



Πανεπιστήμιο Πειραιώς – Τμήμα Πληροφορικής

Πρόγραμμα Μεταπτυχιακών Σπουδών
«Προηγμένα Συστήματα Πληροφορικής»

Μεταπτυχιακή Διατριβή

Τίτλος Διατριβής	ΔΙΚΤΥΑ ΒΑΘΙΑΣ ΠΙΣΤΗΣ DEEP BELIEF NETWORKS
Όνοματεπώνυμο Φοιτητή	ΔΗΜΗΤΡΙΟΣ ΡΑΜΜΟΣ
Πατρώνυμο	ΧΡΗΣΤΟΣ
Αριθμός Μητρώου	ΜΠΣΠ/11037
Επιβλέπων	ΓΕΩΡΓΙΟΣ ΤΣΙΧΡΙΝΤΖΗΣ, ΚΑΘΗΓΗΤΗΣ

Ημερομηνία Παράδοσης **ΝΟΕΜΒΡΙΟΣ 2013**

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

Τριμελής Εξεταστική Επιτροπή

ΓΕΩΡΓΙΟΣ ΤΣΙΧΡΙΝΤΖΗΣ
ΚΑΘΗΓΗΤΗΣ

ΧΑΡΑΛΑΜΠΟΣ
ΚΩΝΣΤΑΝΤΟΠΟΥΛΟΣ
ΕΠΙΚΟΥΡΟΣ ΚΑΘΗΓΗΤΗΣ

ΑΓΓΕΛΟΣ ΠΙΚΡΑΚΗΣ
ΛΕΚΤΟΡΑΣ

ΠΡΟΛΟΓΟΣ

Τα deep belief networks είναι ένας νέος τομέας στην επιστήμη της πληροφορικής, ο οποίος έχει αναπτυχθεί αρκετά τα τελευταία χρόνια και συνεχίζει να αναπτύσσεται σταδιακά με ραγδαία, σημαντικά, καινοτόμα και πολύ χρήσιμα αποτελέσματα για τους επιστήμονες. Εκτός από τον κλάδο της πληροφορικής έχει αντίκτυπο και σε άλλους κλάδους όπως αυτός της ιατρικής, της μόρφωσης, των τεχνών και γενικώς ολόκληρης της καθημερινότητας μας. Η σωστή αξιοποίηση των αποτελεσμάτων αυτών βοηθά όλους τους κλάδους να αναπτυχθούν, να βελτιωθούν και να προοδεύσουν.

Αυτή η διπλωματική διατριβή μπορεί να απαντήσει σε βάθος στα ακόλουθα ερωτήματα.

- Τι είναι η αναγνώριση προτύπου;
- Γιατί είναι σημαντική και ποιες είναι οι χρήσεις της αναγνώρισης προτύπου;
- Ποιές οι διαφορές μεταξύ των 3 κατηγοριών μάθησης (learning). Supervised, Unsupervised και Semi-supervised learning
- Τι είναι τα deep belief networks;
- Ποιές είναι οι ιδιότητες τους;

- Τι είναι τα modular deep belief networks;
- Ποιός είναι ο τρόπος λειτουργίας τους, τι σκοπούς εξυπηρετούν και ποιες οι διαφορές τους σε σχέση με τα απλά deep belief networks;

Specifically, in the first chapter we provide a general introduction on the pattern recognition and its evolution through time and we mention most of the areas (character recognition, computer - aided diagnosis, data mining, etc) in which the results of pattern recognition have brought great progress or are able to bring in the future. We also analyze the categories of learning, such as supervised, unsupervised and semi-supervised learning, as well as the educational methods used by each of these methods.

In the second chapter, in which we are now entering the main part of the thesis we try to make the reader understand the meaning of deep belief networks and their use, giving some specific definitions and analyzing their properties.

In the last chapter, we analyze another separate category of deep belief networks, the so-called modular deep belief networks which are able not to forget features, elements and data that have been taught in the past without having losses when new data is entered in place the previous ones. We analyze the operation of these networks compared to simple deep belief networks and through some experiments that have been conducted and some appropriate figures, we give the reader the opportunity to understand their meaning and function completely.

Περιεχόμενα

ΠΡΟΛΟΓΟΣ.....	3
ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ.....	6
ΜΕΡΟΣ Α : ΕΙΣΑΓΩΓΗ.....	7
ΚΕΦΑΛΑΙΟ 1 : ΕΙΣΑΓΩΓΗ ΣΤΗ ΜΑΘΗΣΗ.....	8
1.1 Γιατί είναι σημαντική η αναγνώριση προτύπου.....	8
1.2 Χαρακτηριστικά, Διανύσματα χαρακτηριστικών και Ταξινομητές.....	10
1.3 Επιτηρούμενη, μη-επιτηρούμενη και ημιεπιτηρούμενη μάθηση.....	13
1.4 Εκπαιδευτικές μέθοδοι για επιτηρούμενη μάθηση.....	15

1.4.1 Εμπειρική ελαχιστοποίησης του κινδύνου	15
1.4.2 Διαρθρωτική ελαχιστοποίησης του κινδύνου.....	15
1.5 Εκπαιδευτικές μέθοδοι για ημιεπιτηρούμενη μάθηση	16
1.5.1 Γενετικά μοντέλα	16
1.5.2 Μέθοδοι βασισμένοι σε γραφήματα.....	17
1.5.3 Μέθοδοι εύρεσης	17
ΜΕΡΟΣ Β : ΚΥΡΙΟ ΜΕΡΟΣ ΕΡΓΑΣΙΑΣ	19
ΚΕΦΑΛΑΙΟ 2 : ΔΙΚΤΥΑ ΒΑΘΙΑΣ ΠΙΣΤΗΣ (DBNs).....	19
2.1 Εισαγωγή	19
2.2 Δίκτυα βαθιάς πίστης σε σχέση με τα απλά κυκλώματα μάθησης	20
2.3 Η θεωρητική τεκμηρίωση της μαθησιακής διαδικασίας.....	21
2.4 Δίκτυα βαθιάς πίστης με άλλου τύπου μεταβλητές.....	21
2.5 Εφαρμογές των δικτύων βαθιάς πίστης.....	21
ΚΕΦΑΛΑΙΟ 3 : ΚΥΚΛΩΜΑΤΙΚΑ ΔΙΚΤΥΑ ΒΑΘΙΑΣ ΠΙΣΤΗΣ ΑΦΟΜΟΙΩΣΗΣ ΔΕΔΟΜΕΝΩΝ.....	21
3.1 Εισαγωγή	21
3.2 Κυκλωματικά δίκτυα βαθιάς πίστης	22
3.2.1 Δίκτυα βαθιάς πίστης.....	22
3.2.2 Κυκλωματικά δίκτυα βαθιάς πίστης που δεν ξεχνούν	23
3.2.3 Μέθοδοι εκπαίδευσης.....	24
3.3 Πειράματα	24
3.3.1 Εξειδίκευση κυκλωμάτων	26
3.3.2 Θέματα - Προβλήματα μη σταθερών ψηφίων.....	27
ΣΥΜΠΕΡΑΣΜΑΤΑ.....	31
ΒΙΒΛΙΟΓΡΑΦΙΑ	32

ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ

Σχήμα 1.1 εικόνων που αντιστοιχούν (a) στην κλάση A και (b) στην κλάση B	11
Σχήμα 1.2 Μέση τιμή έναντι τυπικής απόκλισης κλάσης A(o) και B(+). Η ευθεία γραμμή ξεχωρίζει τις 2 κλάσεις.....	11
Σχήμα 1.3 Τα βασικά στάδια για το σχεδιασμό ενός συστήματος ταξινόμησης.....	13
Σχήμα 1.4 (a) Διάφοροι τύποι εδάφους και (b) ομαδοποίηση των αντίστοιχων χαρακτηριστικών για την πολυφασματική απεικόνιση με δύο ζώνες	14
Σχήμα 3.1 Αρχιτεκτονικές δικτύων: (a) Μονολιθικό DBN, (b) modular M-DBN. Και οι 2 αρχιτεκτονικές έχουν κοινά τα πρώτα στρώματα (γκρι κουτιά). 23	23
Σχήμα 3.2 Η αναλογία των καλύτερων επαναδημιουργημένων δειγμάτων ανά κύκλωμα και η κλάση ψηφίου κατά τη διάρκεια διαφορετικών σταδίων εκπαίδευσης: αμέσως μετά την τυχαία αρχικοποίηση βαρών (αριστερά), μετά από έναν εκπαιδευτικό κύκλο (κέντρο) και μετά από 100 εκπαιδευτικούς κύκλους (δεξιά).....	26
Σχήμα 3.3 Αποδοτικότητα του DBN και του M-DBN (αριστερά). Του forgetting M-DBN και του M-DBN(δεξιά) κατά τη διαδικασία της μετακίνησης. Η εκπαίδευση ξεκινά με τα ψηφία 0-5 και συνεχίζει με τα ψηφία 0-2 μετά από 200 epoch. Η αποδοτικότητα της ταξινόμησης \mathcal{F}^* και του δείκτη εξειδίκευσης \mathcal{S} βασίζεται στα ψηφία 0-5 στην MNIST data set.	28
Σχήμα 3.4 Η αποδοτικότητα του DBN και του M-DBN κατά τη διαδικασία της αντικατάστασης ψηφίου	29

ΜΕΡΟΣ Α : ΕΙΣΑΓΩΓΗ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΚΕΦΑΛΑΙΟ 1 : ΕΙΣΑΓΩΓΗ ΣΤΗ ΜΑΘΗΣΗ

1.1 Γιατί είναι σημαντική η αναγνώριση προτύπου

Η αναγνώριση προτύπου είναι η επιστημονική θεωρία της οποίας ο στόχος είναι η κατάταξη των αντικειμένων σε κατηγορίες ή κλάσεις. Αυτά τα αντικείμενα μπορεί να είναι είτε εικόνες ή κυματομορφές σημάτων ή οτιδήποτε είδος μετρήσεων τα οποία πρέπει να κατηγοριοποιηθούν. Αυτά τα αντικείμενα είναι γνωστά με τον όρο πρότυπα. Η αναγνώριση προτύπου είναι γνώση από το μακρινό παρελθόν αλλά πριν από το 1960 χρησιμοποιούταν κυρίως για θεωρητική έρευνα στον τομέα της στατιστικής. Η έλευση της επιστήμης της πληροφορικής και κατ'επέκταση η δημιουργία των ηλεκτρονικών υπολογιστών αύξησε τις απαιτήσεις για πρακτικές εφαρμογές στην αναγνώριση προτύπων, οι οποίες με τη σειρά τους δημιούργησαν νέες απαιτήσεις για περαιτέρω θεωρητική εξέλιξη. Καθώς η κοινωνία εξελισσόταν από την βιομηχανική στην μεταβιομηχανική φάση της, η αυτοματοποίηση στην βιομηχανική παραγωγή και η ανάγκη για τον έλεγχο, τον χειρισμό, την ανάκτηση αλλά και την βελτίωση της πληροφορίας γίνεται όλο και πιο σημαντική. Αυτή λοιπόν η τάση μέσω της αναγνώρισης προτύπου οδήγησε στη δημιουργία των σημερινών, υψηλού επιπέδου, τεχνολογικών εφαρμογών και έρευνας.

Ο τομέας της μηχανικής όρασης είναι μια περιοχή στην οποία η αναγνώριση προτύπου έχει πολλή μεγάλη σημασία. Ένα σύστημα μηχανικής όρασης αποθανατίζει εικόνες μέσω φωτογραφικής μηχανής και τις αναλύει με σκοπό να είναι σε θέση να περιγράψει τι απεικονίζετε στην καθεμία απ' αυτές. Μια τυπική εφαρμογή ενός τέτοιου συστήματος εμφανίζεται στην μεταποιητική βιομηχανία είτε για αυτόματη οπτική επιθεώρηση, είτε για αυτοματοποίηση στην γραμμή παραγωγής. Στην επιθεώρηση για παράδειγμα σε ένα εργοστάσιο παραγωγής, τα αντικείμενα κατά την παραγωγή τους περνάνε μέσω μετακινούμενων μεταγωγών από τον σταθμό επιθεωρήσεως στον οποίο βρίσκονται κάμερες μέσω των οποίων γίνεται έλεγχος για την ποιότητά τους. Έτσι οι εικόνες που καταγράφουν οι κάμερες πρέπει να αναλυθούν απευθείας και το σύστημα αναγνώρισης προτύπων θα κατατάξει τα αντικείμενα στις κλάσεις που πρέπει, δηλαδή σε ελαττωματική ή μη ελαττωματική κλάση. Ελέγχεται δηλαδή εάν τα αντικείμενα είναι ελαττωματικά και χρειάζονται επιδιόρθωση ή απόσυρση, ή αν είναι έτοιμα προκειμένου να προωθηθούν στην αγορά.

Η αναγνώριση χαρακτήρα (είτε γράμματος, είτε αριθμού) είναι άλλος ένας σημαντικός τομέας της αναγνώρισης προτύπου με κύριο μέλημα στην αυτοματοποίηση και στον έλεγχο της πληροφορίας. Τα οπτικά συστήματα αναγνώρισης χαρακτήρων είναι ήδη διαθέσιμα και πάνω κάτω γνωστά στον καθένα μας. Ένα τέτοιου είδους σύστημα διαθέτει μία μπρος-πίσω συσκευή η οποία αποτελείται από μια πηγής φωτός, ένα φακό σάρωσης, ένα έγγραφο μεταφοράς και έναν ανιχνευτή. Το αποτέλεσμα μέσω του ανιχνευτή μεταφράζεται ανάλογα με την ένταση του φωτός που προκύπτει, σε αριθμούς και σχηματίζεται ένας πίνακας εικόνων. Στη συνέχεια εφαρμόζεται μια σειρά από τεχνικές επεξεργασίας εικόνας που οδηγούν στην κατάμηση των γραμμών και των χαρακτήρων. Η αναγνώριση προτύπου με τη σειρά της αναλαμβάνει να αναγνωρίσει τους χαρακτήρες, δηλαδή να κατατάξει τον καθένα απ' αυτούς στην σωστή κλάση γράμματος, αριθμού και στίξης. Η αποθήκευση του αναγνωρισμένου πλέον εγγράφου έχει διπλάσια πλεονεκτήματα σε σχέση με την αποθήκευση τις σαρωμένης εικόνας. Πρώτον,

υπάρχει η δυνατότητα να γίνει περαιτέρω ηλεκτρονική επεξεργασία αν αυτό κριθεί απαραίτητο μέσω ενός επεξεργαστή λέξεων και δεύτερον είναι πολύ περισσότερο αποδοτικό να αποθηκεύονται χαρακτήρες ASCII απ' ό τι μία εικόνα. Εκτός από συστήματα αναγνώρισης τυπωμένων χαρακτήρων υπάρχει μεγάλο ενδιαφέρον στα συστήματα που αναγνωρίζουν τον γραφικό χαρακτήρα. Δηλαδή χαρακτήρες που είναι γραμμένοι στο χέρι. Μία κλασσική εφαρμογή τέτοιου είδους συστήματος είναι το μηχάνημα ανάγνωσης τραπεζικών επιταγών. Το μηχάνημα αυτό πρέπει να είναι σε θέση να αναγνωρίζει τα ποσά μέσω των ψηφίων και των στοιχείων και να τα ταιριάζει μεταξύ τους. Επιπλέον θα μπορούσε να ελέγχει κατά πόσο ο δικαιούχος αντιστοιχεί στο λογαριασμό στον οποίο γίνεται η πίστωση. Καταλαβαίνουμε λοιπόν ότι αν οι μισές και μόνο τραπεζικές επιταγές ήταν σε θέση να ελεγχθούν από ένα τέτοιο μηχάνημα τότε πολλός κόπος ανθρώπινης εργασίας θα μπορούσε να αποφευχθεί.

