



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΘΕΣΣΑΛΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

ΜΕΘΟΔΟΙ ΤΑΞΙΝΟΜΗΣΗΣ ΜΕ SVM
(SUPPORT VECTOR MACHINES), ΝΕΥΡΩΝΙΚΑ
ΔΙΚΤΥΑ (NEURAL NETWORKS) ΚΑΙ ΒΑΘΙΑ
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (DEEP NEURAL
NETWORKS) – ΣΥΓΚΡΙΣΗ ΤΩΝ ΜΕΘΟΔΩΝ

ΕΥΑΓΓΕΛΙΑ ΕΙΡΗΝΗ ΧΡΟΝΗ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΥΠΕΥΘΥΝΟΣ

Κούκιου Γεωργία
Πανεπιστημιακή Υπότροφος

Μάρτιος 2022



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΘΕΣΣΑΛΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

ΜΕΘΟΔΟΙ ΤΑΞΙΝΟΜΗΣΗΣ ΜΕ SVM
(SUPPORT VECTOR MACHINES), ΝΕΥΡΩΝΙΚΑ
ΔΙΚΤΥΑ (NEURAL NETWORKS) ΚΑΙ ΒΑΘΙΑ
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (DEEP NEURAL
NETWORKS) – ΣΥΓΚΡΙΣΗ ΤΩΝ ΜΕΘΟΔΩΝ

ΕΥΑΓΓΕΛΙΑ – ΕΙΡΗΝΗ ΧΡΟΝΗ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΥΠΕΥΘΥΝΟΣ

Κούκιου Γεωργία
Πανεπιστημιακή Υπότροφος

Λαμία 10 Μαρτίου έτος 2022



UNIVERSITY OF
THESSALY

SCHOOL OF SCIENCE

DEPARTMENT OF COMPUTER SCIENCE & TELECOMMUNICATIONS

CLASSIFICATION METHODS WITH SVMs,
NEURAL NETWORKS AND DEEP NEURAL
NETWORKS – COMPARISON OF THE
METHODS

EVANGELIA – EIRINI CHRONI

FINAL THESIS

ADVISOR

Koukiou Georgia
Academic Scholar

Lamia March 10th year 2022

«Με ατομική μου ευθύνη και γνωρίζοντας τις κυρώσεις ⁽¹⁾, που προβλέπονται από της διατάξεις της παρ. 6 του άρθρου 22 του Ν. 1599/1986, δηλώνω ότι:

1. Δεν παραθέτω κομμάτια βιβλίων ή άρθρων ή εργασιών άλλων αυτολεξεί **χωρίς να τα περικλείω σε εισαγωγικά** και χωρίς να αναφέρω το συγγραφέα, τη χρονολογία, τη σελίδα. Η αυτολεξεί παράθεση χωρίς εισαγωγικά χωρίς αναφορά στην πηγή, είναι λογοκλοπή. Πέραν της αυτολεξεί παράθεσης, λογοκλοπή θεωρείται και η παράφραση εδαφίων από έργα άλλων, συμπεριλαμβανομένων και έργων συμφοιτητών μου, καθώς και η παράθεση στοιχείων που άλλοι συνέλεξαν ή επεξεργάστηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραθέματα.
2. Δέχομαι ότι η αυτολεξεί **παράθεση χωρίς εισαγωγικά**, ακόμα κι αν συνοδεύεται από αναφορά στην πηγή σε κάποιο άλλο σημείο του κειμένου ή στο τέλος του, είναι αντιγραφή. Η αναφορά στην πηγή στο τέλος π.χ. μιας παραγράφου ή μιας σελίδας, δεν δικαιολογεί συρραφή εδαφίων έργου άλλου συγγραφέα, έστω και παραφρασμένων, και παρουσίασή τους ως δική μου εργασία.
3. Δέχομαι ότι υπάρχει επίσης περιορισμός στο μέγεθος και στη συχνότητα των παραθεμάτων που μπορώ να εντάξω στην εργασία μου εντός εισαγωγικών. Κάθε μεγάλο παράθεμα (π.χ. σε πίνακα ή πλαίσιο, κλπ), προϋποθέτει ειδικές ρυθμίσεις, και όταν δημοσιεύεται προϋποθέτει την άδεια του συγγραφέα ή του εκδότη. Το ίδιο και οι πίνακες και τα σχέδια
4. Δέχομαι όλες τις συνέπειες σε περίπτωση λογοκλοπής ή αντιγραφής.

Ημερομηνία: 04/03/2022

Ο – Η Δηλ.
Ευαγγελία Ειρήνη Χρόνη

(1) «Όποιος εν γνώσει του δηλώνει ψευδή γεγονότα ή αρνείται ή αποκρύπτει τα αληθινά με έγγραφη υπεύθυνη δήλωση του άρθρου 8 παρ. 4 Ν. 1599/1986 τιμωρείται με φυλάκιση τουλάχιστον τριών μηνών. Εάν ο υπαίτιος αυτών των πράξεων σκόπευε να προσπορίσει στον εαυτόν του ή σε άλλον περιουσιακό όφελος βλάπτοντας τρίτον ή σκόπευε να βλάψει άλλον, τιμωρείται με κάθειρξη μέχρι 10 ετών.»

ΠΕΡΙΛΗΨΗ

Η παρούσα εργασία εκπονήθηκε στα πλαίσια της ολοκλήρωσης του προπτυχιακού κύκλου σπουδών στο τμήμα Πληροφορικής και Τηλεπικοινωνιών του Πανεπιστημίου Θεσσαλίας. Η εργασία πραγματοποιήθηκε υπό την επίβλεψη της κα. Γεωργίας Κούκιου.

Το αντικείμενο της παρούσας διπλωματικής εργασίας είναι η ταξινόμηση με SVMs, Νευρωνικά δίκτυα και Βαθιά Νευρωνικά δίκτυα, και στη συνέχεια σύγκριση των μεθόδων αυτών.

Θα ήθελα να ευχαριστήσω την επιβλέπουσα κα. Κούκιου για την συμβολή της στην υλοποίηση της παρούσας εργασίας.

Επίσης, θα ήθελα να ευχαριστήσω τους γονείς μου, για την ευγενική υπομονή τους κατά την εκπόνηση αυτής της διπλωματικής εργασίας, για την αγάπη και την ενθάρρυνση τους, χωρίς τους οποίους δεν θα είχα ποτέ τόσες πολλές ευκαιρίες. Είμαι επίσης ευγνώμων στα αδέρφια μου Θεοδώρα, Νίκο και Τάσο για όλες τις διεγερτικές ερωτήσεις και συζητήσεις σχετικά με την τεχνητή νοημοσύνη και που πέρασαν αυτή τη μακρά διαδικασία μαζί μου. Τέλος, δεν θα μπορούσα να ολοκληρώσω αυτή την εργασία χωρίς την υποστήριξη της δεύτερης οικογένειάς μου: τους φίλους μου, που δεν έπαψαν ποτέ να με εντυπωσιάζουν με το πλήθος των χαρούμενων περιστασίων που μου παρείχαν για να με ξεκουράσουν μου από την έρευνά μου.

ABSTRACT

The present work was prepared in the context of the completion of the undergraduate course at the Department of Informatics and Telecommunications of the University of Thessaly. The work was carried out under the supervision of Mrs. Georgia Koukiou.

The object of this dissertation is the classification with SVMs, Neural Networks and Deep Neural Networks, and lastly the comparison of these methods.

I would like to thank the supervisor Mrs. Koukiou for her contribution to the implementation of this work.

I would also like to thank my parents, for their kind patience during the compilation of this dissertation, for their love and encouragement, without whom I would never have enjoyed so many opportunities. I am also grateful to my siblings Theodora, Nikos and Tasos for all the stimulating questions and discussions about artificial intelligence and for enduring this long process with me. Finally, I could not have completed this work without the support of my second family; my friends, who never ceased to impress me with the host of happy distractions they provided to rest my mind outside of my research.

Table of Contents

ΠΕΡΙΛΗΨΗ	I
ABSTRACT	III
<u>ΚΕΦΑΛΑΙΟ 1 ΕΙΣΑΓΩΓΗ.....</u>	<u>3</u>
<u>ΚΕΦΑΛΑΙΟ 2 ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΠΙΣΚΟΠΗΣΗ.....</u>	<u>4</u>
<u>ΚΕΦΑΛΑΙΟ 3 ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ</u>	<u>5</u>
3.1 ΕΙΣΑΓΩΓΗ.....	5
3.2 ΟΡΙΣΜΟΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ.....	5
3.3 ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	6
3.4 Η ΑΝΟΔΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ.....	8
3.5 ΠΩΣ ΠΡΟΕΚΥΨΕ Η ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ.....	8
3.6 ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ.....	9
3.7 ΤΥΠΟΙ – ΕΙΔΗ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ.....	11
<u>ΚΕΦΑΛΑΙΟ 4 ΤΑΞΙΝΟΜΗΣΗ</u>	<u>16</u>
4.1 ΤΙ ΕΙΝΑΙ Η ΤΑΞΙΝΟΜΗΣΗ.....	16
ΕΝΟΤΗΤΑ 4.1.Α ΤΙ ΕΙΝΑΙ ΕΝΑΣ ΑΛΓΟΡΙΘΜΟΣ	17
4.2 ΤΑΞΙΝΟΜΗΣΗ ΚΑΙ ΕΞΟΥΡΥΞΗ ΔΕΔΟΜΕΝΩΝ.....	18
4.3 ΠΩΣ ΛΕΙΤΟΥΡΓΕΙ Η ΤΑΞΙΝΟΜΗΣΗ;	18
4.4 ΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΔΟΚΙΜΕΣ.....	19
4.5 Η ΠΟΛΥΠΛΟΚΟΤΗΤΑ ΩΣ ΔΙΑΧΩΡΙΣΤΙΚΟ	20
4.6 ΤΥΠΟΙ ΤΑΞΙΝΟΜΗΣΗΣ.....	22
4.7 ΑΛΓΟΡΙΘΜΟΙ ΤΑΞΙΝΟΜΗΣΗΣ.....	25
4.8 ΟΡΟΛΟΓΙΕΣ ΤΑΞΙΝΟΜΗΣΗΣ.....	26
4.9 ΠΑΡΑΔΕΙΓΜΑΤΑ ΤΑΞΙΝΟΜΗΣΗΣ.....	26
<u>ΚΕΦΑΛΑΙΟ 5 ΜΗΧΑΝΕΣ ΔΙΑΝΥΣΜΑΤΩΝ ΥΠΟΣΤΗΡΙΞΗΣ – SUPPORT VECTOR MACHINES (SVMS).....</u>	<u>30</u>
5.1 ΕΙΣΑΓΩΓΗ.....	30
5.1.Α ΓΙΑΤΙ ΤΑ ΧΡΗΣΙΜΟΠΟΙΟΥΝΤΑΙ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	31
5.2 ΤΥΠΟΙ SVM.....	31
5.3 ΠΩΣ ΛΕΙΤΟΥΡΓΕΙ ΕΝΑ SVM.....	31
5.3.Α ΥΠΕΡΕΠΙΠΕΔΟ.....	34
5.3.Β ΠΑΡΑΜΕΤΡΟΙ ΣΥΝΤΟΝΙΣΜΟΥ : KERNEL, REGULIZATION, GAMMA, MARGIN.....	34
5.4 ΜΑΘΗΜΑΤΙΚΗ ΔΙΑΤΥΠΩΣΗ ΤΩΝ SVM.....	39
5.4.Α ΓΡΑΜΜΙΚΗ ΤΑΞΙΝΟΜΗΣΗ.....	39
5.5 ΓΕΝΙΚΕΥΣΕΙΣ ΓΙΑ ΤΗΝ ΠΕΡΙΠΤΩΣΗ ΠΟΛΛΩΝ ΤΑΞΕΩΝ	45
5.6 ΜΗ ΓΡΑΜΜΙΚΑ SVM, ΜΗ ΓΡΑΜΜΙΚΗ ΤΑΞΙΝΟΜΗΣΗ.....	45

5.6.A ΜΗ ΓΡΑΜΜΙΚΟΙ ΠΥΡΗΝΕΣ ΓΙΑ SVM	47
--	----

ΚΕΦΑΛΑΙΟ 6 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ (ΝΔ) – NEURAL NETWORKS (NNS) 50

6.1 ΕΙΣΑΓΩΓΗ.....	50
6.2 ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ PERCEPTRON.....	51
6.3 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ – ΤΝΔ	53
6.4 ΤΙ ΣΥΜΒΑΙΝΕΙ ΜΕΣΑ ΣΕ ΕΝΑΝ ΚΟΜΒΟ. ΠΩΣ ΛΕΙΤΟΥΡΓΟΥΝ ΤΑ ΤΝΔ;.....	57
6.5 ΣΥΝΟΠΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΕΝΟΣ ΤΝΔ	59
6.6 ΒΑΣΙΚΕΣ ΙΔΙΟΤΗΤΕΣ ΤΩΝ ΤΝΔ.....	60
6.7 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΤΩΝ ΤΝΔ.....	60
6.8 ΤΝΔ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ.....	61
6.9 ΕΦΑΡΜΟΓΕΣ ΤΑΞΙΝΟΜΗΣΗΣ ΜΕ ΤΝΔ.....	66
6.10 ΠΑΡΑΔΕΙΓΜΑ ΤΑΞΙΝΟΜΗΣΗΣ ΜΕ ΤΝΔ	67
6.11 ΑΞΙΟΛΟΓΗΣΗ ΜΟΝΤΕΛΟΥ.....	68

ΚΕΦΑΛΑΙΟ 7 ΒΑΘΙΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ 70

7.1 ΕΙΣΑΓΩΓΗ.....	70
7.1.A ΣΕ ΤΙ ΔΙΑΦΕΡΕΙ Η ΒΑΘΙΑ ΜΑΘΗΣΗ ΑΠΟ ΤΑ ΤΝΔ	73
7.2 ΓΙΑΤΙ ΒΑΘΙΑ ΜΑΘΗΣΗ;.....	74
7.3 ΤΡΟΠΟΙ ΕΦΑΡΜΟΓΗΣ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ	75
7.4 DNN ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ.....	76
7.4.A ΓΡΑΜΜΙΚΗ ΤΑΞΙΝΟΜΗΣΗ ΚΑΙ DNN	76
7.4.B ΤΟΠΟΛΟΓΙΑ ΠΕΡΙΦΕΡΕΙΩΝ DNN	76
7.4.Γ ΤΟΠΟΛΟΓΙΑ ΤΩΝ ΔΕΔΟΜΕΝΩΝ	76
7.5 ΕΙΝΑΙ ΠΡΑΓΜΑΤΙΚΑ Η ΙΔΑΝΙΚΗ ΤΑΞΙΝΟΜΗΣΗ;.....	77
7.6 ΜΑΘΗΜΑΤΙΚΗ ΑΝΑΛΥΣΗ ΤΩΝ DNN.....	78
7.7 ΠΟΙΑ ΕΙΝΑΙ Η ΔΙΑΦΟΡΑ ΜΕΤΑΞΥ MLP ΚΑΙ DNN	82
7.8 ΓΙΑΤΙ ΕΙΝΑΙ ΔΥΣΚΟΛΗ Η ΕΚΠΑΙΔΕΥΣΗ ΣΤΑ DNN;.....	83
7.9 ΤΑΞΙΝΟΜΗΣΗ ΕΤΙΚΕΤΑΣ ΔΙΑΣΤΗΜΑΤΟΣ (THE INTERVAL LABEL CLASSIFICATION TASK).....	84
7.10 ΣΥΜΠΕΡΙΦΟΡΑ ΚΟΜΒΟΥ Ο ΡΟΛΟΣ ΤΩΝ ΚΡΥΦΩΝ ΚΟΜΒΩΝ ΣΕ ΕΝΑ ΕΚΠΑΙΔΕΥΜΕΝΟ DNN	86
7.11 ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ.....	87
7.12 ΕΦΑΡΜΟΓΕΣ.....	92
7.13 ΤΡΟΠΟΙ ΜΑΘΗΣΗΣ	98
7.14 DNNs ΚΑΙ ΛΙΓΟΤΕΡΑ ΔΕΔΟΜΕΝΑ.....	100

ΚΕΦΑΛΑΙΟ 8 ΣΥΓΚΡΙΣΗ ΜΕΘΟΔΩΝ 104

8.1 ΤΑΞΙΝΟΜΗΣΗ – ΠΡΟΒΛΗΜΑ ΑΝΙΧΝΕΥΣΗΣ ΟΡΙΩΝ	104
(8.A) ΠΡΟΣΕΓΓΙΣΗ ΤΟΥ ΟΡΙΟΥ ΑΠΟΦΑΣΗΣ ΜΕ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ	105
(8.B) ΠΡΟΣΕΓΓΙΣΗ ΤΟΥ ΟΡΙΟΥ ΑΠΟΦΑΣΗΣ ΜΕ SVMs	105
8.2 ΟΙ ΔΥΟ ΑΛΓΟΡΙΘΜΟΙ.....	105
8.2.A SVM ΓΙΑ ΤΑΞΙΝΟΜΗΣΗ	105
8.2.B ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΓΙΑ ΤΑΞΙΝΟΜΗΣΗ.....	106
8.3 ΟΜΟΙΟΤΗΤΕΣ	106

8.4 ΔΙΑΦΟΡΕΣ 107

BIBΛΙΟΓΡΑΦΙΑ 109

ΚΕΦΑΛΑΙΟ 1 Εισαγωγή

Η μηχανική μάθηση είναι μια μορφή αναγνώρισης προτύπων της οποίας η βασική ιδέα της εκπαίδευσης των μηχανών είναι να αναγνωρίζουν μοτίβα και να τα εφαρμόζουν σε πρακτικά προβλήματα. Η μηχανική εκμάθηση είναι μια δυνατότητα (ένα χαρακτηριστικό, ή αλλιώς ένα feature) που μπορεί να μάθει από δεδομένα και να συνεχίσει να ενημερώνεται επαναληπτικά για καλύτερη απόδοση. Από την άλλη, η αναγνώριση μοτίβων δεν μαθαίνει προβλήματα, αλλά μπορεί να κωδικοποιηθεί για να μάθει μοτίβα. Η βασική δουλειά της μηχανικής μάθησης είναι να δημιουργήσει ένα μοντέλο το οποίο θα μπορεί να προβλέψει ή να ταξινομήσει διαφορετικά μοτίβα από δεδομένα. Μία από τις εφαρμογές αυτού είναι η ταξινόμηση των ανεπιθύμητων ή μη ανεπιθύμητων δεδομένων.

Οι αλγόριθμοι βελτιώνουν προσαρμοστικά την απόδοσή τους καθώς αυξάνεται ο αριθμός των δειγμάτων που είναι διαθέσιμα για εκμάθηση.

Δύο κύριοι τύποι μηχανικής εκμάθησης είναι η εποπτευόμενη και η μη εποπτευόμενη μηχανική εκμάθηση. Η ταξινόμηση ανήκει στην τύπο μηχανικής μάθησης : εποπτευόμενη ή αλλιώς επιβλεπόμενη μάθηση.

Η εποπτευόμενη ταξινόμηση είναι μία από τις εργασίες που εκτελούνται συχνότερα από τα λεγόμενα ευφυή συστήματα. Έτσι, έχει αναπτυχθεί ένας μεγάλος αριθμός τεχνικών με βάση την Τεχνητή Νοημοσύνη (Τεχνικές που βασίζονται στη λογική, τεχνικές που βασίζονται στο Δίκτυο Perceptron) και τη Στατιστική (Δίκτυα Bayesian, τεχνικές βασισμένες σε περιπτώσεις). Ο στόχος της εποπτευόμενης μάθησης είναι η οικοδόμηση ενός συνοπτικού μοντέλου κατανομής των ετικετών κλάσης από την άποψη των προγνωστικών χαρακτηριστικών. Ο ταξινομητής που προκύπτει χρησιμοποιείται στη συνέχεια για την εκχώρηση ετικετών κλάσεων στις δοκιμαστικές περιπτώσεις όπου οι τιμές των χαρακτηριστικών πρόβλεψης είναι γνωστές, αλλά η τιμή της ετικέτας κλάσης είναι άγνωστη. Αυτή η εργασία περιγράφει διάφορους αλγόριθμους ταξινόμησης και την σύγκριση αυτών.

ΚΕΦΑΛΑΙΟ 2 Βιβλιογραφική Επισκόπηση

Στο παρόν κεφάλαιο, θα κάνουμε μια σύντομη επισκόπηση της εργασίας, αναφέροντας επιγραμματικά το περιεχόμενο των επόμενων κεφαλαίων. Συγκεκριμένα, το κεφάλαιο 3 έχει βασικό θέμα την τεχνητή νοημοσύνη και την μηχανική μάθηση. Δίνονται οι ορισμοί των δύο εννοιών, καθώς και η μεταξύ τους σχέση. Επιπλέον, γίνεται αναφορά στις εφαρμογές και στα είδη μηχανικής μάθησης.

Στο κεφάλαιο 4, αποσαφηνίζεται ο όρος «Ταξινόμηση». Περιγράφεται ο τρόπος λειτουργίας της ταξινόμησης σε ένα μοντέλο μηχανικής μάθησης, καθώς επίσης, γίνεται αναφορά στους τύπους και αλγορίθμους που χρησιμοποιούνται για την εργασία της ταξινόμησης σε ένα μοντέλο. Τέλος, δίνονται κάποιες βασικές ορολογίες που χρησιμοποιούνται ευρέως, όταν το θέμα είναι η ταξινόμηση.

Το κεφάλαιο 5 πραγματεύεται την αποσαφήνιση της ταξινόμησης με τις μηχανές στήριξης διανυσμάτων, ή αλλιώς SVMs. Αναφέρονται οι τύποι των SVMs, εξηγείται ο τρόπος λειτουργίας της ταξινόμησης με SVMs.

Στο κεφάλαιο 6, ασχολούμαστε με την ταξινόμηση με τα Νευρωνικά Δίκτυα. Το κεφάλαιο, μετά από μια σύντομη εισαγωγή, επεξηγεί τον τρόπο λειτουργίας του Δικτύου Perceptron, και ύστερα δίνει έναν γενικό ορισμό για τα Τεχνητά Νευρωνικά Δίκτυα. Ασχολούμαστε με τον τρόπο λειτουργίας, την αρχιτεκτονική και τις ιδιότητες των δικτύων αυτών. Στη συνέχεια, επεξηγείται η ταξινόμηση με νευρωνικά δίκτυα, αναφέρονται κάποιες εφαρμογές και παραδείγματα της ταξινόμησης με ΤΝΔ και τέλος, γίνεται αναφορά στον τρόπο αξιολόγησης ενός ΤΝΔ μοντέλου.

Στο κεφάλαιο 7, επεξηγούμε την ταξινόμηση με τα Βαθιά Νευρωνικά Δίκτυα. Αρχικά, επεξηγούνται οι έννοιες της βαθιάς μάθησης και των βαθιών νευρωνικών δικτύων, αναφέρονται οι τρόποι εφαρμογής της βαθιάς μάθησης. Ύστερα, συνεχίζουμε με το υπό-κεφάλαιο με θέμα βαθιά νευρωνικά δίκτυα και ταξινόμηση. Τα δίκτυα αυτά επεξηγούνται στη συνέχεια αλγεβρικά. Επιπλέον, δίνονται οι αρχιτεκτονικές της βαθιάς μάθησης.

Τέλος, το κεφάλαιο 8, ασχολείται με τη σύγκριση των παραπάνω μεθόδων. Πιο συγκεκριμένα, αναφέρονται κάποιες ομοιότητες μεταξύ των μεθόδων, οι διαφορές τους, καθώς και τα πλεονεκτήματα και μειονεκτήματα για κάθε έναν απ' τους αλγόριθμους αυτούς.

ΚΕΦΑΛΑΙΟ 3 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση

3.1 Εισαγωγή

Η τεχνητή Νοημοσύνη (ΤΝ) (Artificial Intelligence - AI), παρόλο που συμπλήρωσε μισό αιώνα ζωής, εξακολουθεί να είναι μία από τις πιο μοντέρνες ερευνητικές περιοχές. Η άνοδος της Τεχνητής Νοημοσύνης (AI), των Μεγάλων Δεδομένων, ή αλλιώς Big Data, και των νέων εξελίξεων στη μηχανική μάθηση σε διάφορες εφαρμογές, όπως αναγνώριση εικόνας, νευρωνικά δίκτυα, αναγνώριση ομιλίας, επεξεργασία φυσικής γλώσσας (NLP), όραση υπολογιστή, ανίχνευση αντικειμένων κ.α. έχει επιταχύνει την ανάπτυξη της Τεχνητής Νοημοσύνης σε σημείο που, αυτό που παλιά αποτελούσε επιστημονική φαντασία, πλέον είναι ένα επιστημονικό γεγονός. Εν μέρει οφείλεται στην ίδια την επανάσταση των Big Data. Η πληθώρα δεδομένων έχει οδηγήσει σε εντατικοποιημένη έρευνα για τους τρόπους επεξεργασίας, ανάλυσης και δράσης τους.

Τυπικά, η τεχνητή νοημοσύνη, ξεκίνησε το 1956 στη συνάντηση μερικών επιφανών επιστημόνων, όπως ο John McCarthy, ο Marvin Minsky, ο Claude Shannon και άλλοι. Από την άλλη, η μελέτη της νοημοσύνης είναι ένα από τα πιο παλιά θέματα της ανθρώπινης αναζήτησης. Για περισσότερο από 2000 χρόνια, φιλόσοφοι όπως ο Αριστοτέλης, ο Ηράκλειτος, ο Descartes και άλλοι, προσπάθησαν να περιγράψουν το μηχανισμό της μάθησης, της απομνημόνευσης, της όρασης, της αντίληψης και του συλλογισμού.

Καθώς η τεχνολογία και, κυρίως, η κατανόησή μας για το πώς λειτουργεί το μυαλό μας, έχει προχωρήσει, η αντίληψή μας για το τι συνιστά το AI έχει αλλάξει. Αντί για ολοένα και πιο πολύπλοκους υπολογισμούς, η έρευνα στον τομέα της τεχνητής νοημοσύνης επικεντρώθηκε στη μίμηση των διάφορων διαδικασιών λήψης αποφάσεων από ανθρώπους και στην εκτέλεση έργων με όλο και πιο ανθρώπινους τρόπους.

Η Τεχνητή Νοημοσύνη - συσκευές σχεδιασμένες για να λειτουργούν έξυπνα - συχνά ταξινομούνται σε μία από τις δύο θεμελιώδεις ομάδες - εφαρμοσμένες ή γενικές. Η εφαρμοσμένη τεχνητή νοημοσύνη είναι πολύ πιο συνηθισμένη.

Τα γενικευμένα AI - συστήματα ή συσκευές που θεωρητικά μπορούν να χειριστούν οποιαδήποτε εργασία - είναι λιγότερο συνηθισμένα. Ωστόσο, εδώ παρατηρούνται μερικές από τις πιο συναρπαστικές εξελίξεις σήμερα. Είναι επίσης ο τομέας που οδήγησε στην ανάπτυξη της Μηχανικής Μάθησης, η οποία συχνά, αναφέρεται ως υποσύνολο της τεχνητής νοημοσύνης, είναι δε πραγματικά πιο ακριβές να τον θεωρούμε ως την τρέχουσα τεχνολογία αιχμής.

Η ΤΝ περιλαμβάνει ένα πλήθος ερευνητικών πεδίων, από γενικού σκοπού όπως η αντίληψη και η συλλογιστική έως πιο συγκεκριμένων, όπως το σκάκι και γενικότερα τα παίγνια ικανοτήτων, η απόδειξη θεωρημάτων, η συγγραφή ποίησης, η διάγνωση ασθενειών, η ανίχνευση της συναισθηματικής κατάστασης του ανθρώπου και άλλα. Η τεχνητή νοημοσύνη συστηματοποιεί και αυτοματοποιεί τις διανοητικές εργασίες, για αυτό και μπορεί να έχει εφαρμογή σε οποιαδήποτε σφαίρα της ανθρώπινης διανοητικής δραστηριότητας. Με αυτή την έννοια, είναι πραγματικά ένα οικουμενικό πεδίο. Συχνά ερευνητές από άλλες επιστημονικές περιοχές καταφεύγουν στην ΤΝ με σκοπό να βρουν εργαλεία για να αυτοματοποιήσουν τα λογικά βήματα που χρησιμοποιούν στην εργασία τους. Όμοια, ερευνητές της ΤΝ εφαρμόζουν τις μεθόδους τους σε διάφορες περιοχές που απαιτείται ανθρώπινη ευφυή προσπάθεια.

3.2 Ορισμός Τεχνητής Νοημοσύνης

Η έννοια του τι ορίζει την τεχνητή νοημοσύνη έχει αλλάξει με την πάροδο του χρόνου, αλλά στον πυρήνα υπήρχε πάντα η ιδέα της κατασκευής μηχανών που είναι ικανές να σκέφτονται όπως οι άνθρωποι. Άλλωστε, τα ανθρώπινα όντα έχουν αποδειχθεί μοναδικά ικανά να ερμηνεύουν τον κόσμο γύρω τους και να χρησιμοποιούν τις πληροφορίες που συλλέγουν για να επιφέρουν αλλαγές σε αυτόν. Εάν θέλουμε να κατασκευάσουμε μηχανές που θα μας βοηθήσουν σε αυτό πιο αποτελεσματικά, τότε είναι λογικό να χρησιμοποιούμε τον εαυτό μας ως προσχέδιο!

Η τεχνητή νοημοσύνη, λοιπόν, μπορεί να θεωρηθεί ότι προσομοιώνει την ικανότητα για αφηρημένη, δημιουργική, συμπερασματική σκέψη - και ιδιαίτερα την ικανότητα εκμάθησης - χρησιμοποιώντας την ψηφιακή, δυαδική λογική των υπολογιστών.

Δεν υπάρχει ένας καθολικός ορισμός που να περιγράφει τον όρο «τεχνητή νοημοσύνη» Κατά καιρούς έχουν διατυπωθεί διάφοροι ορισμοί της TN, από τους οποίους άλλοι επικεντρώνονται στη διαδικασία σκέψης και συλλογισμού και άλλοι στη συμπεριφορά. Σύμφωνα με τους Russel & Norvig οι ορισμοί της TN ταξινομούνται σε τέσσερις μεγάλες κατηγορίες οι οποίες προσεγγίζουν την περιοχή από διαφορετική σκοπιά όσον αφορά το στόχο της TN.

- Η πρώτη κατηγορία θέτει ως στόχο της TN την ανάπτυξη συστημάτων που *σκέφτονται όπως οι άνθρωποι*. Για παράδειγμα, ο Haugeland ορίζει την TN ως :

“Η προσπάθεια να κατασκευάσουμε υπολογιστές με διανοητική ικανότητα με την πλήρη και κυριολεκτική έννοια του όρου”.

- Η δεύτερη κατηγορία ορίζει ως TN την προσπάθεια για ανάπτυξη συστημάτων που σκέφτονται λογικά. Ένας χαρακτηριστικός ορισμός δίνεται από τον Winston :

“Η μελέτη των υπολογισμών που καθιστούν εφικτή την αντίληψη, τη λογική σκέψη και την αντίδραση”.

- Η τρίτη κατηγορία επικεντρώνεται σε συστήματα που συμπεριφέρονται όπως οι άνθρωποι, όπως φαίνεται από τον ορισμό των Rich και Knight :

“Η μελέτη του πώς να κάνουμε τους υπολογιστές να κάνουν πράγματα στα οποία αυτήν τη στιγμή οι άνθρωποι είναι καλύτεροι”.

- Τέλος, η τέταρτη κατηγορία θέτει ως στόχο την ανάπτυξη συστημάτων που αντιδρούν λογικά, όπως αναφέρει ο Luger στον ακόλουθο ορισμό :

“Ο τομέας της επιστήμης των υπολογιστών που ασχολείται με την αυτοματοποίηση της ευφυούς συμπεριφοράς”.

Ένας γενικός ορισμός που περιλαμβάνει τα περισσότερα στοιχεία από τους παραπάνω, θα μπορούσε να είναι ο εξής :

TN είναι ο τομέας της Επιστήμης των Υπολογιστών που ασχολείται με τη σχεδίαση και την υλοποίηση προγραμμάτων τα οποία είναι ικανά να μιμηθούν τις ανθρώπινες γνωστικές ικανότητες, εμφανίζοντας έτσι χαρακτηριστικά που αποδίδουμε συνήθως σε ανθρώπινη συμπεριφορά, όπως για παράδειγμα η επίλυση προβλημάτων, η αντίληψη μέσω όρασης, η μάθηση, η εξαγωγή συμπερασμάτων, η κατανόηση φυσικής γλώσσας, κτλ.

Άμεση συνέπεια των παραπάνω ορισμών είναι ότι η TN είναι ένας συνεχώς εξελισσόμενος τομέας της επιστήμης των υπολογιστών που προσπαθεί να κάνει πραγματικότητα, ό,τι η τελευταία δεν έχει καταφέρει μέχρι στιγμής.

3.3 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση

Η Τεχνητή Νοημοσύνη (AI) και η Μηχανική Μάθηση (ML) είναι δύο από τα πιο πολυσυζητημένα αντικείμενα αυτή τη στιγμή και συχνά φαίνεται να χρησιμοποιούνται

εναλλακτικά. Το ενδιαφέρον και οι ανακαλύψεις για την Τεχνητή Νοημοσύνη, ειδικά για τη μηχανική μάθηση, έχουν πολλαπλασιαστεί και ανθίζουν εκθετικά από τη δεκαετία του 2000. Και οι δύο όροι εμφανίζονται πολύ συχνά όταν το κεντρικό θέμα είναι τα Big Data, analytics και τα ευρύτερα κύματα τεχνολογικών αλλαγών που σαρώνουν τον κόσμο μας .Εν ολίγοις, η καλύτερη παραδοχή είναι ότι:

Η Τεχνητή Νοημοσύνη είναι η ευρύτερη έννοια των μηχανών οι οποίες είναι σε θέση να εκτελέσουν εργασίες με τρόπο που θα θεωρούσαμε «έξυπνο». Από την άλλη, η μηχανική μάθηση είναι μια τρέχουσα εφαρμογή της τεχνητής νοημοσύνης που βασίζεται στην ιδέα ότι θα έπρεπε πραγματικά να μπορούμε να δίνουμε στις μηχανές πρόσβαση σε δεδομένα και να τις αφήνουμε να “μαθαίνουν” μόνες τους. Ή αλλιώς, η μηχανική μάθηση είναι μια μέθοδος ανάλυσης δεδομένων που αυτοματοποιεί τη δημιουργία αναλυτικών μοντέλων. Είναι ένας κλάδος τεχνολογίας που επιτρέπει στα συστήματα υπολογιστών να μαθαίνουν από τεράστιες ποσότητες δεδομένων, να εντοπίζουν μοτίβα μέσα σε εικόνες και σε κείμενο και να λαμβάνουν στατιστικές αποφάσεις με ελάχιστη ανθρώπινη παρέμβαση.

Η μάθηση στον άνθρωπο θεωρείται σημαντικό μέρος της νοημοσύνης του. Ο άνθρωπος προσπαθεί να κατανοήσει το περιβάλλον του παρατηρώντας το και δημιουργώντας μια απλοποιημένη (αφαιρετική) εκδοχή του, που ονομάζεται *μοντέλο (model)* . Η δημιουργία ενός τέτοιου μοντέλου, ονομάζεται *επαγωγική μάθηση (inductive learning)* ενώ η διαδικασία γενικότερα ονομάζεται *επαγωγή (induction)*. Επιπλέον ο άνθρωπος έχει τη δυνατότητα να οργανώνει και να συσχετίζει τις εμπειρίες και τις παραστάσεις του δημιουργώντας νέες δομές που ονομάζονται *πρότυπα (patterns)* . Η δημιουργία μοντέλων ή προτύπων από ένα σύνολο δεδομένων, από ένα υπολογιστικό σύστημα ονομάζεται *μηχανική μάθηση*.

Η Μηχανική Μάθηση είναι ένας τομέας λοιπόν της Τεχνητής Νοημοσύνης που ασχολείται με την ανάπτυξη αλγορίθμων μάθησης, δηλαδή αλγορίθμων που βελτιώνουν την επίδοση ενός συστήματος σε προβλήματα όπως αυτά που περιγράψαμε παραπάνω. Για να επιτευχθεί η βελτίωση, δίνεται στον αλγόριθμο ένα ικανό πλήθος παραδειγμάτων ώστε να μπορέσει να εκπαιδευτεί. Η βελτίωση συνήθως γίνεται σταδιακά επειδή ο αλγόριθμος στις περισσότερες περιπτώσεις είναι επαναληπτικός, δηλαδή εξετάζει τα παραδείγματα πολλές φορές σε “εποχές μάθησης”.



Εικόνα 3.1. Από τη βιομηχανία έως την κρυπτογράφηση, η χρήση της μηχανικής μάθησης βοηθά στη συλλογή και επεξεργασία σημαντικών δεδομένων που είναι ζωτικής σημασίας για τη λήψη έξυπνων αποφάσεων

Η μηχανική μάθηση εφαρμόζεται σχεδόν σε όλες τις εφαρμογές κοινωνικών μέσων στις μέρες μας από το YouTube, το Google, το Facebook, το Instagram, το Baidu, το Twitter κ.λπ.

Ακόμη και οι φωνητικοί βοηθοί όπως το Siri, ο Google Assistant και η Alexa παρέχονται μέσω μηχανικής μάθησης, ιδιαίτερα στο NLP και στην Αναγνώριση ομιλίας.

3.4 Η άνοδος της Μηχανικής Μάθησης

Δύο σημαντικές ανακαλύψεις οδήγησαν στην εμφάνιση της Μηχανικής Μάθησης ως το όχημα που "οδηγεί" την ανάπτυξη της Τεχνητής Νοημοσύνης προς τα εμπρός με την ταχύτητα που έχει σήμερα :

Μία από αυτές ήταν η συνειδητοποίηση - πιστώθηκε στον Άρθουρ Σαμουήλ το 1959 - ότι αντί να μαθαίνουμε στους υπολογιστές όλα όσα χρειάζονται για να γνωρίζουν για τον κόσμο και πώς να εκτελούν εργασίες, είναι δυνατόν να τους διδάξουμε να μαθαίνουν μόνοι τους.

Το δεύτερο και πιο πρόσφατο, ήταν η εμφάνιση του διαδικτύου και η τεράστια αύξηση του όγκου των ψηφιακών πληροφοριών που παράγονται, αποθηκεύονται και διατίθενται για ανάλυση.

Μόλις τέθηκαν σε εφαρμογή αυτές οι καινοτομίες, οι μηχανικοί συνειδητοποίησαν ότι αντί να διδάσκουν υπολογιστές και μηχανές πώς να κάνουν τα πάντα, θα ήταν πολύ πιο αποτελεσματικό να τους κωδικοποιήσουν να σκέφτονται σαν ανθρώπινα όντα και στη συνέχεια να τους συνδέουν στο διαδίκτυο για να τους δίνουν πρόσβαση σε όλες τις πληροφορίες του κόσμου.

3.5 Πώς προέκυψε η Μηχανική Μάθηση

Η δημιουργία αλγορίθμων ικανών να το κάνουν αυτό, χρησιμοποιώντας τη δυαδική λογική "ναι" και "όχι" των υπολογιστών, είναι το θεμέλιο της μηχανικής μάθησης - μια φράση που πιθανότατα χρησιμοποιήθηκε για πρώτη φορά κατά τη διάρκεια σοβαρής έρευνας από τον Arthur Samuel στην IBM κατά τη δεκαετία του 1950. Τα πρώτα πειράματα του Samuel περιλάμβαναν τη διδασκαλία μηχανών να μάθουν να παίζουν "checkers" .

Δεδομένου ότι η γνώση - κάτι από το οποίο μπορεί να αντλήσει γνώση και μια βάση για τη λήψη αποφάσεων - είναι βαθιά αναπόσπαστο μέρος της μάθησης, αυτοί οι πρώτοι υπολογιστές είχαν σοβαρά μειονεκτήματα λόγω της έλλειψης (πολλών) δεδομένων στη διάθεσή τους. Χωρίς όλη την ψηφιακή τεχνολογία που έχουμε σήμερα για να συλλέξουμε και να αποθηκεύσουμε πληροφορίες από τον αναλογικό κόσμο, οι μηχανές θα μπορούσαν να μάθουν μόνο από δεδομένα που εισάγονται αργά ,μέσω καρτών διάτρησης και, αργότερα, μαγνητικών ταινιών και αποθήκευσης.

Σήμερα τα πράγματα είναι λίγο διαφορετικά -χάρη στην ανάπτυξη του Διαδικτύου, τη διάδοση των κινητών τηλεφώνων, τη συλλογή δεδομένων και άλλων συσκευών και την υιοθέτηση διαδικτυακής, συνδεδεμένης τεχνολογίας στη βιομηχανία, έχουμε κυριολεκτικά περισσότερα δεδομένα παρά γνώση για το πώς να τα εκμεταλλευτούμε όσο το δυνατόν πιο σωστά και έξυπνα.

3.6 Εφαρμογές Μηχανικής Μάθησης

Υπάρχει μια μεγάλη πληθώρα εφαρμογών της μηχανικής μάθησης σε μια ολοένα αυξανόμενη γκάμα πεδίων που αφορούν μεταξύ άλλων την υγεία, την ασφάλεια, την οικονομία, την επικοινωνία, την αυτοκίνηση, την ενέργεια και πολλά άλλα. Η ραγδαία ανάπτυξη εφαρμογών μηχανικής μάθησης που παρατηρείται τα τελευταία χρόνια αναμένεται να συνεχιστεί και στο μέλλον. [2]

Οι περισσότερες από τις εφαρμογές που χειρίζεται η μηχανική μάθηση αυτή τη στιγμή περιλαμβάνουν εργασίες όπως η ταξινόμηση εικόνων, η μετάφραση γλωσσών, ο χειρισμός μεγάλου όγκου δεδομένων από αισθητήρες και η πρόβλεψη μελλοντικών τιμών με βάση τις τρέχουσες τιμές. Ορισμένες βιομηχανίες και τομείς αξιοποιούν τη δύναμη της μηχανικής μάθησης για να τους βοηθήσουν στο σύστημά τους. Παρακάτω παρατίθενται μερικές από τις πιο δημοφιλείς εφαρμογές μηχανικής μάθησης στον πραγματικό κόσμο:

1. Η αναγνώριση εικόνας είναι πραγματικά μια από τις πιο κοινές εφαρμογές της μηχανικής μάθησης. Αποτελεί μια από τις πρώτες εφαρμογές των μοντέλων μηχανικής μάθησης. Χρησιμοποιείται για τον προσδιορισμό αντικειμένων, προσώπων, τόπων, ψηφιακών εικόνων. Η αναγνώριση εικόνας πλέον χρησιμοποιείται από χιλιάδες εταιρείες και εκατομμύρια καταναλωτές καθημερινά. Χωρίζεται σε διάφορες υποπεριπτώσεις όπως η αναγνώριση προσώπου, η αναγνώριση δακτυλικών αποτυπωμάτων, η αναγνώριση ασθενειών από ιατρικές εικόνες κ.α. . Υπάρχουν πολλά μοντέλα που βασίζονται σε χαρακτηριστικά όπως οι ακμές, η μέση φωτεινότητα κ.ά., τα οποία εξάγονται κατά τη διάρκεια μιας ξεχωριστής φάσης επεξεργασίας. Τα τελευταία χρόνια, μοντέλα μηχανικής μάθησης - πιο συγκεκριμένα, μοντέλα βαθιάς μάθησης τα οποία δέχονται ως είσοδο εικόνες χωρίς ιδιαίτερη προ επεξεργασία - έχουν αναδειχθεί στα καλύτερα εργαλεία αναγνώρισης εικόνας με γενική εφαρμογή σε μεγάλη γκάμα περιπτώσεων και με εξαιρετικά αποτελέσματα σε συλλογές εικόνων πολύ μεγάλου όγκου. Τα συνελκτικικά νευρωνικά δίκτυα είναι η κύρια αρχιτεκτονική που χρησιμοποιείται στη διαδικασία αναγνώρισης εικόνας.
2. Η αναγνώριση ομιλίας είναι ένα διεπιστημονικό υποπεδίο της επιστήμης των υπολογιστών και της υπολογιστικής γλωσσολογίας που αναπτύσσει μεθοδολογίες και τεχνολογίες που επιτρέπουν την αναγνώριση και μετάφραση της ομιλούμενης γλώσσας σε κείμενο από υπολογιστές. Είναι επίσης γνωστή ως αυτόματη αναγνώριση ομιλίας (ASR), αναγνώριση ομιλίας υπολογιστή, όπου ενσωματώνει γνώση και έρευνα στην επιστήμη των υπολογιστών και τη γλωσσολογία. Η κλασική προσέγγιση για την επίλυση αυτού του προβλήματος χωρίζεται στη φάση αναγνώρισης των βασικών φθόγγων της ομιλίας που καλούνται *φωνήματα*, κατόπιν στον συνδυασμό των φωνημάτων σε ενιαίες λέξεις, και τέλος στον συνδυασμό των λέξεων σε προτάσεις με τη χρήση κάποιου μοντέλου της γλώσσας. Η μηχανική μάθηση έχει συμβάλει σημαντικά στην πρόοδο της αναγνώρισης φωνημάτων καθώς και στην αναγνώριση ομιλίας. Τα τελευταία χρόνια εφαρμόζεται με επιτυχία η μηχανική μάθηση - πιο συγκεκριμένα η βαθιά μάθηση - στην αναγνώριση ομιλίας από άκρο σε άκρο, δηλαδή στην απευθείας μετατροπή ήχου σε κείμενο χωρίς το ενδιάμεσο βήμα της αναγνώρισης φωνημάτων.
3. ΣΥΣΤΑΣΗ Με απλά λόγια, ένα μοντέλο σύστασης είναι ένας αλγόριθμος που στοχεύει στην παροχή των πιο συναφών και σχετικών πληροφοριών σε έναν χρήστη ανάλογα με τη συμπεριφορά του χρήστη. Εταιρείες όπως το Netflix και η Google διαθέτουν μια τεράστια βάση δεδομένων για τις συμπεριφορές των δεδομένων που συλλέγονται για να μπορούν να εκτελούν συστάσεις τελευταίας τεχνολογίας, ώστε να μπορούν να εμφανίζουν το πιο σχετικό περιεχόμενο ή υπηρεσίες στους χρήστες για να αυξήσουν την αφοσίωσή τους.

4. ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΚΑΤΑΝΟΗΣΗ ΦΥΣΙΚΟΥ ΛΟΓΟΥ Η επεξεργασία κειμένων φυσικού λόγου χρησιμοποιείται σε πληθώρα εφαρμογών, όπως για παράδειγμα η εκτίμηση της άποψης των συναισθημάτων ή της διάθεσης που εκφράζουν χρήστες ιστότοπων κοινωνικής δικτύωσης σχετικά με κάποιο πρόσωπο, γεγονός ή προϊόν. Η πρόβλεψη αυτή - γνωστή ως *εξόρυξη άποψης* (opinion mining) ή *ανάλυση συναισθήματος* (sentiment analysis) - είναι σημαντική για εταιρείες που προωθούν προϊόντα για επενδυτές που επιθυμούν να εκτιμήσουν τη διάθεση της αγοράς, αλλά και για πρόσωπα που προβάλλονται δημοσίως όπως πολιτικοί, καλλιτέχνες, αθλητές κ.λπ. Μέθοδοι μηχανικής μάθησης που έχουν εφαρμοστεί με επιτυχία στο πρόβλημα αυτό βασίζονται σε γλωσσικά χαρακτηριστικά των κειμένων καθώς και στην ύπαρξη όρων που εκφράζουν είτε συναίσθημα είτε αρέσκεια/δυσαρέσκεια. Μια άλλη σημαντική εφαρμογή της επεξεργασίας φυσικού λόγου με ολοένα αυξανόμενη δημοφιλία είναι η αναγνώριση κειμένων με ψευδείς ειδήσεις.

Η κατανόηση του φυσικού λόγου σχετίζεται με το σημασιολογικό περιεχόμενο των κειμένων. Διάφορα μοντέλα μηχανικής μάθησης έχουν προταθεί για τη διανυσματική αναπαράσταση των λέξεων έτσι ώστε να διατηρείται σε κάποιον βαθμό το σημασιολογικό τους περιεχόμενο, δηλαδή λέξεις με παρόμοιο νόημα να έχουν “κοντινές” αναπαραστάσεις. Αυτές οι μέθοδοι έχουν μεγάλη σημασία στην κατανόηση του κειμένου, η οποία με τη σειρά της βρίσκει σημαντικές εφαρμογές σε αυτόματα συστήματα συνομιλίας όπως τα αυτόματα συστήματα κράτησης θέσεων σε αεροπλάνα, θέατρα κ.λπ. Επίσης, τα ρομποτικά συστήματα συνομιλίας γνωστά ως chatbot, εμφανίζονται όλο και πιο συχνά σε διάφορες πλατφόρμες επικοινωνίας με σκοπό τη διασκέδαση ή την ενημέρωση (π.χ. Siri, Alexa, Cortana κ.ά.). Συνήθως τα συστήματα αυτά βασίζονται σε αναδρομικά μοντέλα μηχανικής μάθησης για την αναπαράσταση των πληροφοριών και σε μοντέλα μάθησης με ενίσχυση για την παραγωγή της απάντησης στα πλαίσια της συνομιλίας.

5. ΥΓΕΙΑ ΚΑΙ ΒΙΟΕΠΙΣΤΗΜΕΣ Η μηχανική μάθηση στην υγειονομική περίθαλψη είναι ένας τέτοιος τομέας που βλέπει σταδιακή αποδοχή στον κλάδο της υγειονομικής περίθαλψης. Ένα παράδειγμα είναι η υποβοήθηση της διάγνωσης μέσω υπολογιστή (Computer Assisted Diagnosis - CAD), όπου μοντέλα μάθησης όπως τα νευρωνικά δίκτυα χρησιμοποιούνται για την πρόβλεψη της ασθένειας με βάση τα ιατρικά δεδομένα του ασθενούς. Τα ιατρικά δεδομένα μπορεί να προέρχονται από δισδιάστατες ή τρισδιάστατες εικόνες (απλές ακτινογραφίες, αξονικές/μαγνητικές τομογραφίες, τομογραφίες PET κ.λπ.). Εταιρείες όπως η Google αναπτύσσουν ήδη τρόπους για τον εντοπισμό πρώιμων συμπτωμάτων καρκίνου του μαστού χρησιμοποιώντας εικόνες μαστογραφίας από έναν ασθενή. Χρησιμοποιώντας την αναγνώριση εικόνας και τη βαθιά μάθηση, αυτά τα μοντέλα μπορούν να προβλέψουν με ακρίβεια εάν μια συγκεκριμένη πάθηση είναι καρκινική ή όχι. Εναλλακτικά, μπορεί να προέρχονται από μονοδιάστατα ηλεκτρικά σήματα, όπως ηλεκτροκαρδιογραφήματα (EGC) και ηλεκτροεγκεφαλογραφήματα (EEG), καθώς και από απλές βαθμωτές πληροφορίες, π.χ. αιματολογικοί δείκτες, πίεση και δημογραφικά χαρακτηριστικά (ηλικία, φύλο κ.λπ.). Η επεξεργασία βιοϊατρικών σημάτων δεν αποσκοπεί πάντα στη διάγνωση ασθενειών. Μπορεί να έχει και άλλες εφαρμογές όπως την αναγνώριση συναισθηματικής κατάστασης, την αυτόματη αλληλεπίδραση εγκεφάλου υπολογιστή (Brain computer Interaction - BCI), την παρακολούθηση της υγείας (health monitoring), την αναγνώριση κατάστασης υπνηλίας οδηγού κ.ά.

Η μηχανική μάθηση βρίσκει επίσης σημαντική εφαρμογή στη βιοπληροφορική, δηλαδή στον κλάδο της βιολογίας που ασχολείται με τη χρήση της πληροφορικής στην επίλυση βιολογικών προβλημάτων. Επιπλέον, χρησιμοποιείται και σε προβλήματα όπως η σήμανση και ανίχνευση γονιδίων σε αλυσίδες DNA (gene prediction), στην πρόβλεψη καρκίνου ή άλλων ασθενειών με βάση τη γονιδιακή έκφραση στο RNA, στη βιολογία συστημάτων όπου οι βιολογικές διαδικασίες μοντελοποιούνται ως αλληλεπιδράσεις μεταξύ συστατικών ενός συστήματος κ.ά..

6. ΑΣΦΑΛΕΙΑ Το κακόβουλο λογισμικό (malware) αποτελεί σημαντικό και ολοένα διογκούμενο πρόβλημα. Η μηχανική μάθηση μπορεί να χρησιμοποιηθεί για την αναγνώριση κακόβουλου λογισμικού, εκμεταλλευόμενη συγκεκριμένα χαρακτηριστικά σε επίπεδο κώδικα ή κάποια ιδιαίτερα μοτίβα στον τρόπο προσπέλασης των δεδομένων στο νέφος (cloud)
7. ΑΥΤΟΝΟΜΗ ΟΔΗΓΗΣΗ Η αυτόνομη οδήγηση οχημάτων είναι ένα νεοεμφανιζόμενο πεδίο εφαρμοσμένης έρευνας με σημαντικές επιπτώσεις στη βιομηχανία της αυτοκίνησης. Δεν είναι τυχαίο ότι οι μεγαλύτερες αυτοκινητοβιομηχανίες επενδύουν στην τεχνολογία των “αυτο-οδηγούμενων οχημάτων”, ελπίζοντας στην εμπορική εκμετάλλευσή τους εντός της δεκαετίας του 2020. Ίσως το πιο σημαντικό πρόβλημα που αντιμετωπίζουν οι σχεδιαστές τέτοιων οχημάτων είναι η αναγνώριση και αποφυγή οδικών εμποδίων. Αυτό συνήθως απαιτεί την επεξεργασία δεδομένων από έναν συνδυασμό αισθητήρων όπως κάμερες, ραντάρ και LIDAR. Και σε αυτή την περίπτωση, οι καλύτερες μέθοδοι ανίχνευσης εμποδίων βασίζονται σε αλγορίθμους μηχανικής μάθησης.

APPLICATIONS OF MACHINE LEARNING

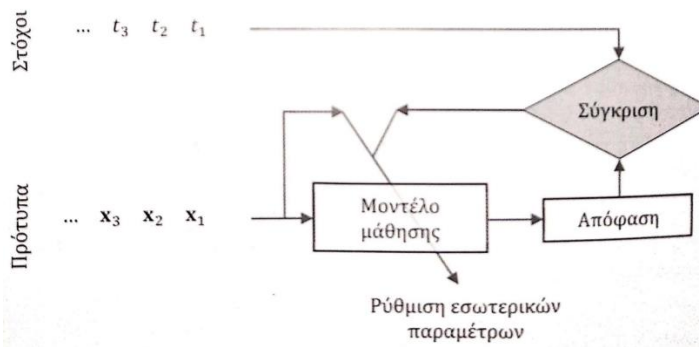


Εικόνα 3.2 Εφαρμογές Μηχανικής Μάθησης

3.7 Τύποι – Είδη Μηχανικής Μάθησης

Έχουν αναπτυχθεί πολλές τεχνικές μηχανικής μάθησης οι οποίες χρησιμοποιούνται ανάλογα με τη φύση του προβλήματος. Οι βασικοί τύποι μάθησης είναι τρεις: α) μάθηση με επίβλεψη, β) μάθηση χωρίς επίβλεψη και γ) μάθηση με ενίσχυση. Παρακάτω θα περιγράψουμε αυτούς τους τύπους αναλυτικότερα.

1. **Μάθηση με επίβλεψη** (supervised learning) .Στόχος της επιβλεπόμενης μάθησης είναι η ανακάλυψη της σχέσης ανάμεσα σε ένα γνώρισμα στόχο και σε ένα σύνολο άλλων γνωρισμάτων. Στην μάθηση με επίβλεψη το σύστημα καλείται να “μάθει” μια έννοια ή συνάρτηση από ένα σύνολο δεδομένων, η οποία αποτελεί περιγραφή ενός μοντέλου. Ονομάζεται έτσι επειδή θεωρείται ότι υπάρχει κάποιος “επιβλέπων” ο οποίος παρέχει τη σωστή τιμή εξόδου της συνάρτησης, για τα δεδομένα που εξετάζονται. Σε αυτόν τον τύπο μάθησης το μοντέλο χρησιμοποιεί μια σειρά από πρότυπα εισόδου x_1, x_2, x_3, \dots , μαζί με τους αντίστοιχους στόχους t_1, t_2, t_3, \dots . Τα πρότυπα είναι συνήθως διανύσματα σε κάποιον χώρο n διαστάσεων. Το διάνυσμα x_i περιέχει τα χαρακτηριστικά x_{i1}, \dots, x_{in} του i -οστού δείγματος το οποίο καλούμαστε να αντιστοιχίσουμε στον στόχο t_i . Το διάγραμμα του τύπου αυτού φαίνεται στο Σχήμα 3.1



Σχήμα 3.1 Το βασικό μοντέλο της μάθησης με επίβλεψη

Στη μάθηση με επίβλεψη το σύστημα πρέπει να “μάθει” επαγωγικά μια συνάρτηση , που ονομάζεται *συνάρτηση στόχος* (target function) και αποτελεί έκφραση του μοντέλου που περιγράφει τα δεδομένα. Η συνάρτηση στόχος (συνήθως συμβολίζεται με c) χρησιμοποιείται για την πρόβλεψη της τιμής μιας μεταβλητής που ονομάζεται *εξαρτημένη μεταβλητή* ή *μεταβλητή εξόδου*, βάσει των τιμών ενός συνόλου μεταβλητών, που ονομάζονται *ανεξάρτητες μεταβλητές* ή *μεταβλητές εισόδου* ή *χαρακτηριστικά* .

Το σύνολο των διαφορετικών δυνατών τιμών εισόδου της συνάρτησης, δηλαδή το πεδίο ορισμού της, ονομάζεται *σύνολο των περιπτώσεων* ή *στιγμιότυπων* (instances) και συμβολίζεται με X . Κάθε περίπτωση (ή στιγμιότυπο) περιγράφεται από ένα *σύνολο χαρακτηριστικών* (attributes or features). Ένα υποσύνολο του συνόλου των περιπτώσεων για τα οποία γνωρίζουμε την τιμή της μεταβλητής εξόδου, ονομάζεται *σύνολο δεδομένων εκπαίδευσης* ή *παραδείγματα* και συμβολίζεται με D .

Για να προσεγγίσει το σύστημα όσο το δυνατόν καλύτερα τη συνάρτηση στόχο εξετάζει διάφορες εναλλακτικές συναρτήσεις οι οποίες ονομάζονται *υποθέσεις* και συμβολίζονται με h . Το σύνολο όλων των δυνατών υποθέσεων που το πρόγραμμα μάθησης πρέπει να εξετάσει προκειμένου να βρει τη συνάρτηση στόχο ονομάζεται *σύνολο υποθέσεων* και συμβολίζεται με H . Κάθε υπόθεση $h \in H$, αναπαριστά είτε μια λογική συνάρτηση $h: X \rightarrow \{0, 1\}$ ή μια πραγματική συνάρτηση $h: X \rightarrow R$.

Η επαγωγική μάθηση στηρίζεται στην υπόθεση επαγωγικής μάθησης (inductive learning hypothesis), σύμφωνα με την οποία κάθε υπόθεση h που έχει βρεθεί να προσεγγίζει καλά τη συνάρτηση στόχο για ένα αρκετά μεγάλο σύνολο παραδειγμάτων, θα προσεγγίσει το ίδιο καλά τη συνάρτηση στόχο και για περιπτώσεις που δεν έχει εξετάσει.

