνος για την παραγωγή σήματος εισόδου (π.χ ομιλία) είναι εκ φύσεως μη γραμμικός.

2. *Προσαρμοστικότητα.* Τα νευρωνικά δίκτυα έχουν εγγενή δυνατότητα να προσαρμόζουν τα συνοπτικά βάρη τους ανάλογα με τις μεταβολές που γίνονται στο περιβάλλον τους. Πιο συγκεκριμένα, ένα νευρωνικό δίκτυο που είναι εκπαιδευμένο να λειτουργεί σε συγκεκριμένο περιβάλλον, μπορεί εύκολα επανεκπαιδευτεί ώστε να λειτουργεί και σε μεταβαλλόμενο περιβάλλον λειτουργίας. Η φυσική αρχιτεκτονική ενός νευρωνικού δικτύου για ταξινόμηση προτύπων, επεξεργασία σήματος και εφαρμογές ελέγχου, σε συνδυασμό με την προσαρμοστική του δυνατότητα, το καθιστά ιδιαίτερα χρήσιμο εργαλείο για την προσαρμοστική ταξινόμηση προτύπων, την προσαρμοστική επεξεργασία σήματος και τον προσαρμοστικό έλεγχο συστημάτων. Σαν γενικό κανόνα θα μπορούσαμε να πούμε ότι όσο πιο προσαρμοστικό είναι ένα σύστημα τόσο πιο χρήσιμο και πιο αποδοτικό θα είναι κυρίως όταν κληθεί να λειτουργήσει σε ένα ασταθές περιβάλλον.

3. *Αντιστοιχισμός εισόδου-εξόδου.* Ένα δημοφιλές παράδειγμα μάθησης, η μάθηση με εκπαίδευση ή επιβλεπόμενη μάθηση, συνίσταται στην τροποποίηση των συναπτικών βαρών ενός νευρωνικού δικτύου εφαρμόζοντας ένα σύνολο παραδειγμάτων εκπαίδευσης, ή παραδειγμάτων εργασιών. Κάθε παράδειγμα αποτελείται από ένα μοναδικό σήμα εισόδου και μια αντίστοιχη επιθυμητή απόκριση. Στο δίκτυο παρουσιάζεται ένα παράδειγμα επιλεγμένο τυχαία από το σύνολο και τα συναπτικά βάρη (ελεύθερες παράμετροι) του δικτύου τροποποιούνται ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ επιθυμητής απόκρισης και της πραγματικής απόκρισης που παράγεται απ το σήμα εισόδου, σύμφωνα με ένα κατάλληλο στατιστικό κριτήριο. Η διαδικασία εκπαίδευσης του δικτύου επαναλαμβάνεται για πολλά παραδείγματα του συνόλου εκπαίδευσης, μέχρι το σύστημα να φτάσει σε μια ευσταθή κατάσταση, χωρίς περαιτέρω σημαντικές μεταβολές. Συμπερασματικά, η αντιστοιχισμός εισόδου εξόδου δημιουργείται μέσω μιας διαδικασίας μάθησης μέσω παραδειγμάτων προσπαθώντας να μειωθούν οι διαφορές της επιθυμητής απόκρισης και της πραγματικής στην προσπάθεια μας να περιοριστούν οι αυθαίρετες εκτιμήσεις στο χώρο του σήματος εισόδου.



Σχήμα1

Σε κάθε νευρώνα καταυθάνει ένας αριθμός σημάτων σαν είσοδος. Καθε σήμα συνδέεται με την τιμή βάρους ($w_1, w_2 \dots$). Ενα βάρους μας λέει πόσο σημαντική είναι η συνεισφορά του συγκεκριμένου σήματος.

4. *Ενδεικτική απόκριση.* Ενα νευρωνικό δίκτυο μπορεί να σχεδιαστεί ώστε να παρέχει πληροφορία όχι μόνο για το ποιό πρότυπο θα επιλεγεί, αλλά και σχετικά με τον βαθμό εμπιστοσύνης στην ληφθείσα απόφαση. Ο βαθμός εμπιστοσύνης μπορεί να χρησιμοποιηθεί για να απορίψει την ακρίβεια της αναγνώρισης (do only you can do).

5. *Ανοχή σε βλάβες.* Λόγω της φύσης και της δομής τους τα νευρωνικά δίκτυα παρουσιάζουν μεγάλη ευρρωστία και ανθεκτικότητα καθώς και ποιοτική απόδοση σε ακραίες ή επισφαλείς συνθήκες. Αυτό συμβαίνει λόγω της κατανεμημένης φύσης της πληροφορίας που αποθηκεύεται στο δίκτυο. Για παράδειγμα αν ένας νευρώνας ή οι συνδέσεις του καταστραφούν αφενός η ποιότητα ανάκλησης ενός αποθηκευμένου προτύπου εκεί μειώνεται, αφετέρου θα πρέπει μια τέτοια βλάβη να πάρει σημαντική έκταση προτού θεωρηθεί «επικίνδυνη» για την *συνολική* απόκριση του δικτύου. Συμπερασματικά, ένα νευρωνικό δίκτυο μπορεί να παρουσιάσει μειωμένη απόδοση αλλά είναι εξαιρετικά δύσκολο να παρουσιάσει καταστροφική αποτυχία στην λειτουργία του.

6. *Δυνατότητα υλοποίησης με τεχνολογία VLSI.* Η μαζικά παράλληλη φύση του νευρωνικού δικτύου το καθιστά κατάλληλο για χρήση τεχνολογίας πολύ μεγάλης κλίμακας ολοκλήρωσης (Very Large Scale Of Integrated).

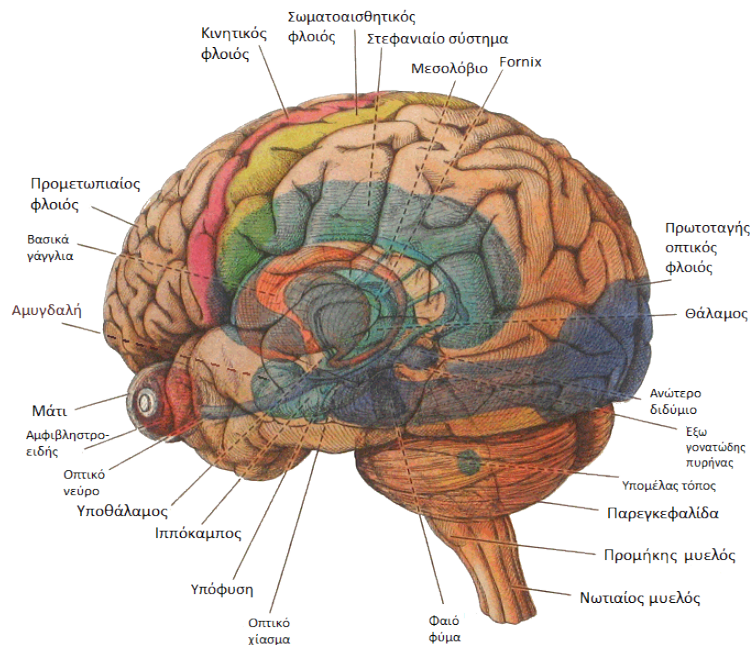
7. *Σχετική με το περιεχόμενο πληροφορία.* Η γνώση ή πληροφορία που παρουσιάζεται στην δομή του κάθε νευρώνα είναι επηρεασμένη από την συνολική δραστηριότητα όλων των άλλων νευρώνων του δικτύου.

8. *Ομοιομορφία ανάλυσης και σχεδίασης.* Υπάρχει μια γενική αρχή ότι οι νευρώνες ως δομικά στοιχεία είναι κοινοί σε όλα τα νευρωνικά δίκτυα. Σαν αποτέλεσμα αυτού καθίσταται εφικτή η χρήση των ίδιων θεωριών και αλγορίθμων μάθησης σε διαφορετικές εφαρμογές των νευρωνικων δικτύων.

Αναλογία με την νευροφυσιολογία του εγκεφάλου. Η σχεδίαση ενός νευρωνικού δικτύου παρουσιάζει πολλές ομοιότητες με στοιχεία από την λειτουργία του ανθρώπινου εγκεφάλου αποδεικνύοντας ότι η παράλληλη επεξεργασία δεν είναι μόνο εφικτή φυσικά αλλά ταχύτατη και ισχυρή και στην μηχανική. Έτσι λοιπόν διακρίνουμε μια αμφίδρομη επικοινωνία μεταξύ δυο φαινομενικά εντελώς διαφορετικών κλάδων της νευροβιολογίας και της πληροφορικής. Οι νευροβιολόγοι αντιμετωπίζουν τα τεχνητά νευρωνικά δίκτυα ως ερευνητικό εργαλείο για την ερμηνεία νευροβιολογικών φαινομένων, ενώ οι μηχανικοί προκειμένου να επιλύσουν ζητήματα αυξημένης πολυπλοκότητας ανατρέχουν στην νευροβιολογία για νέες ιδέες.

http://www.icsd.aegean.gr/lecturers/kavallieratou/NN&EP_files/ci_6.pdf

1.5 Η λειτουργία του εγκεφάλου

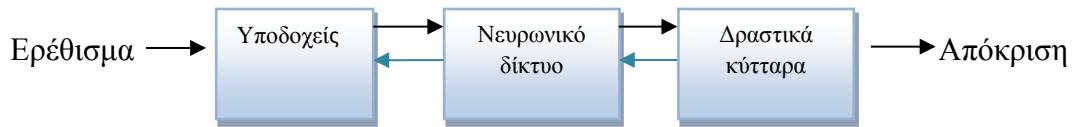


Η σύνθεση όλων των ερευνών οδήγησε τους νευροεπιστήμονες σήμερα να θεωρούν το νευρικό κύτταρο του εγκεφάλου σαν ένα μικρό υπολογιστή και τον εγκέφαλο σαν ένα δίκτυο που αποτελείται από δεκάδες δισεκατομμύρια τέτοια κύτταρα που έχουν την ικανότητα να επεξεργάζονται πληροφορίες. Κάθε νευρικό κύτταρο ή νευρώνας δέχεται ηλεκτρικές ωθήσεις μέσω μιας δενδροειδούς δομής που ονομάζεται δενδρίτης. Οι χιλιάδες μικροσκοπικές διακλαδώσεις του δενδρίτη σήματα στο σώμα του νευρικού κυττάρου. Μερικά από τα εισερχόμενα κύματα διεγείρουν τον νευρώνα, ενώ άλλα τον αναστέλλουν. Αν ο αριθμός των διεγερτικών ώσεων υπερβαίνει τον αριθμό των ανασταλτικών ο νευρώνας αποφορτίζεται στέλνοντας τη δική του ώθηση κατά μήκος μιας νευρωειδούς προέκτασης του που ονομάζεται νευροάξονας. Ένας μοναδικός νευρώνας δέχεται σήματα από χιλιάδες άλλους νευρώνες και ο νευροάξονάς του μπορεί να έχει υπεράριθμες διακλαδώσεις μέσω των οποίων διοχετεύει σήματα σε χιλιάδες άλλους νευρώνες. Μπορούμε λοιπόν να θεωρήσουμε το νευρώνα ως ένα κύτταρο που η ειδικότητα του είναι να μετατρέπει χημικά σήματα σε ηλεκτρικά και αυτά με τη σειρά τους σε χημικά. Όταν ο εγκέφαλος εκτεθεί σε ένα νέο συμβάν (την εικόνα ενός προσώπου, τον ήχο ενός γέλιου) με κάποιο τρόπο ενεργοποιείται μια μοναδική διάταξη νευρώνων. Μέσα στο απέραντο δίκτυο των εγκεφαλικών κυττάρων «ανάβει» ένας συγκεκριμένος αστερισμός.

Δημιουργείται ένα νέο κύκλωμα που λειτουργεί ως σύμβολο, ως αναπαράσταση κάποιου πράγματος που υπάρχει στον εξωτερικό κόσμο. Η αναγνώριση-ανάμνηση πρέπει να συμβαίνει όταν κάποια αντίληψη ανακαλεί μια νευρωνική διάταξη παρόμοια με αυτή που υπάρχει αποθηκευμένη. Ο εγκέφαλος θα αντιληφθεί την ομοιότητα και εμείς θα αισθανθούμε το ευχάριστο σοκ της αναγνώρισης. Αυτές οι διατάξεις πρέπει να είναι κυκλώματα εύπλαστα και διαρκώς μεταβαλλόμενα.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Με την απόκτηση νέων γνώσεων τα παλιά κυκλώματα διαλύονται και σχηματίζονται νέες συνδέσεις, συγκροτώντας και επανασυγκροτώντας ακατάπαυστα τις δικές μας αναπαραστάσεις του κόσμου.



Σχήμα2

Ο αγώνας για την κατανόηση του εγκεφάλου έχει γίνει ευκολότερος χάρη στην εισαγωγή της ιδέας των νευρώνων ως τα δομικά συστατικά του εγκεφάλου. Τυπικά, οι νευρώνες είναι πέντε έως έξι τάξεις μεγέθους αργότεροι από τις λογικές πύλες τεχνολογίας πυριτίου. Σ' ένα ολοκληρωμένο κύκλωμα τα συμβάντα λαμβάνουν χώρα στην κλίμακα των νανοδευτερολέπτων, ενώ στο ανθρώπινο νευρικό σύστημα στην κλίμακα των χιλιοστών του δευτερολέπτου. Ωστόσο ο «αργός» ρυθμός λειτουργίας ενός νευρώνα αντισταθμίζεται με την ύπαρξη ενός τεράστιου πλήθους νευρώνων μ' ένα εξίσου τεράστιο πλήθος διασυνδέσεων μεταξύ τους.

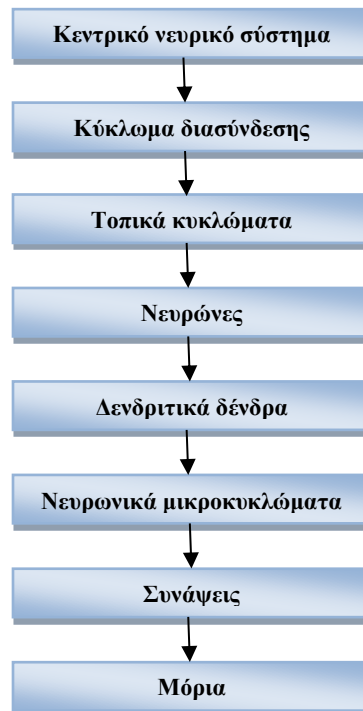
Οι *συνάψεις*, ή *νευρικές απολίξεις*, είναι οι στοιχειώδεις δομικές και λειτουργικές μονάδες που παίζουν μεσολαβητικό ρόλο κατά τις αλληλεπιδράσεις μεταξύ των νευρώνων. Το πιο κοινό είδος σύναψης είναι η χημική σύναψη.

Μια εξαιρετικά ενδιαφέρουσα ιδιότητα του εγκεφάλου είναι η *πλαστικότητα* η οποία επιτρέπει στο νευρικό σύστημα να προσαρμόζεται στο περιβάλλον του. Η πλαστικότητα μπορεί να αποδοθεί σε δύο μηχανισμούς: τη δημιουργία νέων συναπτικών συνδέσεων μεταξύ νευρώνων και την τροποποίηση των υφιστάμενων συνάψεων. Οι άξονες και οι δενδρίτες είναι δύο είδη μορφολογικά διαφορετικών νηματίων των κυττάρων: ένας άξονας έχει πιο ομαλή επιφάνεια, λιγότερους κλάδους και μεγαλύτερο μήκος, ενώ ο δενδρίτης έχει περισσότερους κλάδους και ακαθόριστη επιφάνεια.

(http://www.foundalis.com/dep/cog/N4_gr.htm)

Στην πλειονότητα τους οι νευρώνες κωδικοποιούν τις εξόδους τους σαν μια σειρά παλμών τάσης σύντομης διάρκειας. Οι παλμοί ξεκινούν από το κυτταρικό σώμα των νευρώνων και κατόπιν διαδίδονται, μέσω νευρώνων, με σταθερή ταχύτητα και πλάτος σήματος. Στο σχήμα3 παρουσιάζεται μια ιεραρχία των επιπέδων οργάνωσης του εγκεφάλου. Οι συνάψεις αντιπροσωπεύουν το πλέον θεμελιώδες επίπεδο και βασίζονται σε συγκεκριμένα μόρια και ιόντα για την δράση τους. Στην συνέχεια έχουμε τα νευρωνικά «μικροκύκλωματα», δενδριτικά δέντρα και κατόπιν νευρώνες. Ένα νευρωνικό μικροκύκλωμα αναφέρεται σε μια ομάδα συνάψεων οργανωμένων σε κατάλληλα μοτίβα διασυνδέσεων για την παραγωγή μιας ορισμένης λειτουργίας. Στο επόμενο επίπεδο πολυπλοκότητας έχουμε τοπικά κυκλώματα αποτελούμενα από νευρώνες με όμοιες ή διαφορετικές ιδιότητες: αυτές οι ομάδες νευρώνων εκτελούν λειτουργίες που είναι χαρακτηριστικές για μια συγκεκριμένη περιοχή του εγκεφάλου.

Ακολουθούνται από διαπεριφεριακά κυκλώματα που εκτείνονται σε περισσότερες της μιας περιοχές και αποτελούνται από «διαδρομές», στήλες και τοπογραφικούς χάρτες που εμπλέκουν πολλαπλές περιοχές από διαφορετικά μέρη του εγκεφάλου. (Fontana 1995)



Σχήμα3. Επίπεδα οργάνωσης εγκεφάλου

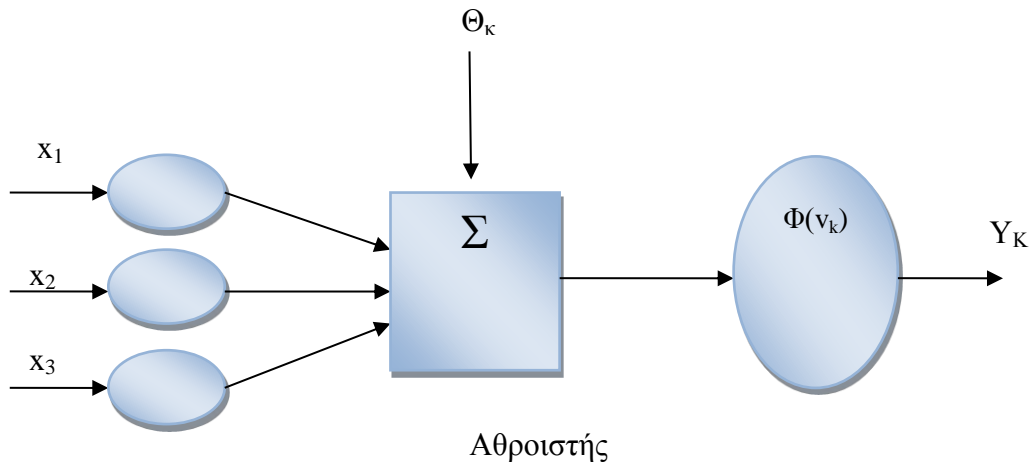
1.6 Περιγραφή ενός νευρώνα

Τα βασικά χαρακτηριστικά ενός νευρώνα είναι τα εξής:

i) **Τα συναπτικά βάρη (*Synaptic Weights*)**. Αν η είσοδος του νευρώνα k στη σύναψη j είναι το σήμα x , τότε αυτό πολλαπλασιάζεται με το συναπτικό βάρος W_{kj} , όπου ο πρώτος δείκτης αναφέρεται στο νευρώνα και ο δεύτερος στη σύναψη που δέχεται στην είσοδό της το σήμα W_{kj} . Ο αθροιστής, ο οποίος στην έξοδό του δίνει το άθροισμα των σταθμισμένων εισόδων.

ii) **Η συνάρτηση ενεργοποίησης (*Activation Function*)**. Από αυτή περνά η έξοδος του αθροιστή και δίνει αποτέλεσμα στο διάστημα $[0, 1]$ ή $[-1, 1]$, ανάλογα με τον τύπο της συνάρτησης που επιλέχθηκε.

iii) **Το κατώφλι θ_k** . Πρόκειται για δευτερεύουσα παράμετρο του συστήματος, η οποία συνήθως επιλέγεται με στόχο την καλύτερη ευελιξία του.



Σχήμα 4. Μοντέλο μη γραμμικού νευρώνα

Στο σχήμα 4 δίνεται το μοντέλο ενός νευρώνα με κατώφλι θ_k και είσοδο το διάνυσμα

$$P = \begin{cases} x_1 \\ x_2 \\ \vdots \\ x_N \end{cases} \quad \text{και βάρη } W = (w_{11}, w_{12}, \dots, w_{1N}) \quad 1.1)$$

Έτσι ισχύει $u_k = \sum_{j=1}^N w_{kj} x_j$, όπου προκειμένου $k=1$ η έξοδος του νευρώνα είναι:

$$y_k = \varphi(u_k - \theta_k) \quad 1.2)$$

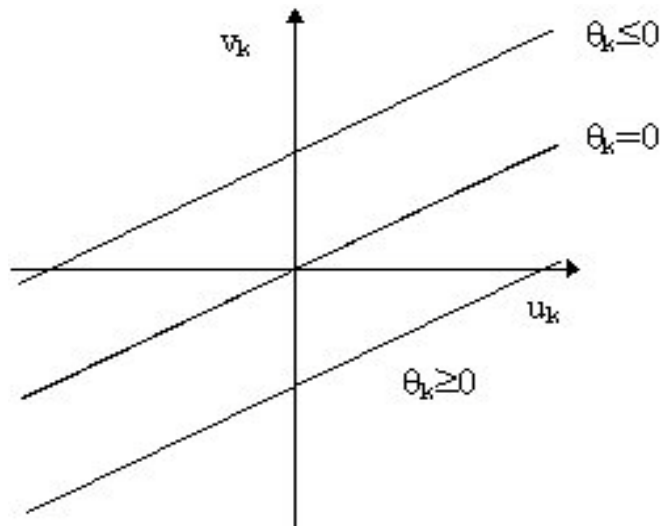
όπου, τα σήματα εισόδου και w_1, w_2, \dots, w_N , τα συναπτικά βάρη του νευρώνα k , θ_k το κατώφλι του, και $\varphi(\cdot)$ η συνάρτηση ενεργοποίησής του.

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

$$V_k = \sum_{j=0}^N w_{kj} x_j \quad 1.3)$$

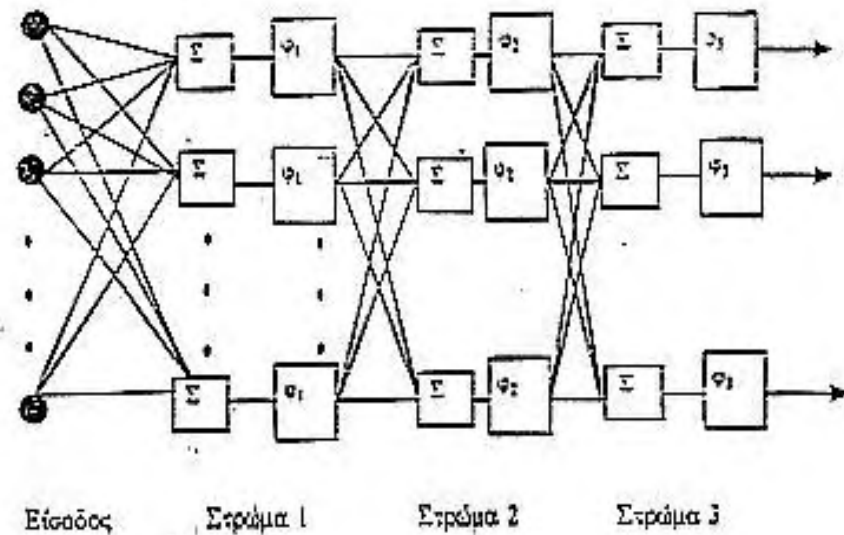
ενώ η έξοδος του νευρώνα είναι: $y_k = \varphi(v_k)$. 1.4)

Στο σχήμα 5 που ακολουθεί φαίνεται και ο ρόλος που διαδραματίζει το κατώφλι θ_k , το οποίο τελικά ελαττώνει την είσοδο της συνάρτησης ενεργοποίησης όταν το σήμα είναι θετικό και την αυξάνει όταν είναι αρνητικό.



Σχήμα 5. Επίδραση του κατωφλιού θ_k στην είσοδο της συνάρτησης εμεργοποίησης

Τα σύγχρονα νευρωνικά δίκτυα αποτελούνται από πολλούς απλούς νευρώνες, όπως αυτόν που περιγράφηκε παραπάνω, οι οποίοι συνθέτουν αρχικά ένα στρώμα και στη συνέχεια ένα σύστημα πολλαπλών στρωμάτων. (1982: ο Hopfield)



Σχήμα 6. Νευρωνικό δίκτυο τριών στρωμάτων

<http://eprints.pascal-network.org/archive/00004161/01/ShalevThesis07.pdf>

(Saad, 1998)

1.7 Παρουσία γνώσης – πληροφορίας στην είσοδο τεχνητού νευρωνικού δικτύου

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

Η αποθηκευμένη πληροφορία που χρησιμοποιείται από τεχνητές ή φυσικές μορφές νοημοσύνης με στόχο την πρόβλεψη και, γενικότερα, την κατάλληλη απόκρισή τους στο περιβάλλον.

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

i) Πληροφορία, η οποία έχει σχέση με το περιβάλλον και τις βασικές ιδιότητες που το χαρακτηρίζουν, και

ii) Λαμβανόμενες μετρήσεις, οι οποίες περιέχουν θόρυβο εξαιτίας ανθρωπίνων σφαλμάτων ή ατελειών των οργάνων μέτρησης και αποτελούν το σύνολο των διανυσμάτων της εκπαίδευσης (Training set).

Η διαδικασία που ακολουθείται είναι συνοπτικά η εξής:

Δίνεται το σήμα εισόδου και η επιθυμητή έξοδος. Στη συνέχεια, αφού ολοκληρωθεί η διαδικασία εκμάθησης δοκιμάζεται η απόδοση του δικτύου σε σύνολο δεδομένων που δεν ανήκουν στο σύνολο εκπαίδευσης. Έτσι δοκιμάζεται η ικανότητα του δικτύου στην εκμάθηση, καθώς με αυτόν τον τρόπο φαίνεται αν αυτή έχει ολοκληρωθεί ή απλά το δίκτυο έχει απομνημονεύσει το σύνολο εκπαίδευσης, με αποτέλεσμα την καλή συμπεριφορά του μόνο σε αυτό. Αυτή είναι η φάση της γενίκευσης (Generalization). Singapore Prentice Hall, 1995

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

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

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

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

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

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

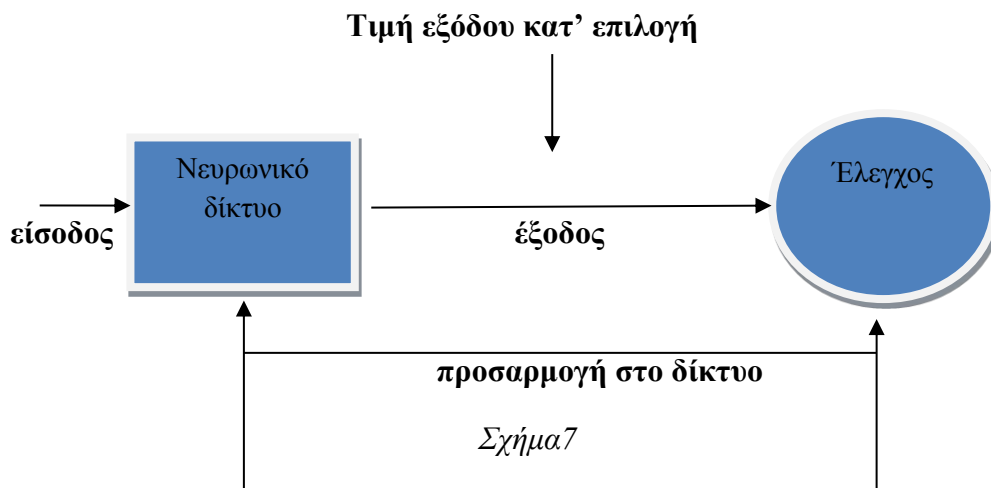
(I.Tsoulos, *Neural network construction and training using grammatical evolution*.2008.)

1.8 Εκπαίδευση τεχνητών νευρωνικών δικτύων

Το πιο σημαντικό χαρακτηριστικό από όλα, που αφορά τα ΤΝΔ (τεχνητά νευρωνικά δίκτυα) είναι η ικανότητα τους να μαθαίνουν. Ωστόσο, παρά τους πολλούς παραλληλισμούς με την ανθρώπινη κατανόηση, η εκπαίδευση ενός ΤΝΔ δεν είναι μια εύκολη δουλειά . Ο σκοπός της εκπαίδευσης ενός ΤΝΔ είναι η απόκτηση ικανότητας ώστε να δίνει το επιθυμητό σετ εξόδων μετά από την εφαρμογή κάποιου σετ εισόδων. Από το σύνολο των δεδομένων επιλέγεται τυχαία ένα δείγμα (συνήθως γύρω στο 80% των συνολικών δεδομένων). Το δείγμα αυτό θα χρησιμοποιηθεί αρχικά για να εκπαιδευθεί το δίκτυο. Από την στιγμή που ξεκινά η διαδικασία TRAIN το δίκτυο μορφοποιεί μια σειρά από πολύπλοκες μαθηματικές εκφράσεις, οι οποίες ορίζονται ανάλογα με το πρόβλημα, προσπαθώντας να βρει μαθηματικές σχέσεις ανάμεσα στα δεδομένα. Οι σχέσεις χρησιμοποιούνται για να αποδοθούν βάρη στα στοιχεία εισόδου, προσπαθώντας να εκτιμήσει ποια στοιχεία είναι αυτά που επηρεάζουν πιο πολύ το αποτέλεσμα και τα αξιολογεί ανάλογα με την βαρύτητα τους αποδίδοντάς τους το βάρος τους.

Ένα νευρωνικό δίκτυο μπορεί να εκπαιδευτεί ώστε να επιτελεί μια συγκεκριμένη λειτουργία . Τούτο επιτυγχάνεται με κατάλληλη προσαρμογή των συναπτικών βαρών. Η προσαρμογή αυτή των συναπτικών βαρών που θα επιτρέψει στο δίκτυο να επιτελέσει μια συγκεκριμένη λειτουργία ονομάζεται εκπαίδευση του δικτύου (training). Τα νευρωνικά δίκτυα εκπαιδεύονται–προσαρμόζονται κατά τρόπο ώστε μια συγκεκριμένη είσοδος (δηλαδή ένα συγκεκριμένο διάνυσμα εισόδου) να δίνει μια συγκεκριμένη-επιθυμητή τιμή στην έξοδο (target output).

(*Τεχνητή Νοημοσύνη - Β' Έκδοση* Ι. Βλαχάβας, Π. Κεφαλάς, Ν. Βασιλειάδης, Φ. Κόκκορας, Η. Σακελλαρίου)



Αν οι τιμές αυτές διαφέρουν, τότε το δίκτυο προσαρμόζεται και η διαδικασία επαναλαμβάνεται έως ότου η τιμή εξόδου που δίνει το δίκτυο ταυτιστεί με την επιθυμητή τιμή. Ο τρόπος αυτός εκπαίδευσης ονομάζεται επιβλεπόμενη μάθηση (*Supervised learning*). Κάθε τέτοιο σετ από εισόδους ή εξόδους αναφέρεται σε μας σαν vector (διάνυσμα). Η εκπαίδευση πετυχαίνεται με συνεχή εφαρμογή από διανύσματα εισόδου καθώς τα βάρη του δικτύου προσαρμόζονται με βάση μια προκαθορισμένη διαδικασία. Κατά την διάρκεια της εκπαίδευσης τα βάρη του δικτύου σταδιακά συγκλίνουν σε τιμές έτσι ώστε το κάθε διάνυσμα εισόδου να δίνει το επιθυμητό διάνυσμα εξόδου. (Simon Haykin 2009 νευρωνικά δίκτυα).

Όπως προαναφέραμε, τα ΤΝΔ διαχωρίζονται σύμφωνα με το κριτήριο του τρόπου εκπαίδευσής τους σε: *Supervised* και *unsupervised*.

1.8.1 Εκπαίδευση με επίβλεψη

Η εποπτευόμενη εκπαίδευση απαιτεί το ζευγάρι του κάθε διανύσματος εισόδου με το διάνυσμα στόχο που αντιπροσωπεύει την επιθυμητή έξοδο, και που μαζί ονομάζονται training pair (ζευγάρι εκπαίδευσης). Για να εκπαιδευτεί ένα δίκτυο χρειάζεται κάποιος αριθμός τέτοιων ζευγαριών. Ένα διάνυσμα εισόδου εφαρμόζεται, η έξοδος του δικτύου υπολογίζεται και συγκρίνεται με το αντίστοιχο διάνυσμα στόχο και η διαφορά (λάθος) τροφοδοτείται πίσω διαμέσου του δικτύου. Τα βάρη αλλάζουν σύμφωνα με ένα αλγόριθμο που τείνει να ελαττώσει το λάθος. Τα διανύσματα εισόδου εφαρμόζονται συνεχώς, τα λάθη υπολογίζονται και τα βάρη προσαρμόζονται για το κάθε διάνυσμα μέχρι το λάθος ολόκληρου του σετ εκπαίδευσης να είναι σε ένα αποδεκτά χαμηλό επίπεδο. (] A.G. Barto, R.S. Sutton, and C.W. Anderson, "Neuronlike adaptive elements that can solve difficult learning control problems", *IEEE Transactions on Systems, Man, and Cybernetics*, volume 13, 834–846, 1983.)

1.8.2 Μη εποπτευμένη εκπαίδευση

Σε αντίθεση με την εποπτευόμενη εκπαίδευση, εδώ δεν απαιτούνται διανύσματα στόχοι για την έξοδο και για αυτό δεν γίνεται σύγκριση με κάποια προκαθορισμένη ιδανική απόκριση. Το σετ εκπαίδευσης αποτελείται μόνο από διανύσματα εισόδου. Ο αλγόριθμος εκπαίδευσης αλλάζει τα βάρη του δικτύου για να παράγονται διανύσματα εξόδου που να είναι συνεπή, δηλαδή είτε η εφαρμογή ενός από τα διανύσματα εκπαίδευσης είτε η εφαρμογή ενός διανύσματος που είναι αρκετά όμοιο με αυτόν θα παράγει το ίδιο πρότυπο από εξόδους. Η διαδικασία εκπαίδευσης βγάζει της στατιστικές ιδιότητες του σετ εκπαίδευσης και ομαδοποιεί τα παρόμοια διανύσματα σε τάξεις. Εφαρμόζοντας ένα διάνυσμα από δοσμένη τάξη στη είσοδο, θα παράγει συγκεκριμένο διάνυσμα εξόδου, αλλά δεν υπάρχει κανένας τρόπος ώστε να καθοριστεί πριν από την εκπαίδευση ένα συγκεκριμένο πρότυπο εξόδου που θα παραχθεί από δοσμένη τάξη διανύσματος εισόδου. Για αυτό οι έξοδοι ενός τέτοιου δικτύου πρέπει, γενικά, να μετατραπούν σε μια κατανοητή μορφή που είναι επακόλουθο της διαδικασίας εκπαίδευσης. Αυτό δεν είναι κάποιο σοβαρό πρόβλημα. Είναι συνήθως απλό το θέμα της αναγνώρισης της σχέσης εισόδου-εξόδου, που έχει εγκαθιδρυθεί από το δίκτυο. (*R. Bellman, Dynamic Programming, Princeton University Press, Princeton, NJ, 1957.*)

Ένας λοιπόν αλγόριθμος εκπαίδευσης είναι και ο παρακάτω: τα βάρη αυξάνονται όταν και οι δυο νευρώνες πηγή - αποδέκτης ενεργοποιούνται. Με αυτό τον τρόπο οι συχνά χρησιμοποιούμενοι διάδρομοι στο δίκτυο είναι ενισχυμένοι, και έτσι εξηγείται το φαινόμενο της συνήθειας και μάθησης διαμέσου της επανάληψης (*D.O. Hebb 1962*).

Ένα ΤΝΔ που χρησιμοποιεί αυτόν τον τρόπο μάθησης, θα αυξήσει τα βάρη του δικτύου σύμφωνα με τα παράγωγα των ανώτερων επίπεδων των νευρώνων πηγής και αποδέκτη. Δηλαδή:

$$w_{ij}(n+1) = w_{ij}(n) + \alpha \cdot OUT_i \cdot OUT_j$$

Όπου:

$W_{ij}(n)$: Η τιμή του βάρους από τον νευρώνα i στον νευρώνα j πριν από την προσαρμογή.

$W_{ij}(n+1)$: Η τιμή του βάρους από τον νευρώνα i στον νευρώνα j μετά την προσαρμογή.

α : Ο συντελεστής των ορίων μάθησης.

OUT_i : Η έξοδος από τον νευρώνα i και η είσοδος στον νευρώνα j .

OUT_j : Η έξοδος από τον νευρώνα j .

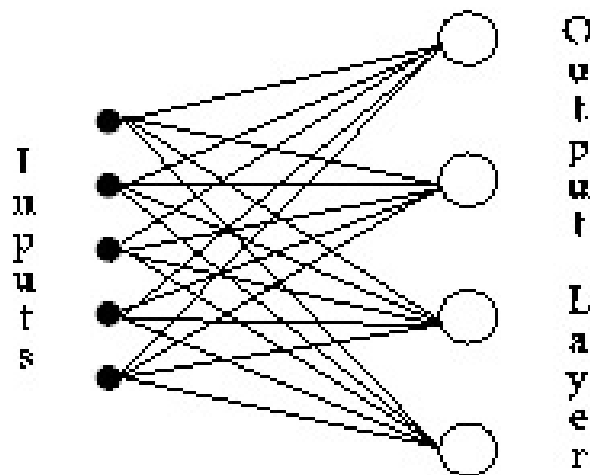
1.9 Νευρωνικά δίκτυα Perceptron

1.9.1 Εισαγωγή

Το perceptron «αισθητήρας» καταλαμβάνει μια ειδική θέση στην ιστορική εξέλιξη των νευρωνικών δικτύων: ήταν το πρώτο νευρωνικό δίκτυο που μπορούσε να περιγραφεί αλγοριθμικά. Η επινοήση του από τον ψυχολόγο Rosenblatt, ενέπνευσε τους επιστήμονες, ωθώντας τους να αφιερώσουν τις ερευνητικές τους προσπάθειες σε διαφορετικές απόψεις των νευρωνικών δικτύων στις δεκαετίες του 60' και του 70'. Το πιο αξιοσημείωτο, όμως, είναι το γεγονός ότι το perceptron παραμένει τόσο χρήσιμο όσο και ενδιαφέρον όσο ήταν το 1958 όταν πρωτοδημοσιεύτηκε η σχετική εργασία του Rosenblatt.

1.9.2 Ορισμός

Ο αισθητήρας (*perceptron*) είναι ένα δίκτυο με δύο επίπεδα. Το πρώτο επίπεδο απαρτίζεται από τις εισόδους του δικτύου, δεν έχει νευρώνες και επομένως δεν γίνεται καμία επεξεργασία πληροφορίας σε αυτό. Το δεύτερο επίπεδο αποτελείται από νευρώνες τύπου McCulloch-Pitts και είναι το επίπεδο εξόδου του δικτύου. Ένα παράδειγμα αισθητήρα, με έξι εισόδους και τέσσερις νευρώνες στο επίπεδο εξόδου, φαίνεται στο Σχήμα 8 που ακολουθεί.



Σχήμα8. Παράδειγμα αισθητήρα perceptron με 6 εισόδους και 4 νευρώνες εξόδου.

Ο στόχος του απλού αισθητήρα είναι να μάθει να λύνει προβλήματα ταξινόμησης, να αντιστοιχεί δηλαδή κάθε σετ εισόδων που δέχεται στη σωστή κλάση. Ο αισθητήρας μπορεί να λύσει πολλά τέτοια προβλήματα με επιτυχία. Ένα από τα πλεονεκτήματα του δικτύου αυτού είναι ότι υπάρχει ένας σαφής αλγόριθμος βάσει

του οποίου μπορεί να εκπαιδευτεί, ώστε να δίνει σωστά αποτελέσματα. Ο αλγόριθμος αυτός, για την πιο απλή περίπτωση για την οποία τα σετ των εισόδων προέρχονται από δύο κλάσεις, έχει ως εξής:

$$W_j(n+1) = \begin{cases} W_j(n) & \text{όταν η } y_i \text{ είναι σωστή} \\ W_j(n) - \eta(n) x_j(n) & \text{όταν } y_j = 1, \text{ ενώ θα έπρεπε να είναι μηδέν} \\ W_j(n) + \eta(n) x_j(n) & \text{όταν } y_j = 0, \text{ ενώ θα έπρεπε να είναι ένα} \end{cases} \quad (1.6)$$

όπου $X_j(n)$ το διάνυσμα εισόδου του νευρώνα j , $Y_j(n)$ το διάνυσμα εξόδου και $W(n)$ το διάνυσμα των βαρών στο βήμα n του αλγορίθμου, $W_j(n+1)$ το διάνυσμα των βαρών στο βήμα $n+1$ και η θετική σταθερά που ονομάζεται *παράμετρος ρυθμού εκπαίδευσης (learning-rate parameter)*. (Roja, Raul. << Weighted Network – The Perceptron. >>2010. <http://page.mi.fuberlin.de/rojas/neural/neural/chapter/k3.pdf>)

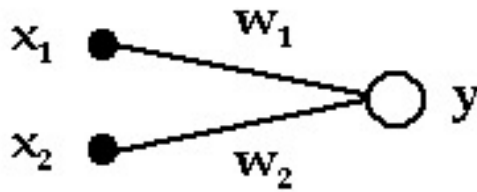
Το ερώτημα που προκύπτει άμεσα είναι κατά πόσο ο αλγόριθμος αυτός συγκλίνει σε μία σωστή λύση του προβλήματος. Όπως ο ίδιος ο Rosenblatt απέδειξε, αν οι κλάσεις του προβλήματος είναι διαχωρίσιμες από τον αισθητήρα, τότε ο παραπάνω αλγόριθμος συγκλίνει και δίνει σωστά αποτελέσματα και μάλιστα σε πεπερασμένο αριθμό βημάτων. Το θεώρημα αυτό ονομάζεται *θεώρημα σύγκλισης του αισθητήρα (perceptron convergence theorem)*. Η ισχύς του θεωρήματος αυτού αποτελεί ένα ακόμα σημαντικό πλεονέκτημα του αισθητήρα. (Robert J. Schalkoff, Artificial neural networks, New York McGraw-Hill, 1997)

Αργότερα όμως οι Minsky και Papert έδειξαν ότι τα προβλήματα ταξινόμησης που μπορεί να λύσει ο αισθητήρας είναι εκείνα τα οποία είναι *γραμμικά διαχωρίσιμα* και μόνο. Το συμπέρασμα αυτό γίνεται εύκολα κατανοητό με ένα απλό παράδειγμα. Έστω λοιπόν ότι ο στόχος του αισθητήρα είναι να δίνει σωστά αποτελέσματα σύμφωνα με τη λογική πράξη XOR, η οποία φαίνεται παρακάτω στον Πίνακα 1.

