



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ
ΣΤΗ ΒΙΟΙΑΤΡΙΚΗ

Ανάπτυξη προγνωστικού μοντέλου με εφαρμογή μεθόδων
επιβλεπόμενης μηχανικής μάθησης σε πολυδιάστατα
ιατρικά δεδομένα

Θεοδώρα Χατζοπούλου

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ
Υπεύθυνος
Βασίλειος Πλαγιανάκος
Καθηγητής

Λαμία, 2023



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ
ΣΤΗ ΒΙΟΙΑΤΡΙΚΗ

Ανάπτυξη προγνωστικού μοντέλου με εφαρμογή μεθόδων
επιβλεπόμενης μηχανικής μάθησης σε πολυδιάστατα
ιατρικά δεδομένα

Θεοδώρα Χατζοπούλου

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ
Υπεύθυνος
Βασίλειος Πλαγιανάκος
Καθηγητής

Λαμία, 2023

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 επεξεργάσθηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραδείματα.
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: /..... /20.....

Ο - Η Δηλ.

(Υπογραφή)

(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.

Ανάπτυξη προγνωστικού μοντέλου με εφαρμογή μεθόδων
επιβλεπόμενης μηχανικής μάθησης σε πολυδιάστατα ιατρικά δεδομένα

Θεοδώρα Χατζοπούλου

Τριμελής Επιτροπή :

Βασίλειος Πλαγιανάκος, Καθηγητής (επιβλέπων)
Αθανάσιος Κακαρούντας, Αναπληρωτής Καθηγητής
Σωτήριος Τασουλής, Επίκουρος Καθηγητής

Περίληψη

Ο καρκίνος του παχέος εντέρου και του πνεύμονα αποτελούν δύο από τις συχνότερες και πιο επικίνδυνες μορφές καρκίνου. Η διάγνωσή τους στα αρχικά στάδια μπορεί να συμβάλει σημαντικά στην έκβαση της θεραπευτικής αντιμετώπισης. Η παρούσα εργασία εστιάστηκε στην ανάπτυξη και σύγκριση πέντε διαφορετικών αρχιτεκτονικών συνελκτικών δικτύων για την αναγνώριση αδενοκαρκινωμάτων του παχέος εντέρου, αδενοκαρκινωμάτων του πνεύμονα και ακανθοκυτταρικών καρκινωμάτων του πνεύμονα σε ιστοπαθολογικές εικόνες. Όλα τα μοντέλα πέτυχαν ακρίβεια υψηλότερη του 97%, ενώ δύο από αυτά πέτυχαν ακρίβεια 99,8%. Τα αποτελέσματα συγκρίθηκαν με εκείνα ενός προεκπαιδευμένου VGG16 δικτύου. Σε όλες τις περιπτώσεις, τα μοντέλα που αναπτύχθηκαν είχαν καλύτερη απόδοση από το μοντέλο VGG.

Λέξεις - Κλειδιά: Καρκίνος Πνεύμονα, Καρκίνος Παχέος Εντέρου, Τεχνητά Νευρωνικά Δίκτυα, Ιστοπαθολογικές Εικόνες, Λήψη Κλινικών Αποφάσεων

Abstract

Colon and lung cancer are two of the most common and dangerous types of cancers. Their diagnosis in early stages can significantly contribute to the outcome of the therapeutic process. This thesis was focused on the development and comparison of five different convolutional neural network architectures for the identification of colon adenocarcinoma, lung adenocarcinoma and lung squamous cell carcinoma in histopathological images. All models achieved an accuracy above 97%, while two of them in particular achieved an accuracy of 99.8%. The results were compared to those of a pretrained VGG16 network. In all cases, models created from scratch outperformed VVG model.

Keywords: Lung Cancer, Colon Cancer, Artificial Neural Networks, Histopathological Images, Clinical Decision Making

Ευχαριστίες

Στο σημείο αυτό, θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή, κ. Βασίλειο Πλαγιανάκο, για την ανάθεση της συγκεκριμένης εργασίας καθώς και για την υποστήριξη και την πολύτιμη καθοδήγησή του.