Μια άλλη πολλή σημαντική εφαρμογή της αναγνώρισης προτύπου είναι τα διαγνωστικά υπολογιστικά συστήματα που έχουν σαν στόχο να βοηθήσουν την επιστήμη της ιατρικής κάνοντας αυτόματες διαγνώσεις. Η τελική όμως διάγνωση θα γίνεται πάντοτε απ' τους κατάλληλους γιατρούς. Κάποια τέτοια συστήματα είναι ήδη σε εφαρμογή και χρησιμοποιούνται με επιτυχία για ιατροφαρμακευτικούς σκοπούς όπως οι ακτίνες X, εικόνες τομογράφου, εικόνες υπέρηχου, ηλεκτροκαρδιογραφήματα, κ.λπ. Η ανάγκη για τα διαγνωστικά αυτά υπολογιστικά συστήματα πηγάζει από το γεγονός ότι τα ιατρικά δεδομένα όπως οι εξετάσεις ή τα αποτελέσματα των εξετάσεων είναι συχνά δύσκολα στην ερμηνεία τους και η ορθή ερμηνεία τους εξαρτάται σε πολύ μεγάλο βαθμό από της ικανότητες του εκάστοτε γιατρού. Ας πάρουμε για παράδειγμα την εξέταση της μαστογραφίας μέσω ακτίνων X που γίνεται για τον εντοπισμό του καρκίνου του μαστού. Ενώ αυτού του είδους η εξέταση είναι μέχρι σήμερα η καλύτερη μέθοδος για τον εντοπισμό του καρκίνου, ένα ποσοστό της τάξης του 10 με 30 επί της εκατό των γυναικών που έχουν προσβληθεί απ' αυτήν την ασθένεια και υποβάλλονται στις εξετάσεις αυτές έχουν αρνητικό αποτέλεσμα. Δηλαδή οι εξετάσεις τους δείχνουν ότι δεν έχουν προσβληθεί. Σε περίπου δύο τρίτα των περιπτώσεων αυτών με λανθασμένα αποτελέσματα, ο ακτινολόγος απέτυχε στο να εντοπίσει τον καρκίνο ο οποίος ήταν εμφανής αναδρομικά. Κάτι τέτοιο μπορεί να οφείλεται στην κακή ποιότητα της εικόνας των αποτελεσμάτων (ακτινογραφίας), στην κακή όραση του γιατρού, ή στην λεπτή φύση των αποτελεσμάτων. Το ποσοστό διόρθωσης των αποτελεσμάτων μπορεί να βελτιωθεί μέσω ενός δεύτερου ελέγχου από κάποιον άλλον ακτινολόγο. Έτσι λοιπόν μπορεί να εφαρμοστεί η αναγνώριση προτύπου δημιουργώντας ένα σύστημα αναγνώρισης έτσι ώστε αυτό να βοηθάει τους ακτινολόγους με μια δεύτερη γνώμη αφού πρώτα ελέγξει τα αποτελέσματα των εκάστοτε εξετάσεων.

Ένας τομέας στον οποίο γίνεται μεγάλη έρευνα για ανάπτυξη είναι η αναγνώριση της ομιλίας. Η ομιλία είναι το πιο φυσικό μέσω με το οποίο οι άνθρωποι επικοινωνούν, συνεννοούνται και ανταλλάσσουν πληροφορίες. Έτσι λοιπόν η δημιουργία τέτοιων έξυπνων συστημάτων αποτελεί μακροχρόνιο στόχο εδώ και πολλά χρόνια. Οι εφαρμογές τέτοιου είδους συστημάτων είναι πάρα πολλές. Μπορούν για παράδειγμα να χρησιμοποιηθούν για να βελτιώσουν την αποδοτικότητα σε ένα περιβάλλον παραγωγής, να έχουν τον έλεγχο των μηχανημάτων απομακρυσμένα όταν αυτά βρίσκονται σε χώρο στον οποίο οι συνθήκες εργασίας είναι δύσκολες και επίσης να μπορούν να βοηθήσουν άτομα με ειδικές ανάγκες έτσι ώστε να είναι σε θέση να ελέγχουν μηχανήματα απλά μιλώντας σε αυτά. Μια μεγάλη προσπάθεια που έχει ήδη γίνει και η οποία είχε πολύ θετικά αποτελέσματα και μεγάλη επιτυχία είναι η εισαγωγή δεδομένων στους υπολογιστές μέσω ενός μικροφώνου. Οι υπολογιστές αυτοί διαθέτουν το κατάλληλο λογισμικό μέσω του οποίου αναγνωρίζετε η φωνή και κατ' επέκταση το υπαγορευόμενο κείμενο το οποίο και μεταφράζετε σε χαρακτήρες ASCII οι οποίοι εμφανίζονται στην οθόνη του υπολογιστή και μπορούν να αποθηκευτούν στη μνήμη του. Όπως γίνεται αντιληπτό το να εισάγουμε δεδομένα μέσω φωνής σε ένα υπολογιστικό σύστημα είναι πολύ πιο γρήγορο απ' ό τι να τα γράφουμε ακόμα και αν αυτό γίνεται από κάποιον επαγγελματία. Τέλος αυτό θα βοηθήσει στην επικοινωνία με τα άτομα τα οποία έχουν ακουστικά προβλήματα.

Η εξόρυξη δεδομένων και η ανάκτηση πληροφοριών στις βάσεις δεδομένων είναι ένας άλλος τομέας της αναγνώρισης προτύπου. Η εξόρυξη δεδομένων παρουσιάζει μεγάλο ενδιαφέρον σε μία ευρεία κλίμακα εφαρμογών όπως στην ιατρική, στην βιολογία, στην οικονομία, στην διαχείριση των επιχειρήσεων, στην επιστήμη αλλά και στην βελτίωση της μουσικής και των εικόνων. Η δημοτικότητα της τείνει να αυξάνεται ολοένα και περισσότερο από το γεγονός της αυξημένης απαίτησης για ανάκτηση πληροφοριών και την μετατροπή τους σε γνώση. Επιπλέον οι πληροφορίες αυτές υπάρχουν σε τεράστιες ποσότητες δεδομένων σε


διαφορετικές μορφές όπως κείμενο, εικόνα, ήχος και βίντεο, αποθηκευμένες σε πολλά διαφορετικά μέρη ανά τον κόσμο. Ο παραδοσιακός τρόπος αναζήτησης της πληροφορίας μέσα σε βάσεις δεδομένων ήταν το μοντέλο στο οποίο η ανάκτηση αντικειμένου στηρίχτηκε στην περιγραφή λέξεων κλειδιά και μεταγενέστερα στο ταίριασμα συγκεκριμένων λέξεων. Ωστόσο, αυτού του είδους η αναζήτηση προϋποθέτει ότι υπάρχουν ήδη κάποια συγκεκριμένα σχόλια στις αποθηκευμένες πληροφορίες τα οποία έχουν γίνει από κάποιον άνθρωπο, όπως για παράδειγμα τον προγραμματιστή της βάσης, με σκοπό την ευκολότερη εύρεση των ζητούμενων πληροφοριών. Αυτού του είδους η εργασία αν και είναι εφικτή όταν το σύνολο των αποθηκευμένων δεδομένων - πληροφοριών είναι μικρό, είναι πολλή χρονοβόρα και θεωρείται ανέφικτη όταν η ποσότητα των αποθηκευμένων πληροφοριών είναι αρκετά μεγάλη. Επιπλέον, η τοποθέτηση σχολίων στα δεδομένα γίνεται περισσότερο προβληματική όταν οι αποθηκευμένες πληροφορίες είναι ευρέως κατανεμημένες και κοινόχρηστες σε ανομοιογενής τοποθεσίες και χρήστες. Τα συστήματα ανάκτησης της πληροφορίας με βάση το περιεχόμενο γίνονται ολοένα και πιο δημοφιλή στο ευρύ κοινό όταν η πληροφορία ζητείται με βάση την ομοιότητα μεταξύ ενός αντικειμένου το οποίο βρίσκεται στο σύστημα και άλλα αντικείμενα που είναι αποθηκευμένα σε διαφορετικές τοποθεσίες ανά τον κόσμο. Σε ένα σύστημα εικόνας ανάκτησης της πληροφορίας με βάση το περιεχόμενο (CBIR), μια εικόνα παρουσιάζεται σε μία συσκευή εισόδου όπως είναι ο σαρωτής. Το σύστημα αυτό επιστρέφει παρόμοιες εικόνες με βάση μετρούμενη υπογραφή η οποία μπορεί να κωδικοποιεί για παράδειγμα πληροφορίες που σχετίζονται με το χρώμα το σχήμα και την υφή. Σε ένα τέτοιου είδους σύστημα που σχετίζεται όμως με τη μουσική, ένα μουσικό κομμάτι ή ένα μέρος αυτού, παρουσιάζεται σε ένα μικρόφωνο (συσκευή εισόδου) και το σύστημα αυτό δίνει σαν αποτέλεσμα στον χρήστη παρόμοια μουσικά κομμάτια. Στην περίπτωση αυτή η ομοιότητα βασίζεται πάνω σε συγκεκριμένα στοιχεία τα οποία χαρακτηρίζουν ένα μουσικό κομμάτι όπως ο ρυθμός της μουσικής ή το μέτρο της.

Η εξόρυξη στην βιοϊατρική και στην ανάλυση των δεδομένων του DNA έχει σημειώσει τεράστια άνοδο από τα μέσα της δεκαετίας του 90. Όλες οι DNA αλληλουχίες περιέχουν τέσσερα βασικά δομικά στοιχεία τα οποία ονομάζονται νουκλεοτίδια. Αυτά είναι η αδενίνη (adenine, A), η κυτοσίνη (cytosine, C), η γουανίνη (guanine, G) και η θυμίνη (thymine, T). Αυτά τα τέσσερα στοιχεία συνδυάζονται μεταξύ τους προκειμένου να δημιουργήσουν μακρές ακολουθίες - αλληλουχίες σε μορφή διπλωμένης σκάλας. Τα γονίδια αποτελούνται από εκατοντάδες νουκλεοτίδια τοποθετημένα σε συγκεκριμένη σειρά. Κάθε συγκεκριμένη γονιδιακή αλληλουχία σχετίζεται με συγκεκριμένες ασθένειες και παίζει πάρα πολύ σημαντικό ρόλο στην ιατρική και κατ' επέκταση στην παραγωγή συγκεκριμένων φαρμάκων. Για το σκοπό αυτό, η αναγνώριση προτύπου είναι ένας τομέας κλειδί με σκοπό τη δημιουργία εργαλείων για την αναζήτηση ομοιοτήτων και συγκρίσεων μεταξύ των πολλών DNA αλληλουχιών. Τέτοιες διαφορές μεταξύ υγιών και μολυσμένων ιστών είναι πολύ σημαντικές για την επιστήμη της ιατρικής έτσι ώστε να είναι σε θέση να εντοπίσει και να αναγνωρίσει βασικές και κρίσιμες διαφορές μεταξύ αυτών των δύο κλάσεων.


Τα προηγούμενα είναι μόλις πέντε παραδείγματα μέσα από μια πολλή μεγάλη κλίμακα πιθανών εφαρμογών. Τυπικά αναφέρουμε την αναγνώριση δακτυλικών αποτυπωμάτων, την αυθεντικότητα της υπογραφής, την ανάκτηση κειμένου, και την αναγνώριση προσώπου και χειριών. Οι τελευταίες αυτές εφαρμογές έχουν προσελκύσει μεγάλο ενδιαφέρον για επενδύσεις και έρευνα σε μια προσπάθεια να διευκολύνουν την αλληλεπίδραση μεταξύ ανθρώπου και υπολογιστή και να ενισχύσουν περαιτέρω το ρόλο του υπολογιστή στην αυτοματοποίηση που αφορά δουλειές γραφείου, στην αυτόματη εξατομίκευση του εκάστοτε περιβάλλοντος και ούτω καθεξής.

1.2 Χαρακτηριστικά, Διανύσματα χαρακτηριστικών και Ταξινόμητές

Για αρχή ας προσομοιώσουμε ένα απλό πρόβλημα το οποίο μιμείται την ταξινόμηση μιας εικόνας που σχετίζεται με την επιστήμη της ιατρικής. Το σχήμα 1.1 απεικονίζει δύο εικόνες κάθε μία απ' τις οποίες περιέχει μία ξεχωριστή περιοχή. Οι δύο αυτές περιοχές είναι οπτικά διαφορετικές. Το σχήμα 1.1α απεικονίζει μία καλοήγη περίπτωση ασθένειας, κλάσης A, σε αντίθεση με το σχήμα 1.1β το οποίο απεικονίζει μία κακοήγη περίπτωση, πχ καρκίνος, κλάσης B.



Σχήμα 1.1 εικόνων που αντιστοιχούν (a) στην κλάση A και (b) στην κλάση B



Σχήμα 1.2 Μέση τιμή έναντι τυπικής απόκλισης κλάσης A(o) και B(+). Η ευθεία γραμμή ξεχωρίζει τις 2 κλάσεις.

Το πρώτο βήμα, είναι να αναγνωρίσουμε τις μετρήσιμες ποσότητες που καθιστούν αυτές τις δύο περιοχές διαφορετικές την μία από την άλλη. Το σχήμα 1.2 απεικονίζει ένα διάγραμμα της μέσης τιμής της έντασης σε κάθε περιοχή ενδιαφέροντος έναντι της αντίστοιχης τυπικής απόκλισης γύρω απ' αυτή τη μέση τιμή. Κάθε σημείο αντιστοιχεί και σε μία διαφορετική εικόνα που περιέχονται στην διαθέσιμη βάση δεδομένων μέσα στην οποία είναι αποθηκευμένες όλες οι εικόνες. Αποδεικνύεται ότι τα πρότυπα της κλάσης A εξαπλώνονται σε μία διαφορετική περιοχή σε σχέση με αυτά της κλάσης B. Η ευθεία γραμμή χρησιμοποιείται για να διαχωρίσει τις δύο αυτές κλάσεις. Ας υποθέσουμε τώρα ότι μας δίνεται μία καινούργια εικόνα παρόμοια με τις προηγούμενες αλλά δεν μπορούμε να ξεχωρίσουμε σε ποιά κλάση αυτή ανήκει. Είναι λογικό να πούμε ότι πρώτα θα μετρήσουμε τη μέση τιμή της έντασης και την τυπική απόκλιση στην περιοχή που μας ενδιαφέρει και έτσι θα βρούμε και θα σχεδιάσουμε το σημείο που ανήκει το αντίστοιχο σημείο. Αυτό φαίνεται από τον αστερίσκο (*) στο σχήμα 1.2. Έτσι καταλαβαίνουμε ότι είναι πιο πιθανό το άγνωστο αυτό πρότυπο να ανήκει στην κλάση A παρά στην κλάση B.