X_1	X_2	$X_1 \text{ XOR } X_2$
0	0	0
0	1	1
1	0	1
1	1	0

Πίνακας 1 η πράξη XOR

Ο κατάλληλος αισθητήρας για το πρόβλημα αυτό είναι εκείνος με δύο εισόδους και έναν νευρώνα εξόδου, όπως φαίνεται στο Σχήμα 9 που ακολουθεί.



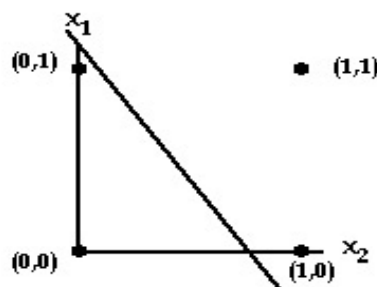
Σχήμα9. Ο αισθητήρας για την XOR

Η έξοδος του αισθητήρα, όπως είδαμε και παραπάνω, θα δίνεται από τη σχέση:

$$y = \begin{cases} 0 & \text{αν } w_1 x_1 + w_2 x_2 \leq \theta \\ 1 & \text{Αλλιώς} \end{cases} \quad (1.7)$$

όπου w_1 και w_2 τα συναπτικά βάρη και θ το κατώφλι. Το ζητούμενο είναι να βρεθούν οι τιμές για τα βάρη, τέτοιες ώστε το αποτέλεσμα των εισόδων να συνάγει με τη λογική πράξη XOR.

Τα τέσσερα σεντ εισόδων του αισθητήρα αντιστοιχούν σε τέσσερα σημεία στο επίπεδο. Σύμφωνα με τον Πίνακα 1, τα σημεία $(0,0)$ και $(1,1)$ ανήκουν στην κλάση 0, ενώ τα $(0,1)$ και $(1,0)$ στην κλάση 1. Η εξίσωση 1.7 είναι μία ευθεία που χωρίζει το επίπεδο σε δύο ημιεπίπεδα. Αρκεί λοιπόν να βρεθεί ένα ζεύγος τιμών για τα και τέτοιες ώστε να χωρίζουν τις δύο αυτές κλάσεις. Όπως φαίνεται όμως στο Σχήμα 10 παρακάτω, αυτό δεν είναι εφικτό. Δεν υπάρχει καμία ευθεία τέτοια ώστε τα σημεία των δύο κλάσεων να ανήκουν σε διαφορετικά ημιεπίπεδα. Για να το πετύχουμε αυτό χρειαζόμαστε δύο ευθείες. Το πρόβλημα αυτό επομένως δεν είναι γραμμικά διαχωρίσιμο και άρα δεν είναι επιλύσιμο από τον αισθητήρα.



Σχήμα 10. Το πρόβλημα της XOR είναι μη γραμμικά διαχωρίσιμο

Η αδυναμία του αισθητήρα να επιλύσει το πρόβλημα της XOR, δεν είναι αμελητέα. Όπως επεσήμαναν οι Minsky και Papert, πολλά προβλήματα βασίζονται στην XOR. Η αποτυχία αυτή είχε σαν αποτέλεσμα να εγκαταλειφθεί η ιδέα των νευρωνικών δικτύων και να σταματήσει σχεδόν κάθε έρευνα πάνω στο αντικείμενο αυτό.

Προκύπτει επομένως το ερώτημα, κατά πόσο θα μπορούσε το αρχικό μοντέλο του αισθητήρα να τροποποιηθεί, ώστε να μπορεί να επιλύει και μη γραμμικά διαχωρίσιμα προβλήματα. Η απάντηση στο ερώτημα αυτό είναι καταφατική. Πράγματι, προσθέτοντας απλά ένα ή περισσότερα επίπεδα νευρώνων μεταξύ του επίπεδου εισόδου και αυτό της εξόδου, ο τροποποιημένος αισθητήρας που προκύπτει μπορεί πλέον να επιλύσει και μη γραμμικά διαχωριζόμενα προβλήματα. (1957: F. Rosenblatt (perceptron))

Κεφάλαιο 2

Εισαγωγή

Στο κεφάλαιο αυτό θα ασχοληθούμε με τον ταχύτερα εξελιγμένο τομέα της τεχνητής νοημοσύνης την μηχανική μάθηση. Θα παρουσιάσουμε τις βασικές έννοιες της μηχανικής μάθησης καθώς επίσης τις διαδικασίες, εργασίες μάθησης, τις οικογένειες αλγορίθμων μηχανικής μάθησης. Στη συνέχεια θα αναλύσουμε τις κύριες διαφορές της μάθησης με εκπαίδευση και χωρίς εκπαίδευση.

2.0 Μηχανική μάθηση

2.1 Βασικές έννοιες – ορισμοί

Μηχανική μάθηση καλούμε το πεδίο έρευνας που είναι αφιερωμένο στην μελέτη και κατανόηση της λειτουργίας των συστημάτων μάθησης. Η Μηχανική Μάθηση (*Machine Learning*) έχει ως αντικείμενο την κατασκευή προγραμμάτων-αλγορίθμων, ικανών να βελτιώνονται αυτόματα με την εμπειρία που αποκτούν κατά την εκτέλεση τους. Είναι ένα υψηλό και συνεχώς εξελισσόμενο διεπιστημονικό πεδίο που δανείζεται και αλληλεπιδρά με εφαρμογές και επιστήμες όπως η στατιστική, η μηχανική, η επιστήμη των υπολογιστών, η γνωσιακή επιστήμη περιλαμβάνοντας ως επί το πλείστον αλγόριθμους βελτιστοποίησης. Στόχος αυτού του πονήματος είναι η εισαγωγή του αναγνώστη στο εξαιρετικά ενδιαφέρον πεδίο της μηχανικής μάθησης καθώς επίσης και η παρουσίαση βασικών αλγορίθμων μάθησης.

Βασική αρχή λειτουργίας ενός αλγορίθμου μηχανικής μάθησης είναι η προσπάθεια εξαγωγής γενικευμένων κανόνων, ικανών να αντιμετωπίσουν το προς επίλυση πρόβλημα από ένα περιορισμένο σύνολο δεδομένων εκπαίδευσης, προσέγγιση δηλαδή της συνάρτησης (έννοιας) στόχου από το σύνολο των πιθανών λύσεων δηλαδή τις υποθέσεις. Όμως, η μόνη διαθέσιμη πληροφορία που υπάρχει είναι το πεπερασμένο δείγμα εκπαίδευσης. Συνεπώς, πρόκειται για μία διαδικασία *επαγωγικού συλλογισμού* (*inductive reasoning*), δηλαδή συμπερασμού μίας γενικότερης έννοιας από την ειδικότερη έννοια που αντιστοιχεί στο συγκεκριμένο δείγμα. Επομένως, το μόνο που είναι εγγυημένο είναι ότι η προσέγγιση της

συνάρτησης στόχου είναι ακριβής για τα δεδομένα εκπαίδευσης, ενώ για όλα τα άλλα στιγμιότυπα μπορούμε μόνο να το υποθέσουμε. Σε αυτό το ζήτημα αναφέρεται η θεμελιώδης παραδοχή της επαγωγικής μάθησης: Όποιος ασχοληθεί με το πεδίο αυτό μπορεί να επωφεληθεί από παραδείγματα, χρησιμοποιώντας τα σαν δεδομένα, για να συλλάβει χαρακτηριστικές λειτουργίες και στην συνέχεια να προβλέψει με σχετική ακρίβεια διάφορα μοντέλα. Τα δεδομένα μπορούν να ληφθούν από παραδείγματα που φανερώνουν τις συσχετίσεις μεταξύ των παρατηρήσιμων μεταβλητών. Το πιο σημαντικό στην μελέτη και έρευνα για την μηχανική μάθηση είναι τα συστήματα αυτοματοποιημένα να «μαθαίνουν» να αναγνωρίζουν πολύπλοκα πρότυπα και να λαμβάνουν έξυπνες αποφάσεις βασιζόμενες στα δεδομένα αυτά. Η δυσκολία σε όλη αυτήν την διαδικασία έγκειται στο γεγονός ότι το σύνολο όλων των δυνατών συμπεριφορών συμπεριλαμβανομένων όλων των δυνατών εισροών είναι τεράστιο για να καλυφθεί από το σύνολο των παρατηρούμενων παραδειγμάτων (Carbonell, 1987; Mitchell, 1997; Witten & Frank, 2000).

Με απλά λόγια το σύνολο των δεδομένων-παραδειγμάτων δεν φτάνει για να κατηγοριοποιήσει την εκάστοτε μοντελοποίηση. Σαν συνέπεια αυτού, κάθε νέα περίπτωση είναι ξεχωριστή και πρέπει να αντιμετωπίζεται διαφορετικά. Κάτι εξαιρετικά ενδιαφέρον, που δεν έχει αποδειχθεί αλλά λειτουργεί σε όλες τις περιπτώσεις είναι το γεγονός ότι οποιαδήποτε υπόθεση έχει βρεθεί να προσεγγίζει καλά την συνάρτηση στόχου σε ένα μεγάλο φάσμα παραδειγμάτων εκπαίδευσης, θα την προσεγγίζει καλά και σε άγνωστα στιγμιότυπα.

Σύμφωνα με τους Mendel και McClaren, με σημείο αναφοράς τα νευρωνικά δίκτυα:

Μάθηση είναι μια διαδικασία με την οποία προσαρμόζονται οι ελεύθερες παράμετροι ενός νευρωνικού δικτύου μέσω μιας συνεχούς διαδικασίας διέγερσης από το περιβάλλον στο οποίο βρίσκεται το δίκτυο. Το είδος της μάθησης καθορίζεται από τον τρόπο με τον οποίο πραγματοποιούνται οι αλλαγές παραμέτρων.

Κατά καιρούς, η μάθηση ορίστηκε ως δημιουργία υποκατάστατων ανακλαστικών (Pavlov), ως δοκιμή και πλάνη (Thorndike), ως επανάληψη μιας αντίδρασης μετά από θετική ενίσχυση (Skinner), ως ενόραση (Kohler), ως μίμηση προτύπου (Bandura), ως επεξεργασία των πληροφοριών (Neisser, Seymour, Gagné) και ως προσωπική ερμηνεία στις νεοαποκτηθείσες πληροφορίες (Maslow, Rogers)

2.2 Διαδικασίες μάθησης

Όπως οι άνθρωποι μαθαίνουν με ποικίλους τρόπους από το περιβάλλον τους έτσι και τα νευρωνικά δίκτυα προσαρμόζουν την λειτουργία τους και μέσω μιας, αρκετά πολύπολικης διαδικασίας μάθησης, επιτυγχάνεται η εκπαίδευση τους. Ο στόχος του τομέα της μηχανικής μάθησης είναι η δημιουργία των συστημάτων πληροφορικής που μαθαίνουν από την εμπειρία και που είναι ικανές να προσαρμοστούν στα περιβάλλοντα τους. Οι μαθησιακές τεχνικές και μέθοδοι που αναπτύχθηκαν από τους ερευνητές στον τομέα αυτό έχουν εφαρμοστεί με επιτυχία σε μια ποικιλία των μαθησιακών δραστηριοτήτων σε ένα ευρύ φάσμα τομέων, συμπεριλαμβανομένων, για παράδειγμα, την ταξινόμηση κειμένου, ανακάλυψη γονιδίων, οικονομικές προβλέψεις, πιστωτική κάρτα ανίχνευση της απάτης, συνεργατικό φιλτράρισμα, το σχεδιασμό της προσαρμοστικής πρακτόρων και άλλων

ιστοσελίδων. ils J. Nilsson, Kumagai Professor of Engineering (Emeritus) Stanford in 1958

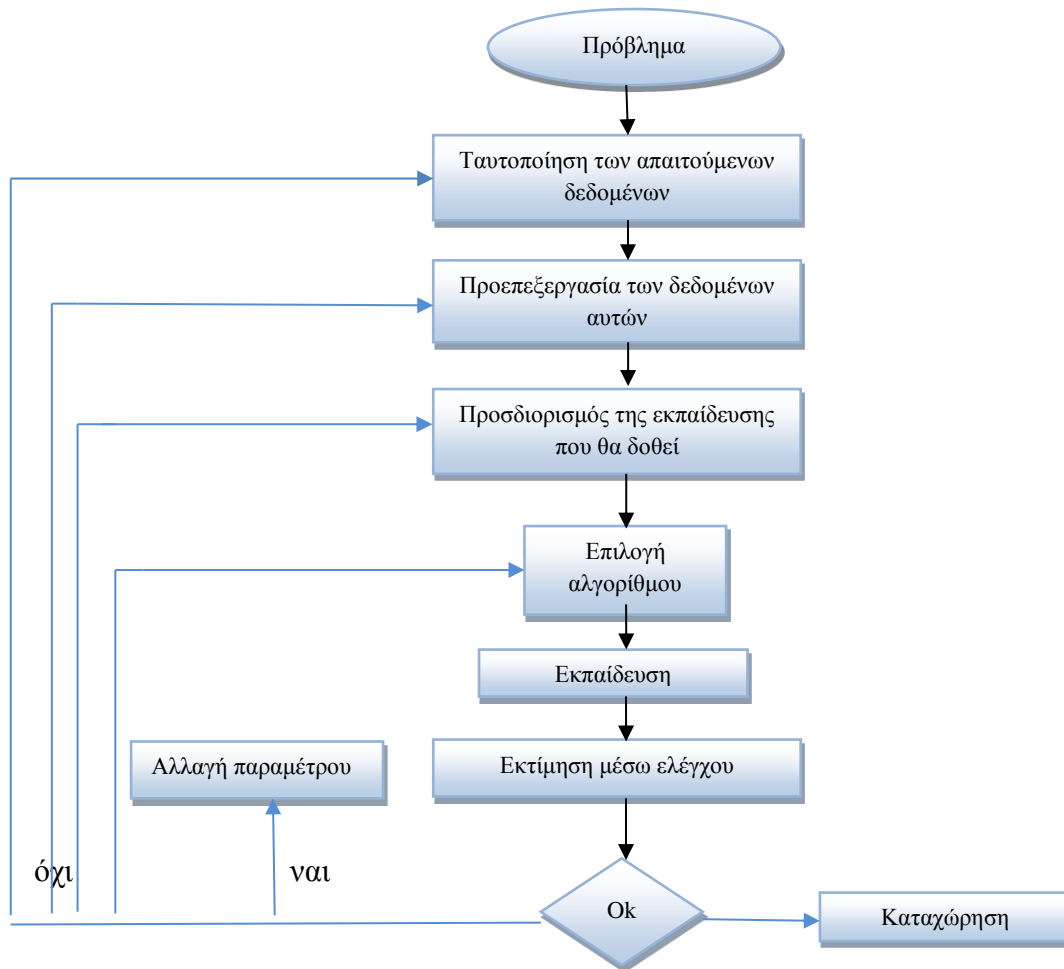
2.3 Μάθηση με εκπαιδευτή

Η διαδικασία της μάθησης υπό πλήρη επίβλεψη στοχεύει στη δημιουργία ενός μοντέλου, ικανό να προβλέπει κάποιες μη παρατηρούμενες ιδιότητες σε άγνωστα αντικείμενα, χρησιμοποιώντας στο σώμα δεδομένων εκπαίδευσης παραδείγματα που έχουν αυτές τις ιδιότητες γνωστές. Ως παραδείγματα αυτής της κατηγορίας μάθησης θα μπορούσαμε να επικαλεστούμε την εκτίμηση του βάρους ενός ανθρώπου δεδομένου του ύψους και άλλων χαρακτηριστικών του, ή του θέματος ενός κειμένου βάσει των συμβολοσειρών (λέξεων, αριθμών και σημείων στίξης) που το απαρτίζουν. Με εννοιολογικούς όρους, μπορούμε να θεωρήσουμε ότι ο εκπαιδευτής έχει γνώση του περιβάλλοντος, και αυτή η γνώση αντιπροσωπεύεται από ένα σύνολο παραδειγμάτων εισόδου-εξόδου. Παρολ' αυτά, το περιβάλλον είναι άγνωστο στο νευρωνικό δίκτυο. Ας υποθέσουμε ότι ο εκπαιδευτής και το νευρωνικό δίκτυο εκτίθενται σε ένα διάνυμα εκπαίδευσης (ένα παράδειγμα) από το περιβάλλον. Χάρη στην εγγενή του γνώση, ο εκπαιδευτής είναι σε θέση να παρέχει στο νευρωνικό δίκτυο μια επιθυμητή απόκριση για το συγκεκριμένο διάνυμα εκπαίδευσης., (Academic Press, 1999)

Η επιθυμητή απόκριση αντιπροσωπεύει τη «βέλτιστη» ενέργεια που πρέπει να εκτελείται από το νευρωνικό δίκτυο. Οι παράμετροι του δικτύου προσαρμόζονται υπό την συνδυασμένη επιρροή του διανύσματος εκπαίδευσης και του σήματος σφάλματος. *Το σήμα σφάλματος ορίζεται ως η διαφορά μεταξύ επιθυμητής απόκρισης και πραγματικής απόκρισης του δικτύου.* Αυτή η προσαρμογή εκτελείται με επαναληπτικό τρόπο, βήμα προς βήμα, με στόχο να φέρει τελικά το νευρωνικό δίκτυο σε μια κατάσταση όπου θα προσομοιώνει τη συμπεριφορά του εκπαιδευτή. Με αυτόν τον τρόπο, η γνώση του περιβάλλοντος που είναι διαθέσιμη στον εκπαιδευτή μεταφέρεται στο νευρωνικό δίκτυο μέσω εκπαίδευσης και αποθηκεύεται με την μορφή «σταθερών» συναπτικών βαρών, τα οποία αντιπροσωπεύουν την *μακροπρόθεσμη μνήμη*. Όταν επιτευχθεί αυτή η συνθήκη, μπορούμε να απαλλαγούμε από τον εκπαιδευτή και να αφήσουμε το νευρωνικό δίκτυο να αντιμετωπίσει το περιβάλλον εντελώς μόνος του χρησιμοποιώντας ένα σύστημα ανάδρασης όπως φαίνεται και στο σχήμα 1.

Συμπερασματικά, θα μπορούσε να δοθεί ο ακόλουθος ορισμός της μάθησης με εκπαιδευτή ή επιβλεπόμενης μάθησης, ως εξής:

Η μάθηση με εκπαίδευση είναι η έρευνα για αλγόριθμους που πηγάζουν από εξωτερικούς παράγοντες με σκοπό να παράγουν γενικές υποθέσεις, που στη συνέχεια χρησιμοποιούνται για μελλοντικές περιπτώσεις. Με άλλα λόγια ο στόχος της επιβλεπόμενης μάθησης είναι να οικοδομήσει ένα περιεκτικό υπόδειγμα της διανομής της κλάσης σε ετικέτες με σκοπό να χρησιμοποιηθούν ως χαρακτηριστικά μελλοντικής πρόβλεψης. Η τελική κλάση ταξινόμησης χρησιμοποιείται για να προσδιορίσει τον τρόπο επίλυσης των εκατοσπε προβλημάτων όπου τα χαρακτηριστικά πρόβλεψης είναι γνωστά, αλλά η τιμή και ο ακριβής προσδιορισμός της κλάσης είναι άγνωστος.



Σχήμα 1. Αλγόριθμος περιγραφής της διαδικασίας επίλυσης προβλήματος μέσω μηχανικής μάθησης

(Witten et al., 1994).

2.4 Μάθηση χωρίς εκπαιδευτή

Μια διαφορετική από την προηγούμενη προσέγγιση είναι η μάθηση χωρίς επίβλεψη, στην οποία τα παραδείγματα του σώματος δεδομένων εκπαίδευσης δεν έχουν γνωστή την τιμή της ιδιότητας που θέλουμε να προβλέψουμε, οπότε ο «μαθητής» αφήνεται ελεύθερος. Από τις σημαντικότερες υποπεριοχές της μάθησης χωρίς επίβλεψη, ξεχωρίζουν η *ομαδοποίηση (clustering)*, και η *εκτίμηση παραμέτρων (parameter estimation)*. Η ομαδοποίηση συνιστάται στην ανακάλυψη ομάδων από αντικείμενα που παρουσιάζουν μεταξύ τους κοινά χαρακτηριστικά. Οι κατηγορίες στην περίπτωση αυτή δεν είναι γνωστές εκ των προτέρων (δεν δίνονται δηλαδή από τον χρήστη) αλλά προκύπτουν δυναμικά κατά την εκτέλεση του αλγορίθμου ομαδοποίησης. Στην εκτίμηση παραμέτρων κατασκευάζουμε ένα στατιστικό μοντέλο του κόσμου του προς αντιμετώπιση προβλήματος, που διαθέτει ένα σύνολο παραμέτρων, τις τιμές των οποίων επιθυμούμε να προσδιορίσουμε. Για το σκοπό αυτό χρησιμοποιούμε έναν αλγόριθμο μάθησης που εκπαιδεύεται σε

αντιπροσωπευτικά δεδομένα του κόσμου μας, προκειμένου να προσεγγίσει τις ζητούμενες παραμέτρους.

Θεωρώντας μια μηχανή (ή ένα ζωντανό οργανισμό) η οποία λαμβάνει μια σειρά από εισόδους $x_1, x_2, x_3, \dots, x_t$. Η είσοδος αυτή, που όπως ειπώθηκε και προηγουμένως λέγεται και δεδομένο, θα μπορούσε να αντιστοιχιστεί σε μια εικόνα στον αμφιβληστροειδή, ένα pixel σε μια φωτογραφική μηχανή ή σε ένα ηχητικό μετατροπέα. Θα μπορούσε επίσης να αντιστοιχιστεί και σε λιγότερα παρατηρήσιμα δεδομένα όπως αισθητήρες δεδομένων ακόμα και μια λίστα πραγμάτων σε ένα καλάθι supermarket. Στην μάθηση χωρίς εκπαιδευτή η μηχανή απλά δέχεται τις εισόδους x_1, x_2, \dots, x_t αλλά δεν αποκτά ούτε καθοδηγούμενους στόχους σαν εξόδους ούτε απολαβές από το περιβάλλον. Θα μπορούσε να φανεί κατά κάποιον τρόπο περιεργο από κάποιον να φανταστεί τι θα μπορούσε η μηχανή να «μάθει» δεδομένου ότι δεν λαμβάνει καμία ανατροφοδότηση από το περιβάλλον. Ωστόσο, είναι πιθανό να αναπτύξει έναν ακριβή σκελετό για μάθηση χωρίς εκπαιδευτή, βασιζόμενη στην αντίληψη ότι στόχος μιας μηχανής είναι να χτίζει παραστάσεις από εισόδους που χρησιμοποιούνται για λήψη αποφάσεων, προβλέποντας μελλοντικές εισόδους, μέσω μιας αποτελεσματικής επικοινωνίας με εισόδους από άλλες μηχανές. Κατά μια έννοια, η μάθηση χωρίς εκπαιδευτή μπορεί να θεωρηθεί σαν η διαδικασία έυρεσης προτύπων στα δεδομένα που δίνονται πέραν από αυτό που θεωρούμε καθαρά ασαφές και μη δεδομένο. Ένα χαρακτηριστικό της είναι το μάζεμα και κατανομή πληροφοριών που οδηγεί στο μεγαλύτερο βαθμό στην απόρριψη τους κρατώντας όμως ένα μικρό χρήσιμο υλικό για μελλοντική διεκπεραίωση. *Συμπερασματικά, δεν υπάρχουν χαρακτηριστικά παραδείγματα της λειτουργίας που πρέπει να μάθει το δίκτυο καθιστώντας την πιο επίπονη σαν διαδικασία.*



Σχήμα 2 Διάνυσμα που περιγράφει την κατάσταση του περιβάλλοντος

Στην συνέχεια θα περιγραφεί μια υποκατηγορία μάθησης χωρίς εκπαιδευτή η ενισχυτική μάθηση.

Στην ενισχυτική μάθηση, η εκμάθηση μιας αντιστοίχισης εισόδου-εξόδου εκτελείται μέσω συνεχούς αλληλεπίδρασης με το περιβάλλον, με στόχο την ελαχιστοποίηση ενός βαθμωτού δείκτη απόδοσης. Η όλη διαδικασία βασίζεται σ' ένα μηχανισμό που λειτουργεί ως κριτής, ο οποίος μετατρέπει ένα κύριο σήμα ενίσχυσης λαμβανόμενο από το περιβάλλον σε ένα υψηλότερης ποιότητας σήμα ενίσχυσης που αποκαλείται ευρετικό σήμα ενίσχυσης αμφοτέρωθεν εκ των οποίων είναι βαθμωτές εισοδοί. Το σύστημα σχεδιάζεται έτσι ώστε να μαθαίνει βάση *καθυστερούμενης ενίσχυσης*, πράγμα που σημαίνει ότι το σύστημα παρατηρεί μια χρονική ακολουθία ερεθισμάτων που λαμβάνει από το περιβάλλον, τα οποία καταλήγουν στην παραγωγή του ευρετικού σήματος ενίσχυσης.

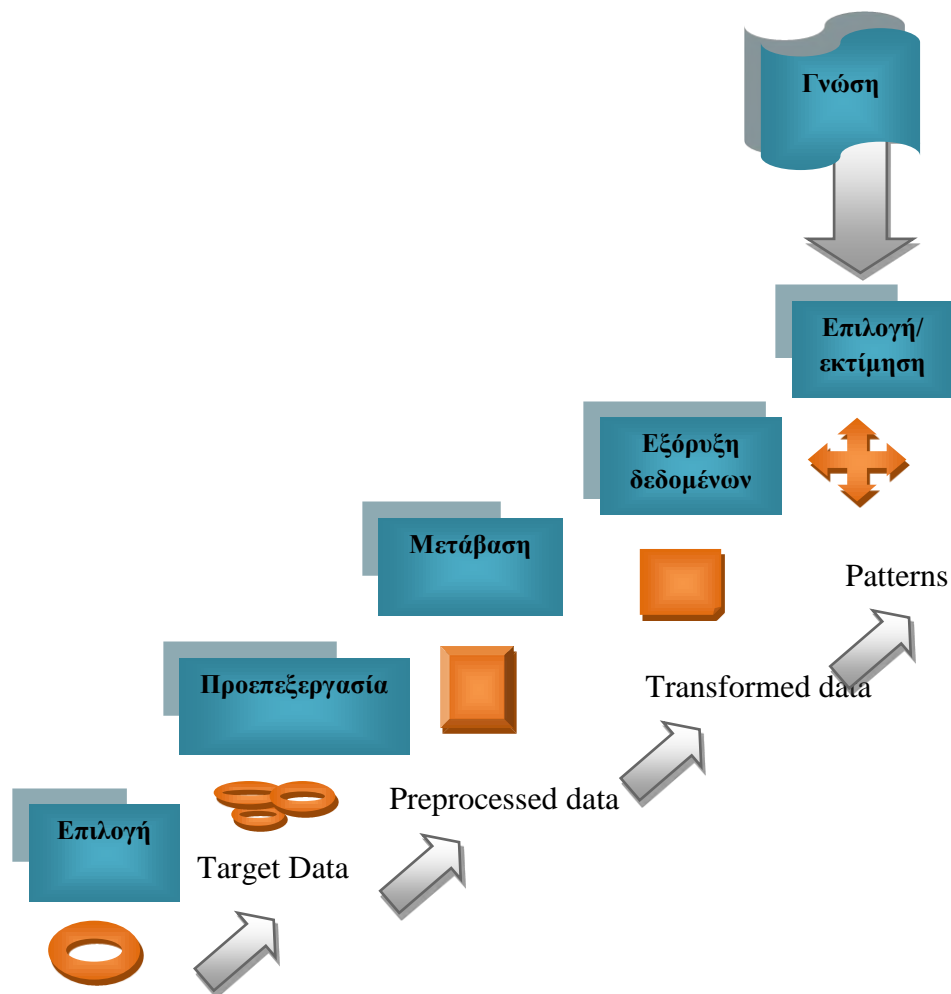
Ο στόχος της ενισχυτικής μάθησης είναι να ελαχιστοποιεί μια συνάρτηση τρέχοντος κόστους, η οποία ορίζεται ως πρόβλεψη του αθροιστικού κόστους,

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

ενεργειών που εκτελούνται σε μια αλληλουχία βημάτων αντί απλώς του άμεσου κόστους μιας ενέργειας. Ενδεχομένως ορισμένες από τις ενέργειες που έχουν εκτελεστεί σ' αυτήν την αλληλουχία χρονικών βημάτων να είναι οι καλύτερες ορίζουσες της συνολικής συμπεριφοράς του συστήματος. Η λειτουργία του συστήματος μάθησης είναι να ανακαλύπτει αυτές τις ενέργειες και να τις τροφοδοτήσει πίσω, στο περιβάλλον. Η ενισχυτική μάθηση με καθυστέρηση είναι δύσκολο να εκτελεστεί για δύο βασικούς λόγους.

- Δεν υπάρχει εκπαιδευτής για να παρέχει μια επιθυμητή απόκριση σε κάθε βήμα της διαδικασίας μάθησης.

- Η καθυστέρηση με την οποία παράγεται το κύριο σήμα ενίσχυσης υποδηλώνει ότι η μηχανή πρέπει να λύσει ένα *χρονικό πρόβλημα ανάθεσης εμπιστοσύνης*. Μ' αυτό εννοούμε ότι η μηχανή πρέπει να είναι σε θέση να καθορίζει το βαθμό επιτυχίας ατομικά για κάθε ενέργεια της χρονικής αλληλουχίας βημάτων που οδήγησαν στο τελικό αποτέλεσμα, ενώ ο κύριος μηχανισμός ενίσχυσης, μπορεί να αποτιμά μόνο το τελικό αποτέλεσμα.



Σχήμα 3

2.5 Εργασίες μάθησης

Στην ενότητα αυτή θα σκιαγραφηθούν ορισμένες βασικές εργασίες μηχανικής μάθησης. Η επιλογή ενός συγκεκριμένου κανόνα μάθησης, προφανώς, επηρεάζεται από τις εργασίες μάθησης, η ποικιλόμορφη φύση των οποίων καταδεικνύει την καθολικότητα εφαρμογής των νευρωνικών δικτύων.

2.5.1 Συσχέτιση προτύπων

Μια συσχετική μνήμη είναι μια μορφή κατανεμημένης μνήμης παρόμοια με αυτή του ανθρώπινου εγκεφάλου, η οποία μαθαίνει μέσω συσχέτισης. Η συσχέτιση αποτελεί κυρίαρχο χαρακτηριστικό της ανθρώπινης μνήμης.

Συσχέτιση μπορεί να λάβει μια από τις εξής δύο μορφές: αυτο-συσχέτιση και έτερο-συσχέτιση. Με την αυτο-συσχέτιση, ένα νευρωνικό δίκτυο καλείται να αποθηκεύσει ένα σύνολο προτύπων (διανύσματα), τα οποία παρουσιάζονται κατ' επανάληψη στο δίκτυο. Στη συνέχεια παρουσιάζεται στο δίκτυο μια ημιτελής περιγραφή ή παραμορφωμένη με θόρυβο έκδοση ενός εκ των αρχικών προτύπων που έχει αποθηκεύσει και το ζητούμενο είναι να ανακτήσει (ανακαλέσει) αυτό το συγκεκριμένο πρότυπο από την μνήμη του. Η ετερο-συσχέτιση διαφέρει από την αυτοσυσχέτιση στο ότι ένα τυχαίο σύνολο προτύπων εισόδου συνδυάζεται με ένα άλλο τυχαίο σύνολο προτύπων εξόδου. Η αυτο-συσχέτιση προϋποθέτει τη χρήση μη επιβλεπόμενης μάθησης, ενώ στην ετερο-συσχέτιση η μάθηση είναι επιβλεπόμενη.

Έστω ότι το x_k είναι ένα πρότυπο-κλειδί που εφαρμόζεται σε μια συσχετιστική μνήμη και το y_k είναι ένα απομνημονευμένο πρότυπο (διάνυσμα). Η συσχέτιση προτύπων που εκτελείται από το δίκτυο περιγράφεται από την

$$x_k \rightarrow y_k \quad k=1,2,\dots,q \quad (2.1)$$

όπου q είναι ο αριθμός των προτύπων που έχουν αποθηκευτεί στο δίκτυο. Το πρότυπο κλειδί x_k δρα ως ερέθισμα, το οποίο όχι μόνο καθορίζει την θέση αποθήκευσης του απομνημονευμένου προτύπου y_k αλλά επίσης «κρατά το κλειδί» για την ανάκτηση του.

Σε μια αυτο-συσχετιστική μνήμη, $y_k = x_k$ οπότε οι χώροι (δεδομένων) εισόδου και εξόδου του δικτύου έχουν ίδια διαδραστικότητα. Σε μια ετερο-συσχετιστική μνήμη $y_k \neq x_k$ άρα η διαστατικότητα του χώρου εξόδου σ αυτή την δεύτερη περίπτωση μπορεί να είναι ίδια με αυτή του χώρου εισόδου, αλλά μπορεί και όχι.

Υπάρχουν δύο φάσεις που εμπλέκονται στη λειτουργία μιας συσχετιστικής μνήμης:

- Η φάση αποθήκευσης, η οποία αναφέρεται στην εκπαίδευση του δικτύου σύμφωνα με την εξίσωση $x_k \rightarrow y_k \quad k=1,2,\dots,q$.
- Η φάση ανάκλησης, η οποία απαιτεί την ανάκτηση ενός απομνημονευμένου προτύπου ως απόκριση στην παρουσίαση μια «θορυβώδους» ή παραμορφωμένης έκδοσης ενός προτύπου-κλειδιού στο δίκτυο.

Έστω ότι το ερέθισμα (είσοδος) x αναπαριστά μια θορυβώδη ή παραμορφωμένη έκδοση ενός προτύπου-κλειδιού x_j . Αυτό το ερέθισμα παράγει μια απόκριση (έξοδο) y , όπως υποδεικνύεται στο σχήμα 4. Για τέλεια ανάκληση, θα πρέπει να διατυπώσουμε $y=y_j$, όπου y_j είναι το απομνημονευμένο πρότυπο που έχει συσχετιστεί με το πρότυπο-κλειδί x_j . Όταν $y \neq y_j$ για $x=x_j$ η συσχετιστική μνήμη λέγεται ότι επιδεικνύει *σφάλμα ανάκλησης*.

(S. Kotsiantis. *Informatica* 31 (3): 249-268 (2007))

2.5.2 Αναγνώριση προτύπων (pattern recognition)

Η Αναγνώριση Προτύπων (Pattern Recognition) είναι μία επιστημονική περιοχή που έχει στόχο την απόδοση κάποιας τιμής ή διακριτικού στοιχείου σε εισαγόμενα δεδομένα. Οι άνθρωποι και τα άλλα όντα έχουν την ικανότητα να ταυτοποιούν πραγματικά δεδομένα χρησιμοποιώντας τις αισθήσεις τους και την αντιληπτική τους ικανότητα (cognition) προκειμένου να λάβουν τις κατάλληλες αποφάσεις ώστε να επιβιώσουν στο περιβάλλον τους.

Μία μηχανή, όπως ένας ηλεκτρονικός υπολογιστής, πρέπει να εκπαιδευθεί κατάλληλα ώστε να αναγνωρίζει *πρότυπα* (patterns) και να τα κατηγοριοποιεί αυτόματα σε κατηγορίες. Ανάλογα με την εφαρμογή γίνεται κατάταξη των αντικειμένων σε *κλάσεις* με τη βοήθεια *αλγορίθμων ταξινόμησης*.

Το ερευνητικό ενδιαφέρον γι' αυτά τα ζητήματα ξεκίνησε από τη δεκαετία του 1960, κατά την πρώτη περίοδο της ανάπτυξης της επιστήμης των υπολογιστών. Βασίζόμενη στο θεωρητικό υπόβαθρο που παρείχε η επιστήμη της Στατιστικής, η πρώιμη έρευνα επικεντρώθηκε στην ανάπτυξη θεωρητικών μεθόδων. Ήδη από το 1970 γίνονταν προσπάθειες για την καλύτερη κατεύθυνση των προσπαθειών και το 1976 ιδρύεται η Παγκόσμια Ένωση για την Αναγνώριση Προτύπων (IARP).

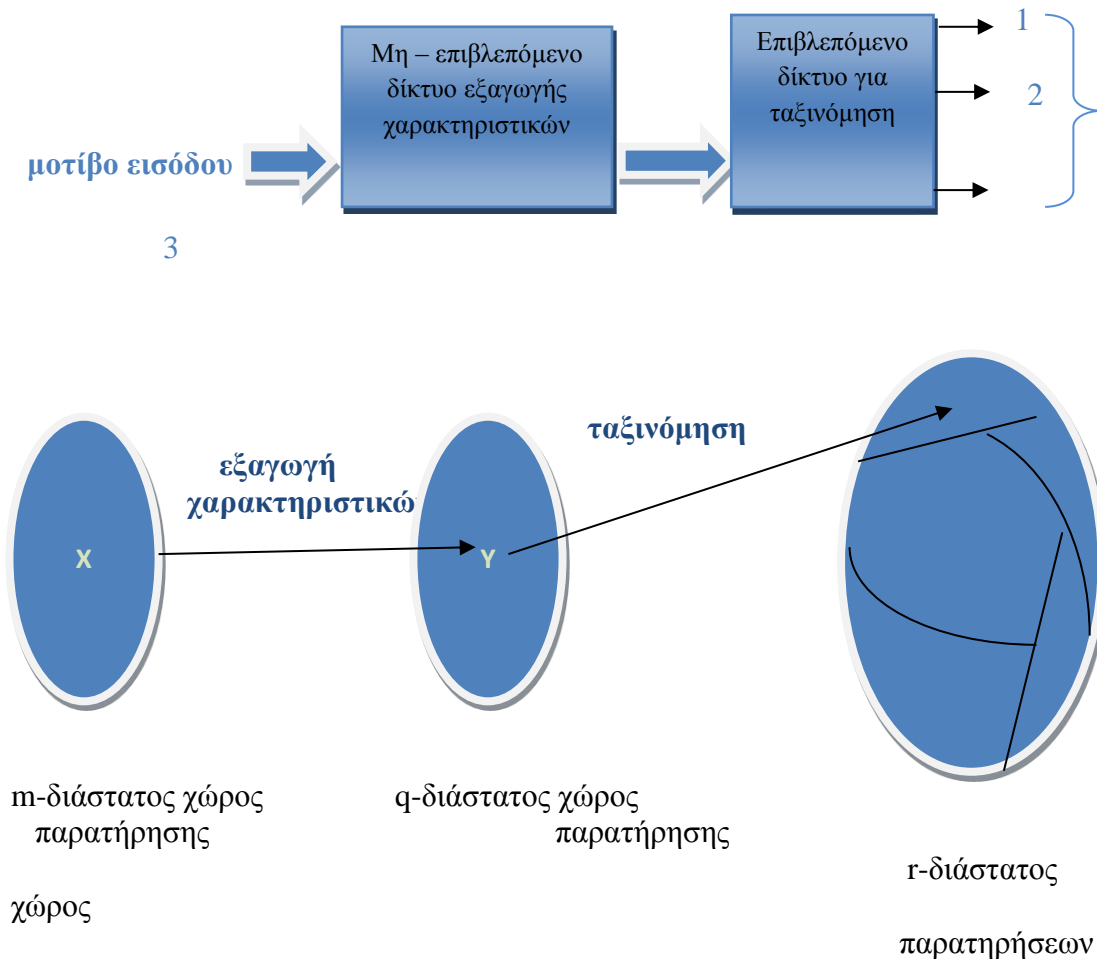
Σε πολλά επιστημονικά πεδία αξιοποιούνται εφαρμογές της αναγνώρισης προτύπων, όπως στην Ιατρική (υποβοηθούμενη από Η/Υ διάγνωση, ανάλυση δεδομένων DNA και άλλες εφαρμογές της βιοπληροφορικής) και την επιστήμη υπολογιστών (υπολογιστική όραση, αναγνώριση χαρακτήρων ή φωνής, νευρωνικά δίκτυα, εξόρυξη δεδομένων και ανάκτηση γνώσης, τεχνητή νοημοσύνη και μηχανική μάθηση, συστήματα υποστήριξης αποφάσεων). Στον σύγχρονο κόσμο, πολλές βιομηχανικές εφαρμογές ενσωματώνουν ανάλογα συστήματα για την αποδοτική και αυτόματη επεξεργασία πληροφοριών. Οι άνθρωποι εκτελούν την αναγνώριση προτύπων αφού περάσουν από μια διαδικασία μάθησης, κάτι το οποίο ισχύει και για τα νευρωνικά δίκτυα. (S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, Academic Press, 1999).

Θα μπορούσαμε να δώσουμε ένα σύντομο και περιεκτικό ορισμό για την αναγνώριση προτύπων *ως η διαδικασία μέσω της οποίας ένα προσλαβανόμενο σήμα/πρότυπο αντιστοιχίζεται σε μια κλάση που ανήκει σε ένα προκαθορισμένο σύνολο κλάσεων*.

