



Πανεπιστήμιο Πειραιώς – Τμήμα Πληροφορικής  
Πρόγραμμα Μεταπτυχιακών Σπουδών  
«Προηγμένα Συστήματα Πληροφορικής»

**Μεταπτυχιακή Διατριβή**

Τίτλος Διατριβής	Μέθοδοι σταδιακής μάθησης σε Τεχνητά Νευρωνικά Δίκτυα
Όνοματεπώνυμο Φοιτητή	Δήμου Αναστάσιος
Πατρώνυμο	Μάλαμας
Αριθμός μητρώου	ΜΠΣΠ/14023
Επιβλέπων	Δημήτρης Αποστόλου, Αναπληρωτής Καθηγητής

Ημερομηνία Παράδοσης **Ιανουάριος 2018**

---

## Τριμελής Εξεταστική Επιτροπή

(υπογραφή)

(υπογραφή)

(υπογραφή)

Δημήτριος Αποστόλου  
Αναπληρωτής καθηγητής

Κωνσταντίνος Μεταξιώτης  
Αναπληρωτής καθηγητής

Άγγελος Πικράκης  
Επίκουρος Καθηγητής



## Πίνακας περιεχομένων

Περίληψη .....	1
1 Εισαγωγή.....	3
1.1 Αντικείμενο .....	3
1.2 Δομή εργασίας.....	3
2 Επιχειρησιακή ευφυΐα .....	5
2.1 Έννοια επιχειρησιακής ευφυΐας.....	5
2.2 Διαδικασία BI .....	6
3 Ροές Δεδομένων και τύποι σταδιακής εκπαίδευσης .....	12
3.1.1 Online Learning μέθοδοι.....	12
3.1.2 Incremental learning μέθοδοι .....	13
4 Νευρωτικά δίκτυα.....	16
4.1 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα .....	16
4.2 ANN και βιολογικά νευρωνικά δίκτυα.....	17
4.2.1 Βιολογικός νευρώνας.....	18
4.2.2 Αναλογία .....	19
4.2.3 Τεχνητός νευρώνας.....	20
4.2.4 Βιολογικό έναντι τεχνητού δικτύου .....	21
4.2.5 Μάθηση .....	21
4.3 Ιστορική αναδρομή.....	21
4.4 Προβλήματα πρόκλησης.....	22
4.5 Αρχιτεκτονική ANN .....	26
4.6 Εκπαίδευση νευρωνικών δικτύων .....	32
4.6.1 Διαδικασία μάθησης.....	33
4.6.2 Τύποι κανόνων μάθησης .....	35
4.6.3 Θεωρία μάθησης .....	43
5 Μέθοδοι σταδιακής μάθησης TND.....	44
5.1 Αλγόριθμος ART .....	44
5.2 Fuzzy ARTMAP.....	47
5.3 TopoART.....	51
5.4 Learn++ .....	54
5.5 Neuroevolution .....	58
6 Συμπεράσματα.....	69
7 Βιβλιογραφία.....	70

## Πίνακας εικόνων

Εικόνα 1 – Συστήματα επιχειρησιακής ευφυΐας .....	6
Εικόνα 2 - Διαδικασία επιχειρησιακής ευφυΐας.....	8
Εικόνα 3 - Βασικός βιολογικός νευρώνας.....	18
Εικόνα 4 - Μεταφορά σήματος διαμέσου της συνάψεως .....	19
Εικόνα 5 - Σύγκριση βιολογικού νευρωνικού δικτύου με τεχνητού .....	20
Εικόνα 6 - Classification .....	23
Εικόνα 7 - Clustering .....	24
Εικόνα 8 - Modeling .....	24
Εικόνα 9 - Forecasting.....	25
Εικόνα 10 - Αναδόμηση εικόνας.....	26
Εικόνα 11 - Control .....	26
Εικόνα 12 - Κατηγορίες ANN και βασικά δίκτυα .....	27
Εικόνα 13 Perceptron ενός επιπέδου .....	27
Εικόνα 14 - Perceptron πολλών επιπέδων (MLP).....	28
Εικόνα 15 - RFB δίκτυα .....	29
Εικόνα 16 - Επαναλαμβανόμενα δίκτυα.....	30
Εικόνα 17 - Δίκτυα Kohonen (SOM).....	30
Εικόνα 18 - Δίκτυα Hopfield.....	31
Εικόνα 19 - Δίκτυα ART .....	32
Εικόνα 20 - Μαθησιακά ζητήματα.....	33
Εικόνα 21 - Σχηματικό διάγραμμα επιβλεπόμενης μάθησης.....	34
Εικόνα 22 - Σχηματικό διάγραμμα μη επιβλεπόμενης μάθησης .....	35
Εικόνα 23 - Σύγκλιση ενός τροποποιημένου αλγόριθμου μάθησης perceptron για το λογικό "ΚΑΙ" πρόβλημα.....	37
Εικόνα 24 - Επιλεκτικότητα προσανατολισμού ενός μόνο νευρώνα .....	39
Εικόνα 25 - Μια απλή ανταγωνιστική αρχιτεκτονική μάθησης. ....	39
Εικόνα 26 - Παράδειγμα ανταγωνιστικής μάθησης: (α) πριν από τη μάθηση. (β) μετά την εκμάθηση .....	40
Εικόνα 27 - (α) VQ (b) LVQ .....	41
Εικόνα 28 - κύκλωμα εκπαίδευσης ART .....	45
Εικόνα 29 - Αρχιτεκτονική Fuzzy ARTMAP.....	48
Εικόνα 30 - Αρχιτεκτονική TopoArt.....	53
Εικόνα 31 - Neuroevolution .....	60
Εικόνα 32 - Παράδειγμα χαρτογράφησης γονότυπου προς φαινότυπο.....	63
Εικόνα 33 - Οι δύο τύποι δομικής μετάλλαξης στην NEAT .....	64
Εικόνα 34 - Αντιστοίχιση γονιδιωμάτων για διαφορετικές τοπολογίες δικτύων με χρήση αριθμών καινοτομίας.....	66

## Περίληψη

Για την σωστή εφαρμογή ενός συστήματος BI σε έναν οργανισμό, είναι αναγκαία γνώση η οποία αποκτάται από ένα τέτοιο σύστημα να είναι διαθέσιμη άμεσα στους χρήστες που την χρειάζονται. Ένα από τα υποσυστήματα του BI που τελευταία έχει γίνει απαραίτητο σε πολλούς οργανισμούς είναι η εξόρυξη δεδομένων. Σχεδόν όλοι οι οργανισμοί εκτός από τα δεδομένα που έρχονται με μεγάλα χρονικά διαστήματα και δεν απαιτείται άμεση πρόσβαση στα νέα αυτά δεδομένα από το σύστημα BI, έχουν και ροές δεδομένων όπου τις περισσότερες φορές απαιτείται να είναι άμεσα διαθέσιμα για την λήψη μια απόφασης ή μιας διορθωτικής ενέργειας. Ειδικά για την εξόρυξη γνώσης η επεξεργασία σε αυτά τα δεδομένα είναι αυτή που χρειάζεται την περισσότερη προσοχή. Στην εργασία αυτή εξετάζουμε τα τεχνητά νευρωνικά δίκτυα και τους τρόπους με τους οποίους μπορούμε να επιτύχουμε την εκπαίδευσή τους με ροές δεδομένων.

Σκοπός της εργασίας είναι η αξιοποίηση της εξόρυξης γνώσης και συγκεκριμένα των τεχνητών νευρωνικών δικτύων σε ροές δεδομένων. Αρχικά θα ορίσουμε τις απαιτήσεις ενός νευρωνικού δικτύου το οποίο θα πρέπει να εκπαιδεύεται σε ροές δεδομένων προοδευτικά, είτε με την λήψη των δεδομένων είτε ανά περιόδους, χωρίς την απώλεια της προηγούμενης γνώσης και χωρίς να απαιτείται η επανεκπαίδευση ολόκληρου του μοντέλου. Θα παρουσιάσουμε τα πιο διαδεδομένα τεχνητά νευρωνικά δίκτυα τα οποία υποστηρίζουν προοδευτική εκπαίδευση, τα νευρωνικά δίκτυα αυτά είναι Fuzzy ARTMAP, TopoART και Learn++. Τέλος θα παρουσιάσουμε την πιο σύγχρονη τεχνική μηχανικής μάθησης που εφαρμόζει εξελικτικούς αλγόριθμους για την κατασκευή τεχνητών νευρωνικών δικτύων που είναι η Neuroevolution.





# 1 Εισαγωγή

## 1.1 Αντικείμενο

Ειδικά τα τελευταία χρόνια τα δεδομένα αυξάνονται με ταχύ ρυθμό. Οι επιχειρήσεις στρέφονται προς τις θεωρίες και τις τεχνολογίες Business Intelligence (BI) για να εξάγουν το μέγιστο όγκο πληροφοριών από αυτά τα δεδομένα, προκειμένου οι εργαζόμενοι να μπορούν να λαμβάνουν καλύτερες επιχειρηματικές αποφάσεις βάση των δεδομένων που έχουν. Το BI μετατρέπει τα δεδομένα που συλλέγονται από διάφορες πηγές σε χρήσιμες πληροφορίες. Αυτές οι πληροφορίες υποστηρίζουν τις επιχειρηματικές δραστηριότητες, παρέχοντας τελικά μακροπρόθεσμη σταθερότητα στην επιχείρηση. Επιπλέον, καθώς αναπτύσσονται οι επιχειρήσεις, υπάρχει η συντριπτική ανάγκη να αναλυθούν τα ιστορικά επιχειρηματικά δεδομένα προκειμένου να προβλεφθούν οι μελλοντικές τάσεις και να βελτιωθούν οι επιχειρηματικές αποφάσεις. Ένας ευρύτερος ορισμός της BI παρουσιάζεται από τον Evelson (2008): "[BI] είναι ένα σύνολο μεθοδολογιών, διαδικασιών, αρχιτεκτονικών και τεχνολογιών που μετατρέπουν τα ακατέργαστα δεδομένα σε χρήσιμες πληροφορίες" ή όπως εξηγεί ο Evalson, «οι χρήστες μια επιχείρησης που μπορούν να λαμβάνουν ενημερωμένες επιχειρηματικές αποφάσεις με δεδομένα σε πραγματικό χρόνο, μπορούν να βάλουν μια εταιρεία μπροστά από τους ανταγωνιστές της». Σε έναν οργανισμό υπάρχουν δεδομένα όπως πωλήσεις – αγορές και άλλα που συλλέγονται συγκεντρωμένα συνήθως στο Data Warehouse και στις περισσότερες περιπτώσεις δεν χρειάζονται άμεση επεξεργασία στα συστήματα του BI (OLAP και ανάλυση δεδομένων), ώστε να είναι άμεσα διαθέσιμα τα αποτελέσματα στους χρήστες. Η επεξεργασία τους γίνεται σε κάποια ορισμένα χρονικά διαστήματα (πχ κάθε βράδυ ή κάθε 4 ώρες) καθώς η ανάλυση δεδομένων και η επεξεργασία των κύβων είναι μια χρονοβόρα διαδικασία. Εκτός από αυτά τα δεδομένα σχεδόν σε όλους τους οργανισμούς υπάρχουν και ροές δεδομένων. Ροές δεδομένων χαρακτηρίζουμε τα δεδομένα τα οποία έρχονται συνεχόμενα ανά τακτά χρονικά διαστήματα (πχ κάθε 1 λεπτό). Αυτά για παράδειγμα μπορεί να είναι δεδομένα από συστήματα παρακολούθησης παραγωγής ή τιμές μετοχών κτλ., Η επεξεργασία των ροών δεδομένων σε συστήματα BI είναι πιο δύσκολη, γιατί σε συγκεκριμένες περιπτώσεις πρέπει να γίνει άμεσα ώστε τα δεδομένα αυτά να είναι άμεσα διαθέσιμα προς τους χρήστες. Για το σύστημα OLAP υπάρχουν διαδικασίες ώστε να μην γίνεται επαναυπολογισμός ολόκληρου του πολυδιάστατου μοντέλου αλλά να ενημερώνεται μόνο με τα νέα δεδομένα όπου και έρχονται. Για τα συστήματα εξόρυξης γνώσης υπάρχουν αντίστοιχες τεχνικές που ονομάζονται προοδευτική εκπαίδευση μηχανικής μάθησης.

## 1.2 Δομή εργασίας

Στην εργασία αυτή στο κεφάλαιο 2, παρουσιάζεται ένα σύστημα επιχειρησιακής ευφυΐας (BI), αναλύοντας την δομή του και τα συστήματα τα οποία εμπεριέχει. Ακόμα αναλύεται η διαδικασία που χρειάζεται να ακολουθηθεί, για την υλοποίηση ενός συστήματος επιχειρησιακής ευφυΐας.

Στο κεφάλαιο 3 παρουσιάζετε ο λόγος για την ανάγκη της προοδευτικής εκπαίδευσης μηχανικής μάθησης και αναλύονται οι προκλήσεις για την υλοποίηση μιας τέτοιας μεθόδου προοδευτικής εκπαίδευσης.

Στο κεφάλαιο 4 παρουσιάζονται τα τεχνητά νευρωνικά δίκτυα. Αρχικά γίνεται μια παρουσίαση του γενικού τρόπου λειτουργίας τους, παρουσιάζοντας και τους βιολογικούς νευρώνες απ' όπου και προέρχονται σαν σύλληψη. Στην συνέχεια αναλύονται οι δομές διαφόρων τύπων νευρωνικών δικτύων. Και τέλος αναλύονται οι τρόποι εκπαίδευσης ενός νευρωνικού δικτύου .

Στο κεφάλαιο 5 περιγράφονται τα πιο δημοφιλή τύπου νευρωνικά δίκτυα που υποστηρίζουν προοδευτική εκπαίδευση.

Στο κεφάλαιο 6 συγκεντρώνονται τα συμπεράσματα της εργασίας.

## 2 Επιχειρησιακή ευφυΐα

### 2.1 Έννοια επιχειρησιακής ευφυΐας

Η επιχειρησιακή ευφυΐα - Business Intelligence (BI) περιλαμβάνει τις στρατηγικές και τις τεχνολογίες που χρησιμοποιούνται από τις επιχειρήσεις και τους οργανισμούς για την ανάλυση των επιχειρησιακών τους δεδομένων [1]. Ο ορισμός Business Intelligence αναφέρεται αρχικά από τον Richard Millar Devens' στο 'Cyclopedia of Commercial and Business Anecdotes' που εκδόθηκε το 1865. Ο ορισμός χρησιμοποιήθηκε για να περιγράψει τον τρόπο λειτουργίας του τραπεζίτη Sir Henry Furnese, που μεγιστοποιούσε τα κέρδη του συλλέγοντας πληροφορίες από το περιβάλλον του και παίρνοντας αποφάσεις βασισμένες σε αυτές συνδυάζοντας τις κατάλληλα, αυτή είναι και η βασική δομή της επιχειρησιακής ευφυΐας σήμερα [2]. Η επιχειρησιακή ευφυΐα όπως αναλύεται σήμερα είναι η εξέλιξη των Συστημάτων λήψης αποφάσεων που ξεκίνησαν την δεκαετία του 60 και εξελίχθηκαν έως τα μέσα του 80. Η ανάλυση επιχειρησιακών δεδομένων αποτελεί σημαντικό μέρος της σύγχρονης διοίκησης επιχειρήσεων, καθώς η αποτελεσματική συλλογή πληροφοριών και η ανάλυσή τους, επιτρέπει στους υπεύθυνους λήψης αποφάσεων να λαμβάνουν τις βέλτιστες αποφάσεις για την πλήρη κάλυψη των στόχων που έχει ορίσει ο οργανισμός.

Για την αποτελεσματική λήψη αποφάσεων σε έναν οργανισμό, το πρώτο βήμα είναι να ορισθούν συγκεκριμένοι και μετρήσιμοι στόχοι σχετικά με τους στόχους που έχουν ορισθεί. Αφού καθοριστούν αυτοί οι στόχοι το επόμενο βήμα είναι να υπάρξουν ακριβείς και χρήσιμες πληροφορίες προς τα στελέχη που θα λάβουν τις αποφάσεις, σχετικά με την εγκυρότητα των στόχων και για το αν μπορούν να επιτευχθούν. Οι πληροφορίες αυτές θα χρησιμεύσουν σαν βάση για τη λήψη αποφάσεων και σαν ανατροφοδότηση σχετικά με τον έλεγχο της αποτελεσματικότητας των αποφάσεων αυτών. Για τον οργανισμό, το βασικό στοιχείο είναι οι πληροφορίες να είναι διαθέσιμες την κατάλληλη στιγμή προς τα στελέχη, που θα λάβουν τις αποφάσεις [3]. Επομένως, το ερώτημα για τον οργανισμό είναι πως ο οργανισμός θα λάβει και θα διανείμει τις πληροφορίες αυτές. Την απάντηση στο συγκεκριμένο ερώτημα έρχεται να δώσει η έννοια της επιχειρηματικής ευφυΐας. Επιχειρηματική ευφυΐα είναι η διαδικασία παροχής ακριβής και χρήσιμης πληροφορίας στα κατάλληλα στελέχη λήψης αποφάσεων εντός του αναγκαίου χρονικού πλαισίου για να υποστηρίξει την αποτελεσματική λήψη απόφασης. Η επιχειρηματική ευφυΐα δεν είναι μόνο απλοί αριθμοί και διαγράμματα σε μια αναφορά. Μια αναφορά που παραθέτει απλά αριθμητικά δεδομένα (παραδείγματα στοιχεία πωλήσεων), μπορεί να αποτελούν σωστή πληροφορία των αποτελεσμάτων αλλά δεν μπορούν να είναι επιχειρηματική ευφυΐα μέχρι να παρουσιαστούν στα σωστά άτομα που λαμβάνουν αποφάσεις, όπου μπορούν να τα κατανοήσουν πλήρως και είναι διαθέσιμα την στιγμή όπου απαιτείται για την λήψη της απόφασης. Για παράδειγμα, μια συνοπτική αναφορά της ικανοποίησης των πελατών, σε μια επιχείρηση η οποία μπορεί να γίνει εύκολα κατανοητή από τα στελέχη, δεν είναι επιχειρηματική ευφυΐα, έως ότου οι πληροφορίες αυτές παραδίδονται την σωστή στιγμή και σε κατάλληλη μορφή έτσι ώστε να επηρεάζουν ουσιαστικά την καθημερινή λήψη αποφάσεων, σχετικά με την εξυπηρέτηση των πελατών. Σύμφωνα με έναν άλλο ορισμό επιχειρηματική ευφυΐα είναι ένα μεγάλο σύνολο εφαρμογών και τεχνολογιών για την συγκέντρωση, αποθήκευση, ανάλυση, κοινοποίηση και παροχή πρόσβασης σε δεδομένα που βοηθούν τις επιχειρήσεις να λαμβάνουν καλύτερες επιχειρηματικές αποφάσεις. Αναφορικά με τον παραπάνω ορισμό, η επιχειρηματική ευφυΐα είναι ένα σύνολο μεθόδων για αποθήκευση και παρουσίαση σημαντικών πληροφοριών έτσι ώστε ο κάθε ενδιαφερόμενος σε κάθε οργανισμό να μπορεί εύκολα και γρήγορα να παίρνει απαντήσεις στα ερωτήματά του και να λαμβάνει τις πιο σωστές αποφάσεις [4].

Τα συστήματα που χρησιμοποιούνται στην επιχειρησιακή ευφυΐας είναι : reporting, online analytical processing, analytics, data mining, process mining, complex event processing, business performance management, benchmarking, text mining, predictive analytics and prescriptive analytics



Εικόνα 1 – Συστήματα επιχειρησιακής ευφυΐας

Τα συστήματα BI μπορούν να χειριστούν πολλά δεδομένα, δομημένα ή αδόμητα που μπορούν να βοηθήσουν στον εντοπισμό, την ανάπτυξη και τη δημιουργία νέων στρατηγικών επιχειρηματικών ευκαιριών. Σκοπός τους είναι να επιτρέπουν την εύκολη ερμηνεία αυτών των μεγάλων δεδομένων.

## 2.2 Διαδικασία BI

Για την εφαρμογή της επιχειρησιακής ευφυΐας αρχικά πρέπει να συγκεντρώσουμε τα δεδομένα από πολλαπλά συστήματα ή υποσυστήματα μέσα στον οργανισμό, όπως συστήματα ERP, CRM, δεδομένα που υπάρχουν σε csv ή excel, δεδομένα από συστήματα επίβλεψης παραγωγής και άλλα. Η συγκέντρωση των δεδομένων αυτών γίνεται σε ένα σύστημα που ονομάζεται data warehouse. Πριν την αποθήκευση των δεδομένων στο DW πρέπει να προηγηθούν κάποια βήματα για τον καθαρισμό και μείωση των δεδομένων από μια διαδικασία που ονομάζεται ETL (Extract, Transform, Load) [4].

Το πρώτο μέρος μιας διαδικασίας ETL περιλαμβάνει την εξαγωγή των δεδομένων από τα συστήματα πηγών των δεδομένων. Σε πολλές περιπτώσεις, αυτό αντιπροσωπεύει τη σημαντικότερη πτυχή του ETL, δεδομένου ότι η εξαγωγή δεδομένων θέτει σωστά το στάδιο για την επιτυχία των επακόλουθων διαδικασιών. Τα περισσότερα DW (data warehouse) συνδυάζουν δεδομένα από διαφορετικά συστήματα. Κάθε ξεχωριστό σύστημα μπορεί επίσης να χρησιμοποιεί διαφορετική οργάνωση δεδομένων ή και μορφή. Οι κοινές μορφές πηγών δεδομένων περιλαμβάνουν σχεσιακές βάσεις δεδομένων, XML, JSON και αρχεία (csv, excel, word και άλλα), αλλά μπορούν επίσης να

περιλαμβάνουν δομημένες ή μη δομικές βάσεων δεδομένων ή ακόμη και μορφές που λαμβάνονται από εξωτερικές πηγές μέσω μέσων όπως web spidering ή social media. Η ροή της εξαγόμενης πηγής δεδομένων και η φόρτωση επί τόπου στη βάση δεδομένων προορισμού είναι ένας άλλος τρόπος εκτέλεσης του ETL όταν δεν απαιτείται ενδιάμεση αποθήκευση δεδομένων. Γενικά, η φάση εξαγωγής αποσκοπεί στη μετατροπή των δεδομένων σε μία ενιαία μορφή κατάλληλη για την επεξεργασία μετασχηματισμού.

Στο στάδιο μετασχηματισμού δεδομένων, εφαρμόζεται μια σειρά κανόνων ή λειτουργιών στα εξαγόμενα δεδομένα προκειμένου να προετοιμαστούν για αποθήκευση στο DW. Ορισμένα δεδομένα δεν απαιτούν καθόλου μετασχηματισμό, αυτά τα δεδομένα είναι γνωστά ως δεδομένα "άμεσης κίνησης" ή "διέλευσης".

Μια σημαντική λειτουργία του μετασχηματισμού είναι ο καθαρισμός των δεδομένων, ο οποίος στοχεύει να περάσει μόνο τα "σωστά" δεδομένα στο DW. Η πρόκληση όταν αλληλοεπιδρούν διαφορετικά συστήματα είναι η διασύνδεση και η επικοινωνία των σχετικών συστημάτων.

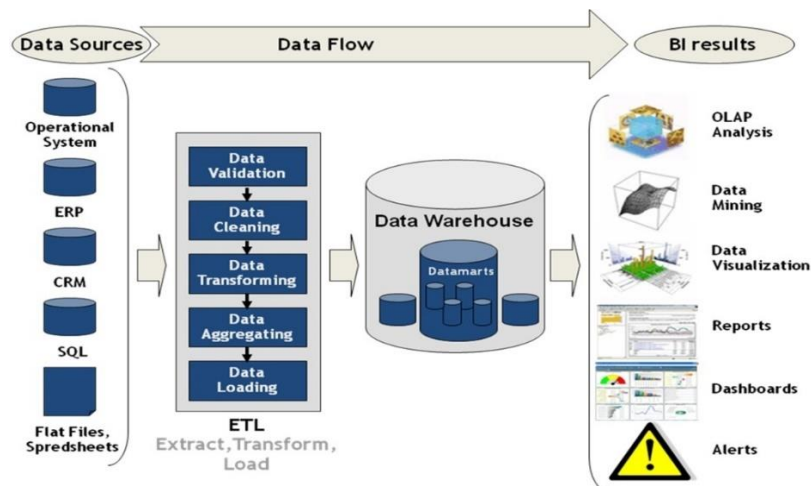
Γενικά, ένας ή περισσότεροι από τους ακόλουθους τύπους μετασχηματισμού μπορεί να απαιτούνται για την κάλυψη των επιχειρηματικών και τεχνικών αναγκών της αποθήκης δεδομένων:

- 1) Επιλογή δεδομένων για μεταφορά: (ή η επιλογή να μην φορτωθούν στήλες με μηδενικές τιμές). Για παράδειγμα, αν τα δεδομένα προέλευσης έχουν τρεις στήλες (γνωστά ως "χαρακτηριστικά"), Επωνυμία πελάτη, διεύθυνση και ΑΦΜ, τότε η επιλογή μπορεί να είναι μόνο τα Επωνυμία πελάτη, διεύθυνση. Ακόμα ο μηχανισμός επιλογής μπορεί να αγνοήσει όλα τα αρχεία όπου δεν υπάρχει ΑΦΜ.
- 2) Μετάφραση κωδικοποιημένων τιμών: (π.χ. αν το σύστημα από το οποίο διαβάζουμε τα δεδομένα κωδικοποιεί το ενεργός πελάτης ως "0" και το ανενεργός ως "1", αλλά το DW κωδικοποιεί ενεργός πελάτης ως "Ναι" και το ανενεργός ως "Όχι")
- 3) Κωδικοποίηση τιμών ελεύθερης μορφής: (π.χ. αντιστοίχιση "Αρσενικό" με "Μ")
- 4) Αποτέλεσμα μιας υπολογιζόμενης τιμής: (π.χ., συνολική αξία = τεμάχια \* αξία)
- 5) Ταξινόμηση των δεδομένων για τη βελτίωση της απόδοσης αναζήτησης
- 6) Σύνδεση δεδομένων από πολλαπλές πηγές (π.χ. αναζήτηση, συγχώνευση) και κατάργηση των διπλότυπων δεδομένων
- 7) Συγκέντρωση δεδομένων (για παράδειγμα, συλλογή - σύνοψη πολλαπλών σειρών δεδομένων - συνολικές πωλήσεις για κάθε προϊόν ανά ημέρα κ.λπ.)
- 8) Δημιουργία τιμών ως υποκατάστατο κλειδιού πίνακα
- 9) Μεταφορά ή περιστροφή (μετατροπή πολλών στηλών σε πολλαπλές σειρές ή αντίστροφα)
- 10) Διαίρεση μιας στήλης σε πολλές στήλες (π.χ. μετατροπή μιας διαχωρισμένης με κόμμα λίστας, καθορισμένης ως συμβολοσειρά σε μία στήλη, σε μεμονωμένες τιμές σε διαφορετικές στήλες)
- 11) Διαχωρισμός επαναλαμβανόμενων στηλών
- 12) 874450 μπορεί να οδηγήσει σε πλήρη απόρριψη των δεδομένων, σε μερική απόρριψη ή σε καμία απόρριψη και έτσι κανένα, μερικά ή όλα τα δεδομένα παραδίδονται στο επόμενο βήμα, ανάλογα με τον σχεδιασμό κανόνων και τον χειρισμό εξαιρέσεων. Πολλοί από τους παραπάνω μετασχηματισμούς μπορεί να έχουν ως αποτέλεσμα εξαιρέσεις.

Η τελευταία φάση του ETL αποθηκεύει τα δεδομένα στον τελικό στόχο που είναι το DW. Ανάλογα με τις απαιτήσεις του οργανισμού, η διαδικασία αυτή ποικίλλει ευρέως. Ορισμένες αποθήκες δεδομένων ενδέχεται να αντικαταστήσουν υπάρχουσες πληροφορίες με αθροιστικές

πληροφορίες. η ενημέρωση των εξαγόμενων δεδομένων γίνεται συχνά σε ημερήσια, εβδομαδιαία ή μηνιαία βάση. Άλλες αποθήκες δεδομένων (ή ακόμη και άλλα τμήματα της ίδιας αποθήκης δεδομένων) ενδέχεται να προσθέτουν νέα δεδομένα σε ιστορική μορφή σε τακτά χρονικά διαστήματα - για παράδειγμα, ανά ώρα, παράδειγμα μια αποθήκη δεδομένων που απαιτείται για τη διατήρηση των αρχείων πωλήσεων του τελευταίου έτους. Αυτή η αποθήκη δεδομένων αντικαθιστά οποιαδήποτε δεδομένα παλαιότερα από ένα χρόνο με νεότερα δεδομένα. Ωστόσο, η εισαγωγή δεδομένων για οποιοδήποτε παράθυρο ενός έτους πραγματοποιείται με ιστορικό τρόπο. Το χρονοδιάγραμμα και η εμβέλεια για αντικατάσταση ή προσάρτηση είναι στρατηγικές επιλογές σχεδιασμού που εξαρτώνται από τον διαθέσιμο χρόνο και τις επιχειρηματικές ανάγκες. Τα πιο σύνθετα συστήματα μπορούν να διατηρήσουν ένα ιστορικό και ένα ίχνος ελέγχου όλων των αλλαγών στα δεδομένα που έχουν φορτωθεί στην αποθήκη δεδομένων.

Το Data Warehouse αποτελεί μία συλλογή δεδομένων, τα οποία είναι διαχρονικά, περιληπτικά και συγχωνευμένα και προέρχονται από τα πρωτογενή εταιρικά δεδομένα. Καλύπτουν μεγάλο χρονικό διάστημα και επιλέγονται από τις επιχειρηματικές βάσεις δεδομένων, ενώ ολοκληρώνονται και αναλύονται με διαδικασίες όπως η OLAP ή η εξόρυξη δεδομένων με σκοπό την υποστήριξη λήψης αποφάσεων. Είναι μια διαδικασία που μπορεί να ομαδοποιήσει τα δεδομένα από ετερογενή πηγές, και την αποδοτική διαθεσιμότητα ιστορικών δεδομένων. Εντός ενός Data Warehouse μπορεί να υπάρχουν Data marts [1]. Τα Κέντρα δεδομένων (Data Marts) είναι μία συλλογή από θεματικά πεδία που είναι οργανωμένα με βάση τις ανάγκες ενός τμήματος για τη λήψη αποφάσεων. Αποτελούν δηλαδή ένα υποσύνολο της αποθήκης δεδομένων. Όπως και στην αποθήκη δεδομένων, τα κέντρα δεδομένων περιέχουν δεδομένα που βοηθούν τα στελέχη των επιχειρήσεων να εφαρμόζουν στρατηγικές βάσει των αναλύσεων και των προηγούμενων τάσεων και εμπειριών. Η βασική διαφορά είναι ότι η ανάγκη για δημιουργία κέντρων δεδομένων είναι συγκεκριμένη και προκαθορισμένη για μία συγκεκριμένη ομάδα επιλεγμένων δεδομένων. Μπορεί να υπάρχουν πολλά κέντρα δεδομένων σε μία επιχείρηση. Ένα κέντρο δεδομένων μπορεί να υποστηρίξει μία συγκεκριμένη λειτουργία, διαδικασία ή μονάδα της επιχείρησης.



Εικόνα 2 - Διαδικασία επιχειρησιακής ευφυΐας

Μετά την επιτυχή συγκέντρωση των δεδομένων σε Data Warehouse και σε Data Marts ακολουθεί εφαρμογή των συστημάτων ενός BI.

OLAP (On-line Analytical Processing) είναι μία πολυδιάστατη ανάλυση των επιχειρηματικών δεδομένων και παρέχει τη δυνατότητα σύνθετων υπολογισμών, ανάλυσης τάσεων και εξελιγμένων

μοντέλων δεδομένων. Είναι η βάση για πολλά είδη επιχειρησιακών εφαρμογών, όπως για τη Διαχείριση Επιχειρησιακής Απόδοσης, τον Σχεδιασμό, τον Προϋπολογισμό, την Πρόβλεψη, τη Χρηματοοικονομική Αναφορά, την Ανάλυση, τα Μοντέλα Προσομοίωσης και την Αναφορά Δεδομένων από την Αποθήκη Δεδομένων [5]. Το OLAP επιτρέπει στους τελικούς χρήστες να πραγματοποιούν μόνοι τους ανάλυση των δεδομένων σε πολλαπλές διαστάσεις, παρέχοντας έτσι την κατανόηση που χρειάζονται για τη λήψη καλύτερων αποφάσεων.

Εξόρυξη Δεδομένων (Data mining), το Data mining είναι ένας κλάδος της επιστήμης των υπολογιστών και αποτελεί μία διαδικασία εξόρυξης γνώσης από σύνολα δεδομένων, συνδυάζοντας μεθόδους στατιστικών και μηχανικής μάθησης με τη διαχείριση βάσης δεδομένων. Η εξόρυξη δεδομένων εντοπίζει νέες πληροφορίες σχετικά με δεδομένα που έχουν ήδη συλλεχθεί. Οι βασικές εφαρμογές της εξόρυξης δεδομένων είναι η συσταδοποίηση, η ταξινόμηση, η παλινδρόμηση, οι κανόνες συσχέτισης και ανίχνευση ανωμαλιών [6].

### **Συσταδοποίηση**

Η συσταδοποίηση είναι η διαδικασία ανακάλυψης ομάδων και δομών στα δεδομένα που είναι "παρόμοια" κατά κάποιο τρόπο, χωρίς να χρησιμοποιούνται γνωστές δομές στα δεδομένα. Ακόμα επιτρέπει σε ένα αντικείμενο να μην είναι μέρος ενός συμπλέγματος ή να ανήκει αυστηρά σε αυτό, ονομάζοντας αυτό το είδος ομαδοποίησης αυστηρή κατανομή. Από την άλλη πλευρά, η χαλαρή κατανομή δηλώνει ότι κάθε αντικείμενο ανήκει σε ένα σύμπλεγμα σε καθορισμένο βαθμό. Πιο συγκεκριμένες διαιρέσεις είναι δυνατόν να δημιουργηθούν, όπως αντικείμενα που ανήκουν σε πολλαπλές ομάδες, ένα αντικείμενο να συμμετάσχει σε μια μόνο ομάδα ή ακόμα και να κατασκευαστούν ιεραρχικά δέντρα με ομαδικές σχέσεις [6]. Υπάρχουν διάφοροι τρόποι υλοποίησης αυτής της κατανομής, που βασίζονται σε ξεχωριστά μοντέλα. Διακριτικοί αλγόριθμοι εφαρμόζονται σε κάθε μοντέλο, διαφοροποιώντας τις ιδιότητες και τα αποτελέσματά του. Αυτά τα μοντέλα διακρίνονται από την οργάνωση και τον τύπο αναδιάρθρωσης μεταξύ τους. Οι σημαντικότερες είναι:

*Centralized*, Κάθε σύμπλεγμα αντιπροσωπεύεται από ένα μοναδικό μέσο διανύσματος και μια τιμή αντικειμένου συγκρίνεται με αυτές τις μέσες τιμές

*Distributed*, Το σύμπλεγμα κατασκευάζεται χρησιμοποιώντας στατιστικές κατανομές

*Connectivity*, Η συνδεσιμότητα σε αυτά τα μοντέλα βασίζεται σε μια λειτουργία απόστασης μεταξύ των στοιχείων

*Group*, Οι αλγόριθμοι ομάδας έχουν μόνο πληροφορίες για τις ομάδες

*Graph*, Οργάνωση ομαδοποίησης και σχέση μεταξύ των μελών καθορίζεται από μια δομή που συνδέεται με ένα γράφημα.

*Density*, Τα μέλη του συμπλέγματος ομαδοποιούνται ανά περιοχές όπου οι παρατηρήσεις είναι πυκνές και παρόμοιες

### **Ταξινόμηση**

Η ταξινόμηση είναι μια λειτουργία εξόρυξης δεδομένων που αποδίδει στοιχεία σε μια συλλογή για να στοχεύει κατηγορίες ή κλάσεις. Ο στόχος της ταξινόμησης είναι η ακριβής πρόβλεψη της τάξης-στόχου για κάθε περίπτωση στα δεδομένα. Για παράδειγμα, θα μπορούσε να χρησιμοποιηθεί ένα μοντέλο ταξινόμησης για τον προσδιορισμό των αιτούντων δανείων ως χαμηλού, μεσαίου ή υψηλού πιστωτικού κινδύνου. Μια εργασία ταξινόμησης αρχίζει με ένα σύνολο δεδομένων στο οποίο είναι γνωστές οι ταξινομήσεις. Για παράδειγμα, ένα μοντέλο ταξινόμησης που προβλέπει πιστωτικό κίνδυνο θα μπορούσε να αναπτυχθεί με βάση τα δεδομένα που έχουν παρατηρηθεί για πολλούς

αιτούντες δάνεια σε μια χρονική περίοδο. Εκτός από την ιστορική αξιολόγηση πιστοληπτικής ικανότητας, τα δεδομένα ενδέχεται να παρακολουθούν το ιστορικό απασχόλησης, την ιδιοκτησία κατοικίας ή την ενοικίαση, τα έτη διαμονής, τον αριθμό και τον τύπο των επενδύσεων και άλλα. Η πιστοληπτική ικανότητα θα ήταν ο στόχος, τα άλλα χαρακτηριστικά θα ήταν οι προβλέψεις και τα δεδομένα για κάθε πελάτη θα αποτελούσαν τις περιπτώσεις. Οι ταξινομήσεις είναι διακριτές και δεν υπονοούν την τάξη. Οι συνεχείς τιμές υποδηλώνουν έναν αριθμητικό και όχι ένα κατηγορηματικό στόχο. Ο απλούστερος τύπος του προβλήματος ταξινόμησης είναι η δυαδική ταξινόμηση. Στη δυαδική ταξινόμηση, ο χαρακτηριστικός στόχος έχει μόνο δύο πιθανές τιμές: για παράδειγμα, υψηλή πιστοληπτική ικανότητα ή χαμηλή πιστοληπτική ικανότητα. Οι στόχοι πολλαπλών κλάσεων έχουν περισσότερες από δύο τιμές: για παράδειγμα, χαμηλή, μεσαία, υψηλή ή άγνωστη αξιολόγηση πιστοληπτικής ικανότητας. Στη διαδικασία κατασκευής μοντέλου (model), ένας αλγόριθμος ταξινόμησης βρίσκει σχέσεις μεταξύ των τιμών των προγνωστικών δεδομένων και των τιμών του στόχου. Οι διαφορετικοί αλγόριθμοι ταξινόμησης χρησιμοποιούν διαφορετικές τεχνικές για την εύρεση σχέσεων. Αυτές οι σχέσεις συνοψίζονται σε ένα μοντέλο, το οποίο μπορεί στη συνέχεια να εφαρμοστεί σε ένα διαφορετικό σύνολο δεδομένων στο οποίο οι ταξινομήσεις είναι άγνωστες. Τα μοντέλα ταξινόμησης ελέγχονται συγκρίνοντας τις προβλεπόμενες τιμές με τις γνωστές τιμές στόχους σε ένα σύνολο δεδομένων δοκιμών. Η βαθμολόγηση ενός μοντέλου ταξινόμησης έχει ως αποτέλεσμα ταξινομήσεις και πιθανότητες για κάθε περίπτωση [7]. Για παράδειγμα, ένα μοντέλο που ταξινομεί την πιστοληπτική ικανότητα κάθε πελάτη ως χαμηλή, μεσαία ή υψηλή θα προέβλεπαι επίσης την πιθανότητα ταξινόμησης για κάθε νέο πελάτη.