Η προηγούμενη τεχνητή διαδικασία της ταξινόμησης περιγράφει το σκεπτικό που χρησιμοποιείται σε μία μεγάλη κατηγορία των προβλημάτων της αναγνώρισης προτύπου. Οι μετρήσεις που γίνονται για την ταξινόμηση, η μέση τιμή και η τυπική απόκλιση σ' αυτήν την περίπτωση είναι γνωστά ως χαρακτηριστικά (features). Στην πιο γενική περίπτωση

χρησιμοποίησης l χαρακτηριστικών x_i , $i = 1, 2, \dots, l$ και σχηματίζουν διάνυσμα χαρακτηριστικών

$$x = [x_1(1), x_1(2), \dots, x_1(l)]^T$$


όπου το T υποδηλώνει τη μεταφορά. Καθένα από τα διανύσματα χαρακτηριστικών προσδιορίζει ένα και μοναδικό πρότυπο (αντικείμενο).

Η ευθεία γραμμή του σχήματος 1.2 είναι γνωστή με τον όρο γραμμή απόφασης και παριστάνει τον ταξινομητή του οποίου ο ρόλος είναι να χωρίζει τον χώρο των χαρακτηριστικών σε περιφέρειες που αντιστοιχούν είτε στην κλάση A είτε στην κλάση B . Εάν ένα μελλοντικό διάνυσμα x , το οποίο αντιστοιχεί σε ένα άγνωστο πρότυπο, βρεθεί στην περιοχή της κλάσης A τότε ταξινομείται σαν κλάση A , αλλιώς σαν κλάση B . Αυτό βέβαια δεν σημαίνει απαραίτητα ότι η απόφαση αυτή είναι και η σωστή. Αν δεν είναι σωστή τότε έχει προκύψει μία λανθασμένη ταξινόμηση. Για να σχεδιάσουμε την ευθεία γραμμή του σχήματος 1.2 εκμεταλλευόμαστε το γεγονός ότι ήδη γνωρίζουμε τις σωστές ετικέτες (κλάση A , κλάση B) για κάθε σημείο του σχήματος. Τα πρότυπα (διανύσματα χαρακτηριστικών) των οποίων η σωστή κλάση είναι ήδη γνωστή και τα οποία χρησιμοποιούνται για το σχεδιασμό του ταξινομητή είναι γνωστά σαν εκπαιδευτικά πρότυπα ή σαν εκπαιδευτικά διανύσματα χαρακτηριστικών.

Έχοντας πλέον αποσαφηνίσει τους ορισμούς και τις σχέσεις μεταξύ τους, παραθέτουμε παρακάτω τα βασικά ερωτήματα που μπορεί να προκύψουν σε ένα πρόβλημα που αφορά την διαδικασία της ταξινόμησης.

- Πως δημιουργούνται τα χαρακτηριστικά; Στο προηγούμενο παράδειγμα χρησιμοποιήσαμε την μέση τιμή και την τυπική απόκλιση επειδή γνωρίζαμε ήδη πως είχαν δημιουργηθεί οι εικόνες. Στην πράξη όμως ο τρόπος διαφέρει και δεν είναι τόσο προφανής. Εξαρτάται από το πρόβλημα και αφορά το στάδιο παραγωγής των χαρακτηριστικών για το σχεδιασμό ενός συστήματος ταξινόμησης που εκτελεί το έργο της αναγνώρισης του προτύπου.
- Ποιός είναι ο καλύτερος αριθμός των χαρακτηριστικών l που μπορούν να χρησιμοποιηθούν; Και αυτό επίσης είναι ένα πολύ σημαντικό πρόβλημα και αφορά το στάδιο της επιλογής των χαρακτηριστικών του συστήματος ταξινόμησης. Στην πράξη χρησιμοποιείται ένας πολύ μεγαλύτερος αριθμός χαρακτηριστικών απ' τον αναγκαίο, και στο τέλος υιοθετούνται τα καλύτερα και αντιπροσωπευτικότερα εξ' αυτών.
- Έχοντας υιοθετήσει τα κατάλληλα χαρακτηριστικά για ένα συγκεκριμένο πρόβλημα, πώς μπορούμε να σχεδιάσουμε τον ταξινομητή; Στο προηγούμενο παράδειγμα η ευθεία γραμμή σχεδιάστηκε εμπειρικά απλά για να ικανοποιεί το μάτι. Στην πράξη όμως δεν μπορεί να συμβαίνει κάτι τέτοιο και η ευθεία πρέπει να σχεδιάζεται με το βέλτιστο δυνατό τρόπο σε σχέση με τα αντίστοιχα κριτήρια ποιότητας. Επίσης, προβλήματα για τα οποία ένας γραμμικός ταξινομητής (ευθεία γραμμή ή υπερεπίπεδο στο διάστημα l χώρο) μπορεί να οδηγήσει σε αποδεκτή απόδοση δεν είναι συνηθισμένα. Σε γενικές γραμμές οι επιφάνειες που χωρίζουν το χώρο σε ποικίλες περιοχές κατηγοριών είναι μη γραμμικές.
- Τέλος, μόλις ο ταξινομητής σχεδιαστεί πώς μπορεί κάποιος να αξιολογήσει την απόδοση του ταξινομητή αυτού; Αυτό σημαίνει ποιό είναι το ποσοστό σφάλματος του ταξινομητή. Αυτό είναι το έργο που αναλαμβάνει να διεκπεραιώσει το σύστημα σταδίων αξιολόγησης.

Το σχήμα 1.3 δείχνει τα πολλαπλά στάδια που ακολουθούνται για το σχεδιασμό ενός συστήματος ταξινόμησης. όπως γίνεται προφανές από τα βελάκια ανατροφοδότησης, αυτά τα στάδια δεν είναι ανεξάρτητα το ένα απ' το άλλο. Αντιθέτως, είναι αλληλένδετα και ανάλογα από τα αποτελέσματα, μπορεί να χρειαστεί να ξανασχεδιαστούν τα προηγούμενα στάδια έτσι ώστε να βελτιωθεί η συνολική απόδοση. Επιπλέον, υπάρχουν κάποιες μέθοδοι οι οποίες συνδυάζουν τα στάδια αυτά, όπως για παράδειγμα η επιλογή των χαρακτηριστικών και το στάδιο σχεδίασης του ταξινομητή, σε ένα κοινό πρόβλημα βελτιστοποίησης.




Σχήμα 1.3 Τα βασικά στάδια για το σχεδιασμό ενός συστήματος ταξινόμησης

1.3 Επιτηρούμενη, μη-επιτηρούμενη και ημιεπιτηρούμενη μάθηση

Στο παράδειγμα του σχήματος 1.1 υποθέσαμε ότι το σύνολο των δεδομένων εκπαίδευσης ήταν ήδη διαθέσιμο και ο ταξινομητής σχεδιάστηκε με βάση την αξιοποίηση των δεδομένων αυτών. Συμπεραίνουμε λοιπόν, ότι οι πληροφορίες είναι γνωστές εκ των προτέρων και η περίπτωση αυτή ονομάζεται επιτηρούμενη αναγνώριση προτύπου ή αναγνώριση προτύπου υπό επιτήρηση ή στο πιο γενικό πλαίσιο της μηχανικής μάθησης σαν επιτηρούμενη μάθηση. Ωστόσο, αυτή δεν είναι η μοναδική περίπτωση που μπορεί να εμφανιστεί, καθώς υπάρχει και άλλος τύπος προβλημάτων της αναγνώρισης προτύπου κατά τον οποίο τα δεδομένα εκπαίδευσης των ήδη γνωστών ετικετών κλάσης δεν είναι διαθέσιμα. Σε αυτή την περίπτωση, μας δίνετε ένα ζευγάρι διανυσμάτων χαρακτηριστικών x και ο στόχος μας είναι να ξεχωρίσουμε τις υποκείμενες ομοιότητες και να ομαδοποιήσουμε τα παρόμοια ή ίδια διανύσματα. Αυτή η περίπτωση είναι γνωστή σαν αναγνώριση προτύπου χωρίς επιτήρηση ή μάθηση χωρίς επιτήρηση ή ομαδοποίηση. Τέτοια προβλήματα προκύπτουν καθημερινά σε πολλές εφαρμογές στις κοινωνικές επιστήμες και στην μηχανική, όπως η τηλεπισκόπηση, η κατάτμηση εικόνας και η κωδικοποίηση της εικόνας ή της ομιλίας. Παρακάτω αναλύουμε δύο τέτοιου είδους προβλήματα.

Στην πολυφασματική τηλεσκόπηση, η ηλεκτρομαγνητική ενέργεια που προέρχεται από την επιφάνεια της γης μετρείται από σαρωτές - αισθητήρες που βρίσκονται πάνω σε έναν δορυφόρο, ένα αεροσκάφος ή ένα διαστημικό σταθμό. Αυτή η ενέργεια μπορεί να αντανakλά ηλιακή ενέργεια ή το ανακλώμενο μέρος της ενέργειας που μεταδίδεται απ' το όχημα έτσι ώστε να εντοπίζεται η επιφάνεια της γης. Οι σαρωτές είναι ευαίσθητοι σε μια σειρά από συγκεκριμένες ζώνες μήκους κύματος της ηλεκτρομαγνητικής ακτινοβολίας. Οι διαφορετικές ιδιότητες της επιφάνειας της γης συμβάλλουν στην αντανάκλαση της ενέργειας στις διάφορες ζώνες. Για παράδειγμα στο ορατό υπέρυθρο φάσμα ιδιοτήτων όπως το ορυκτό του εδάφους αλλά και η υγρασία του, η καθίζηση των υδάτων και η περιεκτικότητα σε υγρασία της βλάστησης είναι οι κύριοι παράγοντες για την ενέργεια που ανακλάται. Σε αντίθεση μ' αυτό, στο θερμικό άκρο του υπέρυθρου φάσματος η θερμοχωρητικότητα και οι θερμικές ιδιότητες της επιφάνειας και κάτω απ' αυτήν είναι τα χαρακτηριστικά που συμβάλουν στην ανάκλαση της ενέργειας. Έτσι, κάθε ζώνη μετρά διαφορετικές ιδιότητες του ίδιου τμήματος της επιφάνειας της γης. Με αυτό τον τρόπο μπορούν να δημιουργηθούν εικόνες της επιφάνειας της γης οι οποίες αντιστοιχούν στην χωροταξική κατανομή της ανακλώμενης ενέργειας σε κάθε ζώνη. Ο στόχος είναι πλέον να γίνει κατάλληλη εκμετάλλευση και διαχείριση των πληροφοριών αυτών έτσι ώστε να μπορούμε πλέον να αναγνωρίσουμε ποικίλους τρόπους εδαφοκάλυψης, δηλαδή οικοδομημένα οικόπεδα, αγροτική γη, δάση, καμένα εδάφη, νερό και μολυσμένες καλλιέργειες. Για το σκοπό αυτό, σχηματίζεται ένα χαρακτηριστικό διάνυσμα x για κάθε κελί από την αισθητή επιφάνεια της γης. Τα χαρακτηριστικά $x_i, i = 1, 2, \dots, l$ του διανύσματος είναι οι αντίστοιχες εντάσεις pixel της εικόνας στις διάφορες φασματικές ζώνες. Στην πράξη όμως, ο αριθμός των φασματικών ζωνών ποικίλει.

Ένας αλγόριθμος ομαδοποίησης μπορεί να δημιουργηθεί έτσι ώστε να εμφανίζει τα γκρουπ στα οποία τα χαρακτηριστικά διανύσματα ομαδοποιούνται στον χαρακτηριστικό χώρο διαστάσεων. Θέματα τα οποία αντιστοιχούν στον ίδιο τύπο εδαφοκάλυψης, όπως για παράδειγμα το νερό, αναμένεται να ομαδοποιηθούν μαζί και να σχηματίσουν τα προαναφερθέντα γκρουπ. Μόλις αυτό πραγματοποιηθεί, ο αναλυτής είναι πλέον σε θέση να αναγνωρίσει τον τύπο της κάθε ομαδοποιημένης ομάδας βοηθούμενος από ένα δείγμα από το κάθε γκρουπ με τα διαθέσιμα στοιχεία του εδάφους όπως χάρτες ή επισκέψεις. Το σχήμα 1.4 απεικονίζει τη διαδικασία αυτή.



Σχήμα 1.4 (a) Διάφοροι τύποι εδάφους και (b) ομαδοποίηση των αντίστοιχων χαρακτηριστικών για την πολυφασματική απεικόνιση με δύο ζώνες

Η ομαδοποίηση χρησιμοποιείται επιπλέον ευρέως στις κοινωνικές επιστήμες προκειμένου να μελετήσει και να συσχετίσει την έρευνα και τα στατιστικά δεδομένα και να αντλήσει χρήσιμα συμπεράσματα, τα οποία στην πορεία θα οδηγήσουν στις ορθές ενέργειες. Ας καταφύγουμε σε ένα απλό παράδειγμα υποθέτοντας ότι ενδιαφερόμαστε να μελετήσουμε κατά πόσο υπάρχει μια οποιαδήποτε σχέση μεταξύ του ακαθάριστου προϊόντος μιας χώρας και το επίπεδο των αναλφάβητων ανθρώπων από τη μία πλευρά, και το ποσοστό θνησιμότητας των παιδιών από την άλλη. Στην περίπτωση αυτή κάθε χώρα αναπαριστάται από ένα τρισδιάστατο χαρακτηριστικό διάνυσμα του οποίου οι συντεταγμένες είναι οι δείκτες μέτρησης των ποσοτήτων ενδιαφέροντος. Ένας αλγόριθμος ομαδοποίησης με τη σειρά του θα εμφανίσει ένα μάλλον μικρό σύμπλεγμα που αντιστοιχεί σε χώρες που εμφανίζουν χαμηλό ποσοστό ακαθάριστου προϊόντος, υψηλά επίπεδα αναλφαβητισμού και υψηλό ποσοστό θνησιμότητας των παιδιών εκφραζόμενο ως ποσοστό του πληθυσμού.