Με γενικούς όρους, οι μηχανές αναγνώρισης προτύπων που χρησιμοποιούν τα νευρωνικά δίκτυα μπορεί να έχουν μια από τις ακόλουθες μορφές.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

I. Η μηχανή χωρίζεται σε δύο μέρη, ένα μη επιβλεπόμενο δίκτυο για την εξαγωγή χαρακτηριστικών και ένα επιβλεπόμενο δίκτυο για την ταξινόμηση, όπως απεικονίζεται στο υβριδικό σύστημα του σχήματος 4.



Σχήμα 4. Κλασσική προσέγγιση ταξινόμησης προτύπων

Η εξαγωγή χαρακτηριστικών περιγράφεται από έναν μετασχηματισμό ο οποίος αντιστοιχίζει το σημείο x σ' ένα ενδιάμεσο σημείο y ενός q -διάστατου χώρου χαρακτηριστικών, όπου $q < m$, όπως υποδεικνύεται στο σχήμα 4. Αυτός ο μετασχηματισμός μπορεί να εκληφθεί ως μείωση της διαστατικότητας (δηλ. συμπίεση δεδομένων), η χρήση της οποίας αιτιολογείται από το γεγονός ότι απλοποιεί την εργασία της ταξινόμησης.

II. Η μηχανή σχεδιάζεται ως ένα δίκτυο πρόσθιας τροφοδότησης χρησιμοποιώντας έναν αλγόριθμο επιβλεπόμενης μάθησης. Σ' αυτή τη δεύτερη

προσέγγιση, η εργασία της εξαγωγής χαρακτηριστικών εκτελείται από τις υπολογιστικές μονάδες στο κρυφό επίπεδο του δικτύου. (Cortes C.,1995).

2.5.3 Προσέγγιση συνάρτησης

Η τρίτη εργασία μάθησης που θα εξετάσουμε εδώ είναι η αποκαλούμενη προσέγγιση συνάρτησης. Θα ξεκινήσουμε θεωρώντας μια μη γραμμική αντιστοίχιση εισόδου-εξόδου η οποία θα περιγράφεται από την σχέση:

$$\mathbf{d}=\mathbf{f}(\mathbf{x}) \quad 2.2)$$

όπου το διάνυσμα \mathbf{x} είναι η είσοδος και το διάνυσμα \mathbf{d} είναι η έξοδος. Η διανυσματική συνάρτηση $f(\cdot)$ υποτίθεται πως είναι άγνωστη. Σαν αντιστάθμισμα για την έλλειψη γνώσης σχετικά με την συνάρτηση $f(\cdot)$, μας δίνεται το ακόλουθο σύνολο χαρακτηριστικών παραδειγμάτων:

$$\Sigma = \{ (\mathbf{x}_i, \mathbf{d}_i) \}_{i=1}^N \quad 2.3)$$

Το ζητούμενο είναι να σχεδιάζουμε ένα νευρωνικό δίκτυο το οποίο θα προσεγγίζει την άγνωστη συνάρτηση $\mathbf{f}(\cdot)$, με τρόπο ώστε η συνάρτηση $\mathbf{F}(\cdot)$ που περιγράφει την αντιστοίχιση εισόδου-εξόδου που υλοποιείται πραγματικά από το δίκτυο, να είναι επαρκώς κοντά στην $f(\cdot)$ υπό την ευκλείδεια έννοια για όλες τις εισόδους, όπως υποδεικνύει η σχέση

$$\| \mathbf{F}(\mathbf{x}) - \mathbf{f}(\mathbf{x}) \| < \varepsilon \quad 2.4)$$

Όπου ε είναι ένας μικρός θετικός αριθμός. Υπό τον όρο ότι το μέγεθος N του δείγματος εκπαίδευσης είναι επαρκώς μεγάλο και το δίκτυο είναι εφοδιασμένο με επαρκή αριθμό ελεύθερων παραμέτρων, το σφάλμα προσέγγισης ε μπορεί να γίνει επαρκώς μικρό για την εν λόγω εργασία.

Ο τρόπος προσέγγισης του προβλήματος που περιγράφεται εδώ είναι ιδανικός για τη χρήση επιβλεπόμενης μάθησης, με το \mathbf{x}_i να παίζει το ρόλο του διανύσματος εισόδου και το \mathbf{d}_i να παίζει το ρόλο της επιθυμητής απόκρισης.

Η δυνατότητα ενός νευρωνικού δικτύου να προσεγγίζει μια άγνωστη αντιστοίχιση εισόδου-εξόδου μπορεί να αξιοποιηθεί με δυο σημαντικούς τρόπους:

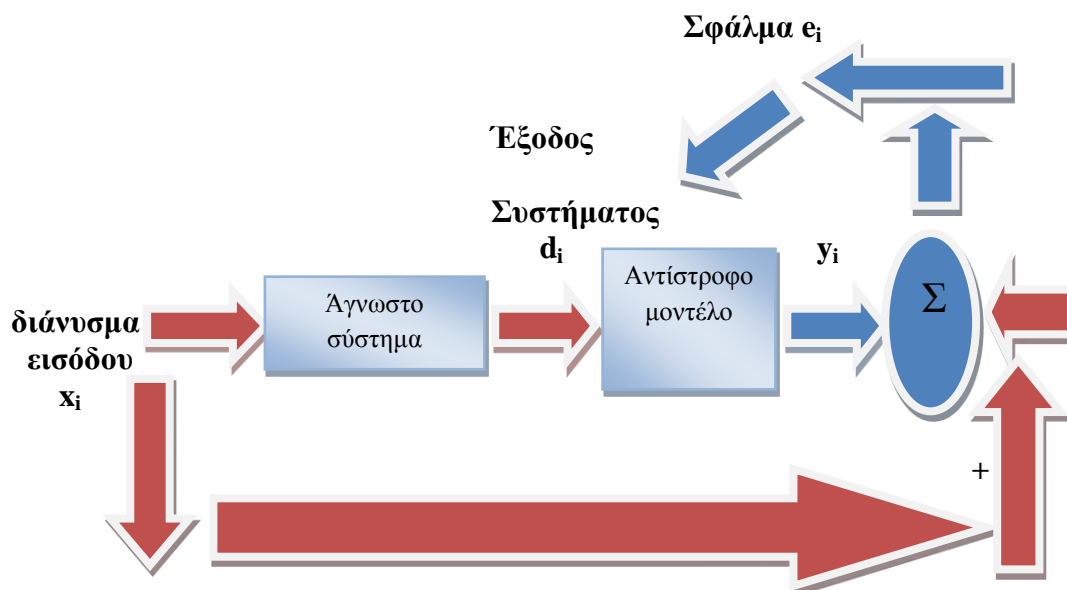
I. Αναγνώριση συστημάτων: έστω ότι η εξίσωση $\mathbf{d}=\mathbf{f}(\mathbf{x})$ περιγράφει τη σχέση εισόδου-εξόδου ενός άγνωστου, «άνευ μνήμης» συστημάτων πολλαπλών εισόδων-πολλαπλών εξόδων (MIMO). Μπορούμε τότε να χρησιμοποιήσουμε το σύνολο χαρακτηριστικών παραδειγμάτων της εξ.2 για την εκπαίδευση ενός νευρωνικού δικτύου ως μοντέλο του συστήματος. Έστω ότι το διάνυσμα \mathbf{y}_i συμβολίζει την πραγματική έξοδο του νευρωνικού δικτύου που παράγεται σε απόκριση προς ένα διάνυσμα εισόδου \mathbf{x}_i . Η διαφορά μεταξύ του \mathbf{d}_i και της εξόδου του δικτύου \mathbf{y}_i παρέχει το διάνυσμα σήματος σφάλματος \mathbf{e}_i όπως απεικονίζεται στο σχήμα 5. Αυτό το σήμα σφάλματος, με τη σειρά του, χρησιμοποιείται για την προσαρμογή των ελεύθερων παραμέτρων του δικτύου, με στόχο την ελαχιστοποίηση του τετραγώνου της

διαφοράς μεταξύ των εξόδων του άγνωστου συστήματος και του νευρωνικού δικτύου και υπολογίζεται για ολόκληρο το δείγμα εκπαίδευσης.

II. Αντίστροφη μοντελοποίηση: Υποθέστε ότι στη συνέχεια μας δίνεται ένα γνωστό άνευ μνήμης σύστημα MIMO. Το ζητούμενο σ' αυτή την περίπτωση είναι να κατασκευαστεί ένα *αντίστροφο μοντέλο* το οποίο θα παράγει το διάνυσμα \mathbf{x} σε απόκριση προς το διάνυσμα \mathbf{d} . Άρα, το αντίστροφο σύστημα μπορεί να περιγραφεί ως

$$\mathbf{x} = \mathbf{f}^{-1}(\mathbf{d}) \quad 2.5)$$

όπου η διανυσματική συνάρτηση $\mathbf{f}^{-1}(\cdot)$ συμβολίζει αναστροφή της συνάρτησης $\mathbf{f}(\cdot)$. Σημειώστε, ωστόσο, ότι η $\mathbf{f}^{-1}(\cdot)$ δεν είναι η αντίστροφη συνάρτηση της $\mathbf{f}(\cdot)$. Σε πολλές περιπτώσεις που συναντώνται στην πράξη, η διανυσματική συνάρτηση $\mathbf{f}(\cdot)$ είναι υπερβολικά πολύπλοκη, δυσχεραίνοντας σε απαγορευτικό βαθμό την διατύπωση της $\mathbf{f}^{-1}(\cdot)$. Δοθέντος του συνόλου χαρακτηρισμένων παραδειγμάτων της εξ 2.3, μπορούμε να υλοποιήσουμε μια προσέγγιση της $\mathbf{f}^{-1}(\cdot)$ μέσω του νευρωνικού δικτύου χρησιμοποιώντας το σχήμα 5. Στην περίπτωση που περιγράφεται εδώ, οι ρόλοι των \mathbf{x}_i και \mathbf{d}_i εναλλάσσονται: το διάνυσμα \mathbf{d}_i χρησιμοποιείται ως είσοδος και το \mathbf{x}_i αντιμετωπίζεται ως επιθυμητή απόκριση. Έστω ότι το διάνυσμα σήματος σφάλματος \mathbf{e}_i συμβολίζει την διαφορά μεταξύ \mathbf{x}_i και της πραγματικής εξόδου \mathbf{y}_i του νευρωνικού δικτύου, η οποία παράγεται σε απόκριση προς το \mathbf{d}_i . Όπως και στην περίπτωση της αναγνώρισης συστημάτων, αυτό το διάνυσμα σήματος σφάλματος χρησιμοποιείται για την προσαρμογή των ελεύθερων παραμέτρων του νευρωνικού δικτύου, με στόχο την ελαχιστοποίηση του τετραγώνου διαφοράς μεταξύ του άγνωστου συστήματος και του νευρωνικού δικτύου και υπολογίζεται για όλο το σύνολο δεδομένων εκπαίδευσης. Συνήθως η μοντελοποίηση είναι δυσκολότερη εργασία μάθησης συγκριτικά με την αναγνώριση συστημάτων, καθώς μπορεί να μην υπάρχει μια μοναδική γι' αυτή.

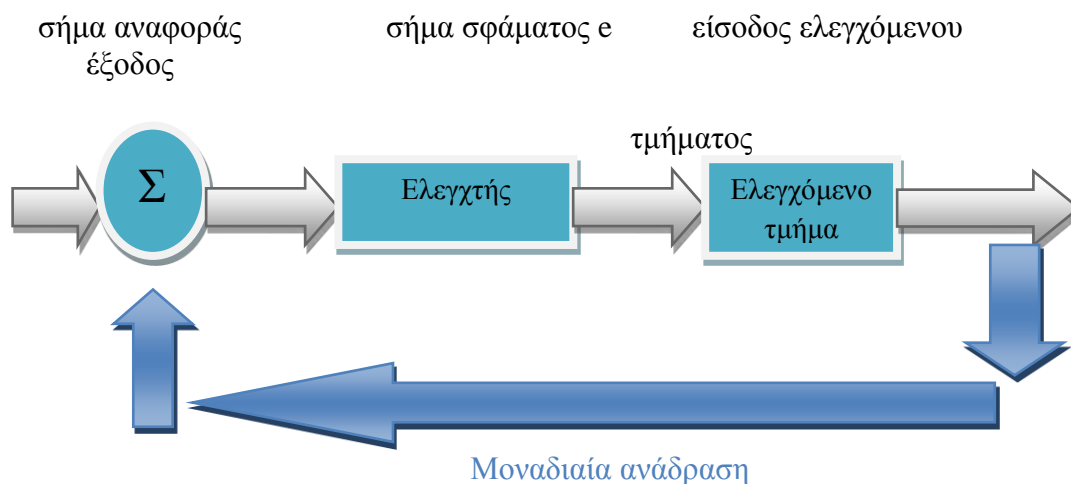


Σχήμα 5. Διάγραμμα αντίστροφης μοντελοποίησης συστημάτων. Το νευρωνικό δίκτυο λειτουργώντας ως αντίστροφο μοντέλο, είναι μέρος του βρόγχου ανάδρασης

2.5.4 Έλεγχος

Ο έλεγχος μιας μονάδας είναι άλλη μια εργασία μάθησης ιδιαίτερα κατάλληλη για υλοποίηση μέσω νευρωνικών δικτύων. Με τον όρο «μονάδα» εννοούμε μια διεργασία ή ένα ζωτικής σημασίας υποσύστημα ενός μεγαλύτερου συστήματος το οποίο πρέπει να διατηρείται σε μια ελεγχόμενη κατάσταση. Η στενή σχέση της μάθησης με τον έλεγχο δεν θα πρέπει να εκπλήσσει στο κάτω κάτω, ο ανθρώπινος εγκέφαλος δεν είναι παρά ένας υπολογιστής (επεξεργαστής πληροφοριών), οι έξοδοι του οποίου είναι οι *ενέργειες μας*. Υπ' αυτό το πρίσμα, ο εγκέφαλος είναι η ζωντανή απόδειξη του ότι είναι δυνατόν να κατασκευαστεί ένας «γενικευμένος» μηχανισμός ελέγχου ο οποίος θα αξιοποιεί πλήρως τις δυνατότητες παράλληλης επεξεργασίας συστημάτων hardcore με κατανομημένη αρχιτεκτονική, ικανός να ελέγχει πολλές χιλιάδες επενεργητές (actuators, μυϊκές ίνες) ταυτόχρονα να χειρίζεται επιτυχώς τη μη γραμμικότητα και το θόρυβο και να εκτελεί βελτιστοποιήσεις με μεγάλο ορίζοντα σχεδιασμού.

Ας εξετάσουμε το σύστημα ελέγχου με ανάδραση που απεικονίζεται στο σχήμα 6. Το σύστημα χρησιμοποιεί ανάδραση γύρω από μια ελεγχόμενη μονάδα του δηλαδή, η έξοδος αυτής της μονάδας τροφοδοτείται πίσω, στην είσοδο της.



Σχήμα 6. Σχηματικό διάγραμμα συστήματος ελέγχου με ανάδραση.

Έτσι, η έξοδος y της μονάδας αφαιρείται από ένα σήμα αναφοράς d το οποίο παρέχεται από μια εξωτερική πηγή. Το παραγόμενο σήμα σφάλματος e εφαρμόζεται σ' έναν νευρωνικό ελεγκτή με στόχο την προσαρμογή των ελεύθερων παραμέτρων του. Ο βασικός στόχος του ελεγκτή είναι να παρέχει κατάλληλες εισόδους στη μονάδα, έτσι ώστε η έξοδος της y να παρακολουθεί το σήμα αναφοράς d .

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Με άλλα λόγια, ο ελεγκτής πρέπει να αντιστρέφει τη συμπεριφορά εισόδου-εξόδου της μονάδας.

Παρατηρείστε ότι στο σύστημα του σχήματος 6, το σήμα σφάλματος e πρέπει να περάσει από νευρωνικό ελεγκτή πριν φτάσει στην μονάδα. Κατά συνέπεια, για να εκτελέσουμε προσαρμογές στις ελεύθερες παραμέτρους της μονάδας σύμφωνα με έναν αλγόριθμο μάθησης με διόρθωση σφάλματος, θα έπρεπε να γνωρίζουμε τον jacobian του συστήματος, ο οποίος είναι ο πίνακας μερικών παραγώγων όπως υποδεικνύει η σχέση

$$J = \{ a_{y_k / a_{u_j}} \}_{j,k} \quad (2.6)$$

Όπου y_k είναι ένα στοιχείο της εξόδου y της μονάδας και u_j είναι ένα στοιχείο της εισόδου u της μονάδας. Δυστυχώς, οι μερικές παράγωγοι a_{y_k} / a_{u_j} για τις διάφορες τιμές των k, j εξαρτώνται από το σημείο λειτουργίας της μονάδας και, ως εκ τούτου, δεν είναι γνωστές. Μπορούμε να χρησιμοποιήσουμε μια από τις εξής δύο προσεγγίσεις για να αντισταθμίσουμε αυτή την έλλειψη γνώσης:

I. *Έμμεση μάθηση.* Χρησιμοποιώντας πραγματικές μετρήσεις της εισόδου και εξόδου της μονάδας, κατασκευάζουμε κατ' αρχήν ένα νευρωνικό μοντέλο το οποίο αποτελεί αντίγραφο της. Αυτό το μοντέλο, με τη σειρά του, χρησιμοποιείται για τον υπολογισμό μιας εκτίμησης του πίνακα jacobian J . Οι μερικές παράγωγοι που αποτελούν τον πίνακα jacobian χρησιμοποιούνται στη συνέχεια στον αλγόριθμο μάθησης με διόρθωση σφάλματος για τον υπολογισμό των προσαρμογών που πρέπει να γίνουν στις ελεύθερες παραμέτρους του νευρωνικού ελεγκτή.

II. *Άμεση μάθηση.* Τα πρόσημα των μερικών παραγώγων a_{y_k} / a_{u_j} είναι γενικά γνωστά και συνήθως παραμένουν σταθερά για όλη τη δυναμική περιοχή της μονάδας. Αυτό υποδηλώνει ότι μπορούμε να προσεγγίζουμε αυτές τις μερικές παραγώγους βάσει των προσήμων του. Οι απόλυτες τιμές τους λαμβάνουν μια κατανομημένη αναπαράσταση στις ελεύθερες παραμέτρους του νευρωνικού ελεγκτή. Έτσι, ο νευρωνικός ελεγκτής έχει τη δυνατότητα να μάθει τις προσαρμογές στις ελεύθερες παραμέτρους του άμεσα από την ελεγχόμενη μονάδα.

F. Denis, R. Gilleron, and M. Tommasi, Text classification from positive and unlabeled examples, IPMU, 2002.

Κεφάλαιο 3

3. Οικογένειες αλγορίθμων μηχανικής μάθησης

Στην βιβλιογραφία συναντάται μια μεγάλη ποικιλία αλγορίθμων μηχανικής μάθησης, οι οποίοι μπορούν να χωριστούν σε κατηγορίες με βασικό κριτήριο τα είδη των προβλημάτων που χειρίζονται. Στο κεφάλαιο αυτό θα γίνει μια παρουσίαση των αλγορίθμων μηχανικής μάθησης. (F. Letouzey, F. Denis, and R. Gilleron, Learning from Positive and Unlabeled examples, In Proceedings of the 11th International Conference on Algorithmic Learning Theory, pages 71-85, 2000.)

3.1 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. (Russell, Norvig 2011)

Ως βασικότερα πλεονεκτήματα της προσέγγισης αυτής μπορούμε να αναφέρουμε:

- *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 εύρρωστων 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 Μ.Μ, καθώς οι αλγόριθμοι της κατηγορίας αυτής εγγυώνται τη βέλτιστη επίλυση ενός προβλήματος, δεδομένου ενός συνόλου υποθέσεων που απλοποιούν την κατασκευή του μοντέλου. (T.M. Mitchell, Machine Learning, McGraw-Hill, 1997.)*

3.2 Μάθηση βασισμένη σε Δένδρα Απόφασης

Μια επίσης ευρέως χρησιμοποιούμενη μέθοδος Μ.Μ 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 κατανέμεται 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. (B. Becker, R. Kohavi, and R. Sommerfield, “Visualizing the simple Bayesian classifier”, KDD-97 Workshop on Issues in the Integration of Data Mining and Data Visualization, 1997.)

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. 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. [Y Fradhany¹, MAB Jondri - 2008](#)

Στα θετικά σημεία της μεθόδου αυτής συγκαταλέγονται:

- *Η ευρρωστία* 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. (Sien Lim και 47 άλλοι, 2000)

3.3 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 Μ.Μ συναντάται στη βιβλιογραφία και ως *Επαγωγικός Λογικός Προγραμματισμός (Inductive Logic Programming ή ILP)*.

Όπως ήδη αναφέραμε, κανόνες μπορούν εύκολα να προκύψουν από την εκμάθηση ενός δένδρου απόφασης και τη μετατροπή του σε κανόνες προτασιακής λογικής. 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). *Cesa-Bianchi, N. and Conconi, A. and Gentile, C. (2004). On the generalization ability of on-line learning algorithms. IEEE Transactions on Information Theory*

3.4 Μάθηση βασισμένη σε Στιγμιότυπα

Πρόκειται για μια ιδιαίτερα απλή προσέγγιση του προβλήματος της Μ.Μ, 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. (Shekhar S., Xiong H. 2008)

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 στιγμιοτύπων, 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. *Aamodt, A., & Plaza, E. (1994). Case-Based Reasoning: Foundational Issues - Methodological Variations, and System Approaches. Artificial Intelligence Communications-IOS Press, 7(1), 39-59.*

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*). *B. Becker, R. Kohavi, and R. Sommerfield, "Visualizing the simple Bayesian classifier", KDD-97 Workshop on Issues in the Integration of Data Mining and Data Visualization, 1997.*

3.5 Μάθηση βασισμένη σε Τεχνητά Νευρωνικά Δίκτυα

Ένας από τους στόχους αυτής της ερευνητικής περιοχής ήταν η βαθύτερη κατανόηση των διεργασιών που επιτελούνται στα πλαίσια της μάθησης στους ζώντες οργανισμούς, και ειδικότερα στον άνθρωπο. Χαρακτηριστικός εκπρόσωπος της προσπάθειας αυτής 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*. *Beale, R., & Jackson, T. (1990).*

Τα τεχνητά νευρωνικά δίκτυα διακρίνονται για την ικανότητά τους να προσεγγίζουν τόσο διακριτές όσο και συνεχείς, πραγματικές, ακόμα και διανυσματικές συναρτήσεις στόχου, για την ευρρωστία 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. (T.M. Mitchell, *Machine Learning*, McGraw-Hill, 1997.)

3.6 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.

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 εκπαίδευσής τους. Aamodt, A., & Plaza, E. (1994). *Case-Based Reasoning: Foundational Issues - Methodological Variations, and System Approaches. Artificial Intelligence Communications-IOS Press*, 7(1), 39-59. Beale, R., & Jackson, T. (1990). *Neural Computing: An Introduction. N.Y.: Adam Hilger*.

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. Μια εκτενέστερη παρουσίαση του θέματος, σε συνδυασμό με μια εφαρμογή μεθόδων του Γενετικού Προγραμματισμού στο χώρο του φιλτραρίσματος μη αιτηθείσας διαφημιστικής αλληλογραφίας μπορεί να αναζητηθεί στο διαδίκτυο [Katirai 1999]. Colin, A. (1996). Building Decision Trees with the ID3 Algorithm. *Dr Dobb's Journal of Software Tools for Professional Programmer*, 21(6), 107-109.

3.7 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 M.M, 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 M.M, 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.

• *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.

• *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)*.

• *Κωδικοποίηση Διόρθωσης Λαθών Εξόδου (Error-Correcting Output Codes)*: Η τεχνική αυτή χρησιμοποιείται για τη βελτίωση της απόδοσης των αλγορίθμων Μ.Μ. 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 αποφαίνονται 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 αντιστοιχίθηκε. (Banzhaf 1998)

3.8 Μάθηση σε μικρή κλίμακα

3.8.1 Ορισμός

Ένα πρόβλημα επιβλεπόμενης μάθησης λέγεται ότι είναι μικρής κλίμακας όταν το μέγεθος του δείγματος εκπαίδευσης (δηλ. ο αριθμός των παραδειγμάτων) είναι ο ενεργός περιορισμός που επιβάλλεται στην διαδικασία μάθησης.

3.8.2 Προβλήματα μάθησης μικρής κλίμακας

Όσον αφορά τα προβλήματα μάθησης μικρής κλίμακας, υπάρχουν τρεις μεταβλητές διαθέσιμες στο σχεδιαστή μιας μηχανής μάθησης:

- Ο αριθμός των παραδειγμάτων εκπαίδευσης, N
- Το επιτρεπτό μέγεθος K της οικογένειας συναρτήσεων προσέγγισης δικτύου f
- Το υπολογιστικό σφάλμα ρ

Με ενεργό περιορισμό τον αριθμό παραδειγμάτων, οι επιλογές σχεδίασης για τα προβλήματα μάθησης του πρώτου είδους έχουν ως εξής:

- Μειώνουμε το σφάλμα εκτίμησης κάνοντας το N όσο μεγάλο επιτρέπει ο υπολογιστικός προϋπολογισμός μας
- Μειώνουμε το σφάλμα βελτιστοποίησης θέτοντας το υπολογιστικό σφάλμα $\rho=0$,
- Προσαρμόζουμε το μέγεθος της F στο βαθμό που κρίνεται εύλογο.

Με $\rho=0$, η μέθοδος ελαχιστοποίησης δομικού ρίσκου, που θα περιγραφεί στην συνέχεια, επαρκεί για τον χειρισμό των μικρής κλίμακας προβλημάτων μάθησης.

3.9 Μάθηση σε μεγάλη κλίμακα

3.9.1 Ορισμός

Ένα πρόβλημα επιβλεπόμενης μάθησης λέγεται ότι είναι μεγάλης κλίμακας όταν ο χρόνος υπολογισμού είναι ο ενεργός περιορισμός που επιβάλλεται στη διαδικασία μάθησης. Με άλλα λόγια, ο ισχύων περιορισμός είναι η ειδοποιός διαφορά της μιας κατηγορίας προβλημάτων μάθησης από την άλλη.

Για ένα ενδεικτικό παράδειγμα μικρής κλίμακας προβλήματος μάθησης, μπορούμε να αναφέρουμε τη σχεδίαση ενός προσαρμοστικού ισοσταθμιστή (equalizer), στόχος του οποίου είναι να αντισταθμίζει την αναπόφευκτη παραμόρφωση των φερόντων πληροφοριών που μεταδίδονται μέσω ενός καναλιού επικοινωνίας. Ο αλγόριθμος LMS, που εδράζεται στη στοχαστική μέθοδο βαθμωτής κατάβασης χρησιμοποιείται ευρέως για την επίλυση αυτού του προβλήματος on-line μάθησης (Haykin 2002).

Για ένα ενδεικτικό παράδειγμα μεγάλης κλίμακας προβλήματος μάθησης, μπορούμε να αναφέρουμε τη σχεδίαση ενός αναγνώστη επιταγών, όπου τα παραδείγματα εκπαίδευσης αποτελούνται από συνδυασμένα ζεύγη, κάθε ένα εκ των οποίων περιγράφει ένα συγκεκριμένο ζεύγος {εικόνα–ποσό}: «εικόνα» είναι η εικόνα της επιταγής και «ποσό» είναι το αναγραφόμενο χρηματικό ποσό σ' αυτήν. Ένα τέτοιο πρόβλημα μάθησης έχει «ανθεκτική» δομή, η οποία περιπλέκεται από τα ακόλουθα ζητήματα (Bottou,2007):

- Τμηματοποίηση σε σχέση με τα πεδία της επιταγής
- Τμηματοποίηση σε σχέση με τους χαρακτήρες του ποσού
- Αναγνώριση των χαρακτήρων
- Συντακτική ερμηνεία

Το συννελεκτικό δίκτυο, εφόσον ενσωματώνει διαφορίσιμες λειτουργικές μονάδες και εκπαιδευτεί με έναν αλγόριθμο στοχαστικής κλίσης για λίγες εβδομάδες, αποτελεί μια ευρέως χρησιμοποιούμενη λύση για την επιτυχή αντιμετώπιση αυτού του δύσκολου προβλήματος μάθησης. Πράγματι, αυτό το πρωτοποριακό δίκτυο χρησιμοποιείται στην πράξη από το 1996, έχοντας ελέγξει δισεκατομύρια επιταγών. Mitchell, T.M. (1997). *Machine Learning*. Maidenhead, H.B.: McGraw-Hill International Editions. Nordlund, J., & Schafer, H. (2006). *Case-Based Reasoning in a Support system* (Master in CS, Πανεπιστήμιο Umea). Pao, Yoh-Han (1989). *Adaptive Pattern Recognition and Neural Networks*. Wokingham, ΗΠΑ: Addison-Wesley.

3.9.2 Προβλήματα μάθησης μεγάλης κλίμακας

Όπως επισημάναμε προηγουμένως, ο ενεργός περιορισμός στα μεγάλης κλίμακας προβλήματα μάθησης είναι ο χρόνος υπολογισμού. Για το χειρισμό των προβλημάτων μάθησης αυτού του δεύτερου είδους, αντιμετωπίζουμε σημαντικά πολυπλοκότερους συμβιβασμούς επειδή τώρα πρέπει να συνυπολογίσουμε και το χρόνο υπολογισμού T . Στα μεγάλης κλίμακας προβλήματα μάθησης, το πλεονάζον σφάλμα ορίζεται από την διαφορά ($J(w_N - J_{actual}(f))$), η οποία αναλύεται σε τρεις όρους (Bottou, 2007):

$$J(w_N - J_{actual}(f)) = \underbrace{J(w_N)} - \underbrace{J(w_N^{\wedge})} + \underbrace{J(w_N^{\wedge}) - J(w^*)} - \underbrace{J_{actual}(f^*)} \quad 3.1)$$

Πλεονάζον σφάλμα *σφάλμα βελτισποίησης* *σφάλμα προσέγγισης* *σφάλμα εκτίμησης*

Οι δύο τελευταίοι όροι, που αποτελούν τα σφάλματα προσέγγισης και εκτίμησης, είναι κοινή σε αμφότερα μικρής και μεγάλης κλίμακας προβλήματα μάθησης. Ο πρώτος όρος της εξίσωσης κάτι είναι αυτός που διαχωρίζει τα μεγάλης κλίμακας προβλήματα μάθησης από τα μικρής κλίμακας. Αυτός ο νέος όρος, το αποκαλούμενο σφάλμα βελτισποίησης, προφανώς σχετίζεται με το υπολογιστικό σφάλμα ρ . Russel, S. J. , & Norvig, P. (2003). *Artificial Intelligence-A Modern Approach* (2η έκδοση). Upper Saddle River, Νιου Τζέρσεϋ: Pearson Prentice Hall (1η έκδοση 1995).

Ο υπολογισμός του φράγματος στο σφάλμα προσέγγισης, είναι καλά τεκμηριωμένος (βάση θεωρίας VC) για τα μικρής κλίμακας προβλήματα μάθησης. Δυστυχώς, οι σταθερές που περιβάλλονται στον τύπο γι' αυτό το φράγμα δίνουν μη ικανοποιητικά αποτελέσματα όταν ο τύπος εφαρμόζεται σε μεγάλης κλίμακας προβλήματα μάθησης. Συνεπώς, σ' αυτές τις δυσκολότερες περιπτώσεις είναι πιο παραγωγικό να αναλύουμε την εξίσωση κάτι βάσει των ρυθμών σύγκλισης και όχι των φραγμάτων.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

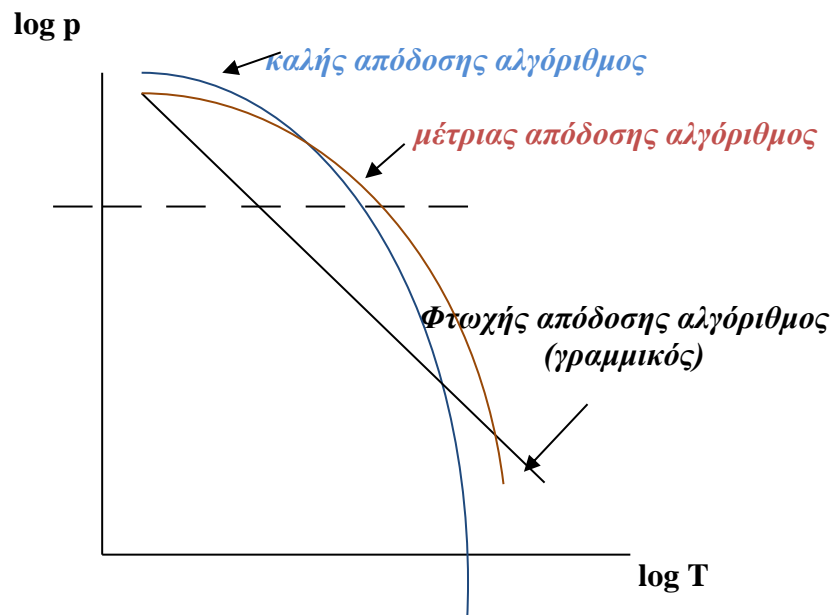
Το ζητούμενο είναι η ελαχιστοποίηση του αθροίσματος των τριών όρων της εξίσωσης 3.1 προσαρμόζοντας τις διαθέσιμες μεταβλητές:

- Τον αριθμό των παραδειγμάτων, N
- Το επιτρεπτό μέγεθος K των συναρτήσεων προσέγγισης δικτύου, F_K .
- Το υπολογιστικό σφάλμα ρ , το οποίο δεν είναι πλέον μηδέν

Η διεξαγωγή αυτής της ελαχιστοποίησης με αναλυτικό τρόπο είναι εξαιρετικά δύσκολη, λόγω του γεγονότος ότι ο χρόνος υπολογισμού T εξαρτάται στην πραγματικότητα και από τις τρεις μεταβλητές N, F και ρ . Για να κατανοήσουμε τις συνέπειες αυτής της εξάρτησης, υποθέτουμε ότι αναθέτουμε μικρή τιμή στο σφάλμα ρ για να μειώσουμε το σφάλμα βελτιστοποίησης. Για να πετύχουμε αυτή τη μείωση, δυστυχώς, θα πρέπει επίσης να αυξήσουμε το N , το F , η αμφότερα, και οποιαδήποτε από αυτές τις ενέργειες θα είχε ανεπιθύμητα επακόλουθα στα σφάλματα προσέγγισης και εκτίμησης.

Παρά ταύτα, σε ορισμένες περιπτώσεις, είναι δυνατό να υπολογίσουμε τους εκθετικούς όρους σε σχέση με τους οποίους τα τρία σφάλματα τείνουν να μειώνονται όταν μειώνεται το ρ και αυξάνονται αμφότερα τα F και N . Παρόμοια, είναι δυνατό να προσδιορίσουμε τους εκθετικούς όρους σε σχέση με τους οποίους αυξάνεται ο χρόνος υπολογισμού T όταν μειώνεται το ρ και αυξάνονται αμφότερα τα F και N . Βάζοντας τα όλα μαζί έχουμε όλα τα στοιχεία που χρειαζόμαστε για μια προσεγγιστική λύση όσον αφορά τους αναγκαίους συμβιβασμούς για το χειρισμό προβλημάτων μάθησης μεγάλης κλίμακας.

Το πιο σημαντικό είναι ότι, σε τελική ανάλυση, οι συμβιβασμοί εξαρτώνται από την επιλογή του αλγορίθμου βελτιστοποίησης.



Σχήμα 1

Καλής απόδοσης αλγόριθμος βελτιστοποίησης (υπεργαμμικός) για τον οποίο το ρ μειώνεται γρηγορότερα από το $\exp(-T)$.

Μέτριας απόδοσης αλγόριθμος βελτιστοποίησης (γραμμικός), για τον οποίο το ρ μειώνεται βάσει $\exp(-T)$.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Φτωχής απόδοσης αλγόριθμος βελτισποίησης, για τον οποίο το ρ μειώνεται βάσει $1/T$.

Το σχήμα 1 απεικονίζει πως επηρεάζεται η γραφική παράσταση του $\log \rho$ ως προς $\log T$. Επηρεάζεται από το είδος του αλγορίθμου βελτισποίησης που χρησιμοποιείται για την επίλυση ενός μεγάλου κλίμακας προβλήματος μάθησης. Τρεις κατηγορίες αλγορίθμων προσδιορίζονται στο σχήμα 1 ένας με κακή απόδοση, ένας με μέτρια απόδοση κι ένας με καλή απόδοση παράδειγμα των οποίων είναι, αντίστοιχα, η στοχαστική βαθμωτή κατάβαση (δηλ on line μάθηση), η βαθμωτή κατάβαση (δηλ η μαζική μάθηση) και η βαθμωτή κατάβαση δεύτερης τάξης. Ο πίνακας 1 συνοψίζει τα χαρακτηριστικά που διακρίνουν αυτές τις τρεις κατηγορίες αλγορίθμων βελτισποίησης.

Αλγόριθμος	Υπολογιστικό κόστος ανά επανάληψη	Χρόνος επίτευξης του ρ
1.στοχαστική βαθμωτή κατάβαση (on line μάθηση)	$O(m)$	$O\left(\frac{1}{\rho}\right)$
2.Βαθμωτή κατάβαση (μαζική μάθηση)	$O(Nm)$	$O\log\left(\frac{1}{\rho}\right)$
3.Βαθμωτή κατάβαση δεύτερης τάξης (on line μάθηση)	$O(m(m+N))$	$O\left(\log\left(\log\frac{1}{\rho}\right)\right)$

Πίνακας 1

m: διάσταση του διανύσματος εισόδου

N: αριθμός των παραδειγμάτων που χρησιμοποιούνται για εκπαίδευση

ρ : υπολογιστικό σφάλμα

Το δίδαγμα αυτής της ενότητας αναφορικά με την επιβλεπόμενη μάθηση μπορεί να συνοψιστεί στο εξής:

Ενώ η μελέτη των μικρής κλίμακας προβλημάτων μάθησης είναι καλά τεκμηριωμένη, η μελέτη των μεγάλης κλίμακας προβλημάτων μάθησης βρίσκεται ακόμη στα αρχικά στάδια της ανάπτυξης της.

Utgoff, P. E. (1989). Incremental Induction of Decision Trees. *Machine Learning*, 4, 161-186. Ανακτήθηκε <http://people.cs.umass.edu/~utgoff/papers/mlj-id5r.pdf> Whitley, D. (1994). A Genetic Algorithm Tutorial. *Statistics and Computing*, 4, 65–85. <http://www.cs.colostate.edu/~genitor/MiscPubs/tutorial.pdf>

Κεφάλαιο 4

Εισαγωγή

Στο κεφάλαιο αυτό θα αναφερθούμε σε μεθόδολογίες επίλυσης προβλημάτων γνωστές και ως μέθοδοι πυρήνα. Θα παρουσιαστεί ο ορισμός και η περιγραφή των μεθόδων πυρήνα σχηματικά αλλά και με παραδείγματα. Στην συνέχεια, θα γίνει περιγραφή των μηχανών διανυσμάτων υποστήριξης καθώς και μια πρακτική εφαρμογή αυτών των μηχανών, τον αλγόριθμο κατηγοριοποίησης δεδομένων. Τέλος, για την καλύτερη κατανόηση των μηχανών πυρήνα συμπεριλαμβανομένων των διανυσμάτων υποστήριξης θα περιγράψουμε το θεμελιώδες θεώρημα Representer.

4.1 Μέθοδοι πυρήνα (kernel methods)

4.1.1 Ορισμός

Στην επιστήμη των υπολογιστών οι μέθοδοι πυρήνα είναι μια κατηγορία αλγορίθμων για την ανάλυση προτύπων, των οποίων το πιο γνωστό στοιχείο είναι η μηχανή διανυσμάτων υποστήριξης (Support Vector Machine). Η γενική αρμοδιότητα της ανάλυσης προτύπων είναι να βρει και να μελετήσει γενικούς τύπους σχέσεων (για ομαδοποίηση, ταξινόμηση, συσχετίσεις) σε γενικού τύπου δεδομένα (όπως έγγραφα κειμένου, διανύσματα, εικόνες κ.τ.λ).

4.1.2 Βασικές έννοιες

Η μέθοδοι πυρήνα προσεγγίζουν το πρόβλημα με την χαρτογράφηση των δεδομένων σε ένα υψηλών διαστάσεων χώρο, όπου κάθε συντεταγμένη αντιστοιχεί σε ένα χαρακτηριστικό στοιχείο δεδομένων, μετατρέποντας τα δεδομένα σε μια σειρά από σημεία σε ένα ευκλείδιο χώρο. Σε αυτό το χώρο μια ποικιλία μεθόδων μπορεί να χρησιμοποιηθεί για να βρει τις τυχόν σχέσεις στα δεδομένα. Δεδομένου ότι η χαρτογράφηση μπορεί να είναι αρκετά γενική, οι σχέσεις που θα προκύψουν με τον τρόπο αυτό θα είναι και αυτές ανάλογα γενικές. Αυτή η προσέγγιση ονομάζεται το τέχνασμα του πυρήνα (Kernel Trick). Οι μέθοδοι πυρήνα οφείλουν το όνομα τους στην χρήση συναρτήσεων πυρήνα, που τους επιτρέπει να λειτουργήσουν στο χαρακτηριστικό πεδίο, χωρίς όμως να υπολογίζουν τις συντεταγμένες των δεδομένων στο χώρο αυτό, αλλά απλώς υπολογίζοντας τα προϊόντα από «μέσα» προσπαθώντας να ταυτιστούν οι εικόνες από όλα τα ζευγάρια δεδομένων στο πεδίο αυτό. Η μέθοδος αυτή είναι συχνά φθηνότερη από τον μαθηματικό υπολογισμό των συντεταγμένων. Οι μέθοδοι πυρήνα έχουν θεσπιστεί για ακολουθίες δεδομένων, γραφικά, κείμενο καθώς και εικόνες. Οι αλγόριθμοι που είναι σε θέση να λειτουργούν με πυρήνες περιλαμβάνουν μηχανές διανυσμάτων υποστήριξης, γκαουσιανές διαδικασίες, ανάλυση κύριων συνιστωσών, φασματική ομαδοποίηση, προσαρμοστικά γραμμικά φίλτρα και πολλά άλλα. Λόγω της ιδιαίτερης κουλτούρας της ερευνητικής κοινότητας που έχει αναπτύξει την προσέγγιση αυτή από τα μέσα της δεκαετίας του 1990, οι περισσότεροι αλγόριθμοι βασίζονται σε κυρτά προβλήματα βελτιστοποίησης ή εγγενώς, είναι υπολογιστικά σταθερή και στατιστικά βάσιμη.