Τα προβλήματα μάθησης με επίβλεψη είναι ίσως τα συνηθέστερα προβλήματα μηχανικής μάθησης. Χωρίζονται σε δύο μεγάλες κατηγορίες :

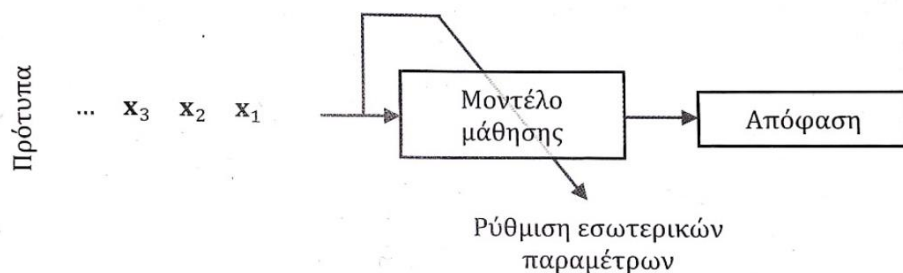
- **Προβλήματα ταξινόμησης** (classification problems) : Η ταξινόμηση (classification) αφορά στη δημιουργία μοντέλων πρόβλεψης διακριτών τάξεων (κλάσεων/κατηγοριών) όπως για παράδειγμα η ομάδα αίματος. Πιο συγκεκριμένα, σε αυτά τα προβλήματα οι στόχοι είναι διακριτές τιμές, πχ $t_i \in \{0, 1\}$, $t_i \in \{0, 1, 2, \dots, C\}$, κτλ. Οι στόχοι αντιστοιχούν σε κλάσεις αντικειμένων. Για παράδειγμα, αν το πρόβλημα είναι η ταξινόμηση ζώων σε δύο κλάσεις - άλογα ή πρόβατα- , θα μπορούσαμε να θέσουμε ως στόχο το $t_i = 0$ αν το πρότυπο x_i αντιστοιχεί σε άλογο, ή το $t_i = 1$ αν το πρότυπο αντιστοιχεί σε πρόβατο.
- **Προβλήματα παλινδρόμησης ή παρεμβολής** (regression problems) : Η παρεμβολή αφορά στη δημιουργία μοντέλων πρόβλεψης αριθμητικών τιμών. Σε αυτά τα προβλήματα οι στόχοι είναι συνεχείς ή απεριόριστο πλήθος διακριτών τιμών, πχ $t_i \in R$. Οι στόχοι αντιστοιχούν σε τιμές ή αξίες κάποιων

ποσοτήτων. Για παράδειγμα, αν το πρόβλημα είναι η εκτίμηση των κατοικιών στη Βοστώνη, οι στόχοι θα είναι πραγματικές θετικές τιμές. Στόχος της παλινδρόμησης είναι η πρόβλεψη μιας εξαρτημένης μεταβλητής, η οποία περιέχει συνεχόμενες (αριθμητικές) τιμές . [2]

Οι κυριότερες τεχνικές μηχανικής μάθησης με επίβλεψη είναι :

- Μάθηση εννοιών (Concept Learning)
- Δένδρα ταξινόμησης ή απόφασης (Classification or Decision Trees)
- Μάθηση Κανόνων (Rule Learning)
- Μάθηση κατά Περίπτωση (Instance Based Learning)
- Μάθηση κατά Bayes
- Γραμμική παρεμβολή (Linear Regression)
- Νευρωνικά Δίκτυα (Neural networks)
- Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVMs)

2. **Μάθηση χωρίς επίβλεψη** (unsupervised learning). Αντίθετα, κατά τη χρήση τεχνικών Μη Επιβλεπόμενης Μάθησης στόχος είναι η ανακάλυψη πιθανής δομής που μπορεί να κρύβεται πίσω από μη χαρακτηρισμένα δεδομένα (unlabeled data). Δηλαδή δε γνωρίζουμε εκ των προτέρων πόσες και ποιες είναι οι κατηγορίες που θέλουμε να χωρίσουμε τα δεδομένα που διαθέτουμε και είναι αρμοδιότητα του μηχανισμού να προσδιορίσει τις επιμέρους κατηγορίες, στις οποίες μπορούν να χωριστούν τα δεδομένα, βάσει των διαφορετικών χαρακτηριστικών που διαθέτουν. Εφόσον τα παραδείγματα τα οποία χρησιμοποιούνται δεν είναι χαρακτηρισμένα, δεν υπάρχει σφάλμα ή σήμα ανταμοιβής για να αξιολογηθούν οι πιθανές λύσεις. Σαν αποτέλεσμα προκύπτουν πρότυπα (περιγραφές), κάθε ένα από τα οποία περιγράφει ένα μέρος από τα δεδομένα. Παραδείγματα προτύπων πληροφόρησης είναι οι *κανόνες συσχέτισης* (association rules) και οι *ομάδες* (clusters), οι οποίες προκύπτουν από τη διαδικασία της *ομαδοποίησης* (clustering). Στη διαδικασία μάθησης αυτού του τύπου το μοντέλο χρησιμοποιεί τα πρότυπα εισόδου x_1, x_2, x_3, \dots , χωρίς όμως να διαθέτει, όπως είπαμε και παραπάνω, πληροφορίες σχετικά με τους στόχους. Το διάγραμμα αυτού του τύπου μάθησης φαίνεται στο Σχήμα 3.2 .



Σχήμα 3.2 Το βασικό μοντέλο μάθησης χωρίς επίβλεψη.

3. **Μάθηση με ενίσχυση** Ενισχυτική Μάθηση (Reinforcement Learning), όπου ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών μέσω μιας άμεσης αλληλεπίδρασης με το περιβάλλον. Εφαρμόζεται στον έλεγχο κίνησης ρομπότ, στη βελτιστοποίηση εργασιών σε εργοστάσια, στη μάθηση επιτραπέζιων παιχνιδιών, κτλ. Η έννοια της ενισχυτικής μάθησης είναι εμπνευσμένη από τα αντίστοιχα ανάλογα της μάθησης με επιβράβευση και τιμωρία που συναντώνται ως μοντέλα μάθησης των έμβιων όντων. Σκοπός του συστήματος μάθησης είναι να μεγιστοποιήσει μια συνάρτηση του αριθμητικού σήματος *ενίσχυσης* (ανταμοιβή), για παράδειγμα την αναμενόμενη τιμή του σήματος ενίσχυσης στο επόμενο βήμα. Το σύστημα

δεν καθοδηγείται από κάποιον εξωτερικό επιβλέποντα για το ποια ενέργεια θα πρέπει να ακολουθήσει, αλλά πρέπει να ανακαλύψει μόνο του ποιες ενέργειες είναι αυτές που θα του αποφέρουν το μεγαλύτερο κέρδος.

Η ενισχυτική μάθηση διαφέρει από τη μάθηση με επίβλεψη, η οποία πραγματοποιείται με παραδείγματα για τα οποία για κάθε είσοδο είναι γνωστή η επιθυμητή έξοδος. Αυτό το είδος μάθησης είναι πολύ σημαντικό αλλά από μόνο του δεν επαρκεί για μάθηση με αλληλεπίδραση. Σε διαδραστικά προβλήματα πολλές φορές είναι δύσκολο να εξαχθούν παραδείγματα επιθυμητής συμπεριφοράς τα οποία να είναι σωστά και να αναπαριστούν όλες τις καταστάσεις στις οποίες το σύστημα μάθησης θα πρέπει να δράσει. Σε τέτοια προβλήματα το σύστημα θα πρέπει να μαθαίνει από τη δική του εμπειρία, κάτι το οποίο γίνεται στην ενισχυτική μάθηση.

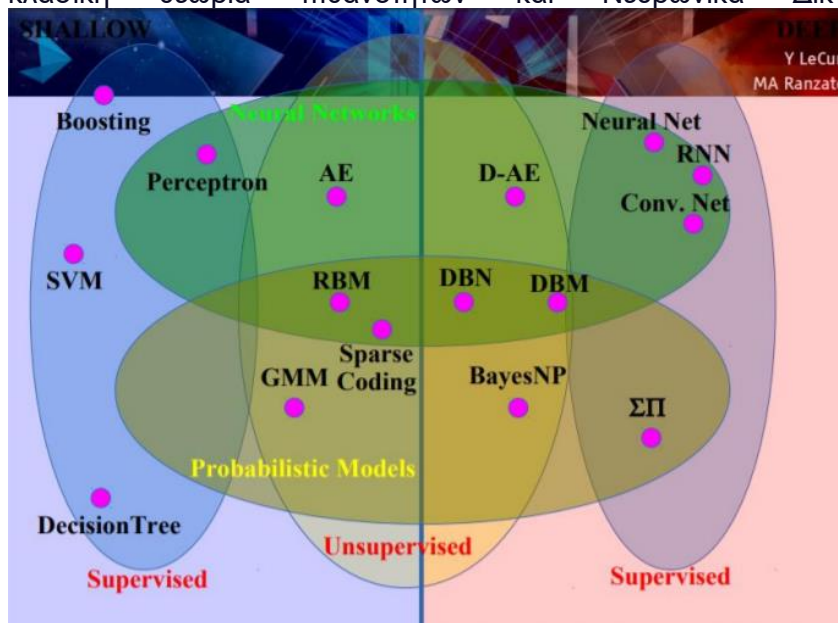
Τις δύο τελευταίες δεκαετίες, η ενισχυτική μάθηση μελετήθηκε εκτεταμένα στην ΤΝ, όπου η έμφαση δόθηκε στο πώς το σύστημα μάθησης μπορεί να βελτιώσει την απόδοσή του σε μια δεδομένη εργασία μέσω της δοκιμής και αποτυχίας (*trial-and-error*)

Ένας άλλος βασικός διαχωρισμός των τεχνικών μηχανικής μάθησης είναι α) Ρηχή Μάθηση (Shallow Learning) και β) Βαθιά Μάθηση (Deep Learning).

Ρηχή Μάθηση (Shallow Learning): Οι Ρηχές τεχνικές Μάθησης βασίζονται, για την εξαγωγή αποτελεσμάτων και προβλέψεων, κυρίως στα χαρακτηριστικά που δίνονται στο σύστημα μέσω των δεδομένων εισόδου.

Βαθιά Μάθηση (Deep Learning): Αντίθετα οι Βαθείς τεχνικές Μάθησης προσπαθούν από τα δεδομένα εισόδου να εξαγάγουν καλύτερες αναπαραστάσεις αυτών, με καινούρια, πιο σύνθετα και συνδυαστικά χαρακτηριστικά. Ο κατασκευαστής του συστήματος εδώ, δεν καλείται υποχρεωτικά να έχει κάποια ιδιαίτερη και βαθύτερη γνώση για τα δεδομένα εισόδου. Το ίδιο το σύστημα έχει τη δυνατότητα να εξαγάγει τέτοια γνώση (Feature Engineering) για το σκοπό που θέλει να επιτύχει

Τέλος μια ομαδοποίηση κάποιων τεχνικών Μηχανικής Μάθησης μπορεί να γίνει βάσει του κατασκευάσματος και των μαθηματικών μεθόδων που χρησιμοποιεί η τεχνική. Οπότε κάνουμε λόγο για τεχνικές που χρησιμοποιούν Πιθανοτικά Μοντέλα (Probabilistic Models) από την κλασική θεωρία πιθανοτήτων και Νευρωνικά Δίκτυα (Neural Networks).



Εικόνα 3.3 Κατηγορίες μάθησης

Στην εργασία αυτή, όπως θα δούμε και σε επόμενες ενότητες, θα ασχοληθούμε με την μάθηση υπό επίβλεψη, καθώς η ταξινόμηση ανήκει στην κατηγορία αυτή.

ΚΕΦΑΛΑΙΟ 4 Ταξινόμηση

4.1 Τι είναι η Ταξινόμηση

Η ταξινόμηση είναι μια από τις πιο συχνά συναντώμενες εργασίες λήψης αποφάσεων της ανθρώπινης δραστηριότητας. Για παράδειγμα, όταν θέλουμε να αποφασίσουμε ποιο φαγητό θα διαλέξουμε σε ένα εστιατόριο ταξινομούμε στο μυαλό μας με βάση την όρεξη μας τις πιθανές επιλογές πιάτων σε ομάδες - κλάσεις (classes). Στη συνέχεια διακρίνουμε το καταλληλότερο πιάτο σκεπτόμενοι διάφορους παράγοντες, όπως τον χρόνο παρασκευής, το κόστος, τις θερμίδες κ.α. Η ταξινόμηση, δηλαδή, εξετάζει τα χαρακτηριστικά ενός νέου αντικειμένου (στο παράδειγμα μας τα χαρακτηριστικά των φαγητών) και με βάση αυτά το κατατάσσει σε ένα προκαθορισμένο σύνολο κλάσεων.

Με άλλα λόγια, ένα πρόβλημα ταξινόμησης εμφανίζεται όταν ένα αντικείμενο πρέπει να εκχωρηθεί σε μια προκαθορισμένη ομάδα ή κλάση με βάση έναν αριθμό παρατηρούμενων χαρακτηριστικών που σχετίζονται με αυτό το αντικείμενο. Πολλά προβλήματα στις επιχειρήσεις, την επιστήμη, τη βιομηχανία και την ιατρική μπορούν να αντιμετωπιστούν ως προβλήματα ταξινόμησης. Παραδείγματα περιλαμβάνουν πρόβλεψη πτώχευσης, πιστωτική βαθμολογία, ιατρική διάγνωση, ποιοτικό έλεγχο, χειρόγραφο αναγνώριση χαρακτήρων και αναγνώριση λόγου.

Πριν προχωρήσουμε στην εκτενέστερη επεξήγηση της ταξινόμησης, ας ρίξουμε άλλη μια ματιά στο τι είναι η εποπτευόμενη μάθηση παραθέτοντας δύο απλά παραδείγματα. Ας υποθέσουμε ότι προσπαθείτε να μάθετε μια νέα έννοια στα μαθηματικά και αφού λύσετε ένα πρόβλημα, μπορείτε να ανατρέξετε στις λύσεις για να δείτε αν είχατε δίκιο ή όχι. Μόλις είστε σίγουροι για την ικανότητά σας να λύσετε ένα συγκεκριμένο είδος προβλήματος, θα σταματήσετε να αναφέρεστε στις απαντήσεις και θα λύσετε τις ερωτήσεις που έχετε θέσει μόνοι σας.

Η επιβλεπόμενη ή αλλιώς εποπτευόμενη μάθηση είναι η εκπαίδευση ενός μοντέλου μηχανικής μάθησης χρησιμοποιώντας δεδομένα με ετικέτα. Αυτό σημαίνει ότι έχουμε δεδομένα που έχουν ήδη τη σωστή ταξινόμηση που σχετίζονται με αυτά. Μια κοινή χρήση της εποπτευόμενης μάθησης είναι η πρόβλεψη τιμών για νέα δεδομένα.

Με την εποπτευόμενη μάθηση, θα χρειαστεί να ξαναχτίσουμε τα μοντέλα μας καθώς η διαδικασία περιλαμβάνει λήψη νέων δεδομένων για να βεβαιωθούμε ότι οι προβλέψεις που επιστρέφονται είναι ακόμα ακριβείς. Ένα παράδειγμα εποπτευόμενης μάθησης θα ήταν η παράθεση ετικετών σε εικόνες τροφίμων. Θα μπορούσαμε να έχουμε ένα σύνολο δεδομένων αφιερωμένο μόνο σε εικόνες πίτσας για να μάθουμε στο μοντέλο μας τι είναι πίτσα.

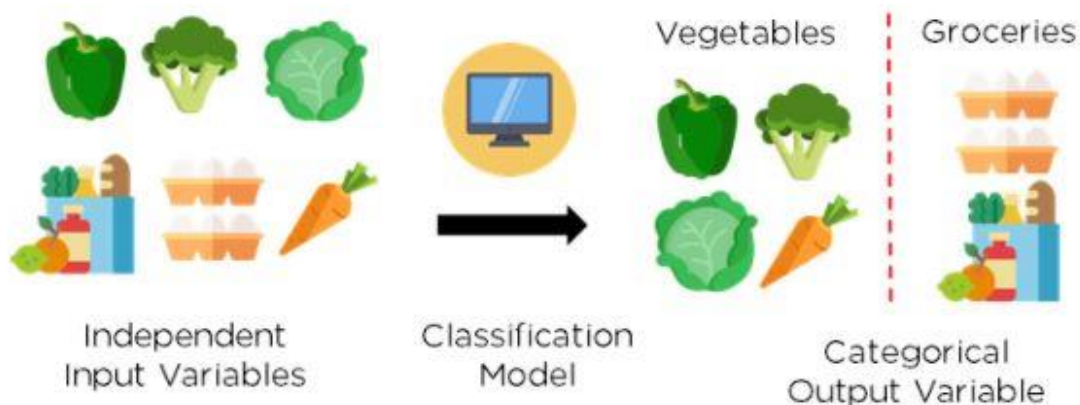
Στην τεχνητή νοημοσύνη και τη μηχανική μάθηση λοιπόν, η ταξινόμηση αναφέρεται στην ικανότητα του μηχανήματος να εκχωρεί τις περιπτώσεις στις σωστές ομάδες τους. Ορίζεται ως η διαδικασία αναγνώρισης, κατανόησης και ομαδοποίησης αντικειμένων και ιδεών σε προκαθορισμένες κατηγορίες, οι οποίες είναι γνωστές και ως «υποπληθυσμοί». Με τη βοήθεια αυτών των προ κατηγοριοποιημένων συνόλων δεδομένων εκπαίδευσης, η ταξινόμηση σε προγράμματα μηχανικής μάθησης αξιοποιεί ένα ευρύ φάσμα αλγορίθμων για την ταξινόμηση των μελλοντικών συνόλων δεδομένων σε αντίστοιχες και σχετικές κατηγορίες. Η ταξινόμηση επομένως είναι μια συστηματική ομαδοποίηση των παρατηρήσεων σε κατηγορίες, όπως όταν οι βιολόγοι κατηγοριοποιούν φυτά, ζώα και άλλες μορφές ζωής σε διαφορετικές ταξινομίες. Είναι μια από τις κύριες χρήσεις της επιστήμης δεδομένων και της μηχανικής μάθησης. Για παράδειγμα, στην όραση υπολογιστή, το μηχάνημα μπορεί να αποφασίσει εάν μια εικόνα περιέχει γάτα ή σκύλο ή αν μια εικόνα περιέχει ανθρώπινο σώμα ή όχι. Στην Επεξεργασία Φυσικής Γλώσσας (NLP), το μηχάνημα μπορεί να προσδιορίσει αν το συναίσθημα ενός δεδομένου κειμένου είναι θετικό, αρνητικό ή ουδέτερο.

Για να μπορέσει το μηχάνημα να αποφασίσει πώς να αναθέσει ένα παράδειγμα στην ομάδα του, πρέπει να μάθει τα πρότυπα αυτής της εργασίας από τις δυνατότητες εκπαίδευσης που είναι διαθέσιμες σε ένα σύνολο δεδομένων εκπαίδευσης με ετικέτα.

Προκειμένου να καθοριστεί η σωστή κατηγορία για μια δεδομένη παρατήρηση, η τεχνολογία μηχανικής μάθησης κάνει τα εξής:

1. Εφαρμόζει έναν αλγόριθμο ταξινόμησης για τον εντοπισμό κοινών χαρακτηριστικών ορισμένων κλάσεων.
2. Συγκρίνει αυτά τα χαρακτηριστικά με τα δεδομένα που προσπαθείτε να ταξινομήσετε.
3. Χρησιμοποιεί αυτές τις πληροφορίες για να εκτιμήσει πόσο πιθανό είναι η παρατήρηση να ανήκει σε μια συγκεκριμένη κατηγορία.

Εν ολίγοις, η ταξινόμηση είναι μια μορφή «αναγνώρισης προτύπων». Εδώ, οι αλγόριθμοι ταξινόμησης που εφαρμόζονται στα δεδομένα εκπαίδευσης βρίσκουν το ίδιο μοτίβο (παρόμοιες ακολουθίες αριθμών, λέξεις ή συναισθήματα και παρόμοια) σε μελλοντικά σύνολα δεδομένων.



Εικόνα 4.1 Ταξινόμηση λαχανικών και ειδών παντοπωλείου

Οι κυριότερες τεχνικές μηχανικής μάθησης με επίβλεψη είναι :

- Μάθηση εννοιών (Concept Learning)
- Δένδρα ταξινόμησης ή απόφασης (Classification or Decision Trees)
- Μάθηση Κανόνων (Rule Learning)
- Μάθηση κατά Περίπτωση (Instance Based Learning)
- Μάθηση κατά Bayes
- Γραμμική παρεμβολή (Linear Regression)
- Νευρωνικά Δίκτυα (Neural networks)
- Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVMs)

Ενότητα 4.1.α Τι είναι ένας αλγόριθμος

Όταν γίνεται αναφορά σε αλγόριθμους μηχανικής μάθησης, αρκεί να θυμόμαστε ότι αφορούν διαφορετικές μαθηματικές εξισώσεις.

Ένας αλγόριθμος είναι απλώς μια προσαρμόσιμη μαθηματική συνάρτηση. Αυτός είναι ο λόγος για τον οποίο οι περισσότεροι αλγόριθμοι περιέχουν πράγματα όπως συναρτήσεις κόστους, τιμές βάρους και συναρτήσεις παραμέτρων που μπορούμε να ανταλλάξουμε με βάση τα δεδομένα με τα οποία εργαζόμαστε.

Αυτός είναι ο λόγος για τον οποίο υπάρχουν τόσοι πολλοί διαφορετικοί αλγόριθμοι για τον χειρισμό διαφορετικών ειδών δεδομένων. Τρεις συγκεκριμένοι είναι τα "SVM, ΝΕΥΡΩΝΙΚΑ

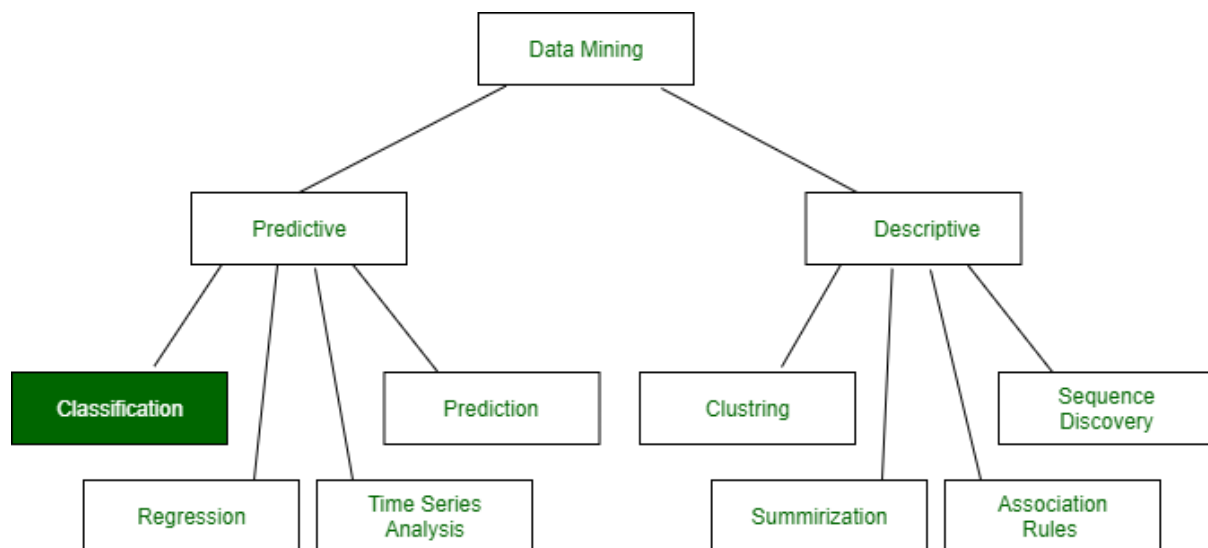
ΔΙΚΤΥΑ ΚΑΙ ΒΑΘΙΑ ΜΑΘΗΣΗ/ΒΑΘΙΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ", θέματα τα οποία θα καλύψει λεπτομερώς αυτή η εργασία.

4.2 Ταξινόμηση και Εξόρυξη Δεδομένων

Εξόρυξη δεδομένων: Η εξόρυξη δεδομένων σε γενικές γραμμές σημαίνει εξόρυξη ή εμβάθυνση σε δεδομένα, τα οποία είναι σε διαφορετικές μορφές, για την απόκτηση προτύπων και την απόκτηση γνώσης για αυτό το μοτίβο. Κατά τη διαδικασία της εξόρυξης δεδομένων, πρώτα ταξινομούνται μεγάλα σύνολα δεδομένων, στη συνέχεια προσδιορίζονται μοτίβα και δημιουργούνται σχέσεις για την ανάλυση δεδομένων και την επίλυση προβλημάτων. [63]

Οι βάσεις δεδομένων είναι πλούσιες σε κρυφές πληροφορίες, οι οποίες μπορούν να χρησιμοποιηθούν για έξυπνη λήψη αποφάσεων. Η ταξινόμηση και η πρόβλεψη είναι δύο μορφές ανάλυσης δεδομένων που μπορούν να χρησιμοποιηθούν για την εξαγωγή μοντέλων που περιγράφουν σημαντικές κατηγορίες δεδομένων ή για την πρόβλεψη μελλοντικών τάσεων δεδομένων.

Η ταξινόμηση είναι μια τεχνική εξόρυξης δεδομένων (μηχανική μάθηση) που χρησιμοποιείται για την πρόβλεψη της ιδιότητας μέλους ομάδας για περιπτώσεις δεδομένων. Η μηχανική μάθηση, όπως είδαμε παραπάνω, αναφέρεται σε ένα σύστημα που έχει την ικανότητα να μαθαίνει αυτόματα τη γνώση από την εμπειρία και άλλους τρόπους. Η ταξινόμηση προβλέπει κατηγορικές ετικέτες ενώ η πρόβλεψη μοντελοποιεί συνεχείς αξίες συναρτήσεων. Η ταξινόμηση (classification) ασχολείται με τη γενίκευση της γνωστής δομής για εφαρμογή σε νέα δεδομένα, ενώ η ομαδοποίηση (clustering) χρησιμοποιείται για την ανακάλυψη ομάδων και δομών στα δεδομένα που είναι κατά κάποιο τρόπο παρόμοια, χωρίς τη χρήση γνωστών δομών στα δεδομένα.



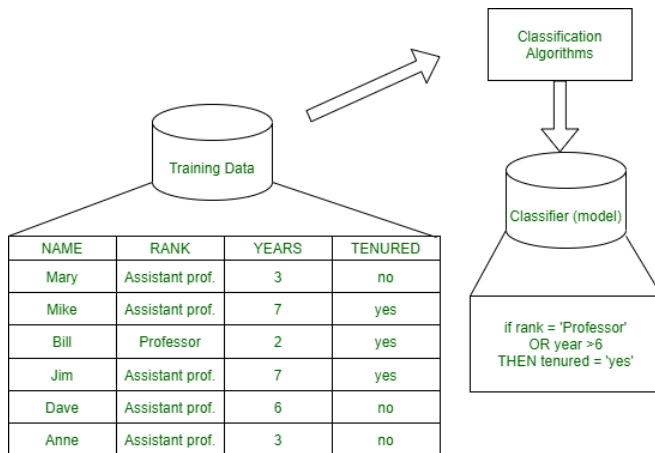
Εικόνα 4.2 Εξόρυξη δεδομένων

4.3 Πώς λειτουργεί η Ταξινόμηση;

Πριν ξεκινήσουμε οποιοδήποτε project, πρέπει να ελέγξουμε τη σκοπιμότητά του. Σε αυτήν την περίπτωση, απαιτείται ένας ταξινομητής για την πρόβλεψη ετικετών κλάσεων όπως για παράδειγμα «Ασφαλής» και «Επικίνδυνη», για την υιοθέτηση του project και για περαιτέρω έγκρισή του. Είναι μια διαδικασία δύο σταδίων:

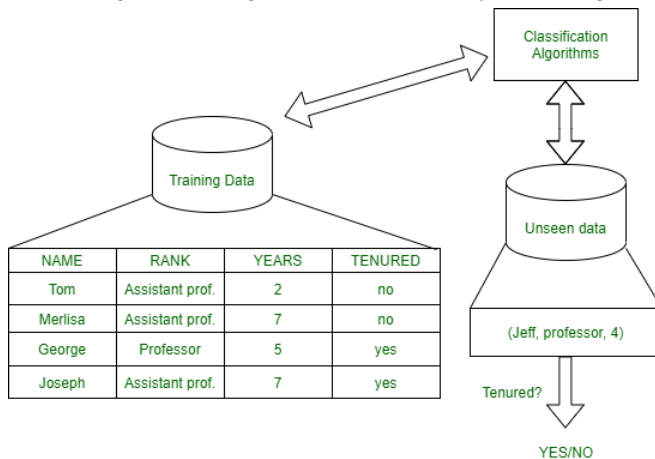
1. **Βήμα μάθησης (Φάση εκπαίδευσης):** Κατασκευή μοντέλου ταξινόμησης. Διαφορετικοί αλγόριθμοι χρησιμοποιούνται για τη δημιουργία ενός ταξινομητή

κάνοντας το μοντέλο να μάθει χρησιμοποιώντας το διαθέσιμο σύνολο εκπαίδευσης. Το μοντέλο πρέπει να εκπαιδευτεί για την πρόβλεψη ακριβών αποτελεσμάτων.



Εικόνα 4.3 Τα δεδομένα δοκιμής (test data) χρησιμοποιούνται για την εκτίμηση της ακρίβειας του κανόνα ταξινόμησης

2. **Βήμα ταξινόμησης:** Μοντέλο που χρησιμοποιείται για την πρόβλεψη ετικετών κλάσεων και τη δοκιμή του κατασκευασμένου μοντέλου σε δεδομένα δοκιμής και ως εκ τούτου την εκτίμηση της ακρίβειας των κανόνων ταξινόμησης



Εικόνα 4.4 Τα δεδομένα δοκιμής χρησιμοποιούνται για την εκτίμηση της ακρίβειας του κανόνα ταξινόμησης

4.4 Εκπαίδευση και Δοκιμές


Ας υποθέσουμε ότι υπάρχει ένα άτομο που κρέμεται κάτω από έναν ανεμιστήρα και ότι ο ανεμιστήρας πάει να πέσει πάνω του. Τότε θα πρέπει να παραμεριστεί για να μην τον χτυπήσει. Έτσι, αυτό είναι το κομμάτι της εκπαίδευσής του για να απομακρυνθεί. Κατά τη διάρκεια της δοκιμής εάν το άτομο δει οποιοδήποτε βαρύ αντικείμενο να έρχεται προς το μέρος του ή να πέφτει πάνω του και παραμεριστεί, τότε το σύστημα ελέγχεται θετικά ενώ εάν το άτομο δεν μετακινηθεί στην άκρη, το σύστημα ελέγχεται αρνητικά.

Το ίδιο συμβαίνει και με τα δεδομένα, τα οποία θα πρέπει να εκπαιδευτούν για να προκύψουν τα ακριβή και καλύτερα αποτελέσματα.

4.5 Η πολυπλοκότητα ως Διαχωριστικό

Η ιδέα πίσω από την ταξινόμηση στη μηχανική μάθηση είναι ότι ο κόσμος, ή μάλλον ένας διανυσματικός χώρος, μπορεί να χωριστεί σε περιοχές που διαθέτουν διαφορετικά αναγνωρίσιμα χαρακτηριστικά. Με αυτόν τον τρόπο, υποθέτουμε ότι ο κόσμος έχει μια πολυπλοκότητα που αντιστοιχεί σε ξεχωριστές υποομάδες αυτού του κόσμου, που δεν επικαλύπτονται μεταξύ τους. Ο κόσμος μπορεί λοιπόν να χωριστεί σε ξεχωριστές περιοχές, που περιλαμβάνουν ξεχωριστές κατηγορίες πραγμάτων, καθένα από τα οποία έχει τα δικά του στοιχεία:


The Universe



Σχήμα 4.1 Κόσμος - 1ος διαχωρισμός

Στη συνέχεια θα μπορούσαμε να αναρωτηθούμε πώς μπορούμε να περιγράψουμε αυτόν τον κόσμο ως προς τις κατηγορίες του και να βρούμε μια ολοκληρωμένη επίσημη περιγραφή που δεν αφήνει καμία περιοχή ανέγγιχτη. Με άλλα λόγια, θα μπορούσαμε να αναρωτηθούμε πώς θα μπορούσαμε να δημιουργήσουμε έναν χάρτη που θα μας επιτρέψει να εντοπίσουμε την ταξική σχέση όλων των σημείων ή παρατηρήσεων που περιέχονται σε αυτόν τον κόσμο. Μας ενδιαφέρει, φυσικά, η πιο απλή συμπερίληψη που λειτουργεί για όλα τα σημεία ή όσο το δυνατόν περισσότερα.

Ένας τρόπος για να γίνει αυτό είναι η δημιουργία ενός άπειρου συνόλου, λίστας ή λεξικού, που περιλαμβάνει όλα τα υπάρχοντα σημεία σε αυτόν τον κόσμο και τη σχετική ταξινόμησή τους. Αυτό γίνεται με τη δειγματοληψία όλου του κόσμου, σημείο προς σημείο και στη συνέχεια τη σύνθεση μιας περιγραφής που αποτελείται από τις τάξεις ή τις κατηγορίες που παρατηρούμε σε κάθε τοποθεσία:




Σχήμα 4.2 Κόσμος - δειγματοληψία όλου του κόσμου, σημείο προς σημείο

Αν το κάναμε αυτό, θα μπορούσαμε να καταλήξουμε σε έναν χάρτη που αποτελείται από τη λίστα κατηγοριών ή τάξεων που παρατηρούμε σε κάθε μεμονωμένο σημείο.

Αν φανταστούμε τώρα τη δειγματοληψία του κόσμου σε μια αυθαίρετη ανάλυση, θα δημιουργήσουμε έναν χάρτη που θα περιέχει όλα τα σημεία αυτού του κόσμου, ή όσα θέλουμε, και τις τάξεις που σχετίζονται με αυτά.

Αυτή η προσέγγιση είναι απολύτως θεμιτή αλλά απίθανο να πραγματοποιηθεί στην πράξη. Ο πρώτος λόγος είναι ότι απαιτεί τη δυνατότητα δειγματοληψίας του χώρου χαρακτηριστικών σε αυθαίρετα υψηλή ανάλυση. Ο δεύτερος λόγος είναι ότι ο χάρτης απαιτεί τόσες πληροφορίες όσο όλος ο κόσμος που περιγράφει, καθιστώντας περιττή τη χρήση του χάρτη και όχι τον κόσμο στον οποίο δείχνει.

Θα μπορούσαμε, ωστόσο, να χρησιμοποιήσουμε μια διαφορετική προσέγγιση βασισμένη στην προηγούμενη γνώση ότι οι περιοχές στις οποίες χωρίζεται ο κόσμος μας δεν αλληλοκαλύπτονται:




Σχήμα 4.3 Κόσμος - 3ος διαχωρισμός

Αυτή η προσέγγιση προτείνει τη χρήση ενός υποσύνολου κάθε περιοχής για τον ορισμό της ίδιας περιοχής. Θα μπορούσαμε, στην πραγματικότητα, να προσδιορίσουμε ρητά μόνο μια υποπεριοχή S κάθε περιοχής R , έτσι ώστε η υποπεριοχή συν το συμπλήρωμά της να αντιστοιχεί σε εκείνη την περιοχή: $S + (R \setminus S) = R$.

Θα μπορούσαμε στη συνέχεια να απαριθμήσουμε ρητά μόνο τα σημεία που περιέχονται στην υποπεριοχή S , όπως έγινε πριν, και να θεωρήσουμε ότι όλα τα άλλα σημεία σε οποιοδήποτε υποσύνολο συμπληρώματος $R \setminus S$ ανήκουν στην ίδια κλάση με την κλάση οποιωνδήποτε στοιχείων στην πλησιέστερη υποπεριοχή S . Αυτό σημαίνει ότι θα κάνουμε δειγματοληψία μόνο σε ένα μικρό υποσύνολο κάθε περιοχής, και συγκεκριμένα σε εκείνα τα υποσύνολα που συνορεύουν με ανάλογες υποομάδες άλλων περιοχών.


Αυτή η μέθοδος σύνοψης/συμπερίληψης είναι λιγότερο περίπλοκη από την προηγούμενη. Αυτό συμβαίνει επειδή απαριθμούμε ρητά μόνο μερικά από τα σημεία και τις αντίστοιχες τάξεις τους, όχι ολόκληρη την περιοχή. Επεκτείνουμε τις υπόλοιπες ενότητες κατηγορίας βάσει μιας διαδικασίας, απαιτώντας έτσι λιγότερο σαφείς πληροφορίες.

Θα μπορούσαμε, ωστόσο, να κάνουμε ακόμα καλύτερη δουλειά συνοψίζοντας την πολυπλοκότητα αυτού του κόσμου. Το μόνο που χρειάζεται να κάνουμε είναι να σκεφτούμε ότι δεν χρειαζόμαστε πραγματικά μια ολόκληρη υποπεριοχή για να εξατομικεύσουμε το όριο μεταξύ των τάξεων, αλλά μόνο μερικά σημεία. Συγκεκριμένα, αυτά που βρίσκονται πλησιέστερα στο όριο μεταξύ περιφερειών:



Σχήμα 4.4 Κόσμος - 4ος διαχωρισμός

Τώρα, η εγγύτητα των σημείων αυτών μεταξύ τους θα εξαρτηθεί από την ανάλυση της δειγματοληψίας μας. Μια υψηλότερη ανάλυση θα αντιστοιχούσε, εδώ, σε σημεία πιο κοντά το ένα στο άλλο, και στα όρια εντός των περιοχών, και αντίστροφα. Αλλά ανεξάρτητα από την ανάλυση, εφόσον έχουμε τουλάχιστον ένα σημείο σε κάθε περιοχή, μπορούμε πάντα να φανταστούμε ότι τα όρια βρίσκονται κάπου μεταξύ των πλησιέστερων σημείων που ανήκουν σε διαφορετικές κατηγορίες:



Σχήμα 4.5 Κόσμος - 5ος διαχωρισμός

Η ακρίβεια των ορίων που προσδιορίζουμε έναντι της πραγματικής πολυπλοκότητας του κόσμου μπορεί να αλλάξει πολύ, σύμφωνα με την ανάλυση της δειγματοληψίας μας. Αλλά σε κάθε περίπτωση, μπορεί να προσδιοριστεί ένα όριο, το οποίο θα είναι σωστό σε ορισμένα τουλάχιστον μέρη του χώρου. [39]

4.6 Τύποι Ταξινόμησης

Ο στόχος της ταξινόμησης όπως αναφέραμε παραπάνω, είναι να καθοριστεί σε ποια κατηγορία ανήκει μια παρατήρηση, πράγμα που γίνεται με την κατανόηση της σχέσης μεταξύ της εξαρτημένης μεταβλητής και των ανεξάρτητων μεταβλητών. Ανάλογα με τη φύση της εξαρτημένης μεταβλητής, μπορούν να γίνουν κατανοητές διαφορετικές τεχνικές ταξινόμησης μηχανικής μάθησης. Από τις διάφορες τεχνικές ταξινόμησης, οι πιο συνηθισμένες είναι οι ακόλουθες:

Υπάρχουν τρεις τύποι ταξινόμησης :

- **Διαδική ταξινόμηση (Binary Classification):** Όταν πρέπει να ταξινομήσουμε υπάρχοντα δεδομένα σε δύο διαφορετικές κατηγορίες. Σε αυτόν τον τύπο, η μηχανή θα πρέπει να ταξινομήσει μια παρατήρηση ως μία μόνο από τις δύο κατηγορίες: ναι/όχι, 1/0, ή true/false. Για παράδειγμα, με βάση τις συγκεκριμένες συνθήκες υγείας ενός ατόμου, πρέπει να καθορίσουμε εάν το άτομο έχει κάποια ασθένεια ή όχι.

Έχουμε ένα σύνολο παρατηρήσεων που ονομάζεται σύνολο δεδομένων εκπαίδευσης, το οποίο περιλαμβάνει δείγματα δεδομένων με πραγματικά αποτελέσματα ταξινόμησης. Εκπαιδεύουμε ένα μοντέλο, που ονομάζεται Classifier σε αυτό το σύνολο δεδομένων, και χρησιμοποιούμε αυτό το μοντέλο για να προβλέψουμε εάν ένας συγκεκριμένος ασθενής θα έχει τη νόσο ή όχι.

Το αποτέλεσμα λοιπόν εξαρτάται πλέον από:

- a. Πόσο καλά μπορούν αυτά τα χαρακτηριστικά να «χαρτογραφηθούν» στο αποτέλεσμα
- b. Την ποιότητα του συνόλου δεδομένων μας (η ποιότητα, αφορά στατιστικές και μαθηματικές ιδιότητες).
- c. Πόσο καλά ο ταξινομητής μας γενικεύει αυτή τη σχέση μεταξύ των χαρακτηριστικών και του αποτελέσματος.
- d. Οι τιμές των x_1 και x_2 (Σχήμα 4.6)


Αποτελεί την πιο βασική και πιο συχνά χρησιμοποιούμενη μορφή ταξινόμησης. Εδώ, η εξαρτημένη μεταβλητή περιλαμβάνει δύο αποκλειστικές κατηγορίες που

συμβολίζονται με 1 και 0, εξ ου και ο όρος Δυαδική Ταξινόμηση. Συχνά 1 σημαίνει Σωστό και 0 σημαίνει Λάθος. Για παράδειγμα, εάν το επιχειρηματικό πρόβλημα είναι αν το μέλος της τράπεζας μπόρεσε να εξοφλήσει το δάνειο και έχουμε ένα χαρακτηριστικό/μεταβλητή που λέει "Loaf Defaulter", τότε η απάντηση θα είναι είτε 1 (που θα σήμαινε True, δηλαδή, αθέτηση δανείου) ή 0 (που θα σήμαινε ψευδές, δηλ. αθέτηση μη δανείου). Αυτή η ταξινόμηση έχει συχνά αποτελέσει τη βάση διαφόρων αλγορίθμων ταξινόμησης και είναι το είδος της τεχνικής ταξινόμησης που κατανοείται πρωτίστως.

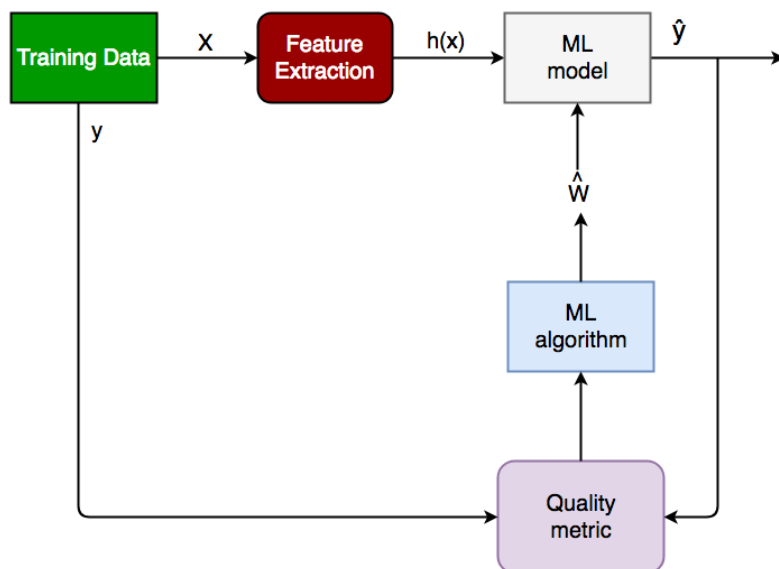
- ο Διωνυμική Ταξινόμηση (Binomial Classification) : Αυτός ο τύπος ταξινόμησης είναι τεχνικά παρόμοιος με τη δυαδική ταξινόμηση, καθώς η μεταβλητή Y περιλαμβάνει δύο κατηγορίες. Ωστόσο, αυτές οι κατηγορίες ενδέχεται να μην έχουν τη μορφή Σωστό και Λάθος. Για παράδειγμα, εάν έχουμε ένα σύνολο δεδομένων για πολλαπλές λειτουργίες που δηλώνουν πυκνότητα εικονοστοιχείων, έχουμε μια μεταβλητή Y με δύο κατηγορίες - "Car" ή "Bike". Αυτός ο τύπος ταξινόμησης είναι γνωστός ως διωνυμική ταξινόμηση. Από πρακτική άποψη, ειδικά όσον αφορά τη Μηχανική Μάθηση, δεν υπάρχει διαφορά, καθώς αυτές οι δύο κατηγορίες μπορούν επίσης να κωδικοποιηθούν και να σημειωθούν ως 0 και 1, κάνοντας αυτόν τον τύπο να μοιάζει μόνο με Δυαδική Ταξινόμηση.
- Ταξινόμηση πολλαπλών τάξεων (Multiclass Classification): Ο αριθμός των τάξεων είναι μεγαλύτερος από δύο. Τα ακόλουθα, αποτελούν παραδείγματα ταξινόμησης πολλαπλών τάξεων : α) Ταξινόμηση ενός κειμένου ως θετικού, αρνητικού ή ουδέτερου, β) Προσδιορισμός της φυλής σκύλου σε μια εικόνα, γ) Ταξινόμηση ενός ειδησεογραφικού άρθρου σε αθλητικά, πολιτικά, οικονομικά ή κοινωνικά, και δ) με βάση δεδομένα σχετικά με διαφορετικά είδη λουλουδιών, πρέπει να καθορίσουμε σε ποιο είδος ανήκει η παρατήρησή μας.

Πιο αναλυτικά, η ταξινόμηση πολλαπλών κατηγοριών προκύπτει όταν η μεταβλητή Y αποτελείται από περισσότερες από δύο κλάσεις/κατηγορίες. Εδώ, κάθε παρατήρηση ανήκει σε μια κλάση και ένας αλγόριθμος ταξινόμησης πρέπει να καθορίσει τη σχέση μεταξύ των μεταβλητών εισόδου και αυτών. Επομένως, κατά τη διάρκεια της πρόβλεψης, κάθε παρατήρηση ανατίθεται σε μια μοναδική κατηγορία. Για παράδειγμα, ένα επιχειρηματικό πρόβλημα όπου υπάρχει ανάγκη ταξινόμησης για το εάν μια παρατήρηση είναι "Ασφαλής", "Σε κίνδυνο" ή "Μη ασφαλής" θα ταξινομηθεί ως πρόβλημα ταξινόμησης πολλαπλών κατηγοριών. Σημείωση - Κάθε παρατήρηση μπορεί να ανήκει σε μία μόνο τάξη και πολλές τάξεις δεν μπορούν να αντιστοιχιστούν στην παρατήρηση. Έτσι εδώ, η παρατήρηση είτε θα είναι «Ασφαλής» είτε «Σε Κίνδυνο» ή «Μη Ασφαλής» και δεν μπορεί να είναι πολλαπλά πράγματα.

- Ταξινόμηση με πολλές ετικέτες (Multi-Label Classification) : Αυτή η μορφή ταξινόμησης είναι παρόμοια με την ταξινόμηση πολλαπλών κλάσεων. Εδώ, η εξαρτημένη μεταβλητή έχει περισσότερες από 2 κατηγορίες. Ωστόσο, διαφέρει από την ταξινόμηση πολλαπλών κλάσεων (multi-class classification) καθώς εδώ, μια παρατήρηση μπορεί να αντιστοιχιστεί σε περισσότερες από μία κατηγορίες. Επομένως, ο αλγόριθμος ταξινόμησης εδώ πρέπει να κατανοήσει σε ποιες κλάσεις μπορεί να σχετίζεται μια παρατήρηση και να κατανοήσει τα πρότυπα ανάλογα. Μια συνηθισμένη περίπτωση χρήσης αυτών των τύπων προβλημάτων ταξινόμησης βρίσκεται στην ταξινόμηση που σχετίζεται με την εξόρυξη κειμένου, όπου μια παρατήρηση (π.χ. κείμενο από ένα άρθρο εφημερίδας) μπορεί να έχει πολλαπλές κατηγορίες στην αντίστοιχη εξαρτώμενη μεταβλητή της (όπως "Πολιτικά", "Όνομα Πολιτικών που Συμμετέχουν », « Σημαντική γεωγραφική θέση » κ.λπ ..).



Σχήμα 4.6 Διαδική Ταξινόμηση και Ταξινόμηση πολλαπλών κλάσεων. Εδώ x_1 και x_2 είναι οι μεταβλητές μας βάσει των οποίων προβλέπεται η κλάση. Ακολουθεί το γενικευμένο μπλοκ διάγραμμα της εργασίας ταξινόμησης :



Σχήμα 4.7 Μπλοκ διάγραμμα γενικευμένης ταξινόμησης

όπου :

- X : προ ταξινομημένα δεδομένα, με τη μορφή πίνακα $N \times M$. Το N είναι το αρ. των παρατηρήσεων και M είναι ο αριθμός των χαρακτηριστικών
- y : Ένα διάνυσμα N -d που αντιστοιχεί σε προβλεπόμενες κλάσεις για καθεμία από τις N παρατηρήσεις.
- Εξαγωγή χαρακτηριστικών (Feature Extraction) : Εξαγωγή πολύτιμων πληροφοριών από την είσοδο X χρησιμοποιώντας μια σειρά μετασχηματισμών.
- ML model: Ο Ταξινομητής που θα εκπαιδεύσουμε.
- y' : Ετικέτες που προβλέπονται από τον Ταξινομητή
- Μέτρηση ποιότητας Quality metric: Μέτρηση που χρησιμοποιείται για τη μέτρηση της απόδοσης του μοντέλου
- Αλγόριθμος ML: Ο αλγόριθμος που χρησιμοποιείται για την ενημέρωση των βαρών w' , που ενημερώνουν το μοντέλο και «μαθαίνει» επαναληπτικά.

4.7 Αλγόριθμοι Ταξινόμησης

Η ταξινόμηση, όπως προαναφέραμε στα προηγούμενα κεφάλαια, ανήκει στην κατηγορία της μάθησης υπό επίβλεψη. Υπάρχουν πολυάριθμοι αλγόριθμοι που μπορούν να χρησιμοποιηθούν για την επίλυση προβλημάτων ταξινόμησης στη ρύθμιση μηχανικής μάθησης. Δεδομένης της ευρείας χρήσης της μηχανικής μάθησης, πολλοί από αυτούς τους αλγόριθμους παρέχουν εξαιρετικά αποτελέσματα και αναπτύσσονται σε διάφορους τομείς. Δεδομένου ότι υπάρχουν τόσοι πολλοί αλγόριθμοι, καθίσταται σημαντικό για έναν επιστήμονα δεδομένων να έχει μια βασική ιδέα για τη λειτουργία τους, τα πλεονεκτήματα, τα μειονεκτήματα και τις τυπικές περιπτώσεις χρήσης. Ωστόσο, πριν από αυτό, είναι καλή ιδέα να γνωρίζουμε εάν αυτοί οι αλγόριθμοι μπορούν να κατηγοριοποιηθούν σύμφωνα με τον μηχανισμό εκμάθησής τους.

Παρόλο που όλοι οι αλγόριθμοι ταξινόμησης λειτουργούν υπό τη ρύθμιση της επιβλεπόμενης μάθησης, μπορούν να χωριστούν σε δύο ομάδες : *Eager Learners* και *Lazy Learners*.

- **Eager Learners - “Πρόθυμοι Μαθητές”** : Σε αυτή την κατηγορία ανήκουν οι περισσότεροι αλγόριθμοι ταξινόμησης, καθώς αυτός είναι ο μάλλον τυπικός τρόπος εκμάθησης της σχέσης μεταξύ της εισόδου και της μεταβλητής στόχου. Εδώ (σε μια τεχνική επικύρωση μεμονωμένου ελέγχου), στα δεδομένα υπό εκπαίδευση, ανιχνεύονται μοτίβα και δημιουργείται μια ποσοτικοποιημένη σχέση μεταξύ της μεταβλητής X και Y (συχνά με τη μορφή μαθηματικής εξίσωσης, κανόνων, συνδυασμού βαρών, κλπ) και αυτό δημιουργεί ένα μοντέλο ταξινόμησης. Αυτή η ποσοτικοποιημένη σχέση στη συνέχεια εφαρμόζεται στο σύνολο δεδομένων δοκιμής για να προκύψουν προβλέψεις. Ένα τυπικό χαρακτηριστικό αυτής της κατηγορίας είναι ότι έχει μια μακρά διαδικασία ανάπτυξης κατά την εφαρμογή του μοντέλου και η επίτευξη προβλέψεων απαιτεί λιγότερο χρόνο. Οι αλγόριθμοι που εντάσσονται στους Πρόθυμους Μαθητές περιλαμβάνουν την Λογιστική παλινδρόμηση (Logistic Regression), τα δέντρα απόφασης (Decision Trees) , τον ταξινομητή διανυσμάτων υποστήριξης (SVMs), τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks) κ.λπ.
- **Lazy Learners - “Τεμπέληδες Μαθητές”** : Οι τεμπέληδες μαθητές απλώς αποθηκεύουν τα δεδομένα εκπαίδευσης και περιμένουν μέχρι να εμφανιστούν δεδομένα δοκιμής. Όταν αυτό συμβεί, η ταξινόμηση πραγματοποιείται με βάση τα πιο σχετικά δεδομένα στα αποθηκευμένα δεδομένα εκπαίδευσης. Σε σύγκριση με τους πρόθυμους μαθητές, οι τεμπέληδες μαθητές έχουν λιγότερο χρόνο εκπαίδευσης, αλλά περισσότερο απαιτούμενο χρόνο για την πρόβλεψη. Αποτελούν το αντίθετο από τους Eager Learners. Πιο συγκεκριμένα, σε αντίθεση με τους Eager Learners, τα δεδομένα εκπαίδευσης δεν χρησιμοποιούνται άμεσα για τη δημιουργία σχέσης μεταξύ των μεταβλητών X και Y και την ανάπτυξη ενός μοντέλου. Τα εκπαιδευόμενα δεδομένα παραμένουν στην άκρη και η ταξινόμηση (πρόβλεψη τάξεων) πραγματοποιείται στα δεδομένα της δοκιμής με βάση την πιο συνηθισμένη παρατήρηση (και την ετικέτα της) που βρίσκεται στα δεδομένα της δοκιμής. Ακριβώς το αντίθετο από τους Πρόθυμους Μαθητές, ο χρόνος που καταναλώνεται κατά τη διάρκεια της φάσης εκπαίδευσης είναι πολύ μεγαλύτερος από τον χρόνο που απαιτείται για την πρόβλεψη των μαθημάτων. Οι τυπικοί αλγόριθμοι που εμπίπτουν σε αυτήν την κατηγορία περιλαμβάνουν τους K -πλησιέστερους γείτονες (K -nearest Neighbours - KNN), αλγόριθμοι CBL κ.λπ.

Ωστόσο, υπάρχουν κι άλλοι τρόποι ομαδοποίησης των αλγορίθμων. Για παράδειγμα, οι αλγόριθμοι μπορούν να ομαδοποιηθούν από την άποψη ότι ορισμένοι είναι γραμμικοί ταξινομητές ενώ άλλοι δεν είναι ή κάποιοι είναι δυαδικοί ταξινομητές ενώ άλλοι έχουν την εγγενή δυνατότητα αναγνώρισης πολλαπλών κλάσεων.

Συνοπτικά, οι πιο διαδεδομένοι ταξινομητές είναι οι εξής :

- Γραμμικοί ταξινομητές: Λογιστική παλινδρόμηση (Linear Classifiers - Logistic Regression)
- Ταξινόμηση βάσει δέντρων: Ταξινομητής δέντρων απόφασης (Tree Based Classification : Decision Tree Classifier)
- Μηχανές διανυσμάτων υποστήριξης (Support Vector Machines -SVMs)
- Τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks)
- Παλινδρόμηση κατά Bayes (Bayesian Regression)
- Ταξινομητές Gaussian Naive Bayes (Gaussian Naive Bayes Classifiers)
- Ταξινομητής στοχαστικής κλίσης (SGD) (Stochastic Gradient Descent Classifier)
- Μέθοδοι συνόλου: Τυχαία δάση, AdaBoost, ταξινομητής σακούλας, ταξινομητής ψηφοφορίας, ταξινομητής ExtraTrees (Random Forests, AdaBoost, Bagging Classifier, Voting Classifier, ExtraTrees Classifier)

Γενικά, υπάρχουν δύο διαφορετικές προσεγγίσεις για την ταξινόμηση δεδομένων: η πρώτη εξετάζει μόνο μια διχοτομική διάκριση μεταξύ των δύο κλάσεων και εκχωρεί ετικέτες κλάσεων 0 ή 1 σε ένα άγνωστο στοιχείο δεδομένων. Η δεύτερη επιχειρεί να μοντελοποιήσει το $P(y|x)$. Αυτό αποδίδει όχι μόνο μια ετικέτα κλάσης για ένα στοιχείο δεδομένων, αλλά και μια πιθανότητα συμμετοχής στην κατηγορία. Οι πιο εξέχοντες εκπρόσωποι της πρώτης κατηγορίας είναι οι μηχανές διανυσμάτων υποστήριξης. Η λογιστική παλινδρόμηση, τα τεχνητά νευρωνικά δίκτυα, οι k-πλησιέστεροι γείτονες και τα δέντρα απόφασης είναι όλα μέλη της δεύτερης κατηγορίας, αν και διαφέρουν σημαντικά ως προς τη δημιουργία μιας προσέγγισης στο $P(y|x)$ από δεδομένα.

4.8 Ορολογίες Ταξινόμησης

- Ταξινομητής - Είναι ένας αλγόριθμος που χρησιμοποιείται για τη χαρτογράφηση των δεδομένων εισόδου σε μια συγκεκριμένη κατηγορία.
- Μοντέλο Ταξινόμησης - Το μοντέλο προβλέπει ή βγάζει συμπέρασμα στα δεδομένα εισόδου που δίνονται για εκπαίδευση, θα προβλέψει την κλάση ή την κατηγορία για τα δεδομένα.
- Χαρακτηριστικό - Ένα χαρακτηριστικό είναι μια ατομική μετρήσιμη ιδιότητα του φαινομένου που παρατηρείται.
- Δυαδική ταξινόμηση - Είναι ένας τύπος ταξινόμησης με δύο αποτελέσματα, για παράδειγμα - είτε αληθινό είτε λάθος.
- Ταξινόμηση πολλαπλών κατηγοριών-Η ταξινόμηση με περισσότερες από δύο κατηγορίες, στην ταξινόμηση πολλαπλών κατηγοριών κάθε δείγμα εκχωρείται σε μία και μόνο μία ετικέτα ή στόχο.
- Ταξινόμηση με πολλές ετικέτες-Αυτός είναι ένας τύπος ταξινόμησης όπου κάθε δείγμα εκχωρείται σε ένα σύνολο ετικετών ή στόχων.
- Προβλέψτε τον στόχο - Για μια μη επισημασμένη παρατήρηση X , η μέθοδος πρόβλεψης (X) επιστρέφει την προβλεπόμενη ετικέτα y .
- Αξιολόγηση - Αυτό σημαίνει βασικά την αξιολόγηση του μοντέλου, δηλαδή την έκθεση ταξινόμησης, τη βαθμολογία ακρίβειας κ.λπ.