### **Παλινδρόμηση**

Η παλινδρόμηση είναι μια λειτουργία εξόρυξης δεδομένων που προβλέπει μία συνάρτηση που μοντελοποιεί τα δεδομένα με το λιγότερο δυνατό σφάλμα. Τα κέρδη, οι πωλήσεις, τα επιτόκια στεγαστικών δανείων, οι τιμές κατοικίας, η θερμοκρασία θα μπορούσαν να προβλεφθούν χρησιμοποιώντας τεχνικές παλινδρόμησης. Για παράδειγμα, ένα μοντέλο παλινδρόμησης θα μπορούσε να χρησιμοποιηθεί για την πρόβλεψη της αξίας ενός σπιτιού με βάση την τοποθεσία, τον αριθμό των δωματίων, το μέγεθος της παρτίδας και άλλους παράγοντες. Μια εργασία παλινδρόμησης ξεκινά με ένα σύνολο δεδομένων στο οποίο είναι γνωστές οι τιμές-στόχοι. Για παράδειγμα, ένα μοντέλο παλινδρόμησης που προβλέπει τιμές οικίας θα μπορούσε να αναπτυχθεί με βάση τα παρατηρούμενα δεδομένα για πολλά σπίτια σε μια χρονική περίοδο. Εκτός από την αξία, τα δεδομένα ενδέχεται να παρακολουθούν την ηλικία του σπιτιού, τα τετραγωνικά μέτρα, τον αριθμό των δωματίων, τους φόρους, τη σχολική συνοικία, την εγγύτητα με τα εμπορικά κέντρα και ούτω καθεξής. Η αξία του σπιτιού θα ήταν ο στόχος, τα άλλα χαρακτηριστικά θα ήταν οι προβλέψεις και τα στοιχεία για κάθε σπίτι θα αποτελούσαν τις περιπτώσεις. Στη διαδικασία κατασκευής μοντέλου, ένας αλγόριθμος παλινδρόμησης υπολογίζει την τιμή του στόχου ως συνάρτηση των προβλέψεων για κάθε περίπτωση στα δεδομένα εκπαίδευσης. Αυτές οι σχέσεις μεταξύ των προβλέψεων και του στόχου συνοψίζονται σε ένα μοντέλο, το οποίο μπορεί στη συνέχεια να εφαρμοστεί σε ένα διαφορετικό σύνολο δεδομένων στο οποίο οι τιμές-στόχοι είναι άγνωστες. Τα μοντέλα παλινδρόμησης ελέγχονται με υπολογισμό διαφόρων στατιστικών στοιχείων που μετρούν τη διαφορά μεταξύ των προβλεπόμενων τιμών και των αναμενόμενων τιμών [7].

### **Κανόνες συσχέτισης**

Οι κανόνες συσχέτισης είναι μια λειτουργία εξόρυξης δεδομένων που ανακαλύπτει την πιθανότητα της ταυτόχρονης εμφάνισης αντικειμένων σε μια συλλογή. Οι σχέσεις μεταξύ των συμβαλλόμενων στοιχείων εκφράζονται ως κανόνες συσχέτισης [6]. Οι κανόνες συσχέτισης χρησιμοποιούνται συχνά για την ανάλυση συναλλαγών πωλήσεων. Για παράδειγμα, μπορεί να σημειωθεί ότι οι πελάτες που αγοράζουν δημητριακά στο παντοπωλείο συχνά αγοράζουν γάλα



ταυτόχρονα. Στην πραγματικότητα, η ανάλυση της συσχέτισης μπορεί να διαπιστώσει ότι το 85% των συνεδριών πληρωμής που περιλαμβάνουν δημητριακά περιλαμβάνουν επίσης το γάλα. Αυτή η σχέση θα μπορούσε να διατυπωθεί ως ο ακόλουθος κανόνας.

Η πώληση δημητριακών υποδηλώνει πώληση γάλατος με εμπιστοσύνη 85%

Αυτή η εφαρμογή των κανόνων συσχέτισης ονομάζεται ανάλυση αγοράς καλαθιού. Είναι πολύτιμο για το άμεσο μάρκετινγκ, τις προωθήσεις πωλήσεων και για την ανακάλυψη των τάσεων των επιχειρήσεων. Η ανάλυση του καλαθιού αγοράς μπορεί επίσης να χρησιμοποιηθεί αποτελεσματικά για τη διαρρύθμιση καταστημάτων και τον σχεδιασμό καταλόγων. Οι κανόνες συσχέτισης έχουν σημαντικές εφαρμογές και σε άλλους τομείς. Για παράδειγμα, στις εφαρμογές ηλεκτρονικού εμπορίου, οι κανόνες σύνδεσης μπορούν να χρησιμοποιηθούν για την εξατομίκευση της ιστοσελίδας. Ένα μοντέλο σύνδεσης μπορεί να διαπιστώσει ότι ένας χρήστης που επισκέπτεται τις σελίδες A και B είναι 70% πιθανό να επισκεφθεί επίσης τη σελίδα Γ στην ίδια συνεδρία. Βάσει αυτού του κανόνα, θα μπορούσε να δημιουργηθεί ένας δυναμικός σύνδεσμος για χρήστες που είναι πιθανό να ενδιαφέρονται για τη σελίδα C. Ο κανόνας σύνδεσης μπορεί να εκφραστεί ως εξής.

Τα A και B υποδηλώνουν C με 70% εμπιστοσύνη

Ο στόχος της ανίχνευσης ανωμαλιών είναι να εντοπιστούν περιπτώσεις που είναι ασυνήθιστες σε δεδομένα που είναι φαινομενικά ομοιογενή. Η ανίχνευση ανωμαλιών είναι ένα σημαντικό εργαλείο για την ανίχνευση της απάτης, της διείσδυσης του δικτύου και άλλων σπάνιων γεγονότων που μπορεί να έχουν μεγάλη σημασία αλλά είναι δύσκολο να βρεθούν.

### **Ανίχνευση ανωμαλιών**

Η ανίχνευση ανωμαλιών είναι μια μορφή ταξινόμησης. Η ανίχνευση ανωμαλίας υλοποιείται ως ταξινόμηση μιας κατηγορίας, επειδή μόνο στα τμήματα της εκπαίδευσης παρουσιάζονται μόνο μία τάξη. Ένα μοντέλο ανίχνευσης ανωμαλίας προβλέπει αν ένα σημείο δεδομένων είναι τυπικό για μια δεδομένη κατανομή ή όχι. Ένα άτυπο σημείο δεδομένων μπορεί να είναι είτε μια απόκλιση ή ένα παράδειγμα μιας νέας κλάσης. Κανονικά, ένα μοντέλο ταξινόμησης πρέπει να εκπαιδευτεί σε δεδομένα που περιλαμβάνουν τόσο παραδείγματα όσο και μη παραδείγματα για κάθε κλάση, ώστε το μοντέλο να μπορεί να μάθει να κάνει διάκριση μεταξύ τους [7]. Για παράδειγμα, ένα μοντέλο που προβλέπει παρενέργειες ενός φαρμάκου θα πρέπει να εκπαιδεύεται σε δεδομένα που περιλαμβάνουν ένα ευρύ φάσμα παρενεργειών στο φάρμακο. Ένας ταξινομητής μιας κατηγορίας αναπτύσσει ένα προφίλ που γενικά περιγράφει μια τυπική περίπτωση στα δεδομένα εκπαίδευσης. Η απόκλιση από το προφίλ αναγνωρίζεται ως ανωμαλία. Οι ταξινομητές μιας κατηγορίας αναφέρονται μερικές φορές ως θετικά πρότυπα ασφαλείας, επειδή επιδιώκουν να αναγνωρίσουν «καλές» συμπεριφορές και να υποθέσουν ότι όλες οι άλλες συμπεριφορές είναι κακές.

οποία τα αποτελέσματα της ανάλυσης δεδομένων παρουσιάζονται στους χρήστες.

### 3 Ροές Δεδομένων και τύποι σταδιακής εκπαίδευσης

Σε έναν οργανισμό υπάρχουν δεδομένα όπως πωλήσεις – αγορές και άλλα που συλλέγονται συγκεντρωμένα συνήθως στο Data Warehouse και στις περισσότερες περιπτώσεις δεν χρειάζονται άμεση επεξεργασία στα συστήματα του BI (OLAP και ανάλυση δεδομένων), ώστε να είναι άμεσα διαθέσιμα τα αποτελέσματα στους χρήστες. Η επεξεργασία τους γίνεται σε κάποια ορισμένα χρονικά διαστήματα (πχ κάθε βράδυ ή κάθε 4 ώρες) καθότι η ανάλυση δεδομένων και η επεξεργασία των κύβων είναι μια χρονοβόρα διαδικασία. Εκτός από αυτά τα δεδομένα σχεδόν σε όλους τους οργανισμούς υπάρχουν και ροές δεδομένων. Ροές δεδομένων χαρακτηρίζουμε τα δεδομένα τα οποία έρχονται συνεχόμενα ανά τακτά χρονικά διαστήματα (πχ κάθε 1 λεπτό). Αυτά για παράδειγμα μπορεί να είναι δεδομένα από συστήματα παρακολούθησης παραγωγής ή τιμές μετοχών κτλ., Η επεξεργασία των ροών δεδομένων σε συστήματα BI είναι ποιο δύσκολή, γιατί σε συγκεκριμένες περιπτώσεις πρέπει να γίνει άμεσα ώστε τα δεδομένα αυτά να είναι άμεσα διαθέσιμα προς τους χρήστες. Για το σύστημα OLAP υπάρχουν διαδικασίες ώστε να μην γίνεται επαναυπολογισμός ολόκληρου του πολυδιάστατου μοντέλου αλλά να ενημερώνεται μόνο με τα νέα δεδομένα όπου και έρχονται. Για τα συστήματα εξόρυξης γνώσης υπάρχουν αντίστοιχες τεχνικές που ονομάζονται προοδευτική εκπαίδευση μηχανικής μάθησης.

Οι μέθοδοι εκπαίδευσης εξόρυξης δεδομένων ή αλλιώς μηχανικής μάθησης προσφέρουν ιδιαίτερα ισχυρές τεχνολογίες για την εξαγωγή πληροφοριών από δεδομένα. Ωστόσο, η πλειοψηφία των εφαρμογών που ισχύουν σήμερα περιορίζεται στην κλασική εκπαίδευση με ομάδες δεδομένων: τα δεδομένα δίνονται πριν από την εκπαίδευση, επομένως η βελτιστοποίηση των παραμέτρων και η επιλογή μοντέλου μπορούν να βασίζονται στο πλήρες σύνολο δεδομένων και η εκπαίδευση μπορεί να στηριχθεί στην υπόθεση ότι τα δεδομένα και η υποκείμενη δομή είναι στατική. Η σταδιακή εκπαίδευση, αντίθετα, αναφέρεται στην κατάσταση της συνεχούς προσαρμογής μοντέλου βασισμένης σε μια συνεχόμενη ροή δεδομένων. Αυτή η ανάγκη υπάρχει όταν τα συστήματα λειτουργούν αυτόνομα, όπως σε αυτόνομη ρομποτική ή οδήγηση. Επιπλέον, η σταδιακή εκμάθηση καθίσταται απαραίτητη σε διαδραστικά σενάρια όπου παρέχονται παραδείγματα κατάρτισης με βάση την ανθρώπινη ανατροφοδότηση με την πάροδο του χρόνου. Τέλος, πολλά ψηφιακά σύνολα δεδομένων, αν και στατικά, μπορούν να γίνουν τόσο μεγάλα ώστε να αντιμετωπίζονται ως ροή δεδομένων, δηλ. Ένα σταδιακό πέραςμα από το πλήρες σύνολο δεδομένων. Η σταδιακή εκπαίδευση διερευνά τον τρόπο μάθησης σε τέτοιες περιπτώσεις ροής δεδομένων. Έρχεται σε διάφορες μορφές στη βιβλιογραφία και η χρήση του όρου δεν είναι πάντα συνεπής. Επομένως, καταρχήν, αναλύουμε τους σχετικούς όρους online learning και incremental learning [8].

#### 3.1.1 Online Learning μέθοδοι

Στην εποπτευόμενη μάθηση, τα δεδομένα  $D = ((x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_m, y_m))$  είναι διαθέσιμα με σήματα εισόδου  $x_i$  και εξόδους  $y_i$ . Για να εφαρμόσουμε Online learning πρέπει να δημιουργήσουμε ένα μοντέλο  $M \approx p(y|x)$  από τα δεδομένα αυτά. Οι αλγόριθμοι μηχανικής μάθησης συχνά εκπαιδεύονται σε ομάδες δεδομένων και χρησιμοποιούν όλα τα παραδείγματα εισόδων και εξόδων  $(x_i, y_i)$  ταυτόχρονα, ανεξάρτητα από την (χρονική) σειρά τους, για να εκτελέσουν, π.χ., ένα βήμα βελτιστοποίησης μοντέλου [10].

##### Πρόκληση 1: Προσαρμογή παραμέτρων μοντέλου Online

Σε πολλά παραδείγματα εφαρμογής, τα δεδομένα  $D$  δεν είναι διαθέσιμα εκ των προτέρων, αλλά τα παραδείγματα φθάνουν με την πάροδο του χρόνου και η εργασία είναι να δημιουργηθεί ένα αξιόπιστο μοντέλο  $M_t$  μετά από κάθε βήμα χρόνου που βασίζεται στο παράδειγμα  $(x_t, y_t)$  και το προηγούμενο μοντέλο  $M_{t-1}$ . Αυτό επιτυγχάνεται μέσω μεθόδων online μάθησης, οι οποίες

χρησιμοποιούν δείγματα εκπαίδευσης μία προς μία, χωρίς να γνωρίζουν εκ των προτέρων τον αριθμό τους, για να βελτιστοποιήσουν τη λειτουργία του μοντέλου. Υπάρχει μια σειρά δυνατοτήτων, που κυμαίνονται από πλήρως Online προσεγγίσεις που προσαρμόζουν το εσωτερικό τους μοντέλο αμέσως μετά την επεξεργασία ενός μόνο δείγματος, τεχνικές μίνι-παρτίδων δεδομένων που συσσωρεύουν ένα μικρό αριθμό δειγμάτων και μεθόδους μάθησης κατά παρτίδες, οι οποίες αποθηκεύουν όλα τα δείγματα εσωτερικά [11].

Η Online μάθηση επιτυγχάνεται εύκολα με στοχαστικές τεχνικές βελτιστοποίησης, όπως online (back-propagation) ανάστροφης μετάδοσης, αλλά υπάρχουν και επεκτάσεις σε support vector machine (SVM). Τα μοντέλα που βασίζονται σε πρότυπα, όπως τα vector quantisation, τα δίκτυα λειτουργιών ακτινικής βάσης (RBF), η supervised learning vector quantisation (LVQ) και οι self-organising maps (SOM), πραγματοποιούν Online εκπαίδευση, διότι βασίζονται σε (κατά προσέγγιση) στοχαστική προοδευτική τεχνική εκπαίδευσης. Οι μέθοδοι αριθμητικής βελτιστοποίησης δεύτερης τάξης και τα προηγμένα συστήματα βελτιστοποίησης μπορούν επίσης να εκπαιδευτούν Online, όπως παραλλαγές Bayes, κυρτή βελτιστοποίηση (convex optimization), μάθηση perceptron δεύτερης τάξης βασισμένη σε στατιστικά στοιχεία υψηλότερης τάξης στον αρχικό ή διπλό χώρο και Online υλοποίηση τεχνική των quasi-Newton Broyden-Fletcher-Goldfarb-Shanno. Στοχαστικά σχήματα βελτιστοποίησης μπορούν να αναπτυχθούν και για λειτουργία μη αποσυνθέσιμου κόστους. Επιπλέον, οι μέθοδοι k-nearest neighbor (k-NN) υποστηρίζουν Online εκπαίδευση λόγω του σχεδιασμού τους [11].

### 3.1.2 Incremental learning μέθοδοι

Η αυξανόμενη μάθηση (incremental learning) αναφέρεται σε στρατηγικές online εκπαίδευσης που λειτουργούν με περιορισμένους πόρους μνήμης. Αυτό αποκλείει προσεγγίσεις οι οποίες ουσιαστικά λειτουργούν με εκπαίδευση σε ομάδες δεδομένων για τη συμπερίληψη του  $M_t$  με την αποθήκευση όλων των παραδειγμάτων μέχρι το βήμα χρόνου  $t$  στη μνήμη. Αντίθετα, η αθροιστική μάθηση πρέπει να βασίζεται σε μια αναπαράσταση των ήδη υπολογισμένων εισόδων – εξόδων, όπως μια αποτελεσματική στατιστική ανάλυση των δεδομένων, ένα εναλλακτικό μοντέλο μικρής μνήμης ή μια αναπαράσταση δεδομένων με όρους τις παραμέτρους του μοντέλου. Ταυτόχρονα, πρέπει να παρέχει ακριβή αποτελέσματα για όλες τις σχετικές ρυθμίσεις, παρά τους περιορισμένους πόρους μνήμης [11].

#### Πρόκληση 2: Μετατόπιση τάσης (Concept drift)

Η αυξανόμενη μάθηση μοιράζεται αρκετές προκλήσεις με την Online μάθηση. Ένα σημαντικό πρόβλημα έγκειται στο γεγονός ότι, όταν ληφθεί υπόψη η χρονική δομή των δειγμάτων δεδομένων, μπορούν να παρατηρηθούν αλλαγές στις στατιστικές δεδομένων που εμφανίζονται με την πάροδο του χρόνου. Οι μεταβολές στην κατανομή των δεδομένων με την πάροδο του χρόνου αναφέρονται συνήθως ως έννοια τάσης. Μπορούν να διακριθούν διάφοροι τύποι μετατόπισης τάσης όπως: αλλαγές μόνο στην κατανομή εισόδου  $p(x)$ , που αναφέρεται ως εικονική μετατόπιση τάσης ή μεταβλητής μετατόπισης, μεταβολές στην ίδια την λειτουργικότητα  $p(y|x)$  που αναφέρεται ως πραγματική μετατόπιση τάσης. Επιπλέον, η μετατόπιση της έννοιας μπορεί να είναι βαθμιαία ή απότομη. Ο όρος τοπική μετατόπιση τάσης χαρακτηρίζει τις αλλαγές της στατιστικής των δεδομένων μόνο σε μια συγκεκριμένη περιοχή του χώρου δεδομένων. Ένα σημαντικό παράδειγμα είναι η προσθήκη μιας νέας κλάσης που τα χαρακτηριστικά της δεν ταιριάζουν σε καμία άλλη σε ένα πρόβλημα ταξινόμησης. Η πραγματική μετατόπιση τάσης είναι προβληματική, διότι οδηγεί σε συγκρούσεις στην ταξινόμηση, για παράδειγμα όταν εμφανίζεται μια νέα αλλά παρόμοια κατηγορία στα δεδομένα: σε κάθε περίπτωση αυτό θα έχει αντίκτυπο στην απόδοση ταξινόμησης έως ότου το μοντέλο μπορεί να προσαρμοστεί αναλόγως.

### Πρόκληση 3: Το δίλημμα σταθερότητας-ελαστικότητας

Ειδικότερα για τα θορυβώδη περιβάλλοντα ή τη μετατόπιση τάσης, μια δεύτερη πρόκληση συνίσταται στην ερώτηση πότε και πώς να προσαρμόσουμε το τρέχον μοντέλο. Μια γρήγορη ενημέρωση επιτρέπει μια γρήγορη προσαρμογή σύμφωνα με νέες πληροφορίες, αλλά οι παλιές πληροφορίες ξεχνιούνται εξίσου γρήγορα. Από την άλλη πλευρά, η προσαρμογή μπορεί να γίνει αργά, οπότε η παλαιά πληροφορία διατηρείται περισσότερο, αλλά μειώνεται η αντιδραστικότητα του συστήματος. Το δίλημμα πίσω από αυτό το εμπόδιο υποδηλώνει συνήθως το δίλημμα σταθερότητας-ελαστικότητας, που είναι ένας πολύ γνωστός περιορισμός για τα συστήματα τεχνητής και βιολογικής μάθησης. Οι τεχνικές προοδευτικής μάθησης, οι οποίες προσαρμόζουν τα μαθησιακά μοντέλα στην μετατόπιση τάσης μόνο σε εκείνες τις περιοχές του χώρου δεδομένων όπου συμβαίνει στην πραγματικότητα η μετατόπιση τάσης, προσφέρουν μερική αντιμετώπιση αυτού του προβλήματος. Πολλές μέθοδοι online μάθησης, παρά του ότι ασχολούνται με περιορισμένους πόρους, δεν είναι σε θέση να επιλύσουν αυτό το δίλημμα, καθώς εκδηλώνουν μια αποκαλούμενη καταστροφική συμπεριφορά ακόμη και όταν τα νέα δεδομένα δεν καταργούν την παλιά γνώση. Μια προσέγγιση για να αντιμετωπιστεί το δίλημμα σταθερότητας-ελαστικότητας συνίσταται στην ενίσχυση των κανόνων μάθησης με σαφείς στρατηγικές, πότε και πώς να μαθαίνουμε. Αυτός είναι ο πυρήνας των δημοφιλών αυξητικών μοντέλων όπως τα δίκτυα ART ή οι στρατηγικές για την μετατόπιση της τάσης όπως ο ταξινομητής (Just in time) JIT ή οι υβριδικές μέθοδοι Online / offline. Ένα σημαντικό συστατικό αυτών των στρατηγικών είναι η εκτίμηση της εμπιστοσύνης της πραγματικής πρόβλεψης του μοντέλου, όπως είναι οι στατιστικές δοκιμές, τα αποδοτικά υποκατάστατα ή κάποια έννοια της αυτοαξιολόγησης. Τέτοιες τεχνικές μπορούν να ενισχυθούν για να σχηματίσουν πολύπλοκα σχήματα δια δραστικής ή σταδιακής μάθησης [12].

### Πρόκληση 4: Προσαρμοσμένη πολυπλοκότητα μοντέλου και μετα-παραμέτροι

Για την αυξητική μάθηση, η πολυπλοκότητα του μοντέλου πρέπει να είναι μεταβλητή, δεδομένου ότι είναι αδύνατο να εκτιμηθεί εκ των προτέρων η πολυπλοκότητα του μοντέλου εάν τα δεδομένα είναι άγνωστα. Ανάλογα με την εμφάνιση γεγονότων σχεδίασης, μπορεί να καταστεί αναγκαία μια αυξημένη πολυπλοκότητα του μοντέλου. Από την άλλη πλευρά, η συνολική πολυπλοκότητα του μοντέλου περιορίζεται συνήθως από τον περιορισμό των διαθέσιμων πόρων. Αυτό απαιτεί την έξυπνη ανακατανομή των πόρων κάθε φορά που επιτυγχάνεται αυτό το όριο. Αρκετές προσεγγίσεις προτείνουν έξυπνες μεθόδους προσαρμογής για την πολυπλοκότητα του μοντέλου, όπως είναι οι αυξητικές αρχιτεκτονικές, η αυτο-προσαρμογή του αριθμού των βασικών μονάδων σε ακραίες μηχανές εκπαίδευσης ή πρωτότυπα μοντέλα, βασικής λειτουργίας διαδοχικής επιλογή για μια επαρκώς ισχυρή αναπαράσταση δεδομένων, ή αυτοσυντονιστικοί αριθμοί συμπλεγμάτων στη μάθηση χωρίς επίβλεψη. Τέτοιες στρατηγικές μπορούν να τοποθετηθούν στο γενικότερο πλαίσιο των αυτοεξελιγμένων συστημάτων. Μια αυξανόμενη πολυπλοκότητα του μοντέλου δεν είναι υποχρεωτική μόνο όταν παρατηρείται μια μετατόπιση τάσης, επομένως και υπάρχει μια πιθανά μεταβαλλόμενη πολυπλοκότητα του μοντέλου, αλλά μπορεί επίσης να επιταχύνει δραματικά την εκμάθηση σε σενάρια εκπαίδευσης με ομαδοποίηση δεδομένων, καθώς κάνει συχνά την κουραστική επιλογή μοντέλου περιττή [11].

Στην εκμάθηση παρτίδων, καθορίζεται όχι μόνο η πολυπλοκότητα του μοντέλου, αλλά και οι ουσιαστικοί μετα-παραμέτροι όπως ο ρυθμός εκμάθησης και η ισχύς της κανονικοποίησης πριν από την εκπαίδευση. Συχνά, η χρονοβόρα επικύρωση δεδομένων χρησιμοποιείται στην εκπαίδευση με ομάδες δεδομένων, όπου υπάρχουν τα πρώτα υποσχόμενα αποτελέσματα για τον τρόπο με τον οποίο μπορεί να γίνει αυτοματοποίηση αυτής της διαδικασίας. Ωστόσο, αυτά δεν είναι κατάλληλα για σενάρια προοδευτικής εκπαίδευσης: Η μετατόπιση της τάσης μετατρέπει τις κρίσιμες μετα-παραμέτρους, όπως ο ρυθμός εκμάθησης σε παραμέτρους μοντέλου, καθώς η επιλογή τους πρέπει

να προσαρμόζεται σύμφωνα με τα (μεταβαλλόμενα) δεδομένα. Λόγω αυτού του γεγονότος, οι αυξητικές τεχνικές βασίζονται συχνά σε μοντέλα με λίγες και ισχυρές μετα-παραμέτρους (όπως σύνολα) ή χρησιμοποιούν μετα-ευριστικές μεθόδους για την προσαρμογή αυτών των ποσοτήτων κατά τη διάρκεια της εκπαίδευσης.

#### Πρόκληση 5: Αποτελεσματικά μοντέλα μνήμης

Λόγω των περιορισμένων πόρων τους, τα μοντέλα αυξητικής μάθησης πρέπει να αποθηκεύουν τις πληροφορίες που παρέχονται από τα παρατηρούμενα δεδομένα σε συμπαγή μορφή. Αυτό μπορεί να γίνει μέσω κατάλληλων μεταβλητών συστήματος (όπως το σφάλμα ταξινόμησης για τα μοντέλα explicit drift detection), μέσω των παραμέτρων του μοντέλου σε σιωπηρή μορφή (όπως πρωτότυπα για μοντέλα με βάση την απόσταση) ή μέσω μίας σαφής μνήμης μοντέλο. Ορισμένα μοντέλα μηχανικής μάθησης προσφέρουν μια απρόσκοπτη μεταφορά παραμέτρων μοντέλου και μοντέλων μνήμης, όπως πρότυπα ή μοντέλα με βάση τα υποδείγματα, τα οποία αποθηκεύουν τις πληροφορίες με τη μορφή τυπικών παραδειγμάτων. Τα μοντέλα σαφής μνήμης μπορούν να βασίζονται σε ένα πεπερασμένο σύνολο χαρακτηριστικών παραδειγμάτων εκπαίδευσης ή να αντιπροσωπεύουν τη μνήμη με τη μορφή ενός παραμετρικού μοντέλου. Και για τις δύο ρυθμίσεις, ο προσεκτικός σχεδιασμός της προσαρμογής της μνήμης είναι κρίσιμος, καθώς αντικατοπτρίζει άμεσα το δίλημμα σταθερότητας-ελαστικότητας [11].

#### Πρόκληση 6: Μοντέλο συγκριτικής αξιολόγησης

Υπάρχουν δύο θεμελιώδεις διαφορετικές δυνατότητες για να εκτιμηθεί η απόδοση των αλγορίθμων προοδευτικής μάθησης [11]:

(1) Incremental εναντίων non-incremental: Ειδικότερα, ο στόχος της μάθησης συνίσταται στο συμπέρασμα της σταθερής κατανομής  $p(y | x)$  για τυπικά δεδομένα που χαρακτηρίζονται από  $p(x)$ . Αυτές οι παράμετροι εμφανίζονται π.χ. κάθε φορά που χρησιμοποιούνται αυξητικοί αλγόριθμοι για μεγάλα σύνολα δεδομένων, όπου ανταγωνίζονται συχνά παραλληλισμένους αλγόριθμους με εκπαίδευση που βασίζεται σε ομάδες δεδομένων. Σε τέτοιες παραμέτρους, η μέθοδος επιλογής αξιολογεί την ακρίβεια ταξινόμησης του τελικού μοντέλου  $M_t$  σε ένα σετ δοκιμών ή σε έναν διασταυρούμενο έλεγχο. Ενώ η προοδευτική μάθηση πρέπει να επιτύχει αποτελέσματα στο ίδιο εύρος με τις παραλλαγές των ομάδων δεδομένων, πρέπει να λάβουμε υπόψη ότι εκπαιδεύονται με περιορισμένες γνώσεις λόγω της ροής των δεδομένων τους. Έχει αποδειχθεί, για παράδειγμα, ότι οι αυξητικοί αλγόριθμοι ομαδοποίησης δεν μπορούν να επιτύχουν την ίδια ακρίβεια με τους αλγορίθμους που εκπαιδεύονται με ομάδες δεδομένων αν είναι περιορισμένες από την άποψη των πόρων τους.

(2) Incremental εναντίων non-incremental: Όταν αντιμετωπίζεται η μετατόπιση τάσης, μπορεί να μας ενδιαφέρουν διάφορες συναρτήσεις κόστους. Η εικονική μετατόπιση τάσης στοχεύει στο συμπέρασμα ενός σταθερού μοντέλου  $p(y|x)$  με πιθανότητα παρασυρόμενης  $p(x)$  για τα δεδομένα εισόδου. Ενδιαφέρον είναι η έλλειψη αξιοπιστίας του μοντέλου όταν αξιολογείται σε δεδομένα δοκιμών που ακολουθούν ενδεχομένως διαστρεβλωμένη κατανομή. Τέτοιες ρυθμίσεις μπορούν εύκολα να παραχθούν π.χ. με την επιβολή μη ισορροπημένων ετικετών για δεδομένα δοκιμών και εκπαίδευσης. Κάθε φορά που υπάρχει πραγματική μετατόπιση τάσης, η online συμπεριφορά του σφάλματος ταξινόμησης  $||M_t(x_t + 1) - y_t + 1||$  για το επόμενο σημείο δεδομένων είναι συνήθως η μέθοδος επιλογής. κατά συνέπεια, ένας απλός μέσος όρος τέτοιων σφαλμάτων μπορεί να συνοδεύεται από λεπτομερή επιθεώρηση του συνολικού σχήματος του Online σφάλματος, καθώς παρέχει μια εικόνα των ρυθμών σύγκλισης.

## 4 Νευρωτικά δίκτυα

### 4.1 Εισαγωγή στα Τεχνητά Νευρωνικά Δίκτυα

Τα Τεχνητά Νευρωνικά Δίκτυα (ANNs) είναι εργαλεία υπολογιστικής μοντελοποίησης που βρίσκουν εκτεταμένη αποδοχή σε πολλούς κλάδους για τη μοντελοποίηση πολύπλοκων πραγματικών προβλημάτων. Τα ANNs μπορούν να οριστούν ως δομές που αποτελούνται από πυκνά διασυνδεδεμένα προσαρμοστικά στοιχεία απλής επεξεργασίας (τεχνητοί νευρώνες ή κόμβοι) που είναι σε θέση να εκτελούν μαζικά παράλληλους υπολογισμούς για την επεξεργασία δεδομένων και την εκπροσώπηση γνώσης. Παρόλο που τα ANNs είναι δραστικές αφαιρέσεις των βιολογικών ομολόγων, η ιδέα των ANNs δεν είναι να αναπαράγει τη λειτουργία των βιολογικών συστημάτων, αλλά να κάνει χρήση της λειτουργικότητας των βιολογικών δικτύων για την επίλυση σύνθετων προβλημάτων. Η ελκυστικότητα των ANN προέρχεται από τα αξιοσημείωτα χαρακτηριστικά επεξεργασίας της πληροφορίας του βιολογικού συστήματος όπως [13]:

- a) Μη γραμμικότητα: ένας τεχνητός νευρώνας μπορεί να είναι είτε γραμμικός, είτε μη γραμμικός. Ένα ΤΝΔ που αποτελείται από διασυνδεδεμένους μη γραμμικούς νευρώνες είναι μη γραμμικό. Αυτή η ιδιότητα είναι πολύ σημαντική, κυρίως αν ο υποκείμενος φυσικός μηχανισμός που παράγει το σήμα εισόδου είναι εκ φύσεως μη γραμμικός.
- b) Αντιστοίχιση εισόδου – εξόδου: ένα δημοφιλές παράδειγμα μάθησης, η μάθηση με εκπαιδευτή ή επιβλεπόμενη μάθηση, συνιστάται στην τροποποίηση των συναπτικών βαρών ενός νευρωνικού δικτύου εφαρμόζοντας ένα σύνολο παραδειγμάτων εκπαίδευσης. Κάθε παράδειγμα αποτελείται από ένα μοναδικό σήμα εισόδου και μια αντίστοιχη επιθυμητή απόκριση. Τα συναπτικά βάρη τροποποιούνται έτσι ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της επιθυμητής απόκρισης και της πραγματικής απόκρισης του δικτύου. Τότε το δίκτυο φτάνει σε μια ευσταθή κατάσταση όπου δεν υπάρχουν άλλες αλλαγές βαρών. Αν και τα ΤΝΔ δεν είναι τα μόνα συστήματα με ικανότητα μάθησης μέσω παραδειγμάτων, εντούτοις διακρίνονται για την ικανότητά τους να οργανώνουν την πληροφορία των δεδομένων εισόδου σε χρήσιμες μορφές. Αυτές οι μορφές αποτελούν στην ουσία ένα μοντέλο που αναπαριστά τη σχέση που ισχύει μεταξύ των δεδομένων εισόδου και εξόδου.
- c) Παράλληλος τρόπος λειτουργίας: Τα νευρωνικά δίκτυα λειτουργούν με παράλληλο τρόπο γιατί μια εργασία μοιράζεται στα διάφορα τμήματα του δικτύου, δηλαδή σε όλους τους επιμέρους νευρώνες. Έτσι τα νευρωνικά δίκτυα είναι συστήματα παράλληλων καταναμημένων διεργασιών. Αυτό παρέχει μεγάλες ταχύτητες γιατί είναι σαν να έχουμε ταυτόχρονα πολλούς επεξεργαστές.
- d) Προσαρμοστικότητα: Τα νευρωνικά δίκτυα έχουν την δυνατότητα να προσαρμόζουν τα συναπτικά τους βάρη ανάλογα με τις μεταβολές που γίνονται στο περιβάλλον τους. Ένα ΤΝΔ εκπαιδευμένο να λειτουργεί σε συγκεκριμένο περιβάλλον, μπορεί εύκολα να επανεκπαιδευτεί ώστε να μπορεί να χειρίζεται τις μεταβολές στο νέο περιβάλλον λειτουργίας του.
- e) Ανοχή σε σφάλμα: Τα νευρωνικά δίκτυα είναι ανεκτικά σε μικρές αλλαγές στην είσοδό τους και σε περίπτωση που είναι υλοποιημένο σε hardware είναι ανθεκτικά σε βλάβες. Υπό την έννοια ότι σε περίπτωση που νευρώνας ή σύνδεση πάθουν βλάβη η ποιότητα της εξόδου μειώνεται σταδιακά, καθώς η πληροφορία που αποθηκεύεται στο δίκτυο είναι καταναμημένη σε όλη την δομή του. Συνεπώς το μέγεθος του σφάλματος είναι ανάλογο του ποσού των κατεστραμμένων συνδέσεων.
- f) Ομοιομορφία ανάλυσης και σχεδίασης: Τα νευρωνικά δίκτυα απολαμβάνουν καθολικής αποδοχής ως επεξεργαστές πληροφοριών, υπό την έννοια ότι χρησιμοποιείται η ίδια σημειογραφία σε όλα τα πεδία εφαρμογής τους. Οι νευρώνες αντιπροσωπεύουν ένα

συστατικό κοινό σε όλα τα νευρωνικά δίκτυα και αυτό καθιστά εφικτή τη χρήση των ίδιων θεωριών και αλγορίθμων μάθησης σε διαφορετικές εφαρμογές των νευρωνικών δικτύων.

- g) Αναλογία με την νευροφυσιολογία του εγκεφάλου: Η σχεδίαση ενός νευρωνικού δικτύου δανείζεται στοιχεία από τη λειτουργία του ανθρώπινου εγκεφάλου, ο οποίος είναι η ζωντανή απόδειξη ότι η εύρωστη, παράλληλη επεξεργασία δεν είναι μόνο φυσικά εφικτή, αλλά επίσης γρήγορη και ισχυρή. Τα ΤΝΔ, όπως και τα βιολογικά, έχουν μεγάλη ανοχή σε δομικά σφάλματα. Αυτό σημαίνει ότι η κακή λειτουργία ή η καταστροφή ενός νευρώνα ή κάποιων συνδέσεων δεν είναι ικανή να διαταράξει σημαντικά τη λειτουργία τους καθώς η πληροφορία που εσωκλείουν δεν είναι εντοπισμένη σε συγκεκριμένο σημείο αλλά διάχυτη σε όλο το δίκτυο. Γενικά, το μέγεθος σφάλματος λόγω δομικών αστοχιών είναι ανάλογο του ποσοστού των κατεστραμμένων συνδέσεων.
- h) Η δυνατότητα θεώρησής τους ως κατανεμημένη μνήμη (Distributed memory) και ως μνήμη συσχέτισης (Associative memory): Ο χαρακτηρισμός των ΤΝΔ ως κατανεμημένη μνήμη, πηγάζει από το ότι η κωδικοποίηση που δημιουργούν είναι κατανεμημένη σε όλα τα βάρη της συνδεσμολογίας τους. Για τον ίδιο λόγο τα ΤΝΔ χαρακτηρίζονται και ως μνήμες συσχέτισης. Μια μνήμη συσχέτισης δεν αποθηκεύει πληροφορία με τον παραδοσιακό τρόπο αλλά μέσω κατάλληλων συσχετίσεων που δημιουργεί από τα δεδομένα εκπαίδευσης. Η ανάκληση της πληροφορίας γίνεται με βάση το περιεχόμενο και όχι τη διεύθυνση, όπως δηλαδή συμβαίνει και με τον ανθρώπινο εγκέφαλο. Η παραπάνω οργάνωση κάνει ορισμένα είδη ΤΝΔ να είναι πολύ ανεκτικά σε μικρές αλλαγές στα σήματα εισόδου, δηλαδή να είναι σε θέση να παράγουν τη σωστή έξοδο ακόμη και αν τα δεδομένα εισόδου είναι λίγο διαφορετικά (για παράδειγμα, λόγω θορύβου) ή και ελλιπή.
- i) Η ικανότητά τους για αναγνώριση προτύπων (pattern recognition): Τέλος, τα ΤΝΔ έχουν εξαιρετική ικανότητα αναγνώρισης προτύπων καθώς δεν επηρεάζονται από ελλιπή ή και με θόρυβο δεδομένα. Από τη στιγμή που ένα ΤΝΔ εκπαιδεύεται στο να αναγνωρίζει συνθήκες και καταστάσεις, απαιτείται ένας μόνο κύκλος λειτουργίας τους για να προσδιορίσουν μια συγκεκριμένη κατάσταση. Η τελευταία ιδιότητα κάνει ένα ΤΝΔ ιδανικό για χρήση σε αυτοματισμούς που θα λειτουργήσουν σε αντίξοες συνθήκες.