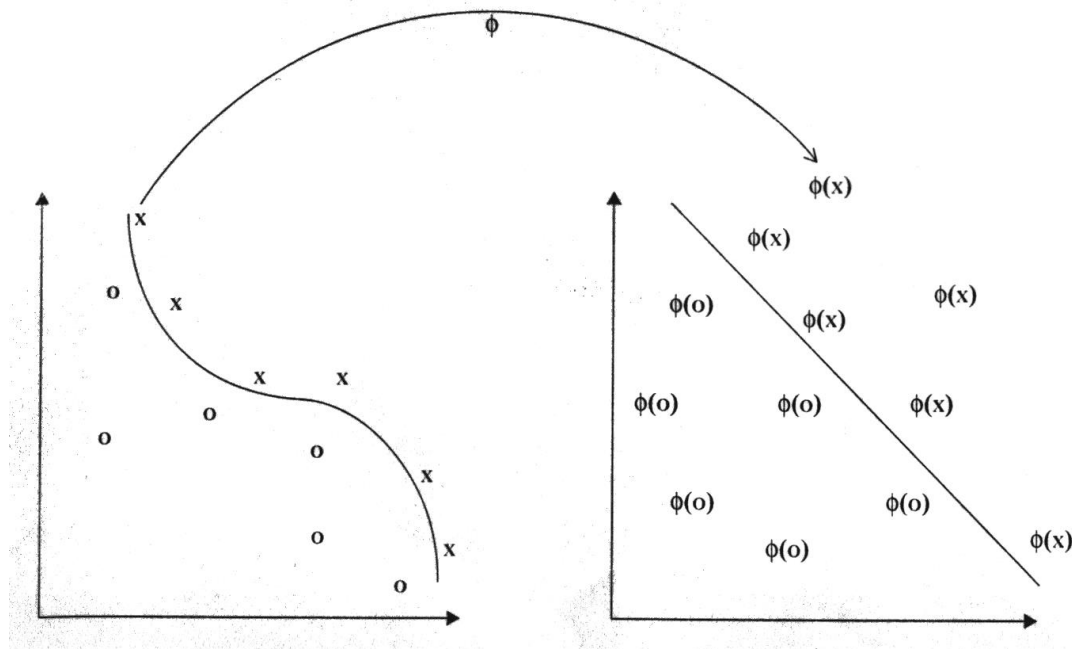
Σε ότι αφορά τις εφαρμογές των μεθόδων πυρήνα, οι κύριοι τομείς εφαρμογής είναι γεωστατική, η αναγνώριση γραφικού χαρακτήρα, η κατηγοριοποίηση κειμένων

καθώς και η βιοπληροφορική. Cohen et al. Taylor & Francis Group. Applied Multiple Regression/ Correlation Analysis for the Behavioural Sciences 3rd ed. (2003).

4.1.3 Περιγραφή

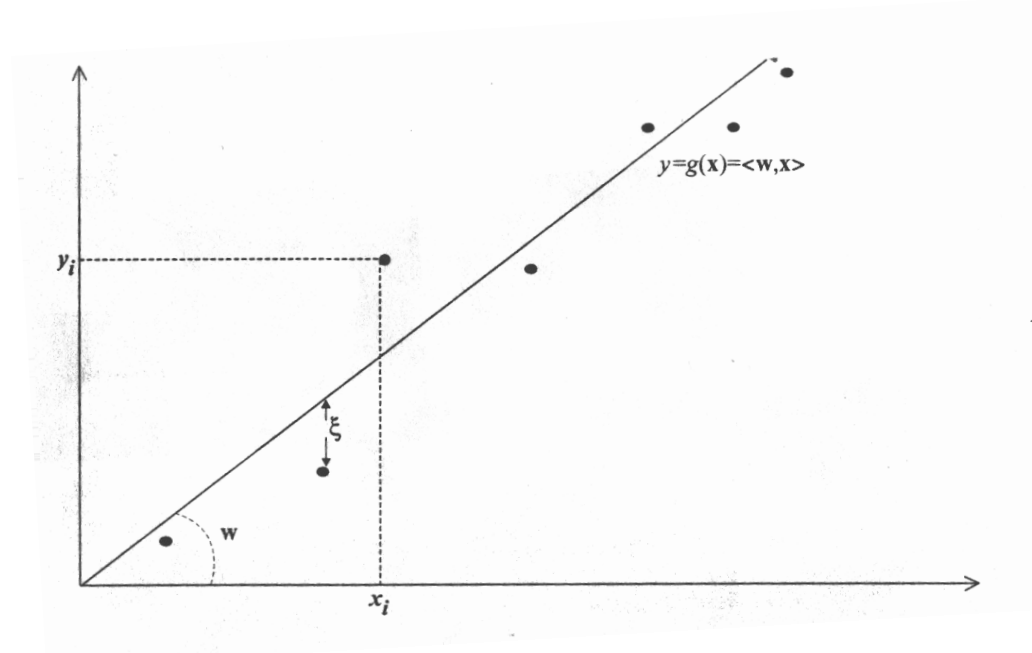
Γνωρίζουμε ότι οι αλγόριθμοι που έχουν αναπτυχθεί γύρω από τα προβλήματα κατηγοριοποίησης απαιτούν κατάλληλα δεδομένα. Άρα πρώτο μας μέλημα πριν αναπτύξουμε τις συναρτήσεις kernel είναι η αναφορά στο παραπάνω ζήτημα. Ως κατάλληλα, εννοούμε τα δεδομένα που μπορούν να χωριστούν σε δύο κατηγορίες γραμμικά. Αυτό επιτυγχάνεται μέσω κάποιας συνάρτησης απεικόνισης $\phi(x)$.

Ουσιαστικά αυτό που κάνουν οι συναρτήσεις απεικόνισης είναι να μεταφέρουν τα δεδομένα σε ένα νέο χώρο μετασχηματίζοντας τις συνιστώσες τους, καθώς μιλάμε για δεδομένα-διανύσματα. Ο μετασχηματισμός αυτός απεικονίζεται παρακάτω στο σχήμα 1.



Σχήμα 1

Από εδώ και πέρα έχουμε να κάνουμε με ένα κλασσικό ζήτημα γραμμικής παρεμβολής. Αναζητούμε ουσιαστικά την εξίσωση ενός υπερ-επιπέδου που να διαχωρίζει τα πολυδιάστατα δεδομένα μας όπως φαίνεται παρακάτω. Σε περιπτώσεις που συνυπάρχει θόρυβος προφανώς δεν πρέπει να απαιτήσουμε ακριβή πρότυπα. Τότε επιλέγουμε τα πρότυπα με το μικρότερο λάθος. Cohen et al. Taylor & Francis Group. Applied Multiple Regression/ Correlation Analysis for the Behavioural Sciences 3rd ed. (2003).



Σχήμα 2

Προφανώς το σύστημα μας έχει τώρα σαφώς πιο εύκολο έργο, την ανίχνευση γραμμικών προτύπων ενώ ταυτόχρονα οι αλγόριθμοι που έχουν αναπτυχθεί γύρω από γραμμικά προβλήματα είναι και πιο πολλοί και πιο κατανοητοί. Είμαστε τώρα σε θέση να προχωρήσουμε στην ανάπτυξη της συναρτήσεως kernel.

University of Texas at Arlington
<http://www.uta.edu/faculty/sawasthi/Statistics/stdiscan.html>

Παρακάτω συμβολίζουμε μαθηματικώς μια συνάρτηση kernel k , η οποία για τις συνιστώσες x, z που ανήκουν στον αρχικό χώρο, υπολογίζει τα εσωτερικά γινόμενα των μετασχηματισμένων πλέον δεδομένων $\varphi(x), \varphi(z)$ τα οποία είναι απαραίτητα για την υλοποίηση του αλγορίθμου.

Όμως στην περίπτωσή μας τα x, z που είναι τα δεδομένα μας είναι πίνακες με αριθμό γραμμών ίσο με το πλήθος των δειγμάτων και αριθμό στηλών ίσο με τις συνιστώσες τους (αφού πρόκειται για διανύσματα). Επομένως, υπολογίζοντας τα εσωτερικά γινόμενα για όλους τους δυνατούς συνδυασμούς των διανυσμάτων όλων των δειγμάτων προφανώς δημιουργείται ένας νέος πίνακας που ονομάζουμε πίνακα kernel (kernel matrix).

K	1	2	...	I
1	$K(X_1, X_1)$	$K(X_1, X_2)$...	$K(X_1, X_I)$
2	$K(X_2, X_1)$	$K(X_2, X_2)$...	$K(X_2, X_I)$
⋮	⋮	⋮	⋮	⋮
I	$K(X_I, X_1)$	$K(X_I, X_2)$...	$K(X_I, X_I)$

Πίνακας 1

Για παράδειγμα, το στοιχείο που βρίσκεται στην πρώτη γραμμή και δεύτερη στήλη $K(X_1, X_2)$, προέρχεται από τον υπολογισμό του εσωτερικού γινομένου των μετασχηματισμένων δεδομένων $\varphi(x_1)$, $\varphi(x_2)$. Αυτός ο πίνακας θα παίξει σημαντικότερο ρόλο και θα μπορούσαμε να τον αποκαλέσουμε πυρήνα των μεθόδων kernel καθώς «συνδέει» τα δεδομένα εισόδου με τους αλγορίθμους και επιπλέον περιέχει όλες τις απαιτούμενες πληροφορίες για τον αλγόριθμο.

Άλλη σημαντική ιδιότητά του είναι ότι είναι θετικά ημι-ορισμένος. Αυτό από τη μια εξασφαλίζει την ύπαρξη κάποιου χώρου απεικόνισης όπου είναι δυνατός ο γραμμικός διαχωρισμός των δεδομένων. Από την άλλη, η παραπάνω ιδιότητα επιτρέπει να χρησιμοποιούμε ως δεδομένα εισόδου πέρα από πραγματικά διανύσματα, σειρές χαρακτήρων (strings), εικόνες, χρονικές ακολουθίες κ.α. Και αυτό γιατί ο πίνακας kernel που θα υπολογιστεί με τα νέα δεδομένα θα εξακολουθεί να είναι θετικά ημι-ορισμένος. Και σε αυτές τις περιπτώσεις τα αρχικά δείγματα προβάλλονται πρώτα σε νέο χώρο όπου έχουν διαχωριστεί μεταξύ τους.

Χρειάζεται ωστόσο προσοχή στο σχηματισμό του πίνακα kernel. Αν αυτός είναι πολύ γενικός και δεν εστιάζει στην ιδιομορφία που παρουσιάζουν τα δεδομένα του κάθε προβλήματος, πολύ δύσκολα θα μπορέσει να οδηγηθεί στα πρότυπα, στις κανονικότητες που τα χαρακτηρίζουν. Έτσι ενώ θα μπορεί εύκολα να κατηγοριοποιήσει τα δείγματα προς εκπαίδευση θα αντιμετωπίζει σοβαρό πρόβλημα σε κάθε νέο δείγμα. Το φαινόμενο αυτό είναι γνωστό με το όνομα overfitting και όπως καταλαβαίνουμε θα πρέπει να αποφεύγεται. Από την άλλη, όταν η συνάρτηση kernel έχει επιλεγεί έτσι ώστε τα μετασχηματισμένα δεδομένα $\varphi(x)$ να είναι όμοια μεταξύ τους, η απεικόνισή τους στο νέο χώρο επικεντρώνεται γύρω από ένα σημείο. Τότε ο πίνακας kernel που θα σχηματιστεί θα έχει επίσης όλα του τα στοιχεία όμοια και θα είναι εξαιρετικά δύσκολο για τον αλγόριθμο να ανακαλύψει τα πρότυπα μεταξύ τους. Εδώ έχουμε να κάνουμε με το φαινόμενο του underfitting που είναι εξίσου ανεπιθύμητο. Γι' αυτόν ακριβώς το λόγο, όπως θα δούμε στην παρουσίαση των πειραμάτων παρακάτω, χρησιμοποιήσαμε περισσότερες από μία συναρτήσεις kernel καθώς κάθε φορά άλλη ήταν αυτή που εντόπιζε καλύτερα τα πρότυπα στα διαφορετικά δεδομένα και άρα έδινε το υψηλότερο ποσοστό επιτυχίας. (Cohen et al. Taylor & Francis Group. Applied Multiple Regression/ Correlation Analysis for the Behavioural Sciences 3rd ed. (2003).

Επιστρέφοντας στις συναρτήσεις kernel, σημαντικότερη ιδιότητά τους είναι ότι υπολογίζουν τα εσωτερικά γινόμενα χωρίς να χρειάζεται να γνωρίζουμε την φ . Ας το αποδείξουμε αυτό με ένα απλό παράδειγμα. Μια μορφή συνάρτησης Kernel είναι η πολυωνυμική. Θεωρούμε ένα διάνυσμα $\mathbf{X} = (X_1, X_2)$ που ανήκει στο διδιάστατο χώρο και του εφαρμόζουμε μια συνάρτηση απεικόνισης φ όπου:

$$\begin{aligned}\Phi : X = (X_1, X_2) &\longrightarrow \Phi(X) = [(X_1^2, X_2^2, \sqrt{2}X_1 X_2), (Z_1^2, Z_2^2, \sqrt{2} Z_1 Z_2)] \\ &= X_1^2 Z_1^2 + X_2^2 Z_2^2 + 2 X_1 X_2 Z_1 Z_2 \\ &= (X_1 Z_1 + X_2 Z_2)^2 \\ &(X, Z)^2 \qquad \qquad \qquad 4.1)\end{aligned}$$

$$\text{Επομένως } K(x, z) = \langle \varphi(x), \varphi(z) \rangle = \langle x, z \rangle^2 \qquad \qquad \qquad 4.2)$$

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Βλέπουμε λοιπόν ότι για τον υπολογισμό της συνάρτησης kernel δε χρειάζεται να γνωρίζουμε τη συνάρτηση απεικόνισης ϕ όπως είχαμε αναφέρει και παραπάνω, μας ενδιαφέρει μόνο ο υπολογισμός του εσωτερικού γινομένου, γεγονός που διευκολύνει πολύ την υλοποίηση της μεθόδου. Εξάλλου στο παραπάνω παράδειγμα έχουμε μεταφορά σε νέο χώρο μεγαλύτερης διάστασης. Αυτό είναι επιθυμητό γιατί διευκολύνει την αναζήτηση της διαχωριστικής ευθείας, υπερ-επιπέδου γενικότερα. Στο διδιάστατο επίπεδο είναι αδύνατος ο γραμμικός διαχωρισμός τους. Αντίθετα, μεταφέροντάς τα σε χώρο τριών διαστάσεων χρωματίζουμε μία από τις πάρα πολλές λύσεις που επιλύουν πλέον το πρόβλημά μας. (J.V. Vapnik, Statistical Learning Theory, J. Wiley & Sons, Inc., New York, NY 1998.)

Πόσες όμως είναι συνολικά οι συναρτήσεις αυτές και ποιες θα χρησιμοποιήσουμε εμείς στα πειράματά μας; Με βάση τις ιδιότητές τους είναι δυνατόν από κάθε απλή συνάρτηση να δημιουργήσουμε πολλές άλλες, νέες.

$$\begin{aligned} & \square \square k(x, z) \quad \square \square \square k_1(x, z) \quad \square \square k_2(x, z) \\ & \square \square k(x, z) \quad \square \square \square a \cdot k_1(x, z) \\ & \square \square k(x, z) \quad \square \square \square k_1(x, z) \quad \square \square k_2(x, z) \\ & \square \square k(x, z) \quad \square \square \square f(x) \quad \square \square f(z) \\ & \square \square k(x, z) \quad \square \square \square \square k_3(\phi(x), \phi(z)) \\ & \square \square k(x, z) \quad \square \square \square \square x' \square B \quad \square \square z \end{aligned}$$

όπου:

K_1 και K_2 είναι συναρτήσεις kernel σε ένα χώρο X , $X \in \mathbb{R}^n$

$a \in \mathbb{R}^+$

$f(\cdot)$ είναι μια πραγματική συνάρτηση στο X

$\phi: X \rightarrow \mathbb{R}^N$,

K_3 μία συνάρτηση Kernel στο χώρο \mathbb{R}^N

B ένας συμμετρικός θετικά ημι-ορισμένος πίνακας $n \times n$

Από τις παραπάνω ιδιότητες προκύπτουν ακόμα τρεις, εξίσου σημαντικές για την κατασκευή καινούργιων συναρτήσεων kernel, οι ακόλουθες:

$$\square \square k(x, z) \quad \square \square p(k_1(x, z))$$

$$\square \square k(x, z) = \exp(k_1(x, z))$$

$$\triangleright k(x, z) = \exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right)$$

Όπου:

k_1 μία συνάρτηση kernel στο χώρο X

$x, z \in X$

$p(x)$ μία πολωνυμική συνάρτηση με θετικούς συντελεστές.

Εμείς για τη διεκπεραίωση των πειραμάτων μας χρησιμοποιήσαμε τέσσερις διαφορετικές συναρτήσεις kernel, την πολωνυμική, την εκθετική, την Gaussian και τη γραμμική. Ας δούμε όμως καθεμία αναλυτικά.

Πολωνυμική:

$$k(x, z) = \sum_{i=0}^n (x_i z_i)^2$$

Εκθετική:

$$k(x, z) = \sum_{i=0}^n e^{(x_i z_i)^2}$$

Η εκθετική προκύπτει από την πολωνυμική σύμφωνα με τις παραπάνω ιδιότητες.

Gaussian:

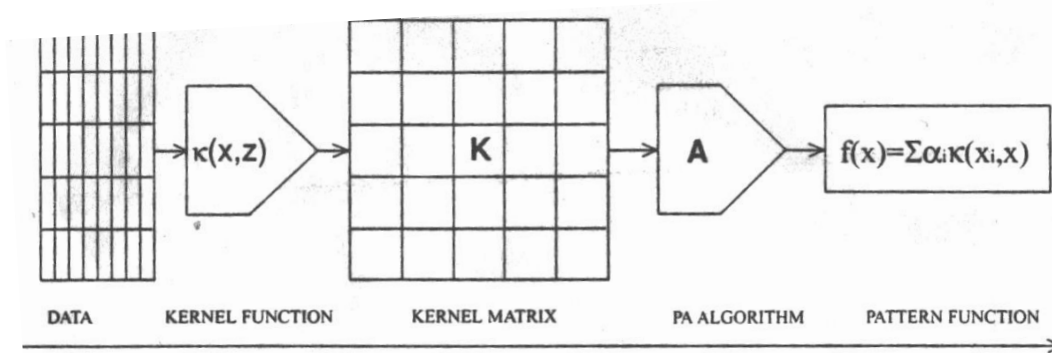
$$k(x, z) = \exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right)$$

Γραμμική:

$$k(x, z) = \sum_{i=0}^n x_i z_i$$

Η γραμμική συνάρτηση kernel ουσιαστικά δεν έχει κανένα νόημα ύπαρξης καθώς λόγω της γραμμικότητας της, δεν λαμβάνει χώρα η απεικόνιση των δεδομένων σε κάποιον καινούργιο χώρο μεγαλύτερης διάστασης. Όμως εμείς χρειάστηκε να την χρησιμοποιήσουμε στην περίπτωση των πειραμάτων Iris όπου κάποιες από τις κατηγορίες ήταν από την αρχή γραμμικώς διαχωριζόμενες και δεν απαιτούσαν το μετασχηματισμό τους. Αντιθέτως μάλιστα σε τέτοια περίπτωση τα αποτελέσματα δεν ήταν καθόλου ικανοποιητικά. Για το λόγο αυτό και για να μη χρειαστεί να γράψουμε καινούργιο κώδικα, καθώς ο ήδη υπάρχων περιείχε τη συνάρτηση kernel, καταφύγαμε στη λύση της γραμμικής.

Συνοψίζοντας όλα τα παραπάνω καταλήγουμε στο σχήμα που ακολουθεί και που παρουσιάζει βήμα προς βήμα τη μέθοδο kernel με σκοπό την «εκμάθηση» του συστήματος.



Σχήμα 3

Τα δεδομένα δίνονται σε μορφή πινάκων καθώς είναι πολυδιάστατοι αριθμοί. Κατόπιν, εφαρμόζουμε σε αυτά τη συνάρτηση kernel που έχουμε επιλέξει δημιουργώντας έτσι τον πίνακα kernel, ο οποίος με τη σειρά του είναι απαραίτητος για τη λειτουργία του αλγορίθμου που εφαρμόζεται για την ανάλυση προτύπων και ο οποίος θα μας δώσει ως αποτέλεσμα μία συνάρτηση f . Η συνάρτηση αυτή επεξεργάζεται νέα και άγνωστα προς εμάς δεδομένα και τα κατηγοριοποιεί. Η σωστή ή όχι κατηγοριοποίησή τους κρίνει ουσιαστικά την αποτελεσματικότητα του αλγορίθμου και της μεθόδου γενικότερα.

http://www.eng.ucy.ac.cy/gmitsis/ece795/lectures/ECE795_Lectures19_20_2012.pdf

4.1.4 Μετατροπή των αλγορίθμων σε μεθόδους πυρήνα

Οι μέθοδοι πυρήνα (kernel methods), χαρακτηριστικό παράδειγμα των οποίων είναι ο αλγόριθμος kernel PCA, είναι υπολογιστικώς αποτελεσματικές επειδή έχουν εγγενώς την δυνατότητα να συνυπολογίζουν συγκεκριμένες πληροφορίες υψηλότερης τάξης που περιέχονται στα δεδομένα εισόδου. Ωστόσο, αυτές οι μέθοδοι υπόκεινται συνήθως από την λεγόμενη κατάρρα της διαστατικότητας, πράγμα που σημαίνει ότι η υπολογιστική πολυπλοκότητά τους αυξάνεται εκθετικά με τη γραμμικά αυξανόμενη διαστατικότητα του χώρου δεδομένων εισόδου.

Σκεφτείτε, για παράδειγμα, το πρόβλημα της αποθρομβοποίησης εικόνων. Δυστυχώς, η υπολογιστική πολυπλοκότητα της αρχικής μορφής του kernel περιορίζει δραστικά την δυνατότητα εφαρμογής του σε εικόνες του πραγματικού κόσμου (πχ, πρόσωπα και φυσικές σκηνές). Ωστόσο, μετατρέποντας σε μέθοδο πυρήνα (kernelization) τον γενικευμένο αλγόριθμο GHA, αποκτάμε έναν επαναληπτικό αλγόριθμο μη επιβλεπόμενης μάθησης ικανό να υπολογίζει τις κύριες συνιστώσεις με γραμμική μόνο υπολογιστική πολυπλοκότητα. Εξίσου σημαντικό είναι το γεγονός ότι η απόδοση του αλγορίθμου στην αποθρομβοποίηση εικόνων είναι συγκρίσιμη με αυτή των αλγορίθμων επιβλεπόμενης μάθησης που χρησιμοποιούνται σήμερα. Μπορούμε λοιπόν να πούμε ότι μέσω της μετατροπής ενός επαναληπτικού αλγορίθμου PCA σε μέθοδο πυρήνα, όχι μόνο παρακάμπτουμε το πρόβλημα της διαστατικότητας με κάποιο μετρήσιμο τρόπο, αλλά επίσης λύνουμε το πρόβλημα της αποθρομβοποίησης εικόνων με χρήση μόνο μη χαρακτηρισμένων παραδειγμάτων.

Το δίδαγμα που μπορούμε να αποκομίσουμε από αυτήν την συζήτηση είναι σημαντικό.

Έχουμε ακόμα πολλά να κερδίσουμε από το kernelization (που εδράζεται στη στατιστική θεωρία μάθησης) των νευροβιολογικής προέλευσης αλγορίθμων μη επιβλεπόμενης μάθησης

4.2 Support Vector Machines (Μηχανές Διανυσμάτων Υποστήριξης)

4.2.1 Ορισμός

Μηχανή διανυσμάτων υποστήριξης καλούμε μια δυαδική μηχανή με δυνατότητα μάθησης, η οποία επιδεικνύει ορισμένες εξαιρετικά κομψές ιδιότητες. Για να κατανοήσουμε καλύτερα πως δουλεύει μια τέτοια μηχανή, θα ήταν ευκολότερο να ξεκινήσουμε από την περίπτωση των διαχωρισμών προτύπων, όπως προκύπτει στο πλαίσιο της ταξινόμησης προτύπων. Η κεντρική ιδέα πίσω απ'την μηχανή μπορεί να συνοψιστεί ως εξής

Δοθέντος ενός δείγματος εκπαίδευσης, η μηχανή διανυσμάτων υποστήριξης κατασκευάζει ένα υπερεπίπεδο ως επιφάνεια απόφασης με τρόπο ώστε το περιθώριο διαχωρισμού μεταξύ θετικών και αρνητικών παραδειγμάτων να μεγιστοποιείται.

Αυτή η βασική ιδέα επεκτείνεται θεωρητικά ώστε να καλύπτει και την πιο δύσκολη περίπτωση των μη γραμμικά διαχωρίσιμων προτύπων.

Μια ιδέα η οποία είναι θεμελιώδης για την ανάπτυξη του αλγορίθμου μάθησης της μηχανής διανυσμάτων υποστήριξης είναι ο *πυρήνας εσωτερικού γινομένου* (*inner product kernel*) μεταξύ ενός «διανύσματος υποστήριξης» κι ενός διανύσματος το οποίο εξαντλείται από το χώρο δεδομένων εισόδου. Το σημαντικότερο όλων είναι ότι τα διανύσματα υποστήριξης αποτελούνται από ένα μικρό υποσύνολο σημείων δεδομένων τα οποία εξάγει ο αλγόριθμος μάθησης από το ίδιο το δείγμα εκπαίδευσης. Στην πραγματικότητα, λόγω αυτής της σημαντικής ιδιότητας ο αλγόριθμος μάθησης που εμπλέκεται στην κατασκευή μιας μηχανής διανυσμάτων υποστήριξης αναφέρεται επίσης ως *μέθοδος πυρήνα*. Η μέθοδος πυρήνα πυρήνα που παίζει βασικό ρόλο στην σχεδίαση μιας μηχανής διανυσμάτων υποστήριξης είναι *βέλτιστη*, με την βελτιστότητα της να οφείλεται στην αποκαλούμενη *κυρή βελτιστοποίηση*. Ωστόσο αυτό το εξαιρετικά επιθυμητό χαρακτηριστικό της μηχανής αυτής επιτυγχάνεται με αντίτιμο την αυξημένη υπολογιστική πολυπλοκότητα.

Όσον αφορά τις διαδικασίες σχεδίασης, η μηχανή διανυσμάτων υποστήριξης μπορεί να χρησιμοποιείται για την επίλυση και των δύο τύπων προβλημάτων (ταξινόμησης μοτίβων και μη γραμμικής παλινδρόμησης). Ωστόσο, ο τομέας της επίλυσης δύσκολων προβλημάτων ταξινόμησης προτύπων είναι αυτός που οφείλεται περισσότερο από τις μηχανές διανυσμάτων υποστήριξης.

4.3 Αλγόριθμος κατηγοριοποίησης δεδομένων

Στο κεφάλαιο αυτό θα παρουσιάσουμε αναλυτικά τον αλγόριθμο τον οποίο χρησιμοποιήσαμε για να δούμε την πρακτική εφαρμογή της μεθόδου των Support Vector Machines σε προβλήματα κατηγοριοποίησης. Όσο αυτός «εργάζεται» θα αναζητά ομοιότητες, σχέσεις ή διαφορές μεταξύ των δεδομένων μας, θα εκπαιδευτεί

ουσιαστικά από αυτά, θα «μάθει» μέσα από τα δοθέντα δεδομένα. Πώς λειτουργεί τί, πού ανήκει τί, πώς συνδέεται τί.

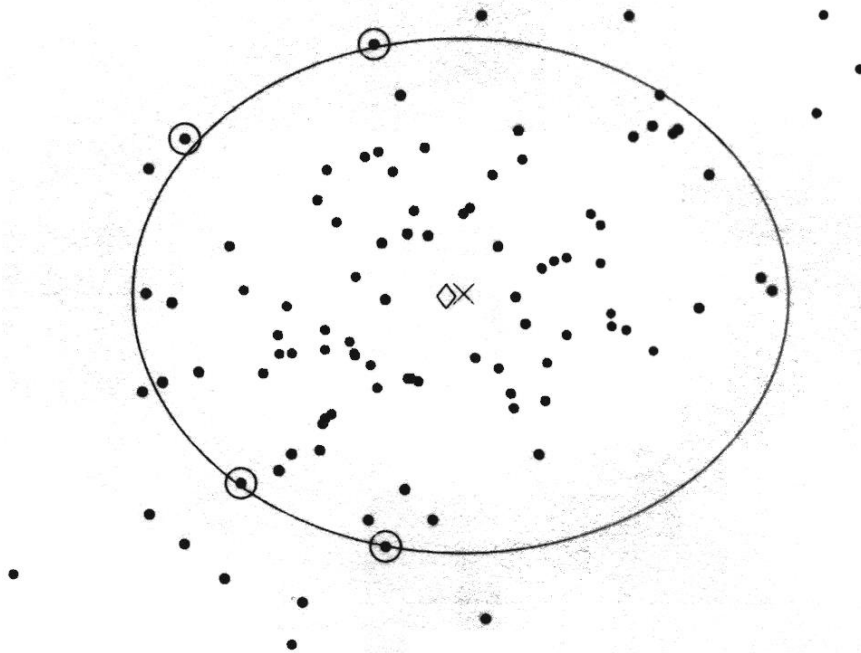
Αρχικά όμως θα αναφερθούμε σε αλγορίθμους που αφορούν μια άλλη κατηγορία ανάλυσης προτύπων γνωστή με την ονομασία novelty-detection (ανίχνευση καινοτομίας) κι αυτό γιατί αποτέλεσαν τη βάση για να προκύψει ο προαναφερθής αλγόριθμος. Στόχος μας στα προβλήματα αυτά είναι η εύρεση της ελάχιστης δυνατής υπερσφαίρας η οποία θα περιέχει τα δεδομένα προς εκπαίδευση. Το γεγονός αυτό σε συνδυασμό και με τη χρήση του αλγορίθμου καθιστά δυνατή την ανίχνευση ανώμαλων σημείων, σημείων δηλαδή εκτός αυτής της υπερσφαίρας (novel detection). Πιο συγκεκριμένα, ο αλγόριθμος αυτός χρησιμοποιεί ένα set δεδομένων (training data) για να «μάθει» το σύστημα τον τρόπο διασύνδεσης των δειγμάτων που μπορούν να προκύψουν από μια πηγή, στην περίπτωση μας, κατανομή. Στη συνέχεια τα μελλοντικά δείγματα που θα έχουμε θα φιλτράρονται από την συνάρτηση προτύπων που θα έχουμε δημιουργήσει στο τέλος του αλγορίθμου και θα ανιχνεύεται ποια από αυτά είναι ανώμαλα, ποια δηλαδή έχουν παραχθεί από διαφορετική κατανομή. Προφανώς όσο μικρότερη θα είναι η υπερσφαίρα αυτή που περικλείει τα δεδομένα εκπαίδευσης τόσο πιο λεπτομερής και ακριβής θα είναι η διαδικασία της ανίχνευσης. Ταυτόχρονα όμως θέλουμε να περικλείει και όσο το δυνατόν περισσότερα δεδομένα εκπαίδευσης. Ο συνδυασμός των δύο αυτών παραμέτρων αποτελεί και το βασικό σκοπό των αλγορίθμων που αναπτύχθηκαν. Κέντρο αυτής της υπερσφαίρας θεωρήθηκε το κέντρο μάζας των σημείων που θα περικλείει ή κάποιο άλλο σημείο κοντά σ' αυτό. Θεωρώντας το κέντρο της υπερσφαίρας μετακινήσιμο, είναι πολύ πιθανή η εύρεση μικρότερης υπερσφαίρας με όλα τα training data στο εσωτερικό της. Στην περίπτωση βέβαια όπου ένα μεμονωμένο σημείο επιβάλλει μια μεγαλύτερη ακτίνα καθιστώντας έτσι το σύστημα «εύθραυστο» προτιμούμε να εξαιρέσουμε το σημείο αυτό έχοντας και πάλι τη μικρότερη υπερσφαίρα. (A. Shigeo *Support Vector Machines for Pattern Classification*, Springer 2005)

Ας θεωρήσουμε τώρα ένα set δεδομένων $S=\{x_1, \dots, x_n\}$ το οποίο θα υποστεί κάποια απεικόνιση ϕ σε ένα νέο χώρο μέσω της συνάρτησης kernel:

Το κέντρο της μικρότερης υπερσφαίρας που θα περικλείει το σύνολο σημείων S είναι κάποιο σημείο c που ελαχιστοποιεί την απόσταση r από το μακρύτερο σημείο που ανήκει στο S , δηλαδή:

$$c = \operatorname{argminmax} \|\phi(x_i) - c\| \quad 4.3)$$

Για να υπολογίσουμε το c που ζητάμε στη εξ4.3 πρέπει να λύσουμε το παραπάνω πρόβλημα βελτιστοποίησης λαμβάνοντας υπόψη και τους περιορισμούς που υπάρχουν. Αυτό επιτυγχάνεται με τη χρήση των τελεστών Lagrange. Αν έρθουμε τώρα να εφαρμόσουμε τα παραπάνω σε αριθμούς μιας κατανομής Gauss για παράδειγμα, θα δούμε ότι το κέντρο που υπολογίζει το πρόβλημα βελτιστοποίησης βρίσκεται πολύ κοντά με αυτό της κατανομής, γεγονός που υποδηλώνει την επιτυχία του. Αυτό απεικονίζεται στο παρακάτω σχήμα όπου με το σχήμα του ρόμβου συμβολίζουμε το κέντρο της κατανομής Gauss, ενώ με το «x» το βέλτιστο κέντρο c^* .



Σχήμα 4

Λύνοντας μαθηματικά το πρόβλημα της βελτιστοποίησης καταλήγουμε σε κάποιον αλγόριθμο. Σημαντικό ρόλο σε όλη αυτή τη διαδικασία παίζουν οι πολλαπλασιαστές Lagrange που συμβολίζονται με a_i για και ικανοποιούν την παρακάτω σχέση:

$$a_i \cdot \|\varphi(x_i) - c\|^2 - r^2 = 0 \quad 4.4)$$

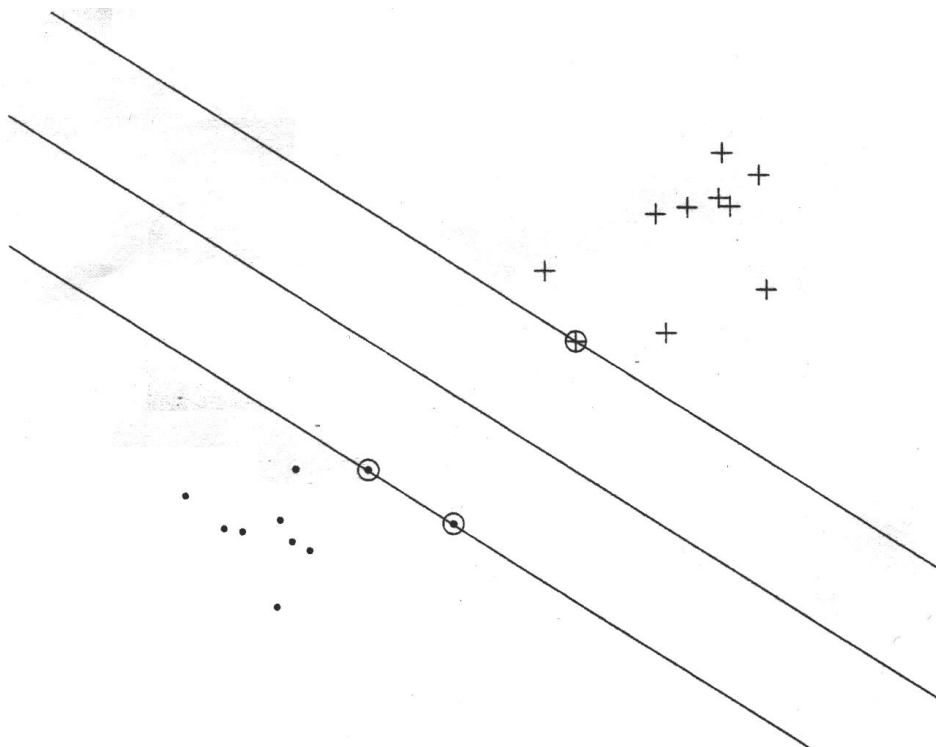
Από τη σχέση 4.4 προκύπτει ότι τα δείγματα x_i των οποίων τα αντίστοιχα i είναι διάφορα του μηδενός, μηδενίζουν το περιεχόμενο της αγκύλης, έχουν ακτίνα r και άρα βρίσκονται πάνω στην υπερσφαίρα. Τα δείγματα αυτά είναι τα ζητούμενα για την υλοποίηση του αλγορίθμου, είναι κυκλωμένα στο σχήμα και ονομάζονται *support vectors*. Άλλωστε είναι αυτά που έδωσαν το όνομά τους στον αλγόριθμο-μηχανή και τον αποκαλούμε Support Vector Machine.

Είναι σημαντικό να αναφέρουμε εδώ ότι η υπερσφαίρα αυτή σχηματίζεται από τα μετασχηματισμένα δεδομένα x_i στα οποία εφαρμόζεται πρώτα η συνάρτηση kernel. Στο τέλος του εκάστοτε αλγορίθμου υπολογίζεται μια συνάρτηση f η οποία παίρνει την τιμή 1 για κάθε νέο σημείο (test set) που βρίσκεται εκτός της υπερσφαίρας και άρα θεωρείται ανώμαλο (novel) και την τιμή 0 για αυτά που βρίσκονται εντός της υπερσφαίρας. (V. P. Oikonomou, A. T. Tzallas, D. I. Fotiadis, "A Kalman filter based methodology for EEG spike enhancement", *Computer methods and programs in biomedicine* 85 (2007))

Με βάση τη λογική που παρουσιάσαμε στο προηγούμενο πρόβλημα περνάμε σ' αυτό, της κατηγοριοποίησης, του οποίου η επίλυση με τη μέθοδο των SVM αποτελεί ένα καθοριστικό ζήτημα. Αντίστοιχα με την υπερσφαίρα που πριν αποτελούσε το κριτήριο για το αν κάποιο δεδομένο προέρχεται από την πηγή που τη δημιούργησε ή όχι, εδώ πλέον ψάχνουμε να βρούμε τη συνάρτηση μιας ευθείας

γραμμής που διαχωρίζει τα δεδομένα στις δύο κατηγορίες από τις οποίες αυτά προέρχονται.

Είναι βασικό τα δεδομένα που έχουμε για την εκπαίδευση του συστήματος να είναι γραμμικώς διαχωριζόμενα γιατί μόνο έτσι λειτουργούν οι αλγόριθμοι που έχουν αναπτυχθεί. Γι' αυτόν ακριβώς το λόγο χρησιμοποιούμε τις συναρτήσεις kernel που μετασχηματίζουν κάποια μη γραμμικώς διαχωριζόμενα δεδομένα σε γραμμικώς διαχωριζόμενα μεταφέροντάς τα σε έναν καινούργιο χώρο.



Σχήμα 5

Η σταθερότητα του αλγορίθμου είναι δεδομένη εάν το περιθώριο γ είναι αρκετά μεγάλο. Όμως, κάτι τέτοιο δεν μας εγγυάται απαραίτητα και την ευρρωστία του (robustness). Δηλαδή θα μπορούσε πολύ εύκολα ένα επιπλέον σημείο από το training set να μειώσει την τιμή του γ καθιστώντας τα δεδομένα ακόμα και μη διαχωρίσιμα. Έτσι σκοπός μας είναι να βρούμε μια γραμμική συνάρτηση η οποία θα μεγιστοποιεί το περιθώριο γ . Η συνάρτηση αυτή ονομάζεται *hard margin support vector machine*. A. Shigeo Support Vector Machines for Pattern Classification, Springer 2005

Το πρόβλημα αυτό της μεγιστοποίησης του γ το αντιμετωπίζουμε μαθηματικά όπως ακριβώς και προηγουμένως χρησιμοποιώντας τους τελεστές Lagrange. Έτσι προκύπτει, στον πίνακα 2 ο παρακάτω αλγόριθμος που είναι γνωστός ως *Hard margin SVM*.

Mohammed J. Zaki, Wagner Meira Jr, "Data Mining and Analysis: Fundamental Concepts and Algorithms", Cambridge University Press, 2014

Είσοδος	Training set $s=\{(x_1,y_1),\dots,(x_l,y_l)\}$, $d > 0$
Διαδικασία βελτιστοποίησης με περιορισμούς	Βρείτε την λύση a του προβλήματος βελτιστοποίησης $W(a) = - \sum_{i,j=1}^l a_i a_j y_i y_j k(x_i, x_j)$ $\sum_{i=1}^l y_i a_i = 0, \sum_{i=1}^l a_i = 1 \text{ και } 0 \leq a_i, i=1,\dots,l$
4	$\gamma = \sqrt{-W(a)}$
5	επιλέξτε i έτσι ώστε $0 < a_i$
6	$b = y_i (\gamma)^2 - \sum_{j=1}^l a_j y_j k(x_i, x_j)$
7	$f(\cdot) = \text{sgn} \left(\sum_{j=1}^l a_j y_j k(x_j, \cdot) + b \right)$;
8	$w = \sum_{j=1}^l y_j a_j \phi(x_j)$
Έξοδος	Διάνυσμα βαρών w, βέλτιστη λύση a , περιθώριο γ και συνάρτηση f που υλοποιεί την κατηγοριοποίηση με βάση το υπέρ-επίπεδο.