4.9 Παραδείγματα Ταξινόμησης

Ταξινόμηση ηλεκτρονικού ταχυδρομείου : Μεταξύ της πιο παραδοσιακής και πρώιμης χρήσης της ταξινόμησης, τα μηνύματα ηλεκτρονικού ταχυδρομείου συχνά απαιτούνταν να ταξινομούνται ως ανεπιθύμητα ή μη ανεπιθύμητα. Αυτό γίνεται με την ανάπτυξη ενός μοντέλου ταξινομητή που περνά από το περιεχόμενο των δεδομένων και προσδιορίζει εάν το μήνυμα ηλεκτρονικού ταχυδρομείου είναι ανεπιθύμητο ή όχι. Δηλαδή σκοπός του προβλήματος είναι να εκπαιδεύσουμε ένα σύστημα το οποίο θα διακρίνει τα μηνύματα ηλεκτρονικού ταχυδρομείου σε ανεπιθύμητα (spam) ή επιθυμητά (ham = όχι spam) Για να αναπτυχθεί ένα τέτοιο μοντέλο ταξινόμησης, απαιτείται μεγάλη ποσότητα καλά επισημασμένων-ετικετοποιημένων μηνυμάτων ηλεκτρονικού ταχυδρομείου, έτσι ώστε στη φάση της εκπαίδευσης να υπάρχουν αρκετά δεδομένα που το μοντέλο να μην πληροί. Καθώς είναι εγγενώς αυτό το πρόβλημα που βασίζεται σε κείμενο, τα περιεχόμενα του ηλεκτρονικού ταχυδρομείου μετατρέπονται σε παρατηρήσεις όπου κάθε χαρακτηριστικό είναι μια λέξη. Η παρατήρηση είναι αν η λέξη ήταν παρούσα / πόσες φορές η λέξη ήταν παρούσα σε αυτό το έγγραφο. Ενώ οι παραδοσιακοί ταξινομητές ηλεκτρονικού ταχυδρομείου αντιμετώπιζαν δυαδικά προβλήματα (Ανεπιθύμητα ή Μη ανεπιθύμητα), οι σύγχρονοι ταξινομητές ηλεκτρονικού ταχυδρομείου προσδιορίζουν εάν το μήνυμα ηλεκτρονικού ταχυδρομείου είναι ανεπιθύμητο καθώς και το θέμα του ηλεκτρονικού ταχυδρομείου, όπως κοινωνικά, διαφημίσεις, ειδοποιήσεις κ.λπ. Παρόμοια μοντέλα χρησιμοποιούνται όλο και περισσότερο σε εφαρμογές ανταλλαγής μηνυμάτων. Ταξινομούν επίσης τα SMS σε παρόμοιες κατηγορίες για να κατανοήσουν καλύτερα την εμπειρία του χρήστη, προστατεύοντάς τους από την κουραστική εργασία διαγραφής περιττών μηνυμάτων.

Παράδειγμα ταξινόμησης email : Ένα σύνολο δεδομένων που περιέχει τα χαρακτηριστικά από $P = 4601$ μηνύματα, καθώς και την κλάση στην οποία ανήκει το καθένα από αυτά, είναι το Spambase Dataset. Για το i -οστό μήνυμα έχει εξαχθεί ένα διάνυσμα χαρακτηριστικών (πρότυπο) $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ το οποίο περιέχει $n = 57$ χαρακτηριστικά. Μερικά παραδείγματα χαρακτηριστικών είναι τα παρακάτω :


- Πλήθος εμφανίσεων του χαρακτήρα '!' στο κείμενο ως ποσοστό επί του συνόλου των χαρακτήρων,
- Πλήθος εμφανίσεων του χαρακτήρα '?' στο κείμενο ως ποσοστό επί του συνόλου των χαρακτήρων
- Πλήθος εμφανίσεων της λέξης "technology" στο κείμενο ως ποσοστό επί του συνόλου των λέξεων,
- Πλήθος εμφανίσεων της λέξης "order" στο κείμενο ως ποσοστό επί του συνόλου των λέξεων,
- Μέσο μήκος όλων των ακολουθιών γραμμάτων που αποτελούνται από συνεχόμενα κεφαλαία γράμματα.
- κ.α.

Οι στόχοι t_i παίρνουν δύο τιμές :

- $t_i = +1$ αν το i -οστό μήνυμα χαρακτηρίζεται spam και
- $t_i = -1$ αν χαρακτηρίζεται ham .

Η συνάρτηση διαχωρισμού $y = f(\mathbf{x}_i; \mathbf{w})$ παράγει την εκτίμηση y του μοντέλου, η οποία εξαρτάται από το πρότυπο εισόδου \mathbf{x} και από το διάνυσμα παραμέτρων \mathbf{w} .

Σκοπός της μάθησης είναι ο καθορισμός του διανύσματος παραμέτρων \mathbf{w} έτσι ώστε οι εκτιμήσεις $y_i = f(\mathbf{x}_i; \mathbf{w})$ να βρίσκονται όσο το δυνατόν πιο κοντά στις πραγματικές τιμές t_i . Για τον σκοπό αυτόν απαιτείται κάποιο μαθηματικό κριτήριο, ώστε να αξιολογείται η εγγύτητα των εκτιμώμενων τιμών και των πραγματικών τιμών. Στην περίπτωση αυτή μπορούμε να επιλέξουμε ως κριτήριο την ακρίβεια (accuracy), που ορίζεται ως το ποσοστό των περιπτώσεων όπου ισχύει $y_i = t_i$, δηλαδή η εκτίμησή μας συμφωνεί με την πραγματικότητα.



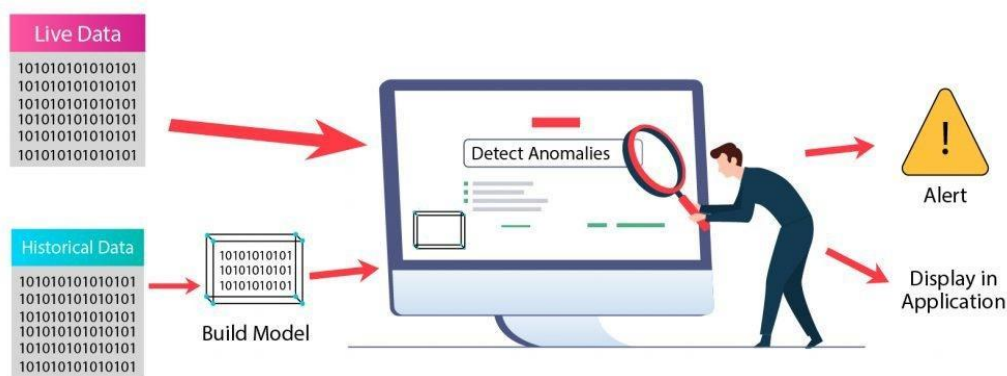
Εικόνα 4.5 Ταξινόμηση μηνυμάτων email

Ταξινόμηση εικόνας : Το επιχειρηματικό πρόβλημα που έχει στοιχειώσει τις βιομηχανίες και αποτελεί πρόκληση για τους ερευνητές εδώ και πολύ καιρό, η ταξινόμηση εικόνων, είναι επιτέλους εφικτό σήμερα. Αλγόριθμοι όπως το Support Vector Machine και τα Τεχνητά Νευρωνικά Δίκτυα (μέθοδοι που θα αναλύσουμε σε επόμενα κεφάλαια) έχουν καταστήσει δυνατή την ταξινόμηση μιας εικόνας με πρωτοφανή ακρίβεια. Θεωρητικά, η πιο βασική μορφή ταξινόμησης μπορεί να είναι η διαφοροποίηση των γατών από τα σκυλιά ή ο προσδιορισμός των αριθμών από τις εικόνες. Ωστόσο, η πραγματική περίπτωση ταξινόμησης εικόνας είναι μάλλον ποικίλη.

Ανωμαλία / Ανίχνευση απάτης : Μια περίπτωση ταξινόμησης χρησιμοποιείται συχνά σε Τραπεζικές, Χρηματοοικονομικές Υπηρεσίες και Ασφάλειες (τομείς BFSI). Πολλές συναλλαγές σε αυτούς τους τομείς και η εξεύρεση συναλλαγών απάτης υψηλής σημασίας και οι περίπλοκοι αλγόριθμοι ταξινόμησης προσπαθούν να δημιουργηθούν και να εφαρμοστούν για να λειτουργήσουν σε πραγματικό χρόνο. Για παράδειγμα, ένα μοντέλο ανίχνευσης απάτης μπορεί να προσδιορίσει μια συναλλαγή ως απάτη με βάση την ασυνήθιστη τοποθεσία, το αγορασμένο προϊόν, το ποσό ή το χρόνο συναλλαγής κ.λπ. Παρόμοιες έννοιες μπορούν να

εφαρμοστούν για να βρεθούν εύλογοι κακοπληρωτές δανείων, άλλοι μη αποπληρωτές κ.λπ.

REAL TIME ANOMALY DETECTION



Εικόνα 4.6 Ταξινόμηση για ανίχνευση απάτης

Η ταξινόμηση εν κατακλείδι, είναι μια συναρπαστική πτυχή της επιστήμης δεδομένων. Ενώ υπάρχουν πολλοί αλγόριθμοι που λύνουν διάφορα επιχειρηματικά (και μη) προβλήματα, ένας μεγάλος αριθμός αυτών των αλγορίθμων ανήκει στον τομέα της ταξινόμησης. Ταξινόμηση ή classification

ονομάζεται η διαδικασία ταξινόμησης δεδομένων σε κλάσεις οι οποίες είναι γνωστές από πριν. Αφού έχουμε ένα σει δεδομένων που όλα έχουν το ίδιο πλήθος χαρακτηριστικών γίνεται πρώτα μία διαδικασία εκπαίδευσης (training) όπου ορίζει ο χρήστης μερικές ετικέτες (labels) 1 ή - 1) στα δεδομένα και γίνεται η εκπαίδευση του αλγόριθμου. Όταν έρθει εις πέρας η εκπαίδευση, δημιουργείται ένα «μοντέλο πρόβλεψης» όπου με βάση αυτού θα γίνει μετά η δοκιμή των νέων «άγνωστων» δεδομένων τα οποία είναι τα εν απομείναντα δεδομένα και ύστερα γίνεται από τον αλγόριθμο η αυτόματη ταξινόμηση.

ΚΕΦΑΛΑΙΟ 5 Μηχανές Διανυσμάτων


Υποστήριξης – Support Vector Machines (SVMs)

5.1 Εισαγωγή

Οι μηχανές διανυσμάτων υποστήριξης ή ΜΔΥ (Support Vector Machines, SVMs) προτάθηκαν από τον Vladimir Vapnik και τους συνεργάτες του το 1992 ως μια νέα μέθοδος μάθησης, παρ' όλο που η γενικότερη ιδέα στην οποία στηρίζονται είχε προταθεί αρκετά νωρίτερα, από τη δεκαετία του '60. Στηρίζονται στη *Θεωρία Στατιστικής Μάθησης* (Statistical Learning Theory) και στα νευρωνικά δίκτυα τύπου *Perceptron*.

Αυτά τα μοντέλα είναι αλγοριθμικές υλοποιήσεις ιδεών από τη θεωρία στατιστικής μάθησης, η οποία ασχολείται με το πρόβλημα της δημιουργίας συνεπών εκτιμητών από δεδομένα: πώς μπορεί να εκτιμηθεί η απόδοση ενός μοντέλου πάνω σε ένα άγνωστο σύνολο δεδομένων, λαμβάνοντας υπόψη μόνο τα χαρακτηριστικά του μοντέλου και την απόδοση σε ένα σετ προπόνησης; Αλγοριθμικά, οι μηχανές διανυσμάτων υποστήριξης δημιουργούν βέλτιστα διαχωριστικά όρια μεταξύ συνόλων δεδομένων λύνοντας ένα περιορισμένο πρόβλημα τετραγωνικής βελτιστοποίησης. Με τη χρήση διαφορετικών συναρτήσεων πυρήνα, ποικίλοι βαθμοί μη γραμμικότητας και ευελιξίας μπορούν να συμπεριληφθούν στο μοντέλο. Επειδή μπορούν να προκύψουν από προηγμένες στατιστικές ιδέες και μπορούν να υπολογιστούν τα όρια του σφάλματος γενίκευσης για αυτές, οι μηχανές διανύσματος υποστήριξης έχουν λάβει σημαντικό ερευνητικό ενδιαφέρον τα τελευταία χρόνια.

Γενικά, στον αλγόριθμο SVM, σχεδιάζουμε - σημειώνουμε κάθε στοιχείο δεδομένων ως σημείο στον n -διάστατο χώρο (όπου n είναι ένας αριθμός χαρακτηριστικών που έχουμε) με την τιμή κάθε χαρακτηριστικού να είναι η τιμή μιας συγκεκριμένης συντεταγμένης. Στη συνέχεια, εκτελούμε ταξινόμηση βρίσκοντας το υπερ-επίπεδο που διαφοροποιεί όσο το δυνατόν πιο καλά τις δύο κατηγορίες.



Σχήμα 5.1 Αλγόριθμος SVM.

Τα τελευταία χρόνια, οι ΜΔΥ έχουν εδραιωθεί ως μια από τις πιο διαδεδομένες μεθόδους (γραμμικής και μη) παρεμβολής και ταξινόμησης, αποτελώντας συνήθως την βέλτιστη επιλογή για εφαρμογές όπως η αναγνώριση γραφής (handwriting recognition), η ταξινόμηση κειμένων (text categorization) και η ταξινόμηση δεδομένων έκφρασης γονιδίων (gene expression data).

5.1.α Γιατί τα χρησιμοποιούνται στη μηχανική μάθηση

Τα SVM χρησιμοποιούνται σε εφαρμογές όπως αναγνώριση χειρόγραφου, ανίχνευση εισβολής, ανίχνευση προσώπου, ταξινόμηση email, ταξινόμηση γονιδίων και σε ιστοσελίδες. Αυτός είναι ένας από τους λόγους που χρησιμοποιούμε SVM στη μηχανική μάθηση. Μπορεί να χειριστεί τόσο την ταξινόμηση όσο και την παλινδρόμηση σε γραμμικά και μη γραμμικά δεδομένα.

Ένας άλλος λόγος που χρησιμοποιούμε SVM είναι επειδή μπορούν να βρουν περίπλοκες σχέσεις μεταξύ των δεδομένων μας χωρίς να χρειάζεται να πραγματοποιήσουμε πολλές μετατροπές οι ίδιοι. Είναι μια εξαιρετική επιλογή όταν δουλεύουμε με μικρότερα σύνολα δεδομένων που έχουν δεκάδες έως εκατοντάδες χιλιάδες δυνατότητες. Τυπικά βρίσκουν πιο ακριβή αποτελέσματα σε σύγκριση με άλλους αλγόριθμους λόγω της ικανότητάς τους να χειρίζονται μικρά, πολύπλοκα σύνολα δεδομένων.

5.2 Τύποι SVM

Υπάρχουν δύο διαφορετικοί τύποι SVM, οι οποίοι χρησιμοποιούνται για διαφορετικά πράγματα:

- Απλό SVM (Simple SVM) : Συνήθως χρησιμοποιείται για προβλήματα γραμμικής παλινδρόμησης και ταξινόμησης.
- SVM Πυρήνα (Kernel SVM) : Έχει μεγαλύτερη ευελιξία για μη γραμμικά δεδομένα, επειδή μπορούν να προστεθούν περισσότερες δυνατότητες για να χωρέσουν σε ένα υπερεπίπεδο απ' ότι σε έναν δισδιάστατο χώρο.


5.3 Πώς λειτουργεί ένα SVM

Το Support Vector Machine (SVM) είναι ένας δυαδικός γραμμικός ταξινομητής που ορίζεται επίσημα από ένα διαχωριστικό υπερεπίπεδο. Με άλλα λόγια, με γνωστά δεδομένα εκπαίδευσης (εποπτευόμενη μάθηση), ο αλγόριθμος εξάγει ένα βέλτιστο υπερεπίπεδο που κατηγοριοποιεί νέα παραδείγματα. .Με αυτό τον τρόπο, ο αλγόριθμος SVM προσπαθεί να μεγιστοποιήσει το περιθώριο διαχωρισμού (margin), δηλαδή την απόσταση μεταξύ των πλησιέστερων δειγμάτων εκπαίδευσης τα οποία ονομάζονται Support Vectors. Έπειτα, διαχωρίζει κατά τον ίδιο τρόπο και τα υπόλοιπα άγνωστα για τον αναλυτή δεδομένα.

Σε δισδιάστατο χώρο, αυτό το υπερεπίπεδο είναι μια γραμμή που χωρίζει ένα επίπεδο σε δύο μέρη, όπου σε κάθε κλάση βρίσκεται σε κάθε πλευρά.


Σύμφωνα με τον Vapnik (1995), ο κίνδυνος (risk) μιας μηχανής μάθησης (R) οριοθετείται από το άθροισμα του εμπειρικού κινδύνου που υπολογίζεται από τα δείγματα εκπαίδευσης (R_{emp}) και από ένα διάστημα εμπιστοσύνης (Ψ): $R \leq R_{emp} + \Psi$. Η στρατηγική της αρχής αυτής είναι να διατηρήσει τον εμπειρικό κίνδυνο (R_{emp}) σταθερό και να ελαχιστοποιήσει το διάστημα εμπιστοσύνης (Ψ) ή να μεγιστοποιήσει το περιθώριο ανάμεσα σε ένα υπερ-επίπεδο διαχωρισμού και των κοντινότερων σημείων δεδομένων. Ο όρος υπερεπίπεδο διαχωρισμού (separating hyperplane) αναφέρεται στο επίπεδο εκείνο που διαχωρίζει τα δείγματα δεδομένων δύο τάξεων σε ένα πολυδιάστατο χώρο. Το βέλτιστο υπερεπίπεδο διαχωρισμού αποτελεί εκείνο το υπερεπίπεδο το οποίο μεγιστοποιεί το περιθώριο (margin) από τα κοντινότερα σημεία δεδομένων στο επίπεδο (Huang κ.α, 2002). Η λογική αυτή αφορά το διαχωρισμό δύο τάξεων. Για προβλήματα ταξινόμησης πολλαπλών τάξεων θα πρέπει να εισαχθούν επιπλέον έννοιες, όπως οι συναρτήσεις kernel, οι οποίες αναλύονται σε επόμενα κεφάλαια.

Ας υποθέσουμε ότι μας δίνεται μία γραφική παράσταση δύο κατηγοριών/κλάσεων με ετικέτες στο γράφημα όπως φαίνεται στο Σχήμα 5.2.α.




Σχήμα 5.2.α Γραφική παράσταση δύο κλάσεων.

Αν παρατηρήσουμε το Σχήμα 5.2.β, θα βρούμε μια διαχωριστική γραμμή. Θα μπορούσαμε να ισχυριστούμε πως διαχωρίζει αρκετά καλά τις δύο κλάσεις. Οποιοδήποτε σημείο που έχει απομείνει από τη γραμμή εμπίπτει στην κλάση με τους μαύρους κύκλους και στα δεξιά «πέφτει» στην κλάση με τα μπλε τετράγωνα. *Διαχωρισμός τάξεων*. Αυτό κάνει το SVM. Βρίσκει μια γραμμή/ υπερ-επίπεδο (σε πολυδιάστατο χώρο που χωρίζει τις τάξεις εκτός). Σύντομα, θα συζητήσουμε γιατί αναφερθήκαμε σε “πολυδιάστατο χώρο”.




Σχήμα 5.2.β Γραφική παράσταση δύο κλάσεων.

Τί θα συμβεί ωστόσο, αν είχαμε δεδομένα όπως φαίνεται στο Σχήμα 5.3.α; Σαφώς, δεν υπάρχει γραμμή που να χωρίζει τις δύο κλάσεις σε αυτό το επίπεδο x-y. Οπότε, τι κάνουμε σε αυτή την περίπτωση; Εφαρμόζουμε τον μετασχηματισμό και προσθέτουμε μια ακόμη διάσταση, την οποία ονομάζουμε άξονα z. Ας υποθέσουμε την τιμή των σημείων στο επίπεδο z, $w = x^2 + y^2$. Σε αυτή την περίπτωση μπορούμε να το χειριστούμε ως απόσταση σημείου από την προέλευση - z. Τώρα αν σχεδιάσουμε στον άξονα z, είναι σαφής ο διαχωρισμός και μια γραμμή.




Σχήμα 5.3.α Γραφική παράσταση δύο κλάσεων.




Σχήμα 5.3.β

Όταν γίνει ο μετασχηματισμός αυτής της γραμμής στο αρχικό επίπεδο, τότε, θα δούμε ότι αντιστοιχεί σε κυκλικό όριο όπως φαίνεται στο Σχήμα 5.3.γ. Αυτοί οι μετασχηματισμοί ονομάζονται **πυρήνες** (kernels).




Σχήμα 5.3.γ Μετασχηματισμός Kernel

Τι γίνεται στην περίπτωση που το γράφημα δεδομένων επικαλύπτεται; Ή, τι γίνεται σε περίπτωση που κάποια από τα μαύρα σημεία βρίσκονται μέσα στα μπλε;



Σχήμα 5.4.α Επικαλυπτόμενο γράφημα δεδομένων

Ποια γραμμή μεταξύ 1 ή 2 πρέπει να τραβήξουμε;



Σχήμα 5.4.β Πρόβλημα ταξινόμησης.

Η πρώτη ανέχεται ορισμένα ακραία σημεία. Η δεύτερη προσπαθεί να επιτύχει 0 ανοχή με τέλειο διαχωρισμό.

Εντούτοις, στον πραγματικό κόσμο, η εύρεση μιας τέλειας τάξης για εκατομμύρια σύνολα δεδομένων εκπαίδευσης απαιτεί πολύ χρόνο. Αυτό ονομάζεται **παράμετρος κανονικοποίησης**.

Σε επόμενα υποκεφάλαια ορίζουμε δύο όρους : **παράμετρος κανονικοποίησης** και **γάμμα**. Αυτές είναι παράμετροι συντονισμού στον ταξινομητή SVM. Μεταβάλλοντας τις παραμέτρους αυτές μπορούμε να επιτύχουμε σημαντική μη γραμμική γραμμή ταξινόμησης με μεγαλύτερη ακρίβεια σε εύλογο χρονικό διάστημα.

Μια ακόμη παράμετρος είναι ο **πυρήνας**. Καθορίζει αν θέλουμε γραμμικό διαχωρισμό. Αυτό αναλύεται επίσης παρακάτω. [8]

5.3.α Υπερεπίπεδο

Τώρα που καταλαβαίνουμε τη λογική SVM, ας δώσουμε έναν επίσημο ορισμό για το υπερεπίπεδο :

Ένα υπερεπίπεδο σε έναν n -διάστατο Ευκλείδειο χώρο είναι ένα επίπεδο, $n-1$ διαστάσεων υποσύνολο αυτού του χώρου που χωρίζει τον χώρο σε δύο αποσυνδεδεμένα μέρη.

Για παράδειγμα, ας υποθέσουμε ότι μια γραμμή είναι ο μονοδιάστατος Ευκλείδειος χώρος μας (δηλ. Ας πούμε ότι τα σύνολα δεδομένων μας βρίσκονται σε μια γραμμή). Μετέπειτα επιλέγουμε ένα σημείο στη γραμμή, με αποτέλεσμα αυτό το σημείο να χωρίσει τη γραμμή σε δύο μέρη. Η γραμμή έχει 1 διάσταση, ενώ το σημείο 0 διαστάσεις. Άρα ένα σημείο είναι ένα υπερεπίπεδο της γραμμής.

Για δύο διαστάσεις είδαμε ότι η διαχωριστική γραμμή ήταν το υπερεπίπεδο. Ομοίως, για τρεις διαστάσεις ένα επίπεδο με δύο διαστάσεις χωρίζει τον τρισδιάστατο χώρο σε δύο μέρη και έτσι λειτουργεί ως υπερεπίπεδο. Έτσι για έναν χώρο με n - διαστάσεις έχουμε ένα υπερεπίπεδο διαστάσεων $n-1$ που ακολούθως το χωρίζει σε δύο μέρη.

5.3.β Παράμετροι Συντονισμού : Kernel, Regulization, Gamma, Margin

Οι παράμετροι είναι ορίσματα που περνάμε όταν δημιουργούμε τον ταξινομητή μας. Ακολουθούν οι σημαντικές παράμετροι για το SVM.

5.3.β.i. Πυρήνας

Η εκμάθηση-εκπαίδευση του υπερεπιπέδου σε γραμμικό SVM γίνεται μετασχηματίζοντας το πρόβλημα χρησιμοποιώντας γραμμική άλγεβρα. Σε αυτό το σημείο παίζει ρόλο ο πυρήνας.

Για τον **γραμμικό πυρήνα**, η εξίσωση για πρόβλεψη για μια νέα είσοδο χρησιμοποιώντας το εσωτερικό γινόμενο (dot product) μεταξύ της εισόδου (x) και κάθε διανύσματος στήριξης (x_i) υπολογίζεται ως εξής:

$$f(x) = B(0) + \sum(a_i * (x, x_i))$$

Αυτή είναι μια εξίσωση που περιλαμβάνει τον υπολογισμό των εσωτερικών γινομένων ενός νέου διανύσματος εισόδου (x) με όλα τα διανύσματα υποστήριξης στα δεδομένα εκπαίδευσης. Οι συντελεστές $B(0)$ και a_i (για κάθε είσοδο) πρέπει να εκτιμηθούν από τα δεδομένα εκπαίδευσης από τον αλγόριθμο μάθησης.

Ο **πολυώνυμος πυρήνας** μπορεί να γραφτεί ως $K(x, x_i) = 1 + \sum(x * x_i)^d$ και ο **εκθετικός** ως $K(x, x_i) = \exp(-\gamma * \sum((x-x_i)^2))$.

Ο **πολυώνυμος** και ο **εκθετικός πυρήνας** υπολογίζει τη γραμμή διαχωρισμού σε υψηλότερη διάσταση. Αυτό ονομάζεται **“κόλπο πυρήνα”**.

Εξισώσεις πυρήνα

1. Γραμμικές

Αυτές συνιστώνται συνήθως για ταξινόμηση κειμένου καθώς τα περισσότερα από αυτά τα είδη προβλημάτων ταξινόμησης είναι γραμμικά διαχωρίσιμα.

Ο γραμμικός πυρήνας λειτουργεί πολύ καλά όταν υπάρχουν πολλά χαρακτηριστικά (features) Τα προβλήματα ταξινόμησης κειμένου έχουν πολλά χαρακτηριστικά. Οι γραμμικές λειτουργίες πυρήνα είναι ταχύτερες από τις περισσότερες άλλες και έχουν λιγότερες παραμέτρους για βελτιστοποίηση.

Η συνάρτηση που ορίζει τον γραμμικό πυρήνα:

$$f(X) = w^T * X + b$$

Σε αυτήν την εξίσωση, w είναι το διάνυσμα βάρους που θέλουμε να ελαχιστοποιήσουμε, X είναι τα δεδομένα που προσπαθούμε να ταξινομήσουμε και b είναι ο γραμμικός συντελεστής που εκτιμάται από τα δεδομένα της εκπαίδευσης. Αυτή η εξίσωση ορίζει το όριο απόφασης που επιστρέφει το SVM.

2. Πολυωνυμικές

Στην πραγματικότητα, ο πολυωνυμικός πυρήνας δεν χρησιμοποιείται πολύ συχνά καθώς δεν είναι τόσο αποδοτικός υπολογιστικά όσο οι άλλοι πυρήνες και επίσης, οι προβλέψεις του δεν είναι τόσο ακριβείς.

Εδώ είναι η συνάρτηση για έναν πολυώνυμο πυρήνα:

$$f(X_1, X_2) = (a + X_1^T * X_2) ^ b$$

Αυτή είναι μια από τις πιο απλές πολυωνυμικές εξισώσεις πυρήνα που μπορούμε να χρησιμοποιήσουμε. Το $f(X_1, X_2)$ αντιπροσωπεύει το όριο πολυωνυμικής απόφασης που θα χωρίσει τα δεδομένα μας. Τα X_1 και X_2 αντιπροσωπεύουν τα δεδομένα μας.


3. Συνάρτηση Gaussian Radial Basis (RBF)

Ένας από τους πιο ισχυρούς και κοινά χρησιμοποιούμενους πυρήνες στα SVM. Συνήθως αποτελεί την επιλογή για μη γραμμικά δεδομένα. Παρόμοια με την πολυωνυμική συνάρτηση, το RBF εκτελεί επίσης μετασχηματισμούς, όπως φαίνεται στην εξίσωση Lagrange

Η εξίσωση για έναν πυρήνα RBF:

$$f(X_1, X_2) = \exp(-\gamma * ||X_1 - X_2 ||^2)$$

Σε αυτήν την εξίσωση, το γάμμα καθορίζει πόσα έχει ένα μόνο σημείο εκπαίδευσης στα άλλα σημεία δεδομένων γύρω του. Το $||X_1 - X_2 ||$ είναι το τελικό προϊόν μεταξύ των χαρακτηριστικών μας. Δεδομένου ότι είναι μια συνάρτηση διανομής Gauss, υπολογίζεται με τη μέγιστη τιμή η οποία λαμβάνεται στο διάνυσμα στήριξης και η οποία διασπάται ομοίμορφα προς όλες τις κατευθύνσεις γύρω από το διάνυσμα στήριξης που οδηγεί σε στρογγυλό περιγράμμα όπως παρακάτω.



Σχήμα 5.5 Παράμετροι svm κατά τη χρήση του πυρήνα RBF.

Από εκείνο το σημείο και μετά, ο ταξινομητής είναι απλώς ένας σταθμισμένος γραμμικός συνδυασμός της συνάρτησης πυρήνα που υπολογίζεται μεταξύ ενός σημείου και καθενός από τα διανύσματα στήριξης.

4. Σιγμοειδής - Sigmoid

Πιο χρήσιμο σε νευρωνικά δίκτυα παρά σε SVM, αλλά υπάρχουν περιστασιακά συγκεκριμένες περιπτώσεις χρήσης.

Ακολουθεί η συνάρτηση για πυρήνα σιγμοειδούς:

$$f(X, y) = \tanh(\alpha * X^T * y + C)$$

Σε αυτή τη συνάρτηση, το α είναι ένα διάνυσμα βάρους και το C είναι μια τιμή αντιστάθμισης για να προκύψει κάποια λανθασμένη ταξινόμηση δεδομένων που μπορεί να συμβεί.

5. Άλλες συναρτήσεις πυρήνα

Υπάρχουν πολλοί άλλοι πυρήνες που μπορούμε να χρησιμοποιήσουμε. Αυτό μπορεί να είναι μια απόφαση που πρέπει να ληφθεί όταν πρέπει να πληρούνται ορισμένοι περιορισμοί σφάλματος, αν θέλουμε να δοκιμάσουμε και να επιταχύνουμε τον χρόνο εκπαίδευσης ή αν θέλουμε να συντονίσουμε υπερβολικά τις παραμέτρους.

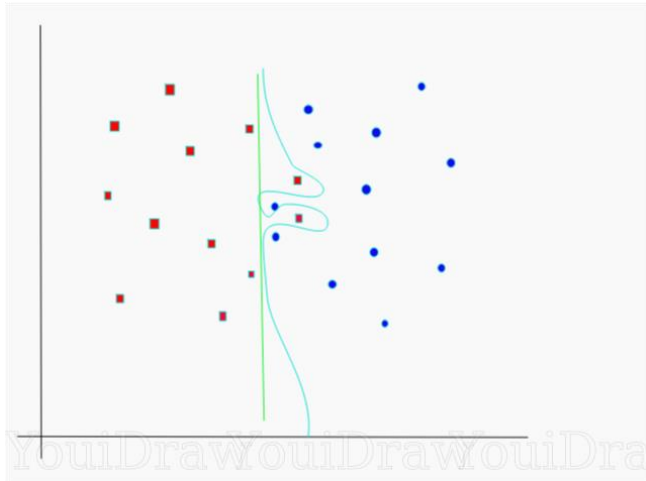
Τέτοιοι είναι : Ακτινική βάση ANOVA, υπερβολική εφαπτομένη και Laplace RBF.

Με την κατάλληλη και βελτιστοποιημένη χρήση των παραμέτρων, το RBF και άλλες συναρτήσεις πυρήνα εγγυώνται μια γενικά βέλτιστη πρόβλεψη που ελαχιστοποιεί τα σφάλματα σε έναν ταξινομητή.

5.3.β.ii Κανονικοποίηση - C

Η παράμετρος κανονικοποίησης (συχνά ονομάζεται παράμετρος C στη βιβλιοθήκη sklearn της rython) προσδιορίζει στη βελτιστοποίηση SVM πόσο θέλουμε να αποφύγουμε την εσφαλμένη ταξινόμηση κάθε παραδείγματος εκπαίδευσης.

Ελέγχει την αντιστάθμιση μεταξύ ομαλών ορίων λήψης αποφάσεων και σωστής κατάταξης των σημείων εκπαίδευσης. Μια μεγάλη τιμή c σημαίνει ότι θα λάβουμε περισσότερους πόντους εκπαίδευσης σωστά.




Σχήμα 5.6 Παράδειγμα με την παράμετρο κανονικοποίησης


Ας εξετάσουμε το παράδειγμα του παραπάνω σχήματος. Υπάρχουν πολλά όρια αποφάσεων που μπορούμε να σχεδιάσουμε για το συγκεκριμένο σύνολο δεδομένων. Ας εξετάσουμε ένα απλό (πράσινο χρώμα) όριο απόφασης το οποίο είναι από τη μία πλευρά αρκετά απλό, από την άλλη όμως έχει κόστος μερικών λανθασμένων κατηγοριών. Αυτά τα εσφαλμένα ταξινομημένα σημεία ονομάζονται ακραία. Μπορούμε επίσης να κάνουμε κάτι που είναι πολύ πιο τρελό (όριο αποφάσεων με μπλε χρώμα), αλλά κατά το οποίο μπορούμε να πάρουμε όλα τα σημεία εκπαίδευσης σωστά. Φυσικά, η ανταλλαγή με κάτι πολύ περίπλοκο, όπως αυτό, εγκυμονεί τον κίνδυνο να μην γενικευθεί τόσο καλά στο σύνολο δοκιμών μας. Έτσι, για κάτι που είναι απλό, η καλύτερη επιλογή είναι να ελέγξουμε την ακρίβεια (accuracy). Η μεγάλη τιμή του c σημαίνει ότι θα έχουμε πιο περίπλοκες καμπύλες αποφάσεων προσπαθώντας να χωρέσουμε όλα τα σημεία.

Για τις μεγάλες τιμές C λοιπόν, η βελτιστοποίηση θα επιλέξει ένα υπερεπίπεδο μικρότερου περιθωρίου εάν αυτό το υπερεπίπεδο λειτουργεί καλύτερα ως προς την σωστή ταξινόμηση όλων των σημείων εκπαίδευσης. Αντιστρόφως, μια πολύ μικρή τιμή C θα "διατάξει" το βελτιστοποιητή να αναζητήσει ένα υπερεπίπεδο διαχωρισμού μεγαλύτερου περιθωρίου, ακόμη και αν αυτό το υπερεπίπεδο παρερμηνεύει περισσότερα σημεία.

Τα παρακάτω σχήματα αποτελούν παράδειγμα δύο διαφορετικών παραμέτρων κανονικοποίησης. Το πρώτο έχει κάποια λανθασμένη ταξινόμηση λόγω χαμηλότερης τιμής κανονικοποίησης. Η υψηλότερη αξία οδηγεί σε αποτελέσματα όπως συμβαίνει στο δεύτερο σχήμα.



Σχήμα 5.7.α Παράδειγμα 1 χαμηλής τιμής C .




Σχήμα 5.7.β Παράδειγμα 2 υψηλής τιμής C.


5.3.β.iii Γάμμα-Gamma

Η παράμετρος γάμμα καθορίζει το πόσο μακριά φτάνει η επιρροή ενός μεμονωμένου παραδείγματος εκπαίδευσης, με χαμηλές τιμές που σημαίνουν «μακριά -far» και υψηλές τιμές «κοντά-close». Εάν έχει χαμηλή τιμή σημαίνει ότι κάθε σημείο έχει μεγάλη απόσταση και αντιστρόφως, υψηλή τιμή γάμμα σημαίνει ότι κάθε σημείο έχει κοντινή προσέγγιση.

Εάν το γάμμα έχει πολύ υψηλή τιμή, τότε το όριο της απόφασης θα εξαρτηθεί απλώς από τα σημεία που βρίσκονται πολύ κοντά στη γραμμή, πράγμα που έχει ως αποτέλεσμα να αγνοήσουμε μερικά από τα σημεία που βρίσκονται πολύ μακριά από το όριο της απόφασης. Αυτό συμβαίνει επειδή τα πιο κοντινά σημεία αποκτούν περισσότερο βάρος με αποτέλεσμα να δημιουργείται μια κυματιστή καμπύλη όπως φαίνεται στο γράφημα στο Σχήμα 5.8. Από την άλλη πλευρά, εάν η τιμή γάμμα είναι χαμηλή, ακόμη και τα μακρινά σημεία αποκτούν σημαντικό βάρος και έχουμε μια πιο γραμμική καμπύλη.



Σχήμα 5.8.α Παράδειγμα με υψηλό γάμμα.




Σχήμα 5.8.β Παράδειγμα με χαμηλό γάμμα.

5.3.β.iv Περιθώριο-Margin


Το περιθώριο ορίζεται ως ο διαχωρισμός της γραμμής προς τα πλησιέστερα σημεία της τάξης/κλάσης.

Ένα **καλό περιθώριο** είναι εκείνο όπου ο διαχωρισμός αυτός είναι μεγαλύτερος και για τις δύο τάξεις. Τα παρακάτω σχήματα δίνουν σε οπτικό παράδειγμα καλό και κακό περιθώριο.

Ένα καλό περιθώριο επιτρέπει στους “κύκλους” να βρίσκονται στις αντίστοιχες τάξεις τους χωρίς να περνούν σε άλλη κατηγορία.



Σχήμα 5.9.α Παράδειγμα με καλό περιθώριο

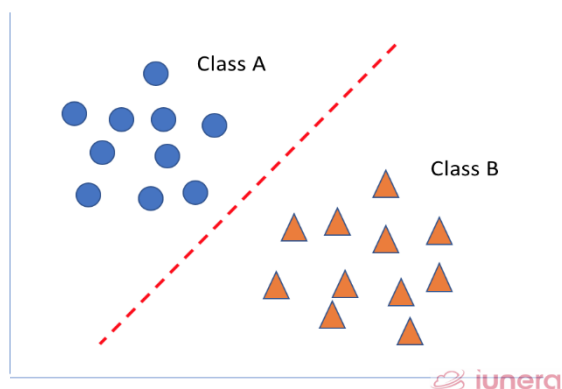


Σχήμα 5.9.β Παράδειγμα με κακό περιθώριο

5.4 Μαθηματική Διατύπωση των SVM

5.4.α Γραμμική Ταξινόμηση

Το γραμμικό SVM μπορεί να εφαρμοστεί σε γραμμικά διαχωρίσιμα δεδομένα. Σε γραμμικά διαχωρίσιμα δεδομένα, μπορεί να σχεδιαστεί μια ευθεία συνάρτηση για τον διαχωρισμό όλων των στοιχείων της κλάσης A και της κλάσης B.



Σχήμα 5.10. SVM - γραμμική ταξινόμηση.

Στην πραγματικότητα, ο αριθμός των πιθανών υπερεπίπεδων που μπορούν να σχεδιαστούν για να διαχωρίσουν τις κλάσεις για γραμμικά διαχωρίσιμα δεδομένα είναι άπειρος.

Εδώ εισάγεται η βασική ιδέα του SVM βάσει της οποίας, βρίσκουμε το βέλτιστο υπερεπίπεδο ή τον ταξινομητή μέγιστου περιθωρίου το οποίο είναι το πιο μακρινό από τις παρατηρήσεις.


Στην καρδιά του σχεδιασμού κάθε SVM ταξινομητή βρίσκεται η έννοια του περιθωρίου (margin). Θεωρήστε τον γραμμικό ταξινομητή :

$$w^T x + w_0 = 0 \quad (5.1).$$

Το περιθώριο είναι η περιοχή μεταξύ δύο παράλληλων υπερεπιπέδων : $w^T x + w_0 = 1$,
 $w^T x + w_0 = -1$ (5.2)


Οι ΜΔΥ(SVM) προσπαθούν να βρουν έτσι, ένα υπερεπίπεδο (hypersurface) που να διαχωρίζει στο χώρο των παραδειγμάτων τα αρνητικά από τα θετικά παραδείγματα. Το υπερεπίπεδο αυτό επιλέγεται έτσι, ώστε να απέχει όσο το δυνατόν περισσότερο από τα κοντινότερα θετικά και αρνητικά παραδείγματα (maximum margin hypersurface). Έτσι, μια ΜΔΥ μπορεί και ταξινομεί περιπτώσεις που είναι παρόμοιες αλλά όχι πανομοιότυπες με κάποιο παράδειγμα εκπαίδευσης. Το αποτέλεσμα μιας ΜΔΥ είναι τελικά μια αριθμητική τιμή στο διάστημα $[-1, +1]$ και όχι μια πιθανότητα όπως σε άλλους ταξινομητές.

Μια ερώτηση που συνήθως τίθεται, είναι γιατί το περιθώριο ορίζεται με αυτούς τους δύο μαγικούς αριθμούς, δηλαδή τους ± 1 . Η απάντηση είναι ότι αυτό δε συνιστά ζήτημα. Ας θεωρήσουμε ένα υπερεπίπεδο στο χώρο, π.χ., αυτό της Εξίσωσης (5.1) όπως παρουσιάζεται στο Σχήμα 5.11 με τη βοήθεια της συνεχούς γραμμής και δύο παράλληλα σε αυτό υπερεπίπεδα (διακεκομμένες γραμμές), σύμφωνα με την $w^T x + w_0 = \pm d$. Η παράμετρος d μπορεί να λάβει οποιαδήποτε τιμή, που σημαίνει ότι τα δύο επίπεδα μπορεί να πλησιάσουν μεταξύ τους ή να απομακρυνθούν. Κρατώντας σταθερή την τιμή της d και διαιρώντας και τα δύο μέλη της προηγούμενης εξίσωσης με d , λαμβάνουμε ± 1 στη δεξιά πλευρά της εξίσωσης. Όμως δεν έχουν αλλάξει η διεύθυνση και η θέση στο χώρο των δύο υπερεπιπέδων. Το ίδιο ισχύει και για το υπερεπίπεδο που περιγράφει η Εξίσωση (5.2). Η κανονικοποίηση με μια σταθερά d δεν επηρεάζει τα σημεία που βρίσκονται πάνω σε ένα υπερεπίπεδο (και που το ορίζουν). [1]



Σχήμα 5.11 Γραμμή και το περιθώριό της μεγέθους $1d$.

Έως τώρα θεωρούσαμε ότι συμβαίνει σφάλμα, όταν ένα σημείο βρεθεί στη λάθος πλευρά της επιφάνειας απόφασης που ορίζει ο ταξινομητής. Τώρα θα είμαστε περισσότερο απαιτητικοί. Δε θα συνεισφέρουν στη συνάρτηση υπολογισμού σφάλματος μόνο τα σημεία που βρίσκονται στην πλευρά του ταξινομητή, αλλά και κάθε σημείο εντός του περιθωρίου, ακόμα και αν το σημείο βρίσκεται στη σωστή πλευρά του ταξινομητή. Μόνο α σημεία εκείνα που βρίσκονται εκτός περιθωρίου και ταυτόχρονα στη σωστή πλευρά του ταξινομητή, δε συνεισφέρουν στον υπολογισμό του κόστους. Το Σχήμα 5.12 δείχνει δύο επικαλυπτόμενες κλάσεις και δύο γραμμικούς ταξινομητές, που αναπαρίστανται με διακεκομμένη(παύλα-τελεία) και σταθερή γραμμή αντιστοίχως. Τα περιθώρια και στις δύο περιπτώσεις έχουν επιλεγεί έτσι ώστε να συμπεριλάβουν πέντε σημεία. Παρατηρούμε πως, στην περίπτωση του ταξινομητή που αναπαρίσεται με διακεκομμένη γραμμή (παύλα-τελεία), το περιθώριο πρέπει να είναι πολύ στενό προκειμένου να εμπεριέχει πέντε σημεία.



Σχήμα 5.12 Δύο γραμμικοί ταξινομητές και οι σχετικές γραμμές περιθωρίου για ένα πρόβλημα δύο κλάσεων.

Ας φανταστούμε τώρα ότι οι άδειοι και οι γεμάτοι κύκλοι είναι σπίτια δύο γειτονικών χωριών και ότι πρέπει να κατασκευαστεί ένας δρόμος μεταξύ αυτών των δύο χωριών. Πρέπει να ληφθεί η απόφαση πού θα κατασκευαστεί ο δρόμος, έτσι ώστε, να είναι όσο το δυνατόν περισσότερο πλατύς και να έχει το μικρότερο δυνατό κόστος (ως προς τον αριθμό των σπιτιών που θα χρειαστεί να κατεδαφιστούν). Προφανώς, κανείς λογικός μηχανικός δεν θα επέλεγε τη λύση που ορίζουν οι διακεκομμένες γραμμές “παύλας-τελείας”.

Ομοίως συμβαίνει και κατά το σχεδιασμό ενός ταξινομητή. Θα πρέπει να τοποθετηθεί μεταξύ των περιοχών μεγάλης συγκέντρωσης σημείων (υψηλής πυκνότητας πιθανότητας) των δύο κλάσεων και ταυτόχρονα σε μια περιοχή αραιή σε σημεία. Αυτό επιβάλλει και η απαίτηση της γενίκευσης της απόδοσης, που κάθε ταξινομητής θα πρέπει να πληροί. Δηλαδή, ο ταξινομητής θα πρέπει να έχει καλή απόδοση όταν αντιμετωπίζει δεδομένα εκτός συνόλου εκπαίδευσης. Εξάλλου, κάθε ταξινομητής “γνωρίζει” το σύνολο εκπαίδευσης πολύ καλά, αφού έχει εκπαιδευτεί με αυτό. Επομένως, μπορούμε εύκολα να κατασκευάσουμε ένα ταξινομητή που παρουσιάζει πολύ χαμηλό σφάλμα στο σύνολο εκπαίδευσης, αλλά φτωχή απόδοση όταν αντιμετωπίζει άγνωστα δεδομένα. Σε γενικές γραμμές, αυτό συμβαίνει διότι ο ταξινομητής έχει προσαρμοστεί στην “ιδιοσυγκρασία” του συγκεκριμένου συνόλου εκπαίδευσης και επομένως δεν μπορεί να συμπεριφερθεί σωστά σε ένα ελαφρώς διαφορετικό σύνολο δεδομένων. Αν συνεχίσουμε το συλλογισμό αυτόν, συμπεραίνουμε πως ο ταξινομητής που αναπαρίσταται με τη διακεκομμένη γραμμή “παύλας-τελείας” θα κατέληγε σε υποδεέστερη γενικευμένη απόδοση συγκριτικά με τον ταξινομητή που έχει σχεδιαστεί με τη “σταθερή” γραμμή, μολονότι και οι δύο έχουν παρόμοια απόδοση ως προς τον αριθμό των σφαλμάτων περιθωρίου στο σύνολο εκπαίδευσης.

Η συζήτηση αυτή οδηγεί στην παρακάτω μαθηματική τυποποίηση. Δοθέντος ενός συνόλου σημείων εκπαίδευσης x_i , με αντίστοιχες ετικέτες κλάσεις, $y_i \in \{-1, 1\}$, $i = 1, 2, \dots, N$, σε ένα πρόβλημα ταξινόμησης δύο κλάσεων, υπολογίζουμε ένα υπερεπίπεδο (Εξίσωση 5.1) έτσι ώστε να

$$J(w, w_0, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (5.3)$$

Ελαχιστοποιεί

$$\Omega \text{ς προς } wTx_i + w_0 \geq 1 - \xi_i, \text{ εάν } x_i \in \omega_1 \quad (5.4)$$

$$wTx_i + w_0 \leq -1 + \xi_i, \text{ εάν } x_i \in \omega_2 \quad (5.5)$$

Το πλάτος του περιθωρίου είναι ίσο με $2/\|w\|$. Τα σφάλματα περιθωρίου ξ_i είναι μη αρνητικά. Είναι ίσα με μηδέν για σημεία εκτός ορίων περιθωρίου που ταυτόχρονα βρίσκονται στη σωστή πλευρά του ταξινομητή, και έχουν θετική τιμή για σημεία εντός ορίων περιθωρίου που όμως βρίσκονται στη λάθος πλευρά του ταξινομητή. Αυτό μπορούμε να το επιβεβαιώσουμε εξετάζοντας προσεκτικά τους περιορισμούς των Εξισώσεων 5.3 και 5.4. C είναι σταθερά που

καθορίζεται από τον χρήστη. Η ελαχιστοποίηση του κόστους συνιστά συμβιβασμό μεταξύ ενός μεγάλου περιθωρίου και ενός μικρού αριθμού σφαλμάτων περιθωρίου. Προκύπτει ότι η λύση δίνεται από έναν ζυγισμένο μέσο των σημείων εκπαίδευσης, δηλαδή,

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad (5.6)$$

Οι συντελεστές λ_i είναι οι Lagrange πολλαπλασιαστές της βελτιστοποίησης και είναι ίσοι με μηδέν για όλα τα σημεία εκτός περιθωρίου που ταυτόχρονα βρίσκονται στη σωστή πλευρά του ταξινομητή. Επομένως τα σημεία αυτά δε συνεισφέρουν στον καθορισμό της διεύθυνσης του ταξινομητή. Τα υπόλοιπα σημεία, με μη μηδενικά λ_i , που συνεισφέρουν στην κατασκευή του w , καλούνται διανύσματα στήριξης (support vectors)


Διανύσματα υποστήριξης

Τα Διανύσματα Υποστήριξης είναι απλώς οι συντεταγμένες της ατομικής παρατήρησης. Ο ταξινομητής SVM είναι ένα όριο που διαχωρίζει καλύτερα τις δύο κατηγορίες (υπερ-επίπεδο/ γραμμή). Πιο συγκεκριμένα, τα διανύσματα υποστήριξης, είναι τα σημεία που βρίσκονται πιο κοντά στο υπερεπίπεδο μεταξύ των 2 ή περισσότερων κλάσεων. Αυτά είναι τα σημεία δεδομένων που είναι πιο δύσκολο να ταξινομηθούν. Γενικά, όσο μεγαλύτερο είναι το περιθώριο ή η απόσταση μεταξύ των διανυσμάτων υποστήριξης, τόσο πιο εύκολο είναι για τον αλγόριθμο να ταξινομηθεί με ακρίβεια. Επομένως, μόλις βελτιστοποιηθεί το υπερεπίπεδο, λέγεται ότι αυτός είναι ο βέλτιστος διαχωρισμός ή ο ταξινομητής μέγιστου περιθωρίου.

Γραμμικά SVM για γραμμικά διαχωρίσιμα προβλήματα

Μπορούμε τώρα να προχωρήσουμε στη μαθηματική επισημοποίηση της διαδικασίας που περιγράψαμε παραπάνω. Εάν έχουμε ένα σύνολο δεδομένων που περιλαμβάνει παρατηρήσεις, αυτά εκτείνονται σε ένα χώρο χαρακτηριστικών $V = \mathbb{R}^{|x|}$. Εδώ, $|x|$ είναι η διαστατικότητα, ή αλλιώς ο αριθμός διαστάσεων του διανύσματος που περιλαμβάνει τα χαρακτηριστικά για μια δεδομένη παρατήρηση x .

Σε αυτό το χαρακτηριστικό χώρο V , ένα SVM προσδιορίζει το υπερεπίπεδο που μεγιστοποιεί την απόσταση που υπάρχει μεταξύ του ίδιου και των δύο πλησιέστερων σημείων ή συνόλου σημείων που ανήκουν σε ξεχωριστές κλάσεις. Εάν υπάρχει ένα τέτοιο υπερεπίπεδο, μπορούμε να πούμε ότι οι παρατηρήσεις είναι γραμμικά διαχωρίσιμες στον χώρο χαρακτηριστικών V :




Σχήμα 5.13 Πρόβλημα γραμμικά διαχωρίσιμο

Ωστόσο, δεν είναι όλα τα προβλήματα γραμμικά διαχωρίσιμα.

Διαχωριστικά Υπερεπίπεδα και Διανύσματα Υποστήριξης


Σε αυτή την περίπτωση, μπορούμε να πούμε ότι ένα SVM που προσδιορίζει ένα υπερεπίπεδο για ένα γραμμικά διαχωρίσιμο πρόβλημα είναι ένα γραμμικό SVM. Θα δούμε παρακάτω τον τύπο για τον υπολογισμό αυτού του υπερεπίπεδου. Πριν το κάνουμε αυτό, ας σκεφτούμε τί είσοδο πρέπει να έχει αυτή η συνάρτηση.

Μπορούμε αφενός να προσπαθήσουμε να προσδιορίσουμε το υπερεπίπεδο διαχωρισμού εξετάζοντας ολόκληρο το σύνολο σημείων ή παρατηρήσεων. Αυτό σημαίνει ότι η εισαγωγή σε οποιαδήποτε μαθησιακή συνάρτηση που θα χρησιμοποιούσαμε θα είχε ωστόσο έναν σημαντικό αριθμό εν πολλοίς μη ενημερωτικών-μη λεπτομερών χαρακτηριστικών. Ο μόνες κατατοπιστικές παρατηρήσεις που απαιτούμε είναι αυτές που βρίσκονται στην πλησιέστερη απόσταση από το όριο απόφασης:



Σχήμα 5.14.α Informative observations

Δεν γνωρίζουμε ακόμη πού ακριβώς βρίσκεται το όριο απόφασης προτού το μάθουμε, φυσικά. Μπορούμε, ωστόσο, να υποθέσουμε, στην περίπτωση του γραμμικού διαχωρισμού, τα ακόλουθα. Εάν οποιοδήποτε ζεύγος παρατηρήσεων ανήκει σε δύο διαφορετικές κατηγορίες, τότε το υπερεπίπεδο βρίσκεται κάπου μεταξύ τους:



Σχήμα 5.14.β Υπόθεση περί της θέσης του ορίου απόφασης.

Αυτές οι “ενημερωτικές” παρατηρήσεις, ή μάλλον τα διανύσματα χαρακτηριστικών τους, υποστηρίζουν τον προσδιορισμό του ορίου απόφασης από το SVM. Για το λόγο αυτό, ονομάζουμε τα διανύσματα χαρακτηριστικών που βρίσκονται κοντά σε παρατηρήσεις άλλων κλάσεων “διανύσματα υποστήριξης (support vectors)”. Από αυτό το όνομα, με τη σειρά του, προέρχεται το όνομα του “μηχανήματος φορέα υποστήριξης (support vector machines)”.

Προσδιορισμός του ορίου απόφασης

Ας εμβαθύνουμε τώρα στη διαδικασία αναγνώρισης αυτού του υπερεπίπεδου για τον διαχωρισμό των τάξεων. Ένας γενικός τύπος για την περιγραφή ενός υπερεπίπεδου h_V σε ένα διανυσματικό χώρο V είναι:

$$\vec{v} \cdot \vec{x} - b = 0$$

όπου v είναι το κανονικό διάνυσμα σε αυτό το υπερεπίπεδο. Σε περίπτωση που ο όρος b ισούται με 0, το υπερεπίπεδο είναι επίσης υπόχωρος του αρχικού διανυσματικού χώρου, αλλά αυτό δεν είναι απαραίτητο.

Μπορούμε να αναδιαμορφώσουμε το πρόβλημα του προσδιορισμού του ορίου απόφασης, ως πρόβλημα αναγνώρισης του κανονικού διανύσματος \vec{v} και της παραμέτρου b . Αυτός ο προσδιορισμός πρέπει να σέβεται τον περιορισμό όσον αφορά τη μεγιστοποίηση της απόστασης. Με άλλα λόγια, το υπερεπίπεδο πρέπει να είναι το πιο απομακρυσμένο από τις δύο κοντινότερες παρατηρήσεις που ανήκουν σε ξεχωριστές κατηγορίες-τάξεις.

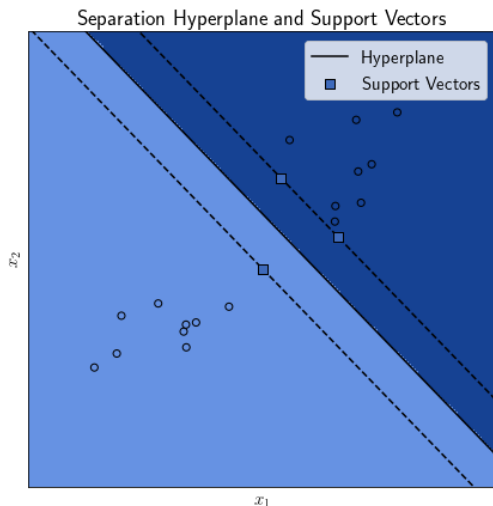
Μπορούμε να ονομάσουμε τη συνάρτηση απόφασης που μαθαίνουμε ως $y = f(x)$. Εάν οι δύο κλάσεις-τάξεις κωδικοποιούνται με τις τιμές 1 και -1, έτσι ώστε $y_i = f(x_i) \rightarrow y_i = 1 \vee y_i = -1$, τότε μπορούμε να γράψουμε το πρόβλημα ως εξής :

$$\min(\|\vec{v}\|) : y_i(\vec{v}x_i + b) \geq 1$$

Από τη μία πλευρά, οι παρατηρήσεις που ανήκουν στην κλάση $y = 1$ μπορούν να αναπαρασταθούν από μια ανισότητα $(\vec{v}x_i + b) \geq 1$. Αυτές που ανήκουν στην κλάση $y = -1$ αντιπροσωπεύονται από την ανισότητα $(\vec{v}x_i + b) \leq -1$. Τα δύο μπορούν λοιπόν να απλοποιηθούν ως εξής :

$$[(\vec{v}x_i + b) \geq y_i | y_i = 1] \vee [(\vec{v}x_i + b) \leq y_i | y_i = -1] \leftrightarrow y_i(\vec{v}x_i + b) \geq 1$$

Αυτός ο τύπος αντιστοιχεί τελικά σε αυτόν του οποίου τον όρο \vec{v} ελαχιστοποιήσαμε στην προηγούμενη έκφραση. Το υπερεπίπεδο που προσδιορίζουμε ως όριο απόφασης είναι αυτό που βρίσκεται στο μισό του δρόμου μεταξύ αυτών που λειτουργούν ως όρια για τους δύο ημιχώρους, που αντιστοιχούν στις ανισότητες που ορίζονται παραπάνω:



Σχήμα 5.15 Υπερεπίπεδο διαχωρισμού και διανύσματα υποστήριξης

5.5 Γενικεύσεις για την περίπτωση πολλών τάξεων

Στην προηγούμενη παράγραφο ασχοληθήκαμε με τον SVM ταξινομητή της περίπτωσης δύο κλάσεων. Υπάρχουν γενικεύσεις και για την περίπτωση πολλών κλάσεων, αλλά το πρόβλημα τείνει να γίνει αρκετά περίπλοκο. Στην πράξη, όταν υπάρχουν περισσότερες από δύο κλάσεις, έχουν προταθεί αρκετές προσεγγίσεις, που εξελίσσονται με άξονα την περίπτωση δύο κλάσεων. Οι τεχνικές αυτού του τύπου δεν απαντώνται μόνο στο πλαίσιο των SVM ταξινομητών. Είναι γενικές τεχνικές που μπορούν να χρησιμοποιηθούν σε συνδυασμό με οποιοδήποτε ταξινομητή έχει αναπτυχθεί για να λύσει ένα πρόβλημα δύο κλάσεων. Επιπλέον δεν εξυπηρετούν μόνο εκπαιδευτικούς σκοπούς, αλλά είναι και ευρέως διαδεδομένες στην πράξη.

Σύμφωνα με τη μέθοδο “ένας εναντίον όλων”, πρέπει να σχεδιαστούν c ταξινομητές. Κάθε ταξινομητής σχεδιάζεται έτσι ώστε να διαχωρίζει μια κλάση από τις υπόλοιπες. Έτσι λοιπόν για την SVM περίπτωση, πρέπει να σχεδιάσουμε c γραμμικούς ταξινομητές:

$$w_j^T x + w_{j0}, j=0,1,2,\dots,c$$

Για παράδειγμα, για να σχεδιάσουμε τον w_1 , λαμβάνουμε υπόψιν τα δεδομένα εκπαίδευσης όλων των κλάσεων πλην της w_1 , προκειμένου να σχηματίσουμε τη δεύτερη κλάση. Προφανώς εκτός και αν συμβεί λάθος, αναμένουμε ότι για όλα τα σημεία της κλάσης w_1 θα λάβουμε

$$w_1^T x + w_{10} > 0$$

ενώ τα δεδομένα των υπολοίπων κλάσεων θα καταλήξουν να δώσουν αρνητικό αποτέλεσμα. Ένα άγνωστο x , ταξινομείται στην w_i αν

$$w_i^T x + w_{i0} > w_j^T x + w_{j0}, \forall i \neq j$$

Ένα μειονέκτημα των τεχνικών τύπου “ένας εναντίον όλων” είναι ότι, μετά την εκπαίδευση, υπάρχουν περιοχές στο χώρο (όπου δεν συναντώνται δεδομένα εκπαίδευσης), στις οποίες περισσότερα του ενός υπερεπίπεδα δίνουν θετική τιμή, ή όλα δίνουν αρνητική τιμή.