Ο βασικός στόχος των υπολογισμών που βασίζονται στο ANN είναι να αναπτυχθούν μαθηματικοί αλγόριθμοι που θα επιτρέψουν στην ANN με τη μίμηση του ανθρώπινου εγκεφάλου την επεξεργασία πληροφοριών και την απόκτηση γνώσεων. Τα μοντέλα που βασίζονται στο ANN είναι εμπειρικά, αλλά μπορούν να παράσχουν πρακτικά ακριβείς λύσεις για ακριβή ή ανακριβώς διατυπωμένα προβλήματα και για φαινόμενα που κατανοούνται μόνο μέσω πειραματικών δεδομένων και παρατηρήσεων. Στη μικροβιολογία, τα ANNs έχουν χρησιμοποιηθεί σε ποικίλες εφαρμογές που κυμαίνονται από τη μοντελοποίηση, την ταξινόμηση, την αναγνώριση προτύπων και την ανάλυση πολλών μεταβλητών δεδομένων. Οι εφαρμογές δειγμάτων περιλαμβάνουν (i) την ερμηνεία της φασματομετρίας πυρόλυσης μάζας, GC και HPLC, (ii) αναγνώριση προτύπου DNA, RNA, πρωτεϊνικής δομής και μικροσκοπικών εικόνων, (iii) πρόβλεψη μικροβιακής ανάπτυξης βιομάζας και (iv) ταυτοποίηση μικροοργανισμών και μορίων [14].

## 4.2 ANN και βιολογικά νευρωνικά δίκτυα

Ο βιολογικός νευρώνας είναι το βασικό δομικό στοιχείο του νευρικού συστήματος, η λειτουργία του θα παρουσιαστεί για την κατανόηση της λειτουργίας των τεχνητών νευρώνων και της αναλογίας μεταξύ των ANN και των βιολογικών δικτύων.

#### 4.2.1 Βιολογικός νευρώνας


Το ανθρώπινο νευρικό σύστημα αποτελείται από δισεκατομμύρια νευρώνες διαφόρων τύπων και μήκους που σχετίζονται με τη θέση τους στο σώμα. Η παρακάτω εικόνα δείχνει ένα σχηματικό ενός υπεραπλουστευμένου βιολογικού νευρώνα με τρεις κύριες λειτουργικές μονάδες δενδρίτες, κυτταρικό σώμα και άξονα [14].



Εικόνα 3 - Βασικός βιολογικός νευρώνας

Το σώμα του κυττάρου έχει έναν πυρήνα που περιέχει πληροφορίες για τα χαρακτηριστικά κληρονομικότητας και ένα πλάσμα που κρατά τον μοριακό εξοπλισμό που χρησιμοποιείται για την παραγωγή του υλικού που χρειάζεται ο νευρώνας. Οι δενδρίτες λαμβάνουν σήματα από άλλους νευρώνες και τους μεταφέρουν στο σώμα των κυττάρων. Η συνολική περιοχή λήψης των δενδριτών ενός τυπικού νευρώνα είναι περίπου 0,25 mm. Ο άξονας, ο οποίος διακλαδίζεται, λαμβάνει σήματα από το κυτταρικό σώμα και τα μεταφέρει διαμέσου της συνάψεως (ένα μικροσκοπικό κενό) στους δενδρίτες των γειτονικών νευρώνων [14]. Μία σχηματική απεικόνιση της μεταφοράς σήματος μεταξύ δύο νευρώνων διαμέσου της συνάψεως φαίνεται στο παρακάτω σχήμα.






Εικόνα 4 - Μεταφορά σήματος διαμέσου της συνάψεως

Μια ώθηση, με τη μορφή ενός ηλεκτρικού σήματος, ταξιδεύει μέσα στους δενδρίτες και μέσω του κυτταρικού σώματος προς την προ-συναπτική μεμβράνη της συνάψεως. Κατά την άφιξη στη μεμβράνη, ένας νευροδιαβιβαστής (χημικό) απελευθερώνεται από τα κυστίδια σε ποσότητες ανάλογες με τη δύναμη του εισερχόμενου σήματος. Ο νευροδιαβιβαστής διαχέεται μέσα στο συναπτικό χάσμα προς την μετασυναπτική μεμβράνη και τελικά στους δενδρίτες των γειτονικών νευρώνων, αναγκάζοντάς τους (ανάλογα με το κατώφλι του νευρώνα λήψης) να παράγουν ένα νέο ηλεκτρικό σήμα. Το παραγόμενο σήμα περνά διαμέσου του δεύτερου νευρώνα με τρόπο πανομοιότυπο με αυτόν που μόλις περιεγράφηκε. Η ποσότητα σήματος που διέρχεται από ένα νευρώνα λήψης εξαρτάται από την ένταση του σήματος που προέρχεται από κάθε νευρώνας τροφοδοσίας, τις συναπτικές τους αντοχές και το όριο του νευρώνα που λαμβάνει. Επειδή ένας νευρώνας έχει έναν μεγάλο αριθμό συνόψεων δενδριτών, μπορεί να λαμβάνει και να μεταφέρει πολλά σήματα ταυτόχρονα. Αυτά τα σήματα μπορούν είτε να βοηθήσουν (διεγείρουν) είτε να εμποδίσουν την πυροδότηση του νευρώνα [13].

#### 4.2.2 Αναλογία

Η αναλογία μεταξύ του τεχνητού νευρώνα και του βιολογικού νευρώνα είναι ότι οι συνδέσεις μεταξύ των κόμβων αντιπροσωπεύουν τους άξονες και τους δενδρίτες, τα βάρη σύνδεσης αντιπροσωπεύουν τις συνάψεις και το κατώφλι προσεγγίζει τη δραστηριότητα στο σώμα. Η παρακάτω εικόνα απεικονίζει τους βιολογικούς νευρώνες με διάφορα σήματα έντασης  $x$  και συνοπτική ισχύ  $w$  που τροφοδοτούν έναν νευρώνα με ένα κατώτατο όριο  $b$  και το ισοδύναμο σύστημα τεχνητών νευρώνων.



Εικόνα 5 - Σύγκριση βιολογικού νευρωνικού δικτύου με τεχνητού

Τόσο το βιολογικό δίκτυο όσο και το ANN μαθαίνουν με τη σταδιακή προσαρμογή των μεγεθών των δυνατοτήτων των βαρών ή των συνάψεων.

#### 4.2.3 Τεχνητός νευρώνας

Τα βασικά ευρήματα από τη λειτουργία των βιολογικών νευρώνων επέτρεψαν σε πρώιμους ερευνητές να μοντελοποιήσουν τη λειτουργία απλών τεχνητών νευρώνων. Ένας τεχνητός νευρώνας επεξεργασίας λαμβάνει εισροές ως ερεθίσματα από το περιβάλλον και τους συνδυάζει με έναν ειδικό τρόπο για να σχηματίσει μια «καθαρή» είσοδο ( $\xi$ ), περνάει από μια γραμμική πύλη κατωφλίου και μεταδίδει το σήμα (εξόδου,  $y$ ) προς τα εμπρός σε ένα άλλο νευρώνα ή στο περιβάλλον, όπως φαίνεται στην προηγούμενη εικόνα. Μόνο όταν υπερβαίνει το όριο του κατωφλίου του νευρώνα (που ονομάζεται επίσης πόλωση,  $\beta$ ), θα ενεργοποιηθεί η έξοδος των νευρώνων. Συνήθως, η δυναμική των νευρώνων υποτίθεται για τον υπολογισμό του  $\xi$ . Η καθαρή είσοδος υπολογίζεται ως το αποτέλεσμα των σημάτων εισόδου ( $x$ ) που προσβάλλουν τον νευρώνα και τις δυνάμεις τους ( $w$ ). Για  $n$  σήματα, η λειτουργία νευρώνα perceptron εκφράζεται ως

$$y = \begin{cases} 1, & \text{εάν } \sum_{i=1}^n w_i x_i \geq \beta \\ 0, & \text{εάν } \sum_{i=1}^n w_i x_i < \beta \end{cases}$$

με 1 που δείχνει 'on' και 0 δείχνει 'off' ή κλάση A και B, αντίστοιχα, για την επίλυση προβλημάτων ταξινόμησης. Τα θετικά βάρη σύνδεσης ( $w_i > 0$ ) ενισχύουν το καθαρό σήμα ( $\xi$ ) και διεγείρουν τον νευρώνα και ο σύνδεσμος καλείται διεγερμένος, ενώ τα αρνητικά βάρη μειώνουν το  $\xi$  και αναστέλλουν τη δραστηριότητα των νευρώνων και ο σύνδεσμος ονομάζεται ανασταλτικός. Το

σύστημα αποτελείται από έναν τεχνητό νευρώνα και οι εισόδους όπως φαίνεται στο προηγούμενο σχήμα ονομάζεται Perceptron και καθορίζει μια χαρτογράφηση μεταξύ της δραστηριότητας των εισόδων (ερεθίσματα) και του σήματος εξόδου. Το κατώφλι του νευρώνα μπορεί να θεωρηθεί ως πρόσθετος κόμβος εισόδου, του οποίου η τιμή είναι πάντα κοινή (πχ.,  $X=1$ ) και το βάρος σύνδεσης του είναι ίσο με  $b$  [14].

#### 4.2.4 Βιολογικό έναντι τεχνητού δικτύου

Κεντρικό σημείο στο βιολογικό μας νευρικό δίκτυο είναι ο εγκεφαλικός φλοιός, ο οποίος είναι ένα επίπεδο φύλλο μαζικά διασυνδεδεμένων νευρώνων πάχους 2-3 mm με επιφανειακό εμβαδόν περίπου 2200 cm<sup>2</sup> που περιέχει 10<sup>11</sup> περίπου νευρώνες. Κάθε νευρώνας συνδέεται με 1.000 έως 10.000 άλλους νευρώνες, κάνοντας περίπου 10<sup>14</sup> έως 10<sup>15</sup> διασυνδέσεις. Αντίθετα, τα ANNs (π.χ. backpropagation) κυμαίνονται συνήθως από 10 έως και 10.000 νευρώνες για τα πιο εξελιγμένα δίκτυα που εφαρμόζονται σε υπολογιστή, με πυκνότητα σύνδεσης που κυμαίνεται από πέντε έως 100 συνδέσεις ανά νευρώνα. Αναφορικά με τη λειτουργία και την εσωτερική τους δομή, τα ANNs θεωρούνται ομοιογενή και συχνά λειτουργούν αιτιοκρατικά, ενώ αυτά του ανθρώπινου φλοιού είναι εξαιρετικά ετερογενή και λειτουργούν με ένα σύνθετο ντετερμινιστικό και στοχαστικό μείγμα. Όσον αφορά τη λειτουργικότητα, δεν προκαλεί έκπληξη το γεγονός ότι τα ANNs συγκρίνονται, αν και κατά προσέγγιση, με βιολογικά δίκτυα καθώς αναπτύσσονται για να μιμούνται τις υπολογιστικές ιδιότητες του εγκεφάλου, όπως η προσαρμοστικότητα, ο θόρυβος (δεδομένα) και την ανοχή σφάλματος (αποκομμένοι νευρώνες) [13].

#### 4.2.5 Μάθηση

Η ικανότητα μάθησης είναι ένα ιδιαίτερο χαρακτηριστικό που σχετίζεται με έξυπνα συστήματα, βιολογικά ή όχι. Σε τεχνητά συστήματα, η μάθηση θεωρείται ως η διαδικασία ενημέρωσης της εσωτερικής αναπαράστασης του συστήματος ως απάντηση σε εξωτερικά ερεθίσματα, ώστε να μπορεί να εκτελεί ένα συγκεκριμένο έργο. Αυτό περιλαμβάνει την τροποποίηση της αρχιτεκτονικής του δικτύου, η οποία περιλαμβάνει την προσαρμογή των βαρών των συνδέσεων, τη δημιουργία ή την μείωση ορισμένων συνδέσεων σύνδεσης ή / και την αλλαγή των κανόνων ενεργοποίησης των επιμέρους νευρώνων. Η ANN μάθηση εκτελείται επαναληπτικά καθώς το δίκτυο παρουσιάζεται με παραδείγματα εκπαίδευσης, παρόμοια με τον τρόπο που μαθαίνουμε από την εμπειρία. Ένα σύστημα βασισμένο σε ANN λέγεται ότι έχει μάθει αν μπορεί να χειρίζεται ασαφείς, θορυβώδεις και πιθανοτικές πληροφορίες χωρίς αξιοσημείωτη δυσμενή επίδραση στην ποιότητα εξόδου του και να γενικεύει από την υπάρχουσα γνώση σε άγνωστα δεδομένα.

### 4.3 Ιστορική αναδρομή

Τα Νευρωνικά Δίκτυα είναι σχετικά μια νέα περιοχή και δεν υπάρχει ουσιαστικά μεγάλη προϊστορία, όπως σε άλλες επιστήμες. Ξεκίνησε σε διεθνές επίπεδο κατά τις τελευταίες δεκαετίες, αλλά η μεγάλη ώθηση σε αυτά δόθηκε μετά το 1980. Σ' αυτό βοήθησε η μεγάλη ανάπτυξη του υλικού/λογισμικού των Η/Υ αλλά και η ανάπτυξη νέων αλγορίθμων εκπαίδευσης. Το πρώτο μοντέλο Νευρωνικού Δικτύου το οποίο προτείνει ότι οι νευρώνες είναι η βασική μονάδα του δικτύου, παρουσιάστηκε το 1943 από τους McCulloch και Pitts. Στην εργασία τους παρουσίασαν για πρώτη φορά την ιδέα ότι ένα Νευρωνικό Δίκτυο αποτελείται από ένα σύνολο ενός μεγάλου αριθμού νευρώνων και έδειξαν πώς θα μπορούσαν να λειτουργούν οι νευρώνες με τις διασυνδέσεις τους. Αυτή θεωρείται η πρώτη εικόνα ενός Νευρωνικού Δικτύου. Το 1947, οι ίδιοι συγγραφείς, προχώρησαν σε ένα πιο εξελιγμένο πρότυπο για την αναγνώριση σχημάτων. Σ' αυτό το πρότυπο, ο νευρώνας θεωρείται ότι μπορεί να έχει μόνο δύο καταστάσεις, οι οποίες είναι ότι είτε πυροδοτεί ή βρίσκεται σε ηρεμία. Μπορεί να έχει πολλές εισόδους αλλά δίνει μία μόνο έξοδο. Οι έξοδοι από διαφορετικούς νευρώνες δεν επιτρέπεται να ενώνονται, αλλά πρέπει υποχρεωτικά να οδηγούν σε


είσοδο άλλου νευρώνα. Οι απολήξεις των νευρώνων είναι δύο ειδών: διεγερτικές και ανασταλτικές. Όταν ο νευρώνας πυροδοτεί, στέλνει ένα παλμό. Οι λειτουργίες αυτές γίνονται πάντα σε διακριτό χρόνο και υποτίθεται ότι όλοι οι νευρώνες αποκρίνονται ταυτόχρονα, δηλαδή το σύστημα δρα συγχρονισμένα. Τα δίκτυα McCulloch-Pitts προσπαθούν να εξηγήσουν για πρώτη φορά πώς δουλεύει η μνήμη. Θεωρούν ότι ένας πιθανός μηχανισμός μνήμης μπορεί να είναι η ύπαρξη κλειστών διαδρομών του σήματος μέσα στο δίκτυο. Έτσι, μια ίνα ενώνει την έξοδο ενός κυττάρου με το σημείο εισόδου στο ίδιο κύτταρο, δημιουργώντας έναν μηχανισμό ανάδρασης (feedback). 11 Τις εργασίες των McCulloch-Pitts χρησιμοποίησε λίγα χρόνια αργότερα ο J. Von Neumann ως παράδειγμα για υπολογιστικές μηχανές και τότε έγιναν και οι πρώτες προσπάθειες άντλησης πληροφοριών από τα βιολογικά δίκτυα και δημιουργίας των πρώτων τεχνητών δικτύων. Το 1949 ο D. Hebb με το βιβλίο του «The organization of behavior», εισάγει τον κανόνα μάθησης του Hebb. Το μοντέλο του Hebb έχει ως κεντρική ιδέα τις συνδέσεις μεταξύ μονάδων του συστήματος, δηλαδή τους νευρώνες. Ο κανόνας αυτός λέει ότι κάθε φορά που το δίκτυο χρησιμοποιεί τις νευρωνικές του συνδέσεις, οι συνδέσεις αυτές ενισχύονται και το δίκτυο πλησιάζει περισσότερο στο να μάθει το πρότυπο το οποίο παρουσιάζεται. Το μοντέλο του αισθητήρα (Perceptron) παρουσιάστηκε για πρώτη φορά το 1957 από τον F. Rosenblatt, ο οποίος αρχικά έφτιαξε το πρώτο δίκτυο με υλικό (hardware) που μπορούσε να κάνει πολλές και διάφορες εργασίες. Είναι ένα πολύ απλό μοντέλο με δύο επίπεδα, της εισόδου και της εξόδου, όπου το σήμα προχωρά μονοδρομικά από την είσοδο στην έξοδο. Στο βιβλίο «Perceptrons» των Minsky και Papert γίνεται μια εκτίμηση της χρησιμότητας του προτύπου αυτού, παρουσιάζονται όμως και οι περιορισμοί του. Την ίδια περίπου εποχή με την ανάπτυξη του Perceptron, οι Widrow και Hoff ανέπτυξαν το 1959 δύο νέα μοντέλα το Adaline και το Madaline. Αυτά τα δύο μοντέλα ήταν από τα πρώτα που χρησιμοποιήθηκαν επιτυχώς σε πρακτικά προβλήματα: Χρησιμοποιήθηκαν ως φίλτρα για να εξαλείψουν την ηχώ σε τηλεφωνικές γραμμές. Το 1982 ο Hopfield έδωσε μεγάλη ώθηση στην ανάπτυξη των Νευρωνικών Δικτύων. Σε μια εργασία του απέδειξε με αυστηρά μαθηματική απόδειξη πώς ένα Νευρωνικό Δίκτυο μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος και επίσης πώς μπορεί να επανακτήσει όλη την πληροφορία ενός συστήματος έστω και αν του δοθούν μερικά μόνο τμήματα και όχι ολόκληρο το σύστημα. Ένα επόμενο σημαντικό βήμα ήταν η πρόοδος στην διαδικασία εκπαίδευσης των δικτύων όταν επινοήθηκε ο κανόνας της διόρθωσης του σφάλματος (error correction learning). Κατά την εκπαίδευση ενός δικτύου, σε όποια κατάσταση και αν βρίσκεται αυτό σε μια δεδομένη στιγμή, σημασία έχει η απόκλιση που δίνει στην έξοδό του το δίκτυο από την αναμενόμενη τιμή ή τον στόχο που έχουμε θέσει. Αυτή η απόκλιση είναι το σφάλμα που παράγει το δίκτυο την δεδομένη στιγμή. Το σφάλμα ενεργοποιεί ένα μηχανισμό ελέγχου ώστε να επιφέρει μια σειρά από διορθωτικές αλλαγές στα βάρη  $w$  των νευρώνων [12]. Το 1986 δημοσιεύεται ένα άλλο σημαντικό έργο από τους McClelland και Rumelhart, το «Parallel Distributed Processing», στο οποίο παρουσιάζεται η ιδέα πώς ένα Νευρωνικό Δίκτυο μπορεί να χρησιμοποιηθεί ως παράλληλος επεξεργαστής. Το έργο αυτό επιτρέπει την ύπαρξη και άλλων επιπέδων νευρώνων, εκτός από την είσοδο και την έξοδο, που αποτελούν την 12 εσωτερική δομή του δικτύου. Προτείνουν μία νέα διαδικασία εκπαίδευσης, την μέθοδο της οπισθοδιάδοσης (back-propagation) η οποία είναι σήμερα η πιο χρήσιμη τεχνική εκπαίδευσης δικτύων [5]. Από το 1985 και μετά αρχίζουν τα πρώτα συνέδρια που είναι αφιερωμένα αποκλειστικά σε Νευρωνικά Δίκτυα, από την American Physical Society και από την IEEE. Ταυτόχρονα δημιουργούνται ειδικές επαγγελματικές εταιρίες Νευρωνικών Δικτύων με χιλιάδες μέλη.

#### 4.4 Προβλήματα πρόκλησης

Γενικά, τα ANNs είναι πολύ ισχυρά και συχνά υπερέρχουν από άλλα υπολογιστικά εργαλεία για την επίλυση διαφόρων προβλημάτων από τις επτά κατηγορίες που ακολουθούν [14].

### 1) Κατηγοριοποίηση (Classification)

Η κατηγοριοποίηση των δεδομένων ασχολείται με την ανακάλυψη ενός μη γνωστού προτύπου εισόδου, χρησιμοποιώντας εποπτευόμενη μάθηση, σε μία από αρκετές προκαθορισμένες κατηγορίες που βασίζονται σε μία ή περισσότερες ιδιότητες που χαρακτηρίζουν μια δεδομένη κλάση, όπως φαίνεται στο παρακάτω σχήμα.




Εικόνα 6 - Classification

Σε αντίθεση με την ανάλυση διακρίσεων στην στατιστική, τα ANNs δεν απαιτούν την παραδοχή της γραμμικότητας και μπορούν να εφαρμοστούν σε μη γραμμικά διαχωρίσιμες κατηγορίες (Garth et al., 1996).

### 2) Ομαδοποίηση (Clustering)

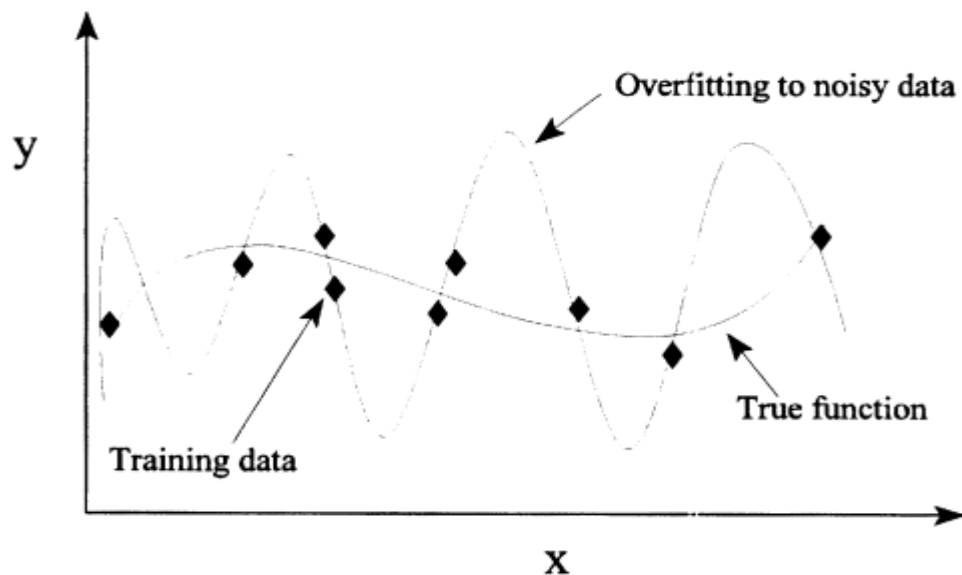
Η ομαδοποίηση πραγματοποιείται μέσω μάθησης χωρίς επίβλεψη, κατά την οποία σχηματίζονται οι ομάδες (κλάσεις) εξετάζοντας τις ομοιότητες ή τις ανισότητες μεταξύ των προτύπων εισόδου βάσει των αλληλοσυσχετισμών τους. Το δίκτυο εκχωρεί «παρόμοια» μοτίβα στην ίδια κλάση.



Εικόνα 7 - Clustering

### 3) Συγκριτική λειτουργία (modeling)

Η προσέγγιση των μοντέλων (modeling) περιλαμβάνει την κατάρτιση του ANN στα δεδομένα εισόδου-εξόδου έτσι ώστε να προσεγγίσουν τους υποκείμενους κανόνες που σχετίζονται με τις εισόδους στις εξόδους.




Εικόνα 8 - Modeling

Τα πολυστρωματικά ANNs θεωρούνται καθολικές προσεγγίσεις που μπορούν να προσεγγίσουν οποιαδήποτε αυθαίρετη λειτουργία σε οποιοδήποτε βαθμό ακρίβειας (Hecht-Nielsen, 1990), έτσι χρησιμοποιούνται άριστα σε αυτή την εφαρμογή. Η προσέγγιση των λειτουργιών εφαρμόζεται σε προβλήματα (i) όπου δεν υπάρχει διαθέσιμο θεωρητικό μοντέλο, δηλαδή δεδομένα που λαμβάνονται από πειράματα ή παρατηρήσεις, ή (ii) υποκατάσταση θεωρητικών μοντέλων που είναι

δύσκολο να υπολογιστούν αναλυτικά χρησιμοποιώντας δεδομένα που προέρχονται από τέτοια μοντέλα.

#### 4) Πρόβλεψη

Η πρόβλεψη περιλαμβάνει την κατάρτιση ενός ANN σε δείγματα από μια χρονοσειρά που αντιπροσωπεύει ένα συγκεκριμένο φαινόμενο σε ένα συγκεκριμένο σενάριο και στη συνέχεια τη χρήση του για άλλα σενάρια για την πρόβλεψη της συμπεριφοράς σε επόμενους χρόνους.



Εικόνα 9 - Forecasting


Δηλαδή, το δίκτυο θα προβλέψει το  $Y(t+1)$  από μία ή περισσότερες προηγούμενες γνωστές ιστορικές παρατηρήσεις (π.χ.  $Y(t-2)$ ,  $Y(t-1)$  και  $Y(t)$ ), όπου  $t$  είναι το βήμα του χρόνου).

#### 5) Βελτιστοποίηση

Η βελτιστοποίηση ασχολείται με την εξεύρεση λύσης που μεγιστοποιεί ή ελαχιστοποιεί μια αντικειμενική λειτουργία που υπόκειται σε ένα σύνολο περιορισμών. Η βελτιστοποίηση είναι ένα καθιερωμένο πεδίο στα μαθηματικά, αν και τα ANN, όπως το δίκτυο Hopfield (Hopfield and Tank, 1986), βρέθηκαν πιο αποτελεσματικά στην επίλυση σύνθετων και μη γραμμικών προβλημάτων βελτιστοποίησης (Pham, 1994).

#### 6) Association

Ο Σύνδεσμος Σύνδεσης περιλαμβάνει την ανάπτυξη ενός προτύπου αναλυτή ANN με εκπαίδευση σε ιδανικά δεδομένα χωρίς θόρυβο και στη συνέχεια χρησιμοποιώντας αυτό το ANN για την ταξινόμηση δεδομένων που έχουν αλλοιωθεί από θόρυβο. Το συνδεδεμένο δίκτυο μπορεί επίσης να χρησιμοποιηθεί για τη διόρθωση (αναδόμηση) των κατεστραμμένων δεδομένων ή για την πλήρη έλλειψη δεδομένων (ή εικόνας), όπως φαίνεται στο παρακάτω σχήμα.




Εικόνα 10 - Αναδόμηση εικόνας

Τα δίκτυα Hopfield και Hamming χρησιμοποιούνται ειδικά για αυτή την εφαρμογή (Lippmann, 1987), και σε μικρότερο βαθμό πολλαπλών επιπέδων backpropagation ANNs που εκπαιδεύονται σε πρότυπα με ίδια εισροή και εκροή (Fu, 1995).

#### 7) Control

Ο έλεγχος ασχολείται με το σχεδιασμό ενός δικτύου, συνήθως επαναλαμβανόμενου, το οποίο θα βοηθήσει ένα προσαρμοστικό σύστημα ελέγχου να παράγει τις απαιτούμενες εισόδους ελέγχου, έτσι ώστε το σύστημα να ακολουθήσει μια συγκεκριμένη τροχιά βασισμένη στην ανατροφοδότηση του συστήματος (Jain et al., 1996).

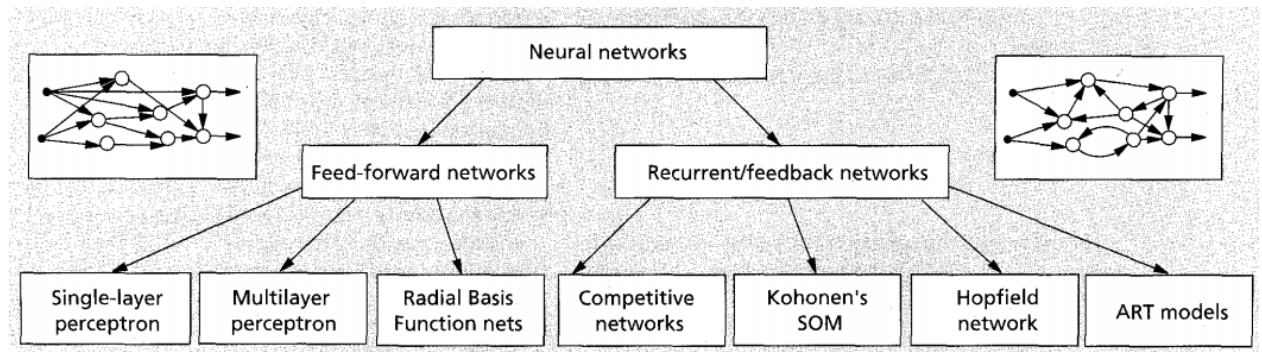


Εικόνα 11 - Control

### 4.5 Αρχιτεκτονική ANN

Τα βασικά χαρακτηριστικά ενός ANN είναι η αρχιτεκτονική του, τη λειτουργία που επιτελούν και την μέθοδο εκπαίδευσής τους. Η αρχιτεκτονική τους καθορίζει τη διάταξη των νευρώνων καθώς και τον αριθμό και τύπο των νευρώνων. Οι νευρώνες οργανώνονται σε μορφή επιπέδων και ο τρόπος δόμησής τους σχετίζεται με τον αλγόριθμο εκμάθησής τους. Υπάρχουν βασικές 2 κατηγορίες αρχιτεκτονικών ενός ANN. Στο παρακάτω σχήμα φαίνονται οι 2 κατηγορίες αρχιτεκτονικών και οι βασικοί τύποι νευρωνικών δικτύων [15].






Εικόνα 12 - Κατηγορίες ANN και βασικά δίκτυα

## 1. Δίκτυα πρόσθιας τροφοδότησης (feed-forward)

Ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης είναι ένα τεχνητό νευρωνικό δίκτυο στο οποίο οι πληροφορίες μετακινούνται μόνο προς μια κατεύθυνση, προς τα εμπρός, από τους κόμβους εισόδου, μέσω των κρυφών κόμβων (εάν υπάρχουν) και του κόμβους εξόδου. Δεν υπάρχουν κύκλοι ή βρόχοι στο δίκτυο. Τα τρία πιο βασικά δίκτυα πρόσθιας τροφοδότησης αναφέρονται παρακάτω.

### 1.1 Μονού επιπέδου perceptron

Το απλούστερο είδος νευρωνικού δικτύου είναι ένα δίκτυο perceptron ενός επιπέδου, το οποίο αποτελείται από ένα μόνο στρώμα κόμβων εξόδου. οι εισοδοί τροφοδοτούνται απευθείας στις εξόδους μέσω μιας σειράς βαρών. Με τον τρόπο αυτό μπορεί να θεωρηθεί το απλούστερο είδος δικτύου πρόσθιας τροφοδότησης. Το άθροισμα των βαρών και των εισόδων υπολογίζεται σε κάθε κόμβο και αν η τιμή είναι πάνω από κάποιο κατώφλι (τυπικά 0), ο νευρώνας ενεργοποιείται και παίρνει την ενεργοποιημένη τιμή (συνήθως 1), διαφορετικά παίρνει την απενεργοποιημένη τιμή (συνήθως -1). Οι νευρώνες με αυτό το είδος της λειτουργίας ενεργοποίησης ονομάζονται επίσης τεχνητοί νευρώνες ή γραμμικές μονάδες κατωφλίου.



Εικόνα 13 Perceptron ενός επιπέδου


Ένα perceptron μπορεί να δημιουργηθεί χρησιμοποιώντας οποιοσδήποτε τιμές για τις ενεργοποιημένες και απενεργοποιημένες καταστάσεις, εφόσον η τιμή κατωφλίου βρίσκεται μεταξύ των δύο. Τα perceptrons μπορούν να εκπαιδευτούν με έναν απλό αλγόριθμο μάθησης ο οποίος συνήθως ονομάζεται κανόνας δέλτα. Υπολογίζει τα σφάλματα μεταξύ των υπολογισμένων εξόδων και των δεδομένων εξόδου δείγματος και με βάση την διαφορά τους δημιουργεί μια προσαρμογή στα βάρη. Τα perceptrons ενός επιπέδου είναι ικανά να μάθουν γραμμικά διαχωρίσιμα μοτίβα.

Αν και μια μοναδική μονάδα κατωφλίου είναι αρκετά περιορισμένη στην υπολογιστική ισχύ της, έχει αποδειχθεί ότι δίκτυα παραλλήλων μονάδων κατωφλίου μπορούν να προσεγγίσουν κάθε συνεχή λειτουργία από ένα συμπαγές διάστημα των πραγματικών αριθμών στο διάστημα  $[-1,1]$ .

## 1.2 Perceptron πολλών επιπέδων

Αυτή η τάξη δικτύων αποτελείται από πολλαπλά στρώματα υπολογιστικών μονάδων, συνήθως διασυνδεδεμένα με τρόπο πρόσθιας τροφοδότησης. Κάθε νευρώνας σε ένα επίπεδο έχει κατευθύνει τις συνδέσεις με τους νευρώνες του επόμενου στρώματος. Σε πολλές εφαρμογές οι μονάδες αυτών των δικτύων εφαρμόζουν μια λειτουργία sigmoid ως λειτουργία ενεργοποίησης.

Τα δίκτυα πολλαπλών επιπέδων χρησιμοποιούν μια ποικιλία τεχνικών μάθησης, η πιο δημοφιλής είναι η οπίσθια διάδοση. Εδώ, οι τιμές εξόδου συγκρίνονται με τη σωστή απάντηση για να υπολογιστεί η τιμή κάποιας προκαθορισμένης συνάρτησης σφάλματος. Με διάφορες τεχνικές, το σφάλμα διοχετεύεται στη συνέχεια μέσω του δικτύου. Χρησιμοποιώντας αυτές τις πληροφορίες, ο αλγόριθμος προσαρμόζει τα βάρη κάθε σύνδεσης για να μειώσει την τιμή της συνάρτησης σφάλματος κατά κάποιο μικρό ποσό. Μετά την επανάληψη αυτής της διαδικασίας για έναν αρκετά μεγάλο αριθμό κύκλων εκπαίδευσης, το δίκτυο συνήθως θα συγκλίνει σε κάποια κατάσταση όπου το σφάλμα των υπολογισμών είναι μικρό. Σε αυτή την περίπτωση, θα λέγαμε ότι το δίκτυο έχει μάθει μια συγκεκριμένη λειτουργία στόχου. Για την σωστή ρύθμιση των βαρών, εφαρμόζεται μια γενική μέθοδος για τη μη γραμμική βελτιστοποίηση που ονομάζεται βαθμολογημένη κλίση. Για το σκοπό αυτό, το δίκτυο υπολογίζει το παράγωγο της συνάρτησης σφάλματος σε σχέση με τα βάρη του δικτύου και αλλάζει τα βάρη έτσι ώστε το σφάλμα να μειώνεται (συνεπώς να κατεβαίνει προς τα κάτω στην επιφάνεια της συνάρτησης σφάλματος). Για το λόγο αυτό, η οπίσθια διάδοση μπορεί να εφαρμοστεί μόνο σε δίκτυα με διαφοροποιήσιμες λειτουργίες ενεργοποίησης.




Εικόνα 14 - Perceptron πολλών επιπέδων (MLP)

Γενικά, το πρόβλημα της διδασκαλίας ενός δικτύου για καλή απόδοση, ακόμη και σε δείγματα που δεν χρησιμοποιήθηκαν ως δείγματα εκπαίδευσης, είναι ένα αρκετά λεπτό θέμα που απαιτεί πρόσθετες τεχνικές. Αυτό είναι ιδιαίτερα σημαντικό για περιπτώσεις όπου υπάρχει πολύ περιορισμένος αριθμός δειγμάτων κατάρτισης. Ο κίνδυνος είναι ότι το δίκτυο υπερισχύει των δεδομένων εκπαίδευσης και δεν καταγράφει την πραγματική στατιστική διαδικασία που παράγει τα δεδομένα. Η θεωρία της υπολογιστικής μάθησης αφορά τους ταξινομητές κατάρτισης σε περιορισμένο αριθμό δεδομένων. Στο πλαίσιο των νευρωνικών δικτύων μια απλή λειτουργία, που

ονομάζεται πρόωρη διακοπή, συχνά εξασφαλίζει ότι το δίκτυο θα γενικευτεί καλά σε παραδείγματα που δεν περιλαμβάνονται στο σετ εκπαίδευσης.

### 1.3 RBF δίκτυα

Ένα δίκτυο RBF (radial basis function) είναι ένα τεχνητό νευρωνικό δίκτυο που χρησιμοποιεί Συναρτήσεις Ακτινικού Τύπου ως λειτουργίες ενεργοποίησης. Η έξοδος του δικτύου είναι ένας γραμμικός συνδυασμός λειτουργιών ακτινικής βάσης των εισόδων και παραμέτρων των νευρώνων. Τα δίκτυα RBF έχουν πολλές χρήσεις, συμπεριλαμβανομένης της προσέγγισης των λειτουργιών, της πρόβλεψης χρονοσειρών, της ταξινόμησης και του ελέγχου του συστήματος. Τα δίκτυα (RBF) έχουν συνήθως τρία επίπεδα: ένα στρώμα εισόδου, ένα κρυφό στρώμα με μη γραμμική λειτουργία ενεργοποίησης RBF και ένα γραμμικό επίπεδο στρώματος εξόδου.