Ένα μείζον θέμα στην αναγνώριση προτύπου χωρίς επιτήρηση είναι αυτό του ορισμού της ομοιότητας μεταξύ δύο χαρακτηριστικών διανυσμάτων και η επιλογή του κατάλληλου μέτρου για αυτό. Ένα άλλο σημαντικό ζήτημα είναι η επιλογή ενός συστήματος αλγορίθμου (algorithm scheme) το οποίο θα ομαδοποιήσει τα διανύσματα με βάση την ομοιότητα του επιλεχθέντος μέτρου που αναφέραμε προηγουμένως. Σε γενικές γραμμές διαφορετικά συστήματα αλγορίθμων μπορούν να οδηγήσουν σε διαφορετικά αποτελέσματα, τα οποία ο εκάστοτε ειδικός πρέπει να ερμηνεύσει σωστά.

Η ημιεπιτηρούμενη μάθηση ή ημιεπιτηρούμενη αναγνώριση προτύπου για το σχεδιασμό ενός συστήματος ομαδοποίησης έχει τους ίδιους στόχους όπως και η επιτηρούμενη μάθηση, ωστόσο τώρα, ο σχεδιαστής έχει στη διάθεσή του ένα ζευγάρι προτύπων άγνωστου κλάσης καταγωγής, εκτός από τα εκπαιδευτικά πρότυπα των οποίων η πραγματική κλάση είναι ήδη γνωστή. Συνήθως αναφερόμαστε στα προηγούμενα σαν μη ταξινομημένα δεδομένα, ενώ στα τελευταία σαν ταξινομημένα δεδομένα. Σε τέτοιες περιπτώσεις, η ανάκτηση επιπρόσθετων πληροφοριών από τα μη ταξινομημένα δείγματα, μπορεί να αποδειχθεί χρήσιμη βελτιώνοντας το σχεδιασμό του συστήματος. Η ημιεπιτηρούμενη μάθηση χρησιμοποιεί επίσης την ομαδοποίηση των δεδομένων. Στην περίπτωση αυτή, τα ταξινομημένα δεδομένα χρησιμοποιούνται σαν περιορισμοί υπό την μορφή must-links και cannot-links. Με άλλα λόγια, το ζήτημα της ομαδοποίησης περιορίζεται στο να αναθέτει συγκεκριμένα ζητήματα στην ίδια ομάδα ή να αποκλείει συγκεκριμένα ζητήματα από το να ανατεθούν στην ίδια ομάδα. Από αυτή την άποψη, η ημιεπιτηρούμενη μάθηση παρέχει μια προγενέστερη γνώση την οποία ο αλγόριθμος ομαδοποίησης πρέπει να ακολουθήσει.

1.4 Εκπαιδευτικές μέθοδοι για επιτηρούμενη μάθηση

Ο τρόπος που δουλεύουν οι αλγόριθμοι κατά την μάθηση με επιτήρηση είναι ο παρακάτω. Λαμβάνοντας υπόψη μια σειρά από παραδείγματα εκπαίδευσης της μορφής $\{ (x_1, y_1), \dots, (x_n, y_n) \}$ ένας αλγόριθμος μάθησης επιδιώκει την λειτουργία βαθμολόγησης, $g : X \rightarrow Y$, όπου το X είναι χώρος εισόδου και το Y ο χώρος εξόδου. Η λειτουργία g είναι ένα στοιχείο πιθανών λειτουργιών G , που συνήθως ονομάζονται υποθετικοί χώροι (hypothesis space). Είναι βολικό κάποιες φορές να αναπαριστούμε το g χρησιμοποιώντας μία λειτουργία βαθμολόγησης $f : X * Y \rightarrow \mathbb{R}$, τέτοια ώστε το g να ορίζεται ως η επιστροφή της τιμής του y που επιστρέφει την υψηλότερη βαθμολογία

$$g(x) = \operatorname{argmax}_y f(x, y)$$

y

Έστω ότι το F υποδηλώνει το χώρο των λειτουργιών βαθμολόγησης. Παρόλο που η G και η F μπορεί να είναι οποιοιδήποτε χώροι της λειτουργίας, πολλοί αλγόριθμοι εκμάθησης είναι μοντέλα πιθανοτήτων, στα οποία η g παίρνει τη μορφή ενός υποθετικού μοντέλου πιθανοτήτων $g(x) = P(x|y)$, ή η f παίρνει τη μορφή ενός κοινού μοντέλου πιθανοτήτων $f(x, y) = P(x, y)$.

Υπάρχουν δύο βασικές εκπαιδευτικές τεχνικές - μέθοδοι για την επιλογή της f ή της g . Η εμπειρική ελαχιστοποίηση του κινδύνου και η διαρθρωτική ελαχιστοποίηση του κινδύνου. Η πρώτη ψάχνει την λειτουργία που ταιριάζει καλύτερα στα εκπαιδευτικά δεδομένα. Η δεύτερη, περιέχει μια λειτουργία ποινής) η οποία ελέγχει την κλίση / διακύμανση των μειονεκτημάτων.

Και στις δύο αυτές περιπτώσεις θεωρούμε ότι το σύνολο της εκπαίδευσης αποτελείται από ένα δείγμα ανεξάρτητων και πανομοιότυπων καταναμημένων ζευγών (x_i, y_i) . Προκειμένου να καταλάβουμε πόσο καλά μία function ταιριάζει με τα εκπαιδευτικά δεδομένα ορίζουμε μια συνάρτηση απώλειας $L : X * Y \rightarrow \mathbb{R} \geq 0$. Για παράδειγμα (x_i, y_i) , η απώλεια για την πρόβλεψη της τιμής \hat{y} είναι $L(y_i, \hat{y})$. Το ρίσκο $R(g)$ της συνάρτησης g ορίζετε ως η αναμενόμενη απώλεια του g . Αυτό μπορεί να υπολογιστεί μέσω των εκπαιδευτικών δεδομένων από την παρακάτω σχέση.

$$R_{emp}(g) = \frac{1}{N} \sum_i L(y_i, g(x_i))$$

1.4.1 Εμπειρική ελαχιστοποίησης του κινδύνου

Κατά την εμπειρική ελαχιστοποίησης του κινδύνου, ο αλγόριθμος της επιτηρούμενης μάθησης αναζητά την διαδικασία g η οποία ελαχιστοποιεί το ρίσκο $R(g)$. Ως εκ τούτου, ένας αλγόριθμος επιτηρούμενης μάθησης μπορεί να δημιουργηθεί εφαρμόζοντας έναν αλγόριθμο βελτιστοποίησης για να βρει το g .

Όταν η G περιέχει πολλές υποψήφιες διαδικασίες ή όταν το σύνολο εκπαίδευσης δεν είναι αρκετά μεγάλο, η τεχνική της εμπειρικής ελαχιστοποίησης του κινδύνου οδηγεί σε υψηλή διακύμανση και σε περιπέτες γενικεύσεις. Έτσι ο αλγόριθμος μάθησης αποσπαστείται τα εκπαιδευτικά παραδείγματα χωρίς σωστή γενίκευση. Αυτό ονομάζεται υπερπροσαρμογή.

1.4.2 Διαρθρωτική ελαχιστοποίησης του κινδύνου

Η τεχνική της διαρθρωτικής ελαχιστοποίησης του κινδύνου αποσκοπεί στην πρόληψη της υπερπροσαρμογής, που αναφέραμε παραπάνω, ενσωματώνοντας μία ποινή τακτοποίησης σε

ότι αφορά την βελτιστοποίηση. Η ποινή αυτή μπορεί να θεωρηθεί ως εφαρμογή μιας φόρμας που προτιμά τις απλούστερες λειτουργίες σε σχέση με τις πιο πολύπλοκες.

Υπάρχει μία ευρεία ποικιλία ποινών η οποία αντιστοιχεί στους διαφορετικούς ορισμούς της πολυπλοκότητας. Για παράδειγμα, ας αναλογιστούμε της περίπτωση κατά την οποία η διαδικασία g αποτελεί μία γραμμική διαδικασία της μορφής

$$\sum_{j=1}^d \beta_j x_j$$

Μια δημοφιλής ποινή τέτοιου είδους, είναι η $\sum \beta_j^2$ η οποία είναι η ευκλείδεια νόρμα των βάρων υψωμένη στο τετράγωνο, γνωστή και σαν L2 νόρμα. Η ποινή συμβολίζεται σαν $C(g)$.

Το πρόβλημα της βελτιστοποίησης για την επιτηρούμενη μάθηση είναι να εντοπίσει την συνάρτηση g η οποία ελαχιστοποιεί την παρακάτω σχέση.

$$J(g) = R_{emp}(g) + \lambda C(g)$$

Η παράμετρος λ ελέγχει την κλίση - διακύμανση των μειονεκτημάτων που αναφέραμε παραπάνω. Όταν το $\lambda=0$, τότε στην τεχνική της εμπειρικής ελαχιστοποίησης του κινδύνου έχουμε υψηλή διακύμανση και χαμηλή κλίση. Στην περίπτωση τώρα όπου το λ είναι μεγάλο, τα αποτελέσματα είναι αντίθετα. Δηλαδή, η διακύμανση είναι χαμηλή αλλά η κλίση υψηλή.

Η ποινή της πολυπλοκότητας έχει μία Bayesian ερμηνεία όπως και ο αρνητικός λογάριθμος πιθανότητας του g , $-\log P(g)$, στην περίπτωση που το $J(g)$ είναι η μεταγενέστερη πιθανότητα του g .

1.5 Εκπαιδευτικές μέθοδοι για ημιεπιτηρούμενη μάθηση

1.5.1 Γενετικά μοντέλα

Η προσέγγιση του γενετικό μοντέλου για στατιστική μάθηση, επιδιώκει πρώτα να υπολογίσει την κατανομή των σημείων των δεδομένων που ανήκουν στην κάθε κλάση μέσω της πιθανότητας $p(x|y)$. Η πιθανότητα $p(y|x)$, όπου ένα ήδη γνωστό σημείο x έχει y ετικέτα, είναι ανάλογη με την $p(x|y)p(y)$ βάση του θεωρήματος του Bayes. Η ημιεπιτηρούμενη μάθηση με γενετικά μοντέλα μπορεί να θεωρηθεί είτε σαν μία επέκταση της επιτηρούμενης μάθησης (ταξινόμηση συν πληροφορίες για την $p(x)$) ή σαν προέκταση της μη επιτηρούμενης μάθησης (ομαδοποίηση (clustering) συν κάποιες ετικέτες).

Τα γενετικά μοντέλα υποθέτουν ότι οι κατανομές λαμβάνουν κάποια συγκεκριμένη μορφή $p(x|y, \theta)$ παραμετροποιήσιμη από το διάνυσμα θ . Αν αυτές οι υποθέσεις δεν είναι σωστές τότε τα μη ταξινομημένα δεδομένα μπορεί να μειώσουν την ακρίβεια της λύσης σε σχέση με τα συμπεράσματα θα λαμβάναμε από τα ταξινομημένα δεδομένα. Ωστόσο, αν οι υποθέσεις αυτές είναι σωστές, τότε τα μη ταξινομημένα δεδομένα αναγκαστικά βελτιώνουν την απόδοση.

Τα μη ταξινομημένα δεδομένα κατανέμονται σύμφωνα με ένα μίγμα διανομών επιμέρους κλάσεων. Προκειμένου να μάθουμε το μίγμα αυτό, των αταξινόμητων δεδομένων, πρέπει να γίνει κατανοητό ότι διαφορετικές παράμετροι πρέπει να παράγουν διαφορετικές αθροισζόμενες κατανομές. Οι Γκαουσιανές κατανομές χρησιμοποιούνται συνήθως στα γενετικά μοντέλα. Η παραμετροποιημένη συλλογική κατανομή μπορεί να γραφτεί ως εξής. $p(x, y|\theta) = p(y|\theta)p(x|y, \theta)$. Κάθε παράμετρος διανύσματος θ , σχετίζεται με μία διαδικασία απόφασης

$$f_{\theta}(x) = \operatorname{argmax}_y p(y|x, \theta)$$

y

Η παράμετρος στη συνέχεια επιλέγεται με βάση τόσο τα ταξινομημένα όσο και τα μη ταξινομημένα δεδομένα, σταθμισμένα από το λ :

$\operatorname{argmax} ($

θ

1.5.2 Μέθοδοι βασισμένοι σε γραφήματα

Οι μέθοδοι αυτοί για την ημιεπιτηρούμενη μάθηση χρησιμοποιούν γραφικές αναπαράστασεις των δεδομένων, με έναν κόμβο για κάθε ταξινομημένο ή αταξιινόμητο παράδειγμα δεδομένων. Κάθε γράφημα μπορεί να δημιουργηθεί χρησιμοποιώντας την κύρια γνώση ή όμοια παραδείγματα. Δύο κλασσικές μέθοδοι είναι η σύνδεση του εκάστοτε σημείου δεδομένων με τα κοντινότερα γειτονικά του k ή σε παραδείγματα στα οποία απέχουν απόσταση ϵ . Το βάρος W_{ij}

του κάθε άκρου μεταξύ του x_i και του x_j ορίζεται ως $e^{-\frac{\|x_i - x_j\|^2}{\epsilon}}$.

1.5.3 Μέθοδοι εύρεσης

Κάποιες μέθοδοι που χρησιμοποιούνται στην ημιεπιτηρούμενη μάθηση δεν είναι άρρηκτα συνδεδεμένες ως προς τη μάθηση τόσο από τα ταξινομημένα όσο και από τα μη ταξινομημένα δεδομένα, αλλά χρησιμοποιούν μόνο τα αταξινόμητα δεδομένα μέσα σε ένα πλαίσιο επιτηρούμενης μάθησης. Για παράδειγμα, τα ταξινομημένα και αταξινόμητα δεδομένα x_1, \dots, x_{1+n} μπορούν να ενημερώσουν μία επιλογή αναπαράστασης, μια μετρική επιλογή ή τον πυρήνα για τα δεδομένα σε μη επιτηρούμενο πρώτο βήμα. Στη συνέχεια χρησιμοποιείται η επιτηρούμενη μάθηση μόνο για τα ταξινομημένα δεδομένα.

Η μέθοδος της αυτό-εκπαίδευσης είναι μια τέτοια μέθοδος για την ημιεπιτηρούμενη μάθηση. Πρώτα χρησιμοποιείται ένας αλγόριθμος επιτηρούμενης μάθησης για να επιλέξει έναν ταξινομητή ο οποίος βασίζεται μόνο στα ταξινομημένα δεδομένα. Αμέσως μετά ο ταξινομητής

αυτός εφαρμόζεται στα αταξινομήτα δεδομένα για να δημιουργήσει ακόμη περισσότερα ταξινομημένα παραδείγματα σαν δεδομένα εισόδου για κάποιο άλλο πρόβλημα επιτηρούμενης μάθησης.