5.6 Μη γραμμικά SVM, μη γραμμική ταξινόμηση

Τι συμβαίνει εάν τα δεδομένα που μας παρουσιάστηκαν για ταξινόμηση δεν είναι γραμμικά διαχωρίσιμα; Προς το παρόν, τα γραμμικά διαχωρίσιμα δεδομένα μπορούν να αναπαρασταθούν σε ένα 1-διάστατο επίπεδο. Αλλά αυτό δεν είναι δυνατό με μη γραμμικά δεδομένα.

Η γενική ιδέα για το πώς να το προσεγγίσουμε είναι να χαρτογραφήσουμε τον αρχικό χώρο χαρακτηριστικών σε κάποιο χώρο υψηλότερης διάστασης όπου το σετ εκπαίδευσης είναι διαχωρίσιμο. Φυσικά, θα θέλαμε να το κάνουμε με τρόπους που διατηρούν τις σχετικές διαστάσεις της συγγένειας μεταξύ των σημείων δεδομένων, έτσι ώστε ο ταξινομητής που προκύπτει να εξακολουθεί να γενικεύεται καλά.

Όρια μη γραμμικής απόφασης

Ορισμένες κατηγορίες προβλημάτων δεν είναι γραμμικά διαχωρίσιμες. Σε αυτήν την περίπτωση, λέμε ότι δεν υπάρχει υπερεπίπεδο του χώρου χαρακτηριστικών που μπορεί να αποτελέσει όριο απόφασης. Ωστόσο, ένα όριο απόφασης μπορεί να εξακολουθεί να υφίσταται. απλά δεν θα είναι υπερεπίπεδο για το V :



Σχήμα 5.16 Ένα μη γραμμικό πρόβλημα διαχωρισμού

Παρόλο που δεν θα είναι υπερεπίπεδο του χώρου χαρακτηριστικών, ενδέχεται να εξακολουθεί να είναι υπερεπίπεδο σε κάποιο μετασχηματισμένο διανυσματικό χώρο. Ας ονομάσουμε αυτόν τον μετασχηματισμένο χώρο $W = \mathbb{R}^m$. Η διάσταση του W αναμένεται να είναι ίση ή μεγαλύτερη με αυτή του V έτσι ώστε $|W| \geq |V|$.

Το έργο της αναγνώρισης ενός ορίου απόφασης για μη γραμμικά διαχωρίσιμα προβλήματα μπορεί επομένως να αναδιατυπωθεί με τον ακόλουθο τρόπο. Αρχικά, μπορούμε να βρούμε μια αντιστοίχιση που προβάλλει το διάστημα χαρακτηριστικών V σε ένα διάνυσμα χώρο W με μετασχηματισμένη τοπολογία:

$$f : V = \mathbb{R}^{|x|} \mapsto W = \mathbb{R}^m \leftrightarrow |x| \leq m$$

Στη συνέχεια, μπορούμε να αντικαταστήσουμε τυχόν εσωτερικά γινόμενα που θα υπολογίζαμε μεταξύ δύο διανυσμάτων χαρακτηριστικών στο μη μετασχηματισμένο διανυσματικό χώρο V με εκείνο του αντίστοιχου μετασχηματισμένου χώρου:

$$x_i, x_j \in V : k(x_i \cdot x_j) = \chi_i \cdot \chi_j | \chi_i, \chi_j \in W \leftrightarrow \chi_i = f(x_i) \wedge \chi_j = f(x_j)$$


Υπάρχει μια συνάρτηση που αντικαθιστά το εσωτερικό γινόμενο δύο διανυσμάτων στον αρχικό χώρο με το μετασχηματισμένο εσωτερικό γινόμενο, όσον αφορά τα μη μετασχηματισμένα διανύσματα. Αυτή η συνάρτηση ονομάζεται πυρήνας k του SVM. ο πυρήνας είναι τέτοιος ώστε $k(x_i, x_j) = f(x_i) \cdot f(x_j)$,

Το υπερεπίπεδο h_W που υπολογίζεται στον μετασχηματισμένο διανυσματικό χώρο έχει ένα κανονικό διάνυσμα $\vec{\omega} = \sum \alpha y f(x)$. Αυτό, με τη σειρά του, μας επιτρέπει να το υπολογίσουμε ως $h_W = \omega \cdot \chi + \beta$ στον μετασχηματισμένο χώρο W και με τις μετασχηματισμένες παρατηρήσεις $\chi = f(x)$.

Στη συνέχεια, μπορούμε να προβάλουμε το υπερεπίπεδο στον αρχικό διανυσματικό χώρο V . Η προβολή πραγματοποιείται μέσω της αντίστροφης χαρτογράφησης f^{-1} , όπως $h_V = f^{-1}(h_W)$.

5.6.α Μη γραμμικοί πυρήνες για SVM

Η προσέγγιση ταξινόμησης με SVM στηρίζεται και στη δυνατότητα μοντελοποίησης πολύπλοκων, μη- γραμμικών ορίων τάξεων σε πολυδιάστατους χώρους χαρακτηριστικών μέσω της έννοιας των συναρτήσεων kernel (Man Duc Chuc κ.α, 2016). Για το σκοπό αυτό υπάρχουν πολυάριθμες τέτοιες συναρτήσεις, όπως οι Polynomial-based και Radial Basis Function (RBF) (συναρτήσεις που θα αναλυθούν σε επόμενα κεφάλαια). Πρακτικά η συνάρτηση RBF είναι η πιο διαδεδομένη και έχει χρησιμοποιηθεί σε διάφορες μελέτες (Foody & Mathur 20041, Guo κ.α 2012, Li κ.α 2014, Yu κ.α 2012). Με αυτό τον τρόπο τα SVM προσπαθούν να μεγιστοποιήσουν το περιθώριο διαχωρισμού (margin), δηλαδή την απόσταση ανάμεσα στα πλησιέστερα δείγματα εκπαίδευσης (ή Support Vectors) και του ίδιου του υπερ- επιπέδου. Τα SVM προβάλλουν τα διανύσματα αυτά (Vectors) στον πολυδιάστατο χώρο χαρακτηριστικών με τη χρήση των kernel συναρτήσεων, ενώ στην συνέχεια εφαρμόζουν το βέλτιστο υπερεπίπεδο που διαχωρίζει τις τάξεις χρησιμοποιώντας τη βέλτιστη συνάρτηση.



Σχήμα 5.6.α.1 Διαδικασία SVM

Μπορούμε τώρα να απαριθμήσουμε τους πιο συνηθισμένους τύπους συναρτήσεων πυρήνα που χρησιμοποιούνται σε μη γραμμικούς SVM. Αυτοί αντιστοιχούν σε αντίστοιχους μετασχηματισμούς μεταξύ του αρχικού χώρου χαρακτηριστικών V και του μετασχηματισμένου W . Οι πιο συνηθισμένοι πυρήνες είναι:

- Ο πολυώνυμος πυρήνας βαθμού $(x_i, x_j)^p$
- Πυρήνας συνάρτησης ακτινικής βάσης, $e^{-\alpha \|x_i - x_j\|^2}$, όπου $\alpha < 0$
- Ο σιγμοειδής, $\tanh(a \cdot x_i \cdot x_j + c)$

Η επιλογή του πυρήνα που θα χρησιμοποιηθεί εξαρτάται από το πρόβλημα που αντιμετωπίζουμε. Ο προσδιορισμός βασίζεται σε κάθε περίπτωση σε ευρετική και έχει μικρή

θεωρητική αξία. Στην πράξη, όλοι οι πυρήνες δοκιμάζονται με τη σειρά μέχρι να βρεθεί ένας του οποίου η ακρίβεια είναι ικανοποιητική.

Για να εφαρμόσουμε την SVM τεχνική στη λύση ενός μη γραμμικού προβλήματος ταξινόμησης, υιοθετούμε τη φιλοσοφία της απεικόνισης των διανυσμάτων χαρακτηριστικών σε ένα χώρο μεγαλύτερης διάστασης, όπου αναμένουμε ότι, με μεγάλη πιθανότητα, οι κλάσεις θα είναι γραμμικώς διαχωρίσιμες. Αυτό μας το εγγυάται το θεώρημα Cover. Η απεικόνιση έχει ως εξής :

$$x \rightarrow \varphi(x) \in H$$

όπου η διάσταση του H είναι μεγαλύτερη του R¹ και, ανάλογα με την επιλογή της (μη γραμμικής) $\varphi(\cdot)$, μπορεί να είναι άπειρη. Επιπλέον, αν η συνάρτηση απεικόνισης επιλεγεί προσεχτικά, μέσα από μια οικογένεια συναρτήσεων που παρουσιάζουν ορισμένες επιθυμητές ιδιότητες, τότε το εσωτερικό γινόμενο μεταξύ εικόνων ($\varphi(x_1), \varphi(x_2)$), μετά την απεικόνιση των δύο σημείων μπορεί να γραφτεί ως

$$\langle \varphi(x_1), \varphi(x_2) \rangle = k(x_1, x_2)$$

όπου $\langle \cdot, \cdot \rangle$ δηλώνει το εσωτερικό γινόμενο στον H και $k(\cdot, \cdot)$ είναι συνάρτηση γνωστή ως συνάρτηση πυρήνα (kernel function). Δηλαδή, τα εσωτερικά γινόμενα στον υψηλότερης διάστασης χώρο, μπορούν να υπολογιστούν αξιοποιώντας τη σχετική συνάρτηση πυρήνα που λειτουργεί στον αρχικό, χαμηλής διάστασης χώρο. Ο χώρος H, που σχετίζεται με την $k(\cdot, \cdot)$ είναι γνωστός ως Χώρος Hilbert με Αναπαραγωγό Πυρήνα (Reproducing Kernel Hilbert Space- RKHS)

Ένα αξιοσημείωτο χαρακτηριστικό της SVM βελτιστοποίησης είναι ότι όλες οι πράξεις μπορούν να εκφραστούν με τη βοήθεια εσωτερικών γινομένων. Επομένως, για να λύσουμε ένα γραμμικό πρόβλημα στο χώρο υψηλότερης διάστασης (μετά την απεικόνιση), αρκεί να αντικαταστήσουμε τα εσωτερικά γινόμενα με τις αντίστοιχες πράξεις πυρήνα. Τυπικά παραδείγματα συναρτήσεων πυρήνα είναι (α) η συνάρτηση ακτινωτής βάσης (radial basis function -RBF), που ορίζεται ως

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

όπου σ είναι παράμετρος που ρυθμίζεται από τον χρήστη και καθορίζει το ρυθμό πτώσης της $k(x, y)$ προς το μηδέν καθώς το y απομακρύνεται από το x και (β) η πολυωνυμική συνάρτηση που ορίζεται ως

$$k(x, y) = (x^T y + \beta)^n$$

όπου β και n είναι παράμετροι που ρυθμίζονται από το χρήστη.

Παρατηρούμε ότι, η λύση ενός γραμμικού προβλήματος σε χώρο μεγαλύτερης διάστασης είναι ισοδύναμη με τη λύση ενός μη γραμμικού προβλήματος στον αρχικό χώρο. Αυτό εύκολα επαληθεύεται. Όπως στην Εξίσωση (5.6), το υπερεπίπεδο που υπολογίζεται από την SVM μέθοδο στον υψηλής διάστασης χώρο H, θα είναι το

$$w = \sum_{i=1}^N \lambda_i y_i \varphi(x_i)$$

Δοθέντος ενός αγνώστου x , απεικονίζουμε πρώτα στο $\varphi(x)$ και στη συνέχεια ελέγχουμε αν το αποτέλεσμα της παρακάτω έκφρασης είναι μικρότερο ή μεγαλύτερο του μηδενός

$$\begin{aligned} g(x) &\equiv \langle w, \varphi(x) \rangle + w_0 = \sum_{i=1}^N \lambda_i y_i \langle \varphi(x), \varphi(x_i) \rangle + w_0 \\ &= \sum_{i=1}^N \lambda_i y_i k(x, x_i) + w_0 \end{aligned}$$

Από την προηγούμενη σχέση γίνεται φανερό ότι στην πράξη, δεν απαιτείται η αναλυτική μορφή της συνάρτησης $\varphi(\cdot)$. Αρκεί να γνωρίζουμε τη συνάρτηση πυρήνα, επειδή τα δεδομένα εμφανίζονται μόνο σε εσωτερικά γινόμενα.

ΚΕΦΑΛΑΙΟ 6 Νευρωνικά Δίκτυα (ΝΔ) – Neural Networks (NNs)

6.1 Εισαγωγή

Η ταξινόμηση είναι ένας από τους πιο ενεργούς τομείς έρευνας και εφαρμογής νευρωνικών δικτύων. Η βιβλιογραφία είναι τεράστια και συνεχώς αυξάνεται. Το τρέχον κεφάλαιο αναλύει την ταξινόμηση με νευρωνικά δίκτυα και επιπλέον συνοψίζει μερικές από τις σημαντικότερες εξελίξεις στην έρευνα ταξινόμησης με νευρωνικά δίκτυα.

Η μελέτη του ανθρώπινου εγκεφάλου είναι χιλιάδων ετών. Με την έλευση των σύγχρονων ηλεκτρονικών, ήταν φυσικό να προσπαθήσουμε να αξιοποιήσουμε αυτή τη διαδικασία σκέψης. Το πρώτο βήμα προς τα τεχνητά νευρωνικά δίκτυα ήρθε το 1943 όταν ο Warren McCulloch, νευροφυσιολόγος και ένας νεαρός μαθηματικός, ο Walter Pitts, έγραψαν μια εργασία για τον τρόπο λειτουργίας των νευρώνων. Διαμόρφωσαν ένα απλό νευρωνικό δίκτυο με ηλεκτρικά κυκλώματα. Τα νευρωνικά δίκτυα, με την αξιοσημείωτη ικανότητά τους να αντλούν νόημα από περίπλοκα ή ανακριβή δεδομένα, μπορούν να χρησιμοποιηθούν για την εξαγωγή μοτίβων και τον εντοπισμό τάσεων που είναι πολύ περίπλοκες για να γίνουν αντιληπτές είτε από ανθρώπους είτε από άλλες τεχνικές υπολογιστών.

Αξίζει να αναφερθεί, πως η επεξεργασία στους βιολογικούς νευρώνες συντελείται πολύ πιο αργά απ' ό τι στα σύγχρονα ψηφιακά συστήματα. Όμως ο εγκέφαλος αντισταθμίζει την σχετικά αργή ταχύτητα λειτουργίας των νευρώνων, με τον πολύ μεγάλο αριθμό συνδέσεων μεταξύ των νευρώνων. Υπολογίζεται πως ο φλοιός του ανθρώπινου εγκεφάλου έχει 107 νευρώνες και 6010 συνδέσεις μεταξύ αυτών, γεγονός που είναι αδύνατον να προσομοιωθεί από κάποιο τεχνητό υπολογιστικό σύστημα, τουλάχιστον με τις μέχρι τώρα τεχνολογικές δυνατότητες.

Τα νευρωνικά δίκτυα είναι μια ιδιαίτερη προσέγγιση στη δημιουργία συστημάτων με νοημοσύνη καθώς αποφεύγουν να αναπαραστήσουν ρητά τη γνώση και να υιοθετήσουν ειδικά σχεδιασμένους αλγορίθμους αναζήτησης. Ο ανθρώπινος εγκέφαλος είναι ένας εξαιρετικά πολύπλοκος, μη γραμμικός, παράλληλος υπολογιστής. Βασικό δομικό στοιχείο του εγκεφάλου είναι τα νευρικά κύτταρα τα οποία δημιουργούν ένα πυκνό δίκτυο επικοινωνίας μεταξύ τους. Κίνητρο για τη μελέτη του νευρώνα και των νευρωνικών δικτύων είναι η ελπίδα ανακάλυψης ενός νέου υπολογιστικού μοντέλου βασισμένου σε μια δικτυακή δομή παρόμοια με αυτή του εγκεφάλου. Αυτή η καινούργια υπολογιστική πλατφόρμα - γνωστή ως *Connectionist Model* - θα είναι πιο κατάλληλη για ανάπτυξη ευφυών αλγορίθμων και γενικότερα διαδικασιών σχετιζόμενων με τη νοημοσύνη, όπως η μάθηση, η μνήμη, η γενίκευση, η συσταδοποίηση προτύπων κ.λπ.

Τα τυπικά τεχνητά νευρωνικά δίκτυα χρησιμοποιούν πολύ απλοποιημένα μοντέλα νευρώνων, τέτοια ώστε να διατηρούν μόνο τα πολύ αδρά χαρακτηριστικά των λεπτομερών μοντέλων που χρησιμοποιούνται στη νευρολογία. Θα έλεγε κανείς ότι αυτά τα τεχνητά νευρωνικά μοντέλα έχουν ελάχιστη σχέση με τα βιολογικά νευρωνικά συστήματα. Ωστόσο πιστεύεται ότι οι λεπτομέρειες δεν έχουν ιδιαίτερη σημασία στην κατανόηση της ευφυούς συμπεριφοράς των βιολογικών νευρωνικών συστημάτων. Ακόμη και αυτά τα απλά μοντέλα νευρώνων μπορούν να δημιουργήσουν ιδιαίτερος ενδιαφέροντα δίκτυα, αρκεί να πληρούν δύο βασικά χαρακτηριστικά :

- A. Οι νευρώνες πρέπει να έχουν ρυθμιζόμενες παραμέτρους ώστε να διευκολύνεται η διαδικασία της μάθησης - μια ιδιότητα γνωστή ως **πλαστικότητα** των νευρώνων, και
- B. Το δίκτυο πρέπει να αποτελείται από μεγάλο πλήθος νευρώνων ώστε να επιτυγχάνεται **παράλληλισμός** της επεξεργασίας και **κατανομή** των πληροφοριών.

Η πρόκληση που αντιμετωπίζει η θεωρία των τεχνητών νευρωνικών δικτύων είναι η εύρεση κατάλληλων αλγορίθμων εκπαίδευσης των δικτύων και ανάκλησης των πληροφοριών που

αυτά περιέχουν, ώστε να προσομοιάζονται ευφυείς διαδικασίες όπως αυτές που αναφέρθηκαν παραπάνω. Για την επίτευξη αυτού του στόχου απαιτείται ο ορισμός του κατάλληλου περιβάλλοντος εκπαίδευσης, π.χ. αν το δίκτυο θα εκπαιδεύεται με επίβλεψη, δηλαδή με τη χρήση κάποιων δεδομένων ως οδηγών-δασκάλων, ή αν θα αφήνεται μόνο του να αυτό-οργανωθεί και με ποιο συγκεκριμένο κριτήριο και στόχο.

Τα νευρωνικά δίκτυα λοιπόν υιοθετούν μια διαφορετική προσέγγιση στην επίλυση προβλημάτων από αυτήν των συμβατικών υπολογιστών. Οι συμβατικοί υπολογιστές χρησιμοποιούν αλγοριθμική προσέγγιση, δηλαδή ο υπολογιστής ακολουθεί μια σειρά οδηγιών για να λύσει ένα πρόβλημα. Αν εξαιρέσουμε την περίπτωση κατά την οποία είναι γνωστά τα συγκεκριμένα βήματα που πρέπει να ακολουθήσει ο υπολογιστής, ο υπολογιστής δεν μπορεί να λύσει το πρόβλημα. Αυτό περιορίζει την ικανότητα επίλυσης προβλημάτων των συμβατικών υπολογιστών σε προβλήματα που ήδη καταλαβαίνουμε και ξέρουμε πώς να λύσουμε. Αλλά οι υπολογιστές θα ήταν πολύ πιο χρήσιμοι αν μπορούσαν να κάνουν πράγματα που δεν ξέρουμε ακριβώς πώς να κάνουμε. Τα νευρωνικά δίκτυα επεξεργάζονται πληροφορίες με παρόμοιο τρόπο με τον ανθρώπινο εγκέφαλο. Το δίκτυο αποτελείται από μεγάλο αριθμό εξαιρετικά διασυνδεδεμένων στοιχείων επεξεργασίας (νευρώνες) που λειτουργούν παράλληλα για να επιλύσουν ένα συγκεκριμένο πρόβλημα. Τα νευρωνικά δίκτυα μαθαίνουν με το παράδειγμα. Δεν μπορούν να προγραμματιστούν για να εκτελέσουν μια συγκεκριμένη εργασία. Τα παραδείγματα πρέπει να επιλεγούν προσεκτικά, διαφορετικά ο χρήσιμος χρόνος χάνεται ή ακόμη χειρότερα το δίκτυο μπορεί να λειτουργεί εσφαλμένα. Το μειονέκτημα είναι ότι επειδή το δίκτυο ανακαλύπτει πώς να λύσει το πρόβλημα από μόνο του, η λειτουργία του μπορεί να είναι απρόβλεπτη. Από την άλλη πλευρά, οι συμβατικοί υπολογιστές χρησιμοποιούν μια γνωστική προσέγγιση για την επίλυση προβλημάτων. Ο τρόπος επίλυσης του προβλήματος πρέπει να είναι γνωστός και να δηλώνεται σε μικρές σαφείς οδηγίες. Αυτές οι οδηγίες στη συνέχεια μετατρέπονται σε πρόγραμμα γλωσσών υψηλού επιπέδου και στη συνέχεια σε κώδικα μηχανής που μπορεί να καταλάβει ο υπολογιστής. Αυτά τα μηχανήματα είναι εντελώς προβλέψιμα. αν κάτι πάει στραβά οφείλεται σε σφάλμα λογισμικού ή υλικού.


Τα νευρωνικά δίκτυα και οι συμβατικοί αλγοριθμικοί υπολογιστές δεν ανταγωνίζονται, αλλά αντιθέτως, αλληλοσυμπληρώνονται. Υπάρχουν πρότζεκτ που ταιριάζουν περισσότερο σε μια αλγοριθμική προσέγγιση όπως αριθμητικές πράξεις, και πρότζεκτ που είναι πιο κατάλληλα για νευρωνικά δίκτυα. Ακόμα περισσότερο, ένας μεγάλος αριθμός πρότζεκτ απαιτεί συστήματα που χρησιμοποιούν συνδυασμό των δύο προσεγγίσεων (συνήθως ένας συμβατικός υπολογιστής χρησιμοποιείται για την επίβλεψη του νευρωνικού δικτύου) προκειμένου να έχουμε τη βέλτιστη απόδοση.

Στην παρούσα εργασία, θα ασχοληθούμε με την επιβλεπόμενη εκπαίδευση των τεχνητών νευρωνικών δικτύων, καθώς η ταξινόμηση ανήκει στη μάθηση υπό επίβλεψη.

6.2 Νευρωνικό Δίκτυο Perceptron

Θα ξεκινήσουμε, εξηγώντας έναν τύπο τεχνητού νευρώνα που ονομάζεται perceptron. Τα Perceptrons αναπτύχθηκαν τη δεκαετία του 1950 και του 1960 από τον επιστήμονα Frank Rosenblatt, εμπνευσμένο από προηγούμενες εργασίες των Warren McCulloch και Walter Pitts. Σήμερα, είναι πιο συνηθισμένο να χρησιμοποιούμε άλλα μοντέλα τεχνητών νευρώνων.

Πώς λειτουργούν λοιπόν τα perceptrons; Ένα perceptron παίρνει αρκετές δυαδικές εισόδους, x_1, x_2, \dots , και παράγει μία μόνο δυαδική έξοδο:



Σχήμα 6.1 Μοντέλο Perceptron

Στο παράδειγμα που παρουσιάζεται στο Σχήμα 5.1 το perceptron έχει τρεις εισόδους, x_1 , x_2 , x_3 . Γενικά θα μπορούσε να έχει περισσότερες ή λιγότερες εισόδους. Ο Rosenblatt πρότεινε έναν απλό κανόνα για τον υπολογισμό της εξόδου. Εισήγαγε τα βάρη : w_1, w_2, \dots , τα οποία είναι πραγματικοί αριθμοί που εκφράζουν τη σημασία των αντίστοιχων εισόδων στην έξοδο. Η έξοδος του νευρώνα, ή οποία μπορεί να είναι είτε 0 είτε 1, καθορίζεται από το αν το σταθμισμένο άθροισμα $\sum_j x_j w_j$ είναι μικρότερο ή μεγαλύτερο από κάποια τιμή κατωφλίου (ορίου). Ομοίως με τα βάρη, το κατώφλι είναι ένας πραγματικός αριθμός που αποτελεί παράμετρο του νευρώνα. Για να το εκφράσουμε με πιο ακριβείς αλγεβρικές λέξεις:

Έξοδος = 0 αν $\sum_j x_j w_j \leq \text{όριο}$, ή

Έξοδος = 1 αν $\sum_j x_j w_j > \text{όριο}$.

Αυτό είναι το βασικό μαθηματικό μοντέλο. Ένας τρόπος με τον οποίο θα μπορούσαμε να παραλληλίσουμε το perceptron είναι ότι είναι μια συσκευή που λαμβάνει αποφάσεις ζυγίζοντας στοιχεία. Ας δώσουμε ένα παράδειγμα. Ας υποθέσουμε ότι το Σαββατοκύριακο πλησιάζει και έχουμε ακούσει ότι θα γίνει μια γιορτή τυριού στην πόλη μας. Προσπαθούμε να αποφασίσουμε αν θα πάμε ή όχι στο φεστιβάλ. Μπορούμε να αποφασίσουμε σταθμίζοντας τρεις παράγοντες:

1. Είναι καλός ο καιρός;
2. Ο φίλος ή η φίλη μας θέλει να σας συνοδεύσει;
3. Είναι το φεστιβάλ κοντά σε συγκοινωνία; (Μη διαθέσιμο αυτοκίνητο).


Μπορούμε να αναπαραστήσουμε αυτούς τους τρεις παράγοντες με αντίστοιχες δυαδικές μεταβλητές x_1 , x_2 και x_3 . Για παράδειγμα, θα είχαμε $x_1 = 1$ εάν ο καιρός είναι καλός και $x_1 = 0$ εάν ο καιρός είναι κακός. Ομοίως, $x_2 = 1$ αν ο φίλος ή η φίλη μας θέλει να φύγει και $x_2 = 0$ αν όχι. Και παρόμοια πάλι για τη μεταβλητή x_3 .

Τώρα, ας υποθέσουμε ότι λατρεύουμε απολύτως το τυρί, τόσο πολύ που είμαστε χαρούμενοι που θα πάμε στο φεστιβάλ ακόμα κι αν ο φίλος ή η φίλη μας δεν ενδιαφέρεται. Αλλά ίσως πραγματικά σιχαινόμαστε τον κακό καιρό και δεν υπάρχει περίπτωση να παμε στο φεστιβάλ αν ο καιρός είναι κακός. Μπορούμε να χρησιμοποιήσουμε perceptrons για να μοντελοποιήσουμε αυτό το είδος λήψης αποφάσεων. Ένας τρόπος για να γίνει αυτό είναι να επιλέξουμε ένα βάρος $w_1 = 6$ για τις καιρικές συνθήκες και $w_2 = 2$ και $w_3 = 2$ για τις άλλες συνθήκες. Η μεγαλύτερη τιμή του w_1 υποδηλώνει ότι ο καιρός έχει μεγάλη σημασία για εμάς, πολύ περισσότερο από το αν ο φίλος ή η φίλη μας θα έρθει μαζί μας ή από την εγγύτητα της δημόσιας συγκοινωνίας. Τέλος, ας υποθέσουμε ότι επιλέξαμε ένα όριο 5 για το perceptron. Με αυτές τις επιλογές, το perceptron εφαρμόζει το επιθυμητό μοντέλο λήψης αποφάσεων, βγάζοντας 1 όταν ο καιρός είναι καλός και 0 όταν ο καιρός είναι κακός. Δεν έχει καμία διαφορά στην έξοδο αν ο φίλος ή η φίλη μας θέλει να πάει ή αν η δημόσια συγκοινωνία είναι κοντά.

Μεταβάλλοντας τα βάρη και το κατώφλι(όριο), μπορούμε να πάρουμε διαφορετικά μοντέλα λήψης αποφάσεων. Για παράδειγμα, ας υποθέσουμε τώρα ότι επιλέξαμε ένα όριο 3. Στη

συνέχεια, το perceptron θα αποφασίσει ότι πρέπει να πάμε στο φεστιβάλ κάθε φορά που ο καιρός είναι καλός ή όταν το φεστιβάλ είναι κοντά στη δημόσια συγκοινωνία και ο φίλος ή η φίλη μας είναι πρόθυμος να συμμετάσχει μαζί μας. Με άλλα λόγια, θα ήταν ένα διαφορετικό μοντέλο λήψης αποφάσεων. Η πτώση του κατωφλίου - ορίου σημαίνει ότι είμαστε πιο πρόθυμοι να πάμε στο φεστιβάλ.

Προφανώς, το perceptron δεν είναι ένα πλήρες μοντέλο λήψης αποφάσεων από τον άνθρωπο! Αλλά αυτό που δείχνει το παράδειγμα είναι πώς ένα perceptron μπορεί να σταθμίσει διαφορετικά είδη αποδείξεων για να λάβει αποφάσεις. Και θα πρέπει να φαίνεται αληθοφανές ότι ένα σύνθετο δίκτυο από perceptrons θα μπορούσε να λάβει πολύ λεπτές αποφάσεις:




Σχήμα 6.2 Σύνθετο δίκτυο Perceptron - παράδειγμα 1ο

Σε αυτό το δίκτυο, η πρώτη στήλη των perceptrons - αυτό που θα ονομάσουμε το πρώτο στρώμα των perceptrons - παίρνει τρεις πολύ απλές αποφάσεις, ζυγίζοντας τα στοιχεία εισόδου. Τι γίνεται με τα perceptrons στο δεύτερο στρώμα; Κάθε ένα από αυτά τα perceptrons λαμβάνει μια απόφαση σταθμίζοντας τα αποτελέσματα από το πρώτο επίπεδο λήψης αποφάσεων. Με αυτόν τον τρόπο ένα perceptron στο δεύτερο στρώμα μπορεί να λάβει μια απόφαση σε πιο πολύπλοκο και πιο αφηρημένο επίπεδο από τα perceptrons στο πρώτο επίπεδο. Και ακόμη πιο πολύπλοκες αποφάσεις μπορούν να ληφθούν από το perceptron στο τρίτο επίπεδο. Με αυτόν τον τρόπο, ένα δίκτυο πολλαπλών στρωμάτων perceptrons μπορεί να εμπλακεί στη σύνθετη λήψη αποφάσεων.

Στο παραπάνω δίκτυο τα perceptrons μοιάζουν να έχουν πολλαπλές εξόδους. Στην πραγματικότητα, εξακολουθούν να αποτελούν μια ενιαία έξοδο. Τα πολλαπλά βέλη εξόδου είναι απλώς ένας χρήσιμος τρόπος για να υποδείξουμε ότι η έξοδος από ένα perceptron χρησιμοποιείται ως είσοδος σε πολλά άλλα perceptrons.


6.3 Τεχνητά Νευρωνικά Δίκτυα – ΤΝΔ

Ας υποθέσουμε ότι έχουμε το παρακάτω δίκτυο:



Σχήμα 6.3 Νευρωνικό δίκτυο με ένα κρυφό στρώμα

Όπως αναφέρθηκε προηγουμένως, το αριστερότερο στρώμα σε αυτό το δίκτυο ονομάζεται στρώμα εισόδου και οι νευρώνες μέσα στο στρώμα ονομάζονται νευρώνες εισόδου. Το δεξί ή το επίπεδο εξόδου περιέχει τους νευρώνες εξόδου, ή, στην συγκεκριμένη περίπτωση, έναν νευρώνα εξόδου. Το μεσαίο στρώμα ονομάζεται κρυφό στρώμα, αφού οι νευρώνες σε αυτό το στρώμα δεν είναι ούτε εισοδοί ούτε έξοδοι. Το παραπάνω δίκτυο έχει μόνο ένα κρυφό επίπεδο, αλλά ορισμένα δίκτυα έχουν πολλά κρυφά επίπεδα. Για παράδειγμα, το ακόλουθο δίκτυο τεσσάρων επιπέδων έχει δύο κρυφά επίπεδα:



Σχήμα 6.4 ΤΝΔ με δύο κρυφά επίπεδα


Κάπως συγκεκριμένα και για ιστορικούς λόγους, τέτοια δίκτυα πολλαπλών επιπέδων καλούνται μερικές φορές πολυστρωματικά perceptrons ή MLPs, παρά το ότι αποτελούνται από σιγμοειδείς νευρώνες και όχι από perceptrons.

Μέχρι τώρα, αναφερθήκαμε στα νευρωνικά δίκτυα όπου η έξοδος από ένα επίπεδο χρησιμοποιείται ως είσοδος στο επόμενο επίπεδο. Τέτοια δίκτυα ονομάζονται νευρωνικά δίκτυα πρόσθιας τροφοδότησης. Αυτό σημαίνει ότι δεν υπάρχουν βρόχοι στο δίκτυο - οι πληροφορίες παρέχονται πάντα προς τα εμπρός, ποτέ προς τα πίσω. Ωστόσο, υπάρχουν και άλλα μοντέλα τεχνητών νευρωνικών δικτύων στα οποία είναι δυνατοί οι βρόχοι ανάδρασης.

Ένα νευρωνικό δίκτυο λοιπόν, είναι ένας τεράστιος παράλληλος επεξεργαστής με κατανομημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από τη φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση που την καθιστά διαθέσιμη για χρήση. Συνήθως αποτελούνται από εκατοντάδες απλές μονάδες επεξεργασίας (αλληλουχία διασυνδεδεμένων Στοιχείων Επεξεργασίας (Processing Units - PUs)), που συνδέονται μεταξύ τους σε ένα πολύπλοκο δίκτυο επικοινωνίας και παράλληλα είναι προγραμματισμένες να μιμούνται τις ιδιότητες των βιολογικών νευρώνων. Ένα σύνολο κόμβων και συνδέσεων μεταξύ τους είναι τα δύο κύρια συστατικά ενός δικτύου. Κάθε μονάδα ή κόμβος είναι ένα απλοποιημένο μοντέλο πραγματικού νευρώνα που στέλνει ένα νέο σήμα ή πυροδοτεί εάν λάβει ένα αρκετά ισχυρό σήμα εισόδου από τους άλλους κόμβους στους οποίους είναι συνδεδεμένος. Θα μπορούσε να πει κανείς ότι ο τρόπος λειτουργίας των

βιολογικών νευρώνων είναι αντίστοιχος με τον δυαδικό τρόπο λειτουργίας των ηλεκτρονικών υπολογιστών. Συγκεκριμένα ένας νευρώνας μπορεί να βρίσκεται είτε σε 'ενεργή' κατάσταση είτε σε 'μη ενεργή'. Ο εγκέφαλος λαμβάνει ερεθίσματα ως εισόδους, τα επεξεργάζεται και εξάγει ανάλογα αποτελέσματα. Ένα τεχνητό νευρωνικό δίκτυο συνδέεται με πολλούς νευρώνες, όπως γίνεται και στον εγκέφαλό μας. Παίρνει εισόδους, κάνει κάποια μαθηματικά για την επεξεργασία των εισόδων και μετά εξάγει τα αποτελέσματα. Αυτές οι βιολογικά εμπνευσμένες μέθοδοι υπολογισμού πιστεύεται ότι είναι η επόμενη σημαντική πρόοδος στη βιομηχανία των υπολογιστών. Ακόμη και απλοί εγκέφαλοι ζώων είναι ικανοί για λειτουργίες που είναι αδύνατες προς το παρόν για έναν υπολογιστή.

Σε αντίθεση με τα μαθηματικά μοντέλα, τα μοντέλα νευρωνικών δικτύων μπορούν να ανιχνεύσουν τις σχέσεις μεταξύ των παραμέτρων χωρίς να εξάγουν αυτές τις σχέσεις, και αυτό έχει καταστήσει τα νευρωνικά δίκτυα ένα ισχυρό εργαλείο ταξινόμησης και μοντελοποίησης. Χρησιμοποιείται για αναγνώριση ομιλίας, ανάλυση εικόνας, προσαρμοστικό έλεγχο κλπ. Αυτές οι εφαρμογές γίνονται μέσω μιας διαδικασίας μάθησης, αντίστοιχης της εκμάθησης στο βιολογικό σύστημα, η οποία περιλαμβάνει την προσαρμογή μεταξύ των νευρώνων μέσω συναπτικής σύνδεσης.



Σχήμα 6.5 Ένα απλό νευρωνικό δίκτυο

Ένας νευρώνας μπορεί να παράγει ηλεκτρικό σήμα, διάρκειας της τάξης ενός msec, το οποίο και συνεχίζει την πορεία του μέσα στο νευρωνικό δίκτυο, από νευρώνα σε νευρώνα, χωρίς να ελαττωθεί καθόλου. Το ηλεκτρικό αυτό σήμα, οφείλεται στην διαφορά δυναμικού που δημιουργείται στην μεμβράνη του κυττάρου μεταξύ της εσωτερικής και εξωτερικής του επιφάνειας. Έτσι λοιπόν όταν καταφθάνουν όλα τα εκπεμπόμενα σήματα σε έναν νευρώνα, αθροίζονται τα ηλεκτρικά δυναμικά τους και υπάρχουν 2 περιπτώσεις:

- Εάν αυτό το άθροισμα ξεπεράσει μια δεδομένη τιμή, τότε ο νευρώνας διεγείρεται, θεωρείται 'ενεργός' και εκπέμπει μέσω του άξονά του ένα ηλεκτρικό σήμα
- Εάν αυτό το άθροισμα δεν ξεπεράσει τη δεδομένη τιμή τότε ο νευρώνας παραμένει 'μη ενεργός' και το πλεονάζων δυναμικό χάνεται.

Σημειώνεται πως το εισερχόμενο σε ένα νευρώνα σήμα μπορεί να είναι διεγερτικό ή ανασταλτικό αναλόγως με το εάν βοηθάει το συνολικό άθροισμα να φτάσει τη

δεδομένη τιμή 'κατώφλι' ή το αντίθετο.

Επομένως, ο τεχνητός νευρώνας (*artificial neuron*) είναι ένα υπολογιστικό μοντέλο τα μέρη του οποίου μπορεί να αντιστοιχιστούν άμεσα με αυτά του βιολογικού νευρώνα. Όπως απεικονίζεται Σχήμα 5,6, ένας τεχνητός νευρώνας δέχεται κάποια *σήματα εισόδου* x_1, x_2, \dots, x_n , τα οποία, σε αντίθεση με τους ηλεκτρικούς παλμούς του εγκεφάλου αντιστοιχούν σε συνεχείς μεταβλητές.


Κάθε τέτοιο σήμα εισόδου μεταβάλλεται από μια *τιμή βάρους* w_i (weight) ο ρόλος της οποίας είναι αντίστοιχος του ρόλου της σύναψης στο βιολογικό νευρώνα. Η τιμή βάρους μπορεί να είναι θετική ή αρνητική, σε αντιστοιχία με την επιταχυντική ή επιβραδυντική λειτουργία της σύναψης. Οι συνάψεις αποτελούν επί της ουσίας τον τρόπο σύνδεσης των νευρώνων μεταξύ τους και χαρακτηρίζονται από το αντίστοιχο βάρος σύναψης κάθε σήματος εισόδου.

Κάθε είσοδος x_i "ζυγίζεται" με ένα βάρος w_i και τα αποτελέσματα αθροίζονται μέσω της *συνάρτησης αθροίσματος* (summation function) F :

$$F = \sum_i^n x_i w_i$$

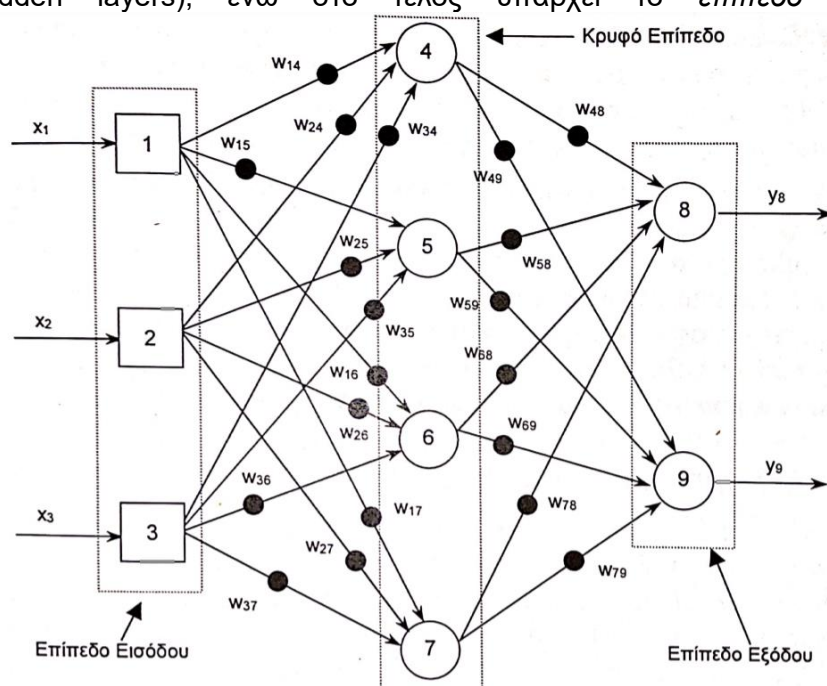
Το σώμα του τεχνητού νευρώνα χωρίζεται σε δύο μέρη, τον *αθροιστή* (*sum*) ο οποίος προσθέτει τα επηρεασμένα από τα βάρη σήματα εισόδου παράγοντας την ποσότητα S και τη *συνάρτηση ενεργοποίησης* (*activation function*), ένα είδος φίλτρου το οποίο διαμορφώνει την τελική τιμή του σήματος εξόδου y , σε συνάρτηση με την ποσότητα S και την τιμή κατωφλίου της συνάρτησης ενεργοποίησης. Ο πρωταρχικός σκοπός των συναρτήσεων ενεργοποίησης είναι η εκτέλεση του μη γραμμικού μετασχηματισμού σε είσοδο και η ικανότητά του να επιλύει πολύπλοκα προβλήματα. Επιπλέον, οι συναρτήσεις ενεργοποίησης είναι υπεύθυνες για την απενεργοποίηση των νευρώνων ή την ενεργοποίηση αυτών με τέτοιο τρόπο ώστε να πάρουν την επιθυμητή έξοδο. Διευκρινίζεται ότι η μοναδικότητα της εξόδου του νευρώνα έχει να κάνει με την τιμή εξόδου και όχι με το πόσες γραμμές-εξόδοι υπάρχουν στο δεξιό μέρος. Μπορεί δηλαδή ένας νευρώνας να έχει πολλές εξόδους, αλλά όλες θα έχουν την ίδια τιμή.

Μερικές φορές θεωρούμε ότι, εκτός από τα εισερχόμενα σήματα και τα αντίστοιχα βάρη, ο νευρώνας έχει και κάποιο βάρος w_0 , το οποίο ονομάζεται *πόλωση* (*bias*) ή *παράγοντας προδιάθεσης* του νευρώνα. Η μόνη διαφορά αυτού του βάρους από τα υπόλοιπα συνίσταται στο ότι επιδρά συνεχώς σε μία τιμή εισόδου $x_0=1$. Ο όρος αυτός δεν θα πρέπει να αποδίδεται στο εσωτερικό του νευρώνα. Πρόκειται για ένα εξωτερικό ερέθισμα το οποίο προστίθεται μαζί με τα υπόλοιπα εισερχόμενα σήματα. Μερικές φορές χρησιμοποιείται για να καθορισθεί έμμεσα και δυναμικά η θέση της συνάρτησης ενεργοποίησης στο καρτεσιανό επίπεδο x - y .



Σχήμα 6.6 Μοντέλο τεχνητού νευρώνα.

Συνήθως οι τεχνητοί νευρώνες περιλαμβάνουν στρώματα κόμβων και είναι οργανωμένοι σε μια σειρά από στρώματα ή επίπεδα (layers). Το επίπεδο εισόδου (input layer) χρησιμοποιείται για την εισαγωγή δεδομένων. Τα στοιχεία του δηλαδή δεν είναι ουσιαστικά νευρώνες, γιατί δεν εκτελούν κάποιο υπολογισμό (δεν έχουν βάρη εισόδου ούτε συνάρτηση ενεργοποίησης). Στη συνέχεια, μπορεί να ακολουθούν προαιρετικά, ένα ή περισσότερα ενδιάμεσα ή κρυφά επίπεδα (hidden layers), ενώ στο τέλος υπάρχει το επίπεδο εξόδου (output layer).



Σχήμα 6.7 ΤΝΔ 3-4-2 πρόσθιας τροφοδότησης με πλήρη διασύνδεση μεταξύ διαδοχικών επιπέδων.

Επίπεδο εισόδου : Παθητικά επίπεδα που μεταδίδουν τις ίδιες πληροφορίες από έναν κόμβο σε πολλαπλές εξόδους. Αυτό είναι το πρώτο σημείο εισόδου του Νευρωνικού Δικτύου, το οποίο περιέχει τα αρχικά δεδομένα για το μοντέλο στο οποίο θα εκπαιδευτεί.

Κρυφό επίπεδο : Εκτελεί μαθηματικούς υπολογισμούς στις εισόδους και παράγει μια καθαρή είσοδο η οποία στη συνέχεια εφαρμόζεται με συναρτήσεις ενεργοποίησης για την παραγωγή της εξόδου. Συνήθως, αυτό το στρώμα αντιμετωπίζεται ως ένα μαύρο κουτί καθώς αποτελείται από πολλά διαφορετικά μικρότερα νευρωνικά στρώματα όπου συμβαίνουν υπολογισμοί.

Επίπεδο εξόδου : Συνδυάζεται και παράγει συγκεκριμένα το αποτέλεσμα εξόδου από τους πολύπλοκους υπολογισμούς από τα προηγούμενα στρώματα.

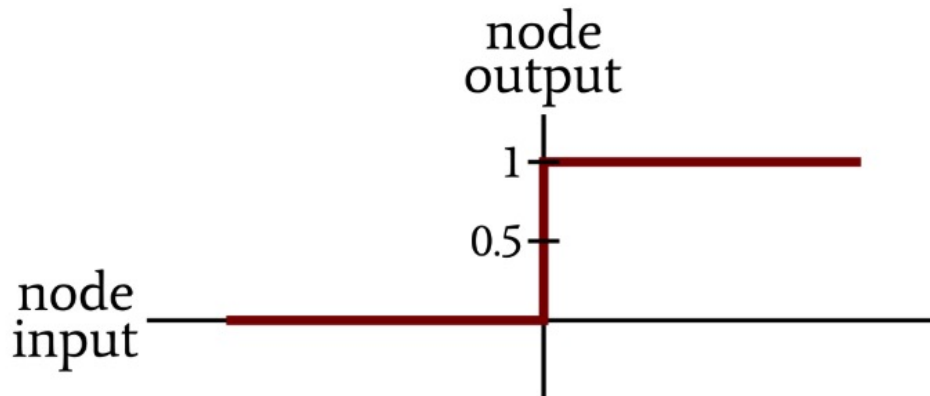
6.4 Τι συμβαίνει μέσα σε έναν κόμβο. Πώς λειτουργούν τα ΤΝΔ;

Οι κόμβοι στο επίπεδο εισόδου είναι απλά σημεία σύνδεσης. Δεν τροποποιούν τα δεδομένα εισόδου. Το επίπεδο εξόδου, καθώς και τυχόν πρόσθετα επίπεδα μεταξύ εισόδου και εξόδου, περιέχουν τους υπολογιστικούς κόμβους του δικτύου. Όταν τα αριθμητικά δεδομένα φτάνουν σε υπολογιστικούς κόμβους, πρώτα αθροίζονται και στη συνέχεια υποβάλλονται σε μια λειτουργία "ενεργοποίησης":

Η έννοια της ενεργοποίησης ανάγεται στη συμπεριφορά των (βιολογικών) νευρώνων, οι οποίοι επικοινωνούν μέσω δυναμικών δράσης που είναι είτε ενεργά είτε ανενεργά. Μοιάζει περισσότερο με ψηφιακό σύστημα on/off παρά με αναλογικό σύστημα. Στο πλαίσιο των

(τεχνητών) νευρωνικών δικτύων, οι κόμβοι - που ονομάζονται επίσης (τεχνητοί) νευρώνες - μπορούν να μιμηθούν τη νευρωνική συμπεριφορά εφαρμόζοντας μια συνάρτηση κατωφλίου που εξάγει 1 όταν η είσοδος είναι μεγαλύτερη από το κατώφλι και 0 διαφορετικά.

Το παρακάτω διάγραμμα μεταφέρει τη σχέση εισόδου -εξόδου της βασικής συνάρτησης ενεργοποίησης "μονάδας βήματος".



Σχήμα 6.8 Διάγραμμα συνάρτησης ενεργοποίησης για είσοδο-έξοδο

Με την εισαγωγή αυτού του μετασχηματισμού κατωφλίου στη διάδοση δεδομένων από κόμβο σε κόμβο, εισάγουμε τη μη γραμμικότητα στο σύστημα και χωρίς αυτήν τη μη γραμμικότητα, η λειτουργικότητα ενός νευρωνικού δικτύου είναι πολύ περιορισμένη.

Πέραν της όποιας αρχιτεκτονικής τους σχεδίασης, η βασική ομοιότητα των ΤΝΔ σε σχέση με τα βιολογικά νευρωνικά δίκτυα εντοπίζεται στον τρόπο με τον οποίο μεταχειρίζονται την 'γνώση', την οποία καλούνται να αξιοποιήσουν. Συγκεκριμένα τα ΤΝΔ λαμβάνουν πληροφορίες από κάποιο καθορισμένο περιβάλλον / δεδομένα, μέσω μιας διαδικασίας εκμάθησης (training phase).

Ένας νευρώνας με N εισόδους ορίζει ένα υπερεπίπεδο στο N -διάστατο χώρο, το οποίο τον διαχωρίζει σε δύο περιοχές. Οι τιμές των βαρών στις εισόδους αυτού του νευρώνα καθορίζουν τη θέση του υπερεπιπέδου στο N -διάστατο χώρο. Χωρίς την πόλωση το υπερεπίπεδο αυτό θα ήταν αναγκασμένο να περνά υποχρεωτικά από την αρχή του χώρου κάτι που σε ορισμένα προβλήματα μπορεί να είναι περιοριστικό.

Στο Σχήμα 5.9 παρουσιάζονται τρεις τυπικές περιπτώσεις για τη συνάρτηση ενεργοποίησης:

- Η *βηματική συνάρτηση* (step function) ή συνάρτηση κατωφλίου (threshold function), η οποία δίνει στην έξοδο αποτέλεσμα (συνήθως 1) μόνο αν η τιμή που υπολογίζει ο αθροιστής είναι μεγαλύτερη από μια τιμή κατωφλίου T .
- Η *συνάρτηση προσήμου* (sign function) η οποία δίνει στην έξοδο αρνητική (ή θετική) πληροφορία αν η τιμή που υπολογίζει ο αθροιστής είναι μικρότερη (ή μεγαλύτερη) από μια τιμή κατωφλίου T .
- συναρτήσεις βηματικής μεταβολής (hard limiter functions),
- συναρτήσεις αναρρίχησης (ramping functions)
- Η *λογιστική συνάρτηση* (logistic function) η οποία εκφράζεται από τη γενική σχέση :


$$f(S) = \frac{1}{1+e^{-aS}}$$

όπου a είναι ένας συντελεστής ρύθμισης της ταχύτητας μετάβασης μεταξύ των δύο ασυμπτωτικών τιμών.

Η λογιστική συνάρτηση ανήκει σε μία οικογένεια συναρτήσεων που ονομάζονται *σιγμοειδείς* (sigmoid) και οι οποίες έχουν τη χαρακτηριστική γραφική παράσταση

σχήματος πεπλατυσμένου “S” με την παράμετρο α να ελέγχει το ρυθμό μετάβασης από μικρές προς μεγάλες τιμές εξόδου. Άλλες τέτοιες συναρτήσεις είναι η αντίστροφη εφαπτομένη (\arctan) και η υπερβολική εφαπτομένη (\tanh) οι οποίες χρησιμοποιούνται συνήθως με την παρακάτω μορφή :

$$F(S) = \frac{2 \tan^{-1}(aS)}{\pi} \quad \text{και} \quad f(S) = \frac{e^{aS} - e^{-aS}}{e^{aS} + e^{-aS}}$$



Σχήμα 5.9 Γραφικές παραστάσεις συναρτήσεων ενεργοποίησης.

Οι άλλες πτυχές της «τέχνης» της χρήσης νευρωνικών δικτύων περιστρέφονται γύρω από τους μυριάδες τρόπους με τους οποίους αυτοί οι μεμονωμένοι νευρώνες μπορούν να ομαδοποιηθούν μαζί. Αυτή η ομαδοποίηση συμβαίνει στο ανθρώπινο μυαλό με τέτοιο τρόπο ώστε οι πληροφορίες να μπορούν να υποβληθούν σε επεξεργασία με δυναμικό, διαδραστικό και αυτο-οργανωμένο τρόπο.

6.5 Συνοπτική Περιγραφή ενός ΤΝΔ

- Τα ΤΝΔ συνήθως οργανώνονται σε επίπεδα (layers) τα οποία καλούνται και στρώματα. Τα ενδιάμεσα επίπεδα καλούνται κρυμμένα επίπεδα (hidden layers) και δεν είναι απαραίτητο να υπάρχουν.
- Τα επίπεδα αποτελούνται από έναν αριθμό μονάδων (units) ή κόμβων (nodes) που είναι έτσι συνδεδεμένες μεταξύ τους, ώστε μία μονάδα να έχει συνδέσμους με πολλές άλλες μονάδες του ίδιου ή άλλου επιπέδου.
- Οι μονάδες επιδρούν σε άλλες μονάδες με το να τις διεγείρουν ή να αναστέλλουν την ενεργοποίησή τους. Για να επιτευχθεί αυτό, η μονάδα λαμβάνει το σταθμισμένο άθροισμα όλων των εισόδων μέσω των συνδέσμων που καταλήγουν σε αυτήν και παράγει μέσω της συνάρτησης μετάβασης μία μοναδική έξοδο, εάν το άθροισμα υπερβαίνει μία τιμή κατωφλίου.

- Οι είσοδοι παρουσιάζονται στο δίκτυο μέσω του επιπέδου εισόδου (input layer) το οποίο επικοινωνεί με έναν ή περισσότερα κρυμμένα επίπεδα. Τα κρυμμένα επίπεδα συνδέονται με το επίπεδο εξόδου (output layer) από το οποίο εξάγεται η απάντηση.

Βασικά στοιχεία της αρχιτεκτονικής των ΤΝΔ που πρέπει να καθοριστούν κατά τη δημιουργία τους είναι:

- Ο αριθμός των ενδιάμεσων κρυφών επιπέδων,
- Ο αριθμός των μονάδων (ή κόμβων) ανά επίπεδο,
- Ο τρόπος σύνδεσης των μονάδων μεταξύ τους,
- Η τιμή ενεργοποίησης (τιμή κατωφλίου),
- Η μορφή της συνάρτησης μετάβασης,
- Οι τιμές των αρχικών βαρών μεταξύ των μονάδων,
- Οι αλγόριθμοι (κανόνες εκπαίδευσης) που χρησιμοποιούνται, για να ενισχυθούν οι σύνδεσμοι μεταξύ των μονάδων κατά τη διαδικασία της εκπαίδευσης.

6.6 Βασικές Ιδιότητες των ΤΝΔ

Υπάρχουν τέσσερις ιδιότητες που είναι άρρηκτα συνδεδεμένες με τα ΤΝΔ :


- Η ικανότητά τους να μαθαίνουν μέσω παραδειγμάτων (learn by example).
- Η δυνατότητα θεώρησής τους ως κατανεμημένη μνήμη (distributed memory) και ως μνήμη συσχέτισης (associative memory).
- Η μεγάλη τους ανοχή σε σφάλματα (fault-tolerant).
- Η ικανότητά τους για αναγνώριση προτύπων (pattern recognition).

6.7 Αρχιτεκτονική των ΤΝΔ

Όσον αφορά το πώς είναι συνδεδεμένες οι μονάδες μεταξύ τους, υπάρχουν δύο βασικές κατηγορίες ΤΝΔ:


- πρόσθιας τροφοδότησης (feed forward) και
- οπίσθιας τροφοδότησης (feed backward)

Στα νευρωνικά δίκτυα πρόσθιας τροφοδότησης, οι μονάδες είναι οργανωμένες σε διαφορετικά επίπεδα, ώστε οι μονάδες του ενός επιπέδου να τροφοδοτούν τις μονάδες του επόμενου επιπέδου, έως ότου τροφοδοτηθούν και οι μονάδες του τελευταίου επιπέδου. Δηλαδή, δεν υπάρχει έξοδος μονάδας ενός επιπέδου που να αποτελεί είσοδο μονάδας του ίδιου ή προηγούμενων επιπέδου. Τέτοια ΤΝΔ είναι τα δίκτυα οπισθοδιάδοσης (backpropagation).



Σχήμα 6.10 ΤΝΔ πρόσθιας τροφοδότησης

Στα οπισθίως τροφοδοτούμενα δίκτυα, που καλούνται και ανατροφοδοτούμενα ΤΝΔ (recurrent ANN), επιτρέπεται στις μονάδες ενός επιπέδου να τροφοδοτούν και μονάδες του ίδιου επιπέδου ή και προηγούμενων επιπέδων. Αν η ανατροφοδότηση αφορά κόμβους στο ίδιο επίπεδο, τότε τα δίκτυα καλούνται αυτοσυσχετιζόμενες μνήμες (autoassociated memories), ενώ διαφορετικά, καλούνται ετεροσυσχετιζόμενες μνήμες (heteroassociated memories)



Σχήμα 6.11 ΤΝΔ οπισθοοπισθίως τροφοδοτούμενα.

Στα ανατροφοδοτούμενα ΤΝΔ δεν υπάρχουν συνήθως άνω του ενός ενδιάμεσα (κρυφά) επίπεδα. Αν και τα ανατροφοδοτούμενα δίκτυα είναι πολύ χρήσιμα, τα περισσότερα νευρωνικά δίκτυα είναι πρόσθιας τροφοδότησης.

6.8 ΤΝΔ και Ταξινόμηση

Τα νευρωνικά δίκτυα έχουν διαφορετικό τρόπο λειτουργίας από τα SVMs και, συγκεκριμένα, δεν απαιτούν πυρήνες. Αυτό, φυσικά, δεν ισχύει για τα συνελκτικά νευρωνικά δίκτυα.


Ένα νευρωνικό δίκτυο για ταξινόμηση, σε αυτό το πλαίσιο, αντιστοιχεί σε ένα ΤΝΔ με ένα μόνο κρυφό στρώμα και μια μη γραμμική συνάρτηση ενεργοποίησης. Οι πιο συνηθισμένοι τύποι μη γραμμικών συναρτήσεων ενεργοποίησης για τα ΤΝΔ για ταξινόμηση είναι:

- λογιστική συνάρτηση,
- υπερβολική εφαπτομένη,
- Softmax,

Όλες αυτές οι συναρτήσεις λαμβάνουν ως είσοδο έναν γραμμικό συνδυασμό ενός διανύσματος χαρακτηριστικών x και ενός διανύσματος βάρους w . Στη συνέχεια επιστρέφουν μια έξοδο που ανήκει σε κάποιο πεπερασμένο διάστημα, συνήθως $(0,1)$ ή $(-1,1)$.