Περιεχόμενα

1	Εισαγωγή	1
2	Τεχνητή Νοημοσύνη	4
2.1	Περιοχές της Τεχνητής Νοημοσύνης	6
2.2	Τεχνητή Νοημοσύνη στην Ιατρική	8
2.3	Μηχανική Μάθηση	12
2.3.1	Είδη Μηχανικής Μάθησης	12
2.3.2	Ταξινόμηση	15
2.3.3	Παλινδρόμηση	15
2.3.4	Συσταδοποίηση	15
2.3.5	Μείωση Διαστατικότητας	17
3	Τεχνητά Νευρωνικά Δίκτυα	20
3.1	Μοντέλο Τεχνητού Νευρώνα	23
3.2	Συναρτήσεις Ενεργοποίησης	24
3.2.1	Βηματική Συνάρτηση	24
3.2.2	Σιγμοειδής Συνάρτηση	25
3.2.3	Υπερβολική Εφαπτομένη	26
3.2.4	Rectified Linear Unit (ReLU)	27
3.2.5	Softmax	28
3.3	Πολυεπίπεδα Νευρωνικά Δίκτυα	29
3.4	Εκπαίδευση Νευρωνικών Δικτύων	30
3.4.1	Συνάρτηση Απώλειας	30
3.4.2	Αλγόριθμοι Βλετιστοποίησης	31
3.4.3	Αλγόριθμος Οπισθοδιάδοσης Σφάλματος	35
3.4.4	Αποφυγή Υπεπροσαρμογής	35
3.5	Συνελκτικά Νευρωνικά Δίκτυα	38
3.5.1	Επίπεδο Συνέλιξης	39
3.5.2	Επίπεδο Χωρικής Υποδειγματοληψίας	40
3.5.3	Πλήρως Συνδεδεμένο Επίπεδο	41
3.5.4	VGG16	42
4	Πρακτικό Μέρος	44

4.1 Προγραμματιστικά Εργαλεία	44
4.2 Σύνολο Δεδομένων	45
4.3 Προεπεξεργασία Δεδομένων	47
4.4 Εκπαίδευση Μοντέλων	49
4.5 Αποτελέσματα	55
4.6 Συμπεράσματα	63
Βιβλιογραφία	65

Κατάλογος Σχημάτων

3.1 Βιολογικός νευρώνας	20
3.2 Μαθηματικό μοντέλο τεχνητού νευρώνα	23
3.3 Γράφημα σιγμοειδούς συνάρτησης	25
3.4 Γράφημα υπερβολικής εφαπτομένης	26
3.5 Γράφημα ReLU	28
3.6 Πολυεπίπεδο νευρωνικό δίκτυο με δύο κρυφά επίπεδα	30
3.7 Σημείο τερματισμού της εκπαίδευσης	36
3.8 Εφαρμογή διάλειψης	37
3.9 Διαδικασία συνέλιξης με 3x3 φίλτρο	39
3.10 Παράδειγμα εφαρμογής zero padding	40
3.11 Μετακίνηση συνελκτικού φίλτρου με βηματισμό 1	40
3.12 Χωρική Υποδειγματοληψία με μέγιστο και μέσο όρο	41
3.13 Τυπική αρχιτεκτονική συνελκτικού δικτύου	42
3.14 Αρχιτεκτονική VGG16	43
4.1 Τυχαίες εικόνες αδενοκαρκινώματος του παχέος εντέρου	46
4.2 Τυχαίες εικόνες καλοήθους ιστού του παχέος εντέρου	46
4.3 Τυχαίες εικόνες αδενοκαρκινώματος του πνεύμονα	46
4.4 Τυχαίες εικόνες ακανθοκυτταρικού καρκινώματος του πνεύμονα	47
4.5 Τυχαίες εικόνες καλοήθους ιστού του πνεύμονα	47
4.6 Κατανομή Κλάσεων	47
4.7 Παραδείγματα επαύξησης δεδομένων	48
4.8 Αποτελέσματα εφαρμογής της τεχνικής επαύξησης δεδομένων σε τυχαία δείγματα	49
4.9 Αρχιτεκτονική πρώτου δικτύου	50
4.10 Αρχιτεκτονική δεύτερου δικτύου	51
4.11 Αρχιτεκτονική τρίτου δικτύου	52
4.12 Αρχιτεκτονική τέταρτου δικτύου	53
4.13 Αρχιτεκτονική πέμπτου δικτύου	54
4.14 Γραφήματα εκπαίδευσης πρώτου δικτύου	55
4.15 Πίνακας σύγχυσης πρώτου μοντέλου	56
4.16 Γραφήματα εκπαίδευσης δεύτερου δικτύου	57
4.17 Πίνακας σύγχυσης δεύτερου μοντέλου	57