Τέλος η συν-εκπαίδευση είναι η επέκταση της αυτό-εκπαίδευσης που μόλις αναφέραμε, κατά την οποία (συν-εκπαίδευση) πολλαπλοί ταξινομητές εκπαιδεύονται σε διαφορετικά ζευγάρια χαρακτηριστικών και δημιουργούν ο ένας για τον άλλο ταξινομημένα παραδείγματα.

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΜΕΡΟΣ Β : ΚΥΡΙΟ ΜΕΡΟΣ ΕΡΓΑΣΙΑΣ

ΚΕΦΑΛΑΙΟ 2 : ΔΙΚΤΥΑ ΒΑΘΙΑΣ ΠΙΣΤΗΣ (DBNs)

2.1 Εισαγωγή

Τα δίκτυα βαθιάς πίστης (deep belief networks, DBNs) είναι διαδεδομένα για την εκμάθηση συμπαγών αναπαραστάσεων δεδομένων υψηλής διάστασης. Ωστόσο, οι περισσότερες προσεγγίσεις μέχρι στιγμής βασίζονται στην ύπαρξη ενός μοναδικού σετ εκπαίδευσης. Εάν

όμως η κατανομή των σχετικών χαρακτηριστικών αλλάζει κατά τη διάρκεια των μεταγενέστερων σταδίων εκπαίδευσης τότε τα χαρακτηριστικά τα οποία έχει ήδη αποστηθίσει σε προγενέστερα στάδια ξεχνιούνται σταδιακά. Συχνά είναι επιθυμητό για τους αλγόριθμους εκμάθησης να διατηρούν τα δεδομένα που έχουν ήδη αφομοιώσει, ακόμα και όταν η κατανομή εισόδου αλλάξει. Στο κεφάλαιο αυτό θα έχουμε την ευκαιρία να αναλύσουμε περαιτέρω τα δίκτυα βαθιάς πίστης, τις ιδιότητές τους, τη χρήση τους και να αναφερθούμε στις εφαρμογές τους. Στο επόμενο κεφάλαιο αναλύουμε κυρίως τα MDBN δηλαδή τα μη επιβλεπόμενα κυκλωματικά δίκτυα βαθιάς πίστης (unsupervised modular DBN) μέσω των οποίων το πρόβλημα της διατήρησης της αφομοίωσης που αναφέραμε παραπάνω αντιμετωπίζεται. Τα δίκτυα αυτά αποτελούνται από ένα αριθμό κυκλωμάτων τα οποία είναι εκπαιδευμένα μόνο πάνω σε δείγματα που μπορούν να ανακατασκευάσουν.

Τα δίκτυα βαθιάς πίστης (deep belief networks) είναι πιθανολογικά γενετικά μοντέλα που αποτελούνται από πολλαπλά επίπεδα-στρώματα στοχαστικών και κρυμμένων μεταβλητών. Οι κρυμμένες μεταβλητές έχουν συνήθως δυαδικές τιμές οι οποίες συνήθως ονομάζονται κρυμμένες μονάδες ή ανιχνευτές χαρακτηριστικών. Τα πρώτα δύο επίπεδα έχουν μη-κατευθυνόμενες συμμετρικές συνδέσεις μεταξύ τους και δημιουργούν μία συσχετιστική μνήμη. Τα χαμηλότερα στρώματα λαμβάνουν κατευθυνόμενες συνδέσεις από το επίπεδο που βρίσκεται από πάνω τους. Η κατάσταση των μονάδων στα χαμηλότερα επίπεδα αντιπροσωπεύει ένα διάγραμμα δεδομένων.

Οι δύο πιο σημαντικές ιδιότητες των δικτύων βαθιάς πίστης είναι οι παρακάτω.

- Η διαδικασία επίπεδο με επίπεδο είναι πολλή αποδοτική, καθώς έτσι τα γενετικά βάρη καθορίζουν τον τρόπο με τον οποίο οι μεταβλητές σε ένα επίπεδο εξαρτώνται από τις μεταβλητές που βρίσκονται στο πάνω ακριβώς επίπεδο.
- Μετά την εκμάθηση, οι τιμές των άγνωστων μεταβλητών μπορούν να δημιουργηθούν με ένα απλό πέρασμα από το κατώτερο στο ανώτερο επίπεδο, που ξεκινάει με ένα διάγραμμα χαρακτηριστικών στο κατώτερο επίπεδο και χρησιμοποιεί τα γενετικά βάρη με την αντίθετη κατεύθυνση.

Τα δίκτυα βαθιάς πίστης (deep belief networks) μαθαίνουν ένα επίπεδο τη φορά, με επεξεργασία των τιμών των κρυμμένων μεταβλητών σε ένα στρώμα, όταν έχουν δημιουργηθεί από δεδομένα, όπως τα δεδομένα για την εκπαίδευση του επόμενου επιπέδου. Αυτή η αποδοτική και άπληστη μέθοδος μάθησης μπορεί να υιοθετηθεί ή να συνδυαστεί με άλλες διαδικασίες μάθησης που τελειοποιούν όλα τα βάρη για να βελτιώσουν την γενετική ή την διακριτική απόδοση ολόκληρου του δικτύου.

Η διακριτική τελειοποίηση μπορεί να επιτευχθεί προσθέτοντας ένα τελικό επίπεδο μεταβλητών το οποίο αντιπροσωπεύει τις επιθυμητές εξόδους-αποτελέσματα και χρησιμοποιεί την τεχνική της ανάστροφης διάδοσης (backpropagation) για τα παραγόμενα λάθη. Η τεχνική αυτή χρησιμοποιείται κυρίως από τα τεχνητά νευρωνικά δίκτυα. Το δίκτυο εκπαιδεύεται μέσω των πολλών εισόδων (εισαγωγή πολλών δεδομένων) και έτσι προκύπτουν τα επιθυμητά αποτελέσματα, τρόπος δηλαδή παρόμοιος με εκείνον όπου ένα μικρό παιδί μαθαίνει να αναγνωρίζει ένα σκύλο μέσα από παραδείγματα στα οποία περιέχονται σκύλοι. Όταν σε δίκτυα με πολλά κρυμμένα επίπεδα εφαρμόζονται πολύ-δομημένα δεδομένα εισόδου, όπως είναι οι εικόνες, τότε η τεχνική της ανάστροφης διάδοσης δουλεύει πολύ καλύτερα εάν οι ανιχνευτές χαρακτηριστικών στα κρυμμένα επίπεδα αρχικοποιούνται με το να εκπαιδευτούν πάνω σε ένα δίκτυο βαθιάς πίστης, το οποίο μοντελοποιεί τη δομή των δεδομένων εισόδου (Hinton & Salakhutdinov, 2006).

2.2 Δίκτυα βαθιάς πίστης σε σχέση με τα απλά κυκλώματα μάθησης

Ένα δίκτυο βαθιάς πίστης (deep belief network) μπορεί να θεωρηθεί σαν μία σύνθεση απλών μαθησιακών κυκλωμάτων καθένα απ' τα οποία είναι τύπου μηχανής Boltzmann και περιέχει ένα επίπεδο ορατών μονάδων που αναπαριστούν τα δεδομένα και ένα επίπεδο κρυφών μονάδων οι οποίες μαθαίνουν να αναπαριστούν χαρακτηριστικά τα οποία καταλαμβάνουν συσχετίσεις

υψηλότερης τάξης-σημασίας στα δεδομένα. Τα δύο αυτά επίπεδα συνδέονται μεταξύ τους μέσω ενός πίνακα συμμετρικά σταθμισμένων συνδέσεων, W και δεν υπάρχουν καθόλου συνδέσεις μέσα στα επίπεδα αυτά. Λαμβάνοντας υπόψη ένα διάνυσμα δραστηριοτήτων v για τις ορατές μονάδες, οι κρυφές μονάδες είναι όλες ανεξάρτητες υπό κάποιους όρους και έτσι είναι εύκολο να πάρουμε για δείγμα ένα διάνυσμα h , από την μεταγενέστερη παραγοντική κατανομή μέσω των κρυφών διανυσμάτων, $p(h|v, W)$. Είναι επίσης εύκολο να πάρουμε ως δείγμα από τη σχέση $p(v|h, W)$. Ξεκινώντας με ένα φανερό διάνυσμα δεδομένων στις φανερές μονάδες και εναλλάσσοντας το αρκετές φορές μεταξύ των δειγματικών σχέσεων $p(h|v, W)$ και $p(v|h, W)$, είναι αρκετά εύκολο να λάβουμε ένα εκπαιδευτικό σήμα ή ένα σήμα εκμάθησης. Αυτό το σήμα είναι απλώς η διαφορά μεταξύ των ζευγών συσχετίσεων των ορατών και των κρυφών μονάδων κατά την έναρξη και τη λήξη της δειγματοληψίας.

2.3 Η θεωρητική τεκμηρίωση της μαθησιακής διαδικασίας

Η βασική ιδέα πίσω από τα δίκτυα βαθιάς πίστης είναι ότι τα βάρη W τα οποία μαθαίνονται από μία μηχανή Boltzmann, προσδιορίζουν τόσο την $p(v|h, W)$ όσο και την προγενέστερη κατανομή μέσω των κρυφών διανυσμάτων $p(h|W)$ και έτσι η πιθανότητα της δημιουργίας ενός φανερού

διανύσματος v μπορεί να γραφτεί ως εξής: $p(v) = \sum_h p(h|W)p(v|h, W)$

2.4 Δίκτυα βαθιάς πίστης με άλλου τύπου μεταβλητές

Τα δίκτυα βαθιάς πίστης συνήθως χρησιμοποιούν μία λογική συνάρτηση για τα βάρη εισόδου που προέρχονται από τα κατώτερα ή τα ανώτερα επίπεδα για να καθορίσουν την πιθανότητα κατά την οποία μία δυαδική μεταβλητή έχει τιμή 1 όταν πραγματοποιείται πέρασμα από το ανώτερο στο κατώτερο επίπεδο ή από το κατώτερο στο ανώτερο, όπως αναφέρθηκε στην αρχή του κεφαλαίου. Παρ' όλα αυτά μπορούν να χρησιμοποιηθούν και άλλα είδη μεταβλητών στις οποίες εφαρμόζεται εξίσου το μεταβλητό όριο, υπό τον όρο ότι οι μεταβλητές αυτές ανήκουν στην εκθετική οικογένεια μεταβλητών.

2.5 Εφαρμογές των δικτύων βαθιάς πίστης

Τα δίκτυα βαθιάς πίστης χρησιμοποιούνται για την δημιουργία και αναγνώριση εικόνων, βίντεο και για την κίνηση-σύλληψη δεδομένων. Εάν ο αριθμός των μονάδων στο υψηλότερο επιπέδο-στρώμα είναι μικρός, τότε τα δίκτυα αυτά εκτελούν μη γραμμική μείωση διαστάσεων και μπορούν να μάθουν μικρούς δυαδικούς κώδικες οι οποίοι επιτρέπουν πολλή γρήγορη ανάκτηση εγγράφων και εικόνων.

ΚΕΦΑΛΑΙΟ 3 : ΚΥΚΛΩΜΑΤΙΚΑ ΔΙΚΤΥΑ ΒΑΘΙΑΣ ΠΙΣΤΗΣ ΑΦΟΜΟΙΩΣΗΣ ΔΕΔΟΜΕΝΩΝ

3.1 Εισαγωγή

Τα δίκτυα βαθιάς πίστης (DBNs) είναι νευρωνικά δίκτυα τα οποία αποτελούνται από μία σείβα επιπέδων της μηχανής Boltzmann τα οποία εκπαιδεύονται ένα τη φορά, μέσω της μάθησης χωρίς επιτήρηση με σκοπό να προκαλέσουν την αύξηση των αφηρημένων αναπαραστάσεων στις εισόδους των ακόλουθων στρωμάτων. Αυτού του είδους η εκπαίδευση, δηλαδή εκπαίδευση από στρώμα σε στρώμα ή από επίπεδο σε επίπεδο, διευκολύνει την μάθηση με επιτήρηση των

δικτύων τα οποία είναι καταρχήν περισσότερο αποδοτικά στην εκμάθηση συμπαγών αναπαραστάσεων δεδομένων υψηλής διάστασης, παρά ρηχών αρχιτεκτονικών, αλλά είναι επίσης εμφανώς δύσκολο να εκπαιδευτούν με παραδοσιακές μεθόδους κλίσης.

Τα δίκτυα βαθιάς πίστης μπορούν να γίνουν ιδιαιτέρως χρήσιμα σαν αισθητικοί προεπεξεργαστές για τους μαθητευόμενους - έξυπνους πράκτορες οι οποίοι αλληλεπιδρούν με ένα περιβάλλον το οποίο απαιτεί εκμάθηση πολύπλοκων αντιστοιχίσεων λειτουργιών από εισροές - εισόδους υψηλών διαστάσεων. Αυτοί οι χώροι εισόδου συνήθως είναι ενσωματωμένοι μέσα σε ένα μεγάλο χώρο κατάστασης όπου η κατανομή εισόδου μπορεί να ποικίλει ευρέως μεταξύ των περιοχών. Αντί να δημιουργήσουμε ένα μονολιθικό σετ εκπαίδευσης καλύπτοντας όλα τα ενδεχόμενα, είναι προτιμότερο και αποδοτικότερο να εκπαιδεύσουμε έναν έξυπνο πράκτορα σταδιακά ώστε να μπορεί να βασιστεί σ' αυτά που έμαθε προηγουμένως. Αυτό το παράδειγμα συνεχούς μάθησης απαιτεί οι υποκείμενοι αλγόριθμοι μάθησης να υποστηρίζουν την κράτηση - αποθήκευση - μνήμη της εκπαίδευσης που έχει λάβει χώρα νωρίτερα. Ωστόσο, στη συνεχή μάθηση - εκπαίδευση, όπου τα στατιστικά των δεδομένων εκπαίδευσης αλλάζουν με την πάροδο του χρόνου, τα δίκτυα βαθιάς πίστης σταδιακά ξεχνούν τις προηγούμενες αναπαραστάσεις που έχουν ήδη διδαχθεί, καθώς νέα πρότυπα εισόδου αντικαθιστούν εκείνα τα πρότυπα που γίνονται πλέον λιγότερο πιθανά.

Μια πιθανή θεραπεία στο πρόβλημα αυτό, δηλαδή στην απώλεια της μνήμης είναι η διαίρεση-διαχωρισμός ενός μονολιθικού δικτύου σε ειδικά - έμπειρα κυκλώματα, καθένα απ' τα οποία ειδικεύεται σε ένα υποσύνολο του συνόλου. Σε μια τέτοια (συνολική) προσέγγιση τα έμπειρα κυκλώματα εκπαιδεύονται στο να βελτιώσουν την απόδοσή τους μόνο σε δευτερεύουσες εργασίες στις οποίες η απόδοσή τους είναι ήδη αρκετά καλή, αγνοώντας τις δευτερεύουσες εργασίες άλλων τέτοιων έμπειρων κυκλωμάτων και ως εκ τούτου προστατεύουν τα δικά τους βάρη από τη φθορά που μπορεί να προκληθεί από άσχετα πρότυπα εισόδου.