Ένα νευρωνικό δίκτυο με ένα μόνο κρυφό στρώμα και μια μη γραμμική συνάρτηση ενεργοποίησης μπορεί να προσεγγίσει κάθε δεδομένη συνεχή συνάρτηση. Εάν το όριο απόφασης δεν είναι συνεχές στον αρχικό χώρο χαρακτηριστικών, η προσθήκη περαιτέρω στρωμάτων στο ΤΝΔ μπορεί να αυξήσει τη διαστατικότητα του, μέχρι ένα σημείο στο οποίο είναι. Ένα βαθύ νευρωνικό δίκτυο μπορεί, ως εκ τούτου, να προσεγγίσει όλα τα όρια απόφασης που αποτελούνται από πολλαπλές συνεχείς περιοχές (σε επόμενο κεφάλαιο θα επεκταθούμε στο τί είναι ένα βαθύ νευρωνικό δίκτυο).

Όπως είδαμε και στο κεφάλαιο 6.2, το πιο απλό νευρωνικό δίκτυο που μπορεί να σχεδιαστεί και να μελετηθεί είναι ένα δίκτυο που αποτελείται από έναν μόνο νευρώνα. Προφανώς η λέξη "δίκτυο" σε αυτή την περίπτωση χρησιμοποιείται καταχρηστικά. Οι μόνες συνδέσεις που υπάρχουν είναι αυτές μεταξύ των εισόδων. Ένα βασικό νευρωνικό δίκτυο Perceptron είναι εννοιολογικά απλό. Δεν μπορεί να αποτελείται από τίποτα περισσότερο από δύο κόμβους εισόδου και έναν κόμβο εξόδου που συνδέονται με σταθμισμένες συνδέσεις:



Σχήμα 6.12 Ένα βασικό νευρωνικό δίκτυο Perceptron.


Έτσι, ένα μοντέλο perceptron είναι μια μονάδα νευρωνικού δικτύου (ένας τεχνητός νευρώνας) που κάνει ορισμένους υπολογισμούς για να ανιχνεύσει χαρακτηριστικά ή ευφυΐα στα δεδομένα εισόδου. Το perceptron αποτελεί τη βάση του αλγορίθμου ενός γραμμικού ταξινομητή. Αυτός ο αλγόριθμος επιτρέπει στους νευρώνες να μαθαίνουν και να επεξεργάζονται στοιχεία στο σετ εκπαίδευσης ένα κάθε φορά. Είναι μια απλή τοπολογία δικτύου πρόσθιας τροφοδότησης χωρίς κρυφά επίπεδα και αποτελεί ιστορικά μια πρώτη προσέγγιση τεχνητών νευρωνικών δικτύων. Προτάθηκε, όπως είπαμε, το 1958 από τον Rosenblatt ως μηχανισμός που μπορεί να εκπαιδευτεί στην ταξινόμηση προτύπων, και σε διάφορες παραλλαγές, πιο απλές ή πιο σύνθετες, εξακολουθεί να υφίσταται ως σήμερα. Αυτό το μοντέλο αποτελείται από ένα επίπεδο εισόδου (input layer) και ένα επίπεδο εξόδου (output layer), με όλες τις επεξεργασίες να πραγματοποιούνται στο δεύτερο. Αν και ο όρος Perceptron χρησιμοποιήθηκε αρχικά για το στοιχειώδες ΤΝΔ πολλών εισόδων και μόνο μιας εξόδου, έχει επικρατήσει να χαρακτηρίζονται ως Perceptrons όλα τα ΤΝΔ πρόσθιας τροφοδότησης που δεν περιέχουν στην αρχιτεκτονική τους κρυφά επίπεδα.

Ο πιο συνηθισμένος τρόπος που χρησιμοποιείται ο αλγόριθμος perceptron για την εκμάθηση από μια δέσμη εκπαιδευόμενων περιπτώσεων είναι η εκτέλεση του αλγορίθμου επανειλημμένα μέσω του σετ εκπαίδευσης έως ότου βρει ένα διάνυσμα πρόβλεψης το οποίο να είναι σωστό σε/για όλα τα σετ εκπαίδευσης. Αυτός ο κανόνας πρόβλεψης χρησιμοποιείται στη συνέχεια για την πρόβλεψη των ετικετών στο σετ δοκιμών.

Η διαστατικότητα των δεδομένων εισόδου πρέπει να ταιριάζει με τη διαστατικότητα του επιπέδου εισόδου. Ο όρος "διαστατικότητα" μπορεί να είναι λίγο συγκεχυμένος εδώ επειδή οι περισσότεροι άνθρωποι δεν μπορούν να απεικονίσουν κάτι με περισσότερες από τρεις διαστάσεις. Στην πραγματικότητα, αυτό σημαίνει ότι τα δεδομένα εισόδου - για παράδειγμα, ένα μοτίβο προς ταξινόμηση - είναι ένα διάνυσμα με ένα δεδομένο μήκος ενώ το επίπεδο εισόδου πρέπει να έχει έναν κόμβο για κάθε στοιχείο στο διάνυσμα. Έτσι, αν προσπαθήσουμε να ταξινομήσουμε ένα μοτίβο που αντιπροσωπεύεται από μια σειρά 20 σημείων δεδομένων (data points), προκύπτει ένα διάνυσμα 20 στοιχείων και ως εκ τούτου χρειαζόμαστε 20 κόμβους εισόδου.

Τα δεδομένα που μετακινούνται από έναν κόμβο σε άλλον, πολλαπλασιάζονται με τα βάρη. Αυτές οι συνηθισμένες κλιμακωτές τιμές είναι στην πραγματικότητα το κλειδί για τη λειτουργικότητα του Perceptron: τα βάρη τροποποιούνται κατά τη διάρκεια της διαδικασίας εκπαίδευσης και προσαρμόζοντας αυτόματα τα βάρη του σύμφωνα με τα πρότυπα που περιέχονται στα δεδομένα εκπαίδευσης, το δίκτυο αποκτά τη δυνατότητα να παράγει χρήσιμη έξοδο.

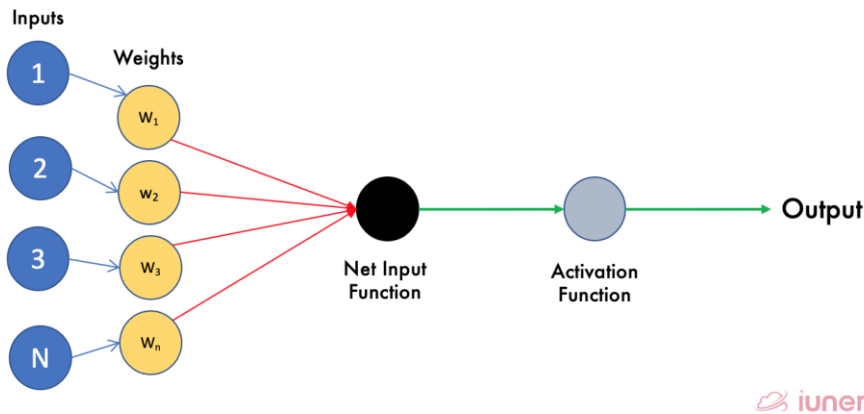
Αν διαθέτουν την κατάλληλη δομή, οι Perceptrons είναι ικανοί να επιλύουν οποιαδήποτε γραμμική συνάρτηση, όπως την κλασική συνάρτηση με διαχωρίσιμες τιμές 'οι'



Σχήμα 6.13 Συναρτήσεις OR-XOR

Το ότι τα Perceptrons δεν μπορούν να επιλύσουν προβλήματα με μη γραμμικά διαχωρίσιμες τιμές εξόδου, όπως η περίπτωση του xor (βλέπε Σχήμα 6.13 δεξιά), οδήγησε στην ανάγκη προσθήκης κρυφών επιπέδων στη δομή των Perceptrons και στη δημιουργία πολυεπίπεδων ΤΝΔ.

Υπάρχουν δύο τύποι perceptrons, τα οποία είναι α) ενός επιπέδου (single - layer) και β) πολυεπίπεδα (multilayer). Τα perceptrons ενός επιπέδου μπορούν να μάθουν μόνο γραμμικά διαχωρίσιμα μοτίβα. Από την άλλη πλευρά, τα πολυεπίπεδα perceptrons ή τα νευρωνικά δίκτυα πρόσθιας τροφοδοσίας με δύο ή περισσότερα επίπεδα έχουν μεγαλύτερη επεξεργαστική ισχύ. Ως εκ τούτου, μπορούν να μάθουν πιο περίπλοκα χαρακτηριστικά που περιλαμβάνουν εικόνες ή βίντεο.

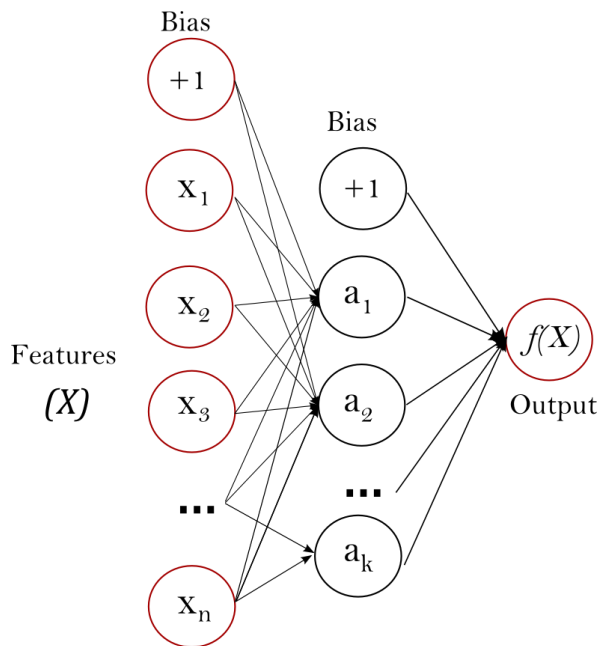


Σχήμα 6.14 Perceptron με έξοδο

Η παραπάνω εικόνα δείχνει ένα Perceptron με έξοδο. Ένα perceptron δέχεται εισόδους, τις μετριάζει με ορισμένες τιμές βάρους, στη συνέχεια εφαρμόζει τη συνάρτηση μετασχηματισμού ή εφαρμόζει μια συγκεκριμένη συνάρτηση ενεργοποίησης για την έξοδο του τελικού αποτελέσματος. Το απλό αυτό μοντέλο χρησιμοποιεί ως συνάρτηση ενεργοποίησης τη βηματική συνάρτηση και συνήθως χρησιμοποιείται στο να διαχωρίζει ή να ταξινομεί ένα σύνολο δεδομένων σε 2 κλάσεις.

Αν και συχνά αναφέρονται ως μαύρα κουτιά, τα νευρωνικά δίκτυα μπορούν στην πραγματικότητα να γίνουν εύκολα κατανοητά από όσους γνωρίζουν τις τεχνικές ανάλυσης παλινδρόμησης. Στην ουσία, πρόκειται για σύνθετες μη γραμμικές εξισώσεις μοντελοποίησης. Η προστιθέμενη πολυπλοκότητα είναι σε μεγάλο βαθμό το αποτέλεσμα μιας διαστρωμάτωσης «κόμβων» που παρέχει έναν πολύ πιο λεπτομερή χάρτη του χώρου αποφάσεων. Ένα νευρωνικό δίκτυο ενός κόμβου θα παράγει μια συγκρίσιμη έξοδο με την λογιστική παλινδρόμηση, όπου μια συνάρτηση θα συνδυάζει τα βάρη των εισόδων για να παράγει την έξοδο. Ο συνδυασμός αυτών των κόμβων σε πολλαπλά επίπεδα προσθέτει στην πολυπλοκότητα του μοντέλου και ως εκ τούτου τη διακριτική δύναμη. Με αυτόν τον τρόπο, ένας αριθμός στοιχείων, καθένα από τα οποία λαμβάνει όλες τις εισόδους και παράγει μια έξοδο, στέλνει αυτές τις εξόδους ως εισόδους σε ένα άλλο στοιχείο(α). Η αρχιτεκτονική ονομάζεται πολυστρωματικό perceptron

Το Perceptron πολλαπλών επιπέδων (MLP) είναι ένας εποπτευόμενος αλγόριθμος μάθησης που μαθαίνει μια συνάρτηση $f(\cdot):R^m \rightarrow R^o$ κάνοντας εκπαίδευση σε ένα σύνολο δεδομένων, όπου m είναι ο αριθμός των διαστάσεων για την είσοδο και o ο αριθμός των διαστάσεων για την έξοδο. Δεδομένου ενός συνόλου χαρακτηριστικών $X = x_1, x_2, \dots, x_m$ και ενός στόχου y , μπορεί να μάθει έναν μη γραμμικό προσεγγιστικό συνάρτησης είτε για ταξινόμηση είτε για παλινδρόμηση. Το Σχήμα 5.15 δείχνει ένα κρυφό στρώμα MLP με κλιμακωτή έξοδο.




Σχήμα 6.15 Κρυφό στρώμα MLP με κλιμακωτή έξοδο.

Το πιο αριστερό στρώμα (στρώμα εισόδου), $\{x_1, x_2, \dots, x_m\}$ αποτελείται από ένα σύνολο νευρώνων που αντιπροσωπεύουν τα χαρακτηριστικά εισόδου. Κάθε νευρώνας στο κρυφό στρώμα μετατρέπει τις τιμές από το προηγούμενο στρώμα με μια σταθμισμένη γραμμική άθροιση $w_1x_1 + w_2x_2 + \dots + w_mx_m$, ακολουθούμενη από μια μη γραμμική συνάρτηση ενεργοποίησης $g(\cdot): \mathbb{R} \rightarrow \mathbb{R}$, όπως η συνάρτηση υπερβολικής εφαπτομένης. Το επίπεδο εξόδου λαμβάνει τις τιμές από το τελευταίο κρυφό στρώμα και τις μετατρέπει σε τιμές εξόδου.

Τα Perceptrons, λοιπόν, μπορούν να ταξινομήσουν μόνο γραμμικά διαχωρίσιμα σύνολα περιπτώσεων. Εάν μπορεί να σχεδιαστεί μια ευθεία ή επίπεδο για να χωριστούν οι εισοδοί στις σωστές κατηγορίες, οι εισοδοί είναι γραμμικά διαχωρίσιμες και το perceptron είναι ικανό να βρει τη λύση. Στην περίπτωση όμως που οι εισοδοί δεν είναι γραμμικά διαχωρίσιμες, η μάθηση δεν θα φτάσει ποτέ σε ένα σημείο όπου όλες οι εισοδοί ταξινομούνται σωστά. Τα τεχνητά νευρωνικά δίκτυα έχουν δημιουργηθεί για να προσπαθήσουν να λύσουν αυτό το πρόβλημα.

Τα ΤΝΔ πρόσθιας τροφοδότησης επιτρέπουν στα σήματα να ταξιδεύουν μόνο με έναν τρόπο, από την είσοδο στην έξοδο. Αρχικά το δίκτυο εκπαιδεύεται σε ένα σύνολο ζευγαρωμένων δεδομένων για τον προσδιορισμό της χαρτογράφησης εισόδου-εξόδου. Στη συνέχεια, τα βάρη των συνδέσεων μεταξύ των νευρώνων καθορίζονται και το δίκτυο χρησιμοποιείται για τον προσδιορισμό των ταξινομήσεων ενός νέου συνόλου δεδομένων.

Οι κόμβοι των διαφόρων επιπέδων μπορεί να είναι πλήρως συνδεδεμένοι (fully connected), δηλαδή κάθε κόμβος του ενός επιπέδου συνδέεται με όλους τους κόμβους του επόμενου, ή μερικώς συνδεδεμένοι (partially connected). Τα ΤΝΔ χαρακτηρίζονται, επιπλέον, με βάση τον τρόπο με τον οποίο είναι συνδεδεμένοι οι κόμβοι τους, όπως αναφέραμε στην προηγούμενη παράγραφο περί Αρχιτεκτονικής ΤΝΔ, δηλαδή αν είναι πρόσθιας τροφοδότησης (feed forward) ή οπίσθιας τροφοδότησης (feed backward ή recurrent). Στην πλειοψηφία των εφαρμογών χρησιμοποιούνται δίκτυα πρόσθιας τροφοδότησης ενός κρυφού επιπέδου με πλήρως συνδεδεμένους κόμβους.



Σχήμα 6.16 ΤΝΔ πρόσθιας τροφοδότησης

Γενικά ο σωστός προσδιορισμός του μεγέθους του κρυμμένου στρώματος αποτελεί πρόβλημα, καθώς μια υποτίμηση του αριθμού των νευρώνων μπορεί να οδηγήσει σε κακή προσέγγιση και γενικεύσεις δυνατοτήτων, ενώ οι υπερβολικοί κόμβοι μπορούν να οδηγήσουν σε υπερβολική προσαρμογή και τελικά να κάνουν πιο δύσκολη την αναζήτηση του γενικού βέλτιστου.

Το ΤΝΔ εξαρτάται από τρεις θεμελιώδεις πτυχές, την είσοδο και τις συναρτήσεις ενεργοποίησης της μονάδας, την αρχιτεκτονική του δικτύου και το βάρος κάθε σύνδεσης εισόδου. Δεδομένου ότι οι δύο πρώτες πτυχές είναι σταθερές, η συμπεριφορά του ΤΝΔ καθορίζεται από τις τρέχουσες τιμές των βαρών. Τα βάρη του δικτύου που θα εκπαιδευτεί αρχικά παίρνουν τυχαίες τιμές και στη συνέχεια τα παραδείγματα (instances) του σετ εκπαίδευσης εκτίθενται επανειλημμένα στο δίκτυο. Οι τιμές για την είσοδο μιας instance τοποθετούνται στις μονάδες εισόδου και η έξοδος του δικτύου συγκρίνεται με την επιθυμητή έξοδο για αυτήν την instance. Στη συνέχεια, όλα τα βάρη στο δίκτυο προσαρμόζονται ελαφρώς προς την κατεύθυνση που θα φέρει τις τιμές εξόδου του δικτύου πιο κοντά στις τιμές της επιθυμητής εξόδου. Υπάρχουν αρκετοί αλγόριθμοι με τους οποίους μπορεί να εκπαιδευτεί ένα δίκτυο. Τα νευρωνικά δίκτυα πρόσθιας τροφοδότησης συνήθως εκπαιδεύονται από τον αρχικό αλγόριθμο Back Propagation ή από κάποια μεταβλητή. Το μεγάλο τους πρόβλημα είναι ότι είναι πολύ αργά για τις περισσότερες εφαρμογές. Μία από τις προσεγγίσεις για την επιτάχυνση του ποσοστού εκπαίδευσης είναι η εκτίμηση του βέλτιστου αρχικού βάρους.

6.9 Εφαρμογές Ταξινόμησης με ΤΝΔ

Τα ΤΝΔ είναι ιδιαίτερα δημοφιλή σε προβλήματα που περιέχουν μη-προβλέψιμες λειτουργίες και τα οποία δεν είναι πλήρως κατανοητά. Τέτοιου είδους προβλήματα υπάρχουν σε πολλές ανθρώπινες δραστηριότητες που σχετίζονται με κατηγοριοποίηση/ταξινόμηση (classification), αναγνώριση (recognition/identification), αποτίμηση (assessment) και πρόβλεψη (forecasting/prediction). Εμείς θα ασχοληθούμε με τις εφαρμογές ταξινόμησης. Πιο συγκεκριμένα :

Εφαρμογές ταξινόμησης :

- Ιατρικός τομέας : ταξινόμηση ιατρικών εικόνων που προέρχονται από εξετάσεις υπερήχων, ηλεκτροκαρδιογραφήματα, τεστ Παπανικολάου, κτλ. Τα ΤΝΔ καλούνται να κάνουν μια πρώτη διάγνωση, επιταχύνοντας σημαντικά χρονοβόρα διαδικασία ελέγχου των δεδομένων ιατρικών εξετάσεων από τους ιατρούς. Οι περιπτώσεις που κρίνονται ως ύποπτες, εξετάζονται στη συνέχεια από ιατρούς.

- Τομέας άμυνας : ταξινόμηση εικόνων προερχόμενων από συσκευές όπως radar, sonar, κτλ.
- Γεωργία : έλεγχος καλλιεργειών σε συνδυασμό με δορυφορικά συστήματα τηλε-επισκόπησης.
- Οικονομία/επιχειρήσεις : ταξινόμηση πελατών με βάση τις αγοραστικές τους συνήθειες

6.10 Παράδειγμα Ταξινόμησης με ΤΝΔ

Ένα απλό νευρωνικό δίκτυο για την ταξινόμηση χειρόγραφων ψηφίων :

Μπορούμε να χωρίσουμε το πρόβλημα της αναγνώρισης των χειρόγραφων ψηφίων σε δύο υποπρόβλήματα. Πρώτον, θα θέλαμε να σπάσουμε μια εικόνα που περιέχει πολλά ψηφία σε μια ακολουθία ξεχωριστών εικόνων, η κάθε μία να περιέχει ένα μόνο ψηφίο. Για παράδειγμα, θα θέλαμε να σπάσουμε την εικόνα :

504192


σε έξι διαφορετικές εικόνες :

5 0 4 1 9 2

Εμείς οι άνθρωποι λύνουμε αυτό το πρόβλημα κατάτμησης με ευκολία, αλλά ένα πρόγραμμα υπολογιστή είναι δύσκολο να διασπάσει σωστά την εικόνα. Μόλις η εικόνα τμηματοποιηθεί, το πρόγραμμα πρέπει στη συνέχεια να ταξινομήσει κάθε μεμονωμένο ψηφίο. Έτσι, για παράδειγμα, θα θέλαμε το πρόγραμμά μας να αναγνωρίσει ότι το πρώτο ψηφίο παραπάνω, είναι ένα 5.

Υπάρχουν πολλές προσεγγίσεις για την επίλυση του προβλήματος κατάτμησης. Μια προσέγγιση είναι να δοκιμάσουμε πολλούς διαφορετικούς τρόπους τμηματοποίησης της εικόνας, χρησιμοποιώντας τον ατομικό ταξινομητή ψηφίων για να βαθμολογήσουμε κάθε δοκιμαστική τμηματοποίηση. Μια δοκιμαστική τμηματοποίηση παίρνει υψηλή βαθμολογία εάν ο ταξινομητής μεμονωμένων ψηφίων είναι σίγουρος για την ταξινόμησή του σε όλα τα τμήματα ,ενώ από την άλλη, παίρνει χαμηλή βαθμολογία εάν ο ταξινομητής αντιμετωπίζει πολλά προβλήματα σε ένα ή περισσότερα τμήματα. Η ιδέα είναι ότι εάν ο ταξινομητής έχει πρόβλημα κάπου, τότε πιθανότατα έχει πρόβλημα επειδή η κατάτμηση έχει επιλεγεί εσφαλμένα. Αυτή η ιδέα και άλλες παραλλαγές μπορούν να χρησιμοποιηθούν για την επίλυση του προβλήματος κατάτμησης αρκετά καλά. Έτσι, αντί να ανησυχούμε για την κατάτμηση, θα επικεντρωθούμε στην ανάπτυξη ενός νευρωνικού δικτύου που μπορεί να λύσει το πιο ενδιαφέρον και δύσκολο πρόβλημα, δηλαδή την αναγνώριση μεμονωμένων χειρόγραφων ψηφίων.

Για την αναγνώριση μεμονωμένων ψηφίων θα χρησιμοποιήσουμε ένα νευρωνικό δίκτυο τριών επιπέδων:



Σχήμα 6.17 ΤΝΔ τριών επιπέδων.

Το επίπεδο εισόδου του δικτύου περιέχει νευρώνες που κωδικοποιούν τις τιμές των εικονοστοιχείων εισόδου. Τα δεδομένα εκπαίδευσης για το δίκτυο θα αποτελούνται από πολλές εικόνες 28 επί 28 εικονοστοιχείων από σαρωμένα χειρόγραφα ψηφία, και έτσι το επίπεδο εισόδου περιέχει $784 = 28 \times 28$ νευρώνες. Για απλότητα έχω παραλείψει τους περισσότερους από τους 784 νευρώνες εισόδου στο παραπάνω διάγραμμα. Τα εικονοστοιχεία εισόδου είναι σε κλίμακα του γκρι, με μια τιμή 0,0 που αντιπροσωπεύει το λευκό, μια τιμή 1,0 που αντιπροσωπεύει το μαύρο και μεταξύ των τιμών που αντιπροσωπεύουν σταδιακά σκούρες αποχρώσεις του γκρι.

Το δεύτερο επίπεδο του δικτύου είναι ένα κρυφό επίπεδο. Δηλώνουμε τον αριθμό των νευρώνων σε αυτό το κρυφό στρώμα με n και θα πειραματιστούμε με διαφορετικές τιμές για το n . Το παράδειγμα που παρουσιάζεται απεικονίζει ένα μικρό κρυφό στρώμα, που περιέχει μόνο $n = 15$ νευρώνες.

Το επίπεδο εξόδου του δικτύου περιέχει 10 νευρώνες. Εάν ο πρώτος νευρώνας πυροδοτήσει, δηλαδή, έχει έξοδο ≈ 1 , τότε αυτό θα δείξει ότι το δίκτυο πιστεύει ότι το ψηφίο είναι 0. Αν ο δεύτερος νευρώνας πυροδοτήσει, τότε αυτό θα δείξει ότι το δίκτυο πιστεύει ότι το ψηφίο είναι 1. Και ούτω καθεξής. Πιο συγκεκριμένα, αριθμούμε τους νευρώνες εξόδου από 0 έως 9 και υπολογίζουμε ποιος νευρώνας έχει την υψηλότερη τιμή ενεργοποίησης. Εάν αυτός ο νευρώνας είναι, ας πούμε, ο νευρώνας αριθμός 6, τότε το δίκτυό μας θα μαντέψει ότι το ψηφίο εισόδου ήταν ένα 6. Και ούτω καθεξής για τους άλλους νευρώνες εξόδου.

6.11 Αξιολόγηση μοντέλου

Τα δύο κριτήρια για την αξιολόγηση της ποιότητας ενός μοντέλου ταξινόμησης είναι η διάκριση και η βαθμονόμηση. Η διάκριση είναι ένα μέτρο του πόσο καλά διαχωρίζονται οι δύο κλάσεις στο σύνολο δεδομένων. Η βαθμονόμηση καθορίζει πόσο ακριβής είναι η εκτίμηση πιθανότητας του μοντέλου $f(x, \alpha)$ στην πραγματική πιθανότητα $P(y|x)$. Για να παρέχεται μια αμερόληπτη εκτίμηση της διάκρισης και της βαθμονόμησης ενός μοντέλου, αυτές οι τιμές πρέπει να υπολογιστούν από ένα σύνολο δεδομένων που δεν χρησιμοποιείται στη διαδικασία κατασκευής του μοντέλου. Συνήθως, ένα μέρος του αρχικού συνόλου δεδομένων, που ονομάζεται σύνολο δοκιμής ή επικύρωσης, τίθεται στην άκρη για το σκοπό αυτό. Σε μικρά

σύνολα δεδομένων, ενδέχεται να μην υπάρχουν αρκετά στοιχεία δεδομένων τόσο για εκπαίδευση όσο και για δοκιμή. Σε αυτήν την περίπτωση, ολόκληρο το σύνολο δεδομένων χωρίζεται σε n κομμάτια, $n-1$ κομμάτια χρησιμοποιούνται για εκπαίδευση και το τελευταίο κομμάτι είναι το δοκιμαστικό σύνολο. Αυτή η διαδικασία n -fold cross-validation δημιουργεί n μοντέλα. οι αριθμοί που αναφέρονται είναι οι μέσοι όροι για όλα τα n σύνολα δοκιμών. Η ακραία περίπτωση χρήσης μόνο ενός στοιχείου δεδομένων για δοκιμές είναι γνωστή ως διασταυρούμενη επικύρωση άδειας.

ΚΕΦΑΛΑΙΟ 7 Βαθιά Νευρωνικά Δίκτυα

7.1 Εισαγωγή

Την τελευταία δεκαετία, ο τομέας της βαθιάς μάθησης έχει αποδειχθεί ένας εξέχων και εξαιρετικά γόνιμος μηχανικός κλάδος. Αυτή η επιστροφή νευρωνικών δικτύων στις αρχές της δεκαετίας του 2000 σάρωσε την κοινότητα της μηχανικής μάθησης και αμέσως μετά βρέθηκε βυθισμένη σχεδόν σε κάθε επιστημονικό, κοινωνικό και τεχνολογικό μέτωπο. Μια αυξανόμενη σειρά συνεισφορών καθιέρωσε αυτόν τον τομέα ως οδηγό σε αποτελέσματα τελευταίας τεχνολογίας σχεδόν σε κάθε εργασία, αναγνώριση περιεχομένου εικόνας, κατανόηση γραπτών εγγράφων, αποκάλυψη σκοτεινών συνδέσεων σε μαζικά σύνολα δεδομένων, διευκόλυνση της αποτελεσματικής αναζήτησης σε μεγάλα αποθετήρια, μετάφραση γλωσσών, επιτρέποντας μια επανάσταση στις μεταφορές, αποκαλύπτοντας νέους επιστημονικούς νόμους στη φυσική και τη χημεία και πολλά άλλα. Τα βαθιά νευρωνικά δίκτυα όχι μόνο λύνουν γνωστά προβλήματα, αλλά προσφέρουν, επίσης, πρωτοφανή αποτελέσματα στην ανάπτυξη της μάθησης σε προβλήματα που μέχρι πρόσφατα θεωρούνταν ελάχιστα επιτυχημένα. Αυτά περιλαμβάνουν αυτόματη σύνθεση κειμένου-μέσων, δημιουργία μουσικών έργων τέχνης, σύνθεση ρεαλιστικών εικόνων και βίντεο, κ.τ.λ.

Περιέργως, όλα αυτά τα μεγάλα εμπειρικά επιτεύγματα επιτυγχάνονται με σχεδόν καμία θεωρητική βάση που θα μπορούσε να δώσει μια σαφή αιτιολόγηση για τις αρχιτεκτονικές που χρησιμοποιήθηκαν, μια κατανόηση των αλγορίθμων που τα συνοδεύουν, έναν σαφή μαθηματικό συλλογισμό πίσω από τα διάφορα κόλπα που χρησιμοποιήθηκαν, και πάνω απ' όλα, τα εντυπωσιακά αποτελέσματα που ελήφθησαν. Η αναζήτηση μιας θεωρίας που θα μπορούσε να εξηγήσει αυτά τα συστατικά έχει γίνει "το Άγιο Δισκοπότηρο" των επιστημών δεδομένων. Διάφορες εντυπωσιακές προσπάθειες παροχής μιας τέτοιας θεωρίας έχουν αρχίσει να εμφανίζονται, στηριζόμενες σε ιδέες από διάφορους κλάδους .


Οι *τεχνικές μηχανικής μάθησης* έχουν εφαρμοστεί ευρέως σε διάφορους τομείς όπως η αναγνώριση προτύπων, η επεξεργασία φυσικής γλώσσας και η υπολογιστική μάθηση. Με τις τεχνικές μηχανικής μάθησης, οι υπολογιστές διαθέτουν την ικανότητα να ενεργούν χωρίς να προγραμματίζονται ρητά, να κατασκευάζουν αλγόριθμους που μπορούν να μάθουν από τα δεδομένα και να λαμβάνουν αποφάσεις ή προβλέψεις που βασίζονται σε δεδομένα. Τις τελευταίες δεκαετίες, η μηχανική μάθηση επέφερε τεράστια επιρροή στην καθημερινή μας ζωή με παραδείγματα που περιλαμβάνουν αποτελεσματική αναζήτηση στο διαδίκτυο, συστήματα αυτόματης οδήγησης, όραση υπολογιστή και οπτική αναγνώριση χαρακτήρων. Επιπλέον, με την υιοθέτηση μεθόδων μηχανικής μάθησης, η τεχνητή νοημοσύνη σε ανθρώπινο επίπεδο έχει επίσης βελτιωθεί. Ωστόσο, όταν πρόκειται για τους ανθρώπινους μηχανισμούς επεξεργασίας πληροφοριών (π.χ. ομιλία και όραση), η απόδοση των παραδοσιακών τεχνικών μηχανικής μάθησης δεν είναι καθόλου ικανοποιητική. Εμπνευσμένη από βαθιές ιεραρχικές δομές της ανθρώπινης αντίληψης και συστημάτων παραγωγής, η έννοια των αλγορίθμων βαθιάς εκμάθησης εισήχθη στα τέλη του 20ού αιώνα. Επιτεύγματα στη βαθιά μάθηση έχουν σημειωθεί από το 2006 όταν ο Χίντον πρότεινε μια νέα αρχιτεκτονική βαθιάς δομημένης μάθησης που ονομάζεται δίκτυο βαθιάς πεπτοίθησης (DBN) . Την τελευταία δεκαετία έχουν σημειωθεί ραγδαίες εξελίξεις τεχνικών βαθιάς μάθησης με σημαντικές επιπτώσεις στην επεξεργασία σήματος και πληροφοριών. Η έρευνα για νευρομορφικά συστήματα υποστηρίζει επίσης την ανάπτυξη μοντέλων βαθιάς δικτύωσης . Σε αντίθεση με τις παραδοσιακές προσεγγίσεις μηχανικής μάθησης και τεχνητής νοημοσύνης, οι τεχνολογίες βαθιάς εκμάθησης έχουν προχωρήσει μαζικά πρόσφατα με επιτυχημένες εφαρμογές στην αναγνώριση ομιλίας, στην επεξεργασία φυσικής γλώσσας (NLP), στην ανάκτηση πληροφοριών, στην υπολογιστική όραση και στην ανάλυση εικόνας .

Η έννοια της βαθιάς μάθησης προήλθε από τη μελέτη για τεχνητά νευρωνικά δίκτυα (ΤΝΔ) . Τα ΤΝΔ έχουν γίνει ενεργός ερευνητικός τομέας τις τελευταίες δεκαετίες . Ωστόσο, ανάλογα με τα προβλήματα, η διαδικασία εκπαίδευσης ενός NN μπορεί να διαρκέσει μεγάλες αιτιώδεις αλυσίδες υπολογιστικών σταδίων. Το Backpropagation είναι ένας αποτελεσματικός

αλγόριθμος gradient descend που έπαιξε σημαντικό ρόλο στα NN από το 1980. Εκπαιδεύει τα TND με προσέγγιση μάθησης με επίβλεψη “δασκάλου” . Αν και η ακρίβεια εκπαίδευσης είναι υψηλή, η απόδοση του backpropagation όταν εφαρμόζεται στα δεδομένα δοκιμών μπορεί να μην είναι ικανοποιητική. Καθώς ο backpropagation βασίζεται σε πληροφορίες τοπικής κλίσης με τυχαίο αρχικό σημείο, ο αλγόριθμος συχνά παγιδεύεται στα τοπικά βέλτιστα. Επιπλέον, εάν το μέγεθος των δεδομένων εκπαίδευσης δεν είναι αρκετά μεγάλο, τα TND θα αντιμετωπίσουν το πρόβλημα της υπερπροσαρμογής. Κατά συνέπεια, υιοθετήθηκαν άλλοι αποτελεσματικοί αλγόριθμοι μηχανικής μάθησης, όπως η μηχανή διάνυσμα υποστήριξης (SVM), η ενίσχυση (boosting) και ο πλησιέστερος γείτονας (K-nearest neighbour -KNN) για την επίτευξη του συνολικού βέλτιστου με χαμηλότερη κατανάλωση ενέργειας. Το 2006, ο Χίντον πρότεινε μια νέα μέθοδο κατάρτισης (που ονομάζεται layer-wise-greedy-learning) που σηματοδότησε τη γέννηση τεχνικών βαθιάς μάθησης. Η βασική ιδέα της μεθόδου αυτής είναι ότι η μάθηση χωρίς επίβλεψη πρέπει να πραγματοποιείται για προ-εκπαίδευση στο δίκτυο πριν από την επακόλουθη εκπαίδευση στρώματος-στρώματος. Με την εξαγωγή χαρακτηριστικών από τις εισόδους, η διάσταση των δεδομένων μειώνεται και αποκτάται συνεπώς μια συμπαγής αναπαράσταση. Στη συνέχεια, εξάγοντας τις δυνατότητες στο επόμενο επίπεδο, όλα τα δείγματα θα ετικετοποιηθούν και το δίκτυο θα ρυθμιστεί με τα ετικετοποιημένα δεδομένα. Ο λόγος για τη δημοτικότητα της βαθιάς μάθησης είναι διπλός: αφενός, η ανάπτυξη τεχνικών ανάλυσης μεγάλων δεδομένων δείχνει ότι το πρόβλημα υπερπροσαρμογής προσαρμογής στα δεδομένα εκπαίδευσης μπορεί να λυθεί εν μέρει. Από την άλλη πλευρά, η διαδικασία προ-εκπαίδευσης πριν από την χωρίς επίβλεψη μάθηση θα εκχωρήσει μη τυχαίες αρχικές τιμές στο δίκτυο. Επομένως, μπορεί να επιτευχθεί ένα καλύτερο τοπικό ελάχιστο μετά τη διαδικασία εκπαίδευσης και να επιτευχθεί ένας ταχύτερος ρυθμός σύγκλισης.

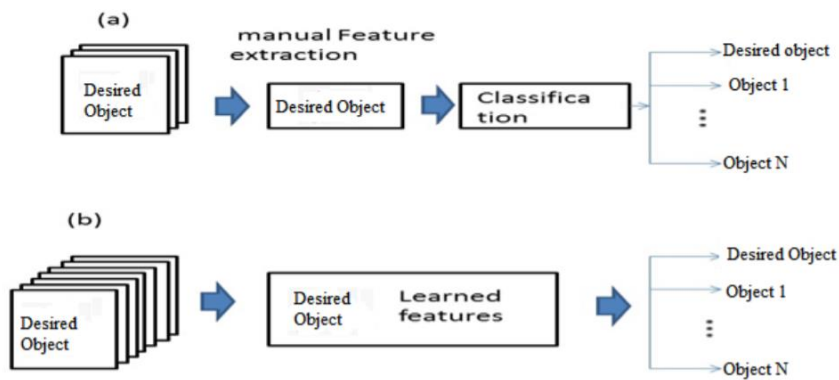
Μέχρι τώρα, η έρευνα σχετικά με τις τεχνικές βαθιάς μάθησης έχει τραβήξει μεγάλη προσοχή και μια σειρά συναρπαστικών αποτελεσμάτων έχουν αναφερθεί στις βιβλιογραφίες. Από το 2009, ο διαγωνισμός του ImageNet έχει προσελκύσει πολλές ομάδες έρευνας όρασης υπολογιστών σε όλο τον κόσμο, τόσο από τον ακαδημαϊκό χώρο όσο και από τη βιομηχανία. Το 2012, η ερευνητική ομάδα με επικεφαλής τον Χίντον κέρδισε τον διαγωνισμό της Ταξινόμησης εικόνας ImageNet χρησιμοποιώντας προσεγγίσεις βαθιάς μάθησης . Η ομάδα του Χίντον παρακολούθησε τον διαγωνισμό για πρώτη φορά και τα αποτελέσματά τους ήταν 10% καλύτερα από αυτά της δεύτερης θέσης. Τόσο η Google όσο και η Baidu έχουν ενημερώσει τις μηχανές αναζήτησης εικόνας που βασίζονται στην αρχιτεκτονική βαθιάς εκμάθησης του Hinton με μεγάλες βελτιώσεις στην ακρίβεια αναζήτησης. Ο Baidu δημιούργησε επίσης το Institute of Deep Learning (IDL) το 2013 και κάλεσε τον Andrew Ng, αναπληρωτή καθηγητή στο Πανεπιστήμιο του Στάνφορντ, ως επικεφαλής επιστήμονα. Τον Μάρτιο του 2016, ένας αγώνας Go Game πραγματοποιήθηκε στη Νότια Κορέα από το πρόγραμμα βαθιάς εκμάθησης της Google (που ονομάζεται DeepMind) μεταξύ του παίκτη AI AlphaGo και ενός από τους ισχυρότερους παίκτες του κόσμου Lee Se-dol . Αποδείχθηκε ότι ο AlphaGo, υιοθετώντας τεχνικές βαθιάς εκμάθησης, έδειξε εκπληκτική δύναμη και κέρδισε τον Lee Se-dol με 4: 1. Επιπλέον, οι αλγόριθμοι βαθιάς μάθησης έχουν επίσης δείξει εξαιρετική απόδοση στην πρόβλεψη της δραστηριότητας των πιθανών μορίων φαρμάκου και των επιπτώσεων των μεταλλάξεων στο μη κωδικοποιητικό DNA στην έκφραση γονιδίων.

Το Σχήμα 7.1 παρακάτω δείχνει την απόδοση της βαθιάς μάθησης και των παλαιότερων αλγορίθμων μάθησης σε διάφορους τομείς.



Σχήμα 7.1 Η απόδοση των παραδοσιακών μεθόδων μάθησης έναντι αυτής της βαθιάς μάθησης


Με την ταχεία ανάπτυξη των τεχνικών υπολογισμού, παρέχεται ένα ισχυρό πλαίσιο από τα ΤΝΔ με βαθιά αρχιτεκτονική για εποπτευόμενη μάθηση. Σε γενικές γραμμές, ο αλγόριθμος βαθιάς μάθησης αποτελείται από μια ιεραρχική αρχιτεκτονική με πολλά επίπεδα, το καθένα από τα οποία αποτελεί μια μη γραμμική μονάδα επεξεργασίας πληροφοριών. Με άλλα λόγια, τα δίκτυα με αυτό το είδος δομής πολλαπλών στρωμάτων - τα δίκτυα με δύο ή περισσότερα κρυμμένα στρώματα-ονομάζονται βαθιά νευρωνικά δίκτυα. Αυτές οι τεχνικές βαθιάς μάθησης βασίζονται σε στοχαστική gradient descent και backpropagation, αλλά εισάγουν και νέες ιδέες. Τα βαθιά νευρωνικά δίκτυα (DNNs), τα οποία χρησιμοποιούν βαθιές αρχιτεκτονικές σε ΤΝΔ, μπορούν να αντιπροσωπεύουν συναρτήσεις με υψηλότερη πολυπλοκότητα εάν αυξηθούν οι αριθμοί των στρωμάτων και των μονάδων σε ένα μόνο επίπεδο. Λαμβάνοντας υπόψη αρκετά σύνολα δεδομένων εκπαίδευσης και κατάλληλα μοντέλα, οι προσεγγίσεις βαθιάς μάθησης μπορούν να βοηθήσουν τους ανθρώπους να δημιουργήσουν συναρτήσεις χαρτογράφησης για ευκολία λειτουργίας. Αυτές οι τεχνικές έχουν επιτρέψει την εκπαίδευση πολύ βαθύτερων (και μεγαλύτερων) δικτύων. Και, αποδεικνύεται ότι αποδίδουν πολύ καλύτερα σε πολλά προβλήματα από τα ρηχά (ή αλλιώς απλά) νευρωνικά δίκτυα, δηλαδή τα δίκτυα με μόνο ένα κρυφό στρώμα. Ο λόγος, φυσικά, είναι η ικανότητα των βαθιών δικτύων να δημιουργούν μια περίπλοκη ιεραρχία εννοιών. Μοιάζει λίγο με τον τρόπο που οι συμβατικές γλώσσες προγραμματισμού χρησιμοποιούν αρθρωτό σχεδιασμό και ιδέες για την αφαίρεση για να επιτρέψουν τη δημιουργία πολύπλοκων προγραμμάτων υπολογιστών. Το να συγκρίνεις ένα βαθύ δίκτυο με ένα ρηχό δίκτυο είναι λίγο σαν να συγκρίνεις μια γλώσσα προγραμματισμού με την ικανότητα να πραγματοποιεί κλήσεις συναρτήσεων σε μια γλώσσα που δεν έχει τη δυνατότητα να πραγματοποιεί τέτοιες κλήσεις. Στο παρακάτω Σχήμα 7.2 βλέπουμε τη διαφορά μεταξύ της παραδοσιακής μάθησης και της βαθιάς μάθησης στην κατηγοριοποίηση ενός αντικειμένου, όπου το (α) είναι η ταξινόμηση χρησιμοποιώντας την παραδοσιακή μέθοδο εκμάθησης και το (β) είναι η μέθοδος βαθιάς εκμάθησης που μαθαίνει αυτόματα από το σύνολο δεδομένων.



Σχήμα 7.2 Παραδοσιακή και Βαθιά Μάθηση

7.1.α Σε τι διαφέρει η βαθιά μάθηση από τα ΤΝΔ

Παρόλο που υπονοούσαν στην εξήγηση των νευρωνικών δικτύων, αξίζει να σημειωθεί πιο ρητά. Το «βαθύ» στη βαθιά μάθηση αναφέρεται στο βάθος των στρωμάτων σε ένα νευρωνικό δίκτυο. Ένα νευρωνικό δίκτυο που αποτελείται από περισσότερα από τρία στρώματα - τα οποία θα περιλαμβάνουν τις εισόδους και την έξοδο - μπορεί να θεωρηθεί ως αλγόριθμος βαθιάς μάθησης. Αυτό γενικά αναπαρίσταται χρησιμοποιώντας το ακόλουθο διάγραμμα:



Σχήμα 7.3 Βαθύ Νευρωνικό Δίκτυο

Τι είναι λοιπόν ένα πυκνό (βαθύ) νευρωνικό δίκτυο (dense neural network -DNN) ;


Το όνομα υποδηλώνει ότι τα στρώματα συνδέονται πλήρως (πυκνά) από τους νευρώνες σε ένα στρώμα δικτύου. Κάθε νευρώνας σε ένα στρώμα λαμβάνει μια είσοδο από όλους τους νευρώνες που υπάρχουν στο προηγούμενο στρώμα - επομένως, είναι πυκνά συνδεδεμένοι.

Με άλλα λόγια, το πυκνό στρώμα είναι ένα τυπικό feedforward δίκτυο, ένα πλήρως συνδεδεμένο στρώμα, που σημαίνει ότι όλοι οι νευρώνες σε ένα στρώμα συνδέονται με αυτούς του επόμενου στρώματος.

Υπάρχει πολύ μικρή διαφορά μεταξύ του τρόπου υπολογισμού ενός βαθιού νευρωνικού δικτύου σε σύγκριση με το πρώτο νευρωνικό δίκτυο. Πάντα μπορούσαμε να δημιουργήσουμε και να υπολογίσουμε βαθιά νευρωνικά δίκτυα. Ένα βαθύ νευρωνικό δίκτυο δεν είναι παρά ένα νευρωνικό δίκτυο με πολλά επίπεδα. Παρόλο που ήμασταν πάντα σε θέση να

δημιουργήσουμε/υπολογίσουμε βαθιά νευρωνικά δίκτυα, μας έλειπε ένα αποτελεσματικό μέσο εκπαίδευσης. Η βαθιά μάθηση παρέχει ένα αποτελεσματικό μέσο για την εκπαίδευση βαθιών νευρωνικών δικτύων.

Το DNN είναι μια συλλογή νευρώνων οργανωμένων σε μια ακολουθία πολλαπλών στρωμάτων, όπου οι νευρώνες λαμβάνουν ως είσοδο τις ενεργοποιήσεις νευρώνων από το προηγούμενο στρώμα και εκτελούν έναν απλό υπολογισμό (π.χ. ένα σταθμισμένο άθροισμα της εισόδου που ακολουθείται από μια μη γραμμική ενεργοποίηση). Οι νευρώνες του δικτύου υλοποιούν από κοινού μια σύνθετη μη γραμμική χαρτογράφηση από την είσοδο στην έξοδο. Αυτή η χαρτογράφηση μαθαίνεται από τα δεδομένα προσαρμόζοντας τα βάρη κάθε νευρώνα χρησιμοποιώντας μια τεχνική που ονομάζεται σφάλμα backpropagation . Τα περισσότερα βαθιά νευρωνικά δίκτυα προωθούνται, δηλαδή ρέουν προς μία κατεύθυνση μόνο από την είσοδο στην έξοδο. Ωστόσο, μπορούμε επίσης να εκπαιδεύσουμε το μοντέλο μας μέσω backpropagation, δηλαδή, να μετακινηθούμε προς την αντίθετη κατεύθυνση από την έξοδο στην είσοδο. Το backpropagation μας επιτρέπει να υπολογίσουμε και να αποδώσουμε το σφάλμα που σχετίζεται με κάθε νευρώνα, επιτρέποντάς μας να προσαρμόσουμε τον αλγόριθμο κατάλληλα. Ένα παράδειγμα νευρωνικού δικτύου φαίνεται στο σχήμα .




Σχήμα 7.3 Παράδειγμα χαρτογράφησης DNN

Τα βαθιά νευρωνικά δίκτυα (DNNs), τα οποία χρησιμοποιούν βαθιές αρχιτεκτονικές σε NNs, μπορούν να αντιπροσωπεύουν συναρτήσεις με υψηλότερη πολυπλοκότητα εάν αυξηθεί ο αριθμός των στρωμάτων και των μονάδων σε ένα μόνο επίπεδο.

7.2 Γιατί Βαθιά Μάθηση;

Για την πρόβλεψη μοντελοποίησης, τα βαθιά νευρωνικά δίκτυα δεν είναι τόσο διαφορετικά από άλλα μοντέλα, όπως: α) SVMs, β) Random Forests, γ) Gradient Boosted Machines . Όπως και αυτά τα μοντέλα, τα νευρωνικά δίκτυα μπορούν να εκτελέσουν ταξινόμηση και παλινδρόμηση. Όταν εφαρμόζονται σε σχετικά μικρές διαστατικές προγνωστικές εργασίες μοντελοποίησης, τα βαθιά νευρωνικά δίκτυα δεν προσθέτουν απαραίτητα σημαντική ακρίβεια σε σχέση με άλλους τύπους μοντέλων. Το πλεονέκτημα των βαθιών νευρωνικών δικτύων έναντι των παραδοσιακών τύπων μοντέλων όπως απεικονίζεται στο Σχήμα 7.4



Σχήμα 7.4 Γράφημα που δείχνει την απόδοση της βαθιάς μάθησης έναντι των παραδοσιακών τύπων μοντέλων

Τα βαθιά νευρωνικά δίκτυα έχουν επίσης δύο επιπλέον σημαντικά πλεονεκτήματα σε σχέση με άλλα μοντέλα μηχανικής μάθησης:

- Συνελικτικά νευρωνικά δίκτυα (CNN) - Μπορούν να σαρώσουν μια εικόνα για μοτίβα μέσα στην εικόνα.
- Επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) - Μπορεί να βρει μοτίβα σε πολλές εισόδους, όχι μόνο σε μία μόνο είσοδο.

Τα νευρωνικά δίκτυα είναι επίσης πολύ ευέλικτα στους τύπους δεδομένων που είναι συμβατά με τα επίπεδα εισόδου και εξόδου. Ένα νευρωνικό δίκτυο μπορεί να λάβει δεδομένα πίνακα, εικόνες, ακολουθίες ήχου, δεδομένα πίνακα χρονικών σειρών και κείμενο ως είσοδο ή έξοδο.

7.3 Τρόποι εφαρμογής Βαθιάς Μάθησης

1) Προβλήματα πρόβλεψης Αναμφισβήτητα ο πιο απλός τρόπος εφαρμογής της βαθιάς μάθησης είναι να την χρησιμοποιήσουμε για την αντιμετώπιση σημαντικών προβλημάτων πρόβλεψης: αντιστοίχιση εισόδων σε προβλέψιμα αποτελέσματα. Αυτή η προγνωστική χρήση της βαθιάς εκμάθησης είναι συνήθως ο τρόπος με τον οποίο χρησιμοποιείται επίσης σε βασικά προβλήματα υπολογιστών και μηχανικής μάθησης. Για παράδειγμα, η είσοδος μπορεί να είναι μια εικόνα βιοψίας και το μοντέλο θα πρέπει να παράγει μια πρόβλεψη για το αν ο απεικονιζόμενος ιστός εμφανίζει σημάδια καρκίνου. Μπορούμε επίσης να σκεφτούμε αυτήν την προγνωστική περίπτωση χρήσης ως το να μαθαίνει το μοντέλο μια συνάρτηση στόχου, στο παράδειγμά μας, χαρτογράφηση από οπτικά χαρακτηριστικά εισόδου σε καρκίνο/μη καρκινική παραγωγή. Η χρήση της βαθιάς μάθησης με αυτόν τον τρόπο περιλαμβάνει επίσης ρυθμίσεις όπου η συνάρτηση στόχου είναι πολύ περίπλοκη, χωρίς μαθηματική κλειστή μορφή ή λογικό σύνολο κανόνων που περιγράφουν τον τρόπο μετάβασης από την είσοδο στην έξοδο. Για παράδειγμα, μπορεί να χρησιμοποιήσουμε ένα μοντέλο βαθιάς μάθησης για να προσομοιώσουμε (μαύρο κουτί) μια πολύπλοκη διαδικασία (π.χ. μοντελοποίηση κλίματος), που είναι πολύ δύσκολο να μοντελοποιήσουμε.

2) Από τις Προβλέψεις στην Κατανόηση Μια βασική διαφορά μεταξύ επιστημονικών ερωτήσεων και βασικών προβλημάτων μηχανικής μάθησης είναι η έμφαση των πρώτων στην κατανόηση των υποκείμενων μηχανισμών. Συχνά, η εξαγωγή μιας ακριβούς πρόβλεψης από μόνη της δεν είναι αρκετή. Αντ' αυτού, θέλουμε να αποκτήσουμε ερμηνεύσιμες γνώσεις σχετικά με τις ιδιότητες των δεδομένων ή τη διαδικασία δημιουργίας δεδομένων που οδήγησαν στην παρατηρούμενη πρόβλεψη ή στο αποτέλεσμα. Για να αποκτήσουμε τέτοιου είδους ιδέες, μπορούμε να στραφούμε σε μεθόδους ερμηνείας και ανάλυσης αναπαράστασης στη βαθιά μάθηση, οι οποίες επικεντρώνονται στον προσδιορισμό του τρόπου με τον οποίο το μοντέλο νευρωνικών δικτύων κάνει μια συγκεκριμένη πρόβλεψη. Έχει γίνει σημαντική εργασία και στα δύο εργαλεία για να κατανοηθεί ποια χαρακτηριστικά εισόδου είναι πιο κρίσιμα για την πρόβλεψη εξόδου, καθώς και τεχνικές για την άμεση ανάλυση των κρυφών αναπαραστάσεων των μοντέλων νευρωνικών δικτύων, οι οποίες μπορούν να αποκαλύψουν σημαντικές ιδιότητες των υποκείμενων δεδομένων.

3) Σύνθετοι μετασχηματισμοί δεδομένων εισόδου Σε πολλούς επιστημονικούς τομείς, η ποσότητα των δεδομένων που δημιουργήθηκαν, ιδιαίτερα τα οπτικά δεδομένα (π.χ. μικροσκοπία φθορισμού, χωρική αλληλουχία, βίντεο δειγμάτων) έχει αυξηθεί δραματικά και υπάρχει επείγουσα ανάγκη για αποτελεσματική ανάλυση και αυτοματοποιημένη επεξεργασία. Οι τεχνικές βαθιάς μάθησης, οι οποίες είναι ικανές για πολλούς πολύπλοκους μετασχηματισμούς δεδομένων, μπορούν να είναι εξαιρετικά αποτελεσματικές για τέτοιες ρυθμίσεις, για παράδειγμα, χρησιμοποιώντας ένα μοντέλο τμηματοποίησης βασισμένο σε νευρωνικό δίκτυο για τον αυτόματο προσδιορισμό των πυρήνων στις εικόνες των κυττάρων ή

ένα σύστημα εκτίμησης πόζας, για την ταχεία επισήμανση συμπεριφορών που εμφανίζονται σε βίντεο ποντικών για ανάλυση νευροεπιστήμης.

7.4 DNN και Ταξινόμηση

Ενώ η γεωμετρία των περιοχών ταξινόμησης και των συναρτήσεων απόφασης που προκαλούνται από τους παραδοσιακούς ταξινομητές (όπως γραμμικός ταξινομητής και πυρήνας SVM) είναι αρκετά καλά κατανοητή, αυτές οι θεμελιώδεις γεωμετρικές ιδιότητες είναι σε μεγάλο βαθμό άγνωστες για τα υπερσύγχρονα βαθιά νευρωνικά δίκτυα. Ωστόσο, για να κατανοήσουμε την πρόσφατη επιτυχία των βαθιών νευρωνικών δικτύων και ενδεχομένως να αντιμετωπίσουμε τις αδυναμίες τους (όπως η αστάθεια τους στις διαταραχές), η κατανόηση αυτών των γεωμετρικών ιδιοτήτων παραμένει αρχέγονη. Ενώ πρόσφατα μελετήθηκαν πολλές θεμελιώδεις ιδιότητες των βαθιών δικτύων, όπως το τοπίο βελτιστοποίησης, η γενίκευσή τους και η εκφραστικότητα τους, οι γεωμετρικές ιδιότητες των ορίων απόφασης και των περιοχών ταξινόμησης των βαθιών δικτύων έχουν συγκριτικά λάβει ελάχιστη προσοχή. (Ο στόχος αυτής της παραγράφου είναι να αναλύσει αυτές τις ιδιότητες και να τις αξιοποιήσει για να βελτιώσει τη στιβαρότητα τέτοιων ταξινομητών σε διαταραχές.

7.4.α Γραμμική ταξινόμηση και DNN

Ένα πυκνά συνδεδεμένο στρώμα παρέχει χαρακτηριστικά μάθησης από όλους τους συνδυασμούς των χαρακτηριστικών του προηγούμενου στρώματος, ενώ ένα στρεπτικό/συνελικτικό στρώμα βασίζεται σε σταθερά χαρακτηριστικά με ένα μικρό επαναλαμβανόμενο πεδίο.

7.4.β Τοπολογία περιφερειών DNN

Τα βαθιά δίκτυα δημιουργούν διαλυμένες και αποσυνδεδεμένες περιοχές ταξινόμησης ή, αντίθετα, μία μεγάλη συνδεδεμένη περιοχή ανά ετικέτα; Ενώ τα βαθιά νευρωνικά δίκτυα έχουν έναν εκθετικό αριθμό γραμμικών περιοχών (σε σχέση με τον αριθμό των στρωμάτων) στο χώρο εισόδου, παραμένει ασαφές εάν τα βαθιά δίκτυα δημιουργούν μία συνδεδεμένη περιοχή ανά κλάση ή διασπούν μια περιοχή ταξινόμησης γύρω από έναν μεγάλο αριθμό μικρών συνδεδεμένων συνόλων. Τυπικά θέτουμε το πρόβλημα της συνδεσιμότητας των περιοχών ταξινόμησης ως εξής: δεδομένου ότι υπάρχουν δύο σημεία δεδομένων $x_1, x_2 \in R_i$ υπάρχει μια συνεχής καμπύλη $\gamma: [0, 1] \rightarrow R_i$ έτσι ώστε $\gamma(0) = x_1, \gamma(1) = x_2$.

Οι περιοχές ταξινόμησης που δημιουργούνται από βαθιά νευρωνικά δίκτυα συνδέονται στο R^d : τα βαθιά δίκτυα δημιουργούν ενιαίες μεγάλες περιοχές που περιέχουν όλα τα σημεία της ίδιας ετικέτας. Όταν τα τελικά σημεία είναι δύο τυχαίες δειγματοληψίες εικόνων από το σύνολο επικύρωσης, η ευθεία διαδρομή μεταξύ των δύο τελικών σημείων ανήκει συντριπτικά στην περιοχή ταξινόμησης. Ωστόσο, οι περιοχές ταξινόμησης δεν είναι κυρτά σώματα στο R^d .