4.18	Γραφήματα εκπαίδευσης πρώτου δικτύου	58
4.19	Πίνακας σύγχυσης τρίτου μοντέλου	58
4.20	Γραφήματα εκπαίδευσης τέταρτου δικτύου	59
4.21	Πίνακας σύγχυσης τέταρτου μοντέλου	59
4.22	Γραφήματα εκπαίδευσης πέμπτου δικτύου	60
4.23	Πίνακας σύγχυσης πέμπτου δικτύου	60
4.24	Γραφήματα εκπαίδευσης VGG16 δικτύου	61
4.25	Πίνακας Σύγχυσης VGG16 δικτύου	62

Κεφάλαιο 1

Εισαγωγή

Ο καρκίνος αναφέρεται σε ένα σύνολο ασθενειών, κοινό χαρακτηριστικό των οποίων είναι ο ανεξέλεγκτος πολλαπλασιασμός κυττάρων, εξαιτίας τυχαίων μεταλλάξεων που διαταράσσουν τους φυσιολογικούς μηχανισμούς ρύθμισης της κυτταρικής ανάπτυξης. Η άκρατη ανάπτυξη των κυττάρων έχει ως αποτέλεσμα το σχηματισμό όγκων, δηλαδή κυτταρικών μαζών, οι οποίοι σε περίπτωση που είναι «κακοήθεις» μπορεί να προκαλέσουν σοβαρή βλάβη στον οργανισμό και να οδηγήσουν ακόμη και στο θάνατο. Οι κακοήθεις όγκοι έχουν την τάση να εισβάλλουν σε παρακείμενους ιστούς, καταστρέφοντάς τους, ενώ παράλληλα διαδίδονται μέσω της κυκλοφορίας του αίματος σε άλλα μέρη του σώματος, παράγοντας δευτερογενείς όγκους, ένα φαινόμενο που καλείται «μετάσταση». Σήμερα, ο καρκίνος αποτελεί μία από τις σοβαρότερες και δυσκολότερα αντιμετωπίσιμες παθήσεις. Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας (World Health Organization – WHO), μόνο το 2020, ήταν υπεύθυνος για περίπου 10 εκατομμύρια θανάτους παγκοσμίως [1].

Δύο από τις συνηθέστερες και πιο επικίνδυνες μορφές καρκίνου είναι ο καρκίνος του παχέος εντέρου και του πνεύμονα. Συγκεκριμένα, το 2020 καταγράφηκαν 1,93 εκατομμύρια περιπτώσεις καρκίνου του παχέος εντέρου και 2,21 εκατομμύρια περιπτώσεις καρκίνου του πνεύμονα [1]. Επιπλέον, οι δύο παραπάνω τύποι καρκίνου κατατάσσονται ανάμεσα στους περισσότερο θανατηφόρους, αφού την ίδια χρονιά ήταν υπεύθυνοι για 916.000 και 1,8 εκατομμύρια θανάτους, αντίστοιχα [1]. Παρόλο που οι συγκεκριμένες παθήσεις μπορούν να αντιμετωπιστούν, καθοριστικό ρόλο στην έκβαση της θεραπευτικής αντιμετώπισης διαδραματίζει η έγκαιρη διάγνωσή τους. Ενδεικτικά, το ποσοστό επιβίωσης για τουλάχιστον πέντε έτη των νοσούντων από καρκίνο του παχέος εντέρου είναι 91% αν η διάγνωση τεθεί σε αρχικά στάδια, όπου ο καρκίνος είναι ακόμη εντοπισμένος. Αντίθετα, αν ο καρκίνος έχει επεκταθεί σε απομακρυσμένα σημεία του σώματος, η αντίστοιχη πιθανότητα είναι μόλις 13% [2]. Βάσει των παραπάνω, καθίσταται εύκολα αντιληπτή η σημασία της ελαχιστοποίησης του κινδύνου εσφαλμένης διάγνωσης στα αρχικά στάδια, όπου τα συμπτώματα δεν είναι τόσο ισχυρά. Η Τεχνητή Νοημοσύνη θα μπορούσε να συνεισφέρει σημαντικά σε αυτή την προσπάθεια, μέσω της ανάπτυξης συστημάτων ανάλυσης και ερμηνείας ιστοπαθολογικών εικόνων.