Πίνακας 2

Ακολουθώντας τα βήματα του αλγορίθμου υπολογίζουμε αρχικά το διάνυσμα a που μεγιστοποιεί τη συνάρτηση $W(a)$ και άρα και το περιθώριο γ . Οι συνιστώσες του διανύσματος a είναι μη μηδενικές μόνο για εκείνα τα x_i από το training set τα οποία απέχουν από το υπερεπίπεδο που διαχωρίζει τις δύο κατηγορίες απόσταση γ .

Ο αλγόριθμος Hard SVM που περιγράψαμε μπορεί να εφαρμοστεί με επιτυχία μόνο όταν τα δεδομένα είναι εύκολα διαχωρίσιμα. Αντιμετωπίζει όμως σοβαρά προβλήματα όταν τα δεδομένα περιέχουν και θόρυβο που είναι και η πιο συνηθισμένη κατάσταση σε πραγματικά προβλήματα. Για το λόγο αυτό αναπτύχθηκε ένας άλλος αλγόριθμος που ονομάζεται Soft margin SVM και ακριβώς επειδή έχει σαφώς καλύτερα αποτελέσματα στα προβλήματα κατηγοριοποίησης από τον Hard είναι και αυτός που χρησιμοποιήσαμε στα πειράματά μας. Ο αλγόριθμος αυτός είναι πιο εύρωστος από τον προηγούμενο και έτσι μπορεί να ανέχεται κάποιο θόρυβο καθώς και μεμονωμένα δεδομένα απομακρυσμένα από το σύνολο χωρίς να αλλάζει σημαντικά το αποτέλεσμα.

4.4. Θεώρημα Representer

Για την καλύτερη κατανόηση των μηχανών πυρήνα συμπεριλαμβανομένων των διανυσμάτων υποστήριξης θα περιγράψουμε το θεμελιώδες θεώρημα Representer. Ορίζουμε ένα χώρο H ως τον RKHS (Reproducing Kernel Hilbert Space) που δημιουργείται από έναν πυρήνα Mercer $k(x, \cdot)$. Δοθείσης οποιασδήποτε πραγματικής συνάρτησης $f(\cdot)$ μπορούμε να την αναλύσουμε στο άθροισμα δύο συνιστωσών, αμφοτέρες εκ των οποίων βρίσκονται φυσικά στο χώρο H . (Haykin, Simon)

- Η μια συνιστώσα περιέχεται στην έκταση των συναρτήσεων πυρήνα $k(x_1, \cdot), k(x_2, \cdot), \dots, k(x_i, \cdot)$ συμβολίζοντας την ως $f_{\parallel}(x)$, μπορούμε να χρησιμοποιήσουμε την εξίσωση $f(\cdot) = \sum_{i=1}^I a_i k(x_i, \cdot)$ για να την αναπαραστήσουμε ως.

$$f_{\parallel}(\cdot) = \sum_{i=1}^I a_i k(x_i, \cdot) \quad 4.5)$$

- Η δεύτερη συνιστώσα είναι ορθογώνια ως προς την έκταση (span) των συναρτήσεων πυρήνα συμβολίζεται ως $f_{\perp}(x)$.

Μπορούμε τώρα να εκφράσουμε την συνάρτηση $f(\cdot)$ ως

$$f(\cdot) = f_{\parallel}(\cdot) + f_{\perp}(\cdot) \quad 4.6)$$

$$= \sum_{i=1}^I a_i k(x_i, \cdot) + f_{\perp}(\cdot)$$

Εφαρμόζοντας την ιδιότητα κλιμάκωσης κατανομής σύμφωνα με την οποία *για οποιοδήποτε ζεύγος σταθερών c και d και οποιαδήποτε σύνολο συναρτήσεων f, g και h στο χώρο H ισχύει*

$$\langle cf + dg, h \rangle = c \langle f, h \rangle + d \langle g, h \rangle \quad 4.7)$$

Καθώς επίσης την ιδιότητα του τετραγώνου νόρμας σύμφωνα με την οποία *για οποιαδήποτε πραγματική συνάρτηση f στο χώρο H , εάν υπολογίσουμε την εξίσωση*

$$\langle f, g \rangle = \sum_{i=1}^I \sum_{j=1}^n a_i k(x_i, x_j) b_j = \quad 4.8)$$

$$= a^T K b$$

μόνο για την f , παίρνουμε το τετράγωνο της νόρμας ή δευτεροβάθμια μητρική

$$\|f\|^2 = \langle f, f \rangle = a^T K a \quad 4.9)$$

Εφόσον ο πίνακας Gram είναι μη-αρνητικά ορισμένος, το τετράγωνο της νόρμας έχει την ιδιότητα $\|f\|^2 \geq 0$

Παίρνουμε $f(x_j) = \langle f(\cdot), k(x_j, \cdot) \rangle_H$

$$\langle \sum_{i=1}^I \mathbf{a}_i \mathbf{k}(\mathbf{x}_i, \cdot), \mathbf{k}(\mathbf{x}_j, \cdot) \rangle_H + \langle \mathbf{k}(\mathbf{x}_j, \cdot), \mathbf{f} \rangle_H \quad (4.10)$$

Εφόσον η $\mathbf{f} \perp$ είναι ορθογώνια ως προς την έκταση των συναρτησέων πυρήνα, ο δεύτερος όρος είναι μηδέν, άρα αυτή η εξίσωση απλοποιείται στην

$$\begin{aligned} \mathbf{f}(\mathbf{x}_j) &= \left\langle \sum_{i=1}^I \mathbf{a}_i \mathbf{k}(\mathbf{x}_i, \cdot), \mathbf{k}(\mathbf{x}_j, \cdot) \right\rangle_H \\ &= \sum_{i=1}^I \mathbf{a}_i(\mathbf{x}_i, \mathbf{x}_j) \end{aligned} \quad (4.11)$$

Η εξίσωση 4.11 που προέκυψε αποτελεί την μαθηματική διατύπωση του θεωρήματος Representer.

Οποιαδήποτε συνάρτηση ορισμένη σ'έναν χώρο RKHS μπορεί να αναπαρασταθεί ως ένας γραμμικός συνδυασμός συναρτήσεων πυρήνα Mercer.

<http://www.gatsby.ucl.ac.uk/~gretton/coursefiles/Slides5A.pdf>

4.4.1 Γενικευμένη εφαρμοστικότητα του θεωρήματος Representer

Μια σημαντική ιδιότητα του θεωρήματος Representer είναι ότι το ανάπτυγμα που δόθηκε στην εξίσωση

$$\begin{aligned} \mathbf{f}(\mathbf{x}_j) &= \left\langle \sum_{i=1}^I \mathbf{a}_i \mathbf{k}(\mathbf{x}_i, \cdot), \mathbf{k}(\mathbf{x}_j, \cdot) \right\rangle_H \\ &= \sum_{i=1}^I \mathbf{a}_i(\mathbf{x}_i, \mathbf{x}_j) \end{aligned} \quad (4.12)$$

Είναι ο ελαχιστοποιητής του εμπειρικού ρίσκου (συνάρτηση κόστους)

$$f = \frac{1}{2N} \sum_{n=1}^N (d(n) - f(x(n)))^2 + \Omega(\|f\|_H) \quad (4.13)$$

όπου $\{x(n), d(n)\}_{n=1}^N$ είναι το δείγμα εκπαίδευσης, f η άγνωστη, προς εκτίμηση, συνάρτηση και $\Omega(\|f\|_H)$ είναι η συνάρτηση ομαλοποίησης. Για να ισχύει το θεώρημα, η συνάρτηση ομαλοποίησης πρέπει να είναι μια αυστηρά μονοτονικά αύξουσα συνάρτηση του ορίσματος της. Από εδώ και στο εξής η απαίτηση αυτή θα αναφέρεται ως *συνθήκη μονοτονικότητας*. Ο όρος

$$\frac{1}{2N} \sum_{n=1}^N (d(n) - f(x(n)))^2 \quad (4.14)$$

της εξίσωσης 4.13 είναι ο στανταρ όρος σφάλματος, ο οποίος είναι μια δευτεροβάθμια συνάρτηση στο f . Άρα, το ανάπτυγμα της εξίσωσης 4.5 είναι ο ελαχιστοποιητής αυτού του όρου. Για να αποδείξουμε ότι αυτό το ανάπτυγμα είναι επίσης ο ελαχιστοποιητής του ομαλοποιημένου μέρους του εμπειρικού ρίσκου ακολουθούμε τα εξής βήματα.

1. Έστω ότι $\mathbf{f} \perp$ συμβολίζει το ορθογώνιο συμπλήρωμα ως προς την έκταση των συναρτήσεων πυρήνα. Τότε, επειδή σύμφωνα με την εξ 4.6 κάθε

συνάρτηση μπορεί να εκφραστεί ως ανάπτυγμα πυρήνα επί των δεδομένων της εκπαίδευσης συν το \mathbf{f}^\perp , μπορούμε να γράψουμε

$$\Omega (\|\mathbf{f}\|_{\mathbf{H}}) = \Omega (\|\sum_{i=1}^I \alpha_i \mathbf{k}(\mathbf{x}_i, \cdot) + \mathbf{f}^\perp\|_{\mathbf{H}}) \quad 4.15)$$

<http://arxiv.org/pdf/1109.2088v1.pdf>

Κεφάλαιο 5

5. Φίλτρα Kalman

5.1 Εισαγωγή

Το φίλτρο Kalman είναι ένας αλγόριθμος ο οποίος λειτουργεί αναδρομικά με θορυβώδη ρεύματα σαν είσοδο για να παράγει μια βέλτιστη εκτίμηση της υποκείμενης κατάστασης του συστήματος *απαλλάσσοντας τις μετρήσεις από ανεπιθύμητο θόρυβο*. Το φίλτρο πήρε το όνομα του από τον Ρούντολφ Ε. Kalman, έναν από τους κύριους δημιουργούς της θεωρίας του. Το φίλτρο Kalman έχει πολλές εφαρμογές στην τεχνολογία όπως στην καθοδήγηση, την πλοήγηση και έλεγχο οχημάτων, αεροσκαφών και διαστημόπλοιων. Οι αισθητήρες χρησιμοποιούνται για να πέρνουν μετρήσεις της κατάστασης του συστήματος (θέση και ταχύτητα στην περίπτωση ενός οχήματος) αλλά πολλές φορές αλλοιώνονται με κάποιο ποσό σφάλματος, συμπεριλαμβανομένων τυχαίο θόρυβο. Η βασική ιδέα είναι παρόμοια με την μαθηματική ταύτιση σημείων της καμπύλης δεδομένων χρησιμοποιώντας μια προσέγγιση ελάχιστων τετραγώνων επιτρέποντας προβλέψεις για μελλοντικά βήματα. Οι πιο βασικές έννοιες των φίλτρων σχετίζονται με την έννοια της *παρεμβολής* (όταν οι προβλέψεις δεδομένων συμπληρώνονται μεταξύ δοθέντων σημείων) και την έννοια της *παρέκτασης* (όταν οι προβλέψεις δεδομένων επεκτείνονται πέρα από το δεδομένο σύνολο πχ για μελλοντικές εκτιμήσεις).⁹ Leonard A. McGee and Stanley F. Schmidt, “Discovery of the Kalman Filter as a Practical Tool for Aerospace and Industry”, NASA Technical Memorandum, 1985.)

Ο αλγόριθμος λειτουργεί σε δυο στάδια. Στο στάδιο της πρόβλεψης, το φίλτρο παράγει εκτιμήσεις για άγνωστες τιμές. Μόλις το αποτέλεσμα της επόμενης μέτρησης παρατηρείται, οι εκτιμήσεις αυτές αναπροσαρμόζονται με σταθμισμένο μέσο όρο, με το περισσότερο βάρος να δίνεται στις εκτιμήσεις με την μεγαλύτερη βεβαιότητα. Αυτή η μέθοδος παράγει εκτιμήσεις που τείνουν να είναι πιο κοντά προς άγνωστες αληθινές τιμές από εκείνες που θα βασίζονταν σε μια απλή μέτρηση.

Επειδή η αξιοπιστία των μετρήσεων είναι δύσκολο να μετρηθεί με ακρίβεια, είναι σύνηθες να ασχολούμαστε με την συμπεριφορά του φίλτρου με όρους κέρδους. Το κέρδος από εφαρμογή Kalman φίλτρου είναι μια συνάρτηση της σχετικής ασφάλειας των μετρήσεων και της τρέχουσας κατάστασης. Με ένα υψηλό κέρδος, το φίλτρο δίνει περισσότερο βάρος στις μετρήσεις, και γι αυτό τις «ακολουθεί» πιό στενά. Με ένα χαμηλό κέρδος, το φίλτρο ακολουθεί τις προβλέψεις του μοντέλου, εξομαλύνοντας το θόρυβο, αλλά μειώνοντας την ανταπόκριση. Σε ακραίες

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

περιπτώσεις, ένα κέρδος που προκαλεί το φίλτρο μπορεί να αγνοήσει εντελώς την κατάσταση προβλέψεων.

(Weihua Lia, Sirish L. Shaha and Deyun Xiaob, “Kalman filters in non - uniformly sampled multirate systems: For FDI and beyond”, ScienceDirect, Automatica 44 (2008) 199 – 208)

Λόγο της αναδρομικότητας του αλγορίθμου, μπορεί να τρέξει σε πραγματικό χρόνο χρησιμοποιώντας μόνο τις παρούσες μετρήσεις των εισροών, και την προγενέστερη κατάσταση, χωρίς να απαιτούνται συμπληρωματικές πληροφορίες από πριν. Από θεωρητική άποψη, η κύρια υπόθεση του φίλτρου Kalman είναι ότι το υποκείμενο σύστημα είναι ένα σύστημα γραμμικών δυναμικών και ότι όλοι οι όροι σφάλματος έχουν Gaussian κατανομή. (B. D. O. Anderson και J. B. Moore, “Kalman Filtering: Whence, What and Whither?”, Mathematical System Theory, pages 41–54. Springer-Verlag, 1991)

Συμπερασματικά ένα φίλτρο Kalman είναι ένας εκτιμητής του λεγόμενου γραμμικού προβλήματος ελάχιστων τετραγώνων, όπου καλείται κανείς να υπολογίσει τη στιγμιαία “κατάσταση” ενός γραμμικού δυναμικού συστήματος που διαταράσσεται από λευκό θόρυβο. Πρακτικά, είναι ένα μοναδικό εργαλείο για τον έλεγχο πολύπλοκων δυναμικών διεργασιών (π.χ ροή ενός πλημμυρισμένου ποταμού, τιμές μετοχών) ή συστημάτων σε οχήματα, πλοία, αεροσκάφη, δορυφόρους, παρέχοντας ένα πλήρες στατιστικό χαρακτηριστικό ενός δυναμικού προβλήματος λαμβάνοντας υπόψη τη διανομή πιθανοτήτων, για όλες τις μεταβλητές που επιφορτίζεται να υπολογίσει.

http://en.wikipedia.org/wiki/Kalman_filter

ΕΦΑΡΜΟΓΗ	ΔΥΝΑΜΙΚΟ ΣΥΣΤΗΜΑ	ΑΙΣΘΗΤΗΡΕΣ
<i>Έλεγχος διεργασίας</i>	<i>Χημικές εγκαταστάσεις</i>	<ul style="list-style-type: none">• Πίεσης• Θερμοκρασίας• Ποσοστό ροής• Ανίχνευσης αερίων
<i>Πρόβλεψη πλημμύρων</i>	<i>Ροή υδάτων ποταμού</i>	<ul style="list-style-type: none">• Στάθμης νερού• Βροχόμετρα• Ραντάρ καιρού
<i>Παρακολούθηση δορυφόρων</i>	<i>Τροχιακή κίνηση</i>	<ul style="list-style-type: none">• Ραντάρ• Αστrolάβοι
<i>Πλοήγηση</i>	<i>Πλοία</i>	<ul style="list-style-type: none">• Εξάντες• Γυροσκόπια• Αδρανειακά συστήματα• GPS

Πίνακας 1. Παράδειγμα εφαρμογής φίλτρων Kalman.

5.2 Το διακριτό φίλτρο kalman

Στο κεφάλαιο αυτό παρουσιάζεται ο αλγόριθμος του Kalman στην αρχική του διατύπωση η οποία στοχεύει στην εκτίμηση της κατάστασης μιας ελεγχόμενης διαδικασίας διακριτού χρόνου η οποία περιγράφεται από μια γραμμική στοχαστική εξίσωση διαφοράς της μορφής,

$$\mathbf{X}_k = \mathbf{A}\mathbf{X}_{k-1} + \mathbf{B}u_{k-1} + \mathbf{W}_{k-1} \quad (5.7)$$

Για την οποία μια μέτρηση z περιγράφεται από την εξίσωση,

$$\mathbf{Z}_k = \mathbf{H}\mathbf{X}_k + v_k \quad (5.8)$$

Όπου οι τυχαίες μεταβλητές w_k και v_k αναπαριστούν τον θόρυβο συστήματος και μέτρησης, αντίστοιχα και τις οποίες θα θεωρήσουμε ασυσχέτιστες με το χρόνο (λευκός θόρυβος) και μεταξύ τους, με κανονικές κατανομές πιθανότητας

$$p(\mathbf{w}) \sim \mathbf{N}(\mathbf{0}, \mathbf{Q}) \quad (5.9)$$

$$p(\mathbf{v}) \sim \mathbf{N}(\mathbf{0}, \mathbf{R}) \quad (5.10)$$

και πίνακες συμμεταβλητότητας (covariance matrices) θορύβου συστήματος και μετρήσεις \mathbf{Q} και \mathbf{R} , αντίστοιχα. Ο $n \times n$ πίνακας \mathbf{A} συσχετίζει την προηγούμενη κατάσταση κατά την διάκριτή στιγμή $k-1$ με την τρέχουσα κατάσταση του συστήματος την στιγμή k χωρίς ο θόρυβος συστήματος να αποτελεί παράμετρο στη σχέση ενώ ο $n \times 1$ πίνακας \mathbf{B} συσχετίζει την είσοδο ελέγχου u με την κατάσταση του συστήματος \mathbf{X} και τέλος ο $m \times n$ πίνακας \mathbf{H} συσχετίζει την μέτρηση \mathbf{Z}_k με την κατάσταση του συστήματος \mathbf{X} . (*Mohinder S. Grewal and Angus P. Andrews, "Kalman Filtering : Theory and Practice Using Matlab", Second Edition, Wiley Publications*)

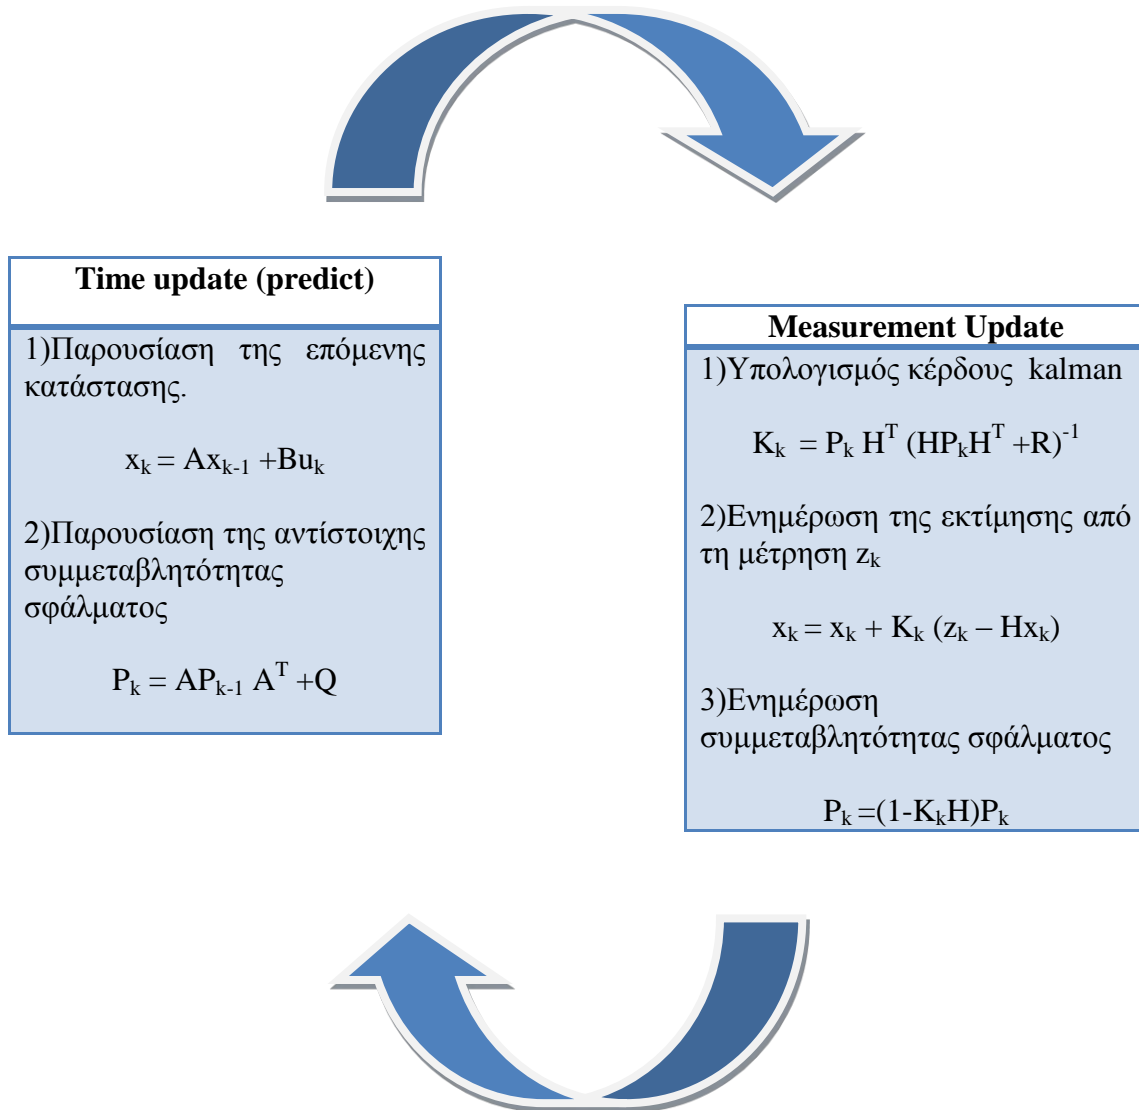
5.3 Η λειτουργία του αλγορίθμου

Η αποτελεσματικότητα του αλγορίθμου, εν γένει, βασίζεται στην αναδρομικότητα του. Έτσι, η εκτίμηση της κατάστασης του συστήματος από το φίλτρο kalman επιτυγχάνεται με χρήση μιας μορφής ανάδρασης. Αρχικά το φίλτρο πραγματοποιεί μια πρώτη εκτίμηση της κατάστασης σε μια διακριτή χρονική στιγμή (πρόβλεψη) και εν συνεχεία εξασφαλίζει μια ενθόρυβη μέτρηση, μέσω ανάδρασης (διόρθωση) για την βέλτιστη εκτίμηση της τρέχουσας κατάστασης.

Κατ'επέκταση, παρατηρείται ένας διαχωρισμός μεταξύ των εξισώσεων που απαρτίζουν το φίλτρο, διακρίνοντας εξισώσεις που ενημερώνονται για την μεταβολή του χρόνου (*time update*) και εξισώσεις που ενημερώνονται για μεταβολές μετρήσεων (*measurement update*). Συγκεκριμένα, οι *time update* εξισώσεις αναλαμβάνουν να προάγουν την τρέχουσα κατάσταση του συστήματος, που εκτιμήθηκε την στιγμή $k-1$, καθώς και τις συμμεταβλητότητες των α priority και α

posteriori εκτιμήσεων σφάλματος για τον υπολογισμό της α priori εκτίμησης της κατάστασης X , ώστε να χρησιμοποιηθεί σε επόμενο χρονικό βήμα

κ. Ενώ οι measurement update εξισώσεις αναλαμβάνουν να προωθήσουν κάθε καινούργια μέτρηση, λειτουργώντας ως σύστημα ανάδρασης, και ενσωματώνοντας την α priori εκτίμηση σφάλματος με σκοπό να υπολογιστεί μια βέλτιστη α posteriori εκτίμηση.



Αρχικές εκτιμήσεις για τα x_{k-1} και P_{k-1}

Σχήμα 1. Σχηματική αναπαράσταση της διαδικασίας του αλγορίθμου Kalman.

Ο παραπάνω κύκλος λειτουργίας του αλγορίθμου εκτελείται επαναληπτικά, μπορούμε να διακρίνουμε ως πρώτο βήμα των διορθωτικών εξισώσεων τον υπολογισμό του κέρδους K_k . Ο $m \times m$ πίνακας K υπολογίζεται ώστε να ελαχιστοποιεί τη συμμεταβλητότητα (covariance) της α posteriori εκτίμησης σφάλματος P_k . Εν συνεχεία, καταγράφεται μια μέτρηση z_k και υπολογίζεται μια α posteriori εκτίμηση της κατάστασης με βάση τη νέα μέτρηση. Τέλος, υπολογίζεται η συμμεταβλητότητα

της *a posteriori* εκτίμησης σφάλματος P_k . Μετά το τέλος λοιπόν κάθε κύκλου λειτουργίας, η διαδικασία επαναλαμβάνεται προωθώντας την τελευταία *a posteriori* εκτίμηση στις εξισώσεις πρόβλεψης ώστε να προκύψει μια νέα *a priori* εκτίμηση. Έτσι, εκτιμάται πως αναδρομική φύση του αλγορίθμου Kalman και η ευρρωστία που προσφέρει, καθιστούν το φίλτρο άρτια υλοποιήσιμο σε πρακτικά προβλήματα.

5.4 Υλοποίηση φίλτρου Kalman

Η υλοποίηση του φίλτρου απαιτεί ο πίνακας συμμεταβλητότητας θορύβου μέτρησης R (measurement noise covariance matrix) να έχει διαμορφωθεί πριν την αρχική λειτουργία του φίλτρου. Κάτι τέτοιο είναι φυσικά εφικτό μιας και μπορούν να υπάρξουν μετρήσεις (δείγματα), που με τον έναν ή άλλο τρόπο παρέχουν πληροφορία για τις μεταβλητές κατάστασης του συστήματος, ώστε να καθορίζεται η στατιστική διακύμανση του θορύβου μέτρησης ακόμα και όταν το φίλτρο δεν έχει τεθεί σε ισχύ.

Όσον αφορά όμως στη διαμόρφωση του πίνακα συμμεταβλητότητας θορύβου συστήματος Q , μια υπόθεση όπως η παραπάνω στέκεται αβάσιμη. Εδώ δεν υπάρχει άμεσος ή ευθύς τρόπος για να παρατηρηθεί το σύστημα για το οποίο επιθυμούμε να εκτιμήσουμε την κατάσταση του. Όμως είναι πιθανό ένα σχετικά απλοϊκό μοντέλο συστήματος να αποδειχτεί ότι παράγει αποδεκτά αποτελέσματα αν κανείς συμπεριλάβει τον βαθμό αβεβαιότητας του μοντέλου που επιλέχθηκε στον πίνακα Q . Σε κάθε περίπτωση όμως, ασχέτος της λογικής και της πρακτικής με την οποία επιλέγονται οι παράμετροι του φίλτρου, μπορεί να επιτευχθεί η βέλτιστη λειτουργία του φίλτρου με κατάλληλη επιλογή των Q και R . Εν τούτοις, όταν κάτω από ορισμένες συνθήκες οι πίνακες Q και R παραμένουν σταθεροί, τότε η συμμεταβλητότητα της *a posteriori* εκτίμησης σφάλματος P_k και το κέρδος Kalman K_k θα τείνουν να σταθεροποιηθούν σε κάποια τιμή. Σε κάθε τέτοια περίπτωση οι παράμετροι του φίλτρου μπορούν να υπολογιστούν όταν το φίλτρο λειτουργεί χωρίς να παρεμβάλλονται ενθόρυβες μετρήσεις ή όταν είναι εφικτό να προυπολογιστεί η τιμή της σταθερής κατάστασης της P_k .

Τέλος, συχνά συμβαίνει το σφάλμα μέτρησης να μην παραμένει σταθερό λόγω διαφορετικών ή και απομακρυσμένων πηγών μετρήσεων. Κάτι τέτοιο μπορεί να συνυπολογιστεί στον πίνακα συμμεταβλητότητας Q . σε παρόμοια περίπτωση, ο πίνακας Q μπορεί να μεταβάλλεται δυναμικά κατά την λειτουργία του φίλτρου όταν το μοντέλο του συτήματος βιώνει ακραίες αλλαγές στο περιβάλλον παρατήρησης. Έτσι σε αυτές τις περιπτώσεις επιλέγεται το Q με βάση το βαθμό αβεβαιότητας του μοντέλου και του παρατηρούμενου συστήματος. (*G. Welch και G. Bishop, "An Introduction to the Kalman Filter", 2006, SIGGRAPH 2001, Course 8, 2001*)

5.5 Εκτεταμένο (extended) φίλτρο Kalman

Όπως είδαμε πριν ο αλγόριθμος kalman σχεδιάστηκε για την αντιμετώπιση προβλημάτων εκτίμησης της κατάστασης γραμμικών συστημάτων. Θα εξετάσουμε τώρα, την περίπτωση αντιμετώπισης προβλημάτων πρόβλεψης για συστήματα μη-γραμμικών διαδικασιών ή και ακόμα για μη-γραμμικά μοντέλα ή διαδικασίες μέτρησης θορύβου. Ο αλγόριθμος που χρησιμοποιείται σε τέτοιες περιπτώσεις ονομάζεται εκτεταμένο φίλτρο kalman και η γενική τακτική του είναι να διαμορφώνει όσο το δυνατόν πιο γραμμικά την τελευταία τιμή και της συμμεταβλητότητας (covariance). (Mohinder S. Grewal and Angus P. Andrews, “Kalman Filtering : Theory and Practice Using Matlab”, Second Edition, Wiley Publications)

Βασικό μειονέκτημα όμως του εκτεταμένου φίλτρου Kalman, σε αντίθεση με το διακριτό φίλτρο, είναι πως οι διάφορες μεταβλητές που περιγράφουν το σύστημα παύουν να ακολουθούν κανονική κατανομή την στιγμή που διαφοροποιούνται μη-γραμμικά.

Για το λόγο αυτό το εκτεταμένο kalman φίλτρο εκτιμά την κατάσταση του συστήματος προσεγγίζοντας την γραμμικά με γώμονα την ευνοϊκότερη δυνατή συνθήκη, κατά Bayes.

Θεωρώντας λοιπόν ότι η κατάσταση του συστήματος περιγράφεται από ένα διάνυσμα $x \in \mathbb{R}^n$, εξετάζουμε μια διαδικασία διακριτού χρόνου οποία περιγράφεται από μια μη-γραμμική στοχαστική διαφορική εξίσωση της μορφής.

$$x_k = f(x_{k-1}, u_{k-1}, w_{k-1}) \quad 5.11)$$

για την οποία μια μέτρηση z ($z \in \mathbb{R}^m$) περιγράφεται από τη μη-γραμμική εξίσωση,

$$z_k = h(x_k, v_k) \quad 5.12)$$

που συσχετίζει την τρέχουσα κατάσταση x_k με την μέτρηση z_k . Οι τυχαίες μεταβλητές w_k και v_k αναπαριστούν τον θόρυβο συστήματος και μέτρησης αντίστοιχα. Η μη-γραμμική συνάρτηση f της διαφορικής εξίσωσης συσχετίζει την χρονική κατάσταση του συστήματος κατά την χρονική στιγμή $k-1$ με την κατάσταση του συστήματος την τρέχουσα χρονική στιγμή k . Όπως και προηγουμένως, έτσι και εδώ, η συνάρτηση f λαμβάνει υπόψιν κάθε ενδεχόμενη είσοδο ελέγχου u_{k-1} και κάθε πηγή θορύβου, με μηδενικη τιμή μέσου, εκφρασμένη στο διάνυσμα w_k και v_k δεν μπορεί να είναι γνωστές ανά πάσα χρονική στιγμή.

Όπως και στο γραμμικό kalman φίλτρο, κάθε επανάληψη έχει δυο κύκλους, μια πρόβλεψης και μια διόρθωσης. Η διαφορά είναι ότι κατά τον κύκλο πρόβλεψης η εκτίμηση της του διανύσματος κατάστασης γίνεται με το μη-γραμμικό μοντέλο ενώ για την εκτίμηση του πίνακα σφάλματος συμμεταβλητότητας, γίνεται πρώτα γραμμικοποίηση. Η γραμμικοποίηση του διανύσματος κατάστασης γίνεται χρησιμοποιώντας τον ακόλουθο πίνακα ιακωβιανών.

$$A_{k-1} = \left[\frac{\delta f(x,u)}{\delta x} \right]_{x_{k-1}} \quad 5.13)$$

Έτσι οι εξισώσεις $x_k = Ax_{k-1} + Bu_k$ και $P_k = AP_{k-1}A^T + Q$ γράφονται:

$$x_k = f(x_{k-1}, u_{k-1}) \quad 5.14)$$

$$\mathbf{P}_k = \mathbf{A}_{k-1} \mathbf{P}_{k-1} \mathbf{A}_{k-1}^T + \mathbf{Q}_{k-1} \quad 5.15)$$

Για τον κύκλο διόρθωσης πρέπει να γραμμικοποιήσουμε το διάνυσμα μετρήσεων με τη χρήση του παρακάτω πίνακα Ιακωβιανών:

$$\mathbf{H}_k = \left[\frac{\delta h(x,u)}{\delta x} \right]_{\mathbf{x}_k} \quad 5.16)$$

Και οι εξισώσεις διόρθωσης $\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R})^{-1}$, $\mathbf{x}_k = \mathbf{x}_k + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \mathbf{x}_k)$, $\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k$ γίνονται:

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad 5.17)$$

$$\mathbf{x}_k = \mathbf{x}_k + \mathbf{K}_k (\mathbf{z}_k - \mathbf{h}(\mathbf{x}_k)) \quad 5.18)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k \quad 5.19)$$

Παρατηρείται, πλέον πως για τους Ιακωβιανούς πίνακες χρησιμοποιείται ο δείκτης k ως ένδειξη ότι οι πίνακες διαφοροποιούνται σε κάθε χρονικό βήμα. Όμοια με το διακριτό φίλτρο Kalman, και εδώ οι εξισώσεις πρόβλεψης προωθούν την τελευταία εκτίμηση της κατάστασης και την συμμεταβλητότητα σφάλματος κατά την χρονική στιγμή $k-1$ στο επόμενο χρονικό βήμα k . Έτσι, και οι διορθωτικές εξισώσεις για το εκτεταμένο φίλτρο kalman συνεκτιμούν την νέα μέτρηση z_k για να διορθώσουν την εκτίμηση της κατάστασης και την εκτίμηση συμμεταβλητότητας σφάλματος P_k . Τέλος σημειώνεται, πως κύριο γνώρισμα του εκτεταμένου φίλτρου Kalman είναι η ικανότητα του Ιακωβιανού πίνακα H_k στην εξίσωση κέρδους να μεταδίδει μόνο τη σωστή ποιότητα και ποσότητα μέτρησης (Y. Ampatzidis, S. Vougioukas, S. Blackmore, D. Bochtis, "An Object-Oriented Asynchronous Kalman Filter with Outlier Rejection for Autonomous Tractor Navigation", Aristotle University of Thessaloniki, Department of Agricultural Engineering και The Royal Veterinary and Agricultural University (KVL), Department of AgroTechnology, Denmark)

5.6 Γενικά για την μέθοδο ICA

Η ανάλυση ανεξάρτητων συνιστωσών έγινε γνωστή ως η μέθοδος που κατόρθωσε να επιλύσει το πρόβλημα του διαχωρισμού σημάτων ομιλίας, που καταγράφονται σε μικρόφωνα, στα συστατικά τους (cocktail party problem). Σύμφωνα μ' αυτό, m χρονικά σήματα-απαγωγές ή σήματα-μίγματα, προκύπτουν από m γραμμικούς συνδυασμούς n χρονικών σημάτων $s_1(t), s_2(t), \dots, s_n(t)$, τα οποία ονομάζονται σήματα-πηγές ή σήματα-συνιστώσες (components).

$$\mathbf{x}_i(t) = \mathbf{a}_{i1} \cdot s_1 + \mathbf{a}_{i2} \cdot s_2 + \dots + \mathbf{a}_{in} \cdot s_n \quad \text{όπου } i = 1, 2, \dots, m \text{ και } \mathbf{a}_{i1}, \mathbf{a}_{i2}, \dots, \mathbf{a}_{in} \in \mathbf{R}, \quad 7.16)$$

τα σήματα-απαγωγές $x_1(t), x_2(t), \dots, x_m(t)$ γίνονται γνωστά μέσω μετρήσεων.

Αντίθετα, τόσο τα σήματα-συνιστώσες $s_1(t), s_2(t), \dots, s_n(t)$, όσο και οι συντελεστές $a_{i1}, a_{i2}, \dots, a_{in}$ αποτελούν ποσότητες άγνωστες. Στόχος της μεθόδου ICA αποτελεί η ανακατασκευή των σημάτων-συνιστωσών, χρησιμοποιώντας μόνο τη γνώση των σημάτων-απαγωγών και κάνοντας κάποιες βασικές υποθέσεις. Fast ICA (Hyvärinen – Oja, 1997)

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Η σχέση 7.16 μπορεί να εκφραστεί και ως ένας γραμμικός μετασχηματισμός ως εξής:

$$\mathbf{x}(t) = \mathbf{A} \cdot \mathbf{s}(t) \quad 7.17$$

όπου $\mathbf{x}(t)$ το διάνυσμα στήλη με στοιχεία τα σήματα-απαγωγές, δηλαδή $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$

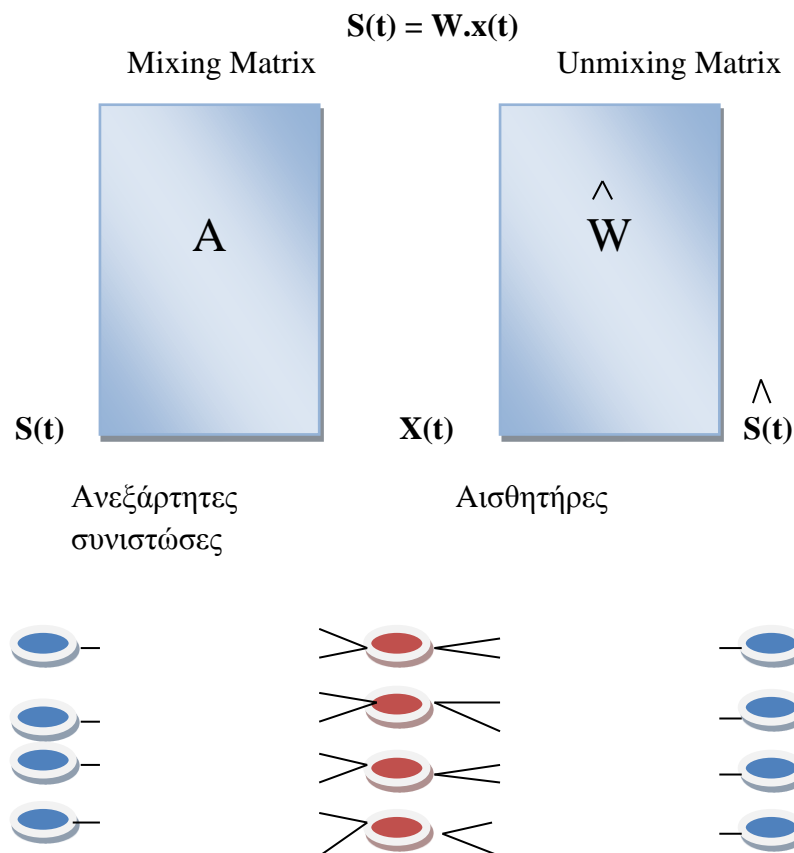
\mathbf{A} : ο πίνακας του γραμμικού μετασχηματισμού διαστάσεων $n \times m$ και $\mathbf{s}(t)$ το διάνυσμα στήλη με στοιχεία τα σήματα-συνιστώσες, δηλαδή $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]^T$.

Με δεδομένη την αναστρεψιμότητα του πίνακα \mathbf{A} , ο αντίστροφος της πάνω σχέσης γραμμικός μετασχηματισμός εκφράζει το διάνυσμα των συνιστωσών, συναρτήσει του διανύσματος των απαγωγών:

$$\mathbf{S}(t) = \mathbf{W} \cdot \mathbf{x}(t) \quad 7.18$$

Όπου \mathbf{W} : ο πίνακας του αντίστροφου γραμμικού μετασχηματισμού διαστάσεων $\mathbf{m} \times \mathbf{n}$.

Με τη νέα μορφή της αρχικής σχέσης γίνεται φανερό πως σκοπός της μεθόδου ICA είναι η κατασκευή, με βάση πάντα μόνο τη γνώση του διανύσματος των απαγωγών $\mathbf{x}(t)$, ενός πίνακα \mathbf{W} , ο οποίος να προσεγγίζει, όσο το δυνατόν περισσότερο, το θεωρητικό πίνακα του αντίστροφου μετασχηματισμού \mathbf{W} . Το διάνυσμα που θα προκύψει από τον πολλαπλασιασμό αυτού του πίνακα \mathbf{W} με το διάνυσμα των απαγωγών $\mathbf{x}(t)$ θα είναι το διάνυσμα των ανακατασκευασμένων συνιστωσών $\mathbf{s}(t)$.



Σχήμα 4. Σχηματικό διάγραμμα μεθόδου ICA

Μια άλλη προσέγγιση στη μέθοδο ICA μπορεί να γίνει μέσω της στατιστικής. Στην περίπτωση αυτή, η σχέση 7.16 μετατρέπεται στην ακόλουθη σχέση:

$$x_i = a_{i1}s_1 + a_{i2}s_2 + a_{in}s_n \text{ όπου } i = 1, 2, \dots, m \text{ και } a_{i1}, a_{i2}, a_{in} \in \mathbb{R} \quad 7.19)$$

όπου x_i ($i = 1, 2, \dots, m$) τυχαίες μεταβλητές-απαγωγές που «γεννιούνται» από m γραμμικούς συνδυασμούς n τυχαίων μεταβλητών-συνιστωσών s_1, s_2, \dots, s_n . Οι μεταβλητές-συνιστώσες ονομάζονται λανθάνουσες μεταβλητές, γιατί δεν μπορούν να παραιτηθούν άμεσα. Για το λόγο αυτό το στατιστικό μοντέλο που χρησιμοποιείται ονομάζεται μοντέλο λανθάνουσων μεταβλητών.