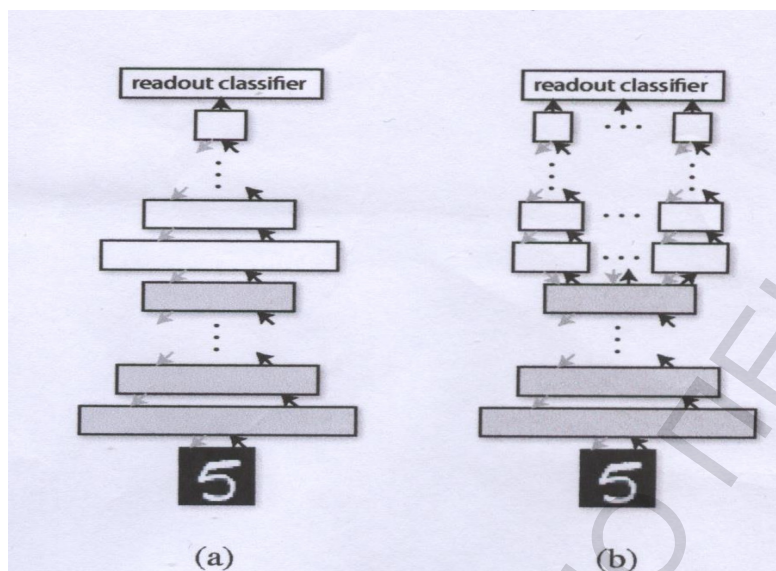
Αυτό το κεφάλαιο περιγράφει τα λεγόμενα κυκλωματικά δίκτυα βαθιάς πίστης (modular DBNs, M-DBNs), μια δηλαδή εκπαιδευτική μέθοδο χωρίς επιτήρηση με σκοπό να επιτευχθεί η εκπαίδευση των ειδικών DBN κυκλωμάτων (expert DBN modules) έτσι ώστε να αποφευχθεί τυχόν απώλεια μνήμης, σε περίπτωση που γίνει κάποια αλλαγή στη βάση δεδομένων, η οποία μπορεί να χαρακτηριστεί ως καταστροφική. Τα M-DBNs χρησιμοποιούν ένα σύστημα - σχέδιο μάθησης με βάση το οποίο κάθε κύκλωμα ενημερώνεται σε αντιστοιχία με τα δείγματα τα οποία ανακατασκευάζει καλύτερα. Τα πειραματικά αποτελέσματα αποδεικνύουν ότι αυτές οι τροποποιήσεις στα αρχικά δίκτυα βαθιάς πίστης είναι επαρκής για να διευκολύνουν την ειδίκευση των κυκλωμάτων και να αποτρέψουν την απώλεια μνήμης των ήδη γνωστών χαρακτηριστικών και ιδιοτήτων σε περιπτώσεις κατά τις οποίες τα στατιστικά και τα αποτελέσματα των δεδομένων εκπαίδευσης αλλάζουν συνεχώς με την πάροδο του χρόνου.

3.2 Κυκλωματικά δίκτυα βαθιάς πίστης

3.2.1 Δίκτυα βαθιάς πίστης

Τα κυκλωματικά δίκτυα βαθιάς πίστης (modular deep belief networks) και κατ' επέκταση η δημιουργία και η λειτουργία τους βασίζεται πάνω στα απλά δίκτυα βαθιάς πίστης τα οποία αποτελούνται από μια στοίβα από κλειστές - περιορισμένες μηχανές Boltzmann (RBMs), Σχήμα 3.1(a). Κάθε RBM έχει ένα στρώμα - επίπεδο εισόδου το οποίο είναι και το φανερό επίπεδο και ένα κρυφό επίπεδο στοχαστικών δυαδικών μονάδων. Το φανερό και το κρυφό επίπεδο ενώνονται μεταξύ τους μέσω ενός πίνακα βαρών και δεν υπάρχει καμία σύνδεση μεταξύ των μονάδων που βρίσκονται στο ίδιο επίπεδο. Η διάδοση του σήματος μπορεί να συμβεί με δύο τρόπους. Ο πρώτος τρόπος είναι η αναγνώριση, όπου οι ορατές ενεργοποιήσεις μεταδίδονται στις κρυφές μονάδες. Ο δεύτερος τρόπος είναι η ανοικοδόμηση, επαναδημιουργία όπου οι κρυφές ενεργοποιήσεις μεταδίδονται στις ορατές μονάδες. Ο ίδιος ο πίνακας βαρών χρησιμοποιείται και για την αναγνώριση και για την επαναδημιουργία. Ελαχιστοποιώντας τη διαφορά μεταξύ της αρχικής εισόδου και της επαναδημιουργίας της (πχ σφάλμα ανοικοδόμησης) μέσω μιας διαδικασίας που ονομάζεται αντιπαραβολική απόκλιση τα βάρη μπορούν να εκπαιδευτούν ώστε να παράγουν τα πρότυπα εισόδου τα οποία παρουσιάζονται σε μια κλειστή μηχανή Boltzmann με υψηλή πιθανότητα.

Στα δίκτυα βαθιάς πίστης (DBNs) τα μεταγενέστερα επίπεδα συνήθως είναι πιο μικρά σε μέγεθος για να υποχρεώνουν το δίκτυο να μαθαίνει και να κατανοεί ευκολότερα όλο και πιο συμπαγείς αναπαραστάσεις των εισόδων του. Αυτή η εκπαιδευτική διαδικασία κάποιες φορές συμβαίνει περισσότερο για την βελτιστοποίηση πρόσθετων όρων, όπως είναι η L1 και η L2 νόρμες του πίνακα βαρών ή οι αναφορές στους περιορισμούς των μονάδων ενεργοποίησης. Τα βάρη αρχικοποιούνται από μια κανονική κατανομή μηδενικής σημασίας και μικρής τυπικής απόκλισης.



Σχήμα 3.1 Αρχιτεκτονικές δικτύων: (a) Μονολιθικό DBN, (b) modular M-DBN. Και οι 2 αρχιτεκτονικές έχουν κοινά τα πρώτα στρώματα (γκρι κουτιά).

3.2.2 Κυκλωματικά δίκτυα βαθιάς πίστης που δεν ξεχνούν

Τα κυκλωματικά δίκτυα βαθιάς πίστης (modular deep belief networks, M-DBNs) αποτελούνται από ένα σύνολο DBN κυκλωμάτων τα οποία λαμβάνουν όλα το ίδιο πρότυπο εισόδου (Σχήμα 3.1b). Τα κυκλώματα μεταδίδουν τα δεδομένα εισόδου μέσω όλων των επιπέδων και από το τελευταίο επίπεδο πάλι πίσω μέσω του δικτύου έτσι ώστε να επαναδημιουργηθούν δεδομένα εισόδου. Στη συνέχεια, υπολογίζεται το σφάλμα επαναδημιουργίας (reconstruction error) για κάθε κύκλωμα στην είσοδό του, και μόνο το κύκλωμα με το σφάλμα επαναδημιουργίας εκπαιδεύεται, ένα επίπεδο τη φορά για ένα μικρό αριθμό κύκλων. Αυτή η διαδικασία επαναλαμβάνεται αρκετές φορές μέχρις ότου να ικανοποιηθούν κάποια προκαθορισμένα κριτήρια.

Αυτή η διαδικασία εκπαίδευσης διευκολύνει την εξειδίκευση και αποτρέπει την απώλεια μνήμης με τους τρεις παρακάτω τρόπους. Πρώτον τα κυκλώματα δεν ειδικεύονται σε δείγματα τα οποία ανατίθενται περιστασιακά σε διαφορετικούς - μεταγενέστερους κύκλους. Δεύτερον ένα κύκλωμα εκσυγχρονίζεται μόνο εάν εξειδικεύεται σε χαρακτηριστικά παρόμοια με ένα ικανοποιητικό αριθμό δειγμάτων. Τέλος ένα κύκλωμα σταματάει να ενημερώνεται - εκσυγχρονίζεται εάν τα δείγματα στα οποία εξειδικεύεται, αφαιρεθούν - αποσπαστούν από τα εκπαιδευτικά δεδομένα.

Τα M-DBNs μπορούν να αποτελούνται από εντελώς ξεχωριστά DBNs ή κάποια κατώτερα στρώματα - επίπεδα μπορούν να διαμοιραστούν μεταξύ των κυκλωμάτων (Σχήμα 3.1b). Ο διαμοιρασμός των στρωμάτων αυτών μεταξύ των κυκλωμάτων μπορεί να μειώσει αισθητά τις υπολογιστικές προσπάθειες, ειδικά σε εργασίες όπου όλα τα πρώτα στρώματα εκπαιδεύονται στο να κατανοήσουν χαρακτηριστικά τα οποία βρίσκονται σε πολύ αρχικό στάδιο και είναι παρόντα σε όλα τα δείγματα. Ο διαχωρισμός ενός δικτύου βαθιάς πίστης σε

κυκλώματα μπορεί να γίνει όσες φορές χρειάζεται σε διαφορετικά στρώματα. Το σφάλμα επαναδημιουργίας, που αναφέρθηκε προηγουμένως, στο πρώτο επίπεδο των κυκλωμάτων (το οποίο όμως δεν είναι και απαραίτητα το επίπεδο εισόδου όλου του δικτύου) καθορίζει ποίο κύκλωμα θα εκπαιδευτεί.

3.2.3 Μέθοδοι εκπαίδευσης

Έχουν προταθεί και άλλες μέθοδοι με σκοπό την σωστή και γρήγορη εκπαίδευση των κυκλωματικών δικτύων βαθιάς πίστης (modular deep belief networks) οι οποίες συνήθως βασίζονται στις τροποποιημένες ενημερώσεις εξομοιώσεων των βαρών που λαμβάνουν υπόψη το σφάλμα επαναδημιουργίας. Μια τέτοια μέθοδος έχει δείξει ότι κάποια μείγματα αυτοκωδικοποιητών είναι σε θέση να ξεχωρίσουν μεταξύ διαφορετικών χειρόγραφων κατηγοριών ψηφίων. Μια άλλη μέθοδος χρησιμοποιεί το σφάλμα επαναδημιουργίας των αυτοκωδικοποιητών των κυκλωμάτων στις ενημερώσεις των βαρών για να αναγκάσει την παραγωγή - έξοδο ενός τουλάχιστον κυκλώματος να ταιριάζει με την είσοδο αλλά και για να αναγκάσει τα υπόλοιπα κυκλώματα να αυξήσουν το σφάλμα μεταξύ της εισόδου και της εξόδου. Τέλος μια άλλη μέθοδος απέδειξε την επιτυχή εξειδίκευση των κυκλωματικών δικτύων βαθιάς πίστης (modular deep belief networks) σε περιορισμένα και ολιγοδιάστατα δεδομένα.

Σε σύγκριση με τα κυκλωματικά δίκτυα βαθιάς πίστης που παρουσιάζονται εδώ, αυτές οι μέθοδοι είναι πιο περίπλοκες, περιλαμβάνουν πρόσθετες ρυθμιζόμενες παραμέτρους και χρησιμοποιούνται κυρίως για να αποδείξουν την εξειδίκευση των κυκλωμάτων ή για να επιτύχουν αύξηση της αποδοτικότητας σε σταθερές βάσεις δεδομένων. Οι περισσότερες προσεγγίσεις των δικτύων αυτών εφαρμόζουν την μέθοδο του ανταγωνισμού για να ενημερώσουν τα βάρη σε όλα τα κυκλώματα παρά απ' το να ενημερώσουν το καλύτερο κύκλωμα. Μολονότι, η ενημέρωση όλων των κυκλωμάτων για κάθε δείγμα μπορεί να οδηγήσει σε γρηγορότερη αλλά και καλύτερη εξειδίκευση, το υπολογιστικό κόστος είναι αρκετά μεγάλο και επίσης κάνει το δίκτυο επιρρεπή στην απώλεια μνήμης. Προκειμένου να αποτραπεί η απώλεια μνήμης, οι ενημερώσεις των κυκλωμάτων πρέπει να είναι πραγματικά τοπικές. Ωστόσο, η ενημέρωση ενός κυκλώματος για κάθε δείγμα είναι απαραίτητη, αλλά όχι και επαρκής στο να αποτρέψει την απώλεια της μνήμης καθώς ακόμη και ένα μόνο δείγμα μπορεί να προκαλέσει αναπροσαρμογή σε ολόκληρο το κύκλωμα στην περίπτωση κατά την οποία η κλάση στην οποία ειδικεύεται το κύκλωμα αυτό, παύει να υφίσταται.

Μία άλλη παρόμοια μέθοδος που αποτρέπει την απώλεια μνήμης είναι η χρήση ξεχωριστών κυκλωμάτων για την βραχυπρόθεσμη αλλά και την μακροπρόθεσμη μνήμη. Σ' αυτήν την προσέγγιση οι πρόσφατες πληροφορίες μεταφέρονται αργά στην μακροπρόθεσμη μνήμη με τη βοήθεια των λεγόμενων ψευδοπροτύπων. Τα ψευδοπρότυπα αυτά είναι κυρίως ζευγάρια εισερχομένων και εξερχομένων δεδομένων για τυχαία πρότυπα εισόδου. Τα κυκλωματικά δίκτυα βαθιάς πίστης μοιάζουν με αυτές τις προσεγγίσεις σε κάποιο βαθμό, καθώς αποθηκεύουν δείγματα για έναν εκπαιδευτικό κύκλο στην βραχυπρόθεσμη μνήμη, καθορίζουν κάποιες ιδιότητες της κατανομής του δείγματος και χρησιμοποιούν τις ιδιότητες αυτές για να εκπαιδεύσουν τα κυκλώματα.

3.3 Πειράματα

Εκτελέσαμε κάποια πειράματα για να μελετήσουμε την ικανότητα των κυκλωματικών δικτύων βαθιάς πίστης (modular deep belief networks) να ειδικεύονται και να διατηρούν τις δεξιότητες, τις οποίες έχουν ήδη διδαχθεί, πάνω σε διάφορες τεχνικές αναγνώρισης χειρόγραφων ψηφίων και τις συγκρίνουμε με μια μη κυκλωματική (non-modular) αρχιτεκτονική, όπως είναι τα απλά δίκτυα βαθιάς πίστης (deep belief networks), συγκρίσιμου μεγέθους. Το σχήμα 3.1 απεικονίζει τις δύο συγκρίσιμες αρχιτεκτονικές που χρησιμοποιήθηκαν για την επίτευξη των πειραμάτων. Τόσο τα δίκτυα βαθιάς πίστης όσο και τα κυκλωματικά δίκτυα βαθιάς πίστης έχουν τα ίδια πρώτα επίπεδα αλλά διαφέρουν στα εναπομείναντα ανώτερα επίπεδα. Ενώ τα ανώτερα αυτά επίπεδα στα δίκτυα βαθιάς πίστης είναι εντελώς συνδεδεμένα μεταξύ τους, όπως ακριβώς συμβαίνει και με τα κατώτερα, τα κυκλωματικά δίκτυα βαθιάς πίστης διαθέτουν ένα ζευγάρι ξεχωριστών μικρότερων ανώτερων επιπέδων για κάθε ένα από τα κυκλώματα τους. Τα ανώτερα επίπεδα των δικτύων βαθιάς πίστης είναι μεγέθους τέτοιου ώστε ο συνολικός αριθμός

των βαρών στα δύο αυτά δίκτυα να είναι περίπου ίσος και το τελικό μέγεθος του επιπέδου να είναι ίσο με τα σε συνδυασμό τελικά μεγέθη των κυκλωμάτων.