Εικόνα 15 - RFB δίκτυα


Τα δίκτυα RBF είναι ανομοιογενή. Στο κρυφό επίπεδο η συνάρτηση ενεργοποίησης είναι ακτινικού τύπου και οι παράμετροι που πρέπει να εκπαιδευτούν είναι τα κέντρα  $c_i$  και τα εύρη  $\sigma_i$  των κρυφών νευρώνων  $i = 1, 2, \dots, K$ . Στο επίπεδο εξόδου η συνάρτηση ενεργοποίησης είναι γραμμική και οι παράμετροι που πρέπει να εκπαιδευτούν είναι οι τιμές των συναπτικών βαρών  $w_{ij}$ . Λόγω αυτής της ανομοιογένειας αντιμετωπίζεται ξεχωριστά το πρόβλημα της εκπαίδευσης του κρυφού επιπέδου από το πρόβλημα της εκπαίδευσης του επιπέδου εξόδου. Αφού βρεθούν τα κέντρα των κρυφών νευρώνων με κάποια μέθοδο ομαδοποίησης (clustering), στη συνέχεια βρίσκονται τα συναπτικά βάρη του εξωτερικού επιπέδου με κάποια μέθοδο εκπαίδευσης με επίβλεψη [16].

## 2. Αναδρομικά δίκτυα (recurrent neural network)

Στα αναδρομικά δίκτυα υπάρχει τουλάχιστον ένας βρόχος ανάδρασης. Η έξοδος κάθε νευρώνα του δικτύου ανατροφοδοτεί την είσοδο των άλλων νευρώνων του ίδιου επιπέδου και σε μερικές περιπτώσεις ακόμα και τη δική του είσοδο (αυτό-ανάδραση). Οι συνδέσεις μεταξύ των νευρώνων σχηματίζουν έναν κατευθυνόμενο κύκλο. Αυτό του επιτρέπει να παρουσιάζει δυναμική χρονική συμπεριφορά. Σε αντίθεση με τα νευρωνικά δίκτυα πρόσθιας τροφοδότησης, τα αναδρομικά νευρωνικά δίκτυα μπορούν να χρησιμοποιήσουν την εσωτερική μνήμη τους για να επεξεργαστούν αυθαίρετες ακολουθίες εισόδων. Αυτό το καθιστά εφαρμόσιμο σε εργασίες όπως η αναγνώριση κειμένου ή η αναγνώριση ομιλίας [16].

## 2.1 Επαναλαμβανόμενα δίκτυα


Σε ένα επαναλαμβανόμενο δίκτυο, οι εξόδους ορισμένων νευρώνων τροφοδοτούνται πίσω στους ίδιους νευρώνες ή στους νευρώνες σε προηγούμενα επίπεδα. Αυτό επιτρέπει μια ροή πληροφοριών τόσο προς τα εμπρός όσο και προς τα πίσω, παρέχοντας έτσι στο νευρωνικό δίκτυο μια δυναμική μνήμη. Υπάρχουν ειδικοί αλγόριθμοι για την εκπαίδευση επαναλαμβανόμενων δικτύων. Τα επαναλαμβανόμενα νευρωνικά δίκτυα BP (Backpropagation) είναι μια απλή παραλλαγή των επαναλαμβανόμενων δικτύων στα οποία η μνήμη εισάγεται σε στατικά δίκτυα πρόσθιας τροφοδότησης με μια ειδική αναπαράσταση δεδομένων (π.χ., χρονική καθυστέρηση) ακολουθούμενη από εκπαίδευση χρησιμοποιώντας την κλασική οπίσθια διάδοση [17].



Εικόνα 16 - Επαναλαμβανόμενα δίκτυα

## 2.2 Δίκτυα Kohonen (SOM)

Αυτά τα δίκτυα, τα οποία ονομάζονται επίσης αυτό-οργανωτικοί χάρτες χαρακτηριστικών, είναι δίκτυα δύο επιπέδων που μετατρέπουν τα  $n$ -διαστατά πρότυπα εισόδου σε δεδομένα χαμηλότερης τάξης, όπου παρόμοια πρότυπα προβάλλονται σε σημεία που βρίσκονται σε πολύ μικρή απόσταση μεταξύ τους.




Εικόνα 17 - Δίκτυα Kohonen (SOM)

Τα δίκτυα Kohonen εκπαιδεύονται κατά τρόπο μη επιτηρούμενο ώστε να σχηματίσουν συστάδες εντός των δεδομένων (δηλ., Ομαδοποίηση δεδομένων). Εκτός από την αναγνώριση και την ταξινόμηση των προτύπων, οι χάρτες Kohonen χρησιμοποιούνται για συμπίεση δεδομένων, όπου τα δεδομένα μεγάλης διαστάσεως χαρτογραφούνται σε μικρότερο χώρο διαστάσεων ενώ διατηρείται το περιεχόμενό τους [18].

### 2.3 Δίκτυα Hopfield

Το δίκτυο αυτό είναι ένα συμμετρικό πλήρως συνδεδεμένο δίκτυο και αποτελείται από ένα μόνο επίπεδο που περιέχει έναν ή περισσότερους επαναλαμβανόμενους νευρώνες. Το δίκτυο Hopfield χρησιμοποιείται συνήθως για εργασίες αυτόματης συσχέτισης και βελτιστοποίησης. Η έξοδος από το  $Y_1$  που πηγαίνει στα  $Y_2$ ,  $Y_i$  και  $Y_n$  έχει τα βάρη  $w_{12}$ ,  $w_{1i}$  και  $w_{1n}$  αντίστοιχα. Ομοίως, τα άλλα τόξα έχουν τα αντίστοιχα βάρη.



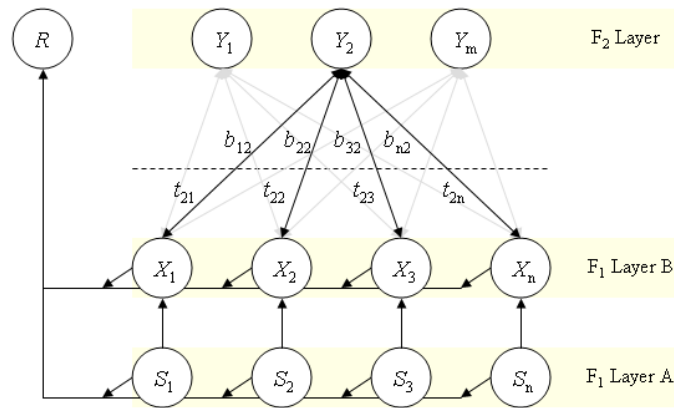
Εικόνα 18 - Δίκτυα Hopfield

Η εκμάθηση γίνεται με τον καθορισμό κάθε βάρους που συνδέει δύο νευρώνες με το αποτέλεσμα των εισροών αυτών των δύο νευρώνων. Όταν παρουσιάζεται με ατελή ή θορυβώδη μοτίβο, το δίκτυο αποκρίνεται με την ανάκτηση ενός εσωτερικά αποθηκευμένου μοτίβου που μοιάζει περισσότερο με το πρότυπο που παρουσιάζεται [19].

### 2.4 Δίκτυα ART

Τα δίκτυα ART εκπαιδεύονται από μη επιτηρούμενη μάθηση όπου το δίκτυο προσαρμόζεται στο περιβάλλον πληροφοριών χωρίς παρέμβαση. Το δίκτυο ART αποτελείται από δύο πλήρως διασυνδεδεμένα στρώματα, ένα στρώμα που λαμβάνει τις εισόδους και ένα στρώμα που αποτελείται από νευρώνες εξόδου. Τα βάρη χρησιμοποιούνται για την επιλογή του νευρώνα εξόδου και χρησιμεύουν ως μακροπρόθεσμη μνήμη για τα δίκτυα. Τα βάρη ανάδρασης είναι τα βάρη επαγρύπνησης που χρησιμοποιούνται για τη δοκιμή της επαγρύπνησης και χρησιμεύουν ως βραχυπρόθεσμη μνήμη για το δίκτυο.





Εικόνα 19 - Δίκτυα ART

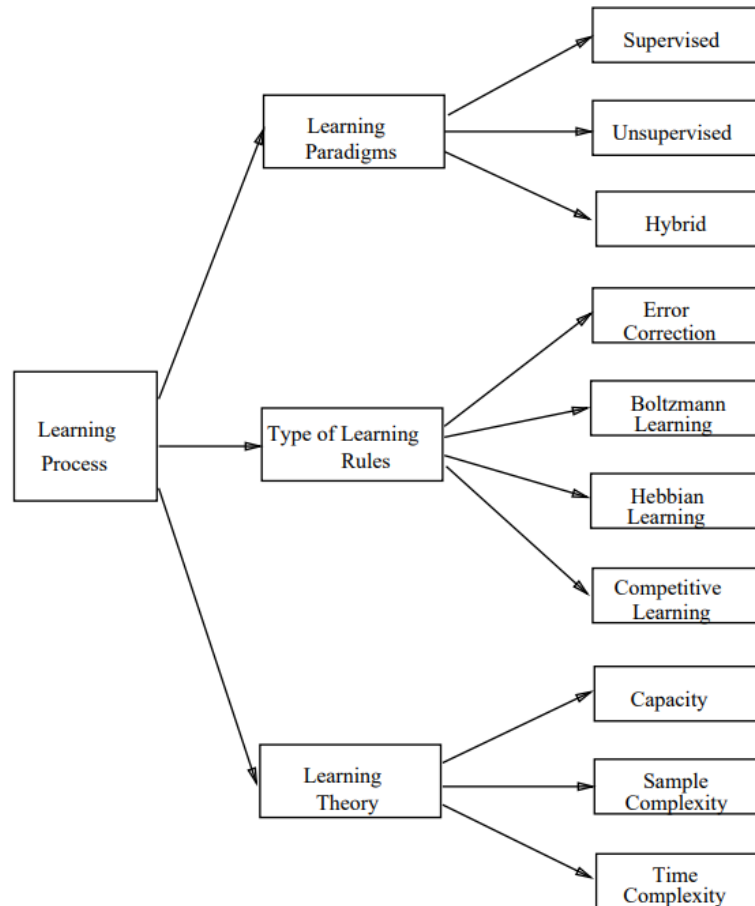
Ένα δίκτυο ART αποθηκεύει ένα σύνολο μοτίβων με τέτοιο τρόπο ώστε όταν το δίκτυο παρουσιάζεται με ένα νέο μοτίβο, είτε θα ταιριάζει με ένα προηγούμενος αποθηκευμένο μοτίβο είτε θα το αποθηκεύει ως νέο μοτίβο εάν είναι αρκετά ανόμοιο με το πλησιέστερο σχέδιο. Όπως τα δίκτυα Hopfield, τα δίκτυα ART μπορούν να χρησιμοποιηθούν για την αναγνώριση και ταξινόμηση προτύπων [20].

#### 4.6 Εκπαίδευση νευρωνικών δικτύων

Ο σκοπός της λειτουργίας ενός Τεχνητού Νευρωνικού Δικτύου είναι

η επίλυση συγκεκριμένων προβλημάτων ή να επιτελεί από μόνο του ορισμένες διεργασίες π.χ. αναγνώριση εικόνων. Για να μπορέσει να επιτελέσει τις εργασίες που του έχουν ανατεθεί, αρχικά θα πρέπει να εκπαιδευτεί. Η εκπαίδευση ενός νευρωνικού δικτύου είναι το σημαντικότερο χαρακτηριστικό τους. Οι δύο βασικές λειτουργίες που πραγματοποιούν τα τεχνητά νευρωνικά δίκτυα είναι η μάθηση και η ανάκληση. Μάθηση (learning) ονομάζεται η διαδικασία τροποποίησης των βαρών ή της μεταβολής της δομής ενός νευρωνικού δικτύου, ώστε για κάθε συγκεκριμένο διάνυσμα εισόδου να παραχθεί συγκεκριμένο διάνυσμα εξόδου. Ανάκληση (recall) ονομάζεται η διαδικασία υπολογισμού ενός διανύσματος εξόδου για συγκεκριμένο διάνυσμα εισόδου, τιμές βαρών και δομής δικτύου [21].

Αν και αυτό που εννοείται με τη μάθηση τεχνητών νευρωνικών δικτύων είναι συχνά δύσκολο να περιγραφεί, μια μαθησιακή διαδικασία στο πλαίσιο των τεχνητών νευρωνικών δικτύων μπορεί να θεωρηθεί ως το πρόβλημα της ενημέρωσης της αρχιτεκτονικής δικτύου και των βαρών σύνδεσης, έτσι ώστε ένα δίκτυο να μπορεί να εκτελεί μια συγκεκριμένη εργασία. Συνήθως, η μάθηση γίνεται με δύο τρόπους. Μερικές φορές, τα βάρη μπορούν να οριστούν εκ των προτέρων από τον σχεδιαστή του δικτύου μέσω μιας σωστής διατύπωσης του προβλήματος. Ωστόσο, τις περισσότερες φορές, το δίκτυο πρέπει να μάθει τα βάρη σύνδεσης από τα δοθέντα πρότυπα εκπαίδευσης. Η βελτίωση της απόδοσης επιτυγχάνεται με την πάροδο του χρόνου μέσω της επαναληπτικής ενημέρωσης των βαρών στο δίκτυο. Η ικανότητα των νευρωνικών δικτύων να μαθαίνουν αυτόματα από τα παραδείγματα κάνει τα τεχνητά νευρωνικά δίκτυα πολύ ελκυστικά και συναρπαστικά. Αντί να χρειάζεται ο ορισμός ενός συνόλου κανόνων, τα νευρωνικά δίκτυα εκπαιδεύονται από μια συλλογή αντιπροσωπευτικών παραδειγμάτων. Αυτό είναι ένα από τα βασικά πλεονεκτήματα των νευρωνικών δικτύων έναντι των παραδοσιακών ειδικών συστημάτων.



Εικόνα 20 - Μαθησιακά ζητήματα

Για να κατανοήσουμε ή να σχεδιάσουμε μια διαδικασία μάθησης, πρέπει πρώτα να έχουμε ένα μοντέλο του περιβάλλοντος στο οποίο λειτουργεί ένα νευρωνικό δίκτυο. Αναφερόμαστε σε αυτό το μοντέλο ως παράδειγμα μάθησης [21]. Δεύτερον, πρέπει να κατανοήσουμε πώς ενημερώνονται τα βάρη στο δίκτυο, δηλαδή ποιοι είναι οι κανόνες μάθησης που διέπουν τη διαδικασία ενημέρωσης. Ένας αλγόριθμος μάθησης αναφέρεται σε μια διαδικασία στην οποία οι κανόνες μάθησης χρησιμοποιούνται για την προσαρμογή των βαρών στο δίκτυο. Τέλος, είναι σημαντικό να διερευνήσουμε πόσο μπορεί να μάθει το δίκτυο από παραδείγματα «χωρητικότητα» (Capacity), πόσα δείγματα εκπαίδευσης απαιτούνται «πολυπλοκότητα δείγματος» (Sample Complexity) και πόσο γρήγορα μπορεί να μάθει το σύστημα «πολυπλοκότητα του χρόνου» (Time Complexity). Η μελέτη της χωρητικότητας, της πολυπλοκότητας του δείγματος και της πολυπλοκότητας του χρόνου είναι αυτό που πρέπει να αντιμετωπίσει μια θεωρία μάθησης. Η εικόνα 20 απεικονίζει όλες τις πτυχές μιας μαθησιακής διαδικασίας.

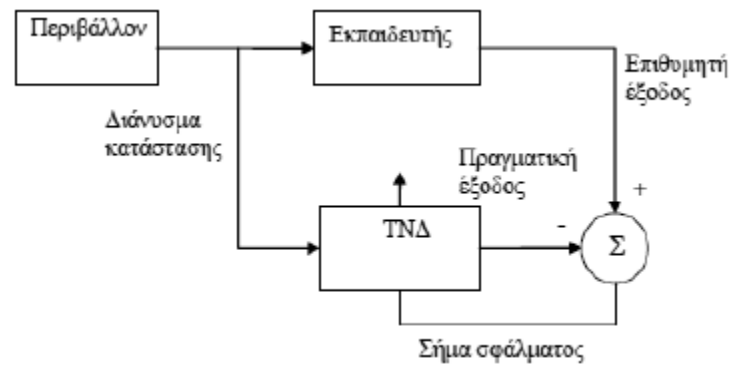
#### 4.6.1 Διαδικασία μάθησης

Υπάρχουν 3 τρόποι εκπαίδευσης των τεχνητών νευρωνικών δικτύων, μάθηση με επίβλεψη (supervised learning), βαθμολογημένη μάθηση (graded learning) και μάθηση χωρίς επίβλεψη (unsupervised learning)

##### **Μάθηση με επίβλεψη (supervised learning)**

Στη μάθηση με επίβλεψη (supervised learning) δίνονται στο νευρωνικό δίκτυο ζευγάρια διανυσμάτων εισόδου – επιθυμητής εξόδου και αυτό υπολογίζει σύμφωνα με την τρέχουσα

κατάσταση των βαρών και της δομής του, μια έξοδο που ίσως να διαφέρει από την επιθυμητή έξοδο. Αυτή η διαφορά μεταξύ της εισόδου και της εξόδου ονομάζεται σφάλμα (error). Βάση αυτής της διαφοράς καθώς και ενός αλγορίθμου εκπαίδευσης γίνεται συνήθως η αναπροσαρμογή των βαρών. Η επιβλεπόμενη μάθηση αναφέρεται συχνά και ως μάθηση με εκπαιδευτή και είναι ο πιο συχνός τρόπος εκπαίδευσης των Νευρωνικών Δικτύων. Το παρακάτω σχήμα περιγράφει αυτή τη μορφή μάθησης.



Εικόνα 21 - Σχηματικό διάγραμμα επιβλεπόμενης μάθησης

Σύμφωνα με το σχήμα 21, η επιβλεπόμενη μάθηση είναι ένα σύστημα ανάδρασης κλειστού βρόχου. Ως μέτρο απόδοσης για το σύστημα συνήθως χρησιμοποιείται το μέσο τετραγωνικό σφάλμα ή το άθροισμα των τετραγώνων των σφαλμάτων ορισμένο ως συνάρτηση (συνάρτηση κόστους) των συναπτικών βαρών του δικτύου. Μερικές φορές η διαδικασία αυτή απαιτεί πολλές επαναλήψεις για την διόρθωση των βαρών του δικτύου και άρα μεγάλους υπολογιστικούς χρόνους [6].

Ο εκπαιδευτής έχει γνώση του περιβάλλοντος σε αντίθεση με το Νευρωνικό Δίκτυο, η γνώση αντιπροσωπεύεται από ένα σύνολο παραδειγμάτων εισόδου – επιθυμητής εξόδου. Ο εκπαιδευτής και το Νευρωνικό Δίκτυο αντλούν από το περιβάλλον ένα παράδειγμα εισόδου σαν διάνυσμα εκπαίδευσης και ο εκπαιδευτής παρέχει στο Νευρωνικό Δίκτυο μια επιθυμητή απόκριση για το συγκεκριμένο διάνυσμα εκπαίδευσης. Η επιθυμητή απόκριση είναι ο στόχος που έχει το νευρωνικό δίκτυο σαν βέλτιστη απόκριση. Η διαφορά μεταξύ της επιθυμητής απόκρισης και της πραγματικής απόκρισης αποτελεί το σφάλμα. Υπό τη συνδυασμένη επιρροή του διανύσματος εκπαίδευσης και του σφάλματος, τα βάρη του δικτύου μεταβάλλονται για κάθε ζευγάρι εισόδου – επιθυμητής εξόδου. Αυτή η προσαρμογή έχει στόχο να φέρει τελικά το νευρωνικό δίκτυο σε μια κατάσταση που σχεδόν θα ταυτίζεται με τη συμπεριφορά του εκπαιδευτή. Έτσι η γνώση του περιβάλλοντος μεταφέρεται στο Νευρωνικό Δίκτυο μέσω εκπαίδευσης και αναλύεται με τη μορφή σταθερών συναπτικών βαρών τα οποία αποτελούν την μακροπρόθεσμη μνήμη του δικτύου.

### **Βαθμολογημένη μάθηση (graded learning)**

Στη βαθμολογημένη μάθηση (graded learning) ή αλλιώς ενισχυτική μάθηση η έξοδος χαρακτηρίζεται ως επιθυμητή ή μη με βάση μια αριθμητική κλίμακα και τα συναπτικά βάρη αναπροσαρμόζονται με βάση αυτή την κλίμακα. Σε αυτόν τον τύπο εκμάθησης, το νευρωνικό δίκτυο τροφοδοτείται και πάλι με διανύσματα εισόδου όμως δεν παρέχονται οι επιθυμητές αποκρίσεις για αυτές τις εισόδους. Σε αυτή την περίπτωση χρησιμοποιείται ένα συνολικό μέτρο της επάρκειας του διανύσματος εξόδου (δείκτης συμπεριφοράς) το οποίο μπορεί να εκπαιδεύσει το δίκτυο στην



επιθυμητή συμπεριφορά. Το μέτρο αυτό είναι γνωστό ως ενισχυτικό σήμα (reinforcement signal) και ανατροφοδοτείται στο ΝΔ έτσι ώστε να επιβεβαιώσει τις ορθές συμπεριφορές και να τονίσει τις λανθασμένες συμπεριφορές. Η ενισχυτική μάθηση βασίζεται στον νόμο Thorndike, ο οποίος ερμηνεύεται ως εξής: «Εάν μια εκροή ενός συστήματος εκπαίδευσης οδηγεί σε μια ικανοποιητική κατάσταση ή συμπεριφορά, τότε η τάση του συστήματος αυτού να παράγει τη συγκεκριμένη ενέργεια ενδυναμώνεται. Διαφορετικά, η διάθεση του συστήματος να παράγει την ενέργεια αυτή εξασθενεί». Η ενισχυτική μάθηση χωρίζεται σε συσχετιστική και μη συσχετιστική ενισχυτική μάθηση. Στην πρώτη, το περιβάλλον τροφοδοτεί εκτός από το ενισχυτικό σήμα και άλλες πληροφορίες από τις οποίες το νευρωνικό δίκτυο πρέπει να εκπαιδευτεί σε μια απεικόνιση με τη μορφή μιας συσχέτισης αιτίου - αποτελέσματος. Στη δεύτερη, η μοναδική πληροφορία που δίνεται από το περιβάλλον στο νευρωνικό δίκτυο είναι το ενισχυτικό σήμα, ενώ ο στόχος του συστήματος εκπαίδευσης είναι να επιλέξει μια μοναδική βέλτιστη ενέργεια παρά να συσχετίσει διάφορες ενέργειες με διαφορετικές εισόδους. Η διαδικασία της ενισχυτικής μάθησης λειτουργεί ως εξής: Το νευρωνικό δίκτυο υπολογίζει τις εξόδους με βάση την τρέχουσα είσοδο με τις τρέχων τιμές των βαρών. Στη συνέχεια το σύστημα αξιολογεί την έξοδο και το ενισχυτικό σήμα τροφοδοτείται στο δίκτυο με σκοπό την ενημέρωση των βαρών με βάση το ενισχυτικό σήμα, αυξάνοντας τις τιμές των βαρών που είχαν καλή απόδοση ή μειώνοντας τις τιμές αυτών που είχαν κακή απόδοση.

### **Μάθηση χωρίς επίβλεψη (unsupervised learning)**

Στη μάθηση χωρίς επίβλεψη (unsupervised learning) η έξοδος του δικτύου βασίζεται στην ικανότητά του να αυτό-οργανώνεται σύμφωνα με τα διανύσματα εισόδου καθώς δεν υπάρχουν αντίστοιχα διανύσματα εξόδου. Αυτή η οργάνωση γίνεται με σκοπό σε συγκεκριμένο σύνολο εισόδων να αντιδρά περισσότερο ένας συγκεκριμένος νευρώνας απ' όλους τους νευρώνες του δικτύου. Σε αυτή την περίπτωση μάθησης, στο δίκτυο δίνεται απλώς η πληροφορία και δεν υπάρχει κάποιο σύστημα εξωτερικού εκπαιδευτή που να παρέχει την επιθυμητή απόκριση και να επιβλέπει τη διαδικασία της μάθησης προτείνοντας διορθώσεις. Τα δείγματα εκπαίδευσης από το περιβάλλον αποτελούνται μόνο από τα διανύσματα εισόδου και δεν περιέχουν διανύσματα επιθυμητής εξόδου. Το δίκτυο χρησιμοποιεί έναν εσωτερικό έλεγχο, με σκοπό να βρει κανονικότητα στα διανύσματα εισόδου και εκπαιδεύεται ώστε τα διανύσματα εξόδου να έχουν τα ίδια χαρακτηριστικά με της εισόδου. Έτσι το δίκτυο εκπαιδεύει τον εαυτό του και διορθώνει τα σφάλματα στα δεδομένα με ένα κόμβο ανάδρασης (feedback). Όταν το δίκτυο σταματήσει να ενημερώνει τις τιμές των βαρών τότε η εκπαίδευση έχει ολοκληρωθεί. Το παρακάτω σχήμα περιγράφει τη διαδικασία της μη επιβλεπόμενης μάθησης:



Εικόνα 22 - Σχηματικό διάγραμμα μη επιβλεπόμενης μάθησης

#### **4.6.2 Τύποι κανόνων μάθησης**

Υπάρχουν τέσσερις βασικοί τύποι κανόνων εκπαίδευσης (όπως φαίνεται στην εικόνα 20) : Κανόνας διόρθωσης σφαλμάτων (error-correction), μάθηση Boltzmann, μάθηση Hebbian, και ανταγωνιστική μάθηση (competitive learning).

### Κανόνας διόρθωσης σφαλμάτων

Στο μοντέλο εποπτευόμενης εκμάθησης, παρέχεται στο δίκτυο η επιθυμητή έξοδος για κάθε πρότυπο εισαγωγής. Κατά τη διάρκεια της διαδικασίας μάθησης, η πραγματική έξοδος,  $y$ , που παράγεται από το δίκτυο μπορεί να μην είναι ίση με την επιθυμητή έξοδο,  $d$ . Η βασική αρχή των κανόνων εκμάθησης διόρθωσης σφαλμάτων είναι η χρήση του σήματος σφάλματος ( $d - y$ ) για την τροποποίηση των βαρών σύνδεσης έτσι ώστε το σφάλμα αυτό να μειώνεται σταδιακά.

Ο γνωστός κανόνας μάθησης perceptron βασίζεται στην αρχή της διόρθωσης σφαλμάτων. Ένα perceptron αποτελείται από ένα μόνο νευρώνα με ρυθμιζόμενα βάρη,  $w_j$ ,  $j = 1, 2, \dots, n$  και το όριο  $\mu$ . Δεδομένου ότι ο φορέας εισόδου  $x = (x_1, x_2, \dots, x_n)^t$ , η καθαρή είσοδος στον νευρώνα (πριν από την εφαρμογή της συνάρτησης κατωφλίου) είναι

$$u = \sum_{j=1}^n w_j x_j - \mu$$

Η έξοδος  $y$  του perceptron είναι +1 εάν  $u > 0$  και 0 σε διαφορετική περίπτωση. Σε ένα πρόβλημα κατηγοριοποίησης δύο κατηγοριών, το perceptron εκχωρεί ένα πρότυπο εισόδου σε μία τάξη αν  $y = 1$  και στην άλλη κλάση αν  $y = 0$ . Η γραμμική εξίσωση είναι

$$\sum_{j=1}^n w_j x_j - \mu = 0$$

Και ορίζει το όριο της απόφασης που διαιρεί τον χώρο σε δύο μισά.

Ο Rosenblatt [23] ανέπτυξε μια διαδικασία μάθησης για τον προσδιορισμό των βαρών και του κατωφλίου σε ένα perceptron, λαμβάνοντας υπόψη ένα σύνολο προτύπων κατάρτισης. Η διαδικασία μάθησης perceptron μπορεί να περιγραφεί ως εξής.


1. Αρχικοποίηση των βαρών και του κατωφλίου σε μικρούς τυχαίους αριθμούς.
2. Παρουσίαση ενός διανύσματος μοτίβου  $(x_1, x_2, \dots, x_n)^t$  και αξιολόγηση της εξόδου του νευρώνα.
3. Ενημέρωση των βαρών σύμφωνα με το

$$w_j(t+1) = w_j(t) + \eta(d - y)x_j$$

Όπου το  $d$  είναι η επιθυμητή έξοδος, το  $t$  είναι ο αριθμός επανάληψης και το  $\eta$  ( $0.0 < \eta < 1.0$ ) είναι το κέρδος (μέγεθος βήματος).

Σημειώστε ότι η μάθηση γίνεται μόνο όταν ένα σφάλμα γίνει από το perceptron. Ο Rosenblatt απέδειξε ότι αν τα εκπαιδευτικά πρότυπα προέρχονται από δύο γραμμικά διαχωρίσιμες κλάσεις, τότε η διαδικασία μάθησης perceptron θα συγκλίνει μετά από έναν πληθωριστικό αριθμό επαναλήψεων. Αυτό είναι το γνωστό θεώρημα σύγκλισης perceptron. Ωστόσο, στην πράξη, δεν γνωρίζουμε αν είναι γραμμικά διαχωρίσιμα ή όχι. Πολλές παραλλαγές αυτού του αλγορίθμου μάθησης έχουν προταθεί στη βιβλιογραφία. Μπορούν επίσης να χρησιμοποιηθούν και άλλες λειτουργίες ενεργοποίησης, οι οποίες οδηγούν σε διαφορετικά μαθησιακά χαρακτηριστικά. Ωστόσο, ένα ενιαίο στρώμα perceptron μπορεί να διαχωρίζει μόνο γραμμικά διαχωρίσιμα μοτίβα, εφόσον χρησιμοποιείται μία λειτουργία μονότονης ενεργοποίησης. Σημειώστε ότι οι μη μονότονες λειτουργίες ενεργοποίησης, όπως μια Gaussian λειτουργία, θα μπορούσαν να σχηματίσουν μη γραμμικά όρια αποφάσεων.

Η παρακάτω εικόνα δείχνει την τροχιά της ορίου απόφασης που εκπαιδεύτηκε, χρησιμοποιώντας ένα τροποποιημένο αλγόριθμο μάθησης perceptron για την ταξινόμηση του λογικού «ΚΑΙ» προβλήματος που είναι γραμμικά διαχωρίσιμο.



Εικόνα 23 - Σύγκλιση ενός τροποποιημένου αλγόριθμου μάθησης perceptron για το λογικό "ΚΑΙ" πρόβλημα

Ο γνωστός αλγόριθμος εκμάθησης πίσω προώθησης (backpropagation) βασίζεται επίσης στην αρχή της διόρθωσης σφαλμάτων.

### Μάθηση Boltzmann

Η μάθηση Boltzmann γίνεται μέσα από συμμετρικά επαναλαμβανόμενα δίκτυα που αποτελούνται από δυαδικές μονάδες (+1 για «on» και -1 για «off»). Με συμμετρικό τρόπο εννοούμε ότι το βάρος στη σύνδεση από τη μονάδα  $i$  στη μονάδα  $j$  είναι ίσο με το βάρος στη σύνδεση από τη μονάδα  $j$  στη μονάδα  $i$  ( $w_{ij} = w_{ji}$ ). Μόνο ένα τμήμα των νευρώνων, οι ορατοί νευρώνες, αλληλοεπιδρούν με το περιβάλλον, οι υπόλοιποι νευρώνες (νευρώνες στα κρυφά επίπεδα) είναι αόρατοι. Κάθε νευρώνας είναι μια στοχαστική μονάδα που παράγει την έξοδο (ή κατάσταση) σύμφωνα με την κατανομή Boltzmann της στατιστικής μηχανικής. Οι μηχανές Boltzmann λειτουργούν σε δύο τρόπους: σφιχτό τρόπο κατά τον οποίο ορατοί νευρώνες συσφίγγονται σε συγκεκριμένες καταστάσεις που καθορίζονται από το περιβάλλον και τρόπος ελεύθερης εκτέλεσης στην οποία επιτρέπεται η ελεύθερη λειτουργία τόσο των ορατών όσο και των κρυμμένων νευρώνων. Ο στόχος της μάθησης Boltzmann είναι να προσαρμόσει τα βάρη συνδέσεων έτσι έτσι ώστε οι καταστάσεις ορατών μονάδων να ικανοποιούν μια συγκεκριμένη επιθυμητή κατανομή πιθανότητας. Σύμφωνα με τον κανόνα μάθησης Boltzmann, η αλλαγή του βάρους σύνδεσης  $w_{ij}$  δίδεται από τον παρακάτω τύπο

$$\Delta w_{ij} = \eta(\bar{\rho}_{ij} - \rho_{ij})$$

όπου:  $\bar{\rho}_{ij}$  και  $\rho_{ij}$  είναι οι συσχετισμοί μεταξύ των καταστάσεων της μονάδας  $i$  και της μονάδας  $j$  όταν το δίκτυο λειτουργεί σε κατάσταση σφιξίματος και ελεύθερης λειτουργίας, αντίστοιχα. Οι τιμές των τιμών  $\bar{\rho}_{ij}$  και  $\rho_{ij}$  υπολογίζονται συνήθως από πειράματα Monte Carlo τα οποία είναι εξαιρετικά αργά.

Η μάθηση του Boltzmann μπορεί να θεωρηθεί ως μια ειδική περίπτωση του κανόνα διόρθωσης σφαλμάτων στην οποία το σφάλμα υπολογίζεται όχι ως η άμεση διαφορά μεταξύ της επιθυμητής απόδοσης και της πραγματικής εξόδου αλλά ως η διαφορά μεταξύ των συσχετίσεων των εξόδων δύο νευρώνων κάτω από δύο συνθήκες λειτουργίας (σφιγμένη και ελεύθερη λειτουργία).

### Μάθηση Hebbian

Ο παλαιότερος, αλλά ακόμα χρησιμοποιούμενος, κανόνας μάθησης είναι ο ισχυρισμός του Hebb για μάθηση [22]. Προτάθηκε από τον Hebb βάσει της ακόλουθης παρατήρησης από νευροβιολογικά

πειράματα: Όταν ένα άξονας ενός κυττάρου A είναι αρκετά κοντά για να διεγείρει ένα κύτταρο B και συμμετέχει επανειλημμένα ή επίμονα στην ενεργοποίησή του, κάποια διαδικασία ανάπτυξης ή μεταβολικές αλλαγές συμβαίνουν σε μία ή και τα δύο κύτταρα έτσι ώστε να αυξάνεται η αποτελεσματικότητα του A ως ένα από τα κύτταρα που πυροδοτούν το B. Με άλλα λόγια, αν δύο νευρώνες στην κάθε πλευρά μιας συνάψεως ενεργοποιούνται συγχρόνως και επανειλημμένα, τότε η ισχύς αυτής της συνάψεως αυξάνεται επιλεκτικά [21]. Μια τέτοια σύναψη συχνά αναφέρεται ως σύναψη του Hebb ή συσχετιστική σύναψη επειδή η αλλαγή της ισχύος της συνάψεως εξαρτάται από τη συσχέτιση μεταξύ των προσυναπτικών και των μετασυναπτικών δραστηριοτήτων.

Μαθηματικά, η ενημέρωση της συνάψεως του Hebb μπορεί να περιγραφεί ως

$$w_{ij}(t + 1) = w_{ij}(t) + \eta y_i(t)x_j(t)$$

όπου  $x_i$  και  $y_j$  είναι οι τιμές εξόδου των νευρώνων  $i$  και  $j$ , αντίστοιχα, οι οποίες συνδέονται με την σύναψη  $w_{ij}$  και  $\eta$  είναι το ποσοστό εκμάθησης. Το  $x_i$  είναι η είσοδος στην σύναψη.


Μια σημαντική ιδιότητα αυτού του κανόνα είναι ότι η εκμάθηση γίνεται τοπικά, δηλαδή η αλλαγή του βάρους της συνάψεως εξαρτάται μόνο από τις δραστηριότητες των δύο νευρώνων που συνδέονται από αυτήν. Αυτό απλοποιεί σημαντικά την πολυπλοκότητα του κύκλου μάθησης σε μια εφαρμογή VLSI

Ένα πρόβλημα με αυτόν τον κανόνα μάθησης είναι ότι τα βάρη σύνδεσης θα αυξηθούν απεριόριστα καθώς προχωρά η μάθηση. Για να αντιμετωπιστεί αυτό το πρόβλημα, έχουν προταθεί πολλές τροποποιήσεις στον βασικό κανόνα του Hebbian [21]. Για παράδειγμα, ο κανόνας της Oja προσθέτει μια αποσύνθεση βάρους ανάλογη προς το  $y_j^2$  με τον βασικό κανόνα Hebbian:

$$w_{ij}(t + 1) = w_{ij}(t) + \eta y_i(t)(x_j(t) - y_j(t)w_{ij})$$

Είναι ενδιαφέρον να σημειωθεί ότι αυτός ο κανόνας είναι παρόμοιος με τον αντίστροφο κανόνα διόρθωσης σφαλμάτων το  $\Delta w_{ij}$  εξαρτάται από τη διαφορά μεταξύ της πραγματικής εισόδου και της οπίσθιας διάδοσης εξόδου.

Ένας μόνος νευρώνας που εκπαιδεύεται χρησιμοποιώντας τον κανόνα Hebbian επιδεικνύει μια εκλεκτικότητα προσανατολισμού. Το σχήμα 24 δείχνει αυτήν την ιδιότητα. Τα σημεία που απεικονίζονται στο Σχήμα 24 αντλούνται από μια διδιάστατη Gaussian κατανομή και χρησιμοποιούνται για την εκπαίδευση ενός νευρώνα. Ο φορέας βάρους του νευρώνα αρχικοποιείται στο  $w_0$  όπως φαίνεται στο σχήμα. Καθώς προχωρά η μάθηση, ο φορέας βάρους κινείται πλησιέστερα προς την κατεύθυνση  $w$  της μέγιστης διακύμανσης των δεδομένων.




Εικόνα 24 - Επιλεκτικότητα προσανατολισμού ενός μόνο νευρώνα

Είναι σωστό να γενικεύσουμε την παραπάνω συμπεριφορά μίας μόνο μονάδας και να καταλήξουμε στο συμπέρασμα ότι ένα μονοστρωματικό feedforward δίκτυο με μονάδες εξόδου  $m$  μπορεί να εξαγάγει τα πρώτα  $m$  κύρια στοιχεία των  $n$  διαστάσεων δεδομένων,  $n$ . Λόγω της ορθογωνιότητας των ιδιοδιανύσμων, τα άλλα κύρια στοιχεία ( $m - 1$ ) βρίσκονται στον υποπεριοχή που είναι κάθετη προς το πρώτο κύριο συστατικό που αντιστοιχεί στο μεγαλύτερο ιδιοδιάνυσμα. Επομένως, τα βασικά συστατικά ( $m - 1$ ) μπορούν να καθοριστούν αναδρομικά σε υπό-χώρους με τρόπο παρόμοιο με τον υπολογισμό του πρώτου στοιχείου. Έχουν προταθεί αρκετές πιο μέθοδοι για τον υπολογισμό των κύριων συνιστωσών ταυτόχρονα επιβάλλοντας ορισμένους περιορισμούς στις δραστηριότητες των μονάδων εξόδου[21].