Το συγκεκριμένο πρόβλημα έχει μελετηθεί στη βιβλιογραφία. Μία ενδιαφέρουσα μελέτη ήταν αυτή των Chehade et al [3], οι οποίοι κατασκεύασαν ένα σύστημα υποβοηθούμενης από τον υπολογιστή διάγνωσης του καρκίνου του παχέος εντέρου και του πνεύμονα, βασισμένο σε παραδοσιακές μεθόδους μηχανικής μάθησης. Οι παραδοσιακές μέθοδοι μηχανικής μάθησης διαθέτουν το πλεονέκτημα της υψηλότερης ερμηνευσιμότητας σε σχέση με τα μοντέλα βαθιάς μάθησης, τα οποία χρησιμοποιούνται τυπικά σε τέτοια προβλήματα. Οι ερευνητές χρησιμοποίησαν τους ταξινομητές XGBoost, SVM, LDA, Random Forest, LightGBM, καθώς και ένα MultiLayer Perceptron (MLP) στο σύνολο ιστοπαθολογικών εικόνων LC25000, το οποίο περιλαμβάνει πέντε διαφορετικούς τύπους ιστού του παχέος εντέρου και του πνεύμονα. Οι ταξινομητές κατάφεραν να διακρίνουν τους πέντε τύπους ιστού σε ικανοποιητικό βαθμό, με καλύτερη απόδοση από αυτούς να εμφανίζει ο XGBoost, ο οποίος πέτυχε ακρίβεια 99%.

Οι Teramoto et al [4], ανέπτυξαν ένα συνελικτικό νευρωνικό δίκτυο, αποτελούμενο από τρία επίπεδα συνέλιξης, τρία επίπεδα χωρικής υποδειγματοληψίας και δύο πλήρως συνδεδεμένα επίπεδα, για την ταξινόμηση μικροσκοπικών εικόνων στις παρακάτω τρεις κατηγορίες: αδενοκαρκίνωμα πνεύμονα, ακανθοκυτταρικό καρκίνωμα πνεύμονα και μικροκυτταρικό καρκίνωμα πνεύμονα. Για την αποφυγή της υπερπροσαρμογής εφαρμόστηκε στο στάδιο της προεπεξεργασίας η τεχνική της επαύξησης δεδομένων, ενώ η αξιολόγηση του μοντέλου πραγματοποιήθηκε με χρήση της μεθόδου διασταυρωμένης επικύρωσης (cross-validation). Το δίκτυο κατάφερε να διακρίνει τις τρεις περιπτώσεις με ακρίβεια περίπου 71%.

Μία ακόμη σχετική μελέτη, βασισμένη στην τεχνική της μεταφερόμενης μάθησης, πραγματοποιήθηκε από τους Abbas et al [5], οι οποίοι χρησιμοποίησαν ένα σύνολο προεκπαιδευμένων δικτύων για την ταξινόμηση 15.000 περιπτώσεων ιστού του πνεύμονα του συνόλου δεδομένων LC25000 στις εξής τρεις κατηγορίες: αδενοκαρκίνωμα, ακανθοκυτταρικό καρκίνωμα και καλοήγητος ιστός πνεύμονα. Στο στάδιο της προεπεξεργασίας, πραγματοποιήθηκε αναστροφή ως προς τον οριζόντιο και κάθετο άξονα και τυχαία μεταβολή της εστίασης και της φωτεινότητας των εικόνων. Στη συνέχεια, συγκρίθηκε η απόδοση των προεκπαιδευμένων δικτύων VGG-19, AlexNet, ResNet-18, ResNet-34, ResNet-50 και ResNet-101. Η ακρίβεια των παραπάνω μοντέλων ήταν 98,93%, 97,26%, 98,8%, 99,18%, 99,6% και 99,8%, αντίστοιχα.

Μία ακόμη προσέγγιση ήταν αυτή των Mehmood et al [6], οι οποίοι χρησιμοποίησαν ένα προεκπαιδευμένο AlexNet δίκτυο για την κατηγοριοποίηση των εικόνων του συνόλου δεδομένων LC25000 σε πέντε κλάσεις. Τα πρώτα αποτελέσματα ήταν ενθαρρυντικά, αφού η ακρίβεια για όλες τις κλάσεις ήταν υψηλή, με εξαίρεση μίας εξ αυτών στην οποία το μοντέλο σημείωσε ακρίβεια 89%. Με σκοπό την αύξηση της συνολικής ακρίβειας του μοντέλου και την ταυτόχρονη διατήρηση της χαμηλής υπολογιστικής πολυπλοκότητας, οι ερευνητές εφάρμοσαν μία τεχνική βελτίωσης της αντίθεσης μόνο στις εικόνες της κλάσης στην οποία το μοντέλο παρουσίασε μειωμένη απόδοση. Η συγκεκριμένη μεθοδολογία είχε ως αποτέλεσμα την αύξηση της συνολικής ακρίβειας σε 98,4%.