Όλα αυτά τα πειράματα χρησιμοποιούν το MNIST σύνολο δεδομένων το οποίο περιέχει 70000, $28 * 28$ pixel images χειρόγραφων ψηφίων 0-9. Προκειμένου να μειώσουμε τον υπολογιστικό χρόνο και να απλοποιήσουμε την παρουσίαση των αποτελεσμάτων, τα πειράματα

περιορίστηκαν στα ψηφία 0 έως 5, δηλαδή τα της συνολικής βάσης δεδομένων. Ακολουθώντας την κοινή πρακτική 10000 εικόνες χρησιμοποιήθηκαν για δοκιμή.

Τόσο τα DBN όσο και τα M-DBN χρησιμοποίησαν τέσσερα κοινά στρώματα τα οποία είχαν μέγεθος 1000 - 500 - 500 - 100. Αυτά τα κοινά στρώματα εκπαιδεύτηκαν αρχικά για 50 κύκλους (epochs) στο εκπαιδευτικό σύνολο δεδομένων MNIST και μετά σταματήσανε - παγώσανε, κάτι το οποίο μείωσε τον υπολογιστικό χρόνο, καθώς τα μεταγενέστερα στρώματα δεν χρειάστηκε να προσαρμοστούν στις επικείμενες αλλαγές στα κοινά βάρη.

Τα κυκλωματικά δίκτυα βαθιάς πίστης που χρησιμοποιήθηκαν στα πειράματα αποτελούνταν από 10 κυκλώματα ($n_M = 10$) με όλο και περισσότερο μικρότερα επάνω στρώματα μεγέθους 70 - 40 - 20 - 10 - 4 - 1. Οι ενημερώσεις των βαρών και τα σφάλματα επαναδημιουργίας για τα δίκτυα αυτά υπολογίστηκαν και εφαρμόστηκαν σε minibatches μεγέθους $100n_M$, παράγοντας ένα modular minibatch μεγέθους 100 στην περίπτωση που τα δείγματα κατανεμηθούν ισάξια σε όλα τα κυκλώματα. Ο ρυθμός μάθησης α^M του κάθε κυκλώματος M ορίστηκε αναλογικά ως προς τα δείγματα x^M τα οποία το module M επανακατασκεύασε καλύτερα.

$$\alpha^M = \alpha * x^M * n_M$$

Ο καθολικός ρυθμός μάθησης ορίστηκε ως 0.1 και ο κυκλωματικός (modular) ρυθμός μάθησης α^M δεν επιτρέπεται να γίνει μεγαλύτερος από τον α . Αν το κλάσμα των καλύτερων

επαναδημιουργημένων δειγμάτων από ένα κύκλωμα είναι μικρότερο από $0.3 \frac{n_M}{n_M}$ τότε το κύκλωμα δεν εκπαιδεύεται

Τα μη κυκλωματικά δίκτυα βαθιάς πίστης (non-modular DBNs) έχουν τον ίδιο αριθμό στρωμάτων όπως και τα κυκλωματικά δίκτυα βαθιάς πίστης, τον ίδιο περίπου αριθμό βαρών και ένα τελικό στρώμα ίδιου μεγέθους με τα σε συνδυασμό μεγέθη του τελικού στρώματος των κυκλωματικών δικτύων βαθιάς πίστης. Για παράδειγμα ένα κυκλωματικό δίκτυο βαθιάς πίστης το οποίο διαθέτει 10 κυκλώματα με ανώτερα στρώματα μεγέθους 70 - 40 - 20 - 10 - 4 - 1 (108440 weights), συγκρίθηκε με ένα δίκτυο βαθιάς πίστης με ανώτερα στρώματα μεγέθους 314 - 179 - 90 - 45 - 18 - 10 (108756 weights). Να σημειωθεί ότι ένα μεγάλο μέρος των βαρών του κυκλωματικού δικτύου βαθιάς πίστης ($\approx 70\%$) βρίσκεται μεταξύ του τελευταίου κοινού στρώματος και των πρώτων στρωμάτων του κυκλώματος. Το δίκτυο βαθιάς πίστης χρησιμοποίησε ένα minibatch μεγέθους 100 και ρυθμό μάθησης 0.1. Για μια δίκαιη σύγκριση με την κυκλωματική προσέγγιση, κάθε στρώμα δικτύου βαθιάς πίστης εκπαιδεύτηκε για 10 διαδοχικούς κύκλους πριν γίνει εκπαίδευση στο επόμενο στρώμα.

Για να ελέγξουμε το βαθμό στον οποίο τα κυκλώματα ειδικεύονται σε μια κλάση ψηφίων, υπολογίσαμε ένα δείκτη εξειδίκευσης για κάθε κύκλωμα M από τον παρακάτω τύπο.

$$\xi^M = \max_i (x_i^M)$$

όπου το x_i^M είναι το κλάσμα των δειγμάτων της κλάσης ψηφίου $i = 0 \dots 5$ τα οποία επανακατασκευάστηκαν καλύτερα από το κύκλωμα M. Όσο ψηλότερος είναι ο δείκτης τόσο πιο πολύ ένα κύκλωμα προτιμάει μία συγκεκριμένη κλάση ψηφίου. Ο μέσος δείκτης εξειδίκευσης

$$\bar{s} = \sum_M x^M s^M$$

δείχνει το βαθμό στον οποίο τα κυκλώματα υπερφορτώνονται και κατά πόσο ένα κυκλωματικό δίκτυο βαθιάς πίστης εξειδικεύεται σαν σύνολο. Ο μέσος όρος εξειδίκευσης του δείκτη με τιμή 1 συνεπάγεται ότι κάθε κύκλωμα εξειδικεύεται σε μία ακριβώς τάξη ψηφίου, ενώ μία τιμή εξειδίκευσης μικρότερη του 1 συνεπάγεται ότι ένα ή περισσότερα κυκλώματα εξειδικεύονται σε παραπάνω από μία κλάση ψηφίου.

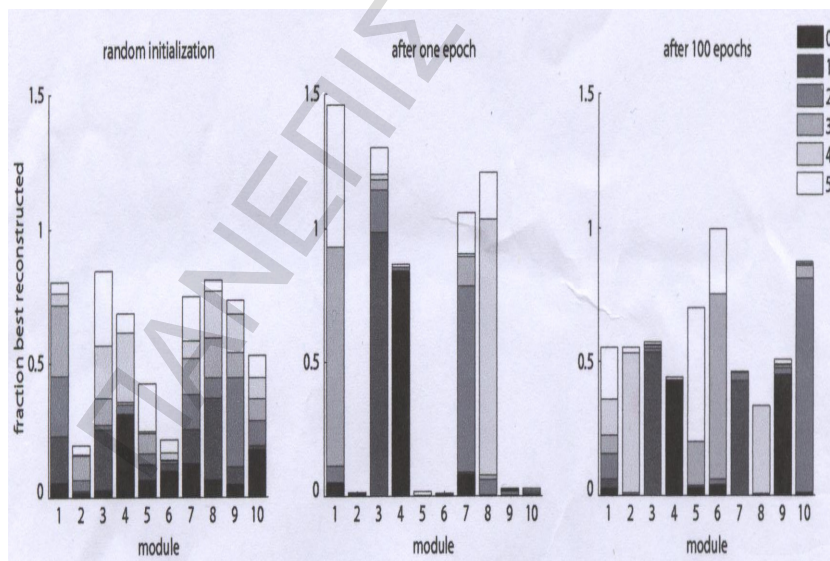
Προκειμένου να καθορισθεί η χρησιμότητα των αναπαραστάσεων οι οποίες μαθεύτηκαν κατά τη διάρκεια των πειραμάτων, μια μηχανή διανυσμάτων υποστήριξης (support vector machine, SVM) εκπαιδεύονταν κάθε 10 κύκλους για να κατατάξει τα ψηφία 0 - 5, με βάση τις M-

DBN και DBN αναπαραστάσεις του τελικού στρώματος από το MNIST test set. Τα από το MNIST test set χρησιμοποιήθηκαν για να εκπαιδευθούν την SVM. Η αποδοτικότητα της ταξινόμησης μετρήθηκε ως το κλάσμα των σωστά ταξινομημένων δειγμάτων \bar{F} ως προς το

εναπομείναν του test dataset.

3.3.1 Εξειδίκευση κυκλωμάτων

Σε πρώτη φάση ερευνούμε την ικανότητα του κυκλωματικού δικτύου βαθιάς πίστης (M-DBN) να εξειδικεύει τα κυκλώματα του σε διαφορετικές κλάσεις ψηφίων. Το σχήμα 3.2 απεικονίζει την αναλογία των ψηφίων που έχουν επανακατασκευαστεί καλύτερα από το κάθε κύκλωμα κατά τη διάρκεια πολλών σταδίων της εκπαίδευσης.



Σχήμα 3.2 Η αναλογία των καλύτερων επαναδημιουργημένων δειγμάτων ανά κύκλωμα και η κλάση ψηφίου κατά τη διάρκεια διαφορετικών σταδίων εκπαίδευσης: αμέσως μετά την τυχαία αρχικοποίηση βαρών (αριστερά), μετά από έναν εκπαιδευτικό κύκλο (κέντρο) και μετά από 100 εκπαιδευτικούς κύκλους (δεξιά).

Αρχικά τα κυκλώματα δεν επιδεικνύουν προφανείς προτιμήσεις ψηφίων, αλλά μετά από έναν εκπαιδευτικό κύκλο κάποια από αυτά έχουν ήδη εξειδικευτεί σε μία ή δύο κλάσεις ψηφίων. Προφανώς, οι μικρές αρχικές διαφορές στην κατανομή των ψηφίων ως προς τα κυκλώματα είναι επαρκείς για να καθορίσουν την εξειδίκευση του εκάστοτε κυκλώματος. Ωστόσο κάποια από αυτά ειδικεύονται σε περισσότερες από μία (συνήθως δύο) κλάσεις ψηφίων, πχ το κύκλωμα 1 μετά από έναν κύκλο. Στα περισσότερα άλλωστε πειράματα συνήθως φαίνεται ότι υπάρχει ένα κύκλωμα το οποίο ειδικεύεται τόσο στο ψηφίο 3 όσο και στο 5. Συνήθως πολλές δεκάδες κύκλων χρειάζονταν για περαιτέρω διαχωρισμό και παρ' όλα αυτά ο πλήρης διαχωρισμός αυτών των κλάσεων ψηφίων δεν ήταν πάντα επιτυχής, πχ τα κυκλώματα 5 και 6 μετά από 100 κύκλους. Ενώ αυτό μπορεί να αποτελέσει πρόβλημα για κάποιες συγκεκριμένες δραστηριότητες στις οποίες τα ψηφία αυτά δεν είναι πάντα διαθέσιμα στα εκπαιδευτικά δεδομένα, την ίδια στιγμή η απόδοση του ταξινομητή ανάγνωσης δεν επηρεάζεται από τους χαμηλότερους δείκτες ειδίκευσης μεταξύ ψηφίων τα οποία βασίζονται στις αναπαραστάσεις του τελικού στρώματος των μη ειδικευμένων κυκλωμάτων.

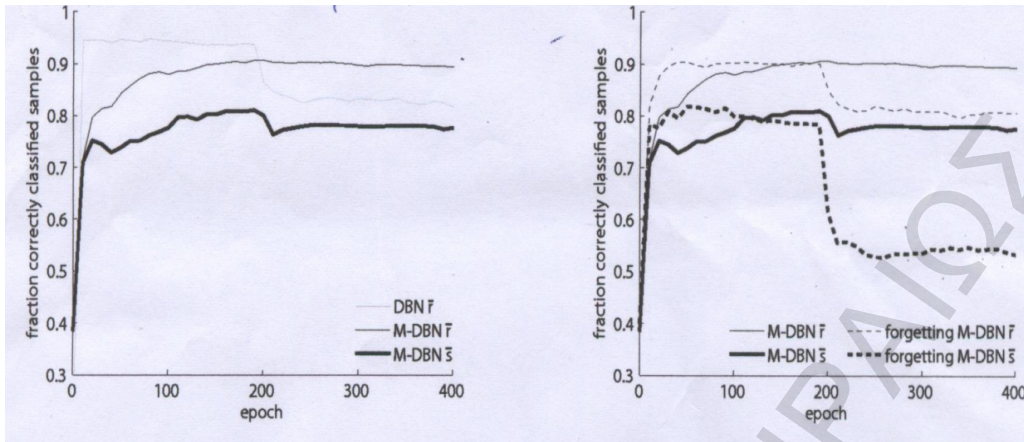
Τα πορίσματα αυτά φανερώνουν ότι τα κυκλώματα ειδικεύονται σε δύο στάδια. Το πρώτο αφορά την ταχεία προσαρμογή προς μια συγκεκριμένη κλάση στους πρώτους κύκλους. Δεύτερον, αργή απώλεια μνήμης των κλάσεων οι οποίες είναι λιγότερο συχνά αφιερωμένες σε ένα κύκλωμα στην περίπτωση που η αρχική ειδίκευση του κυκλώματος δεν ήταν πλήρως επιτυχημένη. Εάν τα δείγματα από πολλαπλές κλάσεις εκχωρούνται σε ένα μόνο κύκλωμα, τότε το κύκλωμα αυτό θα συντονιστεί τελικά προς την κλάση που έχει τα περισσότερα δείγματα για αυτό το κύκλωμα. Αν ωστόσο δεν υπάρχουν κυκλώματα τα οποία να ειδικεύονται σε μία από τις πολλαπλές κλάσεις που ένα κύκλωμα επανακατασκευάζει καλύτερα, καμία περαιτέρω ειδίκευση δεν θα συμβεί. Για παράδειγμα, εάν τα ψηφία 1, 3 και 5 παρέχονται σε τρία κυκλώματα, δύο από τα κυκλώματα αυτά μπορεί αρχικά να ειδικεύονται στο ψηφίο 1 ενώ το τρίτο να ειδικεύεται και στα δύο άλλα ψηφία, δηλαδή στο 3 και στο 5. Αυτό σημαίνει ότι δεν υπάρχουν αρκετά κυκλώματα που κάνουν τις ίδιες διακρίσεις που μπορούν να κάνουν οι άνθρωποι και δείχνει ότι κάποιες πτυχές του προβλήματος αυτού πρέπει να είναι γνωστές εκ των προτέρων προκειμένου να επιτευχθεί η βέλτιστη λύση του. Η αύξηση του αριθμού των κυκλωμάτων (πάνω από 20) βελτιώνει την εξειδίκευση αλλά όπως αναφέρθηκε και παραπάνω το μείζον ζήτημα στην περίπτωση μας δεν είναι η επίτευξη της απόλυτης αποδοτικότητας αλλά η ικανότητα των κυκλωματικών δικτύων βαθιάς πίστης (modular deep belief networks) να εξειδικεύονται και να μην ξεχνάνε, δηλαδή να μην έχουν απώλειες μνήμης.