### Κανόνες ανταγωνιστικής μάθησης

Σε αντίθεση με την εκμάθηση Hebbian, όπου πολλαπλές μονάδες εξόδου μπορούν να ενεργοποιηθούν ταυτόχρονα, σε ανταγωνιστική εκμάθηση όλες οι μονάδες εξόδου ανταγωνίζονται μεταξύ τους για να ενεργοποιηθούν. Ως αποτέλεσμα αυτού του ανταγωνισμού, μόνο μία μονάδα εξόδου, ή μόνο μία ανά ομάδα, είναι ενεργή ανά πάσα στιγμή. Αυτό το φαινόμενο είναι συχνά γνωστό ως winner-take-all (ο νικητής τα παίρνει όλα). Η ανταγωνιστική μάθηση διαπιστώθηκε ότι υπάρχει στα βιολογικά νευρωνικά δίκτυα. Τα νευροβιολογικά πειράματα έχουν δείξει ότι η ανταγωνιστική μάθηση παίζει σημαντικό ρόλο στο σχηματισμό τοπογραφικών χαρτών στον εγκέφαλο και στην αυτό-οργάνωση ευαίσθητων στο προσανατολισμό νευρικών κυττάρων στον φλοιό του ραβδωτού σώματος. Το αποτέλεσμα της ανταγωνιστικής μάθησης είναι συχνά ομαδοποίηση ή κατηγοριοποίηση των δεδομένων εισόδου. Παρόμοια μοτίβα ομαδοποιούνται από το δίκτυο και αντιπροσωπεύονται από μια ενιαία μονάδα. Αυτή η διαδικασία ομαδοποίησης γίνεται από το δίκτυο αυτόματα με βάση τις συσχετίσεις στα δεδομένα. Το απλούστερο ανταγωνιστικό δίκτυο εκμάθησης αποτελείται από ένα μόνο στρώμα μονάδων εξόδου όπως φαίνεται στο σχήμα 25.



Εικόνα 25 - Μια απλή ανταγωνιστική αρχιτεκτονική μάθησης.

Κάθε μονάδα εξόδου  $i$  στο δίκτυο συνδέεται με όλες τις μονάδες εισόδου μέσω βαρών  $w_{ij}$ ,  $j = 1, 2, \dots, \delta$ . Κάθε μονάδα εξόδου συνδέεται επίσης με όλες τις άλλες μονάδες εξόδου μέσω ανασταλτικών βαρών, αλλά έχει αυτοαναρροδοτότητα με ένα διεγερτικό βάρος. Ως αποτέλεσμα του ανταγωνισμού, μόνο η μονάδα με τη μεγαλύτερη (ή τη μικρότερη) καθαρή είσοδο καθίσταται ο νικητής, δηλ.

$$w_{i^*} x \geq w_i x \quad \forall i$$


Ή

$$\|w_{i^*} - x\| \leq \|w_i - x\| \quad \forall i$$

Όταν όλοι οι φορείς βάρους είναι κανονικοποιημένοι, αυτές οι δύο ανισότητες είναι ισοδύναμες. Ένας απλός κανόνας ανταγωνιστικής μάθησης μπορεί να δηλωθεί ως εξής.

$$\Delta w_{ij} = \begin{cases} \eta(x_j^{\mu} - w_{ij}), & i = i^* \\ 0, & i \neq i^* \end{cases}$$

Μόνο τα βάρη της μονάδας νικητή ενημερώνονται. Η επίδραση αυτού του κανόνα μάθησης είναι η μετακίνηση του αποθηκευμένου μοτίβου στη μονάδα νικητή (βάρη) λίγο πιο κοντά στο μοτίβο εισαγωγής. Μια γεωμετρική ερμηνεία της ανταγωνιστικής μάθησης παρουσιάζεται στο Σχήμα 26. Σε αυτό το παράδειγμα, υποθέτουμε ότι όλοι οι φορείς εισόδου έχουν κανονικοποιηθεί ώστε να έχουν μήκος μονάδας και παρουσιάζονται ως μαύρες κουκίδες στο σχήμα 26 (α). Οι φορείς βάρους των τριών μονάδων αρχικοποιούνται τυχαία.




Εικόνα 26 - Παράδειγμα ανταγωνιστικής μάθησης: (α) πριν από τη μάθηση. (β) μετά την εκμάθηση

Οι αρχικές θέσεις και οι τελικές θέσεις τους στη σφαίρα μετά την ανταγωνιστική μάθηση παρουσιάζονται ως σταυροί στις Εικόνες 26(α) και 26(β), αντίστοιχα. Όπως μπορούμε να δούμε από το Σχήμα 26, καθεμία από τις τρεις φυσικές ομάδες μοτίβων έχει ανακαλυφθεί από μια μονάδα εξόδου της οποίας το διάνυσμα βάρους δείχνει στο κέντρο βάρους της ομάδας που ανακαλύφθηκε.

Μπορεί κανείς να δει από τον ανταγωνιστικό κανόνα μάθησης ότι το δίκτυο δεν θα σταματήσει ποτέ να μαθαίνει (ενημέρωση βαρών) εκτός αν το ποσοστό εκμάθησης  $\eta$  είναι μηδέν. Είναι πιθανό ότι ένα συγκεκριμένο μοτίβο μπορεί να πυροδοτήσει διαφορετικές μονάδες εξόδου (κατηγορίες αλλαγής) για πάντα κατά τη διάρκεια της μάθησης. Αυτό αναδεικνύει το ζήτημα της σταθερότητας ενός συστήματος εκμάθησης. Ένα σύστημα εκμάθησης λέγεται ότι είναι σταθερό εάν κανένα πρότυπο στα δεδομένα εκπαίδευσης δεν αλλάζει την κατηγορία του μετά από έναν πεπερασμένο αριθμό επαναλήψεων μάθησης. Ένας τρόπος επίτευξης της σταθερότητας είναι να αναγκαστεί ο ρυθμός εκμάθησης να μειωθεί σταδιακά καθώς προχωρά η διαδικασία μάθησης και επομένως πλησιάζει στο μηδέν. Ωστόσο, αυτό το τεχνητό πάγωμα της μάθησης προκαλεί ένα άλλο πρόβλημα

ελαστικότητας, το οποίο ορίζεται ως η ικανότητα προσαρμογής στα νέα δεδομένα. Αυτό είναι το γνωστό δίλημμα σταθερότητας-ελαστικότητας του Grossberg στην ανταγωνιστική μάθηση.

Ίσως, το πιο γνωστό παράδειγμα ανταγωνιστικής μάθησης είναι η κβαντοποίηση διανύσματος για συμπίεση δεδομένων. Η κβαντοποίηση διανύσματος έχει χρησιμοποιηθεί ευρέως στην επεξεργασία ομιλίας και εικόνας για αποτελεσματική αποθήκευση, μετάδοση και μοντελοποίηση. Ο στόχος της κβαντοποίηση διανύσματος είναι να αντιπροσωπεύει ένα σύνολο ή κατανομή των φορέων εισόδου από σχετικά μικρό αριθμό πρωτότυπων φορέων (φορείς βάρους) ή βιβλίου κωδίκων. Μόλις δημιουργηθεί και συμφωνηθεί ένα βιβλίο κωδίκων, μπορούμε να μεταδώσουμε ή να αποθηκεύσουμε μόνο τον δείκτη του αντίστοιχου πρωτοτύπου στο διάνυσμα εισαγωγής. Με δεδομένο ένα διάνυσμα εισόδου, το αντίστοιχο πρωτότυπο μπορεί να βρεθεί με αναζήτηση του πλησιέστερου πρωτοτύπου στο βιβλίο κωδικών. Εάν χρησιμοποιείται η Ευκλείδεια απόσταση, διαιρείται ο χώρος εισόδου σε μια εκροή Voronoi. Ο κανόνας ανταγωνιστικής μάθησης στην προηγούμενη εξίσωση μπορεί να χρησιμοποιηθεί για τη δημιουργία ενός βιβλίου κωδικών για μια δεδομένη ομάδα φορέων εισόδου.



Εικόνα 27 - (α) VQ (b) LVQ.

Τα μοτίβα από δύο κατηγορίες είναι επισημασμένα με τρίγωνα και κύκλους, αντίστοιχα. Τα συμπαγή σχέδια είναι έμπνευση πρωτοτύπων.

Το βιβλίο κωδίκων και η εξομάλυνση Voronoi που παράγεται από τον κανόνα της μη εποπτευόμενης ανταγωνιστικής μάθησης μπορεί να μην είναι το καλύτερο για σκοπούς ταξινόμησης προτύπων (Εικόνα 27 (α)). Η εκμάθηση διανύσματος κβαντισμού (LVQ) είναι μια εποπτευόμενη τεχνική ανταγωνιστικής μάθησης η οποία χρησιμοποιεί πληροφορίες κλάσης μοτίβου για να προσαρμόσει ελαφρώς τους φορείς Voronoi, έτσι ώστε να βελτιωθεί η ακρίβεια της ταξινόμησης. Στο LVQ, ο κανόνας ενημέρωσης βάρους αντικαθίσταται από

$$w_c(t+1) = \begin{cases} w_c(t) + \eta(t)[x(t) - w_c(t)], & \text{Εάν το } x(t) \text{ έχει κατηγοριοποιηθεί} \\ & \text{σωστά από την μονάδα } c \\ w_c(t) - \eta(t)[x(t) - w_c(t)], & \text{σε κάθε άλλη περίπτωση} \end{cases}$$

Η Εικόνα 27(b) καταδεικνύει την επίδραση του LVQ. Μετακινεί τα πρωτότυπα που έχουν εκπαιδευτεί χρησιμοποιώντας τον αλγόριθμο VQ ελαφρώς προς τα αριστερά για να ταξινομήσει όλα τα μοτίβα σωστά.

### Περίληψη αλγορίθμων μάθησης

Διάφοροι αλγόριθμοι μάθησης και οι σχετικές αρχιτεκτονικές δικτύων τους συνοψίζονται στον παρακάτω πίνακα.

Learning Paradigm	Learning Rule	Architecture	Learning Algorithm	Task	
<b>Supervised</b>	Error-correction	Single or Multi-layer Perceptron	Perceptron learning algorithms	Pattern Classification	
			Backpropagation	Function Approximation	
			ADALINE & MADALINE	Control	
	Boltzmann	Multi-layer Feedforward	Boltzmann Learning algorithm	Pattern Classification	
	Hebbian	Multi-layer Feedforward	Linear Discriminant Analysis	Data Analysis Pattern Classification	
	Competitive	Competitive	Learning Vector Quantization	Within-Class Categorization	
				Data Compression	
ART network			ARTMAP	Pattern Classification Within-Class Categorization	
<b>Unsupervised</b>	Error-correction	Multi-layer Feedforward	Sammon's projection	Data Analysis	
	Hebbian	Feedforward or Competitive	Principal Component Analysis	Data Analysis Data Compression	
			Hopeld Net	Associative memory learning	Associative Memory
	Competitive	Competitive	Vector Quantization	Categorization Data Compression	
			Kohonen SOM	Kohonen's SOM	Categorization Data Analysis
			ART networks	ART1, ART2	Categorization
<b>Hybrid</b>	Error-correction and Competitive	RBF network	RBF Learning algorithm	Pattern Classification Function Approximation Control	

Ωστόσο, δεν είναι καθόλου εξαντλητικός ο παραπάνω κατάλογος των αλγορίθμων μάθησης, με βάση αυτούς που είναι διαθέσιμοι στη βιβλιογραφία. Παρατηρούμε ότι τόσο τα εποπτευόμενα όσο και τα μη εποπτευόμενα παραδείγματα μάθησης χρησιμοποιούν κανόνες μάθησης που βασίζονται στη διόρθωση σφαλμάτων, στην Hebbian και στην ανταγωνιστική μάθηση. Οι κανόνες εκμάθησης βασισμένοι στη διόρθωση σφαλμάτων μπορούν να χρησιμοποιηθούν για την κατάρτιση δικτύων προώθησης, ενώ οι κανόνες μάθησης Hebbian έχουν χρησιμοποιηθεί για όλους τους τύπους αρχιτεκτονικών δικτύων. Ωστόσο, κάθε αλγόριθμος μάθησης έχει σχεδιαστεί για την εκπαίδευση μιας συγκεκριμένης αρχιτεκτονικής δικτύου. Επομένως, όταν μιλάμε για έναν αλγόριθμο μάθησης, υπονοείται ότι υπάρχει μια συγκεκριμένη αρχιτεκτονική δικτύου που συνδέεται με αυτό. Κάθε αλγόριθμος μάθησης σχεδιάζεται επίσης για την εκτέλεση μίας ή μερικών συγκεκριμένων εργασιών. Η τελευταία στήλη του πίνακα 3 παραθέτει έναν αριθμό εργασιών που μπορεί να εκτελέσει κάθε αλγόριθμος μάθησης



### 4.6.3 Θεωρία μάθησης

Η θεωρία της μάθησης πρέπει να αντιμετωπίσει τρία θεμελιώδη και πρακτικά ζητήματα που σχετίζονται με τη μάθηση από παραδείγματα, ικανότητα, πολυπλοκότητα δείγματος, πολυπλοκότητα του χρόνου.

Το πρώτο ζήτημα αφορά το εάν η σωστή λύση περιέχεται στο σύνολο των λύσεων που μπορεί να προσφέρει ένα δίκτυο. Εάν όχι, δεν μπορούμε ποτέ να ελπίζουμε να επιτύχουμε τη βέλτιστη λύση. Αυτό παραμένει ένα δύσκολο και ανοιχτό πρόβλημα. Οι δυνατότητες προσέγγισης των κεκτημένων νευρωνικών δικτύων έχουν πρόσφατα ερευνηθεί από πολλούς ερευνητές. Ένα θεμελιώδες αποτέλεσμα αυτών των μελετών είναι ότι δίκτυα τροφοδοσίας τριών επιπέδων ή ακόμα και δύο επιπέδων, με έναν αυθαίρετα μεγάλο αριθμό μη γραμμικών κρυφών μονάδων, είναι σε θέση να υλοποιήσουν οποιαδήποτε συνεχή χαρτογράφηση με ακρίβεια προαπαιτούμενης υπό ορισμένες ήπιες συνθήκες. Δυστυχώς, οι περισσότερες από αυτές τις θεωρητικές μελέτες αγνοούν το πρόβλημα της μαθησιακότητας που αφορά το εάν υπάρχουν μέθοδοι για να μάθουν τα βάρη του δικτύου από εμπειρικές παρατηρήσεις των αντιστοιχιών.

Το δεύτερο ζήτημα, η πολυπλοκότητα του δείγματος, καθορίζει τον αριθμό των προτύπων κατάρτισης που απαιτούνται για την κατάρτιση του δικτύου, προκειμένου να διασφαλιστεί μια έγκυρη γενίκευση. Πολύ λίγα μοτίβα μπορεί να προκαλέσουν το πρόβλημα «Over-Fitting» όπου το δίκτυο λειτουργεί καλά στο σύνολο δεδομένων εκπαίδευσης, αλλά με χαμηλή απόδοση σε νέα σύνολα δεδομένων που προέρχονται από την ίδια κατανομή με τα πρότυπα εκπαίδευσης.

Το τρίτο ζήτημα είναι η υπολογιστική πολυπλοκότητα του αλγορίθμου μάθησης που χρησιμοποιείται για την εκτίμηση μιας λύσης από τα πρότυπα εκπαίδευσης. Πολλοί υπάρχοντες αλγόριθμοι μάθησης έχουν υψηλή υπολογιστική πολυπλοκότητα. Για παράδειγμα, ο δημοφιλής αλγόριθμος εκμάθησης backpropagation για feedforward δίκτυα απαιτεί υψηλή υπολογιστική ισχύ λόγω της αργής σύγκλισης.

Στις περισσότερες εφαρμογές ΤΝΔ χρησιμοποιείται μάθηση υπό επίβλεψη, για την οποία υπάρχουν αρκετοί αλγόριθμοι. Στον αλγόριθμο που βασίζεται στον κανόνα Δέλτα (Delta rule learning), η διαφορά μεταξύ πραγματικής και επιθυμητής εξόδου ελαχιστοποιείται μέσω μιας διαδικασίας ελαχίστων τετραγώνων. Στον αλγόριθμο ανάστροφης μετάδοσης λάθους (back propagation) η μεταβολή των βαρών βασίζεται στον υπολογισμό της συνεισφοράς κάθε βάρους στο συνολικό σφάλμα. νευρώνες συναγωνίζονται, κατά κάποιο τρόπο, μεταξύ τους και μόνο αυτός με τη μεγαλύτερη απόκριση σε δοθείσα είσοδο τροποποιεί τα βάρη του. Τέλος, στη τυχαία μάθηση (random learning), οι μεταβολές στα βάρη εισάγονται τυχαία και ανάλογα με το αν η έξοδος βελτιώνεται ή όχι με βάση κάποια προκαθορισμένα από το χρήστη κριτήρια, οι μεταβολές αυτές υιοθετούνται ή απορρίπτονται.

Η εκπαίδευση μπορεί να γίνει με δύο τρόπους πρόσληψης δεδομένων. Είτε με ομάδες δεδομένων (batch) και η εκπαίδευση θα ξεκινήσει αφού όλα τα δεδομένα εκπαίδευσης είναι διαθέσιμα στο δίκτυο και ονομάζετε offline. Είτε με online τεχνική όπου το νευρωνικό δίκτυο εκπαιδεύεται όπως έρχονται τα δεδομένα και εφαρμόζει προοδευτική εκπαίδευση όπου θα αναλυθεί στο επόμενο κεφάλαιο.

## 5 Μέθοδοι σταδιακής μάθησης ΤΝΔ

Μέθοδοι σταδιακής μάθησης τεχνητών νευρωνικών δικτύων είναι η τεχνική στην οποία τα δεδομένα εισόδου χρησιμοποιούνται συνεχώς για την επέκταση των γνώσεων του υπάρχοντος μοντέλου, δηλ. για την περαιτέρω εκπαίδευση του μοντέλου. Αντιπροσωπεύει μια δυναμική τεχνική εποπτευόμενης μάθησης και μάθησης χωρίς επίβλεψη που μπορεί να εφαρμοστεί όταν τα δεδομένα εκπαίδευσης διατίθενται σταδιακά με την πάροδο του χρόνου ή το μέγεθός τους είναι εκτός ορίων μνήμης του συστήματος. Οι αλγόριθμοι που μπορούν να διευκολύνουν την αυξητική μάθηση είναι γνωστοί ως αυξητικοί αλγόριθμοι μηχανικής μάθησης (Incremental learning algorithms).

Πολλοί παραδοσιακοί αλγόριθμοι εκμάθησης μηχανών υποστηρίζουν εγγενώς την προοδευτική εκπαίδευση, άλλοι αλγόριθμοι μπορούν να προσαρμοστούν για να διευκολυνθεί αυτό. Οι πιο διαδεδομένοι αλγόριθμοι που θα παρουσιάσουμε είναι οι Fuzzy ARTMAP, TopoART, Learn ++, και NEAT.

Ο στόχος της προοδευτικής μάθησης είναι να προσαρμοστεί το μαθησιακό μοντέλο στα νέα δεδομένα χωρίς να ξεχνάει τις υπάρχουσες γνώσεις του, χωρίς δεν να προβαίνουν σε επανεκπαίδευση του μοντέλου. Μερικοί προοδευτικοί αλγόριθμοι εκπαίδευσης έχουν ενσωματώσει κάποιες παραμέτρους ή υποθέσεις που ελέγχουν τη συνάφεια των παλαιών δεδομένων, ενώ άλλοι, που ονομάζονται σταθεροί αυξητικοί αλγόριθμοι μηχανικής μάθησης, μαθαίνουν αναπαραστάσεις των δεδομένων κατάρτισης που δεν έχουν μερικώς ξεχαστεί με την πάροδο του χρόνου. Το Fuzzy ART και το TopoART αποτελούν δύο παραδείγματα αυτής της δεύτερης προσέγγισης.

Οι προοδευτικοί αλγόριθμοι εφαρμόζονται συχνά σε ροές δεδομένων ή σε μεγάλα δεδομένα, αντιμετωπίζοντας θέματα σχετικά με τη διαθεσιμότητα δεδομένων και την έλλειψη πόρων αντίστοιχα. Η πρόβλεψη της τάσης του αποθέματος και η δημιουργία προφίλ χρηστών είναι μερικά παραδείγματα ροών δεδομένων, όπου νέα δεδομένα καθίστανται συνεχώς διαθέσιμα. Η εφαρμογή της σταδιακής εκμάθησης σε μεγάλα δεδομένα στοχεύει να παράγει ταχύτερους χρόνους ταξινόμησης ή πρόβλεψης [24].

Για να θεωρήσουμε ότι ένας αλγόριθμος μπορεί να υποστηρίξει προοδευτική εκπαίδευση πρέπει να πληρεί τα ακόλουθα κριτήρια:

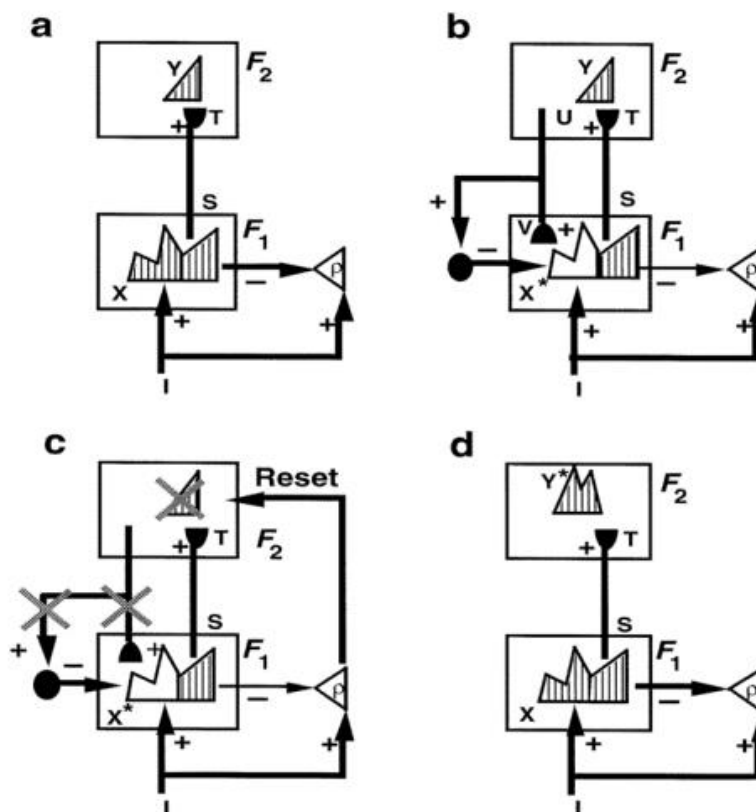
- 1) Θα πρέπει να είναι σε θέση να μάθει επιπλέον πληροφορίες από τα νέα δεδομένα εκπαίδευσης.
- 2) Δεν θα πρέπει να απαιτεί πρόσβαση στα αρχικά δεδομένα που χρησιμοποιούνται για την κατάρτιση του υφιστάμενου ταξινομητή.
- 3) Θα πρέπει να διατηρεί προηγουμένως αποκτημένη γνώση (δηλαδή δεν πρέπει να υποφέρει από catastrophic forgetting)
- 4) Θα πρέπει να είναι σε θέση να εκπαιδευτεί και με νέες κλάσεις που ίσως εμφανιστούν με τα νέα δεδομένα.

### 5.1 Αλγόριθμος ART

Η θεωρία Adaptive Resonance ή ART είναι μια θεωρία για το πώς ο εγκέφαλος γρήγορα μαθαίνει να κατηγοριοποιεί, να αναγνωρίζει και να προβλέπει τα αντικείμενα και τα γεγονότα σε έναν μεταβαλλόμενο κόσμο. Η ART αποσαφηνίζει τις διαδικασίες του εγκεφάλου από τις οποίες προκύπτουν συνειδητές εμπειρίες. Προβλέπει μια λειτουργική σχέση μεταξύ των διαδικασιών συνειδησης, μάθησης, προσδοκιών, προσοχής, συντονισμού και συγχρονισμού, συμπεριλαμβανομένης της πρόβλεψης ότι "όλες οι συνειδητές καταστάσεις είναι συντονισμένες καταστάσεις". Η σύνδεση αυτή διευκρινίζει πώς η δυναμική του εγκεφάλου επιτρέπει στο άτομο να

προσαρμόζεται αυτόνομα σε πραγματικό χρόνο σε έναν ταχέως μεταβαλλόμενο κόσμο. Η ART προβλέπει πως η προσοχή από πάνω προς τα κάτω λειτουργεί και ρυθμίζει την ταχεία σταθερή εκμάθηση των κατηγοριών αναγνώρισης. Συγκεκριμένα, η ART διατυπώνει έναν κρίσιμο ρόλο για τις "συντονισμένες" καταστάσεις οδηγώντας σε ταχείας σταθερής μάθησης, εξ ου και η ονομαστική προσαρμοστική απήχηση. Αυτές οι αντηχείς καταστάσεις συνδέονται, χρησιμοποιώντας από πάνω προς τα κάτω σχολαστική ανατροφοδότηση με τη μορφή των εκπαιδευμένων προσδοκιών, σε συνεκτικές παραστάσεις του κόσμου. Η ART αποσαφηνίζει μια σημαντική έννοια στην οποία ο εγκέφαλος πραγματοποιεί υπολογισμό πρόβλεψης. Η ART εξήγησε και προέβλεψε με επιτυχία ένα ευρύ φάσμα συμπεριφορών και νευρολογικών δεδομένων, συμπεριλαμβανομένων των δεδομένων για την ανθρώπινη γνώση και τη δυναμική των ελασματοειδών φλοιωδών δικτύων. Οι αλγόριθμοι ART έχουν χρησιμοποιηθεί σε εφαρμογές μεγάλης κλίμακας όπως η πρόβλεψη ιατρικών δεδομένων, η απομακρυσμένη αίσθηση, ο σχεδιασμός αεροπλάνων και ο έλεγχος των αυτόνομων προσαρμοστικών ρομπότ.

Το βασικό σύστημα ART είναι ένα μοντέλο μάθησης χωρίς επίβλεψη. Συνήθως αποτελείται από ένα πεδίο σύγκρισης και ένα πεδίο αναγνώρισης που αποτελείται από νευρώνες, μια παράμετρο επαγρύπνησης (κατώφλι αναγνώρισης) και μια ενότητα επαναφοράς. Στην επόμενη εικόνα μπορούμε να δούμε πως ακριβώς λειτουργεί ο αλγόριθμος.



Εικόνα 28 - κύκλωμα εκπαίδευσης ART

Βήμα (α) Το μοτίβο εισόδου I δημιουργείται σε όλους τους ανιχνευτές χαρακτηριστικών στο επίπεδο F1 ως πρότυπο δραστηριότητας βραχυπρόθεσμης μνήμης (STM) X. Η είσοδος I ενεργοποιεί επίσης μη ειδικώς το σύστημα προσανατολισμού με κέρδος που καλείται επαγρύπνηση ( $\rho$ ). δηλαδή, όλες οι διαδρομές εισόδου συγκλίνουν με κέρδος  $\rho$  στο σύστημα προσανατολισμού και προσπαθούν

να την ενεργοποιήσουν. Το STM μοτίβο του X αντιπροσωπεύεται από το γραμμοσκιασμένο σχέδιο στο επίπεδο F1. Το μοτίβο X αναστέλλει το σύστημα προσανατολισμού και παράγει το μοτίβο εξόδου S. Το μοτίβο S πολλαπλασιάζεται με τα μαθησιακά προσαρμοστικά βάρη, που ονομάζονται επίσης ίχνη μακροχρόνιας μνήμης (LTM). Αυτά τα σηματοδοτημένα με LTM σήματα προστίθενται στο επίπεδο F2 για να σχηματίσουν το πρότυπο εισόδου T, το οποίο ενεργοποιεί το μοτίβο STM Y σε όλες τις κατηγορίες αναγνώρισης που κωδικοποιούνται στο επίπεδο F2.

Βήμα (b) Το μοτίβο Y δημιουργεί το "από πάνω προς τα κάτω" μοτίβο εξόδου U, το οποίο πολλαπλασιάζεται με "από πάνω προς τα κάτω" ίχνη του LTM και προστίθεται στους κόμβους F1 για να σχηματίσει ένα πρωτότυπο μοτίβο V που κωδικοποιεί την αποκτηθείσα προσδοκία των ενεργών κόμβων F2. Ένα τέτοιο πρωτότυπο αντιπροσωπεύει το σύνολο των κοινόχρηστων χαρακτηριστικών σε όλα τα πρότυπα εισόδου που είναι ικανά να ενεργοποιήσουν το Y. Εάν το V δεν αντιστοιχεί στο I στο F1, τότε στο F1 επιλέγεται ένα νέο πρότυπο δραστηριότητας STM X\*. Το X\* αντιπροσωπεύεται από το νέο μοτίβο. Αποτελείται από τα χαρακτηριστικά του I που επιβεβαιώνονται από το V. Τα χαρακτηριστικά που δεν επιβεβαιώνονται, παρεμποδίζονται. Οι απενεργοποιημένοι κόμβοι που αντιστοιχούν σε μη επιβεβαιωμένα χαρακτηριστικά του X είναι ασύγκριτοι. Η μείωση της ολικής δραστηριότητας του STM που συμβαίνει όταν το X μετασχηματίζεται σε X\* προκαλεί μείωση της ολικής αναστολής από το F1 προς τον προσανατολισμό

Βήμα (γ) Αν η αναστολή μειώνεται επαρκώς, το σύστημα προσανατολισμού απελευθερώνει ένα μη εξειδικευμένο κύμα διέγερσης στο F2, δηλαδή, ένα κύμα ενεργοποίησης που ενεργοποιεί εξίσου όλους τους κόμβους F2. Αυτό το κύμα δημιουργεί τη διαίσθηση ότι "προκαλούν νέα γεγονότα". Αυτό το κύμα διέγερσης επαναφέρει το πρότυπο STM Y στο F2 παρεμποδίζοντας το Y.

Βήμα (δ) Αφού αναστέλλεται το Y, απομακρύνεται το πρωτότυπο του "από πάνω προς τα κάτω" και το X μπορεί να αποκατασταθεί στο F1. Το γεγονός της προηγούμενης επαναφοράς διατηρεί την αναστολή του Y κατά τη διάρκεια του κύκλου αναζήτησης. Ως αποτέλεσμα, το X μπορεί να ενεργοποιήσει ένα διαφορετικό πρότυπο STM Y στο F2. Εάν το πρωτότυπο "από πάνω προς τα κάτω" λόγω αυτού του νέου μοτίβου Y επίσης δεν αντιστοιχεί το I στο F1, τότε η αναζήτηση ενός κατάλληλου κώδικα F2 συνεχίζεται μέχρι να επιλεγεί μια πιο κατάλληλη αναπαράσταση F2.

Ένας τέτοιος κύκλος αναζήτησης αντιπροσωπεύει έναν τύπο δοκιμής μη στατικών υποθέσεων. Όταν ολοκληρωθεί η αναζήτηση, αναπτύσσεται ένας προσεκτικός συντονισμός και ξεκινά η εκμάθηση των δεδομένων που παρακολούθησατε.

Υπάρχουν δύο βασικές μέθοδοι εκπαίδευσης των νευρωνικών δικτύων ART: αργή και γρήγορη. Στη μέθοδο αργής εκμάθησης, ο βαθμός εξάσκησης των βαρών του νευρώνα αναγνώρισης προς τον διάνυσμα εισόδου υπολογίζεται σε συνεχείς τιμές με διαφορικές εξισώσεις και επομένως εξαρτάται από το χρονικό διάστημα που παρουσιάζεται ο φορέας εισόδου. Με την γρήγορη εκμάθηση, οι αλγεβρικές εξισώσεις χρησιμοποιούνται για τον υπολογισμό του βαθμού προσαρμογών βάρους που πρέπει να γίνουν και χρησιμοποιούνται δυαδικές τιμές. Ενώ η γρήγορη εκμάθηση είναι αποτελεσματική για μια ποικιλία εργασιών, η μέθοδος αργής εκμάθησης είναι πιο βιολογικά εύλογη και μπορεί να χρησιμοποιηθεί με δίκτυα συνεχούς χρόνου (δηλαδή όταν ο φορέας εισόδου μπορεί να μεταβάλλεται συνεχώς) [25].

Ο βασικός αλγόριθμος ART έχει πολλούς τύπους ανάλογα με την εφαρμογή. Οι βασικότεροι τύποι είναι τα παρακάτω

- 1) ART 1 είναι η απλούστερη ποικιλία των δικτύων ART, δέχεται μόνο δυαδικές εισόδους.
- 2) ART 2 επεκτείνει τις δυνατότητες δικτύου για την υποστήριξη συνεχών εισόδων.

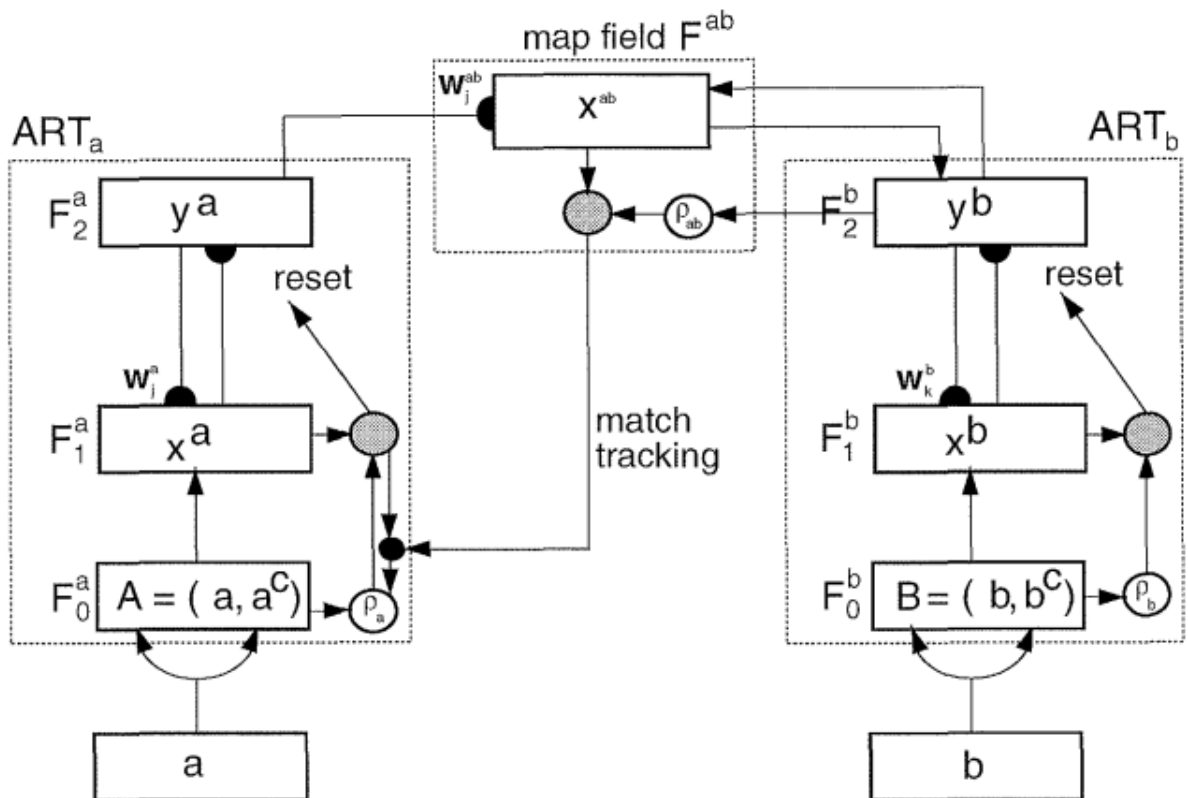
- 3) ART 2-A είναι μια βελτιωμένη μορφή ART-2 με δραστικά επιταχυνόμενη διάρκεια εκτέλεσης και με ποιοτικά αποτελέσματα που είναι σπάνια κατώτερα από την πλήρη υλοποίηση του ART-2.
- 4) ART 3 βασίζεται στο ART-2 με προσομοίωση της στοιχειώδους ρύθμισης του νευροδιαβιβαστή της συναπτικής δραστηριότητας με την ενσωμάτωση προσομοιωμένων συγκεντρώσεων ιόντων νατρίου ( $\text{Na}^+$ ) και ασβεστίου ( $\text{Ca}^{2+}$ ) στις εξισώσεις του συστήματος, με αποτέλεσμα ένα πιο φυσιολογικά ρεαλιστικό μέσο μερικής αναστολής κατηγοριών η αναντιστοιχία σκανδαλισμού ενεργοποιείται.
- 5) ARTMAP, επίσης γνωστό ως Predictive ART, συνδυάζει δύο ελαφρώς τροποποιημένες μονάδες ART-1 ή ART-2 σε μια εποπτευόμενη δομή μάθησης όπου η πρώτη μονάδα λαμβάνει τα δεδομένα εισόδου και η δεύτερη μονάδα λαμβάνει τα σωστά δεδομένα εξόδου, τότε κάνει τον συνδυασμό για να κάνει την ελάχιστη δυνατή ρύθμιση της παραμέτρου επαγρύπνησης στην πρώτη μονάδα προκειμένου να γίνει η σωστή ταξινόμηση [26].
- 6) Το Fuzzy ART υλοποιεί την ασαφή λογική στην αναγνώριση προτύπων του ART, ενισχύοντας έτσι τη γενικευσιμότητα του αλγορίθμου. Ένα προαιρετικό (και πολύ χρήσιμο) χαρακτηριστικό της ασαφούς ART είναι η κωδικοποίηση συμπληρώματος, ένα μέσο ενσωμάτωσης της απουσίας χαρακτηριστικών σε ταξινομήσεις προτύπων, το οποίο προχωρά πολύ μακριά στην αποτροπή του αναποτελεσματικού και περιττού πολλαπλασιασμού των κατηγοριών. Το ασαφές ART είναι γνωστό ότι είναι πολύ ευαίσθητο στον θόρυβο [27].
- 7) Το Fuzzy ARTMAP είναι ένα ARTMAP χρησιμοποιώντας μονάδες ασαφούς ART, με αποτέλεσμα την αντίστοιχη αύξηση της αποτελεσματικότητας [28].
- 8) Το TorοArt συνδυάζει ασαφή ART με δίκτυα μάθησης τοπολογίας όπως το αυξανόμενο νευρικό αέριο. Επιπλέον, προσθέτει έναν μηχανισμό μείωσης θορύβου. Υπάρχουν πολλά παράγωγα νευρωνικά δίκτυα που επεκτείνουν το TorοART σε περαιτέρω παραδείγματα εκμάθησης [29].