7.4.γ Τοπολογία των δεδομένων

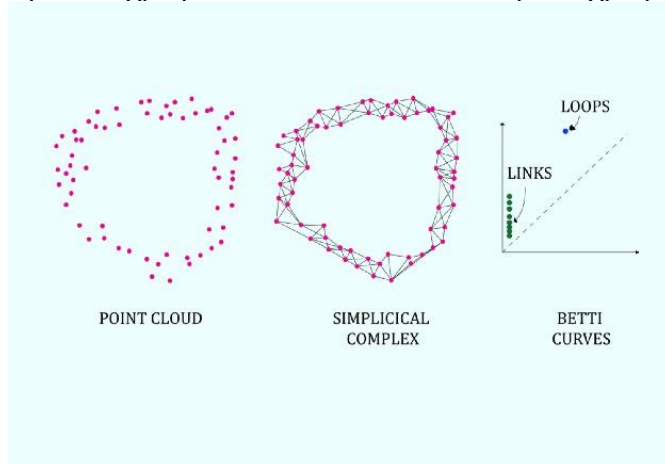
Η οπτικοποίηση αναπαραστάσεων δεδομένων υψηλής διάστασης μέσω μείωσης διαστάσεων είναι μια πολύ γνωστή τεχνική για την εξέταση μοντέλων βαθιάς μάθησης. Εκτός από τη μείωση διαστάσεων, υπάρχουν εναλλακτικές τεχνικές για την απεικόνιση μοντέλων υψηλής διάστασης. Η τοπολογία αναλύει τις πληροφορίες σύνδεσης στοιχείων σε ένα χώρο και ασχολείται με ποιοτικές γεωμετρικές πληροφορίες. Η ανάλυση τοπολογικών δεδομένων (TDA) χρησιμοποιεί θεωρία κατηγορίας, αλγεβρική τοπολογία και άλλες καθαρές μαθηματικές μεθόδους για την πρακτική διερεύνηση της μορφής δεδομένων. Τα σύνολα

δεδομένων υψηλής διάστασης περιορίζουν σημαντικά την ικανότητά μας να τα οπτικοποιήσουμε. Αυτός είναι ο λόγος για τον οποίο το TDA μπορεί να μας βοηθήσει στη βελτίωση της ικανότητάς μας να οπτικοποιούμε και να αναλύουμε πληροφορίες. Οι πιο συχνά παρατηρούμενες τοπολογίες δεδομένων περιλαμβάνουν συνδεδεμένα στοιχεία, βρόχους, κενά και ούτω καθεξής.

Η κατάρτα της διαστατικότητας είναι ένα από τα πιο σημαντικά ζητήματα που αντιμετωπίζουμε κατά την αξιολόγηση των αναπαραστάσεων δεδομένων υψηλής διάστασης σε βαθιά νευρωνικά δίκτυα. Σε χώρο υψηλής διάστασης, τα σημεία είναι πολύ αραιά. Όταν το DNN μεταφέρει δεδομένα από το ένα στρώμα στο άλλο με διαφορετική διάσταση, οι ευκλείδειες αποστάσεις μεταξύ των σημείων και η απόσταση ενός σημείου σε ένα υποσύνολο μεγαλώνει. Η τοπολογία μελετά μόνο τις ιδιότητες των γεωμετρικών αντικειμένων που δεν εξαρτώνται από τις επιλεγμένες συντεταγμένες (είναι χωρίς συντεταγμένες). Για το λόγο αυτό, αυτό το εργαλείο είναι ιδανικό για την ανάλυση αναπαραστάσεων DNN.

Η τοπολογία αποφεύγει τις ποσοτικές τιμές των συναρτήσεων απόστασης και τις αντικαθιστά με την έννοια της «άπειρης εγγύτητας» ενός σημείου σε ένα υποσύνολο στον υποκείμενο χώρο.

Οι μέθοδοι ανάλυσης δεδομένων τοπολογίας ακολουθούν μια βασική ρουτίνα: συναντάμε έναν τοπολογικό χώρο (αναπαράσταση ενός συνόλου δεδομένων μεγάλων διαστάσεων) και πρέπει να βρούμε τη θεμελιώδη ομάδα του (σχέσεις δεδομένων ως σύνδεσμοι, βρόχοι ή κενά). Αλλά το σύνολο δεδομένων μας είναι ένας άγνωστος χώρος και είναι πολύ δύσκολο να δούμε ρητούς βρόχους και σχέσεις. Στη συνέχεια, ψάχνουμε για έναν άλλο χώρο που είναι ομότοπος ισοδύναμος με τον δικό μας, και του οποίου η βασική ομάδα είναι πολύ πιο εύκολο να υπολογιστεί. Δεδομένου ότι και οι δύο χώροι είναι ισοδύναμοι με ομοτοπία, γνωρίζουμε ότι η θεμελιώδης ομάδα στο χώρο μας είναι ισομορφική σε θεμελιώδη ομάδα στο νέο χώρο (δίνει τις ίδιες πληροφορίες συνδεσιμότητας δεδομένων). Και είναι μια διαδικασία χωρίς συντεταγμένες. Οι πληροφορίες συνδεσιμότητας επιπέδου 1 σχετίζονται με συνδέσμους δεδομένων, πληροφορίες συνδεσιμότητας επιπέδου δύο με βρόχους δεδομένων και επιπέδου τρίτου με κενά (το Σχήμα 7.5 δείχνει το επίπεδο πρώτο σε πράσινο χρώμα και το επίπεδο δύο σε μπλε χρώμα).



Σχήμα 7.5 Τοπολογία Δεδομένων

7.5 Είναι πραγματικά η ιδανική ταξινόμηση;

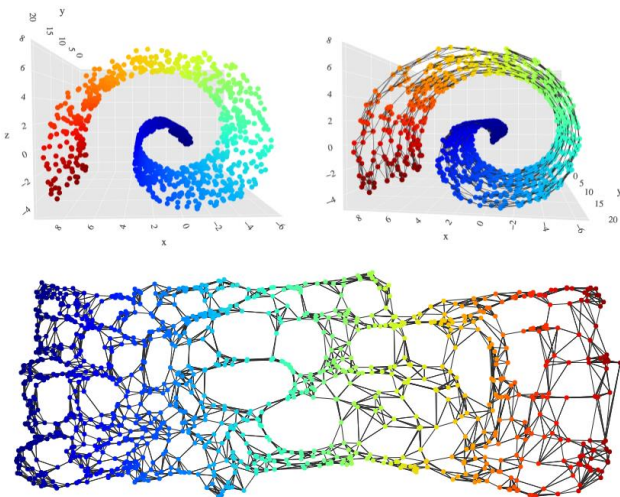
Το DNN λύνει το πρόβλημα ταξινόμησης συνδέοντας όσο το δυνατόν περισσότερα σημεία. Εκτός από αυτό που θα μπορούσαμε να ονομάσουμε τον κύριο συνδεδεμένο κλάδο, το επίπεδο εξόδου έχει μόνο έναν απομονωμένο κόμβο και ένα συνδεδεμένο στοιχείο δύο κόμβων. Τα σημεία συνδέονται περισσότερο από ό, τι στα προηγούμενα επίπεδα.

Η τελική φάση της εκπαίδευσης (TPT) και τα αναμενόμενα αποτελέσματά της είναι ευπρόσδεκτα και επιθυμητά. Ενώ αυτή η πεποίθηση είναι δελεαστική, θα πρέπει να αναδείξουμε τους κινδύνους σε ένα τέτοιο καθεστώς εκπαίδευσης. Η πρόωρη διακοπή ή η αποφυγή παρεμβολής είναι μια γνωστή τεχνική κανονικοποίησης που έχει αποδειχθεί ότι είναι επωφελής για την επεξεργασία φυσικής γλώσσας και την ταξινόμηση εικόνας, και ιδιαίτερα όταν το σύνολο δεδομένων περιλαμβάνει θόρυβο ετικέτας, όπως συνηθίζεται σε πολλές εφαρμογές.

Μια άλλη εξέταση έχει να κάνει με την έννοια της εσφαλμένης βαθμονόμησης : Το TPT οδηγεί σε έναν ταξινομητή του οποίου η έξοδος δεν αντιπροσωπεύει τη βεβαιότητα του μοντέλου. Σε πρακτικές εφαρμογές, αυτό το μέτρο εμπιστοσύνης θα μπορούσε να είναι ζωτικής σημασίας στη διαδικασία λήψης αποφάσεων. Εάν ταξινομήσουμε τις τάξεις C και μερικές είναι νοηματικά κοντά η μία στην άλλη (π.χ. αυτοκίνητα και φορτηγά), ίσως θα ήταν πιο λογικό να το φιλοξενήσουμε στα κέντρα που αποκτήθηκαν, επιτρέποντας μια ευκολότερη μετανάστευση μεταξύ ορισμένων τάξεων.

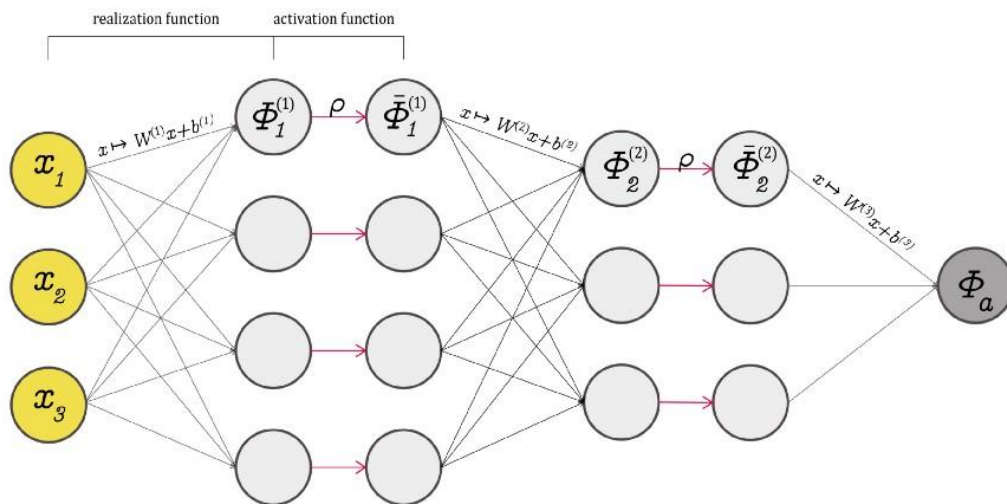
7.6 Μαθηματική ανάλυση των DNN

Το αναδυόμενο θέμα της μαθηματικής ανάλυσης βαθιάς μάθησης έχει αναλάβει να απαντήσει σε ορισμένα «μυστηριώδη» γεγονότα που φαίνεται να είναι ανεξήγητα οι παραδοσιακές μαθηματικές μεθοδολογίες. Προσπαθούν να κατανοήσουν τι πραγματικά κάνει ένα νευρωνικό δίκτυο. Τα Deep Neural Networks (DNN) μετατρέπουν τα δεδομένα σε κάθε επίπεδο, δημιουργώντας μια νέα αναπαράσταση ως έξοδο. Το DNN επιχειρεί να διαιρέσει τα δεδομένα σε ένα πρόβλημα ταξινόμησης, ενισχύοντας αυτήν τη δράση στρώμα προς στρώμα μέχρι να φτάσει σε ένα επίπεδο εξόδου όταν το DNN παρέχει το καλύτερο δυνατό αποτέλεσμα. Σύμφωνα με την υπόθεση της πολλαπλής (the manifold hypothesis) (τα φυσικά δεδομένα δημιουργούν πολλαπλές χαμηλότερης διάστασης στο χώρο ενσωμάτωσής τους), αυτή η εργασία μπορεί να θεωρηθεί ως ο διαχωρισμός πολλαπλών χαμηλότερων διαστάσεων σε έναν χώρο δεδομένων [60] .



Σχήμα 7.6 The manifold hypothesis

Τα στρώματα DNN συνδέονται με μια συνάρτηση συνειδητοποίησης - realization function, Φ (μετασχηματισμός συγγένειας) και μια συνάρτηση ενεργοποίησης, ρ (Σχήμα 7.6)



Σχήμα 7.7 Συνάρτηση συνειδητοποίησης και συνάρτηση ενεργοποίησης

Η αρχιτεκτονική του δικτύου μπορεί να περιγραφεί καθορίζοντας τον αριθμό των στρωμάτων N , L , τον αριθμό των νευρώνων και τη συνάρτηση ενεργοποίησης. Οι παράμετροι του δικτύου είναι ο πίνακας βαρών W και τα διανύσματα πόλωσης b . Η έξοδος κάθε στρώματος είναι ένας νέος τρόπος περιγραφής των εισόδων. Αυτός είναι ο λόγος για τον οποίο αναφέρονται ως αναπαραστάσεις, καθώς είναι ουσιαστικά αφαιρέσεις από δεδομένα εισόδου. Για κάθε στρώμα, $\Phi(x, \theta) = Wx + b$, με παραμέτρους $\theta = (W, b)$, ο πίνακας βαρών είναι ο W , ενώ το διάνυσμα πόλωσης είναι το b .

Η συνάρτηση ενεργοποίησης είναι καθοριστική για τον προσδιορισμό του τρόπου με τον οποίο συνδέονται τα νευρωνικά δίκτυα και για τις πληροφορίες που μεταδίδονται από το ένα στρώμα στο επόμενο. Τέλος, ελέγχει την ανταλλαγή πληροφοριών, επιτρέποντας στα νευρωνικά δίκτυα να «μάθουν» από τα δεδομένα. Το τι μαθαίνουν και γιατί το μαθαίνουν παραμένει ένα δύσκολο θέμα. Ορισμένοι ερευνητές υποστηρίζουν ακόμη ότι το DNN μπορεί να μάθει κάτι συγκεκριμένο από τα δεδομένα και ότι αυτή η έρευνα μοιράζεται σε πολλά επίπεδα. Επομένως, το επιχείρημα ότι ένα επίπεδο μαθαίνει κάτι και μετά περνά μια αναπαραστάση στο επόμενο επίπεδο, το οποίο μαθαίνει κάτι άλλο, είναι εν μέρει σωστό.

Τα βαθιά δίκτυα έχουν τη θεωρητική εγγύηση, την οποία δεν έχουν τα ρηχά δίκτυα, ότι μπορούν να αποφύγουν την κατάρα της διαστατικότητας για μια σημαντική κατηγορία προβλημάτων, που αντιστοιχούν σε ένα συγκεκριμένο τύπο συνθετικών συναρτήσεων, δηλαδή συναρτήσεις συνιστώσες. Ένα ιδιαίτερα ενδιαφέρον υποσύνολο συνθετικών συναρτήσεων είναι αυτές που μπορούν να γραφτούν ως ιεραρχικά τοπικές συνθετικές συναρτήσεις όπου όλες οι συνιστώσες συναρτήσεις είναι τοπικές - με την έννοια της περιορισμένης μικρής διάστασης. Τα βαθιά δίκτυα που μπορούν να τα προσεγγίσουν χωρίς την κατάρα της διαστατικότητας είναι του βαθιού συνελκτικού τύπου.

Ορίζουμε ένα βαθύ δίκτυο με K επίπεδα με τις συνηθισμένες κλιμακούμενες ανά συντεταγμένες συναρτήσεις ενεργοποίησης $\sigma(z): \mathbb{R} \rightarrow \mathbb{R}$ ως το σύνολο των συναρτήσεων $f(W;x) = \sigma(W^K \sigma(W^{K-1} \dots \sigma(W^1 x)))$, όπου η είσοδος είναι $x \in \mathbb{R}^d$ και τα βάρη δίνονται από τους πίνακες W^k , ένα ανά στρώμα, με αντίστοιχες διαστάσεις. Μερικές φορές χρησιμοποιούμε το σύμβολο W ως συντομογραφία για το σύνολο των W^k πινάκων $k = 1, \dots, K$. Δεν υπάρχουν όροι μεροληψίας (bias terms): Το bias εμφανίζεται στο επίπεδο εισόδου με μία από τις διαστάσεις εισόδου να είναι μια σταθερά. Ένα ρηχό δίκτυο είναι ένα βαθύ δίκτυο με $K = 1$.

Προσαρμόζουμε συναρτήσεις με δίκτυα στα οποία η μη γραμμικότητα ενεργοποίησης είναι ReLU, που δίνεται από $\sigma(x) = x_+ = \max(0, x)$. Η αρχιτεκτονική των βαθιών δικτύων αντανάκλα το γράφημα συναρτήσεων, με κάθε κόμβο h_i να είναι μια συνάρτηση κορυφογραμμής, που περιλαμβάνει έναν ή περισσότερους νευρώνες.

Μας δίνεται ένα μεγάλο σύνολο δεδομένων εκπαίδευσης με παραδείγματα σήματος :

$N, \{x_i\}_{i=1}^N \in R^n$, το καθένα από τα οποία ανήκει σε μία από τις κατηγορίες C και ο στόχος μας είναι να τα χρησιμοποιήσουμε για το σχεδιασμό μιας μηχανής που λειτουργεί με νέα σήματα από την ίδια προέλευση, με στόχο να τα ταξινομήσουμε όσο το δυνατόν ακριβέστερα. Τα βαθιά νευρωνικά δίκτυα προσφέρουν μία τέτοια στρατηγική σχεδιασμού (μεταξύ πολλών εναλλακτικών), η οποία έχει αποδειχθεί ότι αποδίδει εξαιρετικά καλά. Το ίδιο το δίκτυο μπορεί να περιγραφεί ως μία συνάρτηση $z = h(x, \Theta)$ που λειτουργεί πάνω στο σήμα εισόδου x , ενώ παραμετροποιείται από το Θ , δημιουργώντας ένα διάνυσμα χαρακτηριστικών $z \in R^p$ ($p \geq C$). Αυτό το διάνυσμα χαρακτηριστικών τροφοδοτείται στη συνέχεια σε έναν γραμμικό ταξινομητή της μορφής $\text{SoftMax}\{Wz+b\} \in RC$ για να λάβει την πραγματική ανάθεση ταξινόμησης.

Τα δίκτυα της παραπάνω μορφής - $h(\cdot)$ και το γραμμικό επίπεδο ταξινόμησης που ακολουθεί - τείνουν να έχουν πολλές (συχνά εκατομμύρια) ελεύθερες παραμέτρους για ρύθμιση και η αρχιτεκτονική τους αποτελείται συνήθως από πολλά επίπεδα (εξού ο όρος «βαθιά») γνωστών υπολογιστικών βημάτων που περιλαμβάνουν συνελίξεις, υποδείγματα λήψεις, έλξη (pulling), διορθωμένες γραμμικές μονάδες, κανονικοποίηση παρτίδας, πολλαπλασιασμοί γενικής μήτρας και πολλά άλλα.

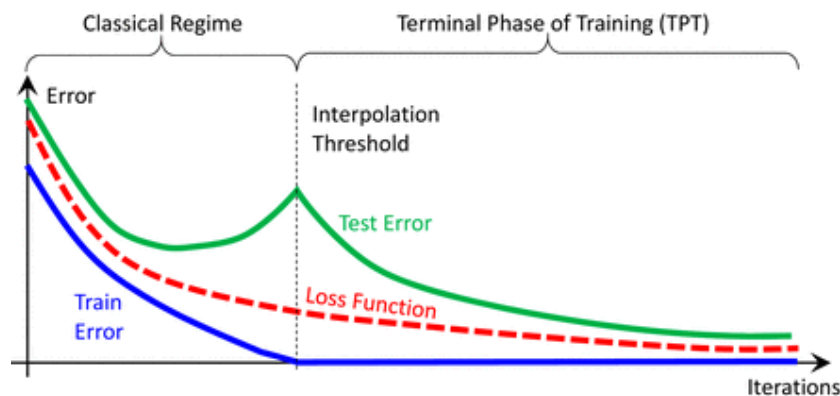
Η κοινή προσέγγιση για τον καθορισμό των παραμέτρων δικτύου $\{\Theta, W, b\}$ είναι μέσω επιβλεπόμενης μάθησης, αξιοποιώντας τις γνωστές ετικέτες των παραδειγμάτων εκπαίδευσης στο σχεδιασμό του ταξινομητή. Η ίδια η μάθηση αποτελείται από μια ελαχιστοποίηση μιας συνάρτησης απώλειας (ή αλλιώς συνάρτησης κόστους) που σχετίζεται με την ακρίβεια της ταξινόμησης στο σετ εκπαίδευσης. Ελαχιστοποιώντας αυτήν την απώλεια μέσω ενός αλγορίθμου στοχαστικής κλίσης (stochastic gradient descent), το δίκτυο βελτιώνει σταδιακά την απόδοσή του, τόσο στην εκπαίδευση όσο και στα σετ δοκιμών, υποδηλώνοντας την ικανότητα γενίκευσης για/σε πρωτόγνωρα, νέα δεδομένα. (Ως γενίκευση ορίζεται η μελέτη της απόδοσης σε νέα δεδομένα).

Ενώ όλα τα παραπάνω αντιπροσωπεύουν μια κοινή πρακτική που φαίνεται εμπειρικά σαφής, σχεδόν τίποτα σε αυτή την αλυσίδα λειτουργιών/αποφάσεων δεν είναι θεωρητικά βάσιμο. Η αρχιτεκτονική του δικτύου επιλέγεται με αυθαίρετο τρόπο δοκιμής και σφάλματος χωρίς σαφή αιτιολογία ή αιτιολόγηση. Η συνάρτηση απώλειας που οδηγεί/κατευθύνει τη μάθηση μπορεί να έχει πολλές μορφές, και όμως όλες είναι εξαιρετικά μη κυρτές και χωρίς εγγυήσεις για την απόκτηση του πραγματικά βέλτιστου δικτύου. Ακόμη και αν έχουμε βρει ένα καλό ελάχιστο, τίποτα δεν υποστηρίζει την προσδοκία μας για μια καλή συμπεριφορά γενίκευσης.

Επιπλέον, μια πιο προσεκτική επιθεώρηση ορισμένων νευρωνικών δικτύων ταξινόμησης με καλύτερη απόδοση αποκαλύπτει ένα ανησυχητικό φαινόμενο: Αυτά τα δίκτυα είναι υπερπαραμετροποιημένα, αποτελούμενα από περισσότερες παραμέτρους από αυτές που θα μπορούσαν ποτέ να φιλοξενήσουν τα δεδομένα εκπαίδευσης. Για να διευκρινιστεί καλύτερα αυτό, εξετάζουμε ένα πρόβλημα ελάχιστων τετραγώνων με περισσότερα άγνωστα (αυτά παραλληλίζουν τις παραμέτρους μας) παρά τις εξισώσεις (που αντιπροσωπεύουν τα δεδομένα εκπαίδευσης). Κλασικά, αναφερόμαστε σε αυτήν την κατάσταση ως κακή, οδηγώντας σε απείρως πολλές πιθανές λύσεις χωρίς σαφή τρόπο διάκρισης μεταξύ τους. Επιστρέφοντας στη μηχανική μάθηση, αυτό σημαίνει ότι υπάρχει η δυνατότητα απόκτησης ενός δικτύου το οποίο θα μπορεί να ταξινομεί τέλεια τα δεδομένα εκπαίδευσης, ενώ αποδίδει πολύ κακώς σε δεδομένα δοκιμών, ένα φαινόμενο γνωστό ως *overfitting*. Ωστόσο, τα βαθιά νευρωνικά δίκτυα που είναι υπερπαραμετροποιημένα, έχει αποδειχθεί, πως τείνουν να λειτουργούν πολύ καλά. Αυτό οφείλεται στο φαινόμενο "διπλής καθόδου" (double-descent).

Το Σχ. 7.7 παρουσιάζει αυτή τη συμπεριφορά σε μία από τις απλούστερες εκδηλώσεις της. Πρώτον, παρατηρήστε την τιμή της συνάρτησης απώλειας καθώς εξελίσσεται κατά τις επαναλήψεις της εκπαίδευσης και, όπως είναι αναμενόμενο, πέφτει (σχεδόν) μονότονα. Παράλληλα με τη διαδικασία εκπαίδευσης, επιθεωρούμε τόσο τα λάθη εκπαίδευσης όσο και τα λάθη της δοκιμής - πραγματικά λάθη που λαμβάνονται σε παραδείγματα σημάτων. Σημειώστε ότι το σφάλμα εκπαίδευσης και η τιμή απώλειας, ενώ είναι στενά συνδεδεμένα, είναι διαφορετικά. Το σφάλμα εκπαίδευσης γίνεται συνεχώς μικρότερο μέχρι να φτάσει (σχεδόν) στο μηδέν, υπονοώντας ότι το δίκτυο έχει απομνημονεύσει τα δεδομένα στα οποία

έχει εκπαιδευτεί, αποδίδοντας βέλτιστα σε αυτό. Από εδώ και πέρα, αυτό το σφάλμα παραμένει πολύ μικρό ή ακόμη και μηδενικό, ενώ οι παράμετροι του δικτύου εξακολουθούν να περιπλανιούνται, ενημερωμένοι από τη διαδικασία εκπαίδευσης. Η συμπεριφορά διπλής καθόδου αναφέρεται στο σφάλμα δοκιμής-σε πρώτη φάση και μέχρι να φτάσει το όριο παρεμβολής, η συμπεριφορά είναι οικεία και κατανοητή, παρουσιάζοντας για λίγο μια τάση βελτίωσης και στη συνέχεια επιδείνωση λόγω υπερβολικής προσαρμογής. Εάν η εκπαίδευση προχωρήσει μετά το σημείο παρεμβολής, το σφάλμα δοκιμής συνεχίζει την κάθοδό του και αυτή τη φορά σε (πολύ) χαμηλότερη τιμή σφάλματος. Αυτό καταδεικνύει μια τυπική συμπεριφορά εξαιρετικά υπερπαραμετροποιημένων δικτύων. Οι πρόσφατες προσπάθειες να εξηγηθεί το φαινόμενο αυτό θεωρητικά είναι εντυπωσιακές, αλλά ακόμα ημιτελείς.



Σχήμα 7.8 Βαθιά Νευρωνικά Δίκτυα και overfittinh

Οι Paryan et al υποθέτουν ότι τα υπερπαραμετροποιημένα δίκτυα συγκλίνουν σε μια ιδανική συμπεριφορά ταξινόμησης μετά από επαρκείς επαναλήψεις εκπαίδευσης. Οι αξιώσεις τους είναι οι ακόλουθες:

- 1) Τα διανύσματα χαρακτηρισικών $z = h(x, \Theta)$ όλων των παραδειγμάτων που ανήκουν σε κάθε κλάση συμπυκνώνονται σε απομονωμένα σημεία.
- 2) Αυτά τα σημεία συγκέντρωσης βρίσκονται σε μέγιστη απόσταση και βρίσκονται σε μια σφαίρα με επίκεντρο την αρχή (των αξόνων)
- 3) Ο γραμμικός πίνακας ταξινόμησης W ταιριάζει απόλυτα με αυτά τα σημεία συγκέντρωσης, και
- 4) Η γραμμική ταξινόμηση τείνει σε μια απλή διαδικασία πλησιέστερου γείτονα.

Αν είναι πράγματι αληθινές, αυτές οι ιδιότητες δεν είναι καθόλου συναρπαστικές, καθώς το αποτέλεσμα είναι ένας φαινομενικά τέλειος ταξινομητής, τόσο ως προς την ικανότητά του για γενίκευση, όσο και ως προς την αντοχή του σε επιθέσεις και θόρυβο. Αυτό ρίχνει επίσης φως στη γενική μηχανική πεποίθηση ότι τα βαθιά νευρωνικά δίκτυα αγγίζουν το ανώτατο όριο όσον αφορά την απόδοσή τους.

Είναι σημαντικό να σημειωθεί ότι οι ισχυρισμοί που διατυπώθηκαν στο έργο των Paryan et al. είναι εμπειρικά προσανατολισμένες εικασίες, που προέκυψαν μετά από μια μαζική σειρά προσομοιώσεων σε διάφορες γνωστές εργασίες ταξινόμησης και χρησιμοποιώντας πολλές δημοφιλείς αρχιτεκτονικές δικτύου. Ως δευτερεύουσα φιλοσοφική σημείωση, θα πρέπει να αναρωτηθεί κανείς εάν αυτός είναι ένας εκπρόσωπος της τρέχουσας εποχής μας, εκθέτοντας έναν νέο τρόπο εκτέλεσης της έρευνας στηριζόμενος σε σημαντικό πειραματικό περιβάλλον. Με βάση τα παραπάνω, το έργο των Paryan et al προηγείται θεωρητικά συνδέοντας αυτήν την υποθετική συμπεριφορά με γνωστά αποτελέσματα σχετικά με τη βέλτιστη ταξινόμηση και τη μέγιστη απόδοση περιθωρίου.

7.7 Ποια είναι η διαφορά μεταξύ MLP και DNN

Πολυστρωματικό Perceptron (MLP) :

- Ένα πολυστρωματικό perceptron (MLP) είναι ένα προωθητικό τεχνητό νευρωνικό δίκτυο που παράγει ένα σύνολο εξόδων από ένα σύνολο εισόδων. Ένα MLP χαρακτηρίζεται από πολλά επίπεδα κόμβων εισόδου που συνδέονται ως κατευθυνόμενο γράφημα μεταξύ των επιπέδων εισόδου και εξόδου. Το MLP χρησιμοποιεί backpropagation για την εκπαίδευση του δικτύου. Το MLP είναι μια μέθοδος βαθιάς μάθησης.
- Ένα πολυστρωματικό perceptron είναι ένα νευρωνικό δίκτυο που συνδέει πολλαπλά στρώματα σε μια κατευθυνόμενη γραφική παράσταση, πράγμα που σημαίνει ότι η διαδρομή σήματος μέσω των κόμβων πηγαίνει μόνο προς μία κατεύθυνση. Κάθε κόμβος, εκτός από τους κόμβους εισόδου, έχει μια μη γραμμική λειτουργία ενεργοποίησης. Ένα MLP χρησιμοποιεί backpropagation ως εποπτευόμενη τεχνική μάθησης. Δεδομένου ότι υπάρχουν πολλά στρώματα νευρώνων, το MLP είναι μια τεχνική βαθιάς εκμάθησης.
- Το MLP χρησιμοποιείται ευρέως για την επίλυση προβλημάτων που απαιτούν επίβλεψη μάθησης καθώς και έρευνα για υπολογιστική νευροεπιστήμη και παράλληλη κατανομημένη επεξεργασία. Οι εφαρμογές περιλαμβάνουν αναγνώριση ομιλίας, αναγνώριση εικόνας και αυτόματη μετάφραση.

Βαθύ νευρωνικό δίκτυο (DNN) :

- Ένα βαθύ νευρωνικό δίκτυο είναι ένα νευρωνικό δίκτυο με ένα ορισμένο επίπεδο πολυπλοκότητας, ένα νευρωνικό δίκτυο με περισσότερα από δύο επίπεδα. Τα βαθιά νευρωνικά δίκτυα χρησιμοποιούν εξελιγμένο μαθηματικό μοντέλο για την επεξεργασία δεδομένων με πολύπλοκους τρόπους.
- Ένα νευρωνικό δίκτυο, γενικά, είναι μια τεχνολογία που δημιουργήθηκε για να προσομοιώσει τη δραστηριότητα του ανθρώπινου εγκεφάλου - συγκεκριμένα, την αναγνώριση προτύπων και τη διέλευση της εισόδου μέσω διαφόρων στρωμάτων προσομοιωμένων νευρωνικών συνδέσεων.
- Πολλοί ειδικοί ορίζουν τα βαθιά νευρωνικά δίκτυα ως δίκτυα που έχουν ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και τουλάχιστον ένα κρυφό στρώμα ενδιάμεσα. Κάθε επίπεδο εκτελεί συγκεκριμένους τύπους διαλογής και ταξινόμησης σε μια διαδικασία που ορισμένοι αναφέρουν ως "ιεραρχία χαρακτηριστικών". Μία από τις βασικές χρήσεις αυτών των εξελιγμένων νευρωνικών δικτύων είναι η αντιμετώπιση δεδομένων χωρίς ετικέτα ή χωρίς δομή. Η φράση "βαθιά μάθηση" χρησιμοποιείται επίσης για να περιγράψει αυτά τα βαθιά νευρωνικά δίκτυα, καθώς η βαθιά μάθηση αντιπροσωπεύει μια συγκεκριμένη μορφή μηχανικής μάθησης όπου οι τεχνολογίες που χρησιμοποιούν πτυχές της τεχνητής νοημοσύνης προσπαθούν να ταξινομήσουν πληροφορίες με τρόπους που υπερβαίνουν τα απλά πρωτόκολλα εισόδου/εξόδου.

Με βάση τα παραπάνω, θα έλεγε κανείς ότι το MLP είναι ένα υποσύνολο του DNN. Ενώ το DNN μπορεί να έχει βρόχους, το MLP είναι πάντα πρόσθιας τροφοδότησης. Το Perceptron Multilayer είναι ένα πεπερασμένο ακυκλικό γράφημα. Τα Deep Neural Networks (DNN) είναι μια επέκταση του MLP και συνήθως θεωρείται DNN εάν το MLP έχει πολλά κρυμμένα επίπεδα.

Εκτός από πολλαπλά επίπεδα, υπάρχουν διαφορετικοί τύποι συναρτήσεων ενεργοποίησης και βελτιστοποιητές κλίσης κλίσης που βοηθούν στην επίτευξη λύσης σε ένα ζήτημα το οποίο αντιμετωπίζουν τα MLP, το οποίο είναι το πρόβλημα της διαβάθμισης που εξαφανίζεται. Το πρόβλημα της διαβάθμισης εξαφανίζεται όταν ένα δίκτυο προσπαθεί να μάθει ένα μοντέλο, αλλά οι κλίσεις ενός σφάλματος είναι τόσο μικρές που οι προσαρμογές στα βάρη μέσω της αντίστροφης διάδοσης (backpropagation) δεν κάνουν σχεδόν καμία διαφορά στη μαθησιακή διαδικασία και φτάνουν στο σημείο να μην φτάσουν ποτέ σε ένα παγκόσμιο ελάχιστο. Όπως αναφέρθηκε προηγουμένως, υπάρχουν διαφορετικές συναρτήσεις ενεργοποίησης που χρησιμοποιούνται συνήθως για MLP και DNN, όπως σιγμοειδείς ή υπερβολικές εφαπτομένες συναρτήσεις. Ωστόσο, ειδικά για το Deep Learning,

έχει αποδειχθεί ότι διαφορετικές συναρτήσεις ενεργοποίησης επιτυγχάνουν καλύτερα αποτελέσματα σε ορισμένες περιπτώσεις. Μία από αυτές τις συναρτήσεις ενεργοποίησης ονομάζεται Rectified Linear Unit (ReLU). Για ορισμένες συναρτήσεις ενεργοποίησης, η αξιολόγηση ενός κόμβου μπορεί να βρίσκεται μεταξύ αρνητικού και θετικού. Ωστόσο, για τη συνάρτηση ReLU, μια αξιολόγηση που είναι κάτω από το μηδέν διακόπτεται και η τιμή μπορεί να είναι μόνο μεταξύ μηδέν και ενός, ή πιο επίσημα $f(x) = \max(0, x)$ όπου x είναι το αποτέλεσμα της εξίσωσης που έρχεται από τον κόμβο του δικτύου. Οι βελτιστοποιητές κλίσης κλίσης είναι αλγόριθμοι βελτιστοποίησης που χρησιμοποιούνται για την εύρεση ενός τοπικού ελαχίστου. Υπερμετρικές παράμετροι, όπως τα ποσοστά εκμάθησης και η ορμή, εξυπηρετούν αυτούς τους αλγόριθμους κλίσης κλίσης, αλλάζοντας το πόσο θα μετακινηθούν σε έναν χώρο συναρτήσεων για να συγκλίνουν σε ένα παγκόσμιο ελάχιστο. Εάν μια τιμή είναι είτε πολύ χαμηλή είτε πολύ υψηλή, τότε ο βελτιστοποιητής μπορεί να χάσει εντελώς το παγκόσμιο ελάχιστο και να επικεντρωθεί σε ένα τοπικό ελάχιστο, ή ίσως να μην συγκλίνει ποτέ καθόλου.

7.8 Γιατί είναι δύσκολη η εκπαίδευση στα DNN;

Τέτοια δίκτυα θα μπορούσαν να χρησιμοποιήσουν τα ενδιάμεσα στρώματα για να δημιουργήσουν πολλαπλά στρώματα αφαίρεσης, όπως κάνουμε στα Boolean κυκλώματα. Για παράδειγμα, εάν κάνουμε οπτική αναγνώριση μοτίβου, τότε οι νευρώνες στο πρώτο στρώμα μπορεί να μάθουν να αναγνωρίζουν ακμές, οι νευρώνες στο δεύτερο στρώμα θα μπορούσαν να μάθουν να αναγνωρίζουν πιο πολύπλοκα σχήματα, ας πούμε τρίγωνα ή ορθογώνια, χτισμένα από άκρες. Το τρίτο στρώμα θα αναγνώριζε επομένως, ακόμα πιο πολύπλοκα σχήματα. Και ούτω καθεξής. Αυτά τα πολλαπλά στρώματα αφαίρεσης φαίνεται να δίνουν στα βαθιά δίκτυα ένα ισχυρό πλεονέκτημα στην εκμάθηση της επίλυσης σύνθετων προβλημάτων αναγνώρισης προτύπων. Επιπλέον, όπως και στην περίπτωση των κυκλωμάτων, υπάρχουν θεωρητικά αποτελέσματα που υποδηλώνουν ότι τα βαθιά δίκτυα είναι εγγενώς πιο ισχυρά από τα ρηχά δίκτυα.

Πώς μπορούμε να εκπαιδεύσουμε τόσο βαθιά δίκτυα όμως; Θα δούμε παρακάτω, οτι τελικά, τα βαθιά δίκτυα δεν αποδίδουν πάντα καλύτερα από τα ρηχά δίκτυα. Τα διαφορετικά επίπεδα στα βαθιά δίκτυα μαθαίνουν με πολύ διαφορετικές ταχύτητες. Συγκεκριμένα, όταν τα επόμενα στρώματα μαθαίνουν καλά, τα πρώτα επίπεδα συχνά κολλάνε κατά τη διάρκεια της εκπαίδευσης, μαθαίνοντας σχεδόν τίποτα απολύτως. Αυτό το κόλλημα δεν οφείλεται απλά στην κακή τύχη. Αντιθέτως, υπάρχουν θεμελιώδεις λόγοι για τους οποίους συμβαίνει η επιβράδυνση της μάθησης, που συνδέονται με τη χρήση τεχνικών μάθησης με κλίση. Από την άλλη, το αντίθετο φαινόμενο μπορεί επίσης να συμβεί: τα πρώτα στρώματα-επίπεδα μπορεί να μαθαίνουν καλά και αποτελεσματικά, αλλά αργότερα τα στρώματα μπορεί να κολλήσουν. Στην πραγματικότητα υπάρχει μια εγγενής αστάθεια που σχετίζεται με τη μάθηση με gradient descent σε βαθιά, πολυστρωματικά νευρωνικά δίκτυα. Αυτή η αστάθεια τείνει να έχει ως αποτέλεσμα είτε τα πρώτα είτε τα τελευταία στρώματα να κολλήσουν κατά τη διάρκεια της εκπαίδευσης.

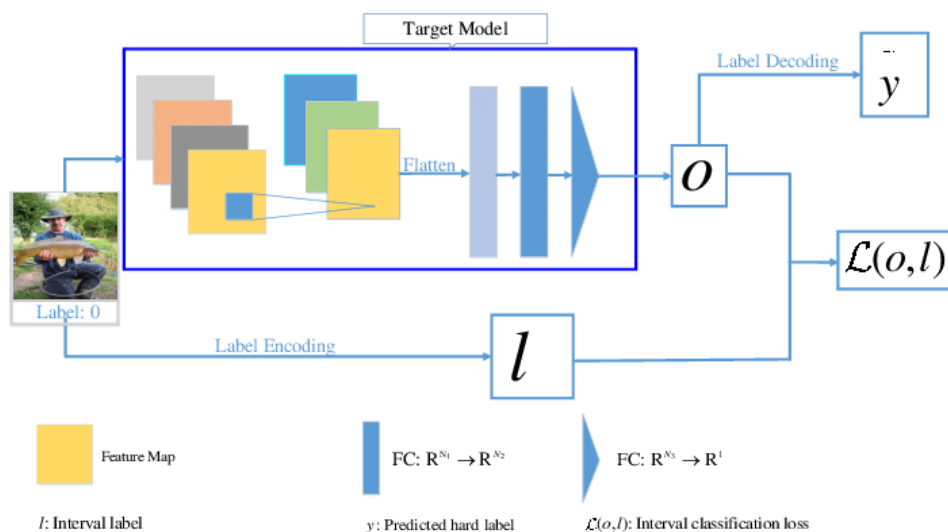
Η κλίση στα βαθιά νευρωνικά δίκτυα είναι ασταθής, τείνοντας είτε να εκραγεί είτε να εξαφανιστεί σε προηγούμενα στρώματα. Αυτή η αστάθεια είναι ένα θεμελιώδες πρόβλημα για τη βαθμιαία μάθηση σε βαθιά νευρωνικά δίκτυα. Είναι κάτι που πρέπει να καταλάβουμε και, αν είναι δυνατόν, να λάβουμε μέτρα για να το αντιμετωπίσουμε.

Επίσης σημαντικό ρόλο παίζουν η επιλογή της συνάρτησης ενεργοποίησης, ο τρόπος με τον οποίο αρχικοποιούνται τα βάρη, ακόμη και οι λεπτομέρειες για το πώς εφαρμόζεται η εκμάθηση με κλίση κλίσης. Και, φυσικά, η επιλογή της αρχιτεκτονικής του δικτύου και άλλων υπερπαραμέτρων είναι επίσης σημαντική. Έτσι, πολλοί παράγοντες μπορούν να διαδραματίσουν ρόλο στο να καταστούν δύσκολο να εκπαιδευτούν τα βαθιά δίκτυα και παράλληλα η κατανόηση όλων αυτών των παραγόντων εξακολουθεί να αποτελεί αντικείμενο συνεχούς έρευνας.

7.9 Ταξινόμηση Ετικέτας Διαστήματος (The interval label classification task)

Πολλές μέθοδοι έχουν προταθεί για τη βελτίωση της στιβαρότητας του συστήματος βαθιάς ταξινόμησης, όπως η εχθρική εκπαίδευση (adversarial training) και η ανίχνευση αντιπαραστατικών παραδειγμάτων (adversarial example detection). Ωστόσο, λίγες μελέτες επικεντρώνονται στο καθαυτό έργο ταξινόμησης. Σε αυτήν την παράγραφο, ερευνούμε τη στιβαρότητα του συστήματος βαθιάς εκμάθησης καθορίζοντας την εργασία ταξινόμησης με ενδιάμεση ετικέτα (interval label). Η εργασία ταξινόμησης interval label αντικαθιστά τη “σκληρή” ετικέτα με ένα διάστημα. [65]

Ορισμός



Σχήμα 7.9 Ταξινόμηση ετικέτας διαστήματος

Η παραδοσιακή εργασία ταξινόμησης εικόνας μπορεί να οριστεί ως εξής: $\forall x \in R^{C \times W \times H}, T : x \rightarrow R^k$, όπου x είναι ένα παράδειγμα εικόνας και C, W και H είναι ο αριθμός των καναλιών, το πλάτος και το ύψος του x , αντίστοιχα. Το T είναι η εργασία ταξινόμησης. Το k είναι ο αριθμός των κατηγοριών. Εδώ, θα ερευνήσουμε το θέμα ευπάθειας της εργασίας ταξινόμησης καθορίζοντας την εργασία ταξινόμησης interval-label. Η εργασία ταξινόμησης ετικετών διαστήματος μπορεί να οριστεί ως: $\forall x \in R^{C \times W \times H}, T : x \rightarrow R^1$. Η έξοδος του ταξινομητή interval-label, δηλαδή το βαθύ μοντέλο για την υλοποίηση της εργασίας ταξινόμησης interval-label, είναι πραγματικός αριθμός και η ετικέτα του x είναι το προκαθορισμένο διάστημα στο οποίο εμπίπτει η έξοδος. Οι ετικέτες της ταξινόμησης interval-label είναι ορισμένα μη επικαλυπτόμενα διαστήματα.

Ένα παράδειγμα της εργασίας ταξινόμησης interval-label

Το workflow του συστήματος ταξινόμησης με ενδιάμεση ετικέτα φαίνεται στο Σχ 7.9. Το σύστημα ταξινόμησης ενδιάμεσης ετικέτας, αποτελείται από τρεις ενότητες, συγκεκριμένα την κωδικοποίηση ετικετών, τη μονάδα αποκωδικοποίησης ετικετών και το μοντέλο-στόχο. Το μοντέλο στόχος είναι ένα βαθύ νευρωνικό δίκτυο με έξοδο 1 διάστασης.

Η μονάδα κωδικοποίησης ετικετών μετατρέπει τη σκληρή ετικέτα σε μια ετικέτα διαστήματος. Η συνάρτηση χάρτη μπορεί να διατυπωθεί ως εξής:

$$M_L(y) = s_0 + y \cdot (\alpha + \beta)$$

$$M_U(y) = M_L(y) + \beta$$

όπου s_0 είναι το μικρότερο κάτω όριο των ετικετών διαστήματος. Το α είναι το μήκος του κενού μεταξύ δύο παρακείμενων ετικετών μεσοδιαστήματος, ενώ β είναι το μήκος της ετικέτας διαστήματος. Το $M_L(\cdot)$ και το $M_U(\cdot)$ είναι συνάρτηση χάρτη κατώτερου και ανώτερου ορίου, αντίστοιχα. Σύμφωνα με την εξίσωση, για τη σκληρή ετικέτα «3», $s_0 = 0$, $\alpha = 1$, $\beta = 3$, η αντίστοιχη ετικέτα διαστήματος είναι [12, 15].

Η λειτουργία αποκωδικοποίησης της ετικέτας μπορεί να διατυπωθεί ως εξής :

$$\tilde{y} = \lfloor \frac{f(x) - s_0}{\alpha + \beta} \rfloor$$

όπου x είναι το παράδειγμα εισόδου, $f(\cdot)$ είναι ο ταξινομητής interval-label.

Η συνάρτηση απώλειας της εργασίας ταξινόμησης interval-label μπορεί να διατυπωθεί ως εξής:

$$\mathcal{L}(B(X, Y'); \theta) = \|r(M_L(Y) - f(X)) + r(f(X) - M_U(Y))\|_2$$

όπου θ είναι το σύνολο παραμέτρων του ταξινομητή f , το $B(X, Y')$ είναι μια μικρή παρτίδα, τα X και Y είναι τα παραδείγματα που έχουν οριστεί και το σύνολο σκληρών ετικετών και το $Y' = [M_L(Y), M_U(Y)]$ είναι το σύνολο των ετικετών διαστήματος. $M_L(Y)$ και $M_U(Y)$ είναι το σύνολο του κατώτερου ορίου και το σύνολο του άνω ορίου, αντίστοιχα. Η $r(\cdot)$ είναι η συνάρτηση ενεργοποίησης ReLU (Nair and Hinton 2010).


- Η ανάλυση του κατώτερου ορίου της αντίπαλης διαταραχής
Για την ταξινόμηση διαστήματος, δεν μπορούμε να λάβουμε άμεσα την πιθανότητα ότι το παράδειγμα ανήκει σε κάθε κατηγορία. Έτσι, όταν σχεδιάζουμε την επίθεση που βασίζεται στη βελτιστοποίηση έναντι του ταξινομητή ταξινόμησης ετικετών interval, θα πρέπει να υπολογίσουμε τις αποστάσεις μεταξύ της εξόδου και κάθε ετικέτας μεσοδιαστήματος.
- Σύγκλιση ταξινόμησης interval-label
Η ετικέτα διαστήματος είναι πιο περίπλοκη από την παραδοσιακή εργασία ταξινόμησης. Επιπλέον, η διαφορά μεταξύ της ακρίβειας εκπαίδευσης και της ακρίβειας δοκιμών για την παραδοσιακή εργασία ταξινόμησης είναι πιο σημαντική από την εργασία με την ετικέτα διαστήματος. Ο λόγος είναι ότι ακόμη και αν ένα παράδειγμα έχει ταξινομηθεί σωστά από το μοντέλο, η απώλεια, όπως η διασταυρούμενη εντροπία απώλεια και η αρνητική απώλεια πιθανότητας καταγραφής, εξακολουθεί να μην είναι 0 για την παραδοσιακή εργασία ταξινόμησης
- Ισχυρότητα της ταξινόμησης με ενδιάμεση ετικέτα
Όσον αφορά την εργασία ταξινόμησης interval-label, όσο υψηλότερη είναι η ακρίβεια των δοκιμών, τόσο πιο ισχυρή είναι. Ο λόγος είναι ότι όταν ένα παράδειγμα ταξινομηθεί σωστά, η απώλειά του θα είναι 0. Επομένως, είναι δύσκολο για τον αντίπαλο να εξερευνήσει μια αποτελεσματική κλίση για τη δημιουργία αντιπαραστατικών παραδειγμάτων. Καταλήγουμε λοιπόν στο συμπέρασμα ότι η ταξινόμηση με την ενδιάμεση ετικέτα μπορεί να μετριάσει τον ανταγωνισμό μεταξύ της στιβαρότητας και της ακρίβειας.
- Επίδραση των α και β στη σύγκλιση
Η εργασία ταξινόμησης με την ενδιάμεση ετικέτα γίνεται πιο σταθερή όταν αυξάνεται το β ή όταν μειώνεται το α .

- Επίδραση των α και β στην Ισχυρότητα
Για το σταθερό μήκος του διαστήματος, η αύξηση του μήκους του χάσματος μεταξύ των διαφορετικών ετικετών μεσοδιαστήματος θα αυξήσει την ευρωστία-ισχυρότητα του συστήματος ταξινόμησης των ενδιάμεσων ετικετών. Σε αντάλλαγμα, για το σταθερό μήκος του διακένου ετικέτας, η αύξηση του μήκους της ετικέτας διαστήματος θα μειώσει τη στιβαρότητα του συστήματος ταξινόμησης της ετικέτας διαστήματος. Για το σταθερό μήκος της διακένου ετικέτας, η αύξηση του μήκους της ετικέτας διαστήματος θα μειώσει τη στιβαρότητα-ισχυρότητα του συστήματος ταξινόμησης της ετικέτας διαστήματος.

7.10 Συμπεριφορά κόμβου Ο ρόλος των κρυφών κόμβων σε ένα εκπαιδευμένο DNN

Σύμφωνα με το σχεδιασμό τους, καθένας από τους κόμβους εξόδου αντιστοιχεί σε ιδιότητα μέλους κλάσης, ενώ ο καθένας από τους κόμβους εισόδου ανταποκρίνεται σε ένα συγκεκριμένο χαρακτηριστικό (και ως εκ τούτου είναι αρκετά αγνωστικιστικό σχετικά με την ιδιότητα μέλους της κλάσης). Επίσης, σε ένα feed-forward δίκτυο χωρίς παραλείψεις συνδέσεων, κάθε στρώμα ενεργοποιήσεων κόμβων είναι μια ολοκληρωμένη περίληψη ή «κατάσταση»: μαζί, ένα στρώμα ενεργοποιήσεων καθορίζει πλήρως τις ενεργοποιήσεις σε κάθε ένα από τα επόμενα στρώματα-επίπεδα.

Σε ένα δίκτυο ReLU, όπου ένας κόμβος είναι είτε ενεργοποιημένος είτε όχι, μπορεί κανείς να προσεγγίσει αυτήν την ερώτηση ρωτώντας κατά πόσο ανταποκρίνεται ο κάθε κόμβος σε εισόδους που ανήκουν στις διαφορετικές κλάσεις. Το σχήμα 6.10 δείχνει ένα παράδειγμα των προτύπων ενεργοποίησης που έχουμε παρατηρήσει σε πολλά δίκτυα ενεργοποιημένων με ReLU διαφόρων αρχιτεκτονικών, εκπαιδευμένα με διαφορετικούς αλγόριθμους σε διαφορετικές εργασίες ταξινόμησης.



Σχήμα 7.10 Δίκτυο RELU

Παρατηρούμε ότι οι κόμβοι στα πρώτα στρώματα δεν είναι ούτε ιδιαίτερα συγκεκριμένοι ούτε ευαίσθητοι σε κάποια συγκεκριμένη κατηγορία: οι περισσότεροι κόμβοι στα δύο πρώτα κρυμμένα επίπεδα ενεργοποιούνται από μερικά δείγματα από διάφορες κλάσεις. Πιο βαθιά στο δίκτυο, ωστόσο, οι κόμβοι γίνονται ιδιαίτερα επιλεκτικοί: κάθε κόμβος ενεργοποιείται είτε από κανένα από τα δείγματα μιας κλάσης είτε από όλα σχεδόν τα δείγματα της κλάσης. Αυτό το μοτίβο εμφανίζεται σε ένα ευρύ φάσμα συνθηκών, εφόσον το δίκτυο έχει αρκετά επίπεδα και κόμβους, και προκύπτει παρά την τυχαία εκκίνηση των βαρών. Συνεπώς, φαίνεται να υποδεικνύει μια θεμελιώδη πτυχή του τρόπου με τον οποίο ένα DNN ρυθμίζει τον εαυτό του για την εκτέλεση της ταξινόμησης και απαιτεί εξηγήσεις όσον αφορά τη διαδικασία εκπαίδευσης του DNN.

Προηγούμενες μελέτες για την ανάλυση της πολυπλοκότητας των DNNs έχουν παρατηρήσει ότι κρυμμένες μονάδες (κόμβοι) σε βαθύτερα στρώματα παράγουν πολλές πρόσθετες ευδιάκριτες γραμμικές περιοχές στο χώρο χαρακτηριστικών. και ότι με το βάθος, η

συμπεριφορά του στρώματος γίνεται πιο αφηρημένη και πιο συγκεκριμένη ως προς την κλάση.

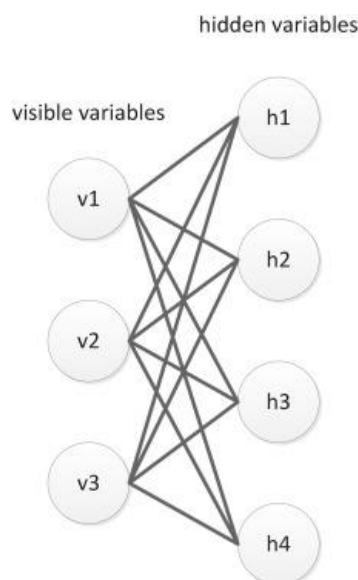
Ωστόσο, η παρατηρούμενη μετάβαση με βάθος είναι εντυπωσιακά απότομη και δεν απλώνεται στο διαθέσιμο βάθος όπως θα περίμενε κανείς.

7.11 Αρχιτεκτονικές Βαθιάς Μάθησης

A. Περιορισμένη μηχανή Boltzmann

Σε αυτό το μέρος, δίνεται μια σύντομη ανασκόπηση των RBM. Τα RBMs χρησιμοποιούνται ευρέως σε δίκτυα βαθιάς εκμάθησης λόγω της ιστορικής τους σημασίας και της σχετικής απλότητάς τους. Το RBM προτάθηκε για πρώτη φορά ως έννοια από τον Smolensky και έγινε εμφανές από τότε που ο Hinton δημοσίευσε το έργο του το 2006. Τα RBM έχουν χρησιμοποιηθεί για τη δημιουργία στοχαστικών μοντέλων TND που μπορούν να μάθουν την κατανομή πιθανότητας σε σχέση με τις εισόδους τους. Τα RBM αποτελούν μια απλοποιημένη παραλλαγή των κλασικών μηχανών Boltzmann (BM) από τις οποίες εκλείπουν οι πλάγιες συνδέσεις μεταξύ νευρώνων του ίδιου τύπου. Με άλλα λόγια, δεν συνδέονται ορατοί νευρώνες με ορατούς νευρώνες ούτε κρυφοί νευρώνες με κρυφούς νευρώνες. Οι BM μπορούν να ερμηνευτούν ως TND με στοχαστικές μονάδες επεξεργασίας συνδεδεμένες αμφίδρομα. Δεδομένου ότι είναι δύσκολο να μάθουμε πτυχές μιας άγνωστης κατανομής πιθανότητας, τα RBMs έχουν προταθεί για να απλοποιήσουν την τοπολογία του δικτύου και να ενισχύσουν την αποδοτικότητα του μοντέλου. Είναι αναγνωρισμένο ότι ένα RBM είναι ένας ειδικός τύπος τυχαίων πεδίων Markov με στοχαστικές ορατές μονάδες στο ένα στρώμα και στοχαστικές παρατηρήσιμες μονάδες στο άλλο στρώμα.

Όπως φαίνεται στο Σχ. 7.11 παρακάτω, σε ένα RBM οι νευρώνες περιορίζονται να σχηματίσουν ένα διμερές γράφημα. Μπορεί να φανεί ότι υπάρχει μια πλήρης σύνδεση μεταξύ των ορατών μονάδων και των κρυφών, ενώ δεν υπάρχει σύνδεση μεταξύ μονάδων από το ίδιο στρώμα. Για την εκπαίδευση ενός RBM, υιοθετείται ο δείκτης Gibbs. Ξεκινώντας με μια τυχαία κατάσταση σε ένα επίπεδο και εκτελώντας δειγματοληψία Gibbs, μπορούμε να δημιουργήσουμε δεδομένα από ένα RBM. Μόλις δοθούν οι καταστάσεις των μονάδων σε ένα επίπεδο, όλες οι μονάδες στα άλλα επίπεδα θα ενημερωθούν. Αυτή η διαδικασία ενημέρωσης θα συνεχιστεί μέχρι να επιτευχθεί η κατανομή ισορροπίας. Στη συνέχεια, τα βάρη εντός ενός RBM λαμβάνονται με τη μεγιστοποίηση της πιθανότητας αυτού του RBM.



Σχήμα 7.11 RBM Δίκτυο


Σήμερα, τα RBM παίζουν σημαντικό ρόλο σε διάφορες εφαρμογές, όπως η μοντελοποίηση θεμάτων, η μείωση των διαστάσεων, το συνεργατικό φιλτράρισμα, η ταξινόμηση και η εκμάθηση χαρακτηριστικών. Για παράδειγμα, ένα RBM μπορεί να χρησιμοποιηθεί για την κωδικοποίηση των δεδομένων και στη συνέχεια να εφαρμοστεί στη μάθηση χωρίς επίβλεψη για ή ταξινόμηση. Επιπλέον, τα RBM μπορούν να χρησιμοποιηθούν ως γενετικά μοντέλα.

Γενικά, τα RBM χρησιμοποιούνται ως εργαλεία εξαγωγής χαρακτηριστικών στη διαδικασία προ-εκπαίδευσης για εργασίες ταξινόμησης. Ωστόσο, οι δυνατότητες που εξάγονται από τα RBMs στη μάθηση χωρίς επίβλεψη μπορεί να μην είναι χρήσιμες στη διαδικασία εποπτευόμενης μάθησης. Επιπλέον, η επιλογή των παραμέτρων, η οποία είναι κρίσιμη για την απόδοση των αλγορίθμων μάθησης, θα φέρει επίσης δυσκολίες. Για να αντιμετωπιστούν αυτά τα προβλήματα, οι μηχανές Boltzmann (DRBM), που εισήχθησαν με διακρίσεις, προτάθηκαν από τους Larochelle και Bengio το 2008. Επιπλέον, για διαδικτυακή μάθηση με μεγάλα σύνολα δεδομένων, το μοντέλο των υβριδικών DBRM (HDRBM) αποδίδει καλά λόγω των συνδυασμένων πλεονεκτημάτων τόσο της δημιουργικής όσο και της διακριτικής μάθησης. Ωστόσο, σε εργασίες ταξινόμησης πολλαπλών ετικετών, η απόδοση των RBM δεν είναι ικανοποιητική. Ο Mnih et al. πρότεινε τα υπό όρους περιορισμένα μηχανήματα Boltzmann (CRBM) για περαιτέρω βελτίωση της απόδοσης. Παράλληλα, σε χρονοσειρές υψηλής διάστασης, τα CRBM μπορούν να χρησιμοποιηθούν ως μη γραμμικά μοντέλα παραγωγής.