Αντίστοιχα, η σχέση $x(t) = A \cdot s(t)$ μετατρέπεται στην ακόλουθη σχέση:

$$x = A \cdot s \quad 7.20)$$

και η σχέση $S(t) = W \cdot x(t)$ μετατρέπεται στην:

$$s = W \cdot x \quad 7.21)$$

όπου x το διάνυσμα στήλη με στοιχεία τις μεταβλητές-απαγωγές, δηλαδή $x = [x_1, x_2, \dots, x_m]^T$ και s το διάνυσμα στήλη με στοιχεία τις μεταβλητές-συνιστώσες, δηλαδή $s = [s_1, s_2, \dots, s_n]^T$. C.J.James, C.W.Hesse. Independent Component Analysis for biomedical signals. Physiological Measurement 26, R15-R39. 2005.

5.7 Αλγόριθμοι υλοποίησης της μεθόδου ICA

5.7.1 Αλγόριθμοι που βασίζονται σε τεχνικές HOS

Οι πολύ δημοφιλείς, αυτοί αλγόριθμοι ICA βασίζουν την κατασκευή στατιστικά ανεξάρτητων συνιστωσών, σε τεχνικές, οι οποίες περιέχουν στατιστικά μεγέθη υψηλότερης τάξης (Higher-Order Statistics /HOS).

Τα στατιστικά μεγέθη υψηλότερης τάξης, όταν αναφέρονται σε μεταβλητές Γκαουσιανής κατανομής μηδενίζονται. Έτσι, ο μηδενισμός ή μη κάποιου τέτοιου μεγέθους, που αναφέρεται στις ανακατασκευασμένες συνιστώσες, μπορεί να αποτελεί κριτήριο για την κανονικότητα ή μη αυτών. Εξάλλου, όπως μπορεί να αποδειχθεί με την χρήση του Θεωρήματος Κετρικού Ορίου η κατασκευή συνιστωσών, μη γκαουσιανής κατανομής, συνεπάγεται τη στατιστική ανεξαρτησία αυτών.

Σ' αυτό ακριβώς το σημείο μπορεί να εντοπιστεί κι ένας περιορισμός των αλγορίθμων ICA που βασίζονται σε τεχνικές HOS, αφού, με αυτόν τον τρόπο, δεν μπορούν να εντοπιστούν συνιστώσες Γκαουσιανής κατανομής. Fast ICA (Hyvärinen – Oja, 1997) [3]: Συνιστώσες μη Γκαουσιανής κατανομής, μέσω του συντελεστή κύρτωσης

Οι τρεις σημαντικότεροι αλγόριθμοι ICA-HOS παρουσιάζονται παρακάτω:

1) ***Fast ICA (1997 Συνιστώσες μη Γκαουσιανής κατανομής, μέσω του συντελεστή κύρτωσης)***

Πρόκειται για έναν ευρέως διαδεδομένο αλγόριθμο ICA, ο οποίος, για να κατασκευάσει συνιστώσες με μη Γκαουσιανή κατανομή, στηρίζεται στον συντελεστή κύρτωσης ένα στατιστικό μέγεθος τέταρτης τάξης, που αποδίδεται σε κάθε τυχαία μεταβλητή. Το μέγεθος αυτό, για μεταβλητές Γκαουσιανής κατανομής, αγγίζει ιδανικά το 0. Σκοπός του αλγορίθμου Fast ICA είναι η μεγιστοποίηση του συντελεστή, έτσι ώστε οι ανακατασκευασμένες συνιστώσες να απομακρυνθούν, όσο το δυνατόν περισσότερο, από τη Γκαουσιανή κατανομή και άρα να γίνουν στατιστικά ανεξάρτητες. Ο συντελεστής κύρτωσης, που ουσιαστικά φανερώνει πόσο απότομες κορυφές έχει η κατανομή μιας μεταβλητής, δίνεται από την εξίσωση

$$kurt(x) = E\{X^4\} - 3(E\{x^2\})^2 \quad 7.22)$$

Όπου x τυχαία μεταβλητή με μηδενική μέση αριθμητική τιμή [1].

2) *Infomax ICA (Bell-Sejnowski ,1995): Συνιστώσες μη Γκαουσιανής κατανομής μέσω διαφορικής εντροπίας*

Ο αλγόριθμος αυτός, για να εκφράσει τη μη Γκαουσιανή κατανομή των συνιστωσών που ανακατασκευάζει, στηρίζεται στο μέγεθος διαφορική εντροπία, ένα μέγεθος από τη Θεωρία της Πληροφορίας. Ανάμεσα σε τυχαίες μεταβλητές της ίδιας διακύμανσης, αλλά διαφορετικών κατανομών, αυτή που είναι Γκαουσιανής κατανομής παρουσιάζει και τη μεγαλύτερη εντροπία, άρα περιέχει το μικρότερο ποσό πληροφορίας. Η διαφορική εντροπία μιας τυχαίας μεταβλητής y ορίζεται ως η διαφορά εντροπίας μιας Γκαουσιανής κατανομής, τυχαίας μεταβλητής u , η οποία έχει την ίδια διακύμανση με την μεταβλητή y , μείον την εντροπία της μεταβλητής y . Παίρνει την τιμή 0, όταν η τυχαία μεταβλητή y είναι Γκαουσιανής κατανομής και τιμή μεγαλύτερη από 0 σε κάθε άλλη περίπτωση.

Σκοπός, λοιπόν, του αλγορίθμου Infomax ICA είναι η μεγιστοποίηση της διαφορικής εντροπίας, έτσι ώστε οι ανακατασκευασμένες συνιστώσες να απομακρυνθούν, όσο το δυνατό περισσότερο, από τη Γκαουσιανή κατανομή και άρα να γίνουν στατιστικά ανεξάρτητες.

Ο Infomax ICA είναι ένας αλγόριθμος νευρωνικού δικτύου διατήρησης της μέγιστης πληροφορίας.

3) *Jade – joint Approximate Diagonalization of Eigenmatrices (Πηγές μη γκαουσιανής κατανομής μέσω της από κοινού διαγωνιοποίησης των ιδιοπινάκων)*. (Hyvärinen, 2001)

Ο αλγόριθμος JADE βασίζεται στους τανυστές αθροιστών υψηλότερης τάξης. Ο τανυστής του αθροιστή δεύτερης τάξης ονομάζεται πίνακας συνδιακύμανσης και καθορίζεται από τον αθροιστή δεύτερης τάξης, δηλαδή την συνδιακύμανση.

Αντίστοιχα ο τανυστής του αθροιστή τέταρτης τάξης καθορίζεται από τον αθροιστή τέταρτης τάξης. Με την εφαρμογή στον πίνακα συνδιακύμανσης των καναλιών, $C_x = \langle xx^T \rangle$, της ανάλυσης ιδιοτιμής, αυτός διαγωνοποιείται, δηλαδή τα σήματα-απαγωγές μετασχηματίζονται, έτσι ώστε η συνδιακύμανση μεταξύ οποιωνδήποτε δύο, να είναι μηδέν. Ομοίως και οι τέταρτης τάξης τανυστές αθροιστών μπορούν να χρησιμοποιηθούν για να μηδενιστούν οι τέταρτης τάξης αθροιστές. Ο μηδενισμός των τέταρτης αθροιστών οδηγεί στην επιθυμητή μη γκαουσιανή κατανομή των συνιστωσών και άρα στην στατιστική τους ανεξαρτησία.

Στην πράξη ο αλγόριθμος JADE, που κοντολογίς επιχειρεί την από κοινού διαφωνιοποίηση μιας σειράς από πίνακες, χρησιμοποιείται ευρέως σε προβλήματα μικρών διαστάσεων, αλλά αντιμετωπίζει αξεπέραστα αριθμητικά προβλήματα, όταν οι διαστάσεις μεγαλώνουν. C.J.James, C.W.Hesse. Independent Component Analysis for biomedical signals. Physiological Measurement 26, R15-R39. 2005.

5.7.2 Αλγόριθμοι που βασίζονται στην εξέλιξη των συνιστωσών στο χρόνο

Οι αλγόριθμοι αυτοί, για την κατασκευή συνιστωσών, βασίζονται στην μηδενική μεταξύ τους συσχέτιση, δηλαδή σε μια συνέπεια της υπόθεσης της στατιστικής ανεξαρτησίας. Η σχέση μεταξύ των σημάτων-απαγωγών εκφράζεται μέσω του (τετραγωνικού) πίνακα συνδιακύμανσης τους. Η εξέλιξη αυτής της σχέσης στο χρόνο εκφράζεται μέσω μιας στοίβας πινάκων συνδιακύμανσης. Σκοπός των αλγορίθμων αποτελεί η κατασκευή πίνακα, ο οποίος θα διαγωνοποιεί από κοινού όλους τους πίνακες της στοίβας και με αυτό τον τρόπο θα μηδενίζει την συσχέτιση των απαγωγών. Αυτός ο πίνακας θα αποτελεί, τότε, τον πίνακα του αντίστροφου μετασχηματισμού W . A.Hyvarinen, J.Karhunen, E.Oja. Independent Component Analysis. 2001.

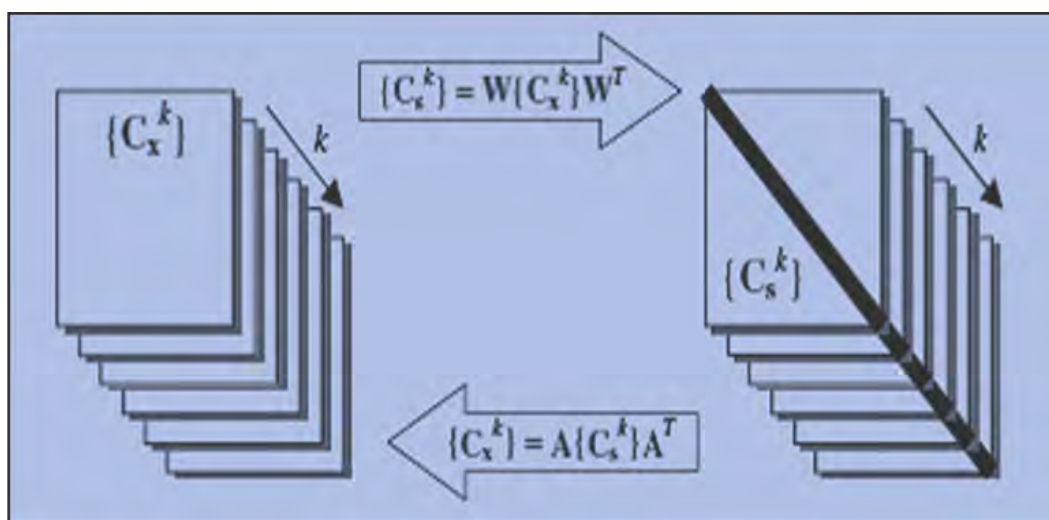
Ισχύει:

$$C_x^k = A C_s^k A^T \quad (7.23)$$

Όπου C_x^k ο k -οστός πίνακας συνδιακύμανσης του διανύσματος $x(t)$, C_s^k ο k -οστός πίνακας συνδιακύμανσης του διανύσματος $s(t)$ και A ο πίνακας μετασχηματισμού. Αντιστρέφοντας την πάνω εξίσωση προκύπτει η επόμενη εξίσωση.

$$C_s^k = W C_x^k W^T \quad (7.24)$$

Όπου W ο πίνακας αντίστροφου μετασχηματισμού.



Σχήμα 5. Σχηματικό διάγραμμα αλγορίθμων ICA που βασίζονται στην εξέλιξη των συνιστωσών στο χρόνο.

Κεφάλαιο 6

Εισαγωγή

Ένας πολύ σημαντικός λόγος που η μηχανική μάθηση παρουσιάζει ταχύτατη ανάπτυξη καθιστώντας την έναν συνεχώς αναπτυσσόμενο κλάδο, είναι και η τεράστια χρησιμότητα της σε ποικίλες εφαρμογές σε όλα σχεδόν τα επιστημονικά πεδία. Οι εφαρμογές της είναι διάφορες, κυρίως στην ανάλυση δεδομένων, συχνά στα πλαίσια συστημάτων υποστήριξης αποφάσεων. Εφαρμογή της σε μεγάλες βάσεις δεδομένων αποτελεί η Εξόρυξη Δεδομένων (Data Mining) ή Ανακάλυψη Γνώσης σε Βάσεις Δεδομένων (Knowledge Discovery in Databases). Αλγορίθμους μηχανικής μάθησης συναντάμε επίσης στην κατηγοριοποίηση κειμένου και αναγνώριση προτύπων. Το κεφάλαιο αυτό παρέχει μια περιεκτική παρουσίαση των εφαρμογών της μηχανικής μάθησης χωρισμένη σε επιστημονικά πεδία.

6.0 Εφαρμογές της μηχανικής μάθησης στη Βιοπληροφορική και στο Παγκόσμιο Ιστό

6.1 Βιοπληροφορική

Η Βιοπληροφορική (bioinformatics) είναι επιστημονικός κλάδος ο οποίος προέκυψε από τη συνεργασία των επιστημών της μοριακής βιολογίας και της πληροφορικής. Το 1990 εμφανίζεται πρώτη φορά ως ανεξάρτητη επιστήμη, θεωρώντας τα βιολογικά δεδομένα DNA - RNA - πρωτεΐνες ως ψηφιακή πληροφορία, εφαρμόζει αλγορίθμους για την επεξεργασία τους και την παραγωγή χρήσιμων συμπερασμάτων με αποδοτικό τρόπο. Συνήθως χρησιμοποιούνται μέθοδοι κλάδων της τεχνητής νοημοσύνης, όπως η εξόρυξη δεδομένων (π.χ. νευρωνικά δίκτυα, μπεϋζιανά δίκτυα κλπ) και ο εξελικτικός υπολογισμός (π.χ. γενετικοί αλγόριθμοι).

Το DNA το RNA και οι πρωτεΐνες είναι βιολογικά μακρομόρια που μπορούν να θεωρηθούν ως ακολουθίες συμβόλων, δηλαδή συμβολοσειρές, για παράδειγμα το DNA μπορεί να θεωρηθεί ως μια ακολουθία χιλιάδων νουκλεοτιδίων ή βάσεων. Υπάρχουν τέσσερα είδη βάσεων και αντίστοιχα τέσσερα είδη νουκλεοτιδίων: η αδενίνη, η θυμίνη, η γουανίνη και η κυτοσίνη.

Αντιστοιχίζοντας σε καθεμία απ' αυτές ένα σύμβολο, π.χ. «A» για την αδενίνη, «T» για τη θυμίνη, «G» για τη γουανίνη και «C» για την κυτοσίνη, μπορούμε να κατασκευάσουμε τέτοιες συμβολοσειρές όπως «...AAGATCGGTAC...»). Κατά παρόμοιο τρόπο, οι πρωτεΐνες μπορούν να περιγραφούν ως ακολουθίες αμινοξέων. Αυτού του είδους η αναπαράσταση είναι ιδιαίτερα πρόσφορη για επεξεργασία σε ηλεκτρονικό υπολογιστή που μπορεί να μας δώσει χρήσιμα αποτελέσματα.

Τα νευρωνικά δίκτυα αποτελούν μια σημαντική μέθοδο ως μια μαθηματική τεχνική της τεχνητής νοημοσύνης, με πολλές εφαρμογές στη βιοπληροφορική. Τα τεχνητά νευρωνικά δίκτυα είναι υπολογιστικές μηχανές που σκοπό είχαν αρχικά να

μιμηθούν τις ικανότητες του ανθρώπινου εγκεφάλου στην αναγνώριση προτύπων (Bishop, 1998). Ο κάθε νευρώνας είναι απλά μια συνάρτηση που δέχεται ερεθίσματα από άλλους νευρώνες και δίνει τελικά ερέθισμα (με βάση τη συνάρτηση αυτή) σε άλλους νευρώνες. Συνήθως, τα δίκτυα τα αναπαριστούμε με ένα γράφο, με τα βέλη να αντιστοιχούν στις συνδέσεις (συνάψεις) μεταξύ των νευρώνων. Το συνολικό δίκτυο δεν είναι παρά μια περίπλοκη συνάρτηση που επεξεργάζεται τα δεδομένα εισόδου και παράγει κάποιο τελικό αποτέλεσμα., είναι κατανοητό ότι σαν νευρώνες εισόδου μπορούν να χρησιμοποιηθούν μεταβλητές που έχουν προκύψει από μια κατάλληλη κωδικοποίηση μιας βιολογικής αλληλουχίας (είτε με τοπική είτε με ολική κωδικοποίηση)

Υπάρχουν πολλών ειδών νευρωνικά δίκτυα, μια σημαντική κατηγορία είναι τα δίκτυα εμπρόσθιας τροφοδότησης (feed forward) στα οποία ένας νευρώνας επικοινωνεί πάντα μόνο με νευρώνες που βρίσκονται σε στρώμα που βρίσκεται παρακάτω, η πληροφορία δηλαδή διαδίδεται πάντα προς τα εμπρός. Τα δίκτυα που δεν διαθέτουν κρυφούς νευρώνες είναι μαθηματικά ισοδύναμα με γραμμικά ή γενικευμένα γραμμικά μοντέλα γνωστά από τη στατιστική ανάλογα με τον αριθμό των νευρώνων εξόδου και της συνάρτησης ενεργοποίησης είναι δυνατόν να κατασκευαστούν δίκτυα ανάλογα με τη γραμμική παλινδρόμηση, τη λογιστική παλινδρόμηση, τη διαχωριστική ανάλυση, την πολυμεταβλητή γραμμική παλινδρόμηση κ.ο.κ.). Η μεγάλη δύναμη των νευρωνικών δικτύων (με κρυφούς νευρώνες) βρίσκεται στο γεγονός ότι η παρουσία των κρυφών νευρώνων μπορεί να οδηγήσει σε σύνθετες μη-γραμμικές αναπαραστάσεις των δεδομένων εισόδου και με αυτόν τον τρόπο μπορούν να λυθούν προβλήματα που είναι γραμμικά μη-διαχωρίσιμα. Ένα απλό παράδειγμα τέτοιου προβλήματος είναι το πρόβλημα XOR, ενώ ένα αντίστοιχο βιολογικό, είναι η ίδια η ύπαρξη του γενετικού κώδικα, της συνάρτησης δηλαδή που αντιστοιχεί τα κωδικόνια στα αμινοξέα. Ο αριθμός των κρυφών νευρώνων καθορίζει το πόσο «λεπτομερής» θα είναι μια τέτοια συνάρτηση.

I.E. Livieris and P. Pintelas, ‘Evaluation of neural network training algorithms using biomedical data’, Technical Report 08-02, Department of Mathematics, University of Patras, 2008.

Η Βιοπληροφορική ή Υπολογιστική Βιολογία είναι διεπιστημονικός κλάδος που έλκει την καταγωγή του από τη μοριακή βιολογία και ιδιαίτερα από τη μελέτη των βιολογικών αλληλουχιών και των δομών.

Ορισμός από NCBI

(<http://www.ncbi.nlm.nih.gov/Class/MLACourse/Modules/MolBioReview/bioinformatics.html>): «Bioinformatics is the field of science in which biology, computer science, and information technology merge into a single discipline. There are three important sub-disciplines within bioinformatics: the development of new algorithms and statistics with which to assess relationships among members of large data sets; the analysis and interpretation of various types of data including nucleotide and amino acid sequences, protein domains, and protein structures; and the development and implementation of tools that enable efficient access and management of different types of information»

6.1.2 Πεδία της Βιοπληροφορικής

Η βιολογία και η ιατρική έχουν αλλάξει σε μεγάλο βαθμό τα τελευταία χρόνια, από μια ποιοτική επιστήμη, ή οποία βασιζόταν σε μεγάλο βαθμό στην παρατήρηση των οργανισμών σε μια περισσότερο ποσοτική επιστήμη που βασίζεται στις μετρήσεις σε μοριακό επίπεδο. Η εφαρμογή της ποσοτικής ανάλυσης στην ιατρική επιστήμη αναπτύσσεται για περισσότερους από δύο αιώνες. Το 1765 ο γνωστός μαθηματικός Daniel Bernoulli υπολόγισε την αποτελεσματικότητα των μαζικών εμβολιασμών ενάντια στην ευλογιά. Στην επιστήμη και την τεχνολογία είναι συνηθισμένο να αναλύουμε δεδομένα, τα οποία συλλέγονται από διάφορα πειράματα που εφαρμόζονται σε διαφορετικά άτομα ενός πληθυσμού.

Εξαιτίας του μεγάλου όγκου πληροφοριών και δεδομένων για την κατάσταση ενός ασθενούς η ιατρική επιστήμη έχει προσανατολιστεί στην εφαρμογή μεθόδων τεχνητής νοημοσύνης στην κλινική λήψη αποφάσεων, στην οποία πρέπει να ληφθούν υπόψη παράγοντες όπως η ασθένεια του ασθενούς, η ψυχολογική του κατάσταση, οι δυνατότητες του οργανισμού του, το κόστος θεραπείας κτλ.. Ένα τυπικό παράδειγμα, το οποίο έχει μελετηθεί αρκετά από την επιστημονική κοινότητα είναι ο χαρακτηρισμός ενός όγκου σε έναν ασθενή ως καλοήγη ή κακοήγη

(L. Prechelt, ‘PROBENI-A set of benchmarks and benchmarking rules for neural network training algorithms’, Technical Report 21/94, Fakultt fr Informatik, University of Karlsruhe, 1994).

Τα τεχνητά νευρωνικά δίκτυα αποτελούν έναν τομέα της υπολογιστικής νοημοσύνης τα οποία ειδικεύονται στην αντιμετώπιση σύνθετων προβλήματων κατηγοριοποίησης με μεγάλο όγκο δεδομένων για τα οποία δεν υπάρχει αλγοριθμική λύση ή είναι αρκετά περίπλοκη για να καθοριστεί. (H. Malmgren, M. Borga, and L. Niklasson, *Artificial Neural Networks in Medicine and Biology, Perspectives in Neural Computing*, Springer, Göteborg, May 2000). Εξαιτίας της εξαιρετικής ικανότητάς τους να παράγουν αξιόπιστες αποφάσεις μετά από κατάλληλη εκπαίδευση έχουν εφαρμοστεί με επιτυχία στην ιατρική, ήδη από τη δεκαετία του '80 έχουν αποδείξει τις δυνατότητες των νευρωνικών δικτύων για την αντιμετώπιση τέτοιων προβλημάτων λήψης αποφάσεων. Ωστόσο κάθε διαδικασία ταξινόμησης πάσχει από σφάλματα, τα οποία μειώνουν τη αξιοπιστία της γενίκευσης, στις ιατρικές εφαρμογές είναι πολύ σημαντικό οι διαγνώσεις να είναι όσον το δυνατόν ακριβέστερες.

Η Βιοπληροφορική ως έννοια αναφέρεται στη συλλογή, οργάνωση και ανάλυση δεδομένων σχετικών με βιολογικά συστήματα. Ο όγκος των πληροφοριών που εμπεριέχονται στο ανθρώπινο DNA είναι τεράστιος

Η μηχανική μάθηση και η υπολογιστική νοημοσύνη χρησιμοποιούνται ως μέθοδοι για να εξάγουν βιολογικά αποτελέσματα από βιομοριακά δεδομένα για τη δημιουργία μοντέλων που αναπαριστούν αυτή τη βιολογική γνώση και έχουν εφαρμοστεί σε ένα ευρύ φάσμα πεδίων της βιοπληροφορικής όπως στη Πρωτεομική, στη Γονιδιωματική, στη Βιολογική εξέλιξη, στην Ανάλυση έκφρασης γονιδίων κ.α.

❖ Στην Πρωτεομική (Proteomics) η πρόβλεψη της δευτεροταγούς και της τριτοταγούς δομής των πρωτεϊνών αποτελεί ένα βασικό πρόβλημα και παράλληλα μια βασική πρόκληση των μεθόδων μηχανικής μάθησης και υπολογιστικής νοημοσύνης.

❖ Στην Γονιδιωματική (Genomics) η οποία μελετάει βιολογικές ακολουθίες σε επίπεδο γονιδίου, οι μέθοδοι εφαρμόζονται για την ανακατασκευή και

ρύθμιση της ακολουθίας γονιδίων σε ολόκληρα γονιδιώματα, για για την πρόβλεψη των φαινοτύπων, για την εξαγωγή δομής των γονιδίων και σε άλλα θέματα της γονιδιωματικής.

❖ Στην συστημική Βιολογία όπου πρόκειται για ένα κλάδο της βιοπληροφορικής που ασχολείται με τη μοντελοποίηση των βιολογικών διαδικασιών στα κύτταρα. Οι Zhang et al δημιούργησαν γενετικά ρυθμιστικά δίκτυα απο χρονικές ακολουθίες δεδομένων έκφρασης γονιδίων για την αλληλεπίδραση των φαρμάκων, επιβεβαιωμένα για την αποτελεσματικότητα τους στην FDA.

❖ Στην ανάλυση δεδομένων έκφρασης γονιδίων που παρέχει σημαντικές πληροφορίες για τη μοριακή βιολογία και την ιατρική.

6.1.3 Ανάλυση Δεδομένων Γονιδιακής Έκφρασης και Σχεδιασμός Φαρμάκων

Η διαδικασία κατά την οποία η κωδικοποιημένη πληροφορία ενός γονιδίου (DNA) μετατρέπεται στις δομικές και λειτουργικές μονάδες ενός κυττάρου (RNA, πρωτεΐνες) καλείται γονιδιακή έκφραση (gene expression). Τα τελευταία χρόνια με την εμφάνιση νέων τεχνολογιών, όπως οι μικροσυστοιχίες (microarrays), έχει γίνει εφικτή η μέτρηση των επιπέδων της έκφρασης χιλιάδων γονιδίων ταυτόχρονα. Το κάθε γονίδιο μπορεί να εκφράζεται με διαφορετικό τρόπο, δηλαδή μπορεί να παράγει διαφορετική ποσότητα προϊόντος (π.χ. πρωτεΐνης) από οργανισμό σε οργανισμό. Η μελέτη των επιπέδων της γονιδιακής έκφρασης μπορεί να αποκαλύψει τα μυστικά της λειτουργίας των οργανισμών και να αποτελέσει ένα σημαντικό όπλο για την καταπολέμηση σημαντικών ασθενειών. Η μηχανική μάθηση είναι ένα από τα σημαντικότερα εργαλεία που χρησιμοποιούνται στη μελέτη και ανάλυση αυτών των δεδομένων.

I.E. Livieris and P. Pintelas, "A survey on algorithms for training artificial neural networks", Technical Report 08-01, Department of Mathematics, University of Patras, 2008.

Υπάρχει μεγάλη συσσώρευση βιολογικών και βιοϊατρικών κειμένων στον παγκόσμιο ιστό. Αντιπροσωπευτικό παράδειγμα αποτελούν οι επιστημονικές δημοσιεύσεις που περιλαμβάνονται στο PubMed Central (<http://www.pubmedcentral.nih.gov>). Η εφαρμογή τεχνικών μηχανικής μάθησης δεν αποσκοπεί μόνο στην αποτελεσματική ανάκτηση σχετικών κειμένων αλλά και τη συσχέτιση γονιδίων, πρωτεϊνών και άλλων βιολογικά σημαντικών εννοιών (π.χ. εύρεση ονομάτων γονιδίων ή πρωτεϊνών που εμφανίζονται στα ίδια κείμενα). Οι πρωτεΐνες αποτελούν τις δομικές και λειτουργικές μονάδες όλων των κυττάρων ενός οργανισμού. Η λειτουργία τους προσδιορίζεται από την τρισδιάστατη δομή τους, η οποία εν μέρει καθορίζεται από την αλληλουχία των πρωτεϊνικών δομικών μονάδων (αμινοξέων) στο μόριό τους. Ένα από τα σημαντικότερα ερωτήματα που ερευνώνται για αρκετές δεκαετίες και δεν έχουν ακόμη απαντηθεί είναι ο προσδιορισμός της τρισδιάστατης δομής μιας πρωτεΐνης δεδομένης της αλληλουχίας των αμινοξέων που την αποτελούν.

Ο σχεδιασμός φαρμάκων απαιτεί τον εντοπισμό των κατάλληλων βιολογικών στόχων (targets), που ουσιαστικά είναι κάποια μόρια στα οποία πρέπει να προσδεθεί μια φαρμακευτική ουσία, ώστε να θεραπεύσει τον πάσχοντα οργανισμό. Ο αποδοτικός και αποτελεσματικός εντοπισμός αυτών των στόχων και κατά συνέπεια ο

σχεδιασμός αποτελεσματικότερων φαρμάκων απαιτεί τη χρήση τεχνικών μηχανικής μάθησης. Δεδομένου το μεγάλο και συνεχώς αυξανόμενο μερίδιο επένδυσης των φαρμακοβιομηχανιών σε IT και e-commerce, κλάδος της φαρμακοβιομηχανίας είναι δυνατό να μετατραπεί σε ηγέτη στον χώρο της νέας τεχνολογίας. Επίσης, η μεγάλη ανάπτυξη των δικτύων των υπολογιστών σε συνδυασμό με τις ιδιαίτερες ανάγκες κάθε χώρας ή περιοχής του κόσμου για ξεχωριστά φάρμακα, παρέχει τη δυνατότητα στον κλάδο να αναπτυχθεί σε παγκόσμιο επίπεδο με γρήγορους ρυθμούς

6.1.4 Υπολογιστικές τεχνικές στο σχεδιασμό φαρμάκων

Οι υψηλής τεχνολογίας ηλεκτρονικοί υπολογιστές αποτελούν σήμερα πολύτιμο εργαλείο στο σχεδιασμό των φαρμάκων παρέχοντας πολύτιμες πληροφορίες σχετικά με:

- Τις προβλέψεις για νέα μόρια
- Τη σύγκριση ενός μορίου με άλλα μόρια
- Την τρισδιάστατη αρχιτεκτονική των μορίων
- Τις φυσικοχημικές τους ιδιότητες
- Τα σύμπλοκα μικρομορίων-μακρομορίων

Η συνεισφορά της Βιοπληροφορικής στο σχεδιασμό νέων φαρμάκων είναι πολύ σημαντική εφόσον στοχεύει στο να σχεδιαστεί ένα φάρμακο χτισμένο ειδικά πάνω στο γονιδιακό υπόστρωμα του κάθε ασθενούς, δηλαδή μια εξατομικευμένη φαρμακευτική αντιμετώπιση. Βασικός σκοπός είναι ο σχεδιασμός αποδοτικών αλγορίθμων και μεθόδων για το σχεδιασμό φαρμακευτικών μορίων στοχεύοντας ασθένειες όπως ο καρκίνος και το AIDS. Οι χρησιμοποιούμενες μέθοδοι συνδυάζουν:

- Αλγόριθμους γραφικών
- Γεωμετρικούς υπολογισμούς
- Αριθμητικές μεθόδους
- Γραφοθεωρητικές μεθόδους

Τα πλεονεκτήματα που προκύπτουν είναι η μείωση: 1. του χρόνου πρόβλεψης μιας νέας φαρμακολογικής ουσίας 2. του κόστους ανάπτυξης ενός φαρμακοφόρου μορίου που σήμερα ανέρχεται στα 500 εκ. δολάρια.

Οι επιστήμονες υποστηρίζουν ότι η βιοπληροφορική θα πάρει τη μορφή υπολογιστών DNA. Στόχος τους είναι να ενσωματώσουν ανθρώπινο γενετικό υλικό μέσα στους μικροεπεξεργαστές, με σκοπό, αρχικά, τη δημιουργία υπερυπολογιστών οι οποίοι θα εκτελούν πολύπλοκους υπολογισμούς και θα επιλύουν δύσκολα μαθηματικά προβλήματα. Την επίβλεψη για τη δημιουργία των επεξεργαστών DNA έχουν αναλάβει οι εταιρείες βιοτεχνολογίας, ελπίζοντας ότι η δημιουργία τους σε συνδυασμό με τις πρόσφατες εξελίξεις στην αποκωδικοποίηση του ανθρώπινου γονιδιώματος θα αλλάξει δραματικά προς το καλύτερο την ανίχνευση και στη συνέχεια τη θεραπεία ανίατων σήμερα ασθενειών.

6.1.5 Γενετικοί αλγόριθμοι

Η τεχνική αυτή αποτελεί μια στοχαστική μέθοδο αναζήτησης για την εύρεση βέλτιστων λύσεων σε ποικίλους και περίπλοκους χώρους αναζήτησης. Το σύνολο από στιγμιότυπα καλείται πληθυσμός εκεί ακριβώς όπου χρησιμοποιείται ο γενετικός αλγόριθμος. Τα στιγμιότυπα που αποτελούν κωδικοποιημένα δεδομένα εισόδων ενός προβλήματος και ονομάζονται χρωμοσώματα. Τα χρωμοσώματα αποτελούνται από γονίδια τα οποία έχουν δυαδικές τιμές το καθένα ξεχωριστά που δηλώνουν την ύπαρξη ή όχι συγκεκριμένων στοιχείων. Η συνάρτηση καταλληλότητας όπως ονομάζεται αποτελεί την ορθότερη λύση σε τέτοιου είδους αναζητήσεις και συγκεκριμένα οι συναρτήσεις με τη μεγαλύτερη τιμή έχουν την ιδιότητα να παράγουν εκ νέου καινούργιες λύσεις σε σχέσει με τις συναρτήσεις χαμηλότερων τιμών καταλληλότητας.

Οι γενετικοί αλγόριθμοι περιέχουν τρεις βασικούς τελεστές :
επιλογή - διασταύρωση - μετάλλαξη για τους υπολογισμούς στα βιολογικά συστήματα.

Οι ερευνητές ερευνητές ασχολήθηκαν με το να αντύξουν γενετικά εξελισσόμενες αρχιτεκτονικές δικτύων με τη χρήση γενετικών αλγορίθμων οι οποίοι χρησιμεύουν στη ρύθμιση παραμέτρων του δικτύου. Παράλληλα εξέτασαν νευρωνικά δίκτυα για εκπαίδευση βαρών στις εφαρμογές μάθησης υπό επίβλεψη όπου τα δεδομένα εκπαίδευσης είναι διαθέσιμα και τα νευρωνικά δίκτυα αποτελούν δίκτυα εμπύροσθιας τροφοδότησης.

Άλλη κατηγορία είναι οι κατασκευαστικοί αλγόριθμοι, ο λεγόμενος αλγόριθμος κλιμακωτής συσχετικής εκμάθησης αρχιτεκτονικών. Ο συγκεκριμένος αλγόριθμος προσθέτει συνεχώς απόρρητες μονάδες στο δίκτυο.

Ο αλγόριθμος γενικευμένης απόκτησης συνδέσεων ανάδρασης ο οποίος χρησιμοποιεί μεταλλάξεις και επιλογές για την εύρεση του πεδίου για τα νευρωνικά δίκτυα με ανατροφοδότηση.

6.1.6 Παράδειγμα αλγόριθμου Adaboost (adaptive boosting)

Ο αλγόριθμος Adaboost είναι κατασκευαστικός αλγόριθμος ταξινομητών όπου βελτιώνει την συλλογική ταξινομία μέσα από μια επαναλαμβανόμενη διαδικασία. Συγκεκριμένα γίνεται αντιστοίχιση βάρους σε όλα τα δείγματα που είναι δύσκολο να ταξινομηθούν. Το αποτέλεσμα είναι i σε κάθε επανάληψη τα βάρη από τα δείγματα που δεν ταξινομήθηκαν σωστά αυξάνονται ενώ παράλληλα μειώνονται εκείνα που ταξινομήθηκαν ορθά.

Input : Αλγόριθμος αθενούς επαγωγής I
Αριθμός επαναλήψεων T
Σύνολο εκπαίδευσης S

Outpout : Ταξινομητές Mt
Βάρη at

t ← 1
t= 1,.....,T
D1 (i) ← 1/m, i=1,.....,T REAPET

Παραδείγματα

Πρόβλημα Διάγνωσης του Καρκίνου του Μαστού

Το πρόβλημα διάγνωσης του καρκίνου του μαστού ταξινομεί έναν όγκο ως καλοήγη ή κακοήγη βασισμένο σε 9 χαρακτηριστικά γνωρίσματα

(L. Prechelt, ‘PROBENI-A set of benchmarks and benchmarking rules for neural network training algorithms’, Technical Report 21/94, Fakultt fr Informatik, University of Karlsruhe, 1994)

Τα δεδομένα αντλήθηκαν από το πανεπιστήμιο του Wisconsin και αποτελούνται από τις εξετάσεις 683 γυναικών. Χρησιμοποιήσαμε νευρωνικά δίκτυα με δύο κρυφά επίπεδα με δύο νευρώνες το καθένα και ένα στρώμα εξόδου με δύο νευρώνες. Τα νευρωνικά δίκτυα αξιολογήθηκαν χρησιμοποιώντας την διασταυρωμένη επικύρωση 10 σημείων

(P. Horton and K. Nakai, ‘Better prediction of protein cellular localization sites with the k Nearest Neighbors classifier’, In the Proceedings of the Proceedings of Intelligent Systems in Molecular Biology, 368–383, 1997).

Το κριτήριο τερματισμού ήταν $E \leq 0.02$ μέσα στο όριο των 2000 υπολογισμών της τιμής των εποχών ETNA ANDE Αλγόριθμος Min Mean Max s.d. succ Min Mean Max. s.d. succ BP 1599 1708.3 1843 87.3 4% 1005 1266.0 1629 264.8 3% BBP 32 133.4 558 99.0 98% 32 170.1 1262 176.1 100% NMBBP 28 88.5 290 57.5 98% 26 103.8 653 91.3 100% BPVS 61 415.6 1985 411.9 96% 55 475.4 1849 408.3 97% NMBPVS 48 394.9 1799 374.2 98% 67 445.8 1940 392.1 96% BFGS 14 108.6 1912 216.0 97% 13 113.8 1278 194.9 93% ASCNMBFGS 14 61.7 383 56.8 98% 13 61.9 351 50.4 98% ASCNMBFGS+ 11 32.7 273 32.0 100% 11 33.3 200 27.7 100% CG 74 394.9 1705 352.5 98% 56 411.5 1765 336.9 92% ANMCG 70 258.6 1210 243.5 98% 74 270.9 655 150.9 93% ANMSCG 20 81.8 710 99.5 100% 18 85.9 447 73.6 100% : Αποτελέσματα των προσομοιώσεων για το πρόβλημα της διάγνωσης του καρκίνου του μαστού, παρουσιάζονται τα αποτελέσματα των προσομοιώσεων των μεθόδων για το πρόβλημα της διάγνωσης του καρκίνου του μαστού.

Οι μέθοδοι Quasi-Newton παρουσιάζουν άριστη απόδοση (100%) και απαιτούν το μικρότερο μέσο αριθμό εποχών για την εκπαίδευση των δικτύων. Η μέθοδος ASCNMBFGS+ υπερτερεί έναντι των υπολοίπων QuasiNewton μεθόδων, η οποία εκθέτει 50% με 75% λιγότερο μέσο αριθμό εποχών. Όσον αφορά τις μεθόδους συζυγών κλίσεων, η μέθοδος ANMSCG παρουσιάζει την άριστη πιθανότητα επιτυχημένης εκπαίδευσης (100%) και χρειάζεται 3 με 5 φορές λιγότερο μέσο αριθμό εποχών. Επίσης αξίζει να αναφέρουμε ότι η μη μονότονη στρατηγική αποτελεί ένα σημαντικό παράγοντα για την απόδοση όλων των μεθόδων μειώνοντας σημαντικά το υπολογιστικό τους κόστος.

Πρόβλημα Διάγνωσης της Καρδιακής Ανεπάρκειας

Το πρόβλημα αυτό κατηγοριοποιεί έναν ασθενή με βάση τα στοιχεία που συλλέχθηκαν από τον τομογράφο, αν έχει ή όχι πρόβλημα καρδιακής ανεπάρκειας. Το πρόβλημα διάγνωσης της καρδιακής ανεπάρκειας αποτελείται από 267 παραδείγματα, τα οποία συγκεντρώθηκαν στο Πανεπιστήμιο του Colorado (P.M.

Murphy and D.W. Aha, ‘‘UCI repository of machine learning databases’’, Irvine, CA: University of California, Department of Information and Computer Science, 1994.)

Από το σύνολο των ασθενών οι 55 έχουν χαρακτηριστεί ότι έχουν κάποιο καρδιακό πρόβλημα ενώ οι υπόλοιποι 212 θεωρούνται υγιείς. Τα νευρωνικά δίκτυα, τα οποία χρησιμοποιήθηκαν αποτελούνται από ένα κρυφό στρώμα των έξι νευρώνων και ένα στρώμα εξόδου με ένα νευρώνα. Επιλέξαμε τυχαία 80 παραδείγματα για την εκπαίδευση των δικτύων και τα υπόλοιπα 187 χρησιμοποιήθηκαν για την αξιολόγηση της γενίκευσης των δικτύων. Το κριτήριο τερματισμού ορίστηκε $E \leq 0.1$ μέσα στο όριο των 1000 εποχών .