## 5.2 Fuzzy ARTMAP

Ο ένας τύπος που καλύπτει τα κριτήρια που έχουμε θέση νωρίτερα είναι ο (ασαφής) αλγόριθμος ARTMAP. Το Fuzzy ARTMAP είναι μια κλάση αρχιτεκτονικών νευρωνικών δικτύων που εκτελούν αυξημένη εποπτεία των κατηγοριών αναγνώρισης και πολυδιάστατους χάρτες σε απόκριση των εισόδων που παρουσιάζονται με αυθαίρετη σειρά. Το πρώτο σύστημα ARTMAP χρησιμοποιήθηκε για την ταξινόμηση δυαδικών φορέων. Στην συνέχεια παρουσιάστηκε ένα γενικότερο σύστημα ARMART που μαθαίνει να ταξινομεί αναλογικά και δυαδικά διανύσματα. Αυτή η γενίκευση ολοκληρώθηκε με την αντικατάσταση των μοντέλων ART 1 του δυαδικού συστήματος ARTMAP με μονάδες Fuzzy ART [27]. Όπου η δυναμική του ART 1 περιγράφεται με όρους οροθετικής λειτουργίας, ενώ η δυναμική του Fuzzy ART περιγράφεται με όρους ασαφούς λειτουργίας [30]. Εξ 'ου και το νέο σύστημα ονομάζεται Fuzzy ARTMAP. Το Fuzzy ARTMAP ακόμη έχει μια στρατηγική ψηφοφορίας του ARTMAP. Αυτή η στρατηγική ψηφοφορίας βασίζεται στην παρατήρηση ότι η γρήγορη μάθηση ARTMAP οδηγεί συνήθως σε διαφορετικά προσαρμοστικά βάρη και κατηγορίες αναγνώρισης για διαφορετικές ρυθμίσεις ενός δεδομένου εκπαιδευτικού σετ, ακόμα και όταν η συνολική προγνωστική ακρίβεια όλων των προσομοιώσεων είναι παρόμοια. Οι διαφορετικές δομές κατηγοριών, προκαλούν το σύνολο των δεδομένων εκπαίδευσης, όπου τα σφάλματα εμφανίζονται να διαφέρουν από τη μία προσομοίωση στην επόμενη. Η στρατηγική ψηφοφορίας που χρησιμοποιεί ένα σύστημα ARTMAP εκπαιδεύεται αρκετές φορές σε σύνολα εισόδου με διαφορετικές ταξινομήσεις. Η τελική πρόβλεψη για ένα συγκεκριμένο τεστ είναι εκείνη που έγινε από τον μεγαλύτερο αριθμό προσομοιώσεων. Δεδομένου ότι το σύνολο των εντολών που κάνουν λανθασμένες προβλέψεις ποικίλλει από μία

προσομοίωση στην επόμενη, η ψήφος ακυρώνει πολλά από τα λάθη. Επιπλέον, η στρατηγική ψηφοφορίας μπορεί να χρησιμοποιηθεί για την εκχώρηση εκτιμήσεων πιθανότητας σε ανταγωνιστικές προβλέψεις, δεδομένου ότι πρόκειται για μικρά, θορυβώδη ή ελλιπή σύνολα εκπαίδευσης.

Τέσσερις κατηγορίες προσομοιώσεων απεικονίζουν την απόδοση Fuzzy ARTMAP σε σύγκριση με τα συστήματα αναφοράς αναδιπλασιασμού και γενετικού αλγορίθμου. Σε όλες τις περιπτώσεις, οι προσομοιώσεις Fuzzy ARTMAP οδηγούν σε ευνοϊκά επίπεδα μαθησιακής ακρίβειας πρόβλεψης, ταχύτητας και συμπίεσης κώδικα στις ρυθμίσεις τόσο Online όσο και offline. Το Fuzzy ARTMAP είναι επίσης εύκολο στη χρήση. Έχει μικρό αριθμό παραμέτρων, δεν απαιτεί επεξεργασία συγκεκριμένων προβλημάτων συστήματος ή επιλογή αρχικών τιμών βάρους και δεν παγιδύεται στα τοπικά ελάχιστα.



Εικόνα 29 - Αρχιτεκτονική Fuzzy ARTMAP

Κάθε σύστημα ARTMAP περιλαμβάνει ένα ζεύγος υπομονάδων ART ( $ART_a$  και  $ART_b$ ) που δημιουργούν σταθερές κατηγορίες αναγνώρισης με απόκριση σε αυθαίρετες ακολουθίες εισροών. Κατά τη διάρκεια της εποπτευόμενης μάθησης, η μονάδα  $ART_a$  λαμβάνει μια ροή  $\{a^{(p)}\}$  των προτύπων εισόδου και το  $ART_b$  λαμβάνει μια ροή  $\{b^{(p)}\}$  προτύπων εισόδου, όπου  $b^{(p)}$  είναι η σωστή πρόβλεψη δεδομένου ενός  $a^{(p)}$ . Αυτές οι μονάδες συνδέονται μέσω ενός συνδυαστικού δικτύου μάθησης και ενός εσωτερικού ελεγκτή που εξασφαλίζει αυτόνομη λειτουργία του συστήματος σε πραγματικό χρόνο. Ο ελεγκτής έχει σχεδιαστεί για να δημιουργεί τον ελάχιστο αριθμό σε κατηγορίες αναγνώρισης του  $ART_a$  ή "κρυφές μονάδες", που απαιτούνται για την ικανοποίηση των κριτηρίων ακρίβειας. Αυτό επιτυγχάνεται με την υλοποίηση ενός κανόνα εκμάθησης Minimax που επιτρέπει σε ένα σύστημα ARTMAP να μάθει γρήγορα, αποτελεσματικά και με ακρίβεια, καθώς ελαχιστοποιεί το σφάλμα πρόβλεψης και μεγιστοποιεί την γενίκευση πρόβλεψης. Αυτό το σχήμα συνδέει αυτόματα την επιτυχία πρόβλεψης με το μέγεθος της κατηγορίας σε δοκιμαστική βάση χρησιμοποιώντας μόνο

τοπικές λειτουργίες. Λειτουργεί αυξάνοντας την παράμετρο επαγρύπνησης  $P_a$  της  $ART_a$  για το ελάχιστο ποσό που απαιτείται για τη διόρθωση ενός προγνωστικού σφάλματος στην  $ART_b$ .

Η παράμετρος  $P_a$  ρυθμίζει την ελάχιστη εμπιστοσύνη που πρέπει να έχει το  $ART_a$  σε μια κατηγορία αναγνώρισης ή μια υπόθεση που ενεργοποιείται από μια είσοδο  $a^{(P)}$ , για να δεχθεί η  $ART_a$  αυτή την κατηγορία, αντί να αναζητήσει μια καλύτερη μέσω μιας αυτόματα ελεγχόμενης διαδικασίας ελέγχου υποθέσεων. Οι χαμηλότερες τιμές του  $P_a$  επιτρέπουν τη δημιουργία μεγαλύτερων κατηγοριών. Αυτές οι χαμηλότερες τιμές  $P_a$  οδηγούν σε ευρύτερη γενίκευση και υψηλότερη συμπίεση κώδικα. Μια προγνωστική αποτυχία στο  $ART_b$  αυξάνει την  $P_a$  με το ελάχιστο ποσό που απαιτείται για την ενεργοποίηση της δοκιμασίας υποθέσεων στο  $ART_a$ , χρησιμοποιώντας έναν μηχανισμό που ονομάζεται παρακολούθηση αντιστοίχισης (Carpenter, Grossberg και Reynolds, 1991). Η παρακολούθηση αντιστοίχισης θυσιάζει την ελάχιστη ποσότητα γενίκευσης που είναι απαραίτητη για τη διόρθωση ενός προγνωστικού σφάλματος. Η δοκιμή υποθέσεων οδηγεί στην επιλογή μιας νέας  $ART_a$  κατηγορίας, η οποία εστιάζει την προσοχή σε ένα νέο σύμπλεγμα χαρακτηριστικών εισόδου ( $P$ ) που είναι σε καλύτερη θέση να προβλέψει το  $b^{(P)}$ . Λόγω του συνδυασμού της παρακολούθηση αντιστοίχισης και της γρήγορης εκμάθησης, ένα σύστημα ARTMAP μπορεί να μάθει μια διαφορετική πρόβλεψη για ένα σπάνιο γεγονός απ' ότι ένα πολλά παρόμοιας συχνότητας γεγονότων στα οποία είναι ενσωματωμένο [31].

Ο αλγόριθμος Fuzzy ARTMAP ενσωματώνει δύο Fuzzy ART μονάδες, τα  $ART_a$  και  $ART_b$  που συνδέονται μεταξύ τους μέσω της μονάδας Inter-ART  $F^{ab}$  που ονομάζεται πεδίο χαρτών. Το πεδίο χαρτών χρησιμοποιείται για τη δημιουργία προγνωστικών σχέσεων μεταξύ κατηγοριών και για την πραγματοποίηση του κανόνα παρακολούθηση αντιστοίχισης με την οποία η παράμετρος επαγρύπνησης της  $ART_a$  αυξάνει σε περίπτωση μιας προγνωστικής ανααντιστοιχίας στην  $ART_b$ . Η παρακολούθηση αντιστοίχισης αναδιοργανώνει τη δομή κατηγορίας έτσι ώστε το σφάλμα πρόβλεψης να μην επαναλαμβάνεται σε επόμενες τιμές της εισόδου. Οι αλληλεπιδράσεις που μεσολαβούν από το πεδίο χαρτών  $F^{ab}$  μπορεί να χαρακτηρίζονται λειτουργικά ως εξής.

#### Μονάδες $ART_a$ και $ART_b$ [28]

Οι εισροές στα  $ART_a$  και  $ART_b$  είναι στη μορφή κώδικα συμπληρώματος:  $A = (a, a^c)$  και  $B = (b, b^c)$ . Οι μεταβλητές στο  $ART_a$  καθορίζονται με δείκτες "a" ή "b".

Για το  $ART_a$ , το  $x^a = (x_1^a \dots x_{2Ma}^a)$  υποδηλώνει το διάνυσμα εξόδου  $F_1^a$ . Το  $y^a = (y_1^a \dots y_{Na}^a)$  υποδηλώνει το διάνυσμα εξόδου  $F_2^a$ . Το  $w_j^a = (w_{j1}^a, w_{j2}^a, \dots, w_{j2Ma}^a)$  υποδηλώνει το διάνυσμα βάρους του  $ART_a$ .

Για το  $ART_b$ , το  $x^b = (x_1^b \dots x_{2Mb}^b)$  υποδηλώνει το διάνυσμα εξόδου  $F_1^b$ . Το  $y^b = (y_1^b \dots y_{Nb}^b)$  υποδηλώνει τον διάνυσμα εξόδου  $F_2^b$ . Το  $w_k^b = (w_{k1}^b, w_{k2}^b, \dots, w_{k2Mb}^b)$  υποδηλώνει το διάνυσμα βάρους του  $ART_b$ .

Για το πεδίο χαρτών, το  $x^{ab} = (x_1^{ab} \dots x_{Nb}^{ab})$  υποδηλώνει τον διάνυσμα εξόδου  $F^{ab}$  και το  $w_j^{ab} = (w_{j1}^{ab}, w_{j2}^{ab}, \dots, w_{jNb}^{ab})$  υποδηλώνει το διάνυσμα βάρους από την τελευταία τιμή του  $F_2^a$  στο  $F^{ab}$ . Τα διανύσματα  $x^a$ ,  $y^a$ ,  $x^b$ ,  $y^b$  και  $x^{ab}$  ορίζονται ως 0 μεταξύ των τιμών εισαγωγής.

Το πεδίο χαρτών  $F^{ab}$  ενεργοποιείται κάθε φορά που είναι ενεργή μία από τις κατηγορίες των  $ART_a$  ή  $ART_b$ . Εάν ο κόμβος J του  $F_2^a$  είναι επιλεγμένος, τότε τα βάρη του  $w_j^{ab}$  ενεργοποιούν το  $F^{ab}$ . Αν ο κόμβος K στο  $F_2^b$  είναι ενεργός, τότε ο κόμβος K στο  $F^{ab}$  ενεργοποιείται από με 1 προς 1 διαδρομές μεταξύ  $F_2^b$  και  $F^{ab}$ . Εάν το  $ART_a$  και το  $ART_b$  είναι ενεργά, τότε το  $F^{ab}$  γίνεται ενεργό μόνο

αν  $ART_a$  προβλέπει η ίδια κατηγορία με  $ART_b$  μέσω των βαρών  $w_j^{ab}$ . Το διάνυσμα εξόδου  $F^{ab}$  ακολουθεί το  $x^{ab}$

$$x^{ab} = \begin{cases} y^b \wedge w_j^{ab} & \text{Εάν ο } J \text{ κόμβος του } F_2^a \text{ είναι ενεργός και του } F_2^b \text{ είναι ενεργός} \\ w_j^{ab} & \text{Εάν ο } J \text{ κόμβος του } F_2^a \text{ είναι ενεργός και του } F_2^b \text{ μη ενεργός} \\ y^b & \text{Εάν το } F_2^a \text{ είναι μη ενεργό και το } F_2^b \text{ είναι ενεργό} \\ 0 & \text{Εάν το } F_2^a \text{ είναι μη ενεργό και το } F_2^b \text{ είναι μη ενεργό} \end{cases}$$

Σύμφωνα με το παραπάνω, το  $x^{ab}=0$  εάν η πρόβλεψη  $w_j^{ab}$  επιβεβαιωθεί από το  $y^b$ . Ένα τέτοιο γεγονός ξεκινάει μια διαδικασία από το  $ART_a$  για να βρεθεί μια καλύτερη κατηγορία, η διαδικασία αυτή είναι η παρακολούθηση αντιστοίχισης (match tracking) και αναλύεται στην συνέχεια.

Στην αρχή κάθε τιμής εισόδου, η παράμετρος επαγρύπνησης του  $ART_a$   $P_a$  ισούται με την τιμή βάσης  $P_a$ . Η παράμετρος επαγρύπνησης πεδίου χάρτη είναι  $P_{ab}$ . Εάν

$$|x^{ab}| < p_{ab}|y^b|$$

Τότε το  $P_a$  αυξάνετε έως ότου είναι ελάχιστο μεγαλύτερο από το  $|A \wedge w_j^a| |A|^{-1}$  όπου  $A$  είναι η είσοδος του  $F_1^a$ , συμπληρωματική μορφή. Τότε

$$|x^a| = |A \wedge w_j^a| < p_a |A|$$

Όπου το  $J$  είναι ο δείκτης του ενεργού  $F_2^a$  κόμβου. Όταν αυτό συμβεί η αναζήτηση του  $ART_a$  οδηγεί είτε στην ενεργοποίηση άλλου  $F_2^a$  κόμβου  $J$  με

$$|x^a| = |A \wedge w_j^a| \geq p_a |A|$$

και

$$|x^{ab}| = |y^b \wedge w_j^a| \geq p_a |y^b|$$

είτε, εάν αυτός ο κόμβος δεν βρεθεί, στο κλείσιμο του  $F_2^a$  για το υπόλοιπο της συγκεκριμένης τιμής εισόδου.

#### Εκπαίδευση Πεδίου Χαρτών

Οι κανόνες μάθησης καθορίζουν τον τρόπο με τον οποίο αλλάζουν τα βάρη στο πεδίο χαρτών  $w_{jk}^{ab}$  με τον χρόνο. Το βάρος  $w_{jk}^{ab}$  στις συνδέσεις  $F_2^a \rightarrow F^{ab}$  αρχικά ικανοποιούν την παρακάτω συνθήκη

$$w_{jk}^{ab}(0) = 1$$

Κατά τη διάρκεια αντιστοίχισης της  $ART_a$  με μια ενεργή κατηγορία  $J$ , το  $w_{jk}^{ab}$  θα πλησιάσει το διάνυσμα πεδίου χάρτη  $x^{ab}$ . Με γρήγορη εκπαίδευση, όταν το  $J$  μάθει να προβλέπει την κατηγορία  $K$  του  $ART_b$ , αυτή η σχέση είναι μόνιμη.

Ο Fuzzy ARTMAP είναι ένας πολύ ισχυρός και ευέλικτος αλγόριθμος. Ωστόσο, έχει τα μειονεκτήματά του. Σε πολλές εφαρμογές, οι ερευνητές παρατήρησαν ότι το Fuzzy ARTMAP είναι πολύ ευαίσθητο στην επιλογή της παραμέτρου αβεβαιότητας, στα επίπεδα θορύβου κατά την κατάρτιση και στο σύνολο των δεδομένων στα οποία παρουσιάζονται τα δεδομένα εκπαίδευσης στον αλγόριθμο. Επιπλέον, ο αλγόριθμος δημιουργεί μεγάλο αριθμό ομάδων που προκαλούν υπερφόρτωση εάν δεν έχει επιλεγεί σωστά η παράμετρος επαγρύπνησης. Συνεπώς, αυτή η παράμετρος τυπικά επιλέγεται κατά τρόπο ad hoc και χωριστά.



### 5.3 ΤοροART

Η βασική δομή και το υπολογιστικό πλαίσιο του ΤοροART σχετίζονται στενά με το Fuzzy Art, το οποίο αποτελεί ένα πολύ αποτελεσματικό δίκτυο ART που χρησιμοποιεί υπερ-ορθογώνιες κατηγορίες. Το ΤοροART αποτελείται από δύο ασαφή τμήματα τύπου ART - ΤοροART<sub>a</sub> και ΤοροART<sub>b</sub>. Αυτά τα εξαρτήματα διαθέτουν δομή τριών επιπέδων με κοινό αρχικό επίπεδο F0. Λειτουργούν με τον ίδιο τρόπο και εκπαιδεύονται παράλληλα. Προκειμένου να δημιουργηθούν παραστάσεις σε διαφορετικά επίπεδα λεπτομέρειας και να μειωθεί η ευαισθησία στον θόρυβο, η διάδοση των διανυσμάτων εισόδου στο ΤοροART<sub>b</sub> ελέγχεται από το ΤοροART<sub>a</sub>. Επιπλέον, το μέγιστο μέγεθος κατηγορίας του ΤοροART<sub>b</sub> μειώνεται σε σύγκριση με το ΤοροART<sub>a</sub> [32].

Οι φορείς εισαγωγής  $x(t)$  παρουσιάζονται στο κοινό αρχικό επίπεδο F0.

$$x(t) = [x_1(t), \dots, x_d(t)]^T$$

Στο αρχικό επίπεδο, η είσοδος κωδικοποιείται χρησιμοποιώντας την κωδικοποίηση συμπληρώματος, η οποία συνιστά μια συσχέτιση του  $x(t)$  και του συμπληρώματός του  $x^c(t)$ .

$$x^c(t) = [1 - x_1(t), \dots, 1 - x_d(t)]^T$$

Τα συμπληρωματικά κωδικοποιημένα διανύσματα υποδηλώνονται με  $x^{F1}(t)$ .

$$x^{F1}(t) = [x(t)^T, x^c(t)^T]^T$$

Ως αποτέλεσμα της χρήσης κωδικοποίησης συμπληρώματος, κάθε συστατικό  $x_i(t)$  ενός διανύσματος εισόδου  $x(t)$  πρέπει να βρίσκεται στο διάστημα  $[0, 1]$ .

Οι κωδικοποιημένοι φορείς εισόδου  $x^{F1}(t)$  μεταδίδονται στο αντίστοιχο επίπεδο σύγκρισης F1. Η συνάρτηση ενεργοποίησης  $Z_i^{F2}(t)$  (λειτουργία επιλογής) των κόμβων F2 υπολογίζεται ως εξής

$$Z_i^{F2}(t) = \frac{[x^{F1}(t) \wedge w_i^{F2}(t)]_1}{a + [w_i^{F2}(t)]_1}$$

Το  $Z_i^{F2}(t)$  αποτελεί ένα μέτρο για την ομοιότητα μεταξύ του  $x^{F1}(t)$  και της κατηγορίας που αντιπροσωπεύεται από τον νευρώνα  $i$ . Το  $\wedge$  υποδηλώνει μια ελάχιστη λειτουργική συνιστώσα. Η παράμετρος  $a$  πρέπει να ρυθμιστεί ελαφρώς πάνω από το μηδέν. Η επιλογή της πραγματικής τιμής δεν είναι κρίσιμη. Γενικά, το  $Z_i^{F2}(t)$  προτιμά τις μικρές κατηγορίες από τις μεγάλες.

Αφού έχουν ενεργοποιηθεί όλοι οι νευρώνες F2, επιλέγεται ο βέλτιστος νευρώνας  $bm$ , δηλαδή ο νευρώνας με την υψηλότερη ενεργοποίηση. Αλλά η κατηγορία που αναπαρίσταται από τα βάρη της  $w_{bm}^{F2}(t)$  επιτρέπεται να αναπτυχθεί και να περικλείσει ένα παρουσιαζόμενο διάνυσμα εισόδου, εάν προκύψει συντονισμός, δηλαδή εάν πληρείται η παρακάτω συνάρτηση αντιστοίχισης.

$$\frac{[x^{F1}(t) \wedge w_{bm}^{F2}(t)]_1}{[x^{F1}(t)]_1} \geq \rho$$

Η παράμετρος επαγρύπνησης  $\rho$  περιορίζει το μέγιστο μέγεθος των κατηγοριών και συνεπώς έχει ισχυρή επίδραση στις παραγόμενες συστοιχίες. Η Fuzzy ART και το αναβαθμισμένο μοντέλο της Fuzzy ARTMAP είναι δυνατό να καταφύγουν σε υπάρχουσα γνώση και διαδικασίες για την εξεύρεση κατάλληλων τιμών  $\rho$ .

Υποθέτοντας ότι ένας νευρώνας δεν μπόρεσε να εκπληρώσει την συνάρτηση αντιστοίχισης, η ενεργοποίησή του επαναφέρεται. Στη συνέχεια επιλέγεται ένας νέος κόμβος καλύτερης αντιστοίχισης. Αν δεν βρεθεί κανένας κατάλληλος νευρώνας με την καλύτερη αντιστοίχιση, ενσωματώνεται ένας νέος νευρώνας που αντιπροσωπεύει το  $x(t)$  και δημιουργείτε συντονισμός.

Σε περίπτωση συντονισμού, προσαρμόζονται τα βάρη  $w_{bm}^{F2}(t)$  του επιλεγμένου νευρώνα και ρυθμίζεται η έξοδος  $y(t)$  του αντίστοιχου μέρους του ΤοροART

$$w_{bm}^{F2}(t+1) = (x^{F1}(t) \wedge w_{bm}^{F2}(t))$$

$$y_i(t) = \begin{cases} 0 & \text{Εάν } i \neq bm \\ 1 & \text{Εάν } i = bm \end{cases}$$

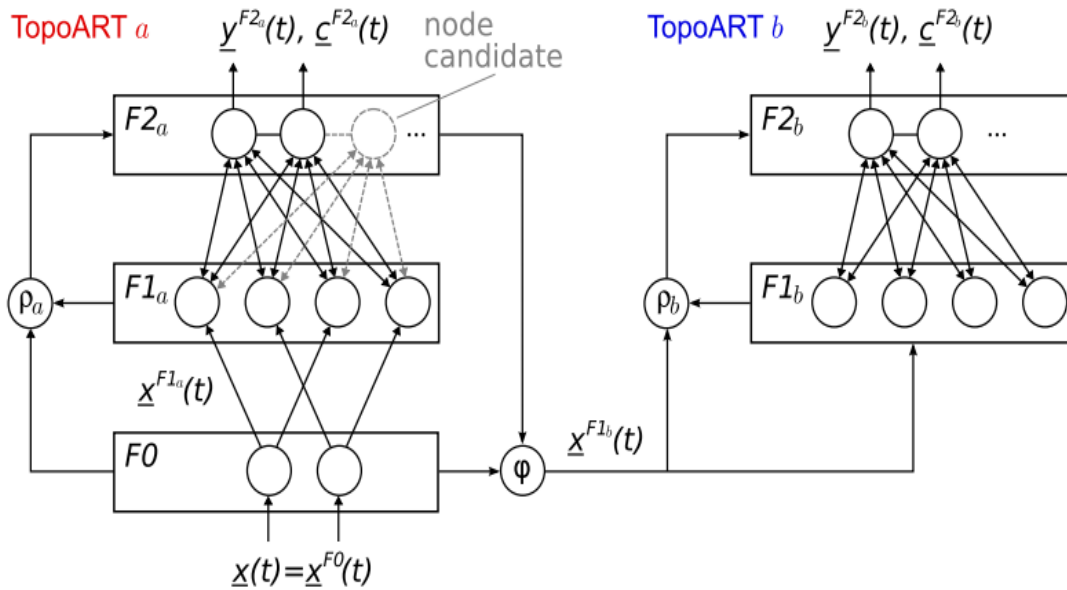
Χρησιμοποιώντας τον παραπάνω τύπο το δίκτυο εκπαιδεύεται σε λειτουργία γρήγορης εκμάθησης, δηλ. κάθε μαθησιακή είσοδος περικλείεται από την κατηγορία που ταιριάζει καλύτερα. Επιπλέον, η συρρίκνωση των κατηγοριών είναι αδύνατη. Ως εκ τούτου, οι σχηματισμένες παραστάσεις είναι σταθερές [33].

Αντί να καθορίζεται μόνο ο βέλτιστος συνδυασμός νευρώνων  $bm$  και να τροποποιεί τα βάρη του, προσαρμόζεται επίσης και το  $sbm$  των νευρώνων με τη δεύτερη υψηλότερη ενεργοποίηση που ικανοποιεί τους παραπάνω τύπους. Εδώ, ο ρυθμός εκμάθησης  $\beta_{sbm}$  θα πρέπει να επιλεγεί μικρότερος του 1, καθώς το  $sbm$  του νευρώνα, σε αντίθεση με το  $bm$  του νευρώνα, προορίζεται μόνο να μαθαίνει εν μέρει  $X^{F1}(t)$ . Τα βάρη του  $w_{sbm}^{F2}(t)$  προσαρμόζονται ως εξής:

$$w_{sbm}^{F2}(t+1) = \beta_{sbm} (x^{F1}(t)w_{sbm}^{F2}(t)) + (1 - \beta_{sbm})w_{sbm}^{F2}(t)$$

Ως αποτέλεσμα αυτής της διαδικασίας, η ανοχή στον θόρυβο αυξάνεται, καθώς οι κατηγορίες είναι περισσότερο πιθανό να αναπτυχθούν σε σχετικές περιοχές του χώρου εισόδου. Αλλά σε σύγκριση με το  $\rho$ , το  $\beta_{sbm}$  έχει πολύ λιγότερο επιρροή. Ως εκ τούτου, ο σκοπός του συνίσταται στην βελτιστοποίηση των αποτελεσμάτων της ομαδοποίησης.

Κάθε νευρώνας  $F2$  και των δύο συνιστωσών έχει ένα μετρητή που δηλώνεται από  $n_i^a$  και  $n_i^a$ , αντίστοιχα, ο οποίος μετράει τον αριθμό των δειγμάτων εισόδου για τα οποία έχει εκπαιδευτεί. Ένα κωδικοποιημένο διάνυσμα εισόδου μεταδίδεται μόνο στο ΤοροART  $b$  εάν έχει προκύψει συντονισμός του ΤοροART  $a$  και  $n_{bm}^a \geq \phi$ . Κάθε  $\tau$  κύκλους μάθησης, όλοι οι νευρώνες με μετρητή μικρότερο από  $\phi$  αφαιρούνται. Επομένως, τέτοιοι νευρώνες ονομάζονται υποψήφιοι κόμβοι. Μόλις το  $n_i$  ισούται ή υπερβεί το  $\phi$ , ο αντίστοιχος νευρώνας δεν μπορεί πλέον να αφαιρεθεί. Δηλαδή, γίνεται ένας μόνιμος κόμβος. Το κλάσμα  $\phi/\tau$  δίνει την ελάχιστη συχνότητα ενεργοποίησης για τους νευρώνες για να γίνουν μόνιμοι. Λόγω αυτής της σχέσης, οι  $\phi$  και  $\tau$  λειτουργούν παρόμοια με μία μόνο παράμετρο, γεγονός που διευκολύνει την επιλογή τους. Επιπλέον,  $\tau$  ορίζει τον αριθμό των εκπαιδευτικών βημάτων που εξετάστηκαν για την εκτίμηση των συχνοτήτων ενεργοποίησης. Έτσι, η αξιοπιστία των εκτιμήσεων αυξάνεται για τις υψηλότερες τιμές του  $\tau$ . Χρησιμοποιώντας αυτόν τον μηχανισμό για την απομάκρυνση σπάνια ενεργοποιημένων κόμβων, το δίκτυο καθίσταται λιγότερο ευαίσθητο στο θόρυβο, αλλά εξακολουθεί να είναι σε θέση να μάθει σταθερές αναπαραστάσεις [33].



Εικόνα 30 - Αρχιτεκτονική TopoArt

Για να μπορέσει το TopoART να μάθει τοπολογίες, δημιουργείται μια πλευρική σύνδεση ή άκρη μεταξύ των νευρώνων  $bm$  και  $sbm$ , εάν μπορεί να βρεθεί ένας δεύτερος βέλτιστος νευρώνας. Αυτά τα άκρα ορίζουν μια τοπολογική δομή. Δεν χρησιμοποιούνται για την ενεργοποίηση άλλων νευρώνων. Εάν οι νευρώνες  $bm$  και  $sbm$  έχουν ήδη συνδεθεί με μια άκρη, παραμένουν αμετάβλητοι, αφού οι άκρες δεν έχουν μια παράμετρο ηλικίας σε αντίθεση με τις άκρες στα δίκτυα ESOINN, SOINN και GNG. Αφαιρούνται αν αφαιρεθεί ένας από τους γειτονικούς νευρώνες. Κατά συνέπεια, τα άκρα μεταξύ των μόνιμων κόμβων είναι μόνιμα, ενώ οι άκρες από ή προς τους υποψήφιους κόμβους μπορούν να εξαλειφθούν. Επιπλέον, είναι πάντα δυνατή η δημιουργία νέων άκρων. Αυτός ο μηχανισμός αποτελεί επέκταση της λύσης του Fuzzy ART, που επιτρέπει την αναπαράσταση της νέας εισόδου διατηρώντας παράλληλα τις ήδη εκπαιδευμένες αναπαραστάσεις.

Οι μόνιμοι κόμβοι και τα άκρα αποτελούν ένα είδος μακροπρόθεσμης μνήμης του δικτύου, καθώς επιτρέπουν την πρόσβαση σε πληροφορίες από το παρελθόν. Θεωρούμε ότι αυτή η ιδιότητα είναι σημαντική για πολλές εργασίες, όπως η δια βίου μάθηση των τεχνητών μέσων ή οι διαδικασίες κατηγοριοποίησης, που απαιτούν οι κατηγορίες εκπαίδευσης για να παραμείνουν σταθερές εάν ενσωματωθούν νέα δεδομένα στο δίκτυο.

Το τρέχον μέγεθος  $S_i(t)$  μιας κατηγορίας μπορεί να προκύψει από τα βάρη  $w_i^{F2}(t)$  του αντίστοιχου νευρώνα  $i$ .

$$S_i(t) = \sum_{j=1}^d \left| (1 - w_{i,d+j}^{F2}(t)) - w_{i,j}^{F2}(t) \right|$$

Εκτός από την παράμετρο επαγρύπνησης  $\rho$ , το μέγιστο μέγεθος κατηγορίας  $S^{\max}$  καθορίζεται από τη διάσταση του χώρου εισόδου  $d$ .

$$S^{\max} = d(1 - \rho)$$

Προκειμένου να βελτιωθεί η αναπαράσταση του TopoARTa μέσω του TopoARTb, το  $\rho_b$  θα πρέπει να είναι υψηλότερο από το  $\rho_a$ . Επομένως, το  $\rho_b$  προσδιορίζεται σύμφωνα με το παρακάτω τύπο, όπου μειώνει το μέγιστο μέγεθος κατηγορίας  $S_{\max}$  κατά 50%.

$$\rho_b = \frac{1}{2}(\rho_a + 1)$$

Με αυτόν τον τρόπο, το ΤοροARTb μαθαίνει μια πιο λεπτομερή αναπαράσταση που επηρεάζεται λιγότερο από το θόρυβο. Οι συνδέσεις μεταξύ των κατηγοριών ΤοροARTa μπορούν να διαχωριστούν από το ΤοροARTb με αποτέλεσμα μια ιεραρχική αναπαράσταση των δεδομένων εισόδου.

Εκτός από την έξοδο  $\gamma(t)$ , κάθε στοιχείο παρέχει τις ετικέτες συστάδων των κόμβων F2 ως διανύσματος που ονομάζεται  $c(t)$ . Αυτές οι ετικέτες προσδιορίζονται ως εξής: Πρώτον, επιλέγεται μια αρχική ετικέτα (ακέραιος αριθμός). Στη συνέχεια, ξεκινώντας από έναν μη επισημασμένο νευρώνα, όλοι οι συνδεδεμένοι νευρώνες λαμβάνουν αυτήν την ετικέτα. Στη συνέχεια, η ετικέτα αυξάνεται και αναζητείται ένας νέος μη επισημασμένος νευρώνας. Η πλήρης διαδικασία επαναλαμβάνεται μέχρι να μην παραμείνουν μη επισημασμένοι νευρώνες. Ως αποτέλεσμα, όλα τα σύνολα διασυνδεδεμένων κόμβων ή μάλλον συμπλεγμάτων έχουν λάβει μια μοναδική ετικέτα. Για λόγους σταθερότητας, μόνο οι μόνιμοι κόμβοι συνυπολογίζονται για τον υπολογισμό του  $c(t)$ . Συνεπώς, οι συστάδες μπορούν να αναπτυχθούν και να συγχωνευθούν, αλλά δεν μπορούν να συρρικνωθούν.

Για να αντιστοιχίσει άγνωστα δεδομένα σε ομάδες που έχουν ήδη δημιουργηθεί, το ΤοροART εντοπίζει τον μόνιμο κόμβο με την υψηλότερη ενεργοποίηση. Στην συνέχεια η ετικέτα συμπλέγματος αυτού του κόμβου επιστρέφεται ως αποτέλεσμα.

Η αρχική ενεργοποίηση εξαρτάται από το μέγεθος της κατηγορίας. Αυτό μπορεί να είναι μειονεκτικό σε περιπτώσεις όπου ένα εκπαιδευμένο δίκτυο εφαρμόζεται σε άγνωστα μοτίβα δοκιμών. Σε μια τέτοια περίπτωση, τα παρουσιαζόμενα δείγματα εισροών δεν είναι εγγυημένα ότι βρίσκονται σε υπάρχουσες κατηγορίες. Επιπλέον, καθώς δεν γίνεται μάθηση, το τρέχον μέγεθος κατηγορίας δεν έχει σημασία. Επομένως, η εναλλακτική ενεργοποίηση που προτάθηκε από τον Tschererapow θα μπορούσε να είναι επωφελής. Αποτελεί την απόσταση μεταξύ ενός δείγματος εισόδου και της αντίστοιχης κατηγορίας, προκειμένου να το καταστήσει πιο κατάλληλο για την εφαρμογή ως λειτουργία ενεργοποίησης, αντιστρέφεται και κανονικοποιείται σε τιμές από το διάστημα  $[0, 1]$  με τον παρακάτω τύπο

$$z_i^{F2}(t) = 1 - \frac{|(x^{F1}(t) \wedge w_i^{F2}(t))|_1}{|x^{F1}(t)|_1}$$

Οι προκύπτουσες τιμές του  $z_i^{F2}(t)$  αντικατοπτρίζουν την ομοιότητα μιας εισόδου με μια κατηγορία και δεν επηρεάζονται από το μέγεθος της κατηγορίας.

## 5.4 Learn++

Ο αλγόριθμος Learn++ εμπνεύστηκε από τον αλγόριθμο AdaBoost (adaptive boosting), που αναπτύχθηκε αρχικά για να βελτιώσει την απόδοση ταξινόμησης των αδύναμων ταξινομητών. Ο Schapire δείχνει ότι για ένα πρόβλημα δύο κλάσεων ένας αδύναμος αλγόριθμος εκπαίδευσης που τα πάει ελάχιστα καλύτερα από μια απλή τυχαία εικασία μπορεί να μετασχηματιστεί σε έναν ισχυρό αλγόριθμο εκπαίδευσης που σχεδόν πάντα επιτυγχάνει πολύ χαμηλό ποσοστό σφάλματος χρησιμοποιώντας μια διαδικασία που ονομάζεται ενίσχυση. Ο Freund αργότερα ανέπτυξε το AdaBoost, επεκτείνοντας την ώθηση σε προβλήματα πολλαπλών κλάσεων και regression. Ουσιαστικά, τόσο το Learn ++ όσο και το AdaBoost παράγουν ένα σύνολο αδύναμων ταξινομητών, κάθε ένα από το οποίο έχει εκπαιδευτεί με διαφορετική κατανομή δειγμάτων κατάρτισης. Τα αποτελέσματα αυτών των ταξινομητών στη συνέχεια συνδυάζονται με το πρόγραμμα πλειοψηφικής ψηφοφορίας του Littlestone για την επίτευξη του τελικού κανόνα ταξινόμησης. Ο συνδυασμός αδύναμων ταξινομητών εκμεταλλεύεται τη λεγόμενη αστάθεια του αδύναμου ταξινομητή. Αυτή η

αστάθεια προκαλεί στους ταξινομητές να κατασκευάσουν επαρκώς διαφορετικές επιφάνειες αποφάσεων για μικρές τροποποιήσεις στα σύνολα δεδομένων εκπαίδευσης [34][35].

Οι εισροές στο Learn ++ είναι τα δεδομένα εκπαίδευσης  $S_k$  των  $m$  δειγμάτων που τυχαία επιλέχθηκαν από την τρέχουσα διαθέσιμη βάση δεδομένων  $D_k$ , έναν ασθενή αλγόριθμο εκμάθησης WeakLearn και έναν ακέραιο  $T_k$ , προσδιορίζοντας τον αριθμό των ταξινομητών που θα δημιουργηθούν. Τα νευρωνικά δίκτυα είναι ιδιαίτερα κατάλληλα για αυτή τη ρύθμιση, δεδομένου ότι χαρακτηρίζονται ως αδύναμοι μαθητές, όπου η αδυναμία τους μπορεί να ελεγχθεί από τον αριθμό των κρυφών επιπέδων / κόμβων και / ή του στόχου σφάλματος. Το Learn ++ απαιτεί από κάθε αδύναμο μαθητή να ταξινομήσει σωστά τουλάχιστον το 50% του τρέχοντος σετ εκπαίδευσης, παράγοντας μόνο μια τυχαία εκτίμηση του πραγματικού ορίου λήψης αποφάσεων. Ως εκ τούτου, κάθε ασθενής μαθητευόμενος μπορεί να εκπαιδευτεί πολύ γρήγορα, ενώ οι ισχυροί μαθητευόμενοι συνήθως περνούν το μεγαλύτερο μέρος του χρόνου κατάρτισης για την τελειοποίηση του ορίου λήψης αποφάσεων.