3.3.2 Θέματα - Προβλήματα μη σταθερών ψηφίων

Εδώ μελετούμε την ικανότητα των κυκλωματικών δικτύων βαθιάς πίστης (M-DBNs) να διατηρούν τα χαρακτηριστικά τα οποία έχουν ήδη μάθει-διδασχθεί σε δύο προβλήματα μη σταθερών ψηφίων. Το πρώτο αφορά την μετακίνηση των κλάσεων των ψηφίων από τα εκπαιδευτικά δεδομένα και το δεύτερο την αντικατάσταση ενός σετ κλάσεων ψηφίων με ένα άλλο. Κατά τη διαδικασία της μετακίνησης, τα δίκτυα εκπαιδεύονται για 200 κύκλους πάνω στα ψηφία 0 - 5 και μετά άλλους 200 μόνο στα ψηφία 0 - 2. Αυτή η διαδικασία ελέγχει την ικανότητα των δικτύων να διατηρούν τα χαρακτηριστικά τα οποία έχουν ήδη διδαχθεί, αφού τα χαρακτηριστικά αυτά εξαφανιστούν από τα εκπαιδευτικά δεδομένα. Κατά τη διαδικασία της αντικατάστασης το εκπαιδευτικό ζευγάρι εναλλασσόταν μεταξύ των κλάσεων ψηφίων 0-2 και 3-5 κάθε 200 κύκλους. Αυτή η διαδικασία τεστάρει κατά πόσο καλά τα δίκτυα διατηρούν τα χαρακτηριστικά που έχουν ήδη μάθει-διδασχθεί αμέσως μόλις αυτά εξαφανιστούν από τα εκπαιδευτικά δεδομένα, ενώ ταυτόχρονα μαθαίνουν νέα χαρακτηριστικά. Πέντε διαφορετικά αρχικοποιημένα δίκτυα βαθιάς πίστης (DBNs) και κυκλωματικά δίκτυα βαθιάς πίστης (M-DBNs) εκπαιδεύτηκαν για κάθε διαδικασία. Όπως περιγράφηκε και παραπάνω, μια μηχανή διανυσμάτων υποστήριξης (SVM) εκπαιδεύτηκε ανά 10 κύκλους για να κατατάξει τα ψηφία 0-5 στον MNIST έλεγχο δεδομένων, χρησιμοποιώντας τις αναπαραστάσεις του τελικού στρώματος.

Το σχήμα 3.3 δείχνει την αποδοτικότητα του δικτύου βαθιάς πίστης (DBN) και του κυκλωματικού δικτύου βαθιάς πίστης (M-DBN) στην διαδικασία της μετακίνησης. Στη σύγκριση συμπεριλήφθηκαν επίσης τα αποτελέσματα για ένα M-DBN που χρησιμοποίησε τον γενικό ρυθμό μάθησης για όλα τα κυκλώματα, αντί για τον συγκεκριμένο ρυθμό μάθησης α^M . Εφόσον η έκδοση αυτή χρησιμοποιεί ειδικευμένα κυκλώματα, αλλά δεν διαθέτει μηχανισμό για να

αποτρέψει την απώλεια μνήμης, ονομάζεται κυκλωματικό δίκτυο βαθιάς πίστης με απώλειες μνήμης (forgetting M-DBN).




Σχήμα 3.3 Αποδοτικότητα του DBN και του M-DBN (αριστερά). Του forgetting M-DBN και του M-DBN(δεξιά) κατά τη διαδικασία της μετακίνησης. Η εκπαίδευση ξεκινά με τα ψηφία 0-5 και συνεχίζει με τα ψηφία 0-2 μετά από 200 epoch. Η αποδοτικότητα της ταξινόμησης \bar{F} και του δείκτη εξειδίκευσης \bar{S} βασίζεται στα ψηφία 0-5 στην MNIST data set.

Αρχικά ο ταξινομητής ανάγνωσης του δικτύου βαθιάς πίστης (DBN) δημιουργεί την καλύτερη ταξινόμηση, αλλά μετά από πολλούς εκατοντάδες κύκλους η αποδοτικότητα πέφτει. Στον κύκλο 200, οι κλάσεις 3 έως 5 παύουν να υπάρχουν στα εκπαιδευτικά δεδομένα και η εκπαίδευση συνεχίζεται μόνο με τις τάξεις 0 έως 2. Λίγο μετά, η απόδοση για το δίκτυο αυτό (DBN) έχει πτωτικές τάσεις. Ωστόσο, περίπου το 85% των δειγμάτων παραμένουν ακόμα σωστά ταξινομημένα από το δίκτυο βαθιάς πίστης μετά τον διακοσιστό κύκλο, μολονότι μόνο το 50% των ψηφιακών κλάσεων είναι παρόν στα εκπαιδευτικά δεδομένα. Αυτό συμβαίνει είτε γιατί το δίκτυο διατηρεί κάποια από τα χαρακτηριστικά που έχει ήδη μάθει, ή επειδή οι αναπαραστάσεις για της εναπομείναντες κλάσεις μπορούν ακόμη να χρησιμοποιηθούν για την σωστή ταξινόμηση των κλάσεων που λείπουν. Για να επαληθεύσουμε ποιά υπόθεση από τις δύο είναι η σωστή, εκπαιδεύσαμε πέντε δίκτυα βαθιάς πίστης στις κλάσεις 0 ως 2 και καθορίσαμε η αποδοτικότητα της ταξινόμησης των μηχανών διανυσμάτων υποστήριξης (readout support vector machines) να βασίζεται στις αναπαραστάσεις του τελικού στρώματος για τα ψηφία 0-5 στην MNIST test data. Καταλήξαμε σε ένα παρόμοιο ποσοστό ταξινόμησης της τάξεως του 85% όπως δηλαδή για ένα δίκτυο βαθιάς πίστης το οποίο εκπαιδεύτηκε στις κλάσεις 0-5 και προηγουμένως (σχήμα 3.3). Έτσι το συμπέρασμα είναι ότι το δίκτυο αυτό όντως ξεχνάει τα σχετικά χαρακτηριστικά για τα ψηφία που δεν είναι παρόντα στα εκπαιδευτικά δεδομένα.

Αντιθέτως η αποδοτικότητα του ταξινομητή ανάγνωσης για το κυκλωματικό δίκτυο βαθιάς πίστης (modular deep belief network) δεν μειώθηκε μετά την μετακίνηση των κλάσεων 3-5. Παρατηρήσαμε ότι η κατανομή των ψηφίων των κλάσεων 3-5 που έχουν πλέον μετακινηθεί σε σχέση με τα κυκλώματα δεν άλλαξε, υποδηλώνοντας ότι τα κυκλώματα αυτά διατηρούν την ειδίκευσή τους. Από την άλλη, ο δείκτης ειδίκευσης του κυκλωματικού δικτύου βαθιάς πίστης, μειώθηκε απότομα μετά την μετακίνηση των ψηφίων 3-5 από τα δεδομένα εκπαίδευσης. Καθώς η εξειδίκευση των κυκλωμάτων δεν ήταν ποτέ εντελώς τέλεια, τα κυκλώματα που σε μεγάλο βαθμό εξειδικεύονταν στα ψηφία 3-5 ήταν επίσης καλύτερα στην επαναδημιουργία ενός πολύ μικρού αριθμού ψηφίων 0-2. Χωρίς ένα προσαρμοσμένο ποσοστό μάθησης, ο μικρός αριθμός των καλύτερα επανακατασκευασμένων δειγμάτων από άλλες κλάσεις τελικά ανάγκασε τα κυκλώματα στο να προσαρμόσουν την εμπειρία τους στις εναπομένουσες κλάσεις του κυκλωματικού δικτύου βαθιάς. Όπως ακριβώς για το δίκτυο βαθιάς πίστης (DBN), έτσι και το κυκλωματικό δίκτυο βαθιάς πίστης (M-DBN) "ξέχασε" τα σχετικά χαρακτηριστικά που χρειαζόνταν για την αναγνώριση των ψηφίων τα οποία δεν είναι πλέον παρόντα στα εκπαιδευτικά δεδομένα, προκαλώντας μείωση στην αποδοτικότητα.

Το σχήμα 3.4 δείχνει τα αποτελέσματα της διαδικασίας της αντικατάστασης. Όπως και στη διαδικασία της μετακίνησης, το κυκλωματικό δίκτυο βαθιάς πίστης (M-DBN) υπερτερεί του

δικτύου βαθιάς πίστης (DBN) μετά την αντικατάσταση στις κλάσεις. Ακόμη και μετά από πολλές παρουσιάσεις των διαφορετικών σετ, το DBN ξεχνάει ακόμα τα χαρακτηριστικά τα οποία έχει ήδη μάθει όταν το σύνολο των δεδομένων αλλάξει. Ωστόσο, η περιορισμένη εκπαίδευση στις κλάσεις 0-2 και 3-5 δεν προκαλεί την ίδια πτώση στην αποδοτικότητα του. Κάποιες φορές ο δείκτης εξειδίκευσης του κυκλωματικού δικτύου βαθιάς πίστης (M-DBN) μειώνεται (όπως για παράδειγμα στους 900 κύκλους). Κάτι τέτοιο προκαλείται από μια ανακατανομή ενός μέρους των δειγμάτων σε ένα διαφορετικό κύκλωμα το οποίο τελικά οδηγεί στην καλύτερη αποδοτικότητα του ταξινομητή ανάγνωσης.



Σχήμα 3.4 Η αποδοτικότητα του DBN και του M-DBN κατά τη διαδικασία της αντικατάστασης ψηφίου

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΣΥΜΠΕΡΑΣΜΑΤΑ

Με αυτήν την διατριβή καταφέραμε να κατανοήσουμε αναλυτικά τη σημασία της αναγνώρισης προτύπου και στη συνέχεια τη σημασία των δικτύων βαθιάς πίστης (deep belief networks, DBNs) που είναι και το κύριο θέμα μας, αλλά και μιας υποκατηγορίας τους, τα κυκλωματικά δίκτυα βαθιάς πίστης (modular deep belief networks, M-DBNs) και το πως η λειτουργία τους επηρεάζει σε βάθος κάποιους άλλους τομείς πέραν της πληροφορικής. Η ανάλυση αυτή μας έμαθε τους λόγους για τους οποίους είναι σημαντική η αναγνώριση προτύπου και τους τομείς πάνω στους οποίους βρίσκει απήχηση όπως είναι η εξόρυξη δεδομένων, η ιατρική και η βιοϊατρική. Τέλος με την χρήση κάποιων εύστοχων παραδειγμάτων και αναλύσεων καταφέραμε να εξηγήσουμε στον αναγνώστη τον τρόπο με τον οποίο επηρεάζονται όλοι αυτοί οι τομείς από την αναγνώριση προτύπου.

Στη συνέχεια της διατριβής μας ασχοληθήκαμε με το κύριο θέμα μας που δεν είναι άλλο από τα δίκτυα βαθιάς πίστης (deep belief networks). Αναφερθήκαμε σ' αυτά δίνοντας κάποιους ορισμούς και αναλύοντας τις ιδιότητες που αυτά έχουν, προκειμένου ο αναγνώστης μας να είναι σε θέση να κατανοήσει πλήρως την ερμηνεία τους καθώς το ζήτημα αυτό είναι ακόμα αρκετά καινούργιο και δεν μπορεί να γίνει εύκολα αντιληπτό απ' τον καθένα. Αναφέραμε επίσης τη σχέση των δικτύων αυτών ως προς τα simple learning modules αλλά και στα δίκτυα βαθιάς πίστης (deep belief networks) τα οποία διαθέτουν άλλου τύπου μεταβλητές. Κλείνοντας το κομμάτι αυτό κάναμε μια σύντομη αναφορά σχετικά με τις εφαρμογές των DBNs.

Στο τελευταίο κεφάλαιο της διατριβής μας έγινε εκτενή αναφορά σε μία άλλη κατηγορία DBN, τα λεγόμενα κυκλωματικά δίκτυα βαθιάς πίστης (modular DBNs). Αναλύσαμε τους λόγους που χρησιμοποιούνται και φυσικά εξηγήσαμε τι ακριβώς είναι αλλά και τον τρόπο που αυτά λειτουργούν. Μέσω κάποιων σχημάτων που χρησιμοποιήσαμε, αλλά και των πειραμάτων που έχουν διεκπεραιωθεί αναλύσαμε τη σχέση τους με τα δίκτυα βαθιάς πίστης, την αποδοτικότητα τους αλλά και κάποια προβλήματα τα οποία μπορεί να εμφανίσουν.

Απ' όλα όσα μελετήσαμε στη διατριβή αυτή καταλήξαμε στο συμπέρασμα ότι τα δίκτυα βαθιάς πίστης (deep belief networks) αποτελούν ένα πολύ σημαντικό κομμάτι για την επιστήμη της πληροφορικής αλλά και για πολλές άλλες επιστήμες. Αυτή τη στιγμή βρίσκονται σε ένα πρώιμο στάδιο αλλά με την κατάλληλη μελέτη και αξιοποίηση τους θα αποτελέσουν σίγουρα ένα κορυφαίο μελλοντικό εργαλείο για τους επιστήμονες μέσω του οποίου πολλές λειτουργίες και πολλά θέματα τα οποία αυτή τη στιγμή φαντάζουν μακρινά και δύσκολα θα υλοποιηθούν κάποια στιγμή στο μέλλον.

ΒΙΒΛΙΟΓΡΑΦΙΑ

1. Sergios Theodoridis, Konstantinos Koutroubas (2009) <<Pattern Recognition>>
2. Leo Pape, Faustino Gomez, Mark Ring, Jurgen Schmidhuber <<Modular Deep Belief Networks that do not forget >>
3. Geoffrey E. Hinton (2009) << Deep Belief Networks>>
http://www.scholarpedia.org/article/Deep_belief_networks
4. <<Supervised learning>> http://en.wikipedia.org/wiki/Supervised_learning
5. <<Semi-supervised learning>> http://en.wikipedia.org/wiki/Semi-supervised_learning

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