Όταν τα RBM εφαρμόζονται σε περιοχές όπως η αναγνώριση εικόνας και ομιλίας, η απόδοσή τους μπορεί να υποβαθμιστεί σημαντικά από τους θορύβους στα δεδομένα. Το 2012, οι Tang et al. εισήγαγαν ένα μοντέλο τελευταίας τεχνολογίας, το στιβαρό μηχανήματα Boltzmann (RoBM), το οποίο μπορεί να χρησιμοποιηθεί για την αντιμετώπιση θορύβων και αποφράξεων στην οπτική αναγνώριση. Με το RoBM, μπορεί να επιτευχθεί καλύτερη γενίκευση εξαλείφοντας την επίδραση των κατεστραμμένων ρixel. Εκπαιδευμένο με δεδομένα χωρίς ετικέτες με θορύβους χρησιμοποιώντας αλγόριθμους κλίσης χωρίς επίβλεψη, το μοντέλο RoBM μπορεί επίσης να μάθει τη χωρική δομή των αποφρακτών. Σε σύγκριση με τους παραδοσιακούς αλγόριθμους, τα RoBM έδειξαν βελτιωμένη απόδοση σε διάφορες εφαρμογές, όπως η βαφή εικόνας και η αναγνώριση προσώπου.

B. Deep belief network

Όπως αναφέρθηκε προηγουμένως, οι κρυφές και ορατές μεταβλητές δεν είναι αμοιβαία ανεξάρτητες. Για να διερευνήσει τις εξαρτήσεις μεταξύ αυτών των μεταβλητών, το 2006, ο Hinton κατασκεύασε τα DBNs στοιβάζοντας μια τράπεζα RBM. Συγκεκριμένα, τα DBN αποτελούνται από πολλαπλά στρώματα στοχαστικών και λανθανουσών μεταβλητών και μπορούν να θεωρηθούν ως μια ειδική μορφή του πιθανολογικού γεννήματος Μπειςιανού μοντέλου. Σε σύγκριση με τα ΤΝΔ, τα DBN είναι πιο αποτελεσματικά, ειδικά όταν εφαρμόζονται σε προβλήματα με δεδομένα χωρίς ετικέτα.



Σχήμα 7.12 Δίκτυο DBN

Από το Σχήμα 7.12 φαίνεται ότι σε ένα DBN, κάθε δύο γειτονικά στρώματα σχηματίζουν ένα RBM. Το ορατό επίπεδο κάθε RBM συνδέεται με το κρυφό στρώμα του προηγούμενου RBM και τα δύο πρώτα στρώματα είναι μη κατευθυντικά. Η κατευθυνόμενη σύνδεση μεταξύ του παραπάνω στρώματος και του κάτω στρώματος γίνεται με τρόπο από πάνω προς τα κάτω. Διαφορετικά επίπεδα RBM σε ένα DBN εκπαιδεύονται διαδοχικά: πρώτα εκπαιδεύονται τα χαμηλότερα RBM και μετά τα υψηλότερα. Αφού εξαχθούν χαρακτηριστικά από το επάνω RBM, θα διαδοθούν πίσω στα χαμηλότερα στρώματα. Σε σύγκριση με ένα μόνο RBM, το στοιβαγμένο μοντέλο θα αυξήσει το ανώτερο όριο της πιθανότητας καταγραφής, το οποίο συνεπάγεται ισχυρότερες μαθησιακές ικανότητες.

Η διαδικασία εκπαίδευσης ενός DBN μπορεί να χωριστεί σε δύο στάδια: το στάδιο της προ-εκπαίδευσης και το στάδιο της λεπτομερούς ρύθμισης. Στο στάδιο της προ-εκπαίδευσης, πραγματοποιείται μια εκπαίδευση χωρίς επίβλεψη βασισμένη στη μάθηση με κατεύθυνση προς τα κάτω για την εξαγωγή χαρακτηριστικών. ενώ στο στάδιο της λεπτομερούς ρύθμισης, πραγματοποιείται ένας εποπτευόμενος αλγόριθμος βασισμένος στην εκμάθηση για περαιτέρω προσαρμογή των παραμέτρων του δικτύου. Σημειώνουμε ότι η βελτιωμένη απόδοση των DBN μπορεί να αποδοθεί σε μεγάλο βαθμό στο στάδιο της προ-εκπαίδευσης στο οποίο τα αρχικά βάρη του δικτύου μαθαίνονται από τη δομή των δεδομένων εισόδου. Σε σύγκριση με τα τυχαία αρχικοποιημένα, αυτά τα βάρη είναι πιο κοντά στο παγκόσμιο βέλτιστο και επομένως μπορούν να επιφέρουν καλύτερη απόδοση.

Στο στάδιο της λεπτομερούς ρύθμισης, τα DBN εκπαιδεύονται με δεδομένα με ετικέτα από τον αλγόριθμο up-down, ο οποίος είναι μια αντίθεση του αλγορίθμου wake-sleep. Για να μάθει τα όρια κατηγοριών του δικτύου, ένα σύνολο ετικετών ορίζεται στο επάνω επίπεδο για τη διαδικασία εκμάθησης βαρών αναγνώρισης. Επίσης, ο αλγόριθμος backpropagation χρησιμοποιείται για να τελειοποιήσει τα βάρη με επισημασμένα δεδομένα. Σε σύγκριση με τον αρχικό αλγόριθμο wake up, ο αλγόριθμος up down δεν πάσχει από τα προβλήματα μέσου όρου λειτουργίας που μπορεί να φέρουν χαμηλά βάρη αναγνώρισης.

Σε σύγκριση με τους τυπικούς αλγόριθμους ταξινόμησης όπως το SVM και το KNN, τα DBN μπορούν επίσης να χρησιμοποιηθούν στην ταξινόμηση εικόνας λόγω της εξαιρετικής απόδοσης τους στην εκμάθηση χαρακτηριστικών. Με βάση τον άπληστο στρώμα-στρώμα χωρίς επίβλεψη αλγόριθμο εκπαίδευσης, οι Abdel et al. πρότειναν ένα σύστημα αυτόματης διάγνωσης που περιλαμβάνει DBN για προ-εκπαίδευση και TND backpropagation για “λεπτό” συντονισμό. Σε σύγκριση με το πρότυπο NN με μία μόνο εποπτευόμενη φάση, το σύστημα διάγνωσης μπορεί να επιτύχει υψηλότερη ακρίβεια ταξινόμησης.

Γ. Συνελικτικά Δίκτυα

Τα τελευταία χρόνια, η βαθιά μάθηση οδήγησε σε πολύ καλές επιδόσεις σε διάφορα προβλήματα, όπως η οπτική αναγνώριση, η αναγνώριση ομιλίας και η επεξεργασία φυσικής γλώσσας. Μεταξύ των διαφόρων τύπων βαθιών νευρωνικών δικτύων, τα συνελικτικά νευρωνικά δίκτυα έχουν μελετηθεί εκτενέστερα. Αξιοποιώντας την ταχεία αύξηση του όγκου των δεδομένων με ετικέτα και τις μεγάλες βελτιώσεις στις δυνάμεις των μονάδων επεξεργαστών γραφικών, η έρευνα για συνελικτικά νευρωνικά πέτυχε κορυφαία αποτελέσματα σε διάφορες εργασίες.

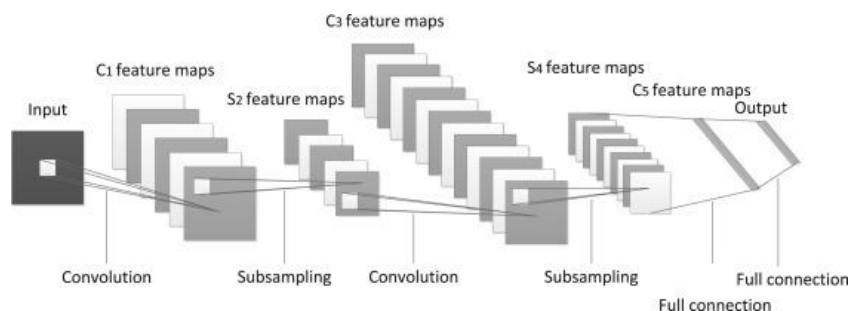
Τα συνελικτικά δίκτυα ανήκουν σε μία κατηγορία δικτύων, η οποία είναι αναμφισβήτητη η πιο γνωστή οικογένεια νευρωνικών δικτύων και είναι πολύ χρήσιμα στην εργασία με κάθε είδους δεδομένων εικόνας. Πιο συγκεκριμένα, χρησιμοποιούν μια ειδική αρχιτεκτονική η οποία είναι ιδιαίτερα καλά προσαρμοσμένη για την ταξινόμηση των εικόνων. Η χρήση αυτής της αρχιτεκτονικής καθιστά τα συνελικτικά δίκτυα γρήγορα στην εκπαίδευση. Αυτό, με τη σειρά του, μας βοηθά να εκπαιδεύσουμε βαθιά, πολυστρωματικά δίκτυα, τα οποία είναι πολύ καλά στην ταξινόμηση εικόνων. Χαρακτηρίζονται από το ότι έχουν στρεπτά στρώματα, τα οποία επιτρέπουν στο νευρωνικό δίκτυο να επαναχρησιμοποιεί παραμέτρους σε διαφορετικές χωρικές θέσεις μιας εικόνας. Αυτή είναι μια εξαιρετικά χρήσιμη επαγωγική προκατάληψη για δεδομένα εικόνας και βοηθά στην αποτελεσματική εκμάθηση καλών χαρακτηριστικών, όπως τα φίλτρα Gabor, που αντιστοιχούν σε παραδοσιακές τεχνικές όρασης υπολογιστή.

Σήμερα, βαθιά συνελκτικά δίκτυα ή κάποια παραλλαγή τους χρησιμοποιούνται στα περισσότερα νευρωνικά δίκτυα για την αναγνώριση εικόνας.


Η έννοια των CNN είναι εμπνευσμένη από νευρωνικά δίκτυα καθυστέρησης χρόνου (TDNN). Σε ένα TDNN, τα βάρη μοιράζονται σε μια χρονική διάσταση, η οποία οδηγεί σε μείωση του υπολογισμού. Στα CNN, η συνέλιξη αντικατέστησε τον γενικό πολλαπλασιασμό μήτρας στα τυπικά ΤΝΔ. Με αυτόν τον τρόπο, ο αριθμός των βαρών μειώνεται, μειώνοντας έτσι την πολυπλοκότητα του δικτύου. Επιπλέον, οι εικόνες, ως ακατέργαστες εισόδοι, μπορούν να εισαχθούν απευθείας στο δίκτυο, αποφεύγοντας έτσι τη διαδικασία εξαγωγής χαρακτηριστικών στους τυπικούς αλγόριθμους εκμάθησης. Πρέπει να σημειωθεί ότι τα CNN είναι η πρώτη πραγματικά επιτυχημένη αρχιτεκτονική βαθιάς μάθησης λόγω της επιτυχούς εκπαίδευσης των ιεραρχικών στρωμάτων. Η τοπολογία του CNN αξιοποιεί τις χωρικές σχέσεις έτσι ώστε να μειωθεί ο αριθμός των παραμέτρων στο δίκτυο και επομένως η απόδοση βελτιώνεται χρησιμοποιώντας τους τυπικούς αλγόριθμους backpropagation. Ένα άλλο πλεονέκτημα του μοντέλου CNN είναι ότι απαιτεί ελάχιστη προεπεξεργασία.

Με την ταχεία ανάπτυξη των τεχνικών υπολογισμού, οι τεχνικές υπολογιστών που επιταχύνονται με GPU έχουν αξιοποιηθεί για να εκπαιδεύσουν τα CNN πιο αποτελεσματικά. Σήμερα, τα CNN έχουν ήδη εφαρμοστεί με επιτυχία στην αναγνώριση χειρογράφου, στην ανίχνευση προσώπου, στην αναγνώριση συμπεριφοράς, στην αναγνώριση ομιλίας, στα συστήματα προτάσεων, στην ταξινόμηση εικόνων και στο NLP.

Τρεις παράγοντες παίζουν βασικό ρόλο στη διαδικασία εκμάθησης ενός CNN: αραιή αλληλεπίδραση, κοινή χρήση παραμέτρων και ισοδύναμη αναπαράσταση. Διαφορετικά από τα παραδοσιακά ΤΝΔ όπου η σχέση μεταξύ των μονάδων εισόδου και εξόδου προκύπτει από πολλαπλασιασμό μήτρας, τα CNN μειώνουν τον υπολογιστικό φόρτο με αραιή αλληλεπίδραση όπου οι πυρήνες γίνονται μικρότεροι από τις εισόδους και χρησιμοποιούνται για ολόκληρη την εικόνα. Η βασική ιδέα της κοινής χρήσης παραμέτρων είναι ότι, αντί να μαθαίνουμε ένα ξεχωριστό σύνολο παραμέτρων σε κάθε τοποθεσία, χρειάζεται μόνο να μάθουμε ένα σύνολο από αυτές, πράγμα που συνεπάγεται καλύτερη απόδοση του CNN. Η κοινή χρήση παραμέτρων έχει “προικίσει” επίσης το CNN με μια ελκυστική ιδιότητα που ονομάζεται ισοδυναμία, που σημαίνει ότι κάθε φορά που αλλάζει η είσοδος, η έξοδος αλλάζει κατά τον ίδιο τρόπο. Κατά συνέπεια, απαιτούνται λιγότερες παράμετροι για το CNN σε σύγκριση με άλλους παραδοσιακούς αλγόριθμους νευρωνικών δικτύων, γεγονός που οδηγεί σε μείωση της μνήμης και βελτίωση της απόδοσης. Τα συστατικά ενός τυπικού στρώματος CNN φαίνονται στο σχήμα 13.α και ένα εννοιολογικό σχηματικό διάγραμμα ενός τυπικού CNN φαίνεται στο σχήμα 7.13.β.



Σχήμα 7.13.α Τα συστατικά ενός τυπικού στρώματος CNN



Σχήμα 7.13.β Εννοιολογικό σχηματικό διάγραμμα ενός τυπικού CNN

Όπως φαίνεται στο Σχ.7.13.β, ένα CNN είναι ένα νευρωνικό δίκτυο πολλαπλών στρωμάτων που αποτελείται από δύο διαφορετικούς τύπους στρωμάτων, δηλαδή στρώματα συστροφής (στρώματα c) και στρώματα υπο δειγματοληψίας (στρώματα s) . Τα στρώματα C και τα στρώματα s συνδέονται εναλλάξ και αποτελούν το μεσαίο τμήμα του δικτύου. Όπως δείχνει το Σχήμα 7.13.α, η εικόνα εισόδου συγχέεται με εκπαιδευτικά φίλτρα σε όλες τις πιθανές μετατοπίσεις προκειμένου να παραχθούν χάρτες χαρακτηριστικών στο πρώτο στρώμα c. Ένα στρώμα βαρών σύνδεσης περιλαμβάνεται σε κάθε φίλτρο. Κανονικά, τέσσερα εικονοστοιχεία στο χάρτη χαρακτηριστικών αποτελούν μια ομάδα. Περνώντας μέσα από μια σιγμοειδή συνάρτηση, αυτά τα εικονοστοιχεία παράγουν πρόσθετους χάρτες χαρακτηριστικών στο πρώτο στρώμα s. Αυτή η διαδικασία συνεχίζεται και έτσι μπορούμε να αποκτήσουμε τους χάρτες χαρακτηριστικών στα ακόλουθα στρώματα c και s. Τέλος, οι τιμές αυτών των εικονοστοιχείων γίνονται ράστερ και εμφανίζονται σε ένα μόνο διάνυσμα ως είσοδος του δικτύου .

Γενικά, τα στρώματα c χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών όταν η είσοδος κάθε νευρώνα συνδέεται με το τοπικό δεκτικό πεδίο του προηγούμενου στρώματος. Μόλις εξαχθούν όλα τα τοπικά χαρακτηριστικά, μπορεί να κατανοηθεί η σχέση θέσης μεταξύ τους. Ένα στρώμα s είναι ουσιαστικά ένα επίπεδο για τη χαρτογράφηση χαρακτηριστικών. Αυτά τα επίπεδα χαρτογράφησης χαρακτηριστικών μοιράζονται τα βάρη και σχηματίζουν ένα επίπεδο. Επιπλέον, για να επιτευχθεί η αμετάβλητη κλίμακα, η σιγμοειδής συνάρτηση επιλέγεται ως συνάρτηση ενεργοποίησης λόγω της μικρής επίδρασής της στον πυρήνα της λειτουργίας. Θα πρέπει επίσης να σημειωθεί ότι, τα φίλτρα σε αυτό το μοντέλο χρησιμοποιούνται για τη σύνδεση μιας σειράς επικαλυπτόμενων δεκτικών πεδίων και τη μετατροπή της εισόδου παρτίδας εικόνας 2-D σε μία μονάδα στην έξοδο.

Ωστόσο, όταν η διάσταση των εισόδων είναι ίση με αυτή της εξόδου φίλτρου, θα είναι δύσκολο να διατηρηθεί η αμετάβλητη μετάφραση με επιπλέον φίλτρα. Λόγω της μεγάλης διαστατικότητας, η εφαρμογή ενός ταξινομητή μπορεί να προκαλέσει υπερπροσαρμογή. Για την επίλυση αυτού του προβλήματος, μια διαδικασία συγκέντρωσης, που ονομάζεται επίσης υπο-δειγματοληψία ή δειγματοληψία, εισάγεται για να μειώσει το συνολικό μέγεθος του σήματος. Στην πραγματικότητα, η υπο-δειγματοληψία έχει ήδη εφαρμοστεί με επιτυχία για τη μείωση του μεγέθους δεδομένων στη συμπίεση ήχου. Στο 2-D φίλτρο, η υπο-δειγματοληψία έχει επίσης χρησιμοποιηθεί για να αυξήσει το αμετάβλητο της θέσης.

Η διαδικασία εκπαίδευσης για ένα CNN είναι παρόμοια με αυτή για ένα τυπικό NN που χρησιμοποιεί backpropagation. Πιο συγκεκριμένα, ο Lecun et al. εισήγαγε κλίση σφάλματος για την εκπαίδευση των CNN. Στο πρώτο στάδιο, οι πληροφορίες διαδίδονται στην κατεύθυνση τροφοδοσίας μέσω διαφορετικών στρωμάτων. Τα κύρια χαρακτηριστικά επιτυγχάνονται με την εφαρμογή ψηφιακών φίλτρων σε κάθε στρώμα. Στη συνέχεια υπολογίζονται οι τιμές της εξόδου. Κατά το δεύτερο στάδιο, υπολογίζεται το σφάλμα μεταξύ των αναμενόμενων και των πραγματικών τιμών της εξόδου. Αντιπροσωπεύοντας και ελαχιστοποιώντας αυτό το σφάλμα, ο πίνακας βάρους προσαρμόζεται περαιτέρω και το

δίκτυο ρυθμίζεται έτσι. Σε αντίθεση με άλλους τυπικούς αλγόριθμους στην ταξινόμηση εικόνας, η προεπεξεργασία δεν εκτελείται συχνά στα CNN. Αντί να ορίσουμε παραμέτρους, όπως συμβαίνει με τα παραδοσιακά NN, πρέπει απλώς να εκπαιδεύσουμε τα φίλτρα στα CNN. Επιπλέον, στην εξαγωγή χαρακτηριστικών, τα CNN είναι ανεξάρτητα από προηγούμενη γνώση και ανθρώπινη παρέμβαση.

Το 1998, η μέθοδος μέγιστης συγκέντρωσης προτάθηκε στο LeNets για υπο δειγματοληψία. Συνοψίζοντας τα στατιστικά στοιχεία των κοντινών εξόδων, μια συνάρτηση συγκέντρωσης χρησιμοποιείται για να αντικαταστήσει την έξοδο του δικτύου σε μια συγκεκριμένη θέση. Χρησιμοποιώντας τη μέθοδο μέγιστης συγκέντρωσης, μπορούμε να λάβουμε τη μέγιστη απόδοση σε μια ορθογώνια γειτονιά. Η διαδικασία συγκέντρωσης μπορεί επίσης να κάνει την αναπαράσταση αμετάβλητη στις μεταφράσεις των εισόδων. Τώρα, προσθέτοντας ένα μέγιστο επίπεδο συγκέντρωσης μεταξύ των συνελκτικών στρωμάτων, η χωρική αφαιρετικότητα αυξάνεται με την αύξηση της αφαιρετικότητας των χαρακτηριστικών.

Η συσσώρευση χρησιμοποιείται για την απόκτηση αμετάβλητων στους μετασχηματισμούς εικόνας. Αυτή η διαδικασία θα οδηγήσει σε καλύτερη αντοχή στον θόρυβο. Επισημαίνεται ότι η απόδοση διαφόρων μεθόδων συγκέντρωσης εξαρτάται από διάφορους παράγοντες, όπως η ανάλυση με την οποία εξάγονται χαρακτηριστικά χαμηλού επιπέδου και οι σύνδεσμοι μεταξύ τυπικών χαρακτηριστικών. Το 2011, ο Boureau διαπίστωσε ότι ακόμη και αν τα χαρακτηριστικά είναι πολύ ανόμοια, είναι δυνατό να τα συνδυάσουμε όσο οι τοποθεσίες τους είναι κοντά. Επιπλέον, διαπιστώνεται ότι μπορεί να επιτευχθεί καλύτερη απόδοση εκτελώντας ομαδοποίηση πριν από το στάδιο της συγκέντρωσης. Αποδεικνύεται ότι καλύτερη απόδοση από κοινού μπορεί να επιτευχθεί με την εκμάθηση δεκτικών πεδίων με μεγαλύτερη προσαρμογή. Συγκεκριμένα, χρησιμοποιώντας την έννοια της υπερ-πληρότητας, προτείνεται ένας αποτελεσματικός αλγόριθμος μάθησης για να επιταχύνει τη διαδικασία εκπαίδευσης με βάση την επιπρόσθετη επιλογή χαρακτηριστικών.

7.12 Εφαρμογές

Σε αυτήν την παράγραφο, θα αναλύσουμε μερικές πρακτικές εφαρμογές των αρχιτεκτονικών βαθιάς μάθησης. Στην πραγματικότητα, λόγω της ικανότητάς τους να χειρίζονται μεγάλες ποσότητες δεδομένων χωρίς ετικέτα, οι τεχνικές βαθιάς μάθησης παρείχαν ισχυρά εργαλεία για την αντιμετώπιση μεγάλων δεδομένων. Τα τελευταία χρόνια, συλλέχθηκαν τεράστιες ποσότητες δεδομένων σε διάφορους τομείς, όπως η ασφάλεια στον κυβερνοχώρο, η ιατρική πληροφορική και τα κοινωνικά μέσα. Οι αλγόριθμοι βαθιάς μάθησης χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών υψηλού επιπέδου από αυτά τα δεδομένα, προκειμένου να ληφθούν ιεραρχικές αναπαραστάσεις. Πρόσφατα, η βαθιά μάθηση έχει προσελκύσει την προσοχή πολλών επιχειρήσεων υψηλής τεχνολογίας, όπως η Google, το Facebook και η Microsoft.

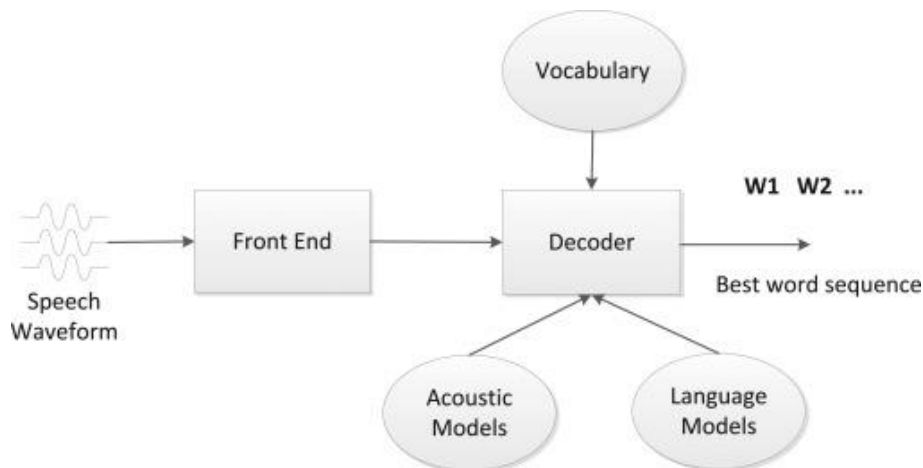
Η αρχιτεκτονική των βαθιών δικτύων έχει εφαρμοστεί ευρέως στην αναγνώριση ομιλίας και στην ακουστική μοντελοποίηση για ταξινόμηση ήχου. Εκτός αυτού, οι προσεγγίσεις βαθιάς μάθησης παίζουν επίσης σημαντικό ρόλο στον τομέα της επεξεργασίας εικόνας, όπως για παράδειγμα στην χειρόγραφη ταξινόμηση, ταξινόμηση σκηνών τηλεπισκόπησης υψηλής ανάλυσης, υπερ-ανάλυση μοναδικής εικόνας (SR), πολλαπλών κατηγοριών γρήγορη σειριακή οπτική παρουσίαση Brain Computer Interfaces (BCI), και προσαρμογή τομέα για ταξινόμηση συναισθημάτων μεγάλης κλίμακας. Επιπλέον, οι βαθιές αρχιτεκτονικές έχουν χρησιμοποιηθεί στη μάθηση πολλαπλών εργασιών για το NLP με αυξημένη στιβαρότητα συμπερασμάτων. Στη συνέχεια, θα κάνουμε μια γενική ανασκόπηση για διάφορες επιλεγμένες εφαρμογές των βαθιών δικτύων: αναγνώριση ομιλίας, όραση υπολογιστή και αναγνώριση προτύπων.

Αναγνώριση ομιλίας

Τις τελευταίες δεκαετίες, οι αλγόριθμοι μηχανικής μάθησης έχουν χρησιμοποιηθεί ευρέως σε τομείς όπως η αυτόματη αναγνώριση ομιλίας (ASR) και η ακουστική μοντελοποίηση. Το ASR

μπορεί να θεωρηθεί ως τυπικό πρόβλημα ταξινόμησης που προσδιορίζει ακολουθίες λέξεων από ακολουθίες χαρακτηριστικών ή κυματομορφές ομιλίας. Σε ορισμένες καλά καθορισμένες εφαρμογές όπως η μεταγραφή και η υπαγόρευση, οι εμπορικοί αναγνωριστές ομιλίας έχουν χρησιμοποιηθεί ευρέως. Πολλά ζητήματα πρέπει να ληφθούν υπόψη για να επιτευχθεί ικανοποιητική απόδοση στο ASR, για παράδειγμα, θορυβώδες περιβάλλον, αναγνώριση πολλών μοντέλων και πολυγλωσσική αναγνώριση. Κανονικά, τα δεδομένα πρέπει να υποβάλλονται σε προεπεξεργασία χρησιμοποιώντας τεχνικές αφαίρεσης θορύβου πριν εφαρμοστούν οι αλγόριθμοι αναγνώρισης ομιλίας. Ο Singh et al. επανεξέτασε ορισμένες γενικές προσεγγίσεις για την αφαίρεση θορύβου και τη βελτίωση της ομιλίας, όπως φασματική αφαίρεση, φιλτράρισμα Wiener, παράθυρα και εκτίμηση φασματικού εύρους. Οι παραδοσιακοί αλγόριθμοι μηχανικής μάθησης, όπως ο SVM και τα ΤΝΔ, έχουν δώσει πολλά υποσχόμενα αποτελέσματα στην αναγνώριση ομιλίας. Για παράδειγμα, μοντέλα Gaussian μείγματος (GMM) έχουν χρησιμοποιηθεί για την ανάπτυξη συστημάτων αναγνώρισης ομιλίας αντιπροσωπεύοντας τη σχέση μεταξύ της ακουστικής εισόδου και των κρυφών καταστάσεων του κρυφού μοντέλου Markov (HMM).

Η τυπική αρχιτεκτονική ενός συστήματος ASR δίνεται παρακάτω:



Σχήμα 7.14 τυπική αρχιτεκτονική ενός συστήματος ASR

Αρχικά, η κυματομορφή ομιλίας περνά μέσα από το ακουστικό μπροστινό άκρο, όπου το σήμα είναι προεπεξεργασμένο και παράγονται χαρακτηριστικά που μοιάζουν με φασματοσκοπία. Στη συνέχεια, οι δυνατότητες θα περάσουν σε έναν εκτιμητή πιθανοτήτων τηλεφώνου (phone likelihood estimator), προκειμένου να εκτιμηθεί η πιθανότητα κάθε τηλεφώνου. Μετά από αυτό, ο αποκωδικοποιητής θα αποκωδικοποιήσει την ομιλία με πιθανότητες τηλεφώνου χρησιμοποιώντας μοντέλο γλώσσας n-gram (LM) και το HMM. Τέλος, η έξοδος θα σταλεί στον αναλυτή, θα μετατραπεί στην καλύτερη ακολουθία λέξεων και θα μετατραπεί σε αναγνώσιμη μορφή.

Πρέπει να σημειωθεί ότι η απόδοση των HMM μπορεί να επηρεαστεί σε μεγάλο βαθμό από την αναντιστοιχία μεταξύ των συνθηκών εκπαίδευσης και δοκιμών. Σε μια τέτοια περίπτωση, απαιτείται μεγάλος όγκος δεδομένων. Επιπλέον, τα GMM παίζουν σημαντικό ρόλο στις εργασίες δημιουργίας ομιλίας και χρησιμοποιούνται συχνά στη χαρτογράφηση καρέ-καρέ, ειδικά για τη βελτίωση της ομιλίας, την αρθρωτική σε ακουστική χαρτογράφηση και τη μετατροπή φωνής. Τα συστήματα GMM-HMM έχουν βελτιώσει σημαντικά την ακρίβεια της ταξινόμησης και μπορούν επίσης να εφαρμοστούν για την αφαίρεση θορύβου σε θορυβώδεις εκφράσεις ομιλίας. Ομολογουμένως, το GMM-HMM εξακολουθεί να έχει κάποιους περιορισμούς. Είναι δύσκολο για το GMM-HMM να αντιπροσωπεύει μη γραμμικές ή πιο πολύπλοκες σχέσεις μεταξύ των ακουστικών χαρακτηριστικών και των εισόδων ομιλίας. Η αποτελεσματικότητα μοντελοποίησης είναι συνήθως πολύ χαμηλή για τα δεδομένα κοντά σε ένα μη-γραμμικό συλλέκτη. Επιπλέον, η υπόθεση της ανεξαρτησίας υπό όρους είναι ένα άλλο

γνωστό μειονέκτημα των GMM. Επιπλέον, η απώλεια ακατέργαστων πληροφοριών μπορεί επίσης να υποβαθμίσει την απόδοση των συστημάτων GMM-HMM.

Είναι ευρέως αναγνωρισμένο ότι τα ΤΝΔ που βρίσκονται πάνω ή κοντά σε ένα μη γραμμικό συλλέκτη μπορούν να αποδώσουν καλύτερες επιδόσεις από τα συστήματα GMM-HMM. Κομψά αποτελέσματα σημειώθηκαν πριν από δύο δεκαετίες όταν οι ερευνητές υιοθέτησαν ΤΝΔ με ένα στρώμα μη γραμμικών κρυφών μονάδων για να προβλέψουν τις καταστάσεις HMM από παράθυρα ακουστικών συντελεστών. Ωστόσο, λόγω των περιορισμένων πόρων υπολογισμού, ήταν δύσκολο να εφαρμοστούν τυπικά NN με πολλά κρυμμένα επίπεδα εκείνη την εποχή. Τα τελευταία χρόνια, οι τεχνικές υπολογισμού έχουν αναπτυχθεί γρήγορα, γεγονός που οδηγεί σε πιο αποτελεσματικούς τρόπους εκπαίδευσης των DNN. Όπως αναφέραμε, οι αλγόριθμοι βαθιάς μάθησης μπορούν να φέρουν ικανοποιητικά αποτελέσματα στην εξαγωγή και τον μετασχηματισμό χαρακτηριστικών και έχουν εφαρμοστεί με επιτυχία στην αναγνώριση προτύπων. Τα σύνθετα μοντέλα δημιουργούνται χρησιμοποιώντας μοντέλα DNN όπου τα χαρακτηριστικά λαμβάνονται από χαμηλότερα στρώματα. Μέσα από ορισμένα γνωστά σύνολα δεδομένων, συμπεριλαμβανομένων των μεγάλων συνόλων δεδομένων λεξιλογίου, οι ερευνητές έδειξαν ότι τα DNN θα μπορούσαν να επιτύχουν καλύτερη απόδοση από τα GMM σε ακουστική μοντελοποίηση για αναγνώριση ομιλίας. Λόγω της εξαιρετικής απόδοσής τους στη μοντελοποίηση συσχετισμού δεδομένων, οι αρχιτεκτονικές βαθιάς μάθησης αντικαθιστούν τώρα τα GMM στην αναγνώριση ομιλίας.

Οι πρώτες εφαρμογές των τεχνικών βαθιάς μάθησης αποτελούνται από μεγάλο λεξιλόγιο συνεχούς αναγνώρισης ομιλίας (LVCSR) και αναγνώριση τηλεφώνου. Σε αυτές τις εφαρμογές, τα DBN χρησιμοποιούνται για την εκπαίδευση των δεδομένων χωρίς ετικέτα διακριτικά. Επιπλέον, η μέθοδος DBN-HMM, η οποία συνδυάζει τα HMM με τα μοντέλα βαθιάς εκμάθησης, έχει σημειώσει μεγάλη επιτυχία. Η πιθανότητα παρατήρησης εκτιμάται χρησιμοποιώντας DBN, ενώ το HMM χρησιμοποιείται για να μοντελοποιήσει τις διαδοχικές πληροφορίες. Η μέγιστη αμοιβαία πληροφορόρηση (MMI) χρησιμοποιείται για την εκπαίδευση του DBN-CRF. Σε αυτήν την περίπτωση, τα βάρη μετάβασης, τα βάρη του DBN και το μοντέλο γλώσσας τηλεφώνου βελτιστοποιούνται από κοινού χρησιμοποιώντας την διαδοχική τεχνική διάκρισης μάθησης. Σε σύγκριση με το DBN-HMM με διαδικασία εκπαίδευσης με διάκριση πλαισίου, το DBN-CRF μπορεί να επιτύχει υψηλότερη ακρίβεια.

Όραση υπολογιστή και αναγνώριση προτύπων

Η όραση υπολογιστών στοχεύει να κάνει τους υπολογιστές να κατανοήσουν με ακρίβεια και να επεξεργαστούν αποτελεσματικά οπτικά δεδομένα όπως βίντεο και εικόνες. Το μηχάνημα καλείται να αντιλαμβάνεται δεδομένα υψηλής διάστασης σε πραγματικό κόσμο και να παράγει αναλόγως συμβολικές ή αριθμητικές πληροφορίες. Ο απώτερος στόχος της όρασης του υπολογιστή είναι να δώσει στους υπολογιστές την ικανότητα αντίληψης που έχει ο άνθρωπος. Εννοιολογικά, η όραση υπολογιστή αναφέρεται στην επιστημονική πειθαρχία που διερευνά τον τρόπο εξαγωγής πληροφοριών από εικόνες σε τεχνητά συστήματα. Οι ακόλουθοι τομείς περιλαμβάνονται ως υποτομείς της όρασης υπολογιστή: ανίχνευση συμβάντων, ανακατασκευή σκηνής, ανίχνευση και αναγνώριση αντικειμένων, εκτίμηση στάσης αντικειμένου, αποκατάσταση εικόνας, στατιστική μάθηση, επεξεργασία εικόνας και βελτίωση βίντεο.

Η αναγνώριση προτύπων είναι ένας επιστημονικός κλάδος που στοχεύει στον προσδιορισμό του προτύπου μιας δεδομένης τιμής εισόδου. Είναι μια μάλλον γενική έννοια που περιλαμβάνει πολλούς υποτομείς όπως η ταξινόμηση, η παλινδρόμηση, η επισήμανση ακολουθίας και η προσθήκη ετικετών ομιλίας. Λόγω της ραγδαίας βιομηχανικής ανάπτυξης, οι απαιτήσεις για τη δυνατότητα ανάκτησης και επεξεργασίας πληροφοριών αυξάνονται ολοένα και περισσότερο, γεγονός που έφερε νέες προκλήσεις στην αναγνώριση προτύπων. Πρόσφατα, η ανάπτυξη αρχιτεκτονικών βαθιάς μάθησης έδωσε νέες προσεγγίσεις στο πρόβλημα της αναγνώρισης προτύπων, οι οποίες θα συζητηθούν στην επόμενη παράγραφο.

Στις εφαρμογές ταξινόμησης, η επιλογή χαρακτηριστικών είναι ένα σημαντικό ζήτημα. Κανονικά, τα χαρακτηριστικά καθορίζονται χειροκίνητα σε παραδοσιακούς αλγόριθμους ταξινόμησης, οι οποίοι έχουν περιορισμένη γενικότητα. Κάποια τυπική αρχιτεκτονική βαθιάς εκμάθησης, όπως τα CNN, μπορούν να επιλέξουν αυτόματα τις δυνατότητες και να επιτύχουν εξαιρετική απόδοση με βάση υπολογιστικούς πόρους που επιταχύνονται με GPU. Σημειώστε ότι τα συστήματα ανθρώπινης όρασης διαφέρουν από τα συστήματα όρασης υπολογιστών και έχει αποδειχθεί ότι τα DNN μπορούν εύκολα να ξεγελαστούν από μη αναγνωρίσιμες εικόνες. Ωστόσο, αυτό δεν σημαίνει ότι οι τεχνικές βαθιάς μάθησης δεν είναι κατάλληλες για εργασίες ταξινόμησης.

Στην αναγνώριση αντικειμένων, η οποία ονομάζεται επίσης ταξινόμηση αντικειμένων, οι μέθοδοι βαθιάς μάθησης έχουν επιτύχει ανώτερη απόδοση σε σύγκριση με τους συμβατικούς αλγόριθμους ταξινόμησης. Για τη γερμανική αναγνώριση πινακίδων κυκλοφορίας, έχει προταθεί το DNN πολλών στρώσεων. Για τη μελέτη νευροψυχιατρικών καταστάσεων που βασίζονται σε πρότυπα λειτουργικής συνδεσιμότητας (FC), έχουν χρησιμοποιηθεί ευρέως τυποποιημένοι ταξινομητές όπως ο SVM. Πρόσφατα, τα DNNs έχουν χρησιμοποιηθεί για να ταξινομήσουν τα σχήματα σχιζοφρένειας FC σε κατάσταση ηρεμίας ολόκληρου του εγκεφάλου (SZ). Για να βελτιωθεί η απόδοση της ταξινόμησης, προτάθηκε ένα νέο πολυτροπικό βαθύ νευρωνικό δίκτυο μέγιστου περιθωρίου (3mDNN) για να επωφεληθούν από τους πολλαπλούς τοπικούς περιγραφείς μιας εικόνας. Σε σύγκριση με τους τυπικούς αλγόριθμους, αυτή η μέθοδος, λαμβάνοντας υπόψη τις πληροφορίες πολλών περιγραφών, μπορεί να επιτύχει διακριτική ικανότητα. Τα DNN μπορούν επίσης να χρησιμοποιηθούν για την ταξινόμηση των μοτίβων ταχύτητας ανέμου και την εμποτευόμενη πολυφασματική ταξινόμηση χρήσης γης.

Στην όραση και την αναγνώριση προτύπων, μερικές φορές χρειάζεται να κατασκευάσουμε και να επεξεργαστούμε τρισδιάστατα μοντέλα. Η κατανόηση των ματιών είναι ένας από τους βασικούς παράγοντες σε αυτόν τον τομέα. Συγκεκριμένα, η επισήμανση πλέγματος μπορεί να χρησιμοποιηθεί για να ανακαλύψει τα εγγενή χαρακτηριστικά του πλέγματος. Για εργασίες επισήμανσης εικόνας, ο Lerouge et al. πρότεινε μια έξοδο είσοδο βαθιάς αρχιτεκτονικής (IODA) το 2015. Προηγουμένως, οι προσεγγίσεις επισήμανσης πλέγματος επικεντρώνονταν στο τρίγωνο πλέγματος που χαρακτηριζόταν από ευρετικά σχεδιασμένα γεωμετρικά χαρακτηριστικά. Αν και αυτές οι τυπικές μέθοδοι θα μπορούσαν να έχουν ικανοποιητικά αποτελέσματα, υστερούσαν στο ότι τα γεωμετρικά χαρακτηριστικά θα μπορούσαν να παρέχουν πολλά υποσχόμενα αποτελέσματα μόνο για λίγους τύπους πλέγματος 3D. Ως εκ τούτου, είναι πολύ σημαντική η ανάπτυξη νέων προσεγγίσεων για τη δημιουργία χαρακτηριστικών και την επισήμανση χρησιμοποιώντας διαφορετικούς τύπους πλεγμάτων. Προς αυτόν τον στόχο, εισήχθη μια πιο αποτελεσματική αναπαράσταση πλεγμάτων. Συνδυάζοντας γνώσεις ανθρώπινης όρασης και μοντέλα βαθιάς μάθησης, τα CNNs χρησιμοποιούνται για να μάθουν αναπαράστασεις πλέγματος με πολύ καλύτερη απόδοση. Επιπλέον, τα DBN έχουν χρησιμοποιηθεί ευρέως σε εργασίες ταξινόμησης αντικειμένων.

Είναι ευρέως αναγνωρισμένο ότι όταν χρησιμοποιούνται μεγαλύτερα σύνολα δεδομένων για εκπαίδευση, το πρόβλημα της υπερφόρτωσης μπορεί να προληφθεί αποτελεσματικά, πράγμα που συνεπάγεται βελτιωμένη απόδοση. Ως εκ τούτου, ως σύνολο δεδομένων που περιλαμβάνει πάνω από 15 εκατομμύρια εικόνες με ετικέτα, το ImageNet έχει προσελκύσει μεγάλη προσοχή.

Πρέπει να σημειωθεί ότι τεχνικές βαθιάς εκμάθησης μπορούν επίσης να εφαρμοστούν στην αναγνώριση της στάσης του χεριού (HPR). Με βάση τη λειτουργική φασματοσκοπία κοντά στην υπέρυθη ακτινοβολία (FNIRS), οι τεχνικές βαθιάς μάθησης έχουν επιτύχει πολλά υποσχόμενα αποτελέσματα στην ταξινόμηση προτύπων ενεργοποίησης εγκεφάλου για BCI.

Ταξινόμηση εικόνας

Αυτή είναι αναμφισβήτητη η απλούστερη και πιο γνωστή εφαρμογή των συνελκτικών νευρωνικών δικτύων. Στο μοντέλο δίνεται μια εικόνα εισόδου και το επιθυμητό αποτέλεσμα

είναι η εξαγωγή μιας κλάσης - μία από τις (τυπικά) αμοιβαίως αποκλειόμενες ετικέτες αυτής της εικόνας.

Σε σύγκριση με άλλες μεθόδους, τα CNN μπορούν να επιτύχουν καλύτερη ακρίβεια ταξινόμησης σε σύνολα δεδομένων μεγάλης κλίμακας λόγω της ικανότητάς τους να χρησιμοποιούν κοινά χαρακτηριστικά και να ταξινομούν ταξινομητές. Η δημιουργία μιας ιεραρχίας ταξινομητών είναι μια κοινή στρατηγική για την ταξινόμηση εικόνων με μεγάλο αριθμό κλάσεων. Το έργο “ N. Srivastava, R. R. Salakhutdinov, Discriminative transfer learning with tree-based priors, in: Proceedings of the Advances in Neural Information Processing Systems (NIPS), 2013, pp. 2094–2102” είναι μία από τις πρώτες προσπάθειες εισαγωγής ιεραρχίας κατηγορίας στο CNN, στην οποία προτείνεται μια διακριτική μεταφορά μάθησης με προτεραιότητες που βασίζονται σε δέντρα. Χρησιμοποιούν μια ιεραρχία τάξεων για την ανταλλαγή πληροφοριών μεταξύ των σχετικών τάξεων προκειμένου να βελτιώσουν την απόδοση για τάξεις με πολύ λίγα παραδείγματα εκπαίδευσης. Ομοίως, ο Wang et al, χτίζουν μια δομή δέντρου για να μάθουν λεπτομερή χαρακτηριστικά για αναγνώριση υποκατηγοριών. Οι Xiao et al., προτείνουν μια μέθοδο εκπαίδευσης που αναπτύσσει ένα δίκτυο όχι μόνο σταδιακά αλλά και ιεραρχικά. Στη μέθοδο τους, οι τάξεις ομαδοποιούνται σύμφωνα με τις ομοιότητες και αυτοοργανώνονται σε διαφορετικά επίπεδα. Οι Yan et al. εισάγουν ένα ιεραρχικό βαθύ CNN (HD-CNN) ενσωματώνοντας βαθιά CNN σε μια ιεραρχία κατηγορίας. Αποσυνθέτουν την εργασία ταξινόμησης σε δύο βήματα. Ο ταξινομητής χονδροειδούς κατηγορίας CNN χρησιμοποιείται αρχικά για να διαχωρίσει τις εύκολες τάξεις μεταξύ τους και στη συνέχεια οι πιο απαιτητικές τάξεις κατευθύνονται προς τα κάτω σε ταξινομητές υψηλής κατηγορίας για περαιτέρω πρόβλεψη. Αυτή η αρχιτεκτονική ακολουθεί το πρότυπο “από χονδροειδές σε εκλεπτυσμένο” (coarse-to-fine) ταξινόμησης και μπορεί να επιτύχει μικρότερο σφάλμα με κόστος προσίτης αύξησης της πολυπλοκότητας. Η ταξινόμηση υποκατηγοριών είναι ένα άλλο ταχέως αναπτυσσόμενο υποπεδίο της ταξινόμησης εικόνας. Υπάρχουν ήδη ορισμένα σύνολα δεδομένων λεπτομερούς εικόνας. Η χρήση πληροφοριών για αντικείμενα είναι επωφελής για την λεπτομερή ταξινόμηση. Γενικά, η ακρίβεια μπορεί να βελτιωθεί εντοπίζοντας σημαντικά μέρη αντικειμένων και αντιπροσωπεύοντας τις εμφανίσεις τους με διακρίσεις. Με αυτόν τον τρόπο, οι Branson et al. , προτείνουν μια μέθοδο που ανιχνεύει τμήματα και η οποία εξαγεί χαρακτηριστικά CNN από πολλαπλές περιοχές πύζας που έχουν κανονικοποιηθεί . Οι πληροφορίες σχολιασμού μέρους χρησιμοποιούνται για την εκμάθηση ενός συμπαγούς χώρου κανονικοποίησης στάσης. Δημιουργούν επίσης ένα μοντέλο που ενσωματώνει στρώματα χαρακτηριστικών χαμηλότερου επιπέδου με ρουτίνες εξαγωγής που εξομαλύνουν τη στάση, και στρώματα χαρακτηριστικών υψηλότερου επιπέδου με μη ευθυγραμμισμένα χαρακτηριστικά εικόνας για τη βελτίωση της ακρίβειας ταξινόμησης. Zhang et al προτείνουν ένα R-CNN μερικής βάσης το οποίο μπορεί να μάθει ανιχνευτές ολόκληρων αντικειμένων και τμημάτων. Οι πληροφορίες σχολιασμού μέρους χρησιμοποιούνται για την εκμάθηση ενός συμπαγούς χώρου κανονικοποίησης πύζας. Δημιουργούν επίσης ένα μοντέλο που ενσωματώνει στρώματα χαρακτηριστικών χαμηλότερου επιπέδου με ρουτίνες εξαγωγής που εξομαλύνουν την πύζα και στρώματα χαρακτηριστικών υψηλότερου επιπέδου με μη ευθυγραμμισμένα χαρακτηριστικά εικόνας για τη βελτίωση της ακρίβειας της ταξινόμησης.

Όπως μπορεί να σημειωθεί, όλες οι προαναφερθείσες μέθοδοι χρησιμοποιούν πληροφορίες σχολιασμού μέρους για επιβλεπόμενη εκπαίδευση. Ωστόσο, αυτοί οι σχολιασμοί δεν είναι εύκολο να συλλεχθούν, ενώ παράλληλα , αυτά τα συστήματα δυσκολεύονται να κλιμακώσουν και να χειριστούν πολλούς τύπους λεπτομερειικών (fine-grained) τάξεων. Για να αποφευχθεί αυτό το πρόβλημα, ορισμένοι ερευνητές προτείνουν να βρεθούν τοπικά τμήματα ή περιοχές με τρόπο χωρίς επίβλεψη. Οι Krause et al. χρησιμοποιούν το σύνολο των εντοπισμένων αναπαραστάσεων που το δίκτυο έχει μάθει, για λεπτομερή ταξινόμηση, χρησιμοποιούν τη συν-κατάμηση και την ευθυγράμμιση για τη δημιουργία τμημάτων και στη συνέχεια συγκρίνουν την εμφάνιση κάθε μέρους και συγκεντρώνουν τις ομοιότητες μαζί.

Τα νευρωνικά δίκτυα για ταξινόμηση εικόνων είναι μια εξαιρετικά κοινή εφαρμογή της βαθιάς μάθησης. Υπάρχουν πολλοί διαφορετικοί τύποι μοντέλων CNN για ταξινόμηση. Μερικά

παραδείγματα αυτών είναι : VGG - μια απλή στοίβα συνελκτικών στρωμάτων ακολουθούμενη από ένα πλήρως συνδεδεμένο στρώμα, ResNets - τα οποία είναι μια οικογένεια συνελκτικών δικτύων διαφορετικών μεγεθών και βάθους τα οποία παραλείπουν συνδέσεις , DenseNets - μια άλλη οικογένεια μοντέλων όπου σε αντίθεση με τα τυπικά νευρωνικά δίκτυα, κάθε επίπεδο σε ένα "μπλοκ" συνδέεται με κάθε άλλο επίπεδο. Πιο πρόσφατα, πολύπλοκα μοντέλα περιλαμβάνουν το ResNeXt και πρόσφατα το EfficientNets, τα οποία έχουν ξεχωριστούς συντελεστές κλιμάκωσης για το βάθος, το πλάτος και τη χωρική ανάλυση της εικόνας εισόδου.

Ανίχνευση αντικειμένων

Η ανίχνευση αντικειμένων ήταν ένα μακροχρόνιο και σημαντικό πρόβλημα στην όραση του υπολογιστή. Γενικά, οι δυσκολίες έγκεινται κυρίως στον τρόπο ακριβούς και αποτελεσματικού εντοπισμού αντικειμένων σε εικόνες ή βίντεο. Η χρήση των CNN για ανίχνευση χρονολογείται στη δεκαετία του 1990. Ωστόσο, λόγω της έλλειψης δεδομένων εκπαίδευσης και περιορισμένων πόρων επεξεργασίας, η πρόοδος της ανίχνευσης αντικειμένων με το CNN αποδείχθηκε αργή πριν από το 2012. Από το 2012 και μετά, η τεράστια επιτυχία των CNNs στην πρόκληση του ImageNet αναζωπυρώνει το ενδιαφέρον για την ανίχνευση αντικειμένων με βάση το CNN.

Η ταξινόμηση εικόνας μπορεί να θεωρηθεί ως μια συνολική περίληψη της εικόνας. Η ανίχνευση αντικειμένων ασχολείται με ορισμένες από τις λεπτομέρειες χαμηλότερου επιπέδου της εικόνας και εξετάζει τον εντοπισμό διαφορετικών αντικειμένων στην εικόνα. Για παράδειγμα, δεδομένης μιας εικόνας εισόδου μιας υπαίθριας σκηνής που έχει ένα σκύλο, ένα άτομο και ένα δέντρο, η ανίχνευση αντικειμένου θα εξετάζει ταυτόχρονα την παρουσία του σκύλου, του προσώπου και του δέντρου και θα «κυκλώνει τη θέση τους» στην εικόνα - συγκεκριμένα, θα υπάρχει ένα κουτί οριοθέτησης γύρω από το καθένα από αυτά. Η εποπτευόμενη εργασία μάθησης είναι, συνεπώς, η λήψη μιας εικόνας εισόδου και η λήψη μιας εξόδου των συντεταγμένων αυτών των οριοθετημένων πλαισίων, καθώς και η κατηγοριοποίηση του είδους του αντικειμένου που περιέχουν.

Όπως και στην ταξινόμηση εικόνας, υπάρχουν πολλές αρχιτεκτονικές υψηλής απόδοσης για ανίχνευση αντικειμένων. Λόγω της πολυπλοκότητας της εργασίας εξόδου, αυτά τα μοντέλα τείνουν να είναι πιο πολύπλοκα με ένα στοιχείο ραχοκοκαλιάς (χρησιμοποιώντας ένα μοντέλο ταξινόμησης εικόνας) και ένα στοιχείο πρότασης περιοχής για οριοθέτηση προτάσεων πλαισίων. Υπάρχουν όμως ακόμα πολλά προπονημένα μοντέλα διαθέσιμα για λήψη. Ένα από τα πιο επιτυχημένα πρώιμα μοντέλα ήταν το Faster R-CNN , το οποίο επιτάχυνε σημαντικά το συστατικό της πρότασης του αργού δεσμευτικού κουτιού. Έκτοτε υπήρξαν πολλά βελτιωμένα μοντέλα, συμπεριλαμβανομένου του YOLOv3 , και πιο πρόσφατα του EfficientDets .. Αναμφισβήτητα η πιο δημοφιλής πρόσφατη αρχιτεκτονική ωστόσο είναι το Mask R-CNN και οι παραλλαγές του . Το Mask R-CNN εκτελεί κάποια τμηματοποίηση καθώς και ανίχνευση αντικειμένων .

Η ανίχνευση αντικειμένων έχει επίσης κερδίσει σημαντική προσοχή σε διάφορες επιστημονικές εφαρμογές. Έχει χρησιμοποιηθεί σε πολλά ιατρικά περιβάλλοντα για τον εντοπισμό χαρακτηριστικών που μας ενδιαφέρουν, για παράδειγμα, καρκινικά κύτταρα σε διαφορετικούς τρόπους απεικόνισης ή κατάγματα στην ακτινολογία .

Ταξινόμηση κειμένου

Η ταξινόμηση κειμένου είναι μια κρίσιμη εργασία για την επεξεργασία φυσικής γλώσσας (NLP). Οι προτάσεις φυσικής γλώσσας έχουν περίπλοκες δομές, διαδοχικές και ιεραρχικές, που είναι απαραίτητες για την κατανόησή τους. Λόγω της ισχυρής ικανότητας καταγραφής τοπικών σχέσεων χρονικών ή ιεραρχικών δομών, τα CNN έχουν επιτύχει κορυφαίες επιδόσεις στη μοντελοποίηση προτάσεων. Μια σωστή αρχιτεκτονική CNN είναι σημαντική για την ταξινόμηση κειμένου. Οι Collobert et al.] και Yu et al. εφαρμόζουν ένα στρεπτικό στρώμα για να μοντελοποιήσουν την πρόταση, ενώ οι Kalchbrenner et al. στοιβάζουν πολλαπλά επίπεδα

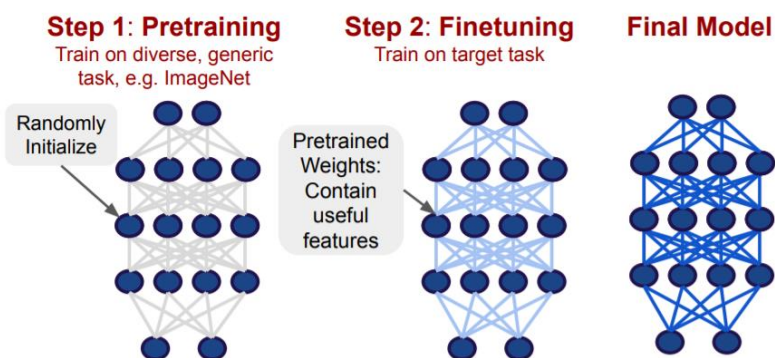
συνέλιξης σε πρότυπες προτάσεις. Αποδεικνύεται ότι πολλαπλά στρεπτικά στρώματα βοηθούν στην εξαγωγή αφηρημένων χαρακτηριστικών υψηλού επιπέδου και ότι τα πολλαπλά γραμμικά φίλτρα μπορούν να εξετάσουν αποτελεσματικά διαφορετικά χαρακτηριστικά n-gram.

7.13 Τρόποι Μάθησης

Στην προηγούμενη ενότητα είδαμε τα συνελκτικά νευρωνικά δίκτυα και τους πολλούς διαφορετικούς τύπους εργασιών που θα μπορούσαν να χρησιμοποιηθούν. Για να εκπαιδεύσουμε τα μοντέλα για αυτές τις εργασίες, βασιζόμαστε συνήθως στη μεθοδολογία εποπτευόμενης μάθησης - βελτιστοποιούμε τις παραμέτρους του μοντέλου για να βγάλουμε σωστά συγκεκριμένες ετικέτες (την επίβλεψη) σε ένα σύνολο παραδειγμάτων δεδομένων εκπαίδευσης.

Πιο αναλυτικά, η τυπική μέθοδος εποπτευόμενης μάθησης για βαθιά νευρωνικά δίκτυα συνίσταται στην (i) συλλογή περιπτώσεων δεδομένων (π.χ. εικόνες) (ii) συλλογή ετικετών για τις περιπτώσεις δεδομένων (π.χ. είναι η εικόνα γάτας ή σκύλου) (iii) διαχωρισμό συνόλου συλλεχθέντων (παραδείγματα δεδομένων, ετικέτα) σε σετ εκπαίδευσης, σύνολο επικύρωσης και σύνολο δοκιμών (iv) τυχαία εκκίνηση παραμέτρων νευρωνικού δικτύου (v) βελτιστοποίηση παραμέτρων, ώστε το δίκτυο να εξάγει τη σωστή αντίστοιχη ετικέτα, δεδομένης μιας παρουσίας δεδομένων εισόδου στο σύνολο εκπαίδευσης (vi) περαιτέρω ρύθμιση και επικύρωση στα σύνολα επικύρωσης και δοκιμής.

Μεταφορά Μάθησης



Σχήμα 7.15 Μεταφορά Μάθησης

Μέσα από τις προηγούμενες ενότητες, κάναμε αναφορές στη χρήση προπονητικών μοντέλων. Αυτό στην πραγματικότητα αναφέρεται σε μια πολύ σημαντική μέθοδο για την εκπαίδευση βαθιών νευρωνικών δικτύων, γνωστή ως μάθηση μεταφοράς. Η μάθηση μεταφοράς είναι μια διαδικασία δύο βημάτων για την εκπαίδευση ενός μοντέλου βαθιάς νευρωνικής δικτύωσης, ένα βήμα προ-εκπαίδευσης, ακολουθούμενο από ένα βήμα εκτέλεσης, όπου το μοντέλο εκπαιδεύεται στην εργασία-στόχο.

Πιο συγκεκριμένα, παίρνουμε ένα νευρωνικό δίκτυο με τυχαία αρχικοποιημένες παραμέτρους και το εκπαιδεύουμε πρώτα σε μια τυπική, γενική εργασία - το βήμα προ-εκπαίδευσης. Για παράδειγμα, σε εργασίες που βασίζονται σε εικόνα, μια κοινή εργασία προ-εκπαίδευσης είναι η ImageNet, η οποία είναι μια εργασία ταξινόμησης εικόνων σε ένα μεγάλο σύνολο δεδομένων φυσικών εικόνων. Με μια κατάλληλη προ-εκπαιδευόμενη εργασία που είναι γενική και αρκετά περίπλοκη, το βήμα προ-εκπαίδευσης επιτρέπει στο νευρωνικό δίκτυο να μάθει χρήσιμες λειτουργίες, αποθηκευμένες στις παραμέτρους του, οι οποίες στη συνέχεια μπορούν να επαναχρησιμοποιηθούν για το δεύτερο βήμα, την εκ νέου ρύθμιση. Στο finetuning, το προ-εκπαιδευμένο νευρωνικό δίκτυο εκπαιδεύεται περαιτέρω (με ίσως κάποιες μικρές τροποποιήσεις στο επίπεδο εξόδου του) στο πραγματικό στόχο-στόχο που μας ενδιαφέρει.