Κάθε ταξινομητής μπορεί να θεωρηθεί ως υπόθεση  $h$  από τον χώρο εισόδου  $X$  στον χώρο εξόδου  $Y$ . Το Learn ++ ζητάει από το WeakLearn να δημιουργήσει πολλαπλές υποθέσεις χρησιμοποιώντας διαφορετικά υποσύνολα των δεδομένων εκπαίδευσης  $S_k$  και κάθε υπόθεση μαθαίνει μόνο ένα μέρος του χώρου εισόδου. Αυτό επιτυγχάνεται με την επαναληπτική ενημέρωση μιας κατανομής  $D_t$ ,  $t = 1, 2, \dots$ ,  $T_k$  από την οποία επιλέγονται τα υποσύνολα εκπαίδευσης. Η ίδια η διανομή λαμβάνεται κανονικοποιώντας ένα σύνολο βαρών που αντιστοιχούν σε κάθε εμφάνιση με βάση την απόδοση ταξινόμησης των ταξινομητών σε αυτή την περίπτωση (βήμα 1). Σε γενικές γραμμές, οι περιπτώσεις που είναι δύσκολο να ταξινομηθούν έχουν υψηλότερα βάρη για να αυξήσουν την πιθανότητα επιλογής τους στο επόμενο σύνολο δεδομένων κατάρτισης. Τα βάρη για την πρώτη επανάληψη  $w_1(i)$  (και συνεπώς και η πρώτη κατανομή  $D_1$ ) αρχικοποιούνται σε  $1/m$ ,  $i = 1, 2, \dots, m$  δίνοντας την ίδια πιθανότητα για κάθε περίπτωση να επιλεγεί στο πρώτο υποσύνολο εκπαίδευσης [36].

Παρακάτω παρουσιάζεται ο αλγόριθμος του Learn++.

Είσοδος: Για κάθε σύνολο δεδομένων που προέρχεται από  $D_k$   $k=1,2,\dots,K$

- Η ακολουθία των παραδειγμάτων  $m$  είναι  $S = [(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)]$ .
- Αδύναμος αλγόριθμος εκμάθησης **WeakLearn**.
- Ο ακέραιος αριθμός  $T_k$ , που καθορίζει τον αριθμό των επαναλήψεων.

Επανάλαβε για κάθε  $k=1,2,\dots,K$

Αρχικό όρισμα :  $w_1(i) = D_1(i) = 1/m$ ,  $\forall i, i = 1, 2, \dots, m$

Επανάλαβε για :  $t=1, 2, \dots, T_k$

1. Όρισε  $D_t = \frac{w_t}{\sum_{i=1}^m w_t(i)}$  ώστε το  $D_t$  είναι μια κατανομή
2. Τυχαία επιλέξτε τα υποσύνολα δεδομένων εκπαίδευσης  $TR_t$  και δεδομένων ελέγχου  $TE_t$  από το  $D_t$ .
3. Κάλεσε το **WeakLearn**, παρέχοντάς του το  $TR_t$  από τη κατανομή  $D_t$ .
4. Επιστρέψτε μια υπόθεση  $h_t: X \rightarrow Y$  και υπολόγισε το σφάλμα του  $h_t$ :

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i)$$

στα  $TR_t + TE_t$ , εάν  $\varepsilon_t > 1/2$  τότε  $t=t-1$ , καθάρισε το  $h_t$  και πήγαινε στο βήμα 2. Αλλιώς υπολόγισε το κανονικοποιημένο σφάλμα ως  $\beta_t = \frac{\varepsilon_t}{(1-\varepsilon_t)}$ .

5. Κάλεσε σταθμισμένη πλειοψηφία, αποκτήστε τη συνολική υπόθεση

$$H_t = \underset{y \in Y}{\operatorname{argmax}} \sum_{i: h_t(x)=y} \log\left(\frac{1}{\beta_t}\right)$$

υπολόγισε το συνδυασμένο σφάλμα

$$E_t = \sum_{i: H_t(x_i) \neq y_i} D_t(i) = \sum_{i=1}^m D_t(i) [|H_t(x_i) \neq y_i|]$$

εάν  $\varepsilon_t > 1/2$  τότε  $t=t-1$ , καθάρισε το  $h_t$  και πήγαινε στο βήμα 2.

6. Όρισε  $B_t = \frac{E_t}{(1-E_t)}$  και ενημέρωσε τα βάρη :

$$W_{t+1}(i) = W_t(i) \times \begin{cases} B_t, & \text{εάν } H_t(x_i) = y_i \\ 1, & \text{σε όλες τις άλλες περιπτώσεις} \end{cases} = W_t(i) \times B_t^{1-|H_t(x_i) \neq y_i|}$$

Κάλεσε την σταθμισμένη πλειοψηφία και εξάγατε την τελική υπόθεση

$$H_{\text{final}}(x) = \underset{y \in Y}{\operatorname{argmax}} \sum_{k=1}^K \sum_{i: h_t(x)=y} \log\left(\frac{1}{\beta_t}\right)$$

Σε κάθε επανάληψη  $t = 1, 2, \dots, T_k$ , ο αλγόριθμος Learn ++ αρχικά διχοτομεί το  $S_k$  σε ένα υποσύνολο εκπαίδευσης  $TR_t$  και ένα υποσύνολο δοκιμής  $TE_t$  σύμφωνα με το  $D_t$  (βήμα 2) και καλεί το WeakLearn για να δημιουργήσει την υπόθεση  $h_t: X \rightarrow Y$  (βήμα 3). Το σφάλμα του  $h_t$  στο  $S_k = TR_t + TE_t$  υπολογίζεται ως (βήμα 4)

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i)$$

Εάν το σφάλμα  $\varepsilon_t$  όπου υπολογίσθηκε είναι μεγαλύτερο από 0,5, τότε καθαρίζουμε απ' ότι περιέχει το  $h_t$  και επιλέγουμε καινούργια  $TR_t$  και  $TE_t$  και εφαρμόζουμε πάλι το WeakLearn. Διαφορετικά το κανονικοποιημένο σφάλμα  $\beta_t$  υπολογίζεται ως

$$\beta_t = \frac{\varepsilon_t}{(1 - \varepsilon_t)}$$

Όλες οι υποθέσεις που δημιουργήθηκαν στην προηγούμενη επανάληψη συνδυάζονται χρησιμοποιώντας σταθμισμένη πλειοψηφία (βήμα 5). Τα βάρη ψηφοφορίας βασίζονται στο κανονικοποιημένο σφάλμα  $\beta$ . Υποθέσεις με χαμηλότερα κανονικοποιημένα βάρη παίρνουν μεγαλύτερα βάρη. Στη συνέχεια γίνεται μια απόφαση ταξινόμησης με βάση τα αποτελέσματα των μεμονωμένων υποθέσεων, η οποία αποτελεί τη σύνθετη υπόθεση  $H_t$

$$H_t = \underset{y \in Y}{\operatorname{argmax}} \sum_{i: h_t(x)=y} \log\left(\frac{1}{\beta_t}\right)$$

Παρατηρούμε ότι το  $H_t$  αποφασίζει για την τάξη που επιλέγεται από την (σταθμισμένη) πλειοψηφία όλων των υποθέσεων  $t$ . Το σφάλμα του  $H_t$  υπολογίζεται στη συνέχεια ως

$$E_t = \sum_{i: H_t(x_i) \neq y_i} D_t(i) = \sum_{i=1}^m D_t(i) [|H_t(x_i) \neq y_i|]$$

όπου  $[|*|]$  είναι 1 εάν ισχύει και 0 διαφορετικά. Εάν  $E_t > \frac{1}{2}$ , το τρέχον  $h_t$  απορρίπτεται, επιλέγεται ένα νέο υποσύνολο κατάρτισης και παράγεται ένα νέο  $h_t$ . Αυτό, ωστόσο, είναι απίθανο να συμβεί, αφού όλα τα  $h_t$  έχουν ήδη επαληθευτεί στο βήμα 4 για να ταξινομήσουν σωστά τουλάχιστον το 50% των περιπτώσεων. Αυτό μπορεί να συμβεί μόνο όταν εισαχθεί μια νέα βάση δεδομένων  $D_{k+1}$ . Αν  $E_t < \frac{1}{2}$ , τότε το σύνθετο κανονικοποιημένο σφάλμα υπολογίζεται ως

$$B_t = \frac{E_t}{(1 - E_t)}$$

Τα βάρη  $w_t(i)$  στη συνέχεια ενημερώνονται, τα οποία χρησιμοποιούνται για τον υπολογισμό της επόμενης κατανομής  $D_{t+1}$ , η οποία με τη σειρά της χρησιμοποιείται για την επιλογή των επόμενων υποσυνόλων εκπαίδευσης και ελέγχου,  $TR_{t+1}$  και  $TE_{t+1}$ , αντίστοιχα. Ο κανόνας ενημέρωσης διανομής αποτελεί την καρδιά του αλγορίθμου, καθώς επιτρέπει στο Learn ++ να υποστηρίζει προοδευτική εκπαίδευση:

$$W_{t+1}(i) = W_t(i) \times \begin{cases} B_t, & \text{εάν } H_t(x_i) = y_i \\ 1, & \text{σε όλες τις άλλες περιπτώσεις} \end{cases} = W_t(i) \times B_t^{1 - [|H_t(x_i) \neq y_i|]}$$

Σύμφωνα με τον κανόνα αυτό, αν η περίπτωση  $x_i = 1, 2, \dots, m$ , ταξινομείται σωστά από τη σύνθετη υπόθεση  $H_t$ , το βάρος της πολλαπλασιάζεται με συντελεστή  $B_t$ , ο οποίος, εξ ορισμού, είναι μικρότερος από 1. Εάν  $x_i$  είναι λάθος κατηγοριοποιημένα, το βάρος διανομής του παραμένει αμετάβλητο. Αυτός ο κανόνας μειώνει την πιθανότητα σωστά ταξινομημένων περιπτώσεων να επιλέγονται σε  $TR_{t+1}$  και αντίθετα αυξάνει την πιθανότητα εμφάνισης εσφαλμένων περιπτώσεων σε  $TR_{t+1}$ . Αν ερμηνεύσουμε περιπτώσεις που έχουν επανειλημμένα ταξινομηθεί λάθος, ως δύσκολα να εκπαιδευτούν παραδείγματα και εκείνα που έχουν ταξινομηθεί σωστά ως παραδείγματα εύκολης εκμάθησης, ο αλγόριθμος επικεντρώνεται όλο και περισσότερο στις δύσκολες περιπτώσεις και αναγκάζει πρόσθετους ταξινομητές να εκπαιδεύονται μαζί τους.

Αφού δημιουργηθούν οι υποθέσεις  $T_k$  για κάθε όλες τις περιπτώσεις  $D_k$ , η τελική υπόθεση (τελικός κανόνας ταξινόμησης) προκύπτει από την σταθμισμένη πλειοψηφία όλων των υποθέσεων. Ο μηχανισμός ψηφοφορίας βελτιώνει αποτελεσματικά το όριο απόφασης από τις ακαθάριστες εκτιμήσεις που παρέχονται από κάθε υπόθεση.

Ο αλγόριθμος μαθαίνει νέες πληροφορίες δημιουργώντας πρόσθετους ταξινομητές και ταυτόχρονα διατηρεί τη γνώση που αποκτήθηκε νωρίτερα. Ο κανόνας ενημέρωσης βάρους επιτρέπει ένα αποτελεσματικό μέσο επίτευξης της προοδευτικής μάθησης συγκεντρώνοντας κατά κύριο λόγο τις δύσκολες για ταξινομήσεις περιπτώσεις. Αυτό ισχύει ιδιαίτερα όταν εισάγονται νέες κλάσεις από νέα δεδομένα, επειδή όλοι οι ταξινομητές που δημιουργήθηκαν στις προηγούμενες επαναλήψεις θα ταξινομήσουν λανθασμένα τις περιπτώσεις από τη νέα τάξη. Επομένως, αυτές οι περιπτώσεις θα ταξινομηθούν εσφαλμένα από τη σύνθετη υπόθεση και θα μετακινηθούν στην επόμενη κατανομή. Ένα τμήμα σωστά ταξινομημένων περιπτώσεων περιλαμβάνεται επίσης στο επόμενο δεδομένων εκπαίδευσης, για να εξασφαλιστεί κάποια ισορροπία μεταξύ των κλάσεων. Η διαδικασία δεν θα λειτουργούσε εξίσου αποτελεσματικά, εάν ο κανόνας ενημέρωσης βάρους βασιζόταν στην απόδοση ταξινόμησης μόνο του  $h_t$  (καθώς το AdaBoost το εφαρμόζει για να ενημερώσει τη διανομή του) αντί της σύνθετης υπόθεσης  $H_t$ .

Το Learn ++ είναι ένας απλός αλγόριθμος, εύκολος στην εφαρμογή και συγκλίνει πολύ πιο γρήγορα από ισχυρούς αλγόριθμους εκμάθησης. Αυτό οφείλεται στο γεγονός ότι η χρήση αδύναμων μαθητών εξαλείφει το πρόβλημα της υπερεκπαίδευσης. Τα αρχικά αποτελέσματα σε δεδομένα που χρησιμοποιούν αυτόν τον αλγόριθμο φαίνονται πολλά υποσχόμενα, αλλά υπάρχει σημαντικό

περιθώριο βελτίωσης και πολλά ερωτήματα που πρέπει να απαντηθούν. Ο αλγόριθμος έχει δύο βασικά στοιχεία, τα οποία και τα δύο μπορούν να βελτιωθούν.

Η πρώτη είναι η επιλογή του επόμενου συνόλου δεδομένων κατάρτισης, το οποίο εξαρτάται από τον κανόνα ενημέρωσης διανομής. Το AdaBoost εξαρτάται αποκλειστικά από την απόδοση των ατόμων, ενώ το Learn ++ χρησιμοποιεί την απόδοση των συνολικών ενημερώσεων διανομής. Ο πρώτος εγγυάται την ευρωστία και αποτρέπει την επιδείνωση της απόδοσης, ενώ το τελευταίο επιτρέπει την αποδοτική αυξητική ικανότητα μάθησης κατά την εισαγωγή νέων τάξεων. Ένας κατάλληλος συνδυασμός των δύο συστημάτων ενημέρωσης μπορεί να προσφέρει τα βέλτιστα επίπεδα απόδοσης. Η αρχικοποίηση της κατανομής όταν εισάγεται μια νέα βάση δεδομένων μπορεί επίσης να βελτιστοποιηθεί με μια αρχική αξιολόγηση ταξινόμησης των σύνθετων υποθέσεων στη νέα βάση δεδομένων. Ο δεύτερος βασικός παράγοντας στο Learn ++ είναι ο κανόνας συνδυασμού υποθέσεων. Επί του παρόντος, τα βάρη ψηφοφορίας καθορίζονται με βάση τις επιδόσεις των υποθέσεων στο δικό τους υποσύνολο δεδομένων εκπαίδευσης. Αυτό δεν είναι βέλτιστο, αφού η απόδοση μιας υπόθεσης σε ένα συγκεκριμένο υποσύνολο του χώρου εισόδου δεν εγγυάται την εκτέλεση αυτής της υπόθεσης σε μια άγνωστη περίπτωση, η οποία μπορεί να προέρχεται από ένα διαφορετικό υποσύνολο του χώρου. Αυτός ο κανόνας του στατικού συνδυασμού μπορεί να αντικατασταθεί από έναν δυναμικό κανόνα που εκτιμά ποιες υποθέσεις είναι πιθανό να ταξινομήσουν σωστά μια δεδομένη (άγνωστη) παρουσία, με βάση στατιστικές μετρήσεις απόστασης ή εκ των υστέρων πιθανότητες, και να καθορίσουν αντίστοιχα βάρη ψηφοφορίας για κάθε περίπτωση. Άλλα θέματα περιλαμβάνουν την επιλογή παραμέτρων αλγορίθμου και τη χρήση άλλων κατηγοριοποιητών ως αδύναμων μαθητών. Οι παράμετροι του αλγορίθμου, όπως η αρχιτεκτονική ταξινομητή βάσης, ο στόχος σφάλματος, ο αριθμός υποθέσεων που πρόκειται να δημιουργηθούν, επιλέγονται επί του παρόντος κατά τρόπο μάλλον ad hoc. Αν και ο αλγόριθμος φαίνεται να είναι μη ευαίσθητος σε μικρές αλλαγές σε αυτές τις παραμέτρους, μια τυπική μέθοδος για την επιλογή τους θα ήταν επωφελής. Η μελλοντική εργασία θα περιλαμβάνει επίσης την αξιολόγηση του Learn ++ με άλλους ταξινομητές που χρησιμοποιούνται ως αδύναμοι εκπαιδευόμενοι, όπως οι RBF NN και οι αλγόριθμοι ταξινόμησης / ομαδοποίησης που βασίζονται σε NN.

Τέλος, η σταθμισμένη πλειοψηφία για τον συνδυασμό των υποθέσεων υποδεικνύει έναν απλό τρόπο εκτίμησης της αξιοπιστίας της τελικής απόφασης και των ορίων εμπιστοσύνης των στοιχείων απόδοσης. Συγκεκριμένα, αν μια τεράστια (οριακή) πλειοψηφία συμφωνεί με την τάξη μιας συγκεκριμένης στιγμής, τότε αυτό μπορεί να ερμηνευτεί ως ο αλγόριθμος που έχει υψηλή (χαμηλή) εμπιστοσύνη στην τελική απόφαση. Μια επίσημη ανάλυση της αξιοπιστίας και των διαστημάτων εμπιστοσύνης του ταξινομητή των εξόδων ταξινομητή μπορεί να γίνει με την εκ των υστέρων υπολογισμό πιθανών αποδόσεων ταξινομητή, οι οποίες στη συνέχεια μπορούν να συγκριθούν με εκείνες που λαμβάνονται με τη χρήση μηχανισμού καταμέτρησης ψήφων.

## 5.5 Neuroevolution

Το Neuroevolution είναι μια τεχνική μηχανικής μάθησης που εφαρμόζει εξελικτικούς αλγόριθμους για την κατασκευή τεχνητών νευρωνικών δικτύων, εμπνευσμένη από την εξέλιξη των βιολογικών νευρικών συστημάτων στη φύση. Σε σύγκριση με άλλες μεθόδους εκπαίδευσης νευρωνικών δικτύων, η neuroevolution είναι πολύ γενική, επιτρέπει την εκμάθηση χωρίς σαφείς στόχους, με μόνο αραιή ανατροφοδότηση και με αυθαίρετα νευρικά μοντέλα και δομές δικτύου [36].

Η προσέγγιση της Neuroevolution στην τεχνητή νοημοσύνη υποκινείται από την εξέλιξη των βιολογικών νευρικών συστημάτων. Αντίστοιχα, η Neuroevolution χρησιμοποιεί μέρη της φυσικής εξέλιξης (δηλαδή εξελικτικούς αλγόριθμους) για την κατασκευή μερών βιολογικών νευρωνικών δικτύων (δηλ. Τεχνητά νευρωνικά δίκτυα). Ένας γενικά φιλόδοξος στόχος είναι να εξελιχθούν




σύνθετα τεχνητά νευρωνικά δίκτυα ικανά για έξυπνη συμπεριφορά. Ως αποτέλεσμα, η Neuroevolution μπορεί να θεωρηθεί και ως μέσο για να διερευνηθεί πώς εξελίχθηκε η νοημοσύνη στη φύση, καθώς και μια πρακτική μέθοδος για την κατασκευή τεχνητών νευρωνικών δικτύων για την εκτέλεση των επιθυμητών εργασιών.

Παρόμοια με τη φυσική επιλογή στη φύση, η οποία οδηγείται μόνο από την ανατροφοδότηση από την αναπαραγωγική επιτυχία, η neuroevolution καθοδηγείται από κάποιο μέτρο συνολικής απόδοσης. Ενώ οι πιο συνηθισμένοι αλγόριθμοι μάθησης τεχνητού νευρικού δικτύου λειτουργούν μέσω εποπτευόμενης μάθησης και κατά συνέπεια εξαρτώνται από ένα επισημασμένο σώμα ζευγαριών εισόδου-εξόδου, το κύριο πλεονέκτημα της Neuroevolution είναι ότι επιτρέπει την εκμάθηση ακόμη και όταν τέτοια δεδομένα δεν είναι διαθέσιμα, βασισμένα μόνο σε αραιή ανατροφοδότηση. Για παράδειγμα, στα παιχνίδια (υπολογιστών), στον έλεγχο των οχημάτων και στη ρομποτική, οι βέλτιστες ενέργειες σε κάθε χρονική στιγμή δεν είναι πάντοτε γνωστές. Είναι δυνατόν να παρατηρήσουμε μόνο πόσο καλά λειτούργησε μια ακολουθία ενεργειών, π.χ. με αποτέλεσμα να κερδίσετε ή να χάσετε το παιχνίδι. Το Neuroevolution καθιστά δυνατή την εξεύρεση ενός νευρικού δικτύου που βελτιστοποιεί τη συμπεριφορά δίνοντας μόνο μια τέτοια αραιή ανατροφοδότηση, χωρίς άμεσες πληροφορίες για το τι ακριβώς θα έπρεπε να κάνει.

Επιπλέον, η Neuroevolution γενικεύει σε ένα ευρύ φάσμα αρχιτεκτονικών δικτύων και νευρικών μοντέλων, η εφαρμογή της Neuroevolution απαιτεί μόνο ότι η απόδοση των δικτύων μπορεί να αξιολογηθεί με την πάροδο του χρόνου και ότι η συμπεριφορά των δικτύων μπορεί να τροποποιηθεί μέσω της εξέλιξης. Ενώ οι περισσότερες μέθοδοι νευρικής μάθησης εστιάζουν στην τροποποίηση μόνο των δυνατοτήτων των νευρικών συνδέσεων (δηλαδή των βαρών σύνδεσης τους), η neuroevolution μπορεί να βελτιστοποιήσει επιπρόσθετα και άλλες παραμέτρους όπως η δομή του δικτύου (π.χ. προσθήκη νευρώνων ή συνδέσεων) νευρώνων, ακόμη και κανόνες μάθησης που τροποποιούν το δίκτυο κατά την αξιολόγηση. Είναι ενδιαφέρον ότι η ενσωμάτωση τέτοιων κανόνων με μεγάλη διάρκεια ζωής (π.χ. Hebbian ή neuromodulated ελαστικότητα) επιτρέπει εξελισσόμενα νευρωνικά δίκτυα να μάθουν από την εμπειρία που αποκτούν. Με αυτόν τον τρόπο, η Neuroevolution μπορεί να διευκολύνει τη διερεύνηση της βιολογικής προσαρμογής σε πολλαπλές χρονικές κλίμακες [37].

Οι πιο συνηθισμένες εφαρμογές της Neuroevolution είναι η ενίσχυση της μάθησης, η εξελικτική ρομποτική και η τεχνητή ζωή. Δείγμα εφαρμογών περιλαμβάνουν εξελισσόμενες συμπεριφορές για επιτραπέζια παιχνίδια και βιντεοπαιχνίδια, έλεγχο κινήσεων ρομπότ και διερεύνηση της εξέλιξης των βιολογικά σχετικών συμπεριφορών.

Τυπικά στη Neuroevolution, αναπτύσσεται ένας πληθυσμός γενετικών κωδικοποιήσεων νευρωνικών δικτύων προκειμένου να βρεθεί ένα δίκτυο που να επιλύει το δεδομένο έργο. Οι περισσότερες μέθοδοι neuroevolution ακολουθούν τον συνήθη βρόχο παραγωγής και δοκιμής εξελικτικών αλγορίθμων.



Εικόνα 31 - Neuroevolution

Κάθε κωδικοποίηση στον πληθυσμό (ένας γονότυπος) επιλέγεται με τη σειρά και αποκωδικοποιείται στο αντίστοιχο νευρωνικό δίκτυο (ένας φαινότυπος). Αυτό το δίκτυο στη συνέχεια χρησιμοποιείται στην εφαρμογή και η απόδοσή του με την πάροδο του χρόνου μετράτε, επιτυγχάνοντας μια τιμή φυσικής κατάστασης για τον αντίστοιχο γονότυπο. Αφού όλα τα μέλη του πληθυσμού έχουν αξιολογηθεί με αυτόν τον τρόπο, οι γενετικοί χειριστές χρησιμοποιούνται για να δημιουργήσουν την επόμενη γενιά του πληθυσμού. Αυτές οι κωδικοποιήσεις με την υψηλότερη φυσική κατάσταση μεταλλάσσονται και διασχίζονται μεταξύ τους και οι απόγονοι που δημιουργούνται αντικαθιστούν τους γονότυπους με τη χαμηλότερη φυσική κατάσταση στον πληθυσμό. Συνεπώς, η διαδικασία αποτελεί μια έξυπνη παράλληλη αναζήτηση προς καλύτερους γονοτύπους και συνεχίζεται μέχρι να βρεθεί ένα δίκτυο με επαρκώς υψηλή φυσική κατάσταση [39].

Υπάρχουν διάφορες μέθοδοι για την ανάπτυξη νευρωνικών δικτύων ανάλογα με τον τρόπο κωδικοποίησης των δικτύων. Η πιο απλή κωδικοποίηση, μερικές φορές αποκαλούμενη συμβατική νευροεξέλιξη CNE (conventional neuroevolution), σχηματίζεται με τη συνένωση των αριθμητικών τιμών για τα βάρη του δικτύου. Αυτή η κωδικοποίηση επιτρέπει στην εξέλιξη να βελτιστοποιήσει τα βάρη μιας σταθερής αρχιτεκτονικής νευρωνικού δικτύου, μια προσέγγιση που είναι εύκολη στην εφαρμογή και είναι πρακτική σε πολλούς τομείς. Ωστόσο, η προσέγγιση CNE μπορεί να συγκλίνει σε παραπλανητικό τοπικό βέλτιστο, αυτό απαιτεί την επιλογή τοπολογίας κατάλληλου μεγέθους και δομημένου δικτύου. και κλιμακώνει ελάχιστα σε πιο δύσκολα προβλήματα επειδή ο αριθμός των παραμέτρων που πρόκειται να εξελιχθούν αυξάνεται γραμμικά ή τετραδικά στο μέγεθος του δικτύου.

Έχουν σχεδιαστεί πιο περίπλοκες κωδικοποιήσεις για την αποφυγή αυτών των προβλημάτων. Μια προσέγγιση είναι να εξεταστεί η εξέλιξη στο επίπεδο των συστατικών της λύσης αντί των πλήρων λύσεων. Δηλαδή, αντί ενός πληθυσμού πλήρων νευρωνικών δικτύων, αναπτύσσεται ένας πληθυσμός μερών νευρωνικού δικτύου, νευρώνων ή βάσεων σύνδεσης. Κάθε οντότητα αξιολογείται ως ένα μέρος ενός πλήρους δικτύου και η καταλληλότητα του αντικατοπτρίζει πόσο καλά συνεργάζεται με άλλες οντότητες στις συγκεκριμένες λύσεις που βοηθά να συνθέσει. Με αυτό τον τρόπο, το σύνθετο πρόβλημα της εύρεσης ενός δικτύου λύσεων χωρίζεται σε αρκετά μικρότερα υπό προβλήματα.

Μια άλλη προσέγγιση είναι να εξελιχθεί η τοπολογία του δικτύου εκτός από τα βάρη. Η ιδέα είναι ότι η επιλογή μιας κατάλληλης τοπολογίας είναι δύσκολη για τους πειραματιστές αλλά μπορεί να έχει μεγάλη επίδραση στην πειραματική έκβαση. Επιπρόσθετα, οι εξελισσόμενες τοπολογίες μπορούν να επιτύχουν καλύτερη απόδοση από ό, τι τα εξελισσόμενα βάρη. Μια πολλά υποσχόμενη προσέγγιση είναι να ξεκινήσουμε την εξέλιξη με απλές λύσεις και να τις κάνουμε σταδιακά πιο περίπλοκες. Μια τέτοια διαδικασία εφαρμόζεται στη βιολογία και είναι μια ισχυρή προσέγγιση στη μηχανική μάθηση γενικά.

Όλες οι παραπάνω μέθοδοι χαρτογραφούν την γενετική κωδικοποίηση απευθείας στο αντίστοιχο νευρωνικό δίκτυο. Κάθε τμήμα της κωδικοποίησης αντιστοιχεί σε ένα μέρος του δικτύου και αντιστρόφως. Η έμμεση κωδικοποίηση, αντίθετα, καθορίζει μια διαδικασία μέσω της οποίας κατασκευάζεται το δίκτυο, όπως η κυτταρική διαίρεση, η χωρική ενσωμάτωση ή η δημιουργία μέσω διασταλτικών γραμματικών κανόνων. Μία τέτοια κωδικοποίηση μπορεί να είναι πολύ συμπαγής (δηλ. Ένας μεγάλος αριθμός συνδέσεων μπορεί να κωδικοποιηθεί με λίγες παραμέτρους), και επίσης να επωφεληθούν από αρθρωτές λύσεις. Η modularity υποδηλώνει ότι οι ίδιες δομές μπορούν να επαναληφθούν με μικρές τροποποιήσεις, όπως συμβαίνει συχνά στη βιολογία. Η επιτυχής κλιμάκωση της neuroevolution σε επίπεδα βιολογικής πολυπλοκότητας (π.χ. σε εκατομμύρια ή δισεκατομμύρια νευρώνες) πιθανόν να εξαρτάται από την ανάπτυξη πιο περίπλοκων έμμεσων κωδικοποιήσεων, καθιστώντας τέτοιες κωδικοποιήσεις μια σημαντική κατεύθυνση για μελλοντική έρευνα.

Οι βασικοί μηχανισμοί της neuroevolution μπορούν να ενισχυθούν με διάφορους τρόπους, καθιστώντας την διαδικασία αποτελεσματικότερη και διευκολύνοντας την επίλυση πιο δύσκολων προβλημάτων. Μια από τις πιο βασικές επεκτάσεις είναι η διαδοχική εξέλιξη ή η διαμόρφωση. Η εξέλιξη ξεκινά με ένα απλό έργο και μόλις επιτύχει την λύση σε αυτό, οι λύσεις εξελίσσονται περαιτέρω σε ένα πιο δύσκολο έργο και μέσω μιας σειράς τέτοιων βημάτων, έως ότου τελικά φτάσει στον πραγματικό στόχο. Η διαμόρφωση μπορεί να λειτουργήσει μέσω της αλλαγής του περιβάλλοντος, όπως η σταδιακή αύξηση της δυσκολίας της εργασίας ή η αλλαγή της λειτουργίας ικανότητας, π.χ. ανταμείβοντας σταδιακά πιο περίπλοκες συμπεριφορές. Είναι συχνά δυνατό να επιλυθούν δύσκολες εργασίες πλησιάζοντάς τους σταδιακά ακόμα και όταν δεν μπορούν να λυθούν άμεσα [40].

Πολλές γενικές επεκτάσεις στις εξελικτικές μεθόδους υπολογισμού εφαρμόζονται ιδιαίτερα καλά για τη neuroevolution. Για παράδειγμα, οι ευφυείς τεχνικές μετάλλαξης όπως αυτές που χρησιμοποιούνται στις εξελικτικές στρατηγικές είναι αποτελεσματικές επειδή τα βάρη έχουν συχνά κατάλληλες συσχετίσεις. Ομοίως, πολλοί αντικειμενικοί εξελικτικοί αλγόριθμοι που εξισορροπούν τα επιτεύγματα σε σχέση με τους ανταγωνιστικούς στόχους μπορούν συχνά να ωφελήσουν τη neuroevolution. Τα νευρωνικά δίκτυα μπορούν επίσης να εξελιχθούν μέσω της συνεργασίας, όπου τα μέρη του πληθυσμού ανταγωνίζονται ή συνεργάζονται μεταξύ τους.

Συγκεκριμένα, μια κούρσα εξοπλισμών μπορεί να διευκολυνθεί από την εξέλιξη της τοπολογίας. Καθώς το δίκτυο γίνεται σταδιακά πιο περίπλοκο, η εξέλιξη είναι πιθανό να επεξεργαστεί τις υπάρχουσες συμπεριφορές αντί να τις αντικαταστήσει. Τέλος, διάφορες γενικές μέθοδοι εξελικτικής υπολογισμού για την αύξηση της εξερεύνησης ή της ποικιλομορφίας στο εσωτερικό του πληθυσμού είναι συχνά αποτελεσματικές και απαραίτητες όταν εφαρμόζονται η neuroevolution σε δύσκολα προβλήματα. Για παράδειγμα, η μείωση του ανταγωνισμού μεταξύ δικτύων με διαφορετικές τοπολογίες, ηλικίες ή λειτουργίες συχνά βελτιώνει τις επιδόσεις.

Από την άλλη, αρκετές επεκτάσεις χρησιμοποιούν τις ειδικές ιδιότητες του φαινοτύπου του νευρικού δικτύου. Για παράδειγμα, οι λειτουργίες ενεργοποίησης των νευρώνων, οι αρχικές

καταστάσεις και οι κανόνες μάθησης μπορούν να εξελιχθούν ώστε να ταιριάζουν σε ένα συγκεκριμένο έργο. Είναι σημαντικό ότι η εξέλιξη μπορεί να συνδυαστεί με άλλες μεθόδους μάθησης νευρικών δικτύων. Σε τέτοιες προσεγγίσεις, ενώ η εξέλιξη παρέχει συνήθως το αρχικό δίκτυο, τότε προσαρμόζεται περαιτέρω κατά την αξιολόγηση του. Η προσαρμογή μπορεί να πραγματοποιηθεί μέσω Hebbian ή neuromodulated ελαστικότητα, επιτρέποντας την προσαρμογή μέσω ανατροφοδότησης. Εναλλακτικά, μπορεί να χρησιμοποιηθεί εποπτευόμενη μάθηση, όπως οπίσθια διάδοση, υπό την προϋπόθεση ότι υπάρχουν στόχοι. Είναι ενδιαφέρον ότι ακόμα και αν δεν είναι γνωστές οι βέλτιστες συμπεριφορές, τέτοια εκπαίδευση μπορεί να είναι χρήσιμη. Τα δίκτυα μπορούν να εκπαιδευτούν για να μιμηθούν τα πιο επιτυχημένα άτομα του πληθυσμού ή ένα μέρος του δικτύου μπορεί να εκπαιδευτεί για να προβλέψει τις επόμενες εισόδους. Οι αλλαγές βάρους μπορούν να κωδικοποιηθούν ξανά στον γονότυπο, εφαρμόζοντας την εξέλιξη της Lamarckian, εναλλακτικά, μπορεί να επηρεάσουν την επιλογή μέσω του αποτελέσματος Baldwin, δηλαδή τα δίκτυα που μαθαίνουν καλά θα επιλεγούν για αναπαραγωγή ακόμα κι αν δεν έχουν κληρονομήσει οι ίδιες οι αλλαγές βάρους.

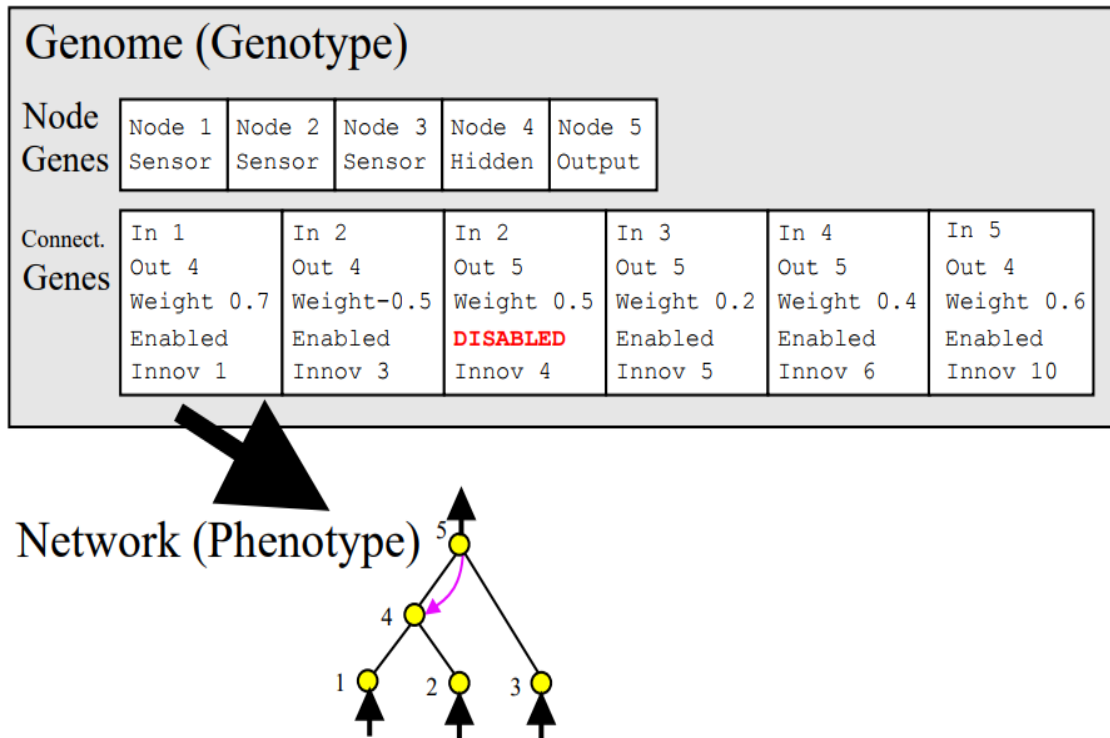
Υπάρχουν επίσης διάφοροι τρόποι ώστε να προκαταλάβετε και να κατευθύνετε το σύστημα μάθησης χρησιμοποιώντας την ανθρώπινη γνώση. Για παράδειγμα, οι κώδικες που δημιουργούνται από τον άνθρωπο μπορούν να κωδικοποιηθούν σε δομές μερικών δικτύων και να ενσωματωθούν στα εξελισσόμενα δίκτυα ως δομικές μεταλλάξεις. Τέτοιες γνώσεις μπορούν να χρησιμοποιηθούν για την εφαρμογή αρχικών συμπεριφορών στον πληθυσμό ή μπορούν να χρησιμεύσουν ως συμβουλή κατά την εξέλιξη. Σε περιπτώσεις όπου δεν υπάρχουν διαθέσιμες γνώμες βασισμένες σε κανόνες, ενδέχεται να είναι δυνατή η λήψη παραδειγμάτων ανθρώπινης συμπεριφοράς. Τέτοια παραδείγματα μπορούν στη συνέχεια να ενσωματωθούν στην εξέλιξη, είτε ως συστατικά της φυσικής κατάστασης είτε με την ρητή εκπαίδευση των εξελιγμένων λύσεων προς την ανθρώπινη συμπεριφορά, π.χ. μέσω της προώθησης. Ομοίως όπως συζητήθηκε παραπάνω, η γνώση σχετικά με την κάθε εφαρμογή και τα συστατικά της μπορεί να χρησιμοποιηθεί για το σχεδιασμό αποτελεσματικών στρατηγικών διαμόρφωσης. Με αυτό τον τρόπο, η ανθρώπινη τεχνογνωσία μπορεί να χρησιμοποιηθεί για να ξεκινήσει και να καθοδηγήσει την εξέλιξη σε δύσκολα καθήκοντα, καθώς και να την κατευθύνει προς τις επιθυμητές λύσεις.