Αλγόριθμος	ETNA					ANAE				
	Min	Mean	Max	s.d.	succ	Min	Mean	Max.	s.d.	succ
BP	1599	1708.3	1843	87.3	4%	1005	1266.0	1629	264.8	3%
BBP	32	133.4	558	99.0	98%	32	170.1	1262	176.1	100%
NMBBP	28	88.5	290	57.5	98%	26	103.8	653	91.3	100%
BPVS	61	415.6	1985	411.9	96%	55	475.4	1849	408.3	97%
NMBPVS	48	394.9	1799	374.2	98%	67	445.8	1940	392.1	96%
BFGS	14	108.6	1912	216.0	97%	13	113.8	1278	194.9	93%
ASCNMBFGS	14	61.7	383	56.8	98%	13	61.9	351	50.4	98%
ASCNMBFGS ⁺	11	32.7	273	32.0	100%	11	33.3	200	27.7	100%
CG	74	394.9	1705	352.5	98%	56	411.5	1765	336.9	92%
ANMCG	70	258.6	1210	243.5	98%	74	270.9	655	150.9	93%
ANMSCG	20	81.8	710	99.5	100%	18	85.9	447	73.6	100%

Αποτελέσματα των προσομοιώσεων για το πρόβλημα της διάγνωσης της καρδιακής ανεπάρκειας παρουσιάζονται τα αποτελέσματα των προσομοιώσεων για το πρόβλημα διάγνωσης της καρδιακής ανεπάρκειας. Όλες οι μέθοδοι εκτός από τη μέθοδο της οπίσθιας διάδοσης του σφάλματος παρουσιάζουν άριστη πιθανότητα (100%) επιτυχημένης εκπαίδευσης και για τους δύο τύπους νευρωνικών δικτύων. Γι αυτό το λόγο το υπολογιστικό κόστος είναι ο κατάλληλος παράγοντας για την αξιολόγηση της απόδοσης αυτών των μεθόδων. Η μέθοδος ASCNMBFGS+ επιδεικνύει το μικρότερο μέσο αριθμό εποχών συγκριτικά με τις υπόλοιπες μεθόδους Quasi-Newton. Επίσης όσον αφορά τις μεθόδους συζυγών κλίσεων η 150 μέθοδος ANMSCG απαιτεί το μικρότερο μέσο αριθμό εποχών. Επιπλέον, οι μέθοδοι της οπίσθιας διάδοσης του σφάλματος με μεταβλητό βήμα (BPVS και NMBPVS) παρουσιάζει 50% με 75% λιγότερο μέσο αριθμό εποχών σε σχέση με τις μονότονες και μη μονότονες μεθόδους πρώτης τάξης, αντίστοιχα.

Πρόβλημα Διάγνωσης του Διαβήτη

Υπάρχουν 8 χαρακτηριστικά, τα οποία αντιπροσωπεύουν τις προσωπικές εξετάσεις κάθε ασθενούς και προκύπτουν από διάφορες ιατρικές εξετάσεις. Ο στόχος αυτού του διάσημου προβλήματος ταξινόμησης είναι να αποφασιστεί πότε ένας ασθενής πάσχει από διαβήτη. Συνολικά το σύνολο των δεδομένων αποτελείται από 768 παραδείγματα εκ των οποίων, οι 500 έχουν διαβητική συμπεριφορά. Χρησιμοποιήσαμε νευρωνικά δίκτυα με δύο κρυφά επίπεδα των τεσσάρων νευρώνων το καθένα και ένα επίπεδο εξόδου με 2 νευρώνες .

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

P.M. Murphy and D.W. Aha, "UCI repository of machine learning databases", Irvine, CA: University of California, Department of Information and Computer Science, 1994.)

Το κριτήριο τερματισμού ορίστηκε $E \leq 0.14$ μέσα στο όριο των 2000 εποχών και τα νευρωνικά δίκτυα αξιολογήθηκαν χρησιμοποιώντας τη διασταυρωμένη επικύρωση

3

σημείων.

Αλγόριθμος	ETNA					ANAE				
	Min	Mean	Max	s.d.	succ	Min	Mean	Max.	s.d.	succ
BP	1599	1708.3	1843	87.3	4%	1005	1266.0	1629	264.8	3%
BBP	32	133.4	558	99.0	98%	32	170.1	1262	176.1	100%
NMBBP	28	88.5	290	57.5	98%	26	103.8	653	91.3	100%
BPVS	61	415.6	1985	411.9	96%	55	475.4	1849	408.3	97%
NMBPVS	48	394.9	1799	374.2	98%	67	445.8	1940	392.1	96%
BFGS	14	108.6	1912	216.0	97%	13	113.8	1278	194.9	93%
ASCNMBFGS	14	61.7	383	56.8	98%	13	61.9	351	50.4	98%
ASCNMBFGS ⁺	11	32.7	273	32.0	100%	11	33.3	200	27.7	100%
CG	74	394.9	1705	352.5	98%	56	411.5	1765	336.9	92%
ANMCG	70	258.6	1210	243.5	98%	74	270.9	655	150.9	93%
ANMSCG	20	81.8	710	99.5	100%	18	85.9	447	73.6	100%

Αποτελέσματα των προσομοιώσεων για το πρόβλημα της διάγνωσης του διαβήτη, παρουσιάζονται τα αποτελέσματα των προσομοιώσεων για το πρόβλημα διάγνωσης του διαβήτη. Και σε αυτό το πρόβλημα είναι καθαρή η υπεροχή των μεθόδων Quasi-Newton με τη μέθοδο ASCNMBFGS⁺ να υπέρχει αισθητά έναντι των υπολοίπων. Χαρακτηριστικό είναι ότι είναι η μόνη μέθοδος που παρουσιάζει άριστη πιθανότητα (100%) εκπαίδευσης και το μικρότερο μέσο αριθμό εποχών. Όσον αφορά τις μεθόδους συζυγών κλίσεων, η μέθοδος ANMSCG εκθέτει άριστη πιθανότητα εκπαίδευσης (100%) και απαιτεί το μικρότερο μέσο αριθμό εποχών. Επίσης αξίζει να τονίσουμε ότι η εφαρμογή μεταβλητού ρυθμού εκπαίδευσης έχει πολύ σημαντική επίδραση στην απόδοση της μεθόδου της οπίσθιας διάδοσης του σφάλματος, η οποία δεν κατάφερε να εκπαιδεύσει κανένα νευρωνικό δίκτυο μέσα στο προκαθορισμένο όριο εποχών.

6.2 Παγκόσμιος Ιστός

Ο Παγκόσμιος Ιστός (World Wide Web - WWW) είναι η πιο ευρέως γνωστή υπηρεσία του Διαδικτύου η οποία μας επιτρέπει την πρόσβαση σε μια απεριόριστη συλλογή ψηφιακών εγγράφων, τις ιστοσελίδες. Αποτελεί ένα ανοιχτό σύστημα διασυνδεδεμένων πληροφοριών και πολυμεσικού περιεχομένου, που επιτρέπει στους χρήστες του Διαδικτύου να αναζητήσουν πληροφορίες μεταβαίνοντας από ένα έγγραφο στο άλλο. Στην ουσία είναι ένα σύνολο από ηλεκτρονικές σελίδες (web pages) μεγάλης πολυπλοκότητας οι οποίες εισάγονται και εξάγονται από αυτό με μία διαδικασία εντελώς αποκεντρωμένη διότι υπάρχει έλλειψη προτύπων και η παντελής έλλειψη δομής και οργάνωσης των σελίδων. Οι σελίδες του Ιστού μπορούν να έχουν γραφτεί σε διάφορες γλώσσες, διαλέκτους ή μορφές από άτομα με διαφορετικό υπόβαθρο, μόρφωση, κουλτούρα, ενδιαφέροντα και κίνητρα. Το μέγεθος του Παγκόσμιου Ιστού αυξάνει διαρκώς και με ιδιαίτερα γρήγορους ρυθμούς.

Κάθε δίκτυο-δομική μονάδα του διαδικτύου αποτελείται από συνδεδεμένους υπολογιστές σε τοπικό επίπεδο. Τα δίκτυα με τη σειρά τους συνδέονται σε ευρύτερα δίκτυα, όπως εθνικά και υπερεθνικά. Το ευρύτερο δίκτυο στον κόσμο λέγεται παγκόσμιος ιστός το οποίο είναι μοναδικό (δηλαδή δεν υπάρχουν παραπάνω από ένα

δίκτυα υπολογιστών παγκόσμιας κλίμακας), και συμπεριλαμβάνεται τόσο τα γήινα δίκτυα, όσο και τα δίκτυα των δορυφόρων της και άλλων διαστημικών συσκευών που είναι συνδεδεμένα σε αυτό. (Arindam Banerjee, Joydeep Ghosh, "Concept-based clustering of clickstream data", *Proceedings of the 3rd International Conf. on Information Technology, pages 145-150, Dec 2000*)

Η τεχνολογία του ιστού καθιστά δυνατή την δημιουργία "υπερκειμένων", μία διασύνδεση δηλαδή πάρα πολλών μη ιεραρχημένων στοιχείων που παλαιότερα ήταν απομονωμένα. Τα στοιχεία αυτά μπορούν να πάρουν και άλλες μορφές πέραν της μορφής του γραπτού κειμένου, όπως εικόνας και ήχου. Η τεχνολογία του ιστού δημιουργήθηκε το 1989 από τον Βρετανό Τιμ Μπέρνερς Λι, που εκείνη την εποχή εργαζόταν στον Ευρωπαϊκό Οργανισμό Πυρηνικών Ερευνών (CERN) στην Γενεύη της Ελβετίας. Το όνομα που έδωσε στην εφευρέσή του ο ίδιος ο Lee είναι World Wide Web, όρος γνωστός στους περισσότερους από το "www". Αυτό που οδήγησε τον Lee στην εφεύρεση του Παγκόσμιου ιστού ήταν το όραμά του για ένα κόσμο όπου ο καθένας θα μπορούσε να ανταλλάσσει πληροφορίες και ιδέες άμεσα προσβάσιμες από τους υπολοίπους. Το σημείο στο οποίο έδωσε ιδιαίτερο βάρος ήταν η μη ιεράρχηση των διασυνδεδεμένων στοιχείων. Οραματίστηκε κάθε στοιχείο, κάθε κόμβο του ιστού ίσο ως προς την προσβασιμότητα με τα υπόλοιπα.

Ο Παγκόσμιος Ιστός έχει πολύ μικρότερη ιστορία από το Διαδίκτυο (το οποίο ξεκίνησε το 1969). Το 1989 ο Τιμ Μπέρνερς Λι (Tim Berners - Lee), μέλος του κέντρου CERN (Σερν - Κέντρο Φυσικής Υψηλής Ενέργειας) επινόησε τον Παγκόσμιο Ιστό, προσπαθώντας να βρει ένα τρόπο να αρχειοθετεί τις επιστημονικές μελέτες των συνεργατών του CERN. Η επιτυχία του ήταν τόσο μεγάλη, ώστε πολύ γρήγορα ενσωματώθηκε στις υπηρεσίες του Διαδικτύου γνωρίζοντας τεράστια απήχηση χάρη στον απλό και ελκυστικό τρόπο περιήγησης και αναζήτησης πληροφοριών.

Οι περισσότερες πληροφορίες στον Παγκόσμιο Ιστό είναι δωρεάν



Κάθε ιστοσελίδα που περιέχεται σε δικτυακό τόπο, έχει τη δική της διεύθυνση στον Παγκόσμιο Ιστό, όπως κι εμείς έχουμε τη δική μας διεύθυνση κατοικίας. Όταν καλούμε ένα φίλο στο σπίτι μας για πρώτη

φορά, του δίνουμε τη διεύθυνσή μας, ώστε να μπορέσει να μας βρει. Όμοια, αν θέλουμε να «επισκεφτούμε» μία ιστοσελίδα, πρέπει να ξέρουμε τη διεύθυνσή της. Η διεύθυνση αυτή καλείται **URL (Uniform Resource Locator) – Ενιαίος Προσδιοριστής Πόρου** ή απλούστερα **διεύθυνση ιστοσελίδας**. Μία διεύθυνση ιστοσελίδας είναι μοναδική και έχει συνήθως την εξής μορφή:



Η επίσκεψη της μιας ιστοσελίδας μετά την άλλη, στην γλώσσα της πληροφορικής ονομάζεται πλοήγηση στον Παγκόσμιο Ιστό. Η δυνατότητα να βλέπουμε το περιεχόμενο των ιστοσελίδων και να πλοηγούμαστε ανάμεσα τους, προϋποθέτει να υπάρχει ένα Λογισμικό Πλοήγησης ή Φυλλομετρητής (Browser). Οι πιο δημοφιλείς φυλλομετρητές είναι: Microsoft Internet Explorer, Netscape Navigator, Mozilla, Firefox, Opera κ.α. . C. Shahabi, A. M. Zarkesh, J. Abidi, and V. Shah, “Knowledge discovery from users webpage navigation”, *Proceedings of workshop on research issues in Data engineering, Birmingham, England, 1997*

6.2.1 Ανακάλυψη Γνώσης από Δεδομένα Ηλεκτρονικής Αλληλογραφίας - Διαφήμιση

Αναπόσπαστο πλέον κομμάτι της καθημερινότητάς μας αποτελεί το ηλεκτρονικό ταχυδρομείο αφού χρησιμοποιείται ως βασικό μέσο επικοινωνίας, αλλά και ως εργαλείο ανταλλαγής πληροφοριών και αρχείων. Η κακή χρήση και η κατάχρηση όμως του μέσου οδήγησε σε προβλήματα που συνοψίζονται στον όρο «Email Overload». Οι χρήστες λαμβάνουν καθημερινά μεγάλο αριθμό ηλεκτρονικών μηνυμάτων από τα οποία τα περισσότερα μας είναι εντελώς άχρηστα. Η μηχανική μάθηση έχει προταθεί ως λύση στο πρόβλημα του φιλτραρίσματος spam μηνυμάτων αλλά και γενικότερα της αυτοματοποιημένης διαχείρισης του ηλεκτρονικού ταχυδρομείου: αυτόματη ομαδοποίηση μηνυμάτων, παραγωγή περίληψης, κατάταξη σε φακέλους κτλ (. H.Marmais 2008)

Η μηχανική μάθηση μπορεί να υποστηρίξει σημαντικά τις διαδικασίες της διαφήμισης στο διαδίκτυο, όπως για παράδειγμα στην πρόβλεψη του αριθμού των click (click rate prediction), στην παραγωγή λέξεων κλειδιών (keyword generation) για κάποιον διαφημιζόμενο, στην ανακάλυψη απάτης στις pay-per-click διαφημίσεις (click fraud detection) και στην επιλογή της κατάλληλης διαφήμισης (content matching) ανάλογα με χαρακτηριστικά του χρήστη (π.χ. λέξεις κλειδιά σε μηχανές

αναζήτησης, ιστοσελίδες που επισκέπτεται, κ.α.). Η μελέτη μπορεί είτε να εμβαθύνει σε μία από τις παραπάνω υποεφαρμογές είτε να σχολιάσει περισσότερες σε λιγότερο βάθος. Η πληροφορία που είναι διαθέσιμη από πολλούς διαδικτυακούς τόπους είναι ιδιαίτερα μεγάλη αφού καλύπτει μεγάλο εύρος θεματολογίας και ανανεώνεται με ιδιαίτερα γρήγορους ρυθμούς. Το φαινόμενο αυτό δημιουργεί πρόβλημα στο χρήστη αφού αδυνατεί να ξεχωρίσει τη πληροφορία που πραγματικά τον ενδιαφέρει. Για το λόγο αυτό έχει προταθεί η χρήση μηχανικής μάθησης για τη προσωποποίηση του περιεχομένου τέτοιων διαδικτυακών τόπων. Η πορεία πλοήγησης (π.χ. ποια άρθρα διαβάζει ο χρήστης) μπορεί να καταγραφεί και να τροφοδοτηθεί σε αλγορίθμους μηχανικής μάθησης οι οποίοι αναλαμβάνουν να «μάθουν» τα ενδιαφέροντα του χρήστη και θα βοηθήσουν το σύστημα να παρουσιάζει περιεχόμενο μόνο από σχετικές θεματολογίες.

Τα προγράμματα τα οποία συλλέγουν ιστοσελίδες από τον Παγκόσμιο Ιστό είναι οι περιηγητές. Μία από τις πιο σημαντικές εφαρμογές των περιηγητών είναι οι μηχανές αναζήτησης όπου χρησιμοποιούνται για την ανανέωση των ιστοσελίδων που δεικτοδοτούν. Επιπρόσθετα, χρησιμοποιούνται για να βοηθούν τους χρήστες να λαμβάνουν ενημερωμένες πληροφορίες από ιστοτόπους που τους ενδιαφέρουν. Μια ενδιαφέρουσα εφαρμογή των περιηγητών είναι η συλλογή πληροφοριών για επιχειρήσεις από τον Παγκόσμιο Ιστό. Τα τελευταία χρόνια, εξαιτίας της μεγάλης έκρηξης της πληροφορίας στον Παγκόσμιο Ιστό, έχουν αναπτυχθεί δικτυακές πύλες οι οποίες είναι προσανατολισμένες σε μία θεματική περιοχή (vortals). Αυτές οι πύλες χρησιμοποιούν προσανατολισμένους περιηγητές (focused crawlers) για να καλύψουν την εκάστοτε θεματική περιοχή. (*Rakesh Agrawal, Ramakrishnan Srikant, Fast Algorithms for Mining Association Rules, Proc. 20th Int. Conf. Very Large Data Bases, VLDB*)

6.2.2 Εξόρυξη δεδομένων (data mining) και κατηγορικά δεδομένα

Είναι σαφές πια ότι ο παγκόσμιος ιστός είναι το δυνατότερο μέσο επικοινωνίας παγκοσμίως, όπου η μετατροπή των δεδομένων σε πληροφορία απαιτείται να οδηγεί στη μετατροπή της πληροφορίας σε γνώση. Η συνύπαρξη ετερόκλητων επιστημονικών πεδίων όπως της στατιστικής, της μηχανικής εκμάθησης, της θεωρίας της πληροφορίας και των υπολογιστικών διαδικασιών, έχει δημιουργήσει μια νέα επιστήμη με δυναμικά εργαλεία. Η επιστήμη αυτή καλείται «Εξόρυξη Δεδομένων (ΕΔ)» (Data Mining) και είναι μέρος της διαδικασίας «Ανακάλυψης Γνώσης από Βάσεις Δεδομένων» (Knowledge Discovery in Databases – KDD). . *C. Shahabi, A. M. Zarkesh, J. Abidi, and V. Shah, "Knowledge discovery from users webpage navigation", Proceedings of workshop on research issues in Data engineering, Birmingham, England, 1997*

Ο τομέας που ασχολείται με την εξόρυξη δεδομένων απο τον ιστό και την εξαγωγή γνώσης καλείται Web Mining. Τα εργαλεία της ΕΔ είναι οι αλγόριθμοί της, οι οποίοι επιχειρούν να βρουν χρήσιμα και κατανοητά πρότυπα στα δεδομένα. Το web mining διερευνά τα δεδομένα και τα περιεχόμενα των ιστοσελίδων καθώς και ελέγχει τα αποτελέσματα μιας αναζήτησης είτε σε κείμενο είτε σε γραφικά. Δεδομένου του ότι το μέγεθος των ιστοσελίδων είναι απροδιόριστα μεγάλο με ανομοιόμορφη δομή και ατελείς οληροφορίες, δημιουργεί πιο επιτακτική την ανάγκη για ανάπτυξη και χρήση τεχνικών ώστε τα αποτελέσματα αναζήτησης να είναι ακριβή

και ορθά. Το World Wide Web (www) ορίζεται ως ευρεία περιοχή ανάκτησης δεδομένων ή υπερμεσικής (hypermedia) πληροφορίας όπου σκοπό έχει να προσφέρει καθολική πρόσβαση σε απεριόριστο σύνολο κειμένων-δεδομένων. Στο web usage mining (/log mining) γίνεται επεξεργασία των log αρχείων όσον αφορά τη πρόσβαση του χρήστη στις ποικίλες ιστοσελίδες, έτσι με τη βοήθεια τεχνικών γίνεται κατανοητή η συμπεριφορά του χρήστη και η δομή της πληροφορίας. Επίσης αναγνωρίζοντας τα πρότυπα της κίνησης γίνεται εξόρυξη ακολουθιακών προτύπων (sequential patterns), τα οποία μπορούν να συσταδοποιηθούν με βάση τις ομοιότητες τους. Τα τελευταία χρόνια έχουν υλοποιηθεί πολλές εφαρμογές και αλγόριθμοι για την εξαγωγή συμπερασμάτων από δεδομένα διαδικτύου. Ο παγκόσμιος ιστός συνιστά μια απέραντη και παγκόσμια πηγή δεδομένων. Η εύρεση εκτόπων (outliers) είναι ένα στοιχειώδες μέρος της διαδικασίας εξόρυξης δεδομένων. Ειδικότερα, έχει χρησιμοποιηθεί στην εύρεση και αφαίρεση ανωμαλιών από δεδομένα. Τα έκτοπα παρουσιάζονται από κάποιο μηχανικό σφάλμα, αλλαγή σε μία συμπεριφορά ενός συστήματος ή ανθρώπινα λάθη. (Fu, Y., Sandhu, K., Shih, M., "A Generalization-Based Approach to Clustering of Web Usage Sessions", *Proceedings of WEBKDD 1999 (San Diego CA, August 1999)*)

6.2.3 Αλγόριθμοι και τεχνικές εξόρυξης δεδομένων από ροές δεδομένων στον παγκόσμιο ιστό

Το γεγονός ότι τα τελευταία χρόνια είναι όλο και πιο επιτακτική η ανάγκη αξιοποίησης ψηφιακών δεδομένων καθώς και ότι υπάρχει ραγδαία αύξηση του όγκου των δεδομένων επιβάλλεται η δημιουργία υπολογιστικών μεθόδων με απώτερο σκοπό την εξόρυξη της χρήσιμης πληροφορίας και γνώσης από αυτά. Οι μέθοδοι εξόρυξης δεδομένων παρουσιάζουν ιδιαίτερο ενδιαφέρον ειδικά στην περίπτωση όπου η πηγή των δεδομένων είναι οι ροές δεδομένων. Με τον όρο ροές δεδομένων εννοούμε προσωρινά δεδομένα τα οποία περνούν από ένα σύστημα «παρατηρητή» συνεχώς και σε μεγάλο όγκο. Σε αντίθεση με τα στατικά δεδομένα σε βάσεις δεδομένων, οι ροές δεδομένων υπάρχουν σε μεγάλο όγκο, συνήθως δεν τελειώνουν, αλλάζουν δυναμικά, και απαιτούν γρήγορες αντιδράσεις. Τα μοναδικά αυτά χαρακτηριστικά κάνουν την ανάλυση των ροών δεδομένων πολύ ενδιαφέρουσα. Ο τομέας αυτός (web mining) είναι αρκετά σύγχρονος και υπάρχουν αρκετές τεχνικές εφαρμογής του. Ειδικά στην κατηγορία τεχνικών γνωστές ως web usage mining techniques η διαχείριση των web click data streams καθώς και άλλων μορφών δεδομένων που έχουν να κάνουν με το χρήστη μπορεί να οδηγήσει στην δημιουργία τάσεων (trends) και προτύπων (patterns) για τη βελτίωση της ποιότητας των υπηρεσιών και των αναγκών του χρήστη. (Usama M. Fayyad, S. George Djorgovski, Nicholas Weir: *From Digitized Images to Online Catalogs: Data Mining a Sky Survey. AI Magazine 17(2): 51-66 (1996)*)

Ένα ενδιαφέρον πεδίο που έχει κερδίσει μεγάλη προσοχή είναι η προσωποποίηση του ιστού στην ερευνητική περιοχή, όπου πολλές ερευνητικές μονάδες έχουν ασχοληθεί με το πρόβλημα από διαφορετικές μεριές, αλλά και στην επιχειρησιακή περιοχή, όπου υπάρχει μία ποικιλία εργαλείων και εφαρμογών που διαθέτουν μια ή περισσότερες υπηρεσίες στη διαδικασία της εξατομίκευσης.

Εξερευνώντας τις πληροφορίες που κρύβονται στα logs του εξυπηρετητή δικτύου, ο στόχος όλων αυτών είναι να ανακαλύψουν τις αλληλεπιδράσεις μεταξύ των επισκεπτών των ιστότοπων και των ιστοσελίδων που περιέχονται σε αυτούς. Οι πληροφορίες αυτές μπορούν να αξιοποιηθούν για τη βελτιστοποίηση των δικτυακών τόπων, εξασφαλίζοντας έτσι αποτελεσματικότερη πλοήγηση για τον επισκέπτη και διατήρηση του πελάτη στην περίπτωση του επιχειρηματικού τομέα. Ένα βασικό βήμα πριν την εξατομίκευση αποτελεί η εξόρυξη χρησιμοποίησης (usage mining) από τον ιστό, ώστε να αποκαλυφθεί τη γνώση που κρύβεται στα log αρχεία ενός web εξυπηρετητή. Εφαρμόζοντας στατιστικές μεθόδους και μεθόδους εξόρυξης δεδομένων στα web log δεδομένα, μπορούν να προσδιοριστούν ενδιαφέροντα πρότυπα που αφορούν τη συμπεριφορά πλοήγησης των χρηστών, όπως συστάδες χρηστών και σελίδων και πιθανές συσχετίσεις μεταξύ web σελίδων και ομάδων χρηστών. Μια προσπάθεια συγχώνευσης γίνεται τα τελευταία χρόνια του περιεχομένου του ιστού στη διαδικασία εξόρυξης χρησιμοποίησης, για να επανξηθεί η αποτελεσματικότητα της εξατομίκευσης. (Ming-Syan Chen, Jong Soo Park, Philip S. Yu, "Efficient Data Mining for Path Traversal Patterns", IEEE Trans. on Knowledge and Data Engineering, 10(2):209-221, March 1998)

Υπάρχουν παρόλα αυτά τεχνικές για αποτελεσματική αναζήτηση στο παγκόσμιο ιστό με χρήση των διασυνδέσεων μεταξύ των ιστοσελίδων. Ο αλγόριθμος HITS (Hyperlink-Induced Topic Search) είναι μια από αυτές τις τεχνικές (Kleinberg) K97 όπου χρησιμοποιείται στο σύστημα Clever . Ο αλγόριθμος Salsa LM00] μια άλλη τεχνική παρουσιάζει μία στοχαστική προσέγγιση στην ανάλυση της δομής των διασυνδέσεων .

Αλγόριθμοι Εκπαίδευσης Νευρωνικών Δικτύων

Αλγόριθμος Backpropagation

1: Αρχικοποίηση w_0 , $\rho \in (0, 1)$, $\sigma \in (0, 1)$, $k = 0$, k_{\max} , φ . 2: Αν $(k \nabla E(w_k) = 0)$ ή $(E(w_k) \leq \varphi)$ ή $(k > k_{\max})$ τότε σταμάτα. 3: Υπολογισμός της κατεύθυνσης αναζήτησης $dk = -\nabla E(w_k)$ 4: Για $\rho, \sigma \in (0, 1)$ όρες την παράμετρο $lk \in \mathbb{Z}^+$ τέτοια ώστε ο ρυθμός μάθησης $\eta_k = \frac{\sigma}{lk} \cdot \rho$ να ικανοποιεί $E(w_{k+1}) - E(w_k) \leq \sigma \eta_k \nabla E(w_k)$ 5: Ενημέρωση των βαρών $w_{k+1} = w_k + \eta_k dk$ 6: Θέσε $k = k + 1$ και πήγαινε στο 2.

Αλγόριθμος NonMonotone Variable Step Backpropagation

1: Αρχικοποίηση w_0 , $\rho \in (0, 1)$, $\sigma \in (0, 1)$,

$M = 3$, $k = 0$, k_{\max} , φ .

2: Αν $(k \nabla E(w_k) = 0)$ ή $(E(w_k) \leq \varphi)$

ή $(k > k_{\max})$ τότε σταμάτα.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

3: Υπολογισμός της κατεύθυνσης αναζήτησης

$$dk = -\nabla E(w)$$

4: Υπολογισμός του ρυθμού μάθησης

$$\eta^k = \frac{1}{2} \frac{kw^k - w^{k-1}k}{k \nabla E(w^k) - \nabla E(w^{k-1})k}$$

5: Υπολογισμός του μη μονότονου ορίζοντα εκπαίδευσης

$M_k = \begin{cases} M_{k-1} + 1, & \text{αν } \Lambda^k < \Lambda^{k-1} < \Lambda^{k-2}, \\ M_{k-1} - 1, & \text{αν } \Lambda^k > \Lambda^{k-1} > \Lambda^{k-2}, \\ M_{k-1}, & \text{διαφορετικά με } \Lambda^k = k \nabla E(w^k) - \nabla E(w^{k-1})k \end{cases}$

6: Για $\rho, \sigma \in (0, 1)$

βρες την παράμετρο $lk \in \mathbb{Z}^+$ τέτοια ώστε ο ρυθμός μάθησης $\eta^k = \eta^k \cdot \rho^{lk}$ να ικανοποιεί $E(w^k + \eta^k dk) - \max_{0 \leq j \leq M} E(w^{k-j}) \leq \sigma \eta^k \nabla E(w^k)^T dk$

7: Ενημέρωση των βαρών $w^{k+1} = w^k + \eta^k dk$ 8: Θέσε $k = k + 1$ και πήγαινε στο 2.

Αλγόριθμο A.6 BFGS

1: Αρχικοποίηση $w^0, \sigma_1 \in (0, 1), \sigma_2 \in (0, 1),$

$$k = 0, k_{\max}, \rho.$$

2: Αν $(k \nabla E(w^k))^k = 0$ ή $(E(w^k) \leq \rho)$ ή $(k > k_{\max})$ τότε σταμάτα.

3: Υπολογισμός της προσέγγισης του Εσσιανού

$$B_{k+1} = B_k - B_k s_k s_k^T k B_k s_k^T k B_k s_k + y_k y_k^T k y_k^T k s_k$$

4: Υπολογισμός της κατεύθυνσης αναζήτησης

$$dk = -B^{-1} k \nabla E(w)$$

5: Για $0 < \sigma_1 < \sigma_2 < 1$

υπολόγισε το ρυθμό μάθησης η^k έτσι ώστε να ικανοποιεί $E(w^k + \eta^k dk) - E(w^k) \leq \sigma_1 \eta^k \nabla E(w^k)^T dk$ $\nabla E(w^k + \eta^k dk)^T dk \geq \sigma_2 \nabla E(w^k)^T dk$

6: Ενημέρωση των βαρών

$$w^{k+1} = w^k + \eta^k dk$$

7: Θέσε $k = k + 1$ και πήγαινε στο 2.

Αλγόριθμο Conjugate Gradient

1: Αρχικοποίηση $w^0, \sigma_1 \in (0, 1), \sigma_2 \in (0, 1),$

$$k = 0, k_{\max}, \rho.$$

2: Αν $(k \nabla E(w, k)) = 0$ ή $(E(w, k) \leq \rho)$ ή $(k > k_{\max})$

τότε σταμάτα.

3: Υπολογισμός της κατεύθυνσης αναζήτησης

$$dk = -\nabla E(w, k)$$

για $k = 0$, $-\nabla E(w, k) + \beta k dk - 1$ διαφορετικά

4: Για $0 < \sigma_1 < \sigma_2 < 1$

υπολόγισε το ρυθμό μάθησης ηk έτσι ώστε να ικανοποιεί $E(w, k + \eta k dk) - E(w, k) \leq \sigma_1 k \nabla E(w, k) \cdot T dk$ $\nabla E(w, k + \eta k dk) \cdot T dk \geq \sigma_2 \nabla E(w, k) \cdot T dk$

5: Ενημέρωση των βαρών

$$w_{k+1} = w_k + \eta k dk$$

6: Θέσε $k = k + 1$ και πήγαινε στο 2.

6.2.4 ΠΑΡΑΔΕΙΓΜΑ

Εφημερίδα Guardian

Η ανάπτυξη ειδησεογραφικών ιστοσελίδων προέβαλε ως επιτακτική ανάγκη, στην εύρεση τρόπων που θα προσαρμόζονταν στις ανάγκες, τις ιδιαιτερότητες κάθε ατόμου, ώστε να του εξασφαλίσουν το επιθυμητό, δηλαδή την αδιάλειπτη και συνεχή εύκολη πρόσβαση στην πληροφορία. Μια από τις πρώτες σε επισκεψιμότητα σελίδες σε ευρωπαϊκό επίπεδο είναι η εφημερίδα Guardian.

Στην αρχική της σελίδα (www.guardian.co.uk) η εφημερίδα έχει πάνω δεξιά την επιλογή εγγραφής στο σύστημα. Η εγγραφή μπορεί να γίνει μέσα σε ελάχιστα δευτερόλεπτα μέσω του λογαριασμού του Facebook που διαθέτει ο χρήστης. Όταν ο χρήστης δώσει τα αναγνωριστικά του στοιχεία (username και password), εξετάζεται – μετά από επικοινωνία με τη βάση δεδομένων – αν αντιστοιχούν σε εγγεγραμμένο χρήστη. Αν ναι, εισάγεται στο σύστημα αρχίζει την πλοήγησή του στην πύλη. Παράλληλα προσφέρεται και η εναλλακτική, αν δεν είναι γραμμένος χρήστης, να συμπληρώσει τη φόρμα εγγραφής και να καταχωρηθεί στο σύστημα.

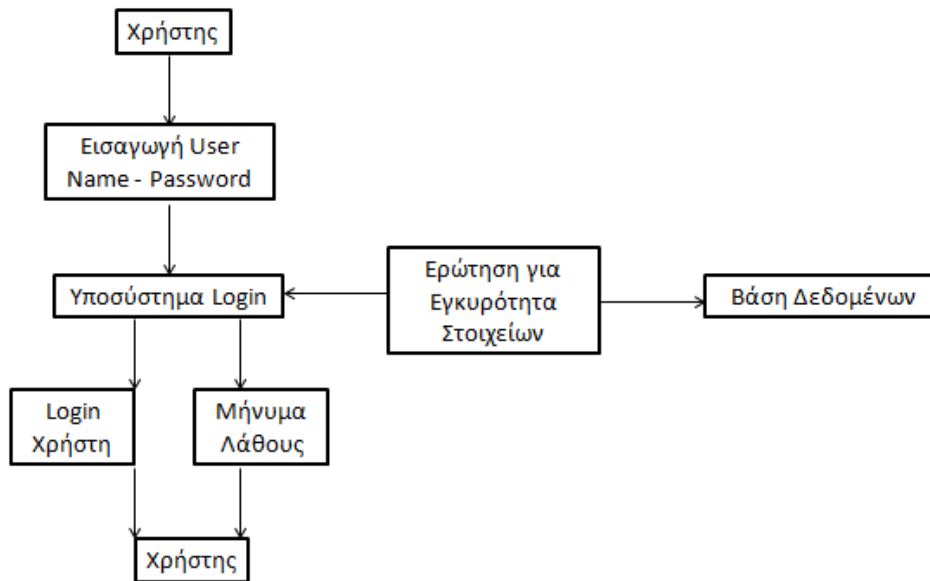


Μετά την εγγραφή του χρήστη στο σύστημα, κάθε άρθρο που διάβάζει ο χρήστης καταγράφεται και αποθηκεύεται σε μια βάση δεδομένων με το ιστορικό των τελευταίων τριάντα ημερών. Ως αποτέλεσμα της διαδικασίας αυτής, κάθε φορά που ο χρήστης διαβάζει ένα άρθρο στο τέλος της σελίδας του προτείνονται άρθρα που ομοιότητες στο περιεχόμενο με αυτά που έχει διαβάσει στο παρελθόν.

Ως στόχος του συστήματος είναι να καταφέρει να προτείνει άρθρα στον χρήστη τα οποία θα ήθελε πολύ αλλά θα ήταν δύσκολο να τα βρει κάτω από άλλες συνθήκες.

Η ιστοσελίδα χρησιμοποιεί επίσης και μια μέθοδο μη προσωποποιημένης σύστασης που βασίζεται στα πιο δημοφιλή άρθρα που έχουν δημοσιευτεί. Η δημοτικότητα

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

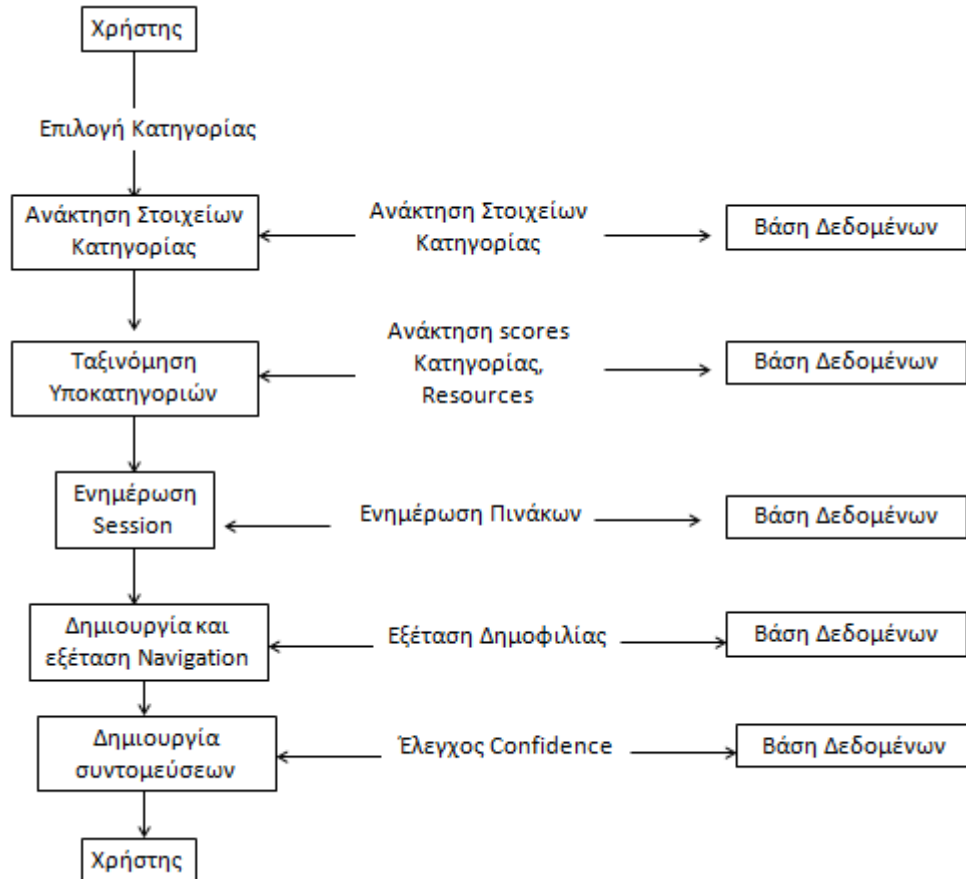


ενός άρθρου φαίνεται από το πόσες ενέργειες έχουν γίνει από τους χρήστες πάνω στο άρθρο. Ενέργεια μπορεί να θεωρηθεί η ανάγνωση ενός άρθρου, το ποστάρισμα του σε κάποιο blog ή το να γίνει αποστολή του άρθρου με e-mail. Η μέθοδος αυτή έχει στόχο να προσελκύσει νέους χρήστες που δεν έχουν κάνει εγγραφή ακόμα

More from the Guardian	What's this?	More from around the web	What's this?
Oxford child sex abuse ring: social services failed me, says victim 14 May 2013		Sanofi, Regeneron Announce Patient Enrollment in Two Phase 3 Sarilumab Trials for Rheumatoid Arthritis (Investing Channel)	
10 gross ingredients you didn't know were in your food 13 May 2013		Why You Should Be Drinking Lemon Water In The Morning (Learnist)	
The day I worked for the NHS 111 helpline 14 May 2013		Burning Away High Blood Pressure (redOrbit)	
Photograph in Tia Sharp case 'appeared to have been taken after death' 09 May 2013		"I question myself daily; will child abuse in Saudi Arabia ever change?" (Your Middle East)	
Young and poor hit hardest as UK cuts widen inequality, says OECD 15 May 2013		Middle-Aged, Yet a Prince, Slouching but Haunted (The New York Times)	

Η ιστοσελίδα χρησιμοποιεί ως πηγή σύστασης τα κειμενικά χαρακτηριστικά καθώς και λέξεις κλειδιά όπως: θέμα και συγγραφέας. Με βάση ένα σύνολο χαρακτηριστικών γνωρισμάτων στοιχείων, το σύστημα προσπαθεί να

δημιουργήσει ένα μοντέλο για κάθε χρήστη που του επιτρέπει να ταξινομήσει τα άγνωστα στοιχεία σε ενδιαφέροντα μη ενδιαφέροντα για αυτόν. Η σύσταση στηρίζεται στο φιλτράρισμα περιεχομένου και η εφαρμογή του αλγόριθμου είναι απλή καθώς δεν χρειάζονται σύνθετες συσχετίσεις, (π.χ. την γνώμη των άλλων αναγνωστών). Ο αλγόριθμός παρουσιάζει την ακόλουθη μορφή.



Ενοικιάσεις ταινιών

Αρκετές εταιρίες ενοικιάσεως ταινιών θέλοντας να προσφέρουν τη δυνατότητα καλύτερων υπηρεσιών στους συνδρομητές σχεδίασαν ένα σύστημα συστάσεων - αλγόριθμος - όπου θα προτείνουν στον καθένα ταινίες με βάση το προφίλ τους. Μια από αυτές τις εταιρίες είναι η Netflix. Ο συγκεκριμένος αλγόριθμος είναι ένα σύστημα συνεργατικού φιλτραρίσματος (collaborate filtering system). Από την άλλη, μια βάση δεδομένων το CineMatch χρησιμοποιεί πληροφορίες από τρεις πηγές για να προτείνει στον χρήστη ταινίες. (Μ.Κωνσταντίνου 2012)

1) Οι ταινίες οργανώνονται με βάση το περιεχόμενό τους. Δίδεται ένας όρος <περιεχόμενο ταινίας> και καλείται ένα σύνολο στοιχείων που μπορούν να προσδιορίσουν λεκτικά τις παραμέτρους μιας ταινίας όπως το είδος της ταινίας, ο σκηνοθέτης, σενάριο, ηθοποιοί, περίληψη. Από τον τίτλο και την περίληψη της ταινίας αφαιρούνται οι συνηθισμένες λέξεις όπως σύνδεσμοι αντωνυμίες κ.α και η

υπλογίζεται η συχνότητα των σημαντικών λέξεων που μπορούν να καθορίσουν μια ταινία.

2) Η βαθμολογία που έχει δώσει ο κάθε χρήστης σε προηγούμενες ταινίες η οποία κυμαίνεται από 1-5 αστέρια. Όσα περισσότερα αστέρια μια ταινία τόσο και πιο προτεινόμενη αναδεικνύεται. Αυτές που είναι κάτω από 3 αστέρια απορρίπτονται. Έτσι γίνονται γνωστές οι προτιμήσεις του χρήστη και παράλληλα διαμορφώνουν και το προφίλ του.