Αυτή η διαδικασία απεικονίζεται στο Σχήμα 7.15. Αλλά η δυνατότητα χρήσης των χαρακτηριστικών που έμαθε κατά την εκπαίδευση συχνά οδηγεί σε αύξηση της απόδοσης και της ταχύτητας σύγκλισης της εργασίας -στόχου, καθώς και ανάγκη λιγότερων επισημασμένων δεδομένων.

Λόγω αυτών των σημαντικών οφελών, η μάθηση μεταφοράς έχει υπάρξει εξαιρετικά χρήσιμη σε πολλές ρυθμίσεις, ιδιαίτερα στην όραση υπολογιστή, η οποία είχε πολλές πρώιμες επιτυχημένες εφαρμογές. Η πρόσφατη ανάπτυξη μοντέλων όπως το ULMFiT και ειδικά το BERT έχει επίσης καταστήσει τη μάθηση μεταφοράς εξαιρετικά επιτυχημένη σε φυσικές γλώσσες και διαδοχικές ρυθμίσεις δεδομένων, με τις πρόσφατες εργασίες/ενέργειες να κάνουν τη διαδικασία μεταφοράς μάθησης ακόμη πιο αποτελεσματική. Το πιο σημαντικό, η έτοιμη διαθεσιμότητα τυπικών αρχιτεκτονικών νευρωνικών δικτύων που έχουν προπονηθεί σε τυπικά σημεία αναφοράς μέσω πολλών αποθεμάτων ανοιχτού κώδικα στο GitHub σημαίνει ότι η λήψη και η εκτέλεση ενός τυπικού προπονημένου/εκπαιδευμένου μοντέλου έχει γίνει το de-facto πρότυπο για τις περισσότερες νέες εφαρμογές βαθιάς εκμάθησης.

Συνήθως, η μεταφορά μάθησης είναι ένας εξαιρετικός τρόπος για να ξεκινήσουμε να δουλεύουμε πάνω σε ένα νέο πρόβλημα ενδιαφέροντος. Υπάρχει το πλεονέκτημα της χρήσης μιας καλά δοκιμασμένης, τυπικής αρχιτεκτονικής νευρωνικών δικτύων, εκτός από την επαναχρησιμοποίηση της γνώσης, την ενίσχυση της σταθερότητας και της σύγκλισης που προσφέρουν τα εκπαιδευμένα βάρη. Σημειώστε, ωστόσο, ότι τα ακριβή αποτελέσματα της μεταφοράς μάθησης δεν είναι ακόμη πλήρως κατανοητά και μια ενεργός ερευνητική περιοχή εξετάζει τη διερεύνηση των ακριβών ιδιοτήτων της.

Multitask Learning

Σε πολλές εφαρμογές μάθησης με επίβλεψη, που κυμαίνονται από την αυτόματη μετάφραση έως τις επιστημονικές ρυθμίσεις, τα νευρωνικά δίκτυα εκπαιδεύονται με τρόπο πολλαπλών εργασιών - προβλέποντας πολλές διαφορετικές εξόδους για μία μόνο είσοδο. Για παράδειγμα, στην ταξινόμηση εικόνας, δεδομένης μιας ιατρικής εικόνας εισόδου, μπορούμε να εκπαιδεύσουμε το δίκτυο όχι μόνο να προβλέπει μια ασθένεια που μας ενδιαφέρει, αλλά την ηλικία του ασθενούς, το ιστορικό άλλων σχετικών ασθενειών κ.λπ. Αυτό συχνά έχει ευεργετικά αποτελέσματα ακόμη και αν υπάρχει μόνο μία πρόβλεψη, καθώς παρέχει στο νευρωνικό δίκτυο χρήσιμη πρόσθετη ανατροφοδότηση (feedback) γεγονός που μπορεί να (το) οδηγήσει στην εκμάθηση των πιο σημαντικών χαρακτηριστικών δεδομένων. (Αυτό μπορεί να είναι τόσο χρήσιμο ώστε μερικές φορές να καθορίζονται μόνο βοηθητικοί στόχοι πρόβλεψης μόνο για αυτόν τον σκοπό.) Επιπλέον, η πρόβλεψη πολλαπλών στόχων μπορεί να σημαίνει ότι υπάρχουν περισσότερα δεδομένα για την εκπαίδευση του μοντέλου (μόνο ένα υποσύνολο δεδομένων έχει τις ετικέτες στόχου ενδιαφέροντος, αλλά πολλές άλλες περιπτώσεις δεδομένων έχουν άλλες βοηθητικές ετικέτες.) Η πιο ακραία έκδοση αυτού είναι η ταυτόχρονη εκπαίδευση σε δύο εντελώς διαφορετικά σύνολα δεδομένων. Για παράδειγμα, αντί να εκτελέσουμε ένα βήμα προ-προπόνησης/τελικής επεξεργασίας, το μοντέλο θα μπορούσε να εκπαιδευτεί τόσο στο ImageNet όσο και σε ένα σύνολο δεδομένων ιατρικής απεικόνισης ταυτόχρονα.

Η εκμάθηση πολλαπλών εργασιών (multitask learning) εφαρμόζεται συνήθως στην πράξη, δίνοντας στο νευρωνικό δίκτυο πολλαπλές κεφαλές. Η κεφαλή ενός νευρωνικού δικτύου αναφέρεται στο επίπεδο εξόδου του και ένα νευρωνικό δίκτυο με πολλαπλές κεφαλές έχει μία κεφαλή για κάθε προγνωστική εργασία (π.χ. μία κεφαλή για την πρόβλεψη της ηλικίας, μία για την πρόβλεψη της νόσου που μας ενδιαφέρει) αλλά μοιράζεται όλα τα άλλα χαρακτηριστικά και παραμέτρους, σε αυτές τις διαφορετικές προγνωστικές εργασίες. Από εκεί προέρχεται το όφελος της εκμάθησης πολλαπλών εργασιών - οι κοινές δυνατότητες, που αποτελούν το μεγαλύτερο μέρος του δικτύου, λαμβάνουν πολλές διαφορετικές πηγές ανατροφοδότησης. Η εφαρμογή της εκμάθησης πολλαπλών εργασιών συχνά απαιτεί επίσης προσεκτική επιλογή του τρόπου στάθμισης των στόχων κατάρτισης/εκπαίδευσης για αυτές τις διαφορετικές εργασίες-καθήκοντα.

Ασθενής επίβλεψη (μακρινή επίβλεψη)

Ας υποθέσουμε ότι είναι πολύ δύσκολο να συλλέξουμε ετικέτες υψηλής ποιότητας για το στόχο που μας ενδιαφέρει και ότι δεν υπάρχει ένα υπάρχον, τυποποιημένο, σχετικό σύνολο δεδομένων και αντίστοιχο προπονημένο/εκπαιδευμένο μοντέλο από το οποίο μπορούμε να εκτελέσουμε μάθηση μεταφοράς. Πώς μπορεί κάποιος να παρέχει στο μοντέλο βαθιάς μάθησης αρκετή εποπτεία κατά τη διάρκεια της διαδικασίας κατάρτισης; Ενώ οι ετικέτες υψηλής ποιότητας μπορεί να είναι δύσκολο να αποκτηθούν, οι θορυβώδεις ετικέτες μπορεί να συλλέγονται σχετικά πιο εύκολα. Η ασθενής/αδύναμη επίβλεψη αναφέρεται στη μέθοδο εκπαίδευσης ενός μοντέλου σε ένα σύνολο δεδομένων με αυτές τις θορυβώδεις ετικέτες (συνήθως για μελλοντική τελική ρύθμιση), όπου οι θορυβώδεις ετικέτες δημιουργούνται συχνά με αυτόματη διαδικασία.

Σε εργασίες όρασης υπολογιστή (βάσει εικόνας), μερικά παραδείγματα είναι: λήψη ετικέτας επιπέδου εικόνας (για ταξινόμηση) και αυτόματη εξαγωγή ετικετών επιπέδου εικονοστοιχείων για τμηματοποίηση, ομαδοποίηση κρυφών αναπαραστάσεων που υπολογίζονται από ένα προπονημένο δίκτυο ως ψευδοετικέτες, ή λήψη ετικετών Instagram ως ετικέτες για προπόνηση.

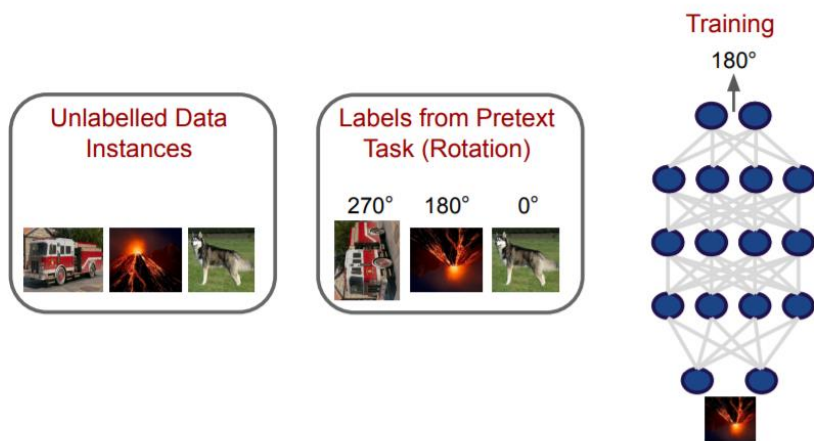
7.14 DNNs και λιγότερα δεδομένα

Οι εποπτευόμενες μέθοδοι μάθησης και συγκεκριμένες παραλλαγές της, όπως η μεταφορά μάθησης και η εκμάθηση πολλαπλών εργασιών αποδείχθηκαν ιδιαίτερα επιτυχημένες στην εκπαίδευση μοντέλων βαθιών νευρωνικών δικτύων. Ωστόσο, ένας σημαντικός περιορισμός στη χρήση τους, και επομένως στη χρήση της βαθιάς μάθησης, είναι η εξάρτηση από μεγάλες ποσότητες δεδομένων με ετικέτα. Σε πολλούς εξειδικευμένους τομείς, όπως η ιατρική, η συλλογή μεγάλου αριθμού αξιόπιστων ετικετών υψηλής ποιότητας μπορεί να είναι απαγορευτικά δαπανηρή.

Ευτυχώς, μόλις τα τελευταία χρόνια, είδαμε αξιοσημείωτες προόδους σε μεθόδους που μειώνουν αυτήν την εξάρτηση, ιδιαίτερα στην αυτοεπίβλεψη και την ημι-εποπτευόμενη μάθηση. Αυτές οι προσεγγίσεις εξακολουθούν να ακολουθούν το παράδειγμα της εκπαίδευσης ενός νευρωνικού δικτύου για τη χαρτογράφηση ακατέργαστων στιγμιότυπων δεδομένων σε μια συγκεκριμένη ετικέτα, αλλά κρίσιμα, αυτές οι ετικέτες δεν συλλέγονται χωριστά, αντιθέτως ορίζονται αυτόματα μέσω μιας εργασίας προσχήματος. Για παράδειγμα, μπορούμε να πάρουμε ένα σύνολο δεδομένων εικόνων, να περιστρέψουμε μερικές από αυτές και στη συνέχεια να ορίσουμε την ετικέτα ως το βαθμό περιστροφής, που είναι ο στόχος πρόβλεψης για το νευρωνικό δίκτυο. Αυτό επιτρέπει τη χρήση δεδομένων χωρίς ετικέτα στην εκπαίδευση των βαθιών νευρωνικών δικτύων.

Αυτο-εποπτευόμενη μάθηση

Στην αυτοεποπτεία, ορίζεται μια εργασία προσχήματος έτσι ώστε οι ετικέτες να μπορούν να υπολογίζονται αυτόματα απευθείας από τις ακατέργαστες περιπτώσεις δεδομένων. Για παράδειγμα, στις εικόνες, θα μπορούσαμε να περιστρέψουμε την εικόνα κατά κάποιο ποσό, να της προσθέσουμε ετικέτα ανάλογα με το πόσο περιστράφηκε και να εκπαιδεύσουμε ένα νευρωνικό δίκτυο για να προβλέψει τον βαθμό περιστροφής - αυτή η ρύθμιση απεικονίζεται στο Σχήμα 6.16. Αυτή η εργασία προσχηματισμού ορίζεται χωρίς να απαιτείται προσπάθεια ετικετοποίησης, αλλά μπορεί να χρησιμοποιηθεί για να διδάξει στο δίκτυο καλές αναπαραστάσεις.



Σχήμα 7.16 Αυτό-εποπτευόμενη Μάθηση

Αυτές οι αναπαραστάσεις μπορούν στη συνέχεια να χρησιμοποιηθούν ως έχουν ή ίσως με λίγα επιπλέον δεδομένα για μεταγενέστερα προβλήματα. Αναμφισβήτητα η μεγαλύτερη επιτυχία της αυτό-εποπτείας ήταν η γλωσσική μοντελοποίηση για διαδοχικά δεδομένα και συγκεκριμένα φυσικά προβλήματα γλώσσας. Παρακάτω αναφέρονται μερικά από τα πιο δημοφιλή και επιτυχημένα παραδείγματα αυτό-εποπτείας τόσο για δεδομένα εικόνας όσο και για διαδοχικά δεδομένα.

Αυτο-εποπτευόμενη μάθηση για εικόνες

Ένα πρόσφατο, δημοφιλές και απλό έργο αυτο-εποπτείας για τις εικόνες είναι η πρόβλεψη περιστροφών εικόνας. Κάθε περίπτωση εικόνας μεταμορφώνεται με μία από τις τέσσερις πιθανές περιστροφές και το μοντέλο βαθιάς μάθησης πρέπει να ταξινομήσει σωστά την περιστροφή. Παρά την απλότητά του, πολλαπλές μελέτες έχουν δείξει την επιτυχία του στην εκμάθηση καλών αναπαραστάσεων. Μια άλλη δημοφιλής μέθοδος που εξετάστηκε σε αυτές τις μελέτες είναι η υποδειγματική (exemplar), η οποία προτείνει ένα έργο αυτοεποπτείας που βασίζεται στην αμετάβλητη μεταμόρφωση εικόνας. Για παράδειγμα, μπορεί να πάρουμε μια πηγή εικόνας μιας γάτας και να εκτελέσουμε μια ακολουθία μετασχηματισμών, όπως περιστροφή, προσαρμογή της αντίθεσης, αναστροφή της εικόνας οριζόντια κ.λπ. Λαμβάνουμε πολλαπλές εικόνες της γάτας επιλέγοντας πολλές τέτοιες ακολουθίες και εκπαιδεύουμε το νευρωνικό δίκτυο να τις αναγνωρίζει όλες ως την ίδια εικόνα.

Άλλες μέθοδοι εξετάζουν τη χρήση μπαλωμάτων εικόνας ως πλαίσιο για να μάθουν για την παγκόσμια δομή της εικόνας και τα σημαντικά χαρακτηριστικά. Μια πρόσφατη σειρά εργασιών/ερευνών εξέτασε τη χρήση μετρήσεων εμπνευσμένων από αμοιβαίες πληροφορίες ως τρόπο για την επίβλεψη της συσχέτισης διαφορετικών επιδιορθώσεων εικόνας. Ωστόσο αυτές μπορεί να είναι πιο περίπλοκες στην εφαρμογή τους. Πολλές από αυτές τις μετρήσεις αμοιβαίας πληροφόρησης βασίζονται επίσης σε αντίθετες απώλειες, οι οποίες, σε υψηλό επίπεδο, παρέχουν επίβλεψη στο δίκτυο κάνοντας τις αναπαραστάσεις ενός ζεύγους παρόμοιων εισόδων πιο παρόμοιες από τις αναπαραστάσεις ενός ζεύγους διαφορετικών εισόδων.

Αυτο-εποπτευόμενη μάθηση για διαδοχικά δεδομένα (Φυσική γλώσσα)

Ενώ η έρευνα για τεχνικές αυτοεποπτείας για εικόνες είναι εξαιρετικά ενεργή, οι ισχυρότερες επιτυχίες αυτού του πλαισίου σημειώθηκαν αναμφισβήτητα στα διαδοχικά δεδομένα, ιδιαίτερα σε κείμενο και φυσική γλώσσα. Η διαδοχική δομή δημιουργεί αμέσως αποτελεσματικές εργασίες προσχήματος αυτοεποπτείας. Δύο κυρίαρχες κατηγορίες εργασιών προσχήματος

(pretext tasks) λειτουργούν είτε (i) χρησιμοποιώντας γειτονικά tokens της ακολουθίας ως πλαίσιο εισόδου για την πρόβλεψη ενός στόχου token (ii) με τη λήψη όλων των tokens μέχρι μια συγκεκριμένη θέση και την πρόβλεψη του επόμενου token. Το τελευταίο από αυτά αποτελεί τη γλωσσική μοντελοποίηση. Το πρώτο αφορά την ενσωμάτωση λέξεων.

Οι ενσωματώσεις λέξεων έχουν καθοριστική σημασία για την επίλυση πολλών φυσικών γλωσσικών προβλημάτων. Πριν από τις πρόσφατες επιτυχίες της πλήρους μεταφοράς μάθησης στη γλώσσα, αυτό το απλό αυτο-εποπτευόμενο παράδειγμα ήταν εκεί όπου συγκεντρώθηκε η επαναχρησιμοποίηση της γνώσης και αποτέλεσε ένα πολύ σημαντικό συστατικό οποιουδήποτε συστήματος βαθιάς εκμάθησης φυσικών (διαδοχικών) δεδομένων. Από επιστημονική σκοπιά, η εκμάθηση ενσωματώσεων λέξεων για διαδοχικά δεδομένα έχει τη δυνατότητα να εντοπίσει προηγουμένως άγνωστες ομοιότητες στις περιπτώσεις δεδομένων. Έχει ήδη βρει ενδιαφέρουσες χρήσεις για την αυτόματη ανάλυση επιστημονικών κειμένων, όπως συστήματα αναγνώρισης ονομάτων φαρμάκων, βιοϊατρική αναγνώριση οντοτήτων, εντοπισμό σημαντικών εννοιών στην επιστήμη των υλικών και ακόμη και ανίχνευση αλληλεπιδράσεων χημικών-πρωτεϊνών

Ημι-εποπτευόμενη μάθηση

Ενώ η συλλογή μεγάλων συνόλων δεδομένων με ετικέτα μπορεί να είναι απαγορευτικά δαπανηρή, είναι συχνά δυνατό να συλλεχθεί μικρότερη ποσότητα δεδομένων με ετικέτα. Κατά τη συναρμολόγηση ενός ολοκαίνουργιου συνόλου δεδομένων, μια τυπική κατάσταση είναι η ύπαρξη μικρής ποσότητας δεδομένων με ετικέτα και (μερικές φορές σημαντικά) μεγαλύτερου αριθμού περιπτώσεων δεδομένων χωρίς ετικέτες. Η ημι-εποπτευόμενη μάθηση εξετάζει ακριβώς αυτήν τη ρύθμιση, προτείνοντας τεχνικές που επιτρέπουν την αποτελεσματική μάθηση σε δεδομένα με ετικέτα και δεδομένα χωρίς ετικέτα. Παρακάτω παρουσιάζουμε μερικές από τις δημοφιλείς μεθόδους για ημι-εποπτευόμενη μάθηση.

Αυτοεποπτεία με Ημι-Εποπτευόμενη Μάθηση

Όπως είδαμε και σε προηγούμενη παράγραφο, ένας φυσικός τρόπος χρήσης των δεδομένων χωρίς ετικέτα είναι να χρησιμοποιήσουμε μια εργασία αυτο-εποπτευόμενης πρόφασης (self-supervised pretext task) . Για να το συνδυάσουμε με τα δεδομένα με ετικέτα, μπορούμε να σχεδιάσουμε ένα νευρωνικό δίκτυο που έχει δύο διαφορετικές κεφαλές εξόδων (ακριβώς όπως στην εκμάθηση πολλαπλών εργασιών), με τη μία κεφαλή εξόδου να χρησιμοποιείται για τα δεδομένα με ετικέτα και την άλλη για τον αυτο-εποπτευόμενο στόχο στα δεδομένα χωρίς ετικέτα. Αυτό σημαίνει ότι τα χαρακτηριστικά που μαθαίνει το νευρωνικό δίκτυο μοιράζονται μεταξύ των δεδομένων με και χωρίς ετικέτα, οδηγώντας σε καλύτερες αναπαραστάσεις. Αυτή η απλή προσέγγιση έχει αποδειχθεί πολύ αποτελεσματική

Αυτοεκπαίδευση (Bootstrapping)

Η αυτοεκπαίδευση, μερικές φορές αναφέρεται επίσης ως bootstrapping ή ψευδοετικέτες, είναι μια επαναληπτική μέθοδος όπου ένα βαθύ νευρωνικό δίκτυο αναπτύσσεται για πρώτη φορά με εποπτευόμενο τρόπο στα δεδομένα με ετικέτα. Αυτό το νευρωνικό δίκτυο χρησιμοποιείται στη συνέχεια για την παροχή (ψευδο) ετικετών στα δεδομένα χωρίς ετικέτα, τα οποία στη συνέχεια μπορούν να χρησιμοποιηθούν σε συνδυασμό με τα δεδομένα με ετικέτα για να εκπαιδεύσουν ένα νέο, πιο ακριβές νευρωνικό δίκτυο. Αυτή η προσέγγιση συχνά λειτουργεί καλά και μπορεί ακόμη και να επαναληφθεί για περαιτέρω βελτιώσεις. Υπάρχουν μερικές κοινές λεπτομέρειες στην εφαρμογή-συχνά κατά την προσθήκη δεδομένων με ψευδοετικέτες νευρωνικού δικτύου, διατηρούμε μόνο τα πιο σίγουρα παραδείγματα με ψευδοετικέτα. Αυτά τα ψευδο-ετικετικοποιημένα παραδείγματα μπορούν επίσης να χρησιμοποιηθούν για εκπαίδευση με διαφορετική αντικειμενική λειτουργία σε σύγκριση με τα δεδομένα με ετικέτα.

Επιβολή συνέπειας (ομαλότητα)

Ένα σημαντικό θέμα σε πολλές μεθόδους ημι-εποπτείας είναι η παροχή εποπτείας στα δεδομένα χωρίς ετικέτα μέσω της επιβολής της συνέπειας. Εάν δώσουμε σε έναν άνθρωπο δύο εικόνες A και B, όπου το B είναι μια ελαφρώς τροποποιημένη έκδοση του A (ίσως θολή, ίσως κάποια εικονοστοιχεία να είναι πιο σκοτεινά ή ακόμη σβησμένα), τότε θα έδινε σε αυτές τις εικόνες την ίδια ετικέτα - συνέπεια. Μπορούμε επίσης να εφαρμόσουμε αυτήν την αρχή για να παρέχουμε ανατροφοδότηση στο νευρωνικό μας δίκτυο για τα δεδομένα χωρίς ετικέτα, συνδυάζοντάς τα με τις προβλέψεις δεδομένων με ετικέτα, όπως στην εκμάθηση πολλαπλών εργασιών, για να σχηματίσουμε έναν ημι-εποπτευόμενο αλγόριθμο μάθησης. Μια δημοφιλής μέθοδος για την επιβολή της συνέπειας είναι η εικονική εχθρική εκπαίδευση, η οποία επιβάλλει τη συνέπεια σε προσεκτικά επιλεγμένες διαταραχές/τροποποιήσεις εικόνας.

Συνεκπαίδευση


Ένας άλλος τρόπος για την παροχή feedback για δεδομένα χωρίς ετικέτα είναι η εκπαίδευση δύο (ή πολλών) μοντέλων νευρωνικών δικτύων, το καθένα με διαφορετική άποψη των ακατέργαστων/ωμών δεδομένων. Για παράδειγμα, με δεδομένα κειμένου, κάθε μοντέλο μπορεί να δει ένα διαφορετικό μέρος της πρότασης εισαγωγής. Αυτά τα μοντέλα μπορούν στη συνέχεια να λάβουν ανατροφοδότηση(feedback) ώστε να είναι στο μέγιστο δυνατό συνεπή μεταξύ τους, ή με ένα διαφορετικό μοντέλο που βλέπει όλα τα δεδομένα, ή ακόμη και να χρησιμοποιηθεί για αυτοεκπαίδευση, με κάθε διαφορετικό μοντέλο να παρέχει ψευδοετικέτες στις περιπτώσεις στις οποίες είναι πιο σίγουρο.

ΚΕΦΑΛΑΙΟ 8 Σύγκριση μεθόδων

8.1 Ταξινόμηση – Πρόβλημα ανίχνευσης ορίων

Σε αυτό το κεφάλαιο θα εξετάσουμε τις ομοιότητες και τις διαφορές των αλγορίθμων μηχανικής μάθησης που αναλύσαμε σε προηγούμενα κεφάλαια.


Το πρόβλημα της ταξινόμησης, όπως εξηγήσαμε σε προηγούμενα κεφάλαια συνίσταται στην εκμάθηση μιας συνάρτησης της μορφής $y = f(x)$, όπου το x είναι ένα διάνυσμα χαρακτηριστικών και το y είναι ένα διάνυσμα που αντιστοιχεί στις κλάσεις που σχετίζονται με τις παρατηρήσεις. Αυτή η εικόνα αντιπροσωπεύει ταξινόμηση σε γραφική μορφή:



Εικόνα 8.1 Το πρόβλημα της ταξινόμησης

Τα SVM και τα Νευρωνικά Δίκτυα μπορούν και τα δύο εξίσου να εκτελέσουν αυτήν την εργασία, με κατάλληλη επιλογή πυρήνα, στην περίπτωση του SVM, ή συνάρτησης ενεργοποίησης, στην περίπτωση των Νευρωνικών Δικτύων. Η διαφορά, επομένως, δεν έγκειται στους τύπους εργασιών που εκτελούν, αλλά μάλλον σε άλλα χαρακτηριστικά των θεωρητικών τους βάσεων και της εφαρμογής τους, όπως θα δούμε σύντομα.

Και οι δύο μπορούν επίσης, το οποίο είναι εξίσου σημαντικό, να προσεγγίσουν γραμμικές και μη γραμμικές συναρτήσεις :



Εικόνα 8.2 Γραμμικά και μη γραμμικά μοντέλα

Αυτό σημαίνει ότι και οι δύο αλγόριθμοι μπορούν να αντιμετωπίσουν εξίσου όλους τους τύπους προβλημάτων ταξινόμησης. Ως εκ τούτου, η απόφαση να χρησιμοποιήσετε το ένα έναντι του άλλου δεν εξαρτάται από το ίδιο το πρόβλημα.

Μια τελευταία σημείωση: τόσο τα SVM όσο και τα Νευρωνικά Δίκτυα που συζητάμε εδώ αναφέρονται αποκλειστικά στις παραλλαγές τους για ταξινόμηση. Ωστόσο, αυτές δεν είναι οι μόνες πιθανές μορφές SVM ή Νευρωνικών Δικτύων.

(8.α) Προσέγγιση του ορίου απόφασης με Νευρωνικό Δίκτυο

Το καθολικό θεώρημα προσέγγισης μας λέει ότι ένα νευρωνικό δίκτυο με ένα μόνο κρυφό στρώμα και μια μη γραμμική ενεργοποίηση μπορεί να προσεγγίσει, με κατάλληλη επιλογή βαρών, οποιαδήποτε συνεχή συνάρτηση.

Εάν το όριο απόφασης ενός προβλήματος ταξινόμησης μπορεί να οριστεί ως μια συνεχής συνάρτηση, κάτι που συμβαίνει πάντα, τότε μπορεί επίσης να οριστεί ως μια συνεχής αντιστοίχιση του χώρου χαρακτηριστικών. Αυτό, με τη σειρά του, σημαίνει ότι το καθολικό θεώρημα προσέγγισης εγγυάται ότι μπορεί να προσεγγιστεί με ένα NN.

(8.β) Προσέγγιση του ορίου απόφασης με SVMs

Όσον αφορά τα SVM, ωστόσο, το επιχείρημα είναι λίγο διαφορετικό. Οι μηχανές διανυσμάτων υποστήριξης λειτουργούν εντοπίζοντας το υπερεπίπεδο που αντιστοιχεί στους καλύτερους δυνατούς διαχωρισμούς μεταξύ των πλησιέστερων παρατηρήσεων που ανήκουν σε διαφορετικές κλάσεις.

Αυτές οι παρατηρήσεις παίρνουν το όνομα «διανύσματα υποστήριξης». Είναι, για ένα σωστά αποκαλούμενο SVM, ένα μικρό υποσύνολο του συνόλου των δεδομένων εκπαίδευσης. Το SVM μαθαίνει το υπερεπίπεδο που διαχωρίζει καλύτερα αυτά τα διανύσματα υποστήριξης, μέσω της μεγιστοποίησης της απόστασης μεταξύ αυτών των διανυσμάτων και του εαυτού του.

Εάν το υπερεπίπεδο ή το όριο απόφασης δεν υπάρχει στον αρχικό χώρο χαρακτηριστικών, τότε το SVM μπορεί να προβάλει αυτόν τον χώρο σε έναν νέο διανυσματικό χώρο με υψηλότερη διάσταση. Το επίπεδο διαχωρισμού αναζητείται στη συνέχεια στον νέο, υψηλότερης διάστασης διανυσματικό χώρο.

Στο διανυσματικό χώρο όπου τελικά το SVM βρίσκει ένα όριο απόφασης, αυτό το όριο απόφασης είναι μια συνεχής περιοχή αυτού του διανυσματικού χώρου. Πιο συγκεκριμένα, είναι ένα υπερεπίπεδο αυτού του χώρου. Όταν προβάλλεται στον αρχικό χώρο χαρακτηριστικών, το υπερεπίπεδο απόφασης στη συνέχεια καθορίζει μία ή περισσότερες συνεχείς περιοχές του χώρου χαρακτηριστικών.

Ο λόγος για τον οποίο θα βρίσκεται πάντα η λύση σε ένα πρόβλημα ταξινόμησης είναι ότι, όπως συζητείται εδώ, τα SVM δεν περιορίζονται στον χώρο χαρακτηριστικών στον οποίο ορίζεται η είσοδος. Αντίθετα, μπορούν να αυξήσουν τη διάσταση του προβλήματος μέχρι ένα χώρο στον οποίο υπάρχει λύση. Αυτό σημαίνει, συγκεκριμένα, ότι μπορούν να χρησιμοποιήσουν όσες παραμέτρους χρειάζονται έως ότου το μέγεθος του SVM επιτρέψει την εύρεση λύσης.

Το μειονέκτημα των μηχανών διανυσμάτων υποστήριξης είναι ότι το αποτέλεσμα της ταξινόμησης είναι καθαρά διχοτομικό και δεν δίνεται πιθανότητα συμμετοχής στην τάξη.

8.2 Οι δύο αλγόριθμοι

8.2.α SVM για ταξινόμηση

Ένα SVM ανήκει σε έναν από τους δύο τύπους και ο καθένας από αυτούς συμπεριφέρεται διαφορετικά. Αυτοί οι δύο τύποι είναι τα γραμμικά και τα μη γραμμικά SVM.

Το γραμμικό SVM είναι το πιο απλό και ακολουθεί έναν απλό κανόνα. Κάθε φορά που ένα εσωτερικό γινόμενο υπολογίζεται μεταξύ δύο χαρακτηριστικών της εισόδου του, αυτό το γινόμενο ισούται με τον γραμμικό συνδυασμό της εισόδου του:

$$f(ax_n, bx_m) = f(ax_n) + f(bx_m)$$

Το μη γραμμικό SVM είναι, αντίθετα, ένα SVM για το οποίο αυτός ο κανόνας δεν ισχύει. Κατά τον υπολογισμό της εξόδου του εσωτερικού γινόμενου μεταξύ δύο χαρακτηριστικών της εισόδου, το μη γραμμικό SVM χρησιμοποιεί έναν πυρήνα.

Η λέξη πυρήνας, στη μηχανική μάθηση, έχει διαφορετική σημασία από αυτή των πυρήνων για λειτουργικά συστήματα. Στην τεχνητή νοημοσύνη, ένας πυρήνας αντιστοιχεί σε μια μέθοδο για τη μείωση της διάστασης της εισόδου σε έναν ταξινομητή.

Ο πυρήνας είναι, επομένως, η συνάρτηση που χρησιμοποιείται στη θέση ενός εσωτερικού γινόμενου μεταξύ δύο διανυσμάτων, όποτε χρειάζεται να υπολογιστεί ένα. Παραδείγματα πυρήνων περιλαμβάνουν τον πολυωνυμικό πυρήνα, την υπερβολική επαπτομένη και τον εκθετικό πυρήνα.

Αυτό σημαίνει ότι ένα SVM μπορεί να μάθει συναρτήσεις απόφασης που έχουν το σχήμα, σε κάποιο χώρο υψηλής διαστάσεων, του πυρήνα που χρησιμοποιεί.

8.2.β Νευρωνικά Δίκτυα για ταξινόμηση

Τα νευρωνικά δίκτυα έχουν διαφορετικό τρόπο λειτουργίας και, ειδικότερα, δεν απαιτούν πυρήνες. Αυτό, φυσικά, με εξαίρεση τα συνελκτικά νευρωνικά δίκτυα.

Ένα νευρωνικό δίκτυο για ταξινόμηση, σε αυτό το πλαίσιο, αντιστοιχεί σε ένα ΝΔ με ένα μόνο κρυφό στρώμα και μια μη γραμμική συνάρτηση ενεργοποίησης. Οι πιο συνηθισμένοι τύποι μη γραμμικών συναρτήσεων ενεργοποίησης για NN για ταξινόμηση είναι: α) λογιστική συνάρτηση, β) υπερβολική επαπτομένη, γ) softmax,

Όλες αυτές οι συναρτήσεις λαμβάνουν ως είσοδο έναν γραμμικό συνδυασμό ενός διανύσματος χαρακτηριστικών x και ενός διανύσματος βάρους w . Στη συνέχεια επιστρέφουν μια έξοδο που περιλαμβάνεται σε κάποιο πεπερασμένο διάστημα, συνήθως $(0,1)$ ή $(-1,1)$.

Όπως αναφέρθηκε προηγουμένως, ένα νευρωνικό δίκτυο με ένα μόνο κρυφό στρώμα και μια μη γραμμική συνάρτηση ενεργοποίησης μπορεί να προσεγγίσει οποιαδήποτε δεδομένη συνεχή συνάρτηση. Εάν το όριο απόφασης δεν είναι συνεχές στον αρχικό χώρο χαρακτηριστικών, η προσθήκη περαιτέρω επιπέδων στο NN μπορεί να αυξήσει τη διάστασή του, μέχρι ένα σημείο στο οποίο βρίσκεται. Ένα βαθύ νευρωνικό δίκτυο μπορεί, επομένως, να προσεγγίσει όλα τα όρια απόφασης που αποτελούνται από πολλαπλές συνεχείς περιοχές.

Το πρόβλημα, ωστόσο, είναι ότι το καθολικό θεώρημα προσέγγισης δεν περιλαμβάνει καμία εγγύηση για τη δυνατότητα εκμάθησης μιας συνάρτησης απόφασης. Αυτό σημαίνει ότι, για μια δεδομένη αρχική τυχαία διαμόρφωση των βαρών του δικτύου, το NN μπορεί να μην μάθει ποτέ τη συνάρτηση απόφασης μέσω gradient descent. Τα SVM, από την άλλη πλευρά, εγγυώνται πάντα τη σύγκλιση.

8.3 Ομοιότητες

1) Και τα SVMs και τα Νευρωνικά δίκτυα είναι παραμετρικά :

Η πρώτη ομοιότητα αφορά το γεγονός ότι και οι δύο αλγόριθμοι είναι παραμετρικοί, αν και για διαφορετικούς λόγους. Στην περίπτωση του SVM, οι τυπικές παράμετροι είναι: A) η λεγόμενη παράμετρος soft-margin, που συνήθως υποδεικνύεται με C

B) και η παράμετρος της συνάρτησης πυρήνα που συνήθως ονομάζεται γ

Τα νευρωνικά δίκτυα χρησιμοποιούν επίσης παραμέτρους, αν και απαιτούν πολύ περισσότερες από αυτές. Οι πιο σημαντικές παράμετροι αφορούν τον αριθμό των επιπέδων και το μέγεθός τους, αλλά και τον αριθμό των εποχών εκπαίδευσης και τον ρυθμό εκμάθησης.

Υπό αυτή την έννοια, τα δύο μοντέλα είναι παρόμοια στο βαθμό που είναι και τα δύο παραμετρικά, αλλά ανόμοια ως προς τον τύπο και τον αριθμό των παραμέτρων που απαιτούν.

2) Και οι δύο αλγόριθμοι μπορούν να υποστηρίξουν τη μη γραμμικότητα

Και οι δύο αλγόριθμοι μηχανικής μάθησης ενσωματώνουν τη μη γραμμικότητα. Αυτό γίνεται, στην περίπτωση των SVM, μέσω της χρήσης μιας μεθόδου πυρήνα. Τα νευρωνικά δίκτυα, αντίθετα, ενσωματώνουν τη μη γραμμικότητα χρησιμοποιώντας μη γραμμικές συναρτήσεις ενεργοποίησης. Και οι δύο κατηγορίες αλγορίθμων μπορούν, επομένως, να προσεγγίσουν τις μη γραμμικές συναρτήσεις απόφασης, αν και με διαφορετικές προσεγγίσεις. Ειδικότερα, ο λόγος για την ανάπτυξη των νευρωνικών δικτύων είναι ακριβώς η ανάγκη να ξεπεραστεί το πρόβλημα της ταξινόμησης των μη γραμμικά διαχωρίσιμων παρατηρήσεων. Αυτό σημαίνει ότι η μη γραμμικότητα είναι ο θεμελιώδης λόγος ύπαρξής τους και ότι το γραμμικό τους ισοδύναμο, όπως τα συνελκτικά νευρωνικά δίκτυα που χρησιμοποιούν ReLU, αναπτύχθηκαν μόνο αργότερα.

3) Και οι δύο ταξινομούνται με συγκρίσιμη ακρίβεια

Τόσο τα SVM όσο και τα ΝΔ μπορούν να αντιμετωπίσουν το ίδιο πρόβλημα ταξινόμησης σε σχέση με το ίδιο σύνολο δεδομένων. Αυτό σημαίνει ότι δεν υπάρχει κανένας λόγος που να προέρχεται από τα χαρακτηριστικά του προβλήματος για την προτίμηση του ενός έναντι του άλλου.

Αυτό που είναι πιο σημαντικό, ωστόσο, είναι ότι και τα δύο αποδίδουν με συγκρίσιμη ακρίβεια σε σχέση με το ίδιο σύνολο δεδομένων, εάν τους δοθεί συγκρίσιμη εκπαίδευση. Ωστόσο, εάν δοθεί όσο το δυνατόν περισσότερη εκπαίδευση και υπολογιστική ισχύς, τα ΝΔ τείνουν να υπερτερούν των SVM.

Όπως θα δούμε στην επόμενη ενότητα, ωστόσο, ο χρόνος που απαιτείται για την εκπαίδευση των δύο αλγορίθμων είναι πολύ διαφορετικός για το ίδιο σύνολο δεδομένων.

8.4 Διαφορές

1) Η δομή

Η πρώτη διαφορά αφορά την υποκείμενη δομή των δύο αλγορίθμων. Ένα SVM διαθέτει έναν αριθμό παραμέτρων που αυξάνονται γραμμικά με τη γραμμική αύξηση του μεγέθους της εισόδου. Ένα ΝΔ, από την άλλη πλευρά, δεν το κάνει.

Παρόλο που εδώ επικεντρωθήκαμε ειδικά σε δίκτυα ενός επιπέδου, ένα νευρωνικό δίκτυο μπορεί να έχει όσα επίπεδα θέλουμε. Αυτό, με τη σειρά του, σημαίνει ότι ένα βαθύ νευρωνικό δίκτυο με τον ίδιο αριθμό παραμέτρων με ένα SVM έχει πάντα μεγαλύτερη πολυπλοκότητα από το τελευταίο.

Αυτό οφείλεται στην πιο σύνθετη αλληλεπίδραση μεταξύ των παραμέτρων του μοντέλου. Στα ΝΔ, αυτό περιορίζεται σε εκείνα που ανήκουν σε γειτονικά επίπεδα. Αντίθετα, ένα SVM έχει παραμέτρους που όλες αλληλεπιδρούν μεταξύ τους.

2) Ποσότητα Απαιτούμενων Δεδομένων Εκπαίδευσης

Η δεύτερη διαφορά αφορά τον όγκο των πληροφοριών που απαιτούνται για την εκπαίδευση του αλγόριθμου.

Οι μηχανές διανυσμάτων υποστήριξης χρησιμοποιούν αποτελεσματικά μόνο ένα υποσύνολο ενός συνόλου δεδομένων ως δεδομένα εκπαίδευσης. Αυτό συμβαίνει επειδή προσδιορίζουν αξιόπιστα το όριο απόφασης με βάση τα μοναδικά διανύσματα υποστήριξης. Κατά συνέπεια, για καλά διαχωρισμένες τάξεις, ο αριθμός των παρατηρήσεων που απαιτούνται για την εκπαίδευση ενός SVM δεν είναι υψηλός.

Όσον αφορά τα νευρωνικά δίκτυα, αντίθετα, η εκπαίδευση πραγματοποιείται με βάση τις παρτίδες δεδομένων που τροφοδοτούνται σε αυτό. Αυτό σημαίνει ότι το

συγκεκριμένο όριο απόφασης που μαθαίνει το νευρωνικό δίκτυο εξαρτάται σε μεγάλο βαθμό από τη σειρά με την οποία παρουσιάζονται σε αυτό οι παρτίδες δεδομένων. Αυτό, με τη σειρά του, απαιτεί την επεξεργασία του συνόλου των δεδομένων εκπαίδευσης. Διαφορετικά, το δίκτυο μπορεί να έχει εξαιρετικά κακή απόδοση.

3) Η εκπαίδευση

Μια άλλη διαφορά σχετίζεται με τον χρόνο που απαιτείται για την εκπαίδευση του αλγόριθμου. Τα SVM είναι γενικά πολύ γρήγορα στην εκπαίδευση, κάτι που είναι συνέπεια του σημείου που αναφέραμε στην προηγούμενη ενότητα. Το ίδιο όμως δεν ισχύει για τα νευρωνικά δίκτυα.

Όπως συζητήσαμε σε προηγούμενα κεφάλαια, ορισμένα ιδιαίτερα μεγάλα ΝΔ απαιτούν στην πραγματικότητα αρκετές ημέρες, μερικές φορές και εβδομάδες, για να εκπαιδευτούν. Αυτό σημαίνει ότι η επανεκκίνηση της εκπαίδευσης και η προετοιμασία των τυχαιών βαρών με διαφορετικό τρόπο, για παράδειγμα, είναι δυνατή για τα SVM αλλά πολύ ακριβά για τα ΝΔ.

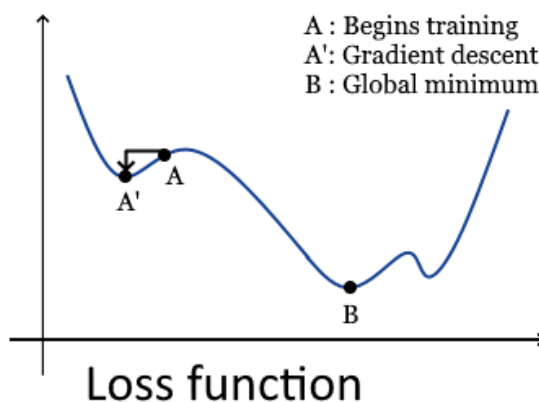
4) Βελτιστοποίηση των Παραμέτρων

Μια άλλη διαφορά αφορά τον αλγόριθμο που χρησιμοποιούν τα νευρωνικά δίκτυα και τα SVM για να βελτιστοποιήσουν τις παραμέτρους τους. Συνήθως, η βελτιστοποίηση για νευρωνικά δίκτυα πραγματοποιείται μέσω gradient descent, καθώς αυτή είναι η πιο κοινή τεχνική. Η χρήση του gradient descent είναι ωστόσο επίσης ένας από τους λόγους για τους οποίους τα νευρωνικά δίκτυα μερικές φορές δεν μπορούν να μάθουν μια συνάρτηση εάν η αρχική τους διαμόρφωση τα τοποθετεί στο τοπικό ελάχιστο μιας συνάρτησης.

Το SVM χρησιμοποιεί, αντί αυτού, τη μέθοδο που ονομάζεται τετραγωνικός προγραμματισμός. Ο τετραγωνικός προγραμματισμός αποτελείται από τη βελτιστοποίηση μιας συνάρτησης σύμφωνα με γραμμικούς περιορισμούς στις μεταβλητές της. Ο τετραγωνικός προγραμματισμός για SVM λύνεται στην πράξη με διαδοχική ελάχιστη βελτιστοποίηση, η οποία επιτρέπει τον εντοπισμό μιας πιθανής λύσης με επαναληπτικό υπολογισμό της αναλυτικής λύσης σε ένα υποσύνολο του προβλήματος.

5) Ευαισθησία στην αρχική τυχαιοποίηση των βαρών

Η τελευταία διαφορά αφορά μια συνέπεια της διαφορετικής χρήσης των τεχνικών βελτιστοποίησης. Επειδή τα ΝΔ χρησιμοποιούν gradient descent, αυτό τα καθιστά ευαίσθητα στην αρχική τυχαιοποίηση του πίνακα βάρους του. Αυτό συμβαίνει επειδή, εάν η αρχική τυχαιοποίηση τοποθετεί το νευρωνικό δίκτυο κοντά σε ένα τοπικό ελάχιστο της συνάρτησης βελτιστοποίησης, η ακρίβεια δεν θα αυξηθεί ποτέ πέρα από ένα συγκεκριμένο όριο:



Σχήμα 8.3 Ευαισθησία στην τυχαιοποίηση των βαρών

Αντίθετα, τα SVM είναι πιο αξιόπιστα και εγγυώνται τη σύγκλιση στο παγκόσμιο ελάχιστο, ανεξάρτητα από την αρχική τους διαμόρφωση.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Άγγελος Πικράκης - Εισαγωγή στην Αναγνώριση προτύπων με Matlab
- [2] Κωνσταντίνος Διαμαντάρας , Δημήτρης Μπότσης - Μηχανική Μάθηση
- [3] Σ, Θεοδωρίδης, Κ. Κουτρούμπας - Αναγνώριση προτύπων
- [4] Vladimir Vapnik, · Rauf Izmailov - Knowledge transfer in SVM and neural networks
<https://link.springer.com/article/10.1007/s10472-017-9538-x>
- [5] Stanislaw Osowski, Krzysztof Siwek, Tomasz Markiewicz - MLP and SVM Networks – a Comparative Study
https://www.researchgate.net/profile/Krzysztof_Siwek2/publication/4095905_MLP_and_SVM_networks_-_a_comparative_study/links/0f31753a58e1a37d71000000/MLP-and-SVM-networks-a-comparative-study.pdf
- [6] Milecia McGregor - SVM Machine Learning Tutorial - What is the Support Vector Machine Algorithm, Explained with Code Examples
<https://www.freecodecamp.org/news/svm-machine-learning-tutorial-what-is-the-support-vector-machine-algorithm-explained-with-code-examples/>
- [7] Jair Cervantes, Farid Garcia-Lamont, Lisbeth Rodriguez-Mazahua, Asdrubal Lopez - A comprehensive survey on support vector machine classification : Applications, challenges and trends
https://www.sciencedirect.com/science/article/pii/S0925231220307153?casa_token=bQwT3k2HkaMAAAAAA:q_Y31Zl8H_7BdbyLRDdfjnT-CIKTTNnh9kq0KBDKznRLsn4l8oGKcXSCqhz_x1A0DIGKUcD_0ml
- [8] Savan Patel - Chapter 2: SVM (Support Vector Machine) - Theory
<https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>
- [9] Rohith Gandhi - Support Vector Machine — Introduction to Machine Learning Algorithms
<https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
- [10] Ashis Pradhan - SUPPORT VECTOR MACHINE-A Survey
<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.437.1036&rep=rep1&type=pdf>
- [11] Dr. Subarna Shakya - Performance Analysis of Wind Turbine Monitoring Mechanism Using Integrated Classification and Optimization Techniques
<https://irojournals.com/aicn/V2/I1/04.pdf>
- [12] Βλαχάβας Ιωάννης, Κεφαλας Πέτρος, Βασιλειάδης Νικόλαος, Κόκκορας Φώτης, Σακελλαρίου Ηλίας - Τεχνητή Νοημοσύνη
- [13] Ms. Sonali. B. Maind, ,Ms. Priyanka Wankar - Research Paper on Basic of Artificial Neural Network
<https://ijritcc.org/index.php/ijritcc/article/view/2920/2920>
- [14] Diego AAlvarez, Jorge EHurtado - Neural-network-based reliability analysis: a comparative study
https://www.sciencedirect.com/science/article/abs/pii/S0045782501002481?casa_token=4Y4FSnTpWTAaaaaa:5uwqc5fDW576KM4qVa1g39y6Ue4aVtwFMJ1ZW9Y-Cgk1r-r1Zug8A7msdlpw3Bc2ApSpyGG5Nfw

[15] ΖΩΡΗΣ ΝΙΚΟΛΑΟΣ ΚΑΙ ΚΑΤΣΙΝΟΥΛΑΣ ΝΙΚΟΛΑΟΣ - ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ ΑΥΤΩΝ

[16] David Reby a, Sovan Lek b , Ioannis Dimopoulos c , Jean Joachim a, Jacques Lauga c, Stéphane Aulagnier a - Artificial neural networks as a classification method in the behavioural science
https://www.sciencedirect.com/science/article/abs/pii/S0376635796007668?casa_token=CDiCnHf2Ug4AAAAA:LIPjEgtQRf2xSqE4bKGYFnO5atkGd3f8BWPWzCUIVO0kfPwmH3wft4uh9W46BsdzIAcqoL6zug

[17] Oliver Knocklein - Classification Using Neural Networks
<https://towardsdatascience.com/classification-using-neural-networks-b8e98f3a904f>

[18] Peter G. Zhang - Neural Networks for Classification: A Survey
https://www.researchgate.net/publication/3421357_Neural_Networks_for_Classification_A_Survey

[19] Raphaël Feraud , Fabrice Clerot - A methodology to explain neural network classification
https://www.researchgate.net/publication/11348549_A_methodology_to_explain_neural_network_classification

[20] Rajni Bala, Dr. Dharmender Kumar - Classification Using ANN: A Review
https://www.ripublication.com/ijcir17/ijcirv13n7_22.pdf

[21] B. D.Ripley - Neural Networks and Related Methods for Classification
<https://rss.onlinelibrary.wiley.com/doi/epdf/10.1111/j.2517-6161.1994.tb01990.x>

[22] Saravanan K, S. Sasithra -REVIEW ON CLASSIFICATION BASED ON ARTIFICIAL NEURAL NETWORKS <https://airccse.org/journal/ijasa/papers/2414asa02.pdf>

[23] Alfredo Canziani, Eugenio Culurciello , Adam Paszke - AN ANALYSIS OF DEEP NEURAL NETWORK MODELS FOR PRACTICAL APPLICATIONS
<https://arxiv.org/pdf/1605.07678.pdf>

[24] Grégoire Montavon , Wojciech Samek, Klaus-Robert Müller - Methods for interpreting and understanding deep neural networks
<https://www.sciencedirect.com/science/article/pii/S1051200417302385>

[25] Weibo Liua , Zidong Wang a.* , Xiaohui Liua , Nianyin Zeng b , Yurong Liuc,d and Fuad E. Alsaadid - A Survey of Deep Neural Network Architectures and Their Applications
<https://bura.brunel.ac.uk/bitstream/2438/14221/1/FullText.pdf>

[26] Heba Mohsen, El-Sayed A.El-Dahshan, El-Sayed M.El-Horbaty, Abdel-Badeeh M.Salem - Classification using deep learning neural networks for brain tumors
<https://www.sciencedirect.com/science/article/pii/S2314728817300636>

[27] Weibo Liu, Zidong Wang, Xiaohui Liu, Nianyin Zeng, Yurong Liu, Fuad E.Alsaadi - A survey of deep neural network architectures and their applications
https://www.sciencedirect.com/science/article/abs/pii/S0925231216315533?casa_token=n-wKgfO4ghoAAAAA:Fr8yAFMXz4YgFKwM7vI6waRcW-8zHkMkfAgA3kqfWsnSkup28UbgcAwQ8BDilxRwYrK_BZhyg

[28] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton - ImageNet Classification with Deep Convolutional Neural

Networks <https://papers.nips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>

[29] Gabrielle De Luca - SVM Vs Neural Network <https://www.baeldung.com/cs/svm-vs-neural-network>

[30] Bernard Marr - Deep Learning Vs Neural Networks - What's The Difference? <https://bernardmarr.com/deep-learning-vs-neural-networks-whats-the-difference/>

[31] Upasana Priyadarshiny - Introduction to Classification Algorithms <https://dzone.com/articles/introduction-to-classification-algorithms>

[32] Rachel Wolff - 5 Types of Classification Algorithms in Machine Learning <https://monkeylearn.com/blog/classification-algorithms/>

[33] T. Evgeniou - Classification Methods <https://inseaddataanalytics.github.io/INSEADAnalytics/CourseSessions/Sessions67/ClassificationAnalysisReading.html>

[34] Sebastian Raschka - When Does Deep Learning Work Better Than SVMs or Random Forests? <https://www.kdnuggets.com/2016/04/deep-learning-vs-svm-random-forest.html>

[35] Manikandan Jeeva - The Scuffle Between Two Algorithms -Neural Network vs. Support Vector Machine <https://medium.com/analytics-vidhya/the-scuffle-between-two-algorithms-neural-network-vs-support-vector-machine-16abe0eb4181>

[36] Milecia McGregor - SVM Machine Learning Tutorial – What is the Support Vector Machine Algorithm, Explained with Code Examples <https://www.freecodecamp.org/news/svm-machine-learning-tutorial-what-is-the-support-vector-machine-algorithm-explained-with-code-examples/>

[37] Nick McCullum - Deep Learning Neural Networks Explained in Plain English <https://www.freecodecamp.org/news/deep-learning-neural-networks-explained-in-plain-english/>

[38] Sanjula Jayawardana - Activation Functions in Neural Networks <https://medium.com/analytics-vidhya/activation-functions-in-neural-networks-d0d0ab8eaa4b>

[39] Gabriele De Luca - Support Vector Machines (SVM) <https://www.baeldung.com/cs/ml-support-vector-machines>

[40] Gabriele De Luca - Advantages and Disadvantages of Neural Networks Against SVMs <https://www.baeldung.com/cs/ml-ann-vs-svm>

[41] Baeldung - Advantages and Disadvantages of Neural Networks <https://www.baeldung.com/cs/neural-net-advantages-disadvantages>

[42] Baeldung - What is the Difference Between Labeled and Unlabeled Data <https://www.baeldung.com/cs/ml-labeled-vs-unlabeled-data>

[43] Baeldung - Multiclass Classification Using Support Vector Machines <https://www.baeldung.com/cs/svm-multiclass-classification>

[44] Orkun Susuz, Selcuk Bayraci - DEEP NEURAL NETWORK (DNN) BASED CLASSIFICATION MODEL IN APPLICATION TO LOAN DEFAULT PREDICTION https://www.researchgate.net/publication/330467622_DEEP_NEURAL_NETWORK_DNN_B

ASED CLASSIFICATION MODEL IN APPLICATION TO LOAN DEFAULT PREDICTION

[45] Xingyi Song, Johann Petrak , Angus Roberts - A Deep Neural Network Sentence Level Classification Method with Context Information <https://aclanthology.org/D18-1107.pdf>

[46] Michael Nielsen - Neural Networks and Deep Learning
https://www.academia.edu/42751314/Neural_Networks_and_Deep_Learning

[47] Simplilearn - Classification in Machine Learning: What it is and Classification Models
<https://www.simplilearn.com/tutorials/machine-learning-tutorial/classification-in-machine-learning>

[48] Dr. Abul Bashar - SURVEY ON EVOLVING DEEP LEARNING NEURAL NETWORK ARCHITECTURES <https://www.ijournals.com/aicn/V1/I2/03.pdf>

[49] Dr. T. Vijayakumar - CLASSIFICATION OF BRAIN CANCER TYPE USING MACHINE LEARNING <https://www.ijournals.com/aicn/V1/I2/06.pdf>

[50] Robert Keim - How to Perform Classification Using a Neural Network: What Is the Perceptron? <https://www.allaboutcircuits.com/technical-articles/how-to-perform-classification-using-a-neural-network-introducing-the-perceptron/>

[51] Jason Brownlee - How Do Convolutional Layers Work in Deep Learning Neural Networks? <https://machinelearningmastery.com/convolutional-layers-for-deep-learning-neural-networks/>

[52] Dr. Subarna Shakya - Analysis of Artificial Intelligence based Image Classification Techniques <https://www.ijournals.com/iroiip/V2/I1/05.pdf>

[53] Dr. Samuel Manoharan - IMAGE DETECTION, CLASSIFICATION AND RECOGNITION FOR LEAK DETECTION IN AUTOMOBILES <https://www.ijournals.com/iroiip/V1/I2/01.pdf>

[54] Dr. Rajesh Sharma, Dr. Akey Sungheetha - An Efficient Dimension Reduction based Fusion of CNN and SVM Model for Detection of Abnormal Incident in Video Surveillance <https://ijournals.com/jscp/V3/I2/01.pdf>

[55] Dr. P. Karuppusamy - Analysis of Neural Network Based Language Modeling
<https://www.ijournals.com/aicn/V2/I1/06.pdf>

[56] Dinesh Valluru, Jasmine Selva kumari Jeya - DEEP NEURAL NETWORK BASED CLASSIFICATION MODEL FOR FEATURE EXTRACTION
https://ejmcm.com/article_7302_f990c845cd0d1481f3a84458467d44e6.pdf

[57] Bernard Marr - What Is Deep Learning AI? A Simple Guide With 8 Practical Examples
<https://bernardmarr.com/what-is-deep-learning-ai-a-simple-guide-with-8-practical-examples/>

[58] Bernard Marr - What Is Machine Learning – A Complete Beginner’s Guide
<https://bernardmarr.com/what-is-machine-learning-a-complete-beginners-guide/>

[59] Maxwell, A., Li, R., Yang, B. et al. Deep learning architectures for multi-label classification of intelligent health risk prediction. <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-017-1898-z#citeas>

- [60] Javier Marin - Explainable Deep Neural Networks
<https://towardsdatascience.com/explainable-deep-neural-networks-2f40b89d4d6f>
- [61] Yonatan Geifman, Ran El-Yaniv - Selective Classification for Deep Neural Networks
<https://arxiv.org/pdf/1705.08500.pdf>
- [62] Dr. T. Vijayakumar - COMPARATIVE STUDY OF CAPSULE NEURAL NETWORK IN VARIOUS APPLICATIONS <https://www.irojournals.com/aicn/V1/I1/03.pdf>
- [63] GeeksforGeeks - Basic Concept of Classification (Data Mining)
<https://www.geeksforgeeks.org/basic-concept-classification-data-mining/>
- [64] S.B. Kotsiantis - Supervised Machine Learning: A Review Of Classification Techniques
https://books.google.gr/books?hl=el&lr=&id=vLiTXDHR_sYC&oi=fnd&pg=PA3&dq=classification+in+machine+learning&ots=CZnrts-Dmi&sig=A2aQyFXscPRY2xlnBaV_3jVZ7e0&redir_esc=y#v=onepage&q=classification%20in%20machine%20learning&f=false
- [65] Keji Han, Yun Li – Is It Time to Redefine the Classification Task for Deep Neural Networks?
https://www.researchgate.net/publication/344621926_Is_It_Time_to_Redefine_the_Classification_Task_for_Deep_Neural_Networks