## **NEAT**

Ο ποιο διαδεδομένος αλγόριθμος Topology and Weight Evolving Artificial Neural Networks (TWEANNs) είναι ο neuroevolution of augmenting topologies (NEAT) [43].

### **Γενετική κωδικοποίηση**

Το σχήμα γενετικής κωδικοποίησης της NEAT έχει σχεδιαστεί έτσι ώστε να επιτρέπει στα αντίστοιχα γονίδια να ευθυγραμμίζονται εύκολα όταν δύο γονιδιώματα διασταυρώνονται κατά τη διάρκεια της σύνδεσης. Έτσι, τα γονιδιώματα είναι γραμμικές αναπαραστάσεις συνδεσιμότητας δικτύου. Όπως παρουσιάζονται και στην παρακάτω εικόνα, ένας γονότυπος που παράγει τον εμφανιζόμενο φαινότυπο. Παρατηρούμε ότι το τρίτο γονίδιο είναι απενεργοποιημένο, οπότε η σύνδεση που καθορίζει (μεταξύ κόμβων 2 και 5) δεν εκφράζεται στον φαινότυπο.

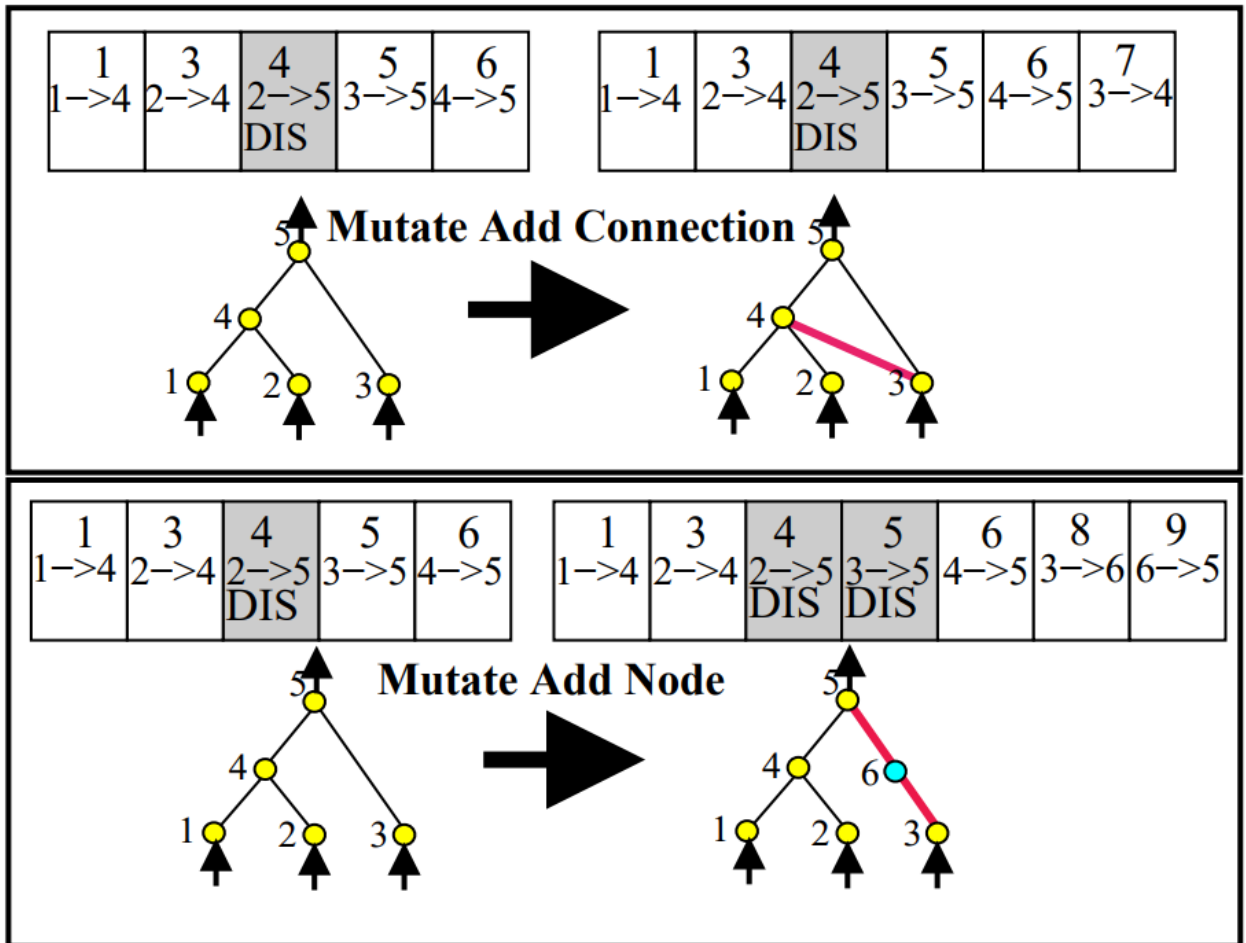


Εικόνα 32 - Παράδειγμα χαρτογράφησης γονότυπου προς φαινότυπο

Κάθε γονιδίωμα περιλαμβάνει μια λίστα γονιδίων σύνδεσης, καθένα από τα οποία αναφέρεται σε δύο γονίδια κόμβων που συνδέονται. Κάθε γονίδιο σύνδεσης καθορίζει τον εσωτερικό κόμβο, τον εξωτερικό κόμβο, το βάρος της σύνδεσης, ανεξάρτητα από το εάν εκφράζεται ή όχι το γονίδιο σύνδεσης (ένα bit ενεργοποίησης) και έναν αριθμό καινοτομίας που επιτρέπει την εύρεση αντίστοιχων γονιδίων.

Η μετάλλαξη στην NEAT μπορεί να αλλάξει τόσο τα βάρη σύνδεσης όσο και τις δομές δικτύου. Τα βάρη σύνδεσης μεταλλάσσονται όπως σε κάθε σύστημα neuroevolution, με κάθε σύνδεση να διαταράσσεται ή όχι σε κάθε γενιά. Οι δομικές μεταλλάξεις συμβαίνουν με δύο τρόπους. Κάθε μετάλλαξη διευρύνει το μέγεθος του γονιδιώματος με την προσθήκη γονιδίων. Στην προσθήκη μετάλλαξης σύνδεσης, προστίθεται ένα καινούριο γονίδιο σύνδεσης που συνδέει δύο μη συνδεδεμένους κόμβους. Στη μετάλλαξη προσθέτου κόμβου μια υπάρχουσα σύνδεση χωρίζεται και ο νέος κόμβος τοποθετείται εκεί όπου ήταν παλιά η παλιά σύνδεση. Η παλιά σύνδεση είναι απενεργοποιημένη και δύο νέες συνδέσεις προστίθενται στο γονιδίωμα. Οι δύο τύποι δομικής μετάλλαξης φαίνονται και στο παρακάτω σχήμα (εικόνα 33) [41].

Στο επόμενο σχήμα (εικόνα 33) απεικονίζονται τα γονίδια πάνω από τους φαινότυπους τους για τους δύο τύπους μετάλλαξης που παρέχει η NEAT. Ο μέγιστος αριθμός σε κάθε γονιδίωμα είναι ο αριθμός καινοτομίας αυτού του γονιδίου. Οι αριθμοί καινοτομίας είναι ιστορικοί δείκτες που προσδιορίζουν τον αρχικό ιστορικό πρόγονο κάθε γονιδίου. Στα νέα γονίδια αποδίδονται ολόένα και μεγαλύτεροι αριθμοί.



Εικόνα 33 - Οι δύο τύποι δομικής μετάλλαξης στην NEAT

**Παρακολούθηση γονιδίων μέσω των ιστορικών σημάνσεων**

Αποδεικνύεται ότι υπάρχουν ανεξερεύνητες πληροφορίες στην εξέλιξη που μας λένε ακριβώς ποια γονίδια ταιριάζουν με τα γονίδια μεταξύ οποιωνδήποτε ατόμων σε έναν τυπολογικά διαφορετικό πληθυσμό. Αυτή η πληροφορία είναι η ιστορική προέλευση κάθε γονιδίου στον πληθυσμό. Δύο γονίδια με την ίδια ιστορική προέλευση πρέπει να αντιπροσωπεύουν την ίδια δομή (αν και ενδεχομένως με διαφορετικά βάρη), καθώς προέρχονται και από το ίδιο προγονικό γονίδιο από κάποιο σημείο στο παρελθόν. Έτσι, το μόνο που χρειάζεται να γνωρίζει ένα σύστημα είναι τα γονίδια που ευθυγραμμίζονται με τα οποία γίνεται η παρακολούθηση της ιστορικής προέλευσης κάθε γονιδίου στο σύστημα.

Η παρακολούθηση της ιστορικής προέλευσης απαιτεί πολύ λίγους υπολογισμούς. Κάθε φορά που εμφανίζεται ένα νέο γονίδιο (μέσω δομικής μετάλλαξης), ένας γενικός αριθμός καινοτομίας αυξάνεται και αποδίδεται σε αυτό το γονίδιο. Οι αριθμοί καινοτομίας αντιπροσωπεύουν έτσι μια χρονολόγηση της εμφάνισης κάθε γονιδίου στο σύστημα. Για παράδειγμα, ας πούμε ότι οι δύο μεταλλάξεις στο προηγούμενο σχήμα εμφανίστηκαν το ένα μετά το άλλο στο σύστημα. Το νέο γονίδιο σύνδεσης που δημιουργήθηκε στην πρώτη μετάλλαξη έχει αντιστοιχιστεί στον αριθμό 7 και τα δύο νέα γονίδια σύνδεσης που προστέθηκαν κατά τη διάρκεια της νέας μετάλλαξης κόμβου έχουν αντιστοιχιστεί με αριθμούς 8 και 9. Στο μέλλον, όποτε αυτά τα γονιδιώματα ζευγαρώνονται, οι απόγονοι θα κληρονομήσουν τους ίδιους αριθμούς καινοτομίας σε κάθε γονίδιο, οι αριθμοί

καινοτομίας δεν αλλάζουν ποτέ. Έτσι, η ιστορική προέλευση κάθε γονιδίου στο σύστημα είναι γνωστή σε όλη την εξέλιξη.

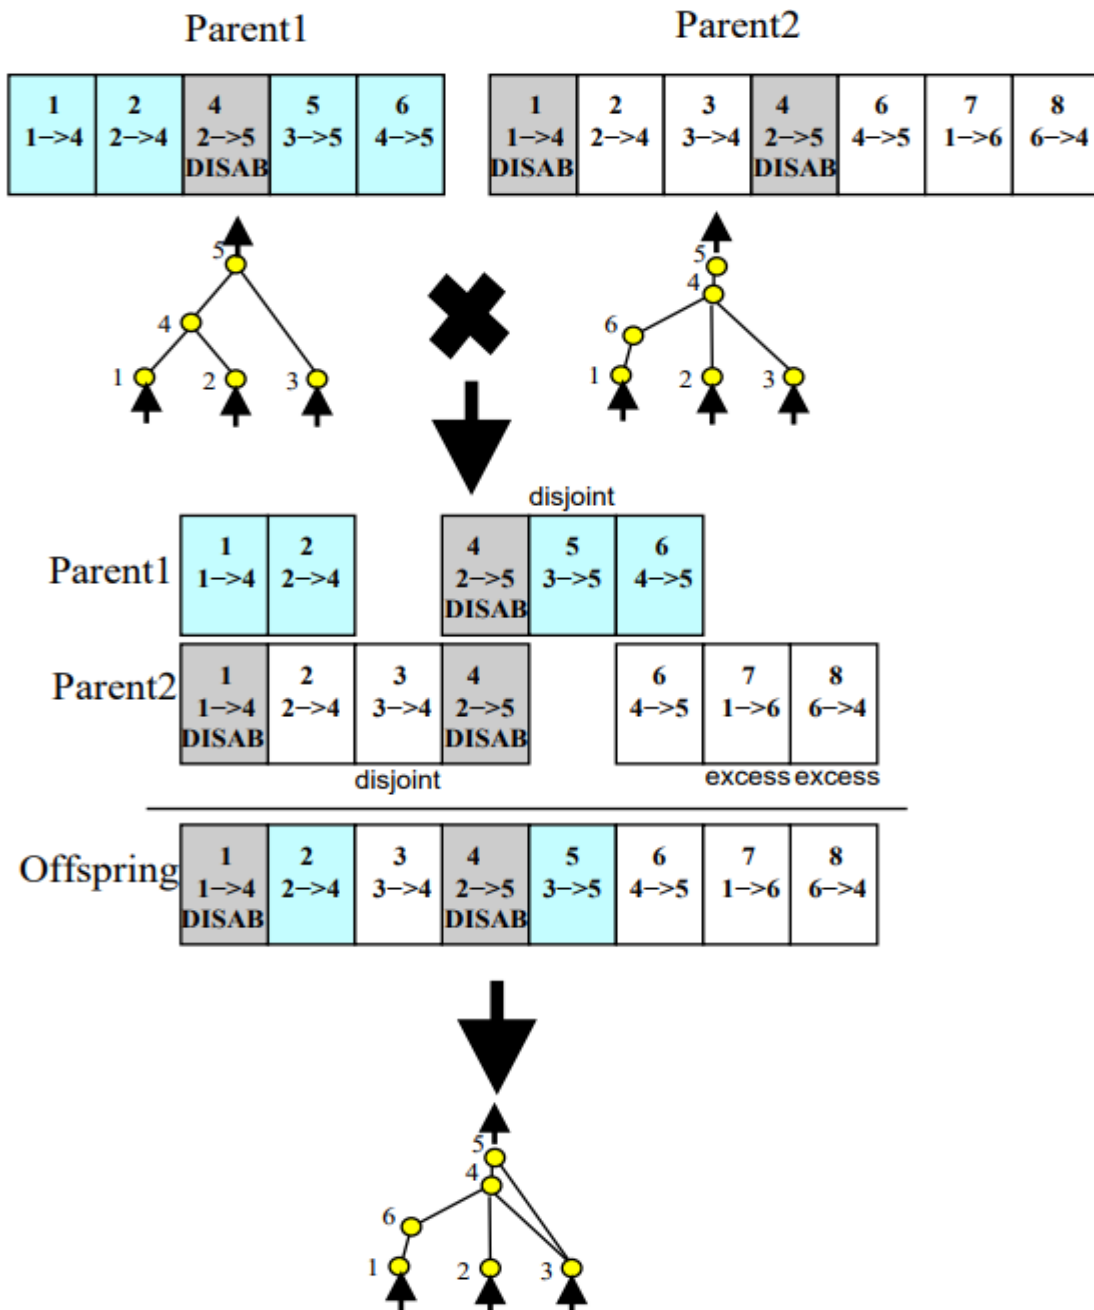
Οι ιστορικές σημάνσεις δίνουν στην NEAT μια ισχυρή ικανότητα, το σύστημα γνωρίζει ακριβώς ποια γονίδια ταιριάζουν με αυτά. Κατά τη διέλευση, τα γονίδια και στα δύο γονιδιώματα με τους ίδιους αριθμούς καινοτομίας παρατάσσονται. Αυτά τα γονίδια ονομάζονται ταιριαστά γονίδια. Τα γονίδια που δεν ταιριάζουν είναι είτε διαφορετικά σύνολα είτε περίσσεια, ανάλογα με το αν συμβαίνουν εντός ή εκτός του εύρους των αριθμών καινοτομίας του άλλου γονέα. Αντιπροσωπεύουν δομή που δεν υπάρχει στο άλλο γονιδίωμα. Κατά τη σύνθεση των απογόνων, τα γονίδια επιλέγονται τυχαία είτε από τον γονέα στα αντίστοιχα γονίδια, ενώ όλα τα υπερβολικά ή διαχωρισμένα γονίδια περιλαμβάνονται πάντα από τον πιο κατάλληλο γονέα ή αν είναι εξίσου κατάλληλοι και από τους δύο γονείς. Με αυτόν τον τρόπο, τα ιστορικά σήματα επιτρέπουν στο NEAT να εκτελέσει διασταύρωση χρησιμοποιώντας γραμμικά γονιδιώματα χωρίς την ανάγκη ακριβούς τοπολογικής ανάλυσης.

Με την προσθήκη νέων γονιδίων στον πληθυσμό και με τη λογική αντιστοίχιση γονιδιωμάτων που αντιπροσωπεύουν διαφορετικές δομές, το σύστημα μπορεί να διαμορφώσει έναν πληθυσμό διαφορετικών τοπολογιών. Ωστόσο, αποδεικνύεται ότι ένας τέτοιος πληθυσμός από μόνος του δεν μπορεί να διατηρήσει τις τοπολογικές καινοτομίες. Επειδή οι μικρότερες δομές βελτιστοποιούνται ταχύτερα από τις μεγαλύτερες δομές και η προσθήκη κόμβων και συνδέσεων αρχικά μειώνει την καταλληλότητα του δικτύου, οι πρόσφατα επαυξημένες δομές έχουν ελάχιστες ελπίδες να επιβιώσουν περισσότερες από μία γενιές, παρόλο που οι καινοτομίες που αντιπροσωπεύουν ενδέχεται να είναι κρίσιμες για την επίλυση του έργου μακροπρόθεσμα. Η λύση είναι να προστατευθεί η καινοτομία με την εξειδίκευση του πληθυσμού [42].

Στο παρακάτω σχήμα βλέπουμε την αντιστοίχιση γονιδιωμάτων για διαφορετικές τοπολογίες δικτύων με χρήση αριθμών καινοτομίας. Αν και ο γονέας 1 και ο γονέας 2 φαίνονται διαφορετικοί, οι αριθμοί καινοτομίας τους (που εμφανίζονται στην κορυφή κάθε γονιδίου) μας λένε ποια γονίδια ταιριάζουν με αυτά. Ακόμη και χωρίς κάποια τοπολογική ανάλυση, μπορεί να δημιουργηθεί μια νέα δομή που συνδυάζει τα επικαλυπτόμενα τμήματα των δύο γονέων καθώς και τα διάφορα μέρη τους. Τα γονίδια ταυτοποίησης κληρονομούνται τυχαία, ενώ τα διαζευγμένα γονίδια (εκείνα που δεν ταιριάζουν στη μέση) και τα υπερβολικά γονίδια (εκείνα που δεν ταιριάζουν στο τέλος) κληρονομούνται από τον πιο κατάλληλο γονέα. Σε αυτή την περίπτωση, υποτίθεται ότι υπάρχουν ίσες φυσικές ικανότητες, έτσι ώστε τα διαζευγμένα και τα υπερβολικά γονίδια κληρονομούνται επίσης τυχαία.

#### Προστασία της καινοτομίας με την εξειδίκευση του πληθυσμού

Η προδιαγραφή εφαρμόζεται συνήθως στη βελτιστοποίηση των πολυτροπικών λειτουργιών και στη συνένωση των αρθρωτών συστημάτων, όπου η κύρια λειτουργία της είναι η διατήρηση της ποικιλομορφίας. Λαμβάνουμε την γνώση από αυτούς τους τομείς και την εφαρμόζουμε στα TWEANN, για την προστασία την καινοτομία. Η εξειδίκευση επιτρέπει στους οργανισμούς να ανταγωνίζονται κυρίως μέσα στις δικές τους θέσεις αντί με τον πληθυσμό γενικότερα. Με αυτό τον τρόπο, οι τοπολογικές καινοτομίες προστατεύονται σε μια νέα θέση όπου έχουν το χρόνο να βελτιστοποιήσουν τη δομή τους μέσα από τον ανταγωνισμό στην εξειδικευμένη θέση.



Εικόνα 34 - Αντιστοίχιση γονιδιωμάτων για διαφορετικές τοπολογίες δικτύων με χρήση αριθμών καινοτομίας

Η ιδέα είναι να διαιρέσουμε τον πληθυσμό σε είδη έτσι ώστε παρόμοιες τοπολογίες να βρίσκονται στο ίδιο είδος. Αυτή η εργασία εμφανίζεται ως πρόβλημα αντιστοίχισης τοπολογίας. Ωστόσο, αποδεικνύεται και πάλι ότι οι ιστορικές ενδείξεις προσφέρουν μια πιο αποτελεσματική λύση. Ο αριθμός των πλεοναζόντων και διαζευγμένων γονιδίων μεταξύ ενός ζεύγους γονιδιωμάτων είναι ένα φυσικό μέτρο της συμβατότητάς τους. Όσες περισσότερες διαφορές έχουν δύο γονιδιώματα τόσο λιγότερο εξελικτική ιστορία μοιράζονται, επομένως τόσο λιγότερο συμβατά είναι μεταξύ τους. Συνεπώς, μπορούμε να μετρήσουμε την απόσταση συμβατότητας  $\delta$  των διαφορετικών δομών σε NEAT ως απλό γραμμικό συνδυασμό του αριθμού των γονιδίων υπερβολικά (E) και διαχωρισμένα γονίδια (D), καθώς και των μέσων διαφορετικών βαρών των αντιστοιχων γονιδίων (W):

$$\delta = \frac{c_1 E}{N} + \frac{c_2 D}{N} + c_3 W$$



Οι συντελεστές  $c_1, c_2$  και  $c_3$  μας επιτρέπουν να προσαρμόζουμε την σημαντικότητα των τριών παραγόντων. Ο παράγοντας  $N$  χαρακτηρίζει τον αριθμό των γενιών στο μεγαλύτερο γονιδίωμα, κανονικοποιείται για το μέγεθος του γονιδιώματος (μπορεί να οριστεί σε 1 εάν και τα δύο γονιδιώματα είναι μικρά, δηλ. αποτελούνται από λιγότερα από 20 γονίδια).

Το μέτρο απόστασης  $\delta$  μας επιτρέπει να εξειδικεύσουμε τα γονιδιώματα χρησιμοποιώντας ένα όριο συμβατότητας  $\delta_i$ . Τα γονιδιώματα συγκρίνονται με κάθε είδος ένα κάθε φορά, αν η απόσταση ενός γονιδιώματος από ένα τυχαία επιλεγμένο μέλος του είδους είναι μικρότερη από  $\delta_i$ , τοποθετείται σε αυτό το είδος. Κάθε γονιδίωμα τοποθετείται στο πρώτο είδος όπου ικανοποιείται αυτή η συνθήκη, έτσι ώστε κανένα γονιδίωμα να μην ανήκει σε περισσότερα από ένα είδη. Η μέτρηση  $\delta$  για ένα ζεύγος γονιδιωμάτων είναι γραμμική στον αριθμό των συνδέσεων παρόλο που  $\delta$  ακριβώς εκφράζει τη συμβατότητα μεταξύ πολυδιάστατων τοπολογιών. Η αποτελεσματικότητα αυτή είναι δυνατή λόγω των ιστορικών σημάνσεων.

Ως μηχανισμός αναπαραγωγής για το NEAT, χρησιμοποιούμε την σαφή κοινή καταλληλότητα, όπου οι οργανισμοί του ίδιου είδους πρέπει να μοιράζονται την καταλληλότητα της θέσης τους. Έτσι, ένα είδος δεν έχει την πολυτέλεια να γίνει πολύ μεγάλο ακόμα και αν πολλοί από τους οργανισμούς του αποδίδουν καλά. Ως εκ τούτου, οποιοδήποτε είδος είναι απίθανο να αναλάβει ολόκληρο τον πληθυσμό, το οποίο είναι κρίσιμο για την εφαρμογή της εξειδίκευση του πληθυσμού. Οι αρχικές καταλληλότητες προσαρμόζονται αρχικά διαιρώντας με τον αριθμό των ατόμων στο είδος. Στη συνέχεια, τα είδη αυξάνονται ή συρρικνώνονται ανάλογα με το αν η μέση προσαρμοσμένη καταλληλότητά τους είναι πάνω ή κάτω από το μέσο όρο του πληθυσμού:

$$N'_j = \frac{\sum_{i=1}^{N_j} f_{ij}}{\bar{f}}$$

Όπου  $N_j$  και  $N'_j$  είναι το παλιό και το νέο πλήθος ατόμων σε είδη  $j$ .  $f_{ij}$  είναι η ρυθμισμένη καταλληλότητα του ατόμου  $i$  στα είδη  $j$ . Και  $\bar{f}$  είναι η μέση τιμή ρυθμισμένης καταλληλότητας ολόκληρου του πληθυσμού. Το βέλτιστο  $r\%$  κάθε είδους τυχαία συνδυάζονται για να παράγουν  $N'_j$  απογόνους, αντικαθιστώντας ολόκληρο τον πληθυσμό του είδους. Σε σπάνιες περιπτώσεις όπου η καταλληλότητα ολόκληρου του πληθυσμού δεν βελτιώνεται για περισσότερο από 20 γενεές, μόνο τα δύο πρώτα είδη επιτρέπεται να αναπαράγονται, επαναπροσδιορίζοντας την αναζήτηση στους πιο ελπιδοφόρους χώρους [42].

#### Μείωση των διαστάσεων με την προοδευτική ανάπτυξη από την ελάχιστη δομή

Τα TWEANN αρχίζουν συνήθως με έναν αρχικό πληθυσμό τυχαίων τοπολογιών, έτσι η τοπολογική ποικιλομορφία εισάγεται από την αρχή στον πληθυσμό. Ωστόσο, δεν είναι σαφές ότι αυτή η πολυμορφία είναι απαραίτητη ή χρήσιμη. Ένας πληθυσμός τυχαίων τοπολογιών έχει μια πολύ αδικαιολόγητη δομή που δεν έχει αντέξει μια μοναδική αξιολόγηση καταλληλότητας. Επομένως, δεν υπάρχει τρόπος να γνωρίζουμε εάν είναι αναγκαία κάποια τέτοια δομή. Είναι όμως δαπανηρό επειδή, επειδή όσο περισσότερες συνδέσεις περιέχει ένα δίκτυο, τόσο μεγαλύτερος είναι ο αριθμός των διαστάσεων που πρέπει να αναζητηθούν για τη βελτιστοποίηση του δικτύου. Επομένως, με τυχαίες τοπολογίες ο αλγόριθμος μπορεί να σπαταλάει πολύ μεγάλη προσπάθεια βελτιστοποιώντας άσκοπα πολύπλοκες δομές.

Αντίθετα, η NEAT μεροληπτεί την αναζήτηση προς ελάχιστους διακριτούς χώρους ξεκινώντας από ένα ομοιόμορφο πληθυσμό δικτύων με μηδενικούς κρυμμένους κόμβους, δηλαδή όλες οι εισοδοί συνδέονται απευθείας με τις εξόδους. Η νέα δομή εισάγεται διαδοχικά, καθώς συμβαίνουν δομικές μεταλλάξεις και μόνο εκείνες οι δομές επιβιώνουν που θεωρούνται χρήσιμες μέσω

αξιολογήσεων καταλληλότητας. Με άλλα λόγια, οι δομικές επεξεργασίες που συμβαίνουν στην NEAT είναι πάντοτε δικαιολογημένες. Δεδομένου ότι ο πληθυσμός ξεκινάει όσον δυνατόν μικρότερος, ελαχιστοποιείται η διαστασιολόγηση του χώρου αναζήτησης και η NEAT αναζητά πάντοτε λιγότερες διαστάσεις από τα υπόλοιπα συστήματα TWEANN και σταθερής τοπολογίας neuroevolution. Η ελαχιστοποίηση των διαστάσεων δίνει στο NEAT πλεονέκτημα απόδοσης σε σύγκριση με άλλες προσεγγίσεις.

## 6 Συμπεράσματα

Τα βασικά χαρακτηριστικά ενός νευρωνικού δικτύου το οποίο θα εκπαιδευτεί πάνω σε ροές δεδομένων με προοδευτική μάθηση είναι : να είναι σε θέση να μάθει επιπλέον πληροφορίες από τα νέα δεδομένα εκπαίδευσης, χωρίς απαιτεί πρόσβαση στα αρχικά δεδομένα που χρησιμοποιούνται για την κατάρτιση του υφιστάμενου ταξινομητή, θα πρέπει να διατηρεί προηγουμένως αποκτημένη γνώση, θα πρέπει να είναι σε θέση να εκπαιδευτεί και με νέες κλάσεις που ίσως εμφανιστούν με τα νέα δεδομένα. Οι αλγόριθμοι που εξετάζουμε καλύπτουν όλα αυτά τα βασικά χαρακτηριστικά, όμως κάποιος είναι εξειδικευμένοι για κάποιες εφαρμογές και κάποιος άλλοι έχουν προτερήματα ή μειονεκτήματα στην εφαρμογή τους.

Το Fuzzy ARTMAP αν και πολύ καλός τύπος νευρωνικού δικτύου με πολύ καλά αποτελέσματα είναι πολύ ευαίσθητο στην επιλογή της παραμέτρου αβεβαιότητας, στα επίπεδα θορύβου. Επιπλέον, ο αλγόριθμος δημιουργεί μεγάλο αριθμό ομάδων που προκαλούν υπερφόρτωση εάν δεν έχει επιλεγεί σωστά η παράμετρος επαγρύπνησης.

Στο ΤοροART παρόλο που ο αριθμός των παραμέτρων που πρέπει να οριστούν στην αρχή είναι μικρός, πρέπει να χρησιμοποιούνται κάποιες προηγούμενες γνώσεις σχετικά με την κατανομή των δεδομένων εισόδου. Αυτό είναι ιδιαίτερα δύσκολο, καθώς η ΤοροART εκπαιδεύεται OnLine. Για την επίλυση του προβλήματος, η ιεραρχική δομή του ΤοροART μπορεί να αξιοποιηθεί, αφού παρέχει εναλλακτικές συστοιχίες της κατανομής δεδομένων εισόδου. Παρόλα αυτά είναι ένας αλγόριθμος που ειδικά για incremental εκπαίδευση συμπεριφέρεται πολύ καλά σε ελλιπή δεδομένα εισόδου.

Το Learn++ είναι ένας απλός αλγόριθμος νευρωνικού δικτύου, εύκολος στην εφαρμογή και συγκλίνει πολύ πιο γρήγορα από ισχυρούς αλγόριθμους εκμάθησης. Αυτό οφείλεται στο γεγονός ότι η χρήση αδύναμων μαθητών εξαλείφει το πρόβλημα της υπερεκπαίδευσης. Είναι ένα δίκτυο με πολύ καλή συμπεριφορά στα νέα δεδομένα που περιέχουν νέες ομάδες χωρίς να απαιτείται πρόσβαση στα παλαιότερα δεδομένα.

Τέλος η τεχνική Neuroevolution και συγκεκριμένα η NEAT είναι το πιο σύγχρονο από τους αλγόριθμους που εξετάζουμε, η NEAT είναι μια ισχυρή μέθοδος για τεχνητά εξελισσόμενα νευρωνικά δίκτυα. Η NEAT καταδεικνύει ότι η εξέλιξη της τοπολογίας μαζί με τα βάρη μπορεί να αποτελέσει μείζον πλεονέκτημα. Οι πειραματικές συγκρίσεις επιβεβαιώνουν ότι αυτή η εξέλιξη είναι αρκετές φορές πιο αποτελεσματική από τις άλλες μεθόδους neuroevolution μέχρι στιγμής. Οι μελέτες δείχνουν ότι οι ιστορικές σημάνσεις, η προστασία της καινοτομίας μέσω της συσχέτισης και η αυξητική ανάπτυξη από την ελάχιστη δομή λειτουργούν από κοινού για να παράγουν ένα σύστημα ικανό να εξελίξει λύσεις ελάχιστης πολυπλοκότητας.

## 7 Βιβλιογραφία

1. Dedić N. & Stanier C. (2016). Measuring the Success of Changes to Existing Business Intelligence Solutions to Improve Business Intelligence Reporting. *Lecture Notes in Business Information Processing*. 268. Springer International Publishing. pp. 225–236
2. Miller Devens, Richard. *Cyclopaedia of Commercial and Business Anecdotes; Comprising Interesting Reminiscences and Facts, Remarkable Traits and Humors of Merchants, Traders, Bankers Etc. in All Ages and Countries*. D. Appleton and company. p. 210. Retrieved 15 February 2014.
3. Rud, Olivia (2009). *Business Intelligence Success Factors: Tools for Aligning Your Business in the Global Economy*. Hoboken, N.J: Wiley & Sons.
4. *The Data Warehouse Lifecycle Toolkit* (2nd ed.). Ralph Kimball (2008).
5. *Microsoft Data Warehouse Toolkit*. Wiley Publishing. (2006)
6. Han, Kamber, Pei, Jaiwei, Micheline, Jian (June 9, 2011). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
7. Kantardzic, Mehmed (2003). *Data Mining: Concepts, Models, Methods, and Algorithms*. John Wiley & Sons.
8. Gama, João (2010). *Knowledge Discovery from Data Streams*. Data Mining and Knowledge Discovery. Chapman and Hall.
9. Ian H. Witten, Eibe Frank, Mark A. Hall (2011). *Practical Machine Learning Tools and Techniques*.
10. L. Rosasco, T. Poggio, *Machine Learning: A Regularization Approach*, MIT-9.520 Lectures Notes, Manuscript, Dec. 2015. Chapter 7 - Online Learning
11. Alexander Gepperth, Barbara Hammer. *Incremental learning algorithms and applications*. European Symposium on Artificial Neural Networks (ESANN), 2016, Bruges, Belgium
12. B. Ans and S. Rousset. *Avoiding catastrophic forgetting by coupling two reverberating neural networks*. *Academie des Sciences, Sciences de la vie*, 320, 1997.
13. Kshirsagar, P. and Rathod, N., 2012. *Artificial neural network*. *International Journal of Computer Applications*.
14. Basheer, I.A. and Hajmeer, M., 2000. *Artificial neural networks: fundamentals, computing, design, and application*. *Journal of microbiological methods*, 43(1), pp.3-31.
15. Jain, A.K., Mao, J. and Mohiuddin, K.M., 1996. *Artificial neural networks: A tutorial*. *Computer*, 29(3), pp.31-44.
16. Broomhead, D. S.; Lowe, David (1988). *Radial basis functions, multi-variable functional interpolation and adaptive networks* (Technical report).
17. Li, Xiangang; Wu, Xihong (2014-10-15). "Constructing Long Short-Term Memory based Deep Recurrent Neural Networks for Large Vocabulary Speech Recognition".
18. Kohonen, Teuvo (1982). "Self-Organized Formation of Topologically Correct Feature Maps". *Biological Cybernetics*. 43 (1): 59–69.
19. Sathasivam, Saratha. (2008)"Logic Learning in Hopfield Networks".
20. Holthaus, P. and Wachsmuth, S., 2013, August. *Direct on-line imitation of human faces with hierarchical ART networks*. In *RO-MAN, 2013 IEEE* (pp. 370-371). IEEE.
21. S. Haykin. *Neural Networks: A Comprehensive Foundation*. MacMillan College Publishing Company, New York, 1994.
22. J. Hertz, A. Krogh, and R. G. Palmer. *Introduction to the Theory of Neural Computation*. Addison-Wesley, Redwood City, 1991
23. T. Kohonen. *Self-Organization and Associative Memory*. Third edition, Springer-Verlag, 1989.

24. Gepperth, A. and Hammer, B., 2016. Incremental learning algorithms and applications. In European Symposium on Artificial Neural Networks (ESANN).
25. Carpenter, G.A. & Grossberg, S. (2003), Adaptive Resonance Theory, In Michael A. Arbib (Ed.), The Handbook of Brain Theory and Neural Networks, Second Edition (pp. 87-90). Cambridge, MA: MIT Press
26. Carpenter, G.A., Grossberg, S., & Reynolds, J.H. (1991), ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network, Neural Networks (Publication).
27. Carpenter, G.A., Grossberg, S., & Rosen, D.B. (1991b), Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system, Neural Networks (Publication).
28. Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J.H., & Rosen, D.B. (1992), Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, IEEE Transactions on Neural Networks.
29. Marko Tscherepanow. (2010) TopoART: A Topology Learning Hierarchical ART Network, In: Proceedings of the International Conference on Artificial Neural Networks (ICANN), Part III.
30. Kosko, B., 1986. Fuzzy entropy and conditioning. Information sciences, 40(2), pp.165-174.
31. Dagher, I., Georgiopoulos, M., Heileman, G.L. and Bebis, G., 1999. An ordering algorithm for pattern presentation in fuzzy ARTMAP that tends to improve generalization performance. IEEE transactions on neural networks, 10(4), pp.768-778.
32. Tscherepanow, M., Kortkamp, M. and Kammer, M., 2011. A hierarchical ART network for the stable incremental learning of topological structures and associations from noisy data. Neural Networks, 24(8), pp.906-916.
33. Tscherepanow, M., 2010, September. TopoART: A topology learning hierarchical ART network. In International Conference on Artificial Neural Networks (pp. 157-167). Springer Berlin Heidelberg.
34. Polikar, R., 2001. Learn++: an incremental learning algorithm based on psycho-physiological models of learning. In Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE (Vol. 1, pp. 672-675). IEEE.
35. Polikar, R., Byorick, J., Krause, S., Marino, A. and Moreton, M., 2002. Learn++: A classifier independent incremental learning algorithm for supervised neural networks. In Neural Networks, 2002. IJCNN'02. Proceedings of the 2002 International Joint Conference on (Vol. 2, pp. 1742-1747). IEEE.
36. Muhlbaier, M., Topalis, A. and Polikar, R., 2004, June. Learn++. MT: A new approach to incremental learning. In International Workshop on Multiple Classifier Systems (pp. 52-61). Springer, Berlin, Heidelberg.
37. Stanley, Kenneth O. (2017-07-13). "Neuroevolution: A different kind of deep learning". O'Reilly Media
38. Risi, Sebastian; Togelius, Julian (2017). "Neuroevolution in Games: State of the Art and Open Challenges" (PDF). IEEE Transactions on Computational Intelligence and AI in Games.
39. Schaffer, J. David; Whitley, Darrell and Eshelman, Larry J. (1992). Combinations of genetic algorithms and neural networks. In: COGANN-92, pp. 1-37.
40. Floreano, Dario; Dürr, Peter and Mattiussi, Claudio (2008). Neuroevolution: from architectures to learning. Evolutionary Intelligence 1: 47-62.
41. Stanley, K.O., Bryant, B.D. and Miikkulainen, R., 2005. Real-time neuroevolution in the NERO video game. IEEE transactions on evolutionary computation, 9(6), pp.653-668.
42. Stanley, K.O. and Miikkulainen, R., 2002. Evolving neural networks through augmenting topologies. Evolutionary computation, 10(2), pp.99-127.

43. Manning, T., Sleator, R.D. and Walsh, P., 2014. Biologically inspired intelligent decision making: a commentary on the use of artificial neural networks in bioinformatics. *Bioengineered*, 5(2), pp.80-95