3) Η βαθμολογία όλων των χρηστών της υπηρεσίας. (Χ.Χριστάκου 2012)




Εικόνα 17 Αποτελέσματα Recommender System στο Netflix

Συνδυάζει αυτές τις πληροφορίες μεταξύ τους. Εβδομαδιαία το CineMatch επεξεργάζεται τις παλιότερες αξιολογήσεις ταινιών από τους συνδρομητές με σκοπό να κατηγοριοποιήσει τις ταινίες με ομοιότητες. Για να συμβεί αυτό χρησιμοποιείται ο συντελεστής γραμμικής συσχέτισης (Φ.Μιχελινάκης 2011)

Η τιμή ενός δείκτη –συντελεστής συσχέτισης- μας δείχνει το βαθμό συνάφειας μεταξύ των ταινιών. Η διαδικασία συσχέτισης παρουσιάζεται στις κατηγορικές μεταβλητές του Netflix με μια παραλλαγή του συντελεστή pearson. Το στατιστικό χ^2 pearson chi-square test είναι το πιο δημοφιλές, καθώς υπάρχουν ποιοτικά δεδομένα οργανωμένα σε κατηγορίες στόχος είναι να προσδιοριστεί η αναλογία του πληθυσμού που ανήκει στην κάθε κατηγορία. Έτσι διατυπώνεται μια

μηδενική υπόθεση που δηλώνει ότι δεν υπάρχει κάποια συγκεκριμένη προτίμηση σε αυτές τις διαθέσιμες ονομαστικές κατηγορίες. Ο έλεγχος που ακολουθεί αξιολογεί την μηδενική υπόθεση σε σχέση με τις ονομαστικές και μη ονομαστικές κατηγορίες δειγμάτων συγκρίνοντας τον αριθμό των υποκειμένων



Your Queue Show all DVD activity

DVDs At Home

	Movie Title	Watch Instantly	Star Rating	Shipped	Est. Arrival	
1.	A Scanner Darkly		☆☆☆☆☆	04/01/08	04/02/08	Report Problem
2.	Neil Young: Heart of Gold		☆☆☆☆☆	04/01/08	04/02/08	Report Problem

Get another movie for only \$2.50 and we'll send it Monday. [Upgrade to the 3 at-a-time \(unlimited\) plan now!](#)

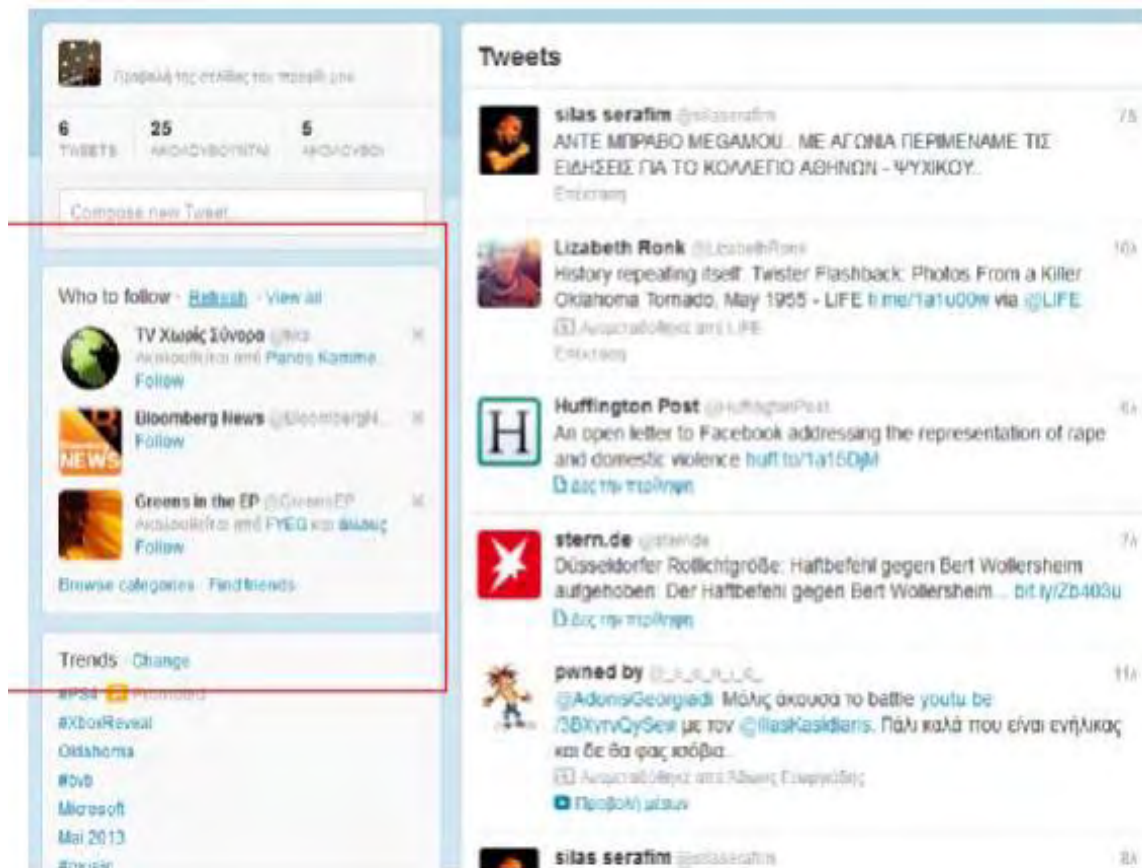
DVD Queue (9) See Queue tips Update Your Queue

List Order	Movie Title	Watch Instantly	Star Rating	Genre	Availability	Remove
1	I Am Legend		☆☆☆☆☆	Thriller	Long Wait	<input type="checkbox"/>
2	Once		☆☆☆☆☆	Independent		<input type="checkbox"/>
3	Beowulf: Director's Cut		☆☆☆☆☆	Sci-Fi & Fantasy		<input type="checkbox"/>
4	A Prairie Home Companion		☆☆☆☆☆	Comedy		<input type="checkbox"/>
5	Meet the Robinsons		☆☆☆☆☆	Children & Family		<input type="checkbox"/>
6	I, Robot		☆☆☆☆☆	Sci-Fi & Fantasy		<input type="checkbox"/>
7	The Librarian: Quest for the Spear		☆☆☆☆☆	Action & Adventure		<input type="checkbox"/>
8	Enchanted		☆☆☆☆☆	Comedy		<input type="checkbox"/>

Εικόνα 18 Κατάταξη των ταινιών βάσει της λίστας αναμονής που υπάρχει για αυτές. Για κάθε μια ταινία δίνεται η συνολική αξιολόγηση που έχει λάβει από το κοινό

Twitter

Τελευταία αξιοσημείωτη στο προσκήνιο τα τελευταία χρόνια micro-blogging υπηρεσία είναι το twitter (following) όπου κάθε χρήστης επιλέγει ποιον θέλει να ακολουθεί (follow) στο κοινωνικό δίκτυο. Αυτού του είδους το micro-blogging επικοινωνίας επιτρέπει στους χρήστες τους φερόμενους “twitterers” να αναρτούν μικρά μηνύματα ενημέρωσης στο web και στις διάφορες υπηρεσίες μηνυμάτων χωρίς να απαιτείται να παρέχεται άδεια.



Αρχική σελίδα του twitter.

Οι χρήστες twitteres δημοσιεύουν tweets με όριο 140 χαρακτήρες και έτσι δημιουργείται ένα κοινωνικό δίκτυο χωρίς να χρειάζεται να στέλνουν προσκλήσεις προς άλλους χρήστες όπως συμβαίνει με τις άλλες υπηρεσίες του κοινωνικού δικτύου. Ο λεγόμενος follower (ακόλουθος) στον κα'θε twitterer επιτέπι να διαλέγει ποιον επιθυμεί να ακολουθεί χωρίς απίτης έγκρισης αυτής της ενέργειας από τον δεύτερο.

Το πρώτο εξάμηνο του 2010 καταγράφηκαν πάνω από 100 εκατομμύρια χρήστες με 65 εκατομμύρια μηνύματα- tweets την ημέρα. Το twitter προσεγγίζει τεράστιο ενδιαφέρον της δικτυακής έρευνας αφενός ως υπηρεαία αφετέρου ως προς τον προσδιορισμό της ταυτότητας των twitterers. Χρησιμοποιεί έναν αλγόριθμο που βασίζεται στην εξής υπόθεση :

<εάν κάποιος που ακολουθεί ο χρήστης A, ακολουθεί με τη σειρά του κάποιον χρήστη B πιθανώς τότε ο χρήστης A να θέλει να ακολουθήσει τον χρήστη B>

Αποτέλεσμα αυτής της μεθόδου είναι χρήστες που έχουν κοινούς ακόλουθους να θέλουν να ακολουθηθούν μεταξύ τους "FOLLOWING". Η following αυτή σχέση είναι ένας ισχυρός δείκτης ομοιότητας μεταξύ των χρηστών αφού φέρεται να μοιράζονται θέματα ομοίου ενδιαφέροντος. Στο περιβάλλον του twitter ο twitterer ακολουθεί ένα φίλο επειδή ενδιαφέρεται για το περιεχόμενο που ο φίλος δημοσιεύει, και ο φίλος ακολουθεί επειδή θεωρεί ότι μοιράζονται κοινού ενδιαφέροντος θέματα.

Συμπεράσματα

Η ανακάλυψη των αλγορίθμων εμπίπτει χρονικά στην ερευνητική τάση της τελευταίας κυρίως δεκαετίας που είναι σαφώς προσανατολισμένη στην υλοποίηση συστημάτων και τεχνικών με σκοπό την προσομοίωση συγκεκριμένων διαδικασιών της φύσης ή της ανθρώπινης σκέψης. Τα τεχνητά νευρωνικά δίκτυα, τα Συστήματα Ασαφούς Λογικής (Fuzzy Logic Systems) και η Τεχνητή Νοημοσύνη (Artificial Intelligence) εμπερικλύονται σε αυτή την τάση. Οι αλγόριθμοι θεμελιώνονται σε αρχές εμπνευσμένες από τους πραγματικούς μηχανισμούς της γενετικής που διέπουν τα βιολογικά συστήματα και την εξέλιξη των ειδών σύμφωνα με την θεωρία του Δαρβίνου.

Ο βασικός στόχος ενός αλγόριθμου είναι η παραγωγή ενός συνόλου (πληθυσμού) λύσεων κάποιου προβλήματος, οι οποίες αρχικά παράγονται τυχαία, συγκροτώντας έτσι έναν πληθυσμό από άτομα, όπου θα χρησιμοποιηθούν οι τεχνικές εξέλιξης. Οι νευρώνες έχουν μία συγκεκριμένη διάταξη που οδηγεί σε μία δομή, η οποία ποικίλει στους διάφορους τύπους δικτύων. Όμως, όλοι οι τύποι έχουν το κοινό χαρακτηριστικό ότι δέχονται σήματα στην είσοδο τους, τα οποία τα πολλαπλασιάζουν επί το αντίστοιχο βάρος, βρίσκουν το άθροισμα όλων των γινομένων και ακολούθως μεταβιβάζουν το άθροισμα αυτό σε μία ειδική συνάρτηση η οποία παράγει την έξοδο από τον κάθε νευρώνα. Μια από τις σημαντικότερες εφαρμογές των αλγορίθμων είναι η χρήση τους στην εξέλιξη λογικών κανόνων για την προσομοίωση συστημάτων. 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». Παί δευση μηχανών βάσει γενετικών αλγορίθμων Genetic Based Machine Learning.

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.

Η εξόρυξη δεδομένων χρησιμοποιεί εξελιγμένες στατιστικές αναλύσεις και τεχνικές δημιουργίας μοντέλων για να αποκαλύψει κρυμμένα πρότυπα, κανόνες και σχέσεις σε οργανωμένες βάσεις δεδομένων. Με τη χρήση των τεχνολογιών αναγνώρισης προτύπων αλλά και στατιστικές και μαθηματικές τεχνικές, η εξόρυξη δεδομένων βοηθάει τους αναλυτές να εντοπίζουν σημαντικά γεγονότα, σχέσεις, πρότυπα, εξαιρέσεις αλλά και ανωμαλίες, οι οποίες θα μπορούσαν να περάσουν απαρατήρητες. Εντούτοις εξακολουθεί να αντιμετωπίζει πολλές προκλήσεις και ανεπίλυτα προβλήματα που θέτουν νέα ερευνητικά ζητήματα για περαιτέρω μελέτη. Τέτοια θέματα αποτελούν η ανάπτυξη μιας ευέλικτης και κατανοητής γλώσσας απόδοσης των αποτελεσμάτων, η ανάπτυξη τεχνικών εξόρυξης δεδομένων σε προηγμένα συστήματα βάσεων δεδομένων, όπως οι ενεργές βάσεις δεδομένων (active databases) και οι χωρικές βάσεις δεδομένων (spatial databases) η ενσωμάτωση της ανακαλυφθείσας γνώσης με τη γνώση των εμπειρογνομώνων, και η ανάπτυξη μεθόδων για τη διασφάλιση της ασφάλειας και την προστασία της ιδιωτικής ζωής.

Επίσης με την εξάπλωση της χρήσης των υπολογιστών στον τομέα της βιοπληροφορικής έχουν αυξηθεί σημαντικά οι δυνατότητές μας να παράγουμε και να συλλέγουμε πληροφορίες. Η μηχανική εκπαίδευση και η εξόρυξη γνώσης αποτελούν δύο από τους κυριότερους τομείς έρευνας, οι οποίες υποστηρίζουν την αυτόματη μετατροπή των υπό επεξεργασία πληροφοριών σε χρήσιμη γνώση. Αργυράκης, Πάνος (2001). *Τεχνητή Νοημοσύνη – Εφαρμογές*. Ελληνικό Ανοικτό Πανεπιστήμιο.

Εντούτοις υπάρχουν πολλά αναπάντητα ερωτήματα στην αρχιτεκτονική της συσσωρευμένης γενίκευσης για τον συνδυασμό ταξινομητών. Για παράδειγμα, αν θα υπάρχουν αυστηροί κανόνες για το ποιοί ταξινομητές θα πρέπει να χρησιμοποιηθούν και σε ποιά χαρακτηριστικά των δεδομένων. Επίσης, ένα ακόμα ερώτημα είναι πως μπορούν να διαχειριστούμε τις μεγάλες δυνατότητες των νευρωνικών δικτύων και ιδιαίτερα την υπερευαισθησία τους σε μικρές αλλαγές των δεδομένων.

C.-W. Hsu, C.-C. Chang, and C.-J. Lin, A practical guide to SVM classification, Technical report, Department of Computer Science and Information Technology, National Taiwan University, 2003.

Μια νέα μελέτη ερευνητών του Πανεπιστημίου της Νέας Υόρκης, εντοπίζει ότι η νευρωνική δομή που χρησιμοποιείτε για να αποθηκευθούν και επεξεργαστούν πληροφορίες στην Λεκτική Εργαζόμενη Μνήμη, στον ανθρώπινο εγκέφαλο, είναι περισσότερο σύνθετη από ότι είχε θεωρηθεί προηγουμένως. Η μελέτη δείχνει ότι η επεξεργασία της πληροφορίας στην Εργαζόμενη Μνήμη περιλαμβάνει δυο διαφορετικά δίκτυα στον εγκέφαλο μάλλον, παρά ένα – μια ανακάλυψη που σίγουρα θα έχει συνέπειες στη δημιουργία συστημάτων τεχνητής νοημοσύνης, όπως τα εργαλεία μετάφρασης του λόγου.

«Τα αποτελέσματά μας δείχνουν ότι υπάρχουν τουλάχιστον δυο εγκεφαλικά δίκτυα που είναι ενεργά όταν διαχειριζόμαστε πληροφορίες ομιλίας και γλώσσας στο μυαλό μας», εξηγεί ο Bijan Pesaran, αναπληρωτής καθηγητής στο Κέντρο για την Νευρωνική Επιστήμη, του Πανεπιστημίου της Νέας Υόρκης και κύριος συγγραφέας της έρευνας που δημοσιεύεται στο περιοδικό Nature Neuroscience.

Προηγούμενες μελέτες είχαν δώσει έμφαση στο πώς ένας απλός «κεντρικός επεξεργαστής» επέβλεπε τη διαχείριση της πληροφορίας που αποθηκεύεται στην Εργαζόμενη Μνήμη(*). Η διάκριση είναι σημαντική, παρατηρεί ο Pesaran, επειδή τα τρέχοντα συστήματα Τεχνητής Νοημοσύνης που αναπαράγουν την ανθρώπινη ομιλία, τυπικά, υποθέτουν ότι οι υπολογισμοί που εμπλέκονται στην λεκτική εργαζόμενη μνήμη εκτελούνται από ένα απλό νευρωνικό δίκτυο. «Η Τεχνητή Νοημοσύνη βαθμιαία γίνεται περισσότερο όμοια με του ανθρώπου», λέει ο Pesaran. «Με την καλύτερη κατανόηση της νοημοσύνης στον ανθρώπινο εγκέφαλο, μπορούμε να προτείνουμε τρόπους να βελτιώσουμε τα συστήματα της Τεχνητής Νοημοσύνης. Η εργασία μας δείχνει ότι απαιτούνται συστήματα Τεχνητής Νοημοσύνης με πολλαπλά δίκτυα εργαζόμενης μνήμης».

Η μελέτη εστίασε σε μια μορφή εργαζόμενης μνήμης αποφασιστικής σημασίας για τη σκέψη, τη σχεδίαση και τους δημιουργικούς συλλογισμούς και εμπλέκει τη διατήρηση στο νου και το μετασχηματισμό της πληροφορίας που είναι απαραίτητη για ομιλία και γλώσσα. Οι ερευνητές, εξέτασαν ασθενείς που υπόκεινται σε παρακολούθηση του εγκεφάλου για θεραπεία από αντιστεκόμενη σε φάρμακα

επιληψία. Συγκεκριμένα, αποκωδικοποίησαν τη νευρωνική δραστηριότητα που καταγράφεται από την επιφάνεια του εγκεφάλου αυτών των ασθενών, καθώς άκουγαν ήχους ομιλίας και μιλώντας μετά μια σύντομη καθυστέρηση. Η μέθοδος απαιτούσε από τα υποκείμενα της έρευνας να χρησιμοποιήσουν ένα κανόνα, που δόθηκε από τους ερευνητές, για να μετασχηματίσουν τους ήχους ομιλίας που άκουσαν με διαφορετικό λόγο – για παράδειγμα, από τους ασθενείς είχε ζητηθεί να επαναλάβουν τον ίδιο ήχο που είχαν ακούσει, ενώ άλλες φορές οι ερευνητές ζήτησαν από τους ασθενείς να ακούσουν τον ήχο και να τον αναπαράγουν με διαφορετικό λόγο.

Οι ερευνητές αποκωδικοποίησαν την νευρωνική δραστηριότητα στον εγκέφαλο κάθε ασθενή, καθώς ο ασθενής εφάρμοζε τον κανόνα για να μετατρέψει ότι είχε ακούσει, σε αυτό που απαιτούνταν να πει. Τα αποτελέσματα αποκάλυψαν ότι η διαχείριση της πληροφορίας, που πραγματοποιήθηκε στη μνήμη εργασίας, ενέπλεκε τη λειτουργία των δύο εγκεφαλικών δικτύων. Το ένα δίκτυο κωδικοποιούσε τον κανόνα τον οποίο οι ασθενείς χρησιμοποιούσαν για να οδηγηθούν στον διαφορετικό λόγο που αυτοί διατύπωναν (το δίκτυο του κανόνα). Παραδόξως, ωστόσο, το δίκτυο του κανόνα δεν κωδικοποιούσε τις λεπτομέρειες του τρόπου με τον οποίο τα υποκείμενα μετασχημάτιζαν ότι άκουσαν, σε ότι είπαν. Η διαδικασία της χρήσης του κανόνα, για το μετασχηματισμό των ήχων σε ομιλία, έγινε από ένα δεύτερο δίκτυο μετασχηματισμού. Η δραστηριότητα σε αυτό δίκτυο θα μπορούσε να χρησιμοποιηθεί για να παρακολουθηθεί με ποιο τρόπο τα εισερχόμενα (ότι άκουσαν) μετατράπηκαν σε αποτελέσματα (ότι είπαν) στιγμή προς στιγμή.

Η μετάφραση ότι ακούστηκε σε μια γλώσσα, για να αποδοθεί σε μια άλλη γλώσσα εμπλέκει την εφαρμογή ενός όμοιου συνόλου αφηρημένων κανόνων. Άνθρωποι με προβλήματα στην λεκτική εργαζόμενη μνήμη βρίσκεται να δυσκολεύονται να μάθουν νέες γλώσσες. Οι σύγχρονες ευφυείς μηχανές, επίσης, έχουν προβλήματα να μάθουν γλώσσες, προσθέτουν οι ερευνητές.

«Ένας τρόπος με τον οποίο μπορούμε να βελτιώσουμε την ανάπτυξη περισσότερο ευφυών συστημάτων, είναι με την πληρέστερη κατανόηση του πώς λειτουργεί ο ανθρώπινος εγκέφαλος και το μυαλό», σημειώνει ο Pesaran. «Η διάγνωση και η αντιμετώπιση των προβλημάτων στην εργαζόμενη μνήμη, στους ανθρώπους, εμπλέκουν ψυχολογικές αξιολογήσεις. Κατ' αναλογία, μια μηχανή ψυχολογίας μπορεί μια μέρα να είναι χρήσιμη για διάγνωση και αντιμετώπιση προβλημάτων στην ευφυΐα των μηχανών μας. Αυτή η έρευνα εξετάζει μια μοναδικά ανθρώπινη μορφή νοημοσύνης, τη λεκτική μνήμη εργασίας, και προτείνει νέους τρόπους για να κάνουν τις μηχανές πιο ευφυείς». <http://egno.gr/2016/12/anthropos-egkefalos-anakalipsi-erevnton-stin-architektoniki-tis-lektikis-ergazomenis-mnimis-chrisimi-gia-tin-techniti-noimosini/> Πηγή: New York University

ΠΑΡΑΡΤΗΜΑ

Δημοσίευση: 26/01/2017

Αλγόριθμος τεχνητής νοημοσύνης εντοπίζει τον καρκίνο του δέρματος

Το σύστημα, που συνεχίζει να μαθαίνει από την εμπειρία του, μπορεί ήδη να αναγνωρίζει τόσο τους πιο συχνούς όσο και τους πιο θανατηφόρους καρκίνους του δέρματος, όπως το κακόηθες καρκίνωμα και το μελάνωμα αντίστοιχα.



SHARE IT

Ένα νέο σύστημα τεχνητής νοημοσύνης, που βασίζεται σε έναν αλγόριθμο βαθιάς μάθησης, εξετάζει φωτογραφίες ανθρώπων στον υπολογιστή και μπορεί να κάνει διάγνωση διαφόρων καρκίνων του δέρματος, με ακρίβεια ανάλογη με εκείνη των δερματολόγων.

Πρόκειται για ένα ακόμη σημαντικό βήμα προόδου, που δείχνει τις δυνατότητες αξιοποίησης της τεχνητής νοημοσύνης στην ιατρική. Το νέο επίτευγμα μπορεί να απλουστεύσει μελλοντικά το έργο των δερματολόγων.

Ο καρκίνος του δέρματος είναι η συχνότερη μορφή κακοήθειας στους ανθρώπους. Η αρχική διάγνωσή του συνήθως γίνεται οπτικά δια γυμνού οφθαλμού ή με το δερματοσκόπιο και μετά επιβεβαιώνεται μέσω βιοψίας και ιστολογικών εξετάσεων.

Η αυτοματοποίηση της διάγνωσης από υπολογιστικό σύστημα δεν είναι εύκολη υπόθεση, επειδή οι αλλοιώσεις του δέρματος εμφανίζουν μεγάλη ποικιλομορφία. Οι μηχανικοί και γιατροί του Πανεπιστημίου Στάνφορντ της Καλιφόρνια, με επικεφαλής τον ηλεκτρολόγο μηχανικό Αντρέ Εστέβα του Εργαστηρίου Τεχνητής Νοημοσύνης, που έκαναν τη σχετική δημοσίευση στο περιοδικό "Nature", ξεπέρασαν τις δυσκολίες, αναπτύσσοντας έναν εξελιγμένο αλγόριθμο που εκπαιδεύθηκε στις διαγνώσεις μελετώντας περίπου 130.000 εικόνες από 2.000 διαφορετικές δερματικές παθήσεις (καρκίνους και άλλες).

Το σύστημα, που συνεχίζει να μαθαίνει από την εμπειρία του, μπορεί ήδη να αναγνωρίζει τόσο τους πιο συχνούς όσο και τους πιο θανατηφόρους καρκίνους του δέρματος, όπως το κακόηθες καρκίνωμα και το μελάνωμα αντίστοιχα. Η απόδοση του συστήματος συγκρίθηκε με εκείνη 21 δερματολόγων και βρέθηκε ουσιαστικά στο ίδιο επίπεδο, με ακρίβεια τουλάχιστον 91%. Σε επόμενη φάση, το σύστημα πρέπει να δοκιμασθεί σε πραγματικές κλινικές συνθήκες. Οι ερευνητές θεωρούν ότι ένα παρόμοιο σύστημα τεχνητής νοημοσύνης μπορεί να αξιοποιηθεί σε άλλα ιατρικά πεδία, όπως η οφθαλμολογία, η ακτινολογία και η παθολογία. Αν μάλιστα ενσωματωθεί ως εφαρμογή σε «έξυπνα» κινητά τηλέφωνα, μπορεί να προσφέρει μια φθηνή και ευρεία πρόσβαση σε ζωτικές διαγνωστικές εξετάσεις, π.χ. σε μέρη όπου υπάρχει έλλειψη σχετικών διαγνωστικών κέντρων ή ακόμη και γιατρών.

Η πενταετής επιβίωση μετά τη διάγνωση του μελανώματος φθάνει πλέον το 97%, αν η ανίχνευση γίνει έγκαιρα, αλλά πέφτει στο 14%, αν η διάγνωση γίνει με καθυστέρηση. Συνεπώς, όπως και σε άλλες μορφές καρκίνου, η έγκαιρη διάγνωση είναι ζωτικής σημασίας και σε αυτό μπορεί να βοηθήσει η τεχνητή νοημοσύνη. Η βαθιά και γενικότερα η μηχανική μάθηση εκπαιδεύει έναν υπολογιστή έτσι ώστε να λύνει ένα πρόβλημα μόνος του, μαθαίνοντας από τα δεδομένα, χωρίς να χρειάζεται εκ των προτέρων ο σχετικός προγραμματισμός με τον κατάλληλο κώδικα, αφού ο αλγόριθμος αναλαμβάνει πρωτοβουλίες. Η σχετική τεχνολογία εφαρμόζεται όλο και συχνότερα στην επεξεργασία εικόνων και, σταδιακά, στις ιατρικές διαγνώσεις.

Πηγή: <http://www.skai.gr/news/health/article/337194/algorithmos-tehnetis-noimosunis-edopizei-ton-karkino-tou-dermatos/#ixzz4jTzALRIT>

Βιβλιογραφία

Νευρωνικά Δίκτυα και Μηχανική Μάθηση (Simon Haykin). 3^η έκδοση (εκδόσεις Παπασωτηρίου)

Αλγόριθμοι εξόρυξης πληροφορίας, Τζιραλής Γεώργιος ΔΠΜΣ <εφαρμοσμένες μαθηματικές επιστήμες, 2006>

Τεχνητή Νοημοσύνη - Β' Έκδοση Ι. Βλαχάβας, Π. Κεφαλάς, Ν. Βασιλειάδης, Φ. Κόκκορας, Η. Σακελλαρίου

Αργυράκης, Πάνος (2001). Τεχνητή Νοημοσύνη – Εφαρμογές. Ελληνικό Ανοιχτό Πανεπιστήμιο.

Albano, A.M., A. Passamante, T. Hediger and Mary Eileen Farrell. 1992. “Using neural nets to look for chaos.” Physica D 58: 1-9

R.Lempel and A.Saffer “PicASHOW: Pictorial Authority Search by Hyperlinks on the Web” Proc. 10th International World Wide Web Conference, Hong Kong, May 2001

C.H.Papadimitriou, P.Raghavan, H.Tamaki and S.Vempala “Latent

Bigus, Joseph P and Bigus, Jennifer (). Constructing Intelligent Agents Using Java. Willey Computer Publishing

G. Zoutendijk, Integer and NonLinear Programming, North Holland, Amsterdam, 1970

Mohinder S. Grewal and Angus P. Andrews, “Kalman Filtering : Theory and Practice Using Matlab”, Second Edition, Wiley Publications

B. D. O. Anderson και J. B. Moore, “Kalman Filtering: Whence, What and Whither?”, Mathematical System Theory, pages 41–54. Springer-Verlag, 1991

Haykin, Simon (1999). Neural Networks, A Comprehensive Foundation. Prentice Hall International, Inc, New Jersey

Ilachinski, Andrew (2001). Cellular Automata, A Discrete Universe. World Scientific Publishing Co. Pte. Ltd.

Cohen et al. Taylor & Francis Group. Applied Multiple Regression/ Correlation Analysis for the Behavioural Sciences 3rd ed. (2003).

Masters, Timothy (1993). Practical Neural Network Recipes in C++. Academic Press

Thomas g.Dietterich An experimental comparison of 3 methods for constructing ensembles

Yoav Freud, Raj Iyer, E. Schapire, Yoram Singer : An efficient boosting algorithm for combining preferences 2003

C.J. James, C.W. Hesse. Independent Component Analysis for biomedical signals. *Physiological Measurement* 26, R15-R39. 2005. Ref Type: Journal (Full)

A.G. Barto, R.S. Sutton, and C.W. Anderson, "Neuronlike adaptive elements that can solve difficult learning control problems", *IEEE Transactions on Systems, Man, and Cybernetics*, volume 13, 834-846, 1983

R. Bellman, *Dynamic Programming*, Princeton University Press, Princeton, NJ, 1957.

A. Hyvarinen, J. Karhunen, E. Oja. *Independent Component Analysis*. 2001.

A. Hyvarinen, E. Oja. A fast fixed-point algorithm for independent component analysis. *Neural Computing* 1997; 9:1483-1492.

A.J. Bell, T.J. Sejnowski. An information-maximization approach to blind separation and blind deconvolution. *Neural Computing* 1995; 7:1129-1159. (5) Σ.Γ. Τζαφέστας. *Υπολογιστική Νοημοσύνη : Μεθοδολογίες*. 2002.

Amati, G. and Crestani, F. 1999. Probabilistic learning for selective dissemination of information. *Information Processing and Management* 35, 5, 633-564.

Androutsopoulos, I., Koutsias, J., Chandrinos, K.V., Paliouras, G. and Spyropoulos, C.D. 2000a. An evaluation of Naive Bayesian Anti-Spam Filtering. In *Proceedings of Workshop on Machine Learning in the New Information Age, 11th European Conference on Machine Learning (ECML 2000)*, Barcelona, Spain, pp. 9-17.

Ginsberg, M. 1999. *Essentials of Artificial Intelligence*. Morgan Kaufmann Publishers, San Francisco, California.

Liu, H. and Setiono, R. 1996. A Probabilistic Approach to Feature Selection - A Filter Solution. In *Proceedings of ICML-96, 13th Conference on Machine Learning*, pp. 319-327.

Aptè, C., Damerau, F.J. and Weiss, S.M. 1994. Automated learning of decision rules for text categorization. *ACM Transactions on Information Systems* 12, 3, 233-251.

John, G.H. and Langley, P. 1995. Estimating Continuous Distributions in Bayesian Classifiers. In *Proceedings of the 11th Conference on Uncertainty in Artificial Intelligence*. Morgan Kaufmann Publishers, San Mateo, 1995

University of Texas at Arlington
<http://www.uta.edu/faculty/sawasthi/Statistics/stdiscan.html>

Platt, J.C. 1998. Sequential Minimal Optimization: A fast algorithm for training Support Vector Machines. *Advances in Kernel Method, Support Vector Learning*, by Scholkopf, Burges and Smola, MIT Press, pp. 185-208.

A. Shigeo Support Vector Machines for Pattern Classification, Springer 2005.

California Institute of Technology, Yaser S. Abu-Mostafa

Attardi, G., Gullí, A. anCreecy, R.M., Masand, B.M., Smith, S. and Waltz, D.L. 1992. Trading MIPS and memory for knowledge engineering: classifying census returns on the Connection Machine. Communications of the ACM 35, 8, 48-63. d Sebastiani, F. 1999.

Automatic Web page categorization by link and context analysis. In Proceedings of THAI-99, European Symposium on Telematics, Hypermedia and Artificial Intelligence, Varese, Italy, pp. 105-119.

T.M. Mitchell, Machine Learning, McGraw-Hill, 1997.

B. Becker, R. Kohavi, and R. Sommerfield, “Visualizing the simple Bayesian classifier”, KDD-97 Workshop on Issues in the Integration of Data Mining and Data Visualization, 1997.

Baker, L. and McCallum, A.K. 1998. Distributional clustering of words for text categorization. In Proceedings of the 21st ACM International Conference on Research and Development in Information Retrieval (SIGIR 1998), Melbourne, Australia, pp. 96-103.

Boone, G. 1998. Concept features in re:agent, an intelligent e-mail agent. In Second International Conference on Autonomous Agents.

Boser, B.E., Guyon, I.M. and Vapnik, V. 1992. A training algorithm on optimal margin classifiers. In Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory, Pittsburgh. B

G. and Bratley, P. 1996. Fundamentals of algorithms. Prentice Hall, New Jersey, 1996.

P. Horton and K. Nakai, “Better prediction of protein cellular localization sites with the k Nearest Neighbors classifier”, In the Proceedings of the Proceedings of Intelligent Systems in Molecular Biology, 368–383, 1997.

Breiman, L. 1996. Bias, variance and arcing classifiers. Technical Report, University of California, Berkely. Breiman, L. 1997. Prediction games and arcing algorithms. Technical Report 504, Statistics Department, University of California, Berkely. Submitted to Neural Computing.

Buchanan, B.G., Smith, D.H., White, W.C., Gritter, R., Feigenbaum, E.A., Lederberg, J. and Djerassi, C. 1976. Applications of artificial intelligence for chemical interference, XXII: Automatic rule formation in mass spectrometry by means of the meta-DENDRAL program. Journal of the American Chemical Society, 98, 6168.

- JV. Vapnik, *Statistical Learning Theory*, J. Wiley & Sons, Inc., New York, NY 1998.
- I.E. Livieris and P. Pintelas, “Evaluation of neural network training algorithms using biomedical data”, Technical Report 08-02, Department of Mathematics, University of Patras, 2008.
- Murthy, “Automatic construction of decision trees from data: A multi-disciplinary survey”, *Data Mining and Knowledge Discovery*, volume 2, 345–389, 1998.
- Burges, C.J.C. 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2):955-974, 1998.
- V. Castelli and T.M. Cover, On the exponential value of labeled samples, *Pattern Recognition Letters*, 16(1):105-111, 1995.
- J. Cheng, C. Hatzis, H. Hayashi, M. Krogel, S. Morishita, D. Page, and J. Sese, KDD Cup 2001 Report, *ACM SIGKDD Explorations Volume3*, Issue 2, January 2002.
- N.V. Chawla, N. Japkowicz, and A. Kolcz, In *Proceedings of the ICML' 2003 Workshop on Learning from Imbalanced Data Sets*, 2003.
- P.M. Murphy and D.W. Aha, “UCI repository of machine learning databases”, Irvine, CA: University of California, Department of Information and Computer Science, 1994.
- C.-C. Chang, and C.-J. Lin, LIBSVM: a library for support vector machines, 82 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- G. Cong, W.S. Lee, H. Wu, and B. Liu, Semi-supervised Text Classification Using Partitioned EM, *DASFAA 2004*: 482-493, 2004.
- N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press, 2000.
- I.E. Livieris and P. Pintelas, “A survey on algorithms for training artificial neural networks”, Technical Report 08-01, Department of Mathematics, University of Patras, 2008.
- Y. Ampatzidis, S. Vougioukas, S. Blackmore, D. Bochtis, “An Object-Oriented Asynchronous Kalman Filter with Outlier Rejection for Autonomous Tractor Navigation”, Aristotle University of Thessaloniki, Department of Agricultural Engineering και The Royal Veterinary a V. P. Oikonomou, A. T. Tzallas, D. I. Fotiadis, “A Kalman filter based methodology for EEG spike enhancement”, *Computer methods and programs in biomedicine* 85 (2007) 1 nd Agricultural University (KVL), Department of AgroTechnology, Denmark
- P.K. Chan and S.J. Stolfo, Toward scalable learning with non-uniform class and cost distributions: a case study in credit card fraud detection, In *Proceedings of the 4th*

International Conference on Knowledge Discovery and Data Mining, pages 164-168, 2001.

Y. Chan, X. Zhou and T. Huang, One class SVM for learning in image retrieval, In Proceedings of IEEE International Conference on Image Processing, 2001.

Utgoff, P. E. (1989). Incremental Induction of Decision Trees. Machine Learning, 4, 161-186. Ανακτήθηκε από <http://people.cs.umass.edu/~utgoff/papers/mlj-id5r.pdf>

Whitley, D. (1994). A Genetic Algorithm Tutorial. Statistics and Computing, 4, 65–85. Ανακτήθηκε από <http://www.cs.colostate.edu/~genitor/MiscPubs/tutorial.pdf>

Qu, R. (2002). Case-Based Reasoning for Course Timetabling Problems (Διδακτορική Διατριβή Πανεπιστήμιο Nottingham). Ανακτήθηκε από <http://www.cs.nott.ac.uk/~rxq/files/PhDThesis.pdf>

Quinlan, J. R. (1993). C4.5 : Programs for Machine Learning. ΗΠΑ: Morgan Kaufmann.

Holland, J. H. (1992). Adaptation in Natural and Artificial Systems (2η έκδοση). Κάμπριτζ, MA: MIT Press. (1η έκδοση 1975 University of Michigan Press).

F. DeComite, F. Denis, R. Gilleron, and F. Letouzey, Positive and Unlabeled examples help learning, In Proceedings of the 10th International Conference on Algorithmic Learning Theory, pages 219-230, 1999. [Den98]

F. Denis, R. Gilleron, A. Laurent, and M. Tommasi, Text Classification and Co-training from Positive and Unlabeled Examples, In Proceedings of the ICML Workshop: the Continuum from Labeled Data to Unlabeled Data in Machine Learning and Data Mining, pages 80-87, 2003.

F. Denis, R. Gilleron, and M. Tommasi, Text classification from positive and unlabeled examples, IPMU, 2002.

R. Duda, P. Hart, and D. Stork, Pattern Classification, John Wiley & Sons Inc, 2001.

A. Dempster, N. M. Laird, and D. Rubin, Maximum likelihood from incomplete data via the EM algorithm, Journal of the Royal Statistical Society, B:39, 1-38, 1997.

I. Guyon, B. Boser, and V. Vapnik, Automatic capacity tuning of very large VC-dimension classifiers. Advances in Neural Information Processing Systems, Vol. 5, 1993.

R.C. Holte, L.E. Acker, and B.W. Porter, Concept learning and the problem of small disjuncts, In Proceedings of the 11th International Joint Conference on Artificial Intelligence, pages 813-181, 1989.

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

C.-W. Hsu, C.-C. Chang, and C.-J. Lin, A practical guide to SVM classification, Technical report, Department of Computer Science and Information Technology, National Taiwan University, 2003.

H. Hartley and J. Rao, Classification and estimation in analysis of variance problems, Review of International Statistical Institute, 36:141-147, 1968.

N. Japkowicz, Proceedings of the AAAI' 2000 Workshop on Learning from Imbalanced Data Sets, Technical Report, AAAI Tech Report WS-00-05, 2000.

T. Joachims, Transductive inference for text classification using support vector machines, In Proceedings of ICML-99, 16th International Conference on Machine Learning, 200-209, 1999.

M. Kearns, Efficient noise tolerant learning from statistical queries, In Proceedings of the 25th ACM symposium on the Theory of Computing, pages 392-401, 1993.

S. Theodoridis and K. Koutroumbas, Pattern Recognition, Academic Press, 1999

K. Woods, C. Doss, K. Bowyer, J. Solka, C. Priebe, and P. Kegelmeyer, Comparative Evaluation of Pattern Recognition Techniques for Detection of Microcalcifications in Mammography, International Journal of Pattern Recognition and Artificial Intelligence, 7 (6):1417-1436, 1993.

ΙΣΤΟΣΕΛΙΔΕΣ

http://el.wikipedia.org/wiki/%CE%9C%CE%B7%CF%87%CE%B1%CE%BD%CE%B9%CE%BA%CE%AE_%CE%BC%CE%AC%CE%B8%CE%B7%CF%83%CE%B7

http://el.wikipedia.org/wiki/%CE%A4%CE%B5%CF%87%CE%BD%CE%B7%CF%84%CE%AE_%CE%BD%CE%BF%CE%B7%CE%BC%CE%BF%CF%83%CF%8D%CE%BD%CE%B7

<http://aibook.csd.auth.gr/include/slides/Chap18.pdf>

<http://www.ai-junkie.com>

http://www.icsd.aegean.gr/lecturers/kavallieratou/NN&EP_files/ci_6.pdf

http://www.foundalis.com/dep/cog/N4_gr.htm

http://en.wikipedia.org/wiki/Machine_learning

<http://mlg.eng.cam.ac.uk/zoubin/papers/ul.pdf>

<http://www.dbnet.ece.ntua.gr/pubs/uploads/DIPL-2006-15.pdf>

<http://nemertes.lis.upatras.gr/jspui/bitstream/10889/244/1/326.pdf>

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

<http://arxiv.org/pdf/1109.2088v1.pdf>

http://en.wikipedia.org/wiki/Kernel_methods#Applications

http://en.wikipedia.org/wiki/Kalman_filter[http://vivliothmy.ee.auth.gr/1221/1/diplo
matiki.pdf](http://vivliothmy.ee.auth.gr/1221/1/diplo
matiki.pdf)

<http://www.gatsby.ucl.ac.uk/~gretton/coursefiles/Slides5A.pdf>

<http://www.eng.ucy.ac.cy/gmitsis/ece795/lectures/Lecture1.pdf>