Τέλος, οι Bukhari et al [7], χρησιμοποίησαν τρεις εκδοχές του προεκπαιδευμένου μοντέλου ResNet (ResNet-18, ResNet-34 και ResNet-50) για τον εντοπισμό αδενοκαρκινώματος του παχέος εντέρου σε ιστολογικές εικόνες. Στη συγκεκριμένη μελέτη, συνδυάστηκαν δύο διαφορετικά σύνολα δεδομένων, το LC25000 και το CRAG Dataset. Από αυτά, το πρώτο χρησιμοποιήθηκε αποκλειστικά για την εκπαίδευση και επαλήθευση των δικτύων, ενώ το δεύτερο αξιολογήθηκε από δύο ιστοπαθολόγους και διαχωρίστηκε σε δύο υποσύνολα, το ένα εκ των οποίων αξιοποιήθηκε για την εκπαίδευση, ενώ το δεύτερο για τον έλεγχο των μοντέλων. Την υψηλότερη απόδοση σημείωσε το μοντέλο ResNet-50, με ακρίβεια 93,91%, ενώ τα ResNet-34 και ResNet-18 σημείωσαν ακρίβεια 93,04%.

Από τα παραπάνω, γίνεται αντιληπτό πως η Τεχνητή Νοημοσύνη θα μπορούσε να συνεισφέρει στην υποβοήθηση της λήψης κλινικών αποφάσεων και, ως εκ τούτου, η ανάπτυξη σχετικών συστημάτων αποτελεί ένα πολλά υποσχόμενο πεδίο. Η παρούσα εργασία επικεντρώνεται στην κατασκευή και σύγκριση διαφορετικών αρχιτεκτονικών συνελκτικών νευρωνικών δικτύων με στόχο την ανάπτυξη ενός μοντέλου αναγνώρισης του καρκίνου του παχέος εντέρου και του πνεύμονα. Τα μοντέλα καλούνται να ταξινομήσουν τα δείγματα στις πέντε παρακάτω κατηγορίες: αδενοκαρκίνωμα παχέος εντέρου, καλοήθης ιστός παχέος εντέρου, αδενοκαρκίνωμα του πνεύμονα, ακανθοκυτταρικό καρκίνωμα πνεύμονα και καλοήθης ιστός πνεύμονα. Στη συνέχεια, η απόδοσή τους συγκρίνεται με εκείνη ενός προεκπαιδευμένου VGG16 δικτύου.

Στο δεύτερο κεφάλαιο της εργασίας, πραγματοποιείται μία γενικότερη επισκόπηση της περιοχής της Τεχνητής Νοημοσύνης, με αναφορές σε βασικές έννοιες, όπως τα είδη της μηχανικής μάθησης και κάποια αντιπροσωπευτικά προβλήματα της κάθε κατηγορίας. Στο τρίτο κεφάλαιο, γίνεται εκτενής αναφορά στα Τεχνητά Νευρωνικά Δίκτυα, στα οποία βασίστηκε η περιματική διαδικασία. Τέλος, στο τέταρτο κεφάλαιο, παρουσιάζεται το πρακτικό μέρος, τα αποτελέσματα που προέκυψαν καθώς και τα συμπεράσματα και οι μελλοντικές επεκτάσεις.

Κεφάλαιο 2

Τεχνητή Νοημοσύνη

Η Τεχνητή Νοημοσύνη βρίσκεται στο σταυροδρόμι πολλών διαφορετικών επιστημών, συμπεριλαμβανομένων των μαθηματικών, της επιστήμης των υπολογιστών, της ψυχολογίας και της γλωσσολογίας [8]. Στο πέρασμα του χρόνου έχουν γίνει πολυάριθμες προσπάθειες ορισμού της οι οποίες διαφοροποιούνται ως προς τον προσδιορισμό του στόχου της. Κάποιοι από τους ορισμούς που έχουν διατυπωθεί βασίζονται στη διαδικασία σκέψης και συλλογισμού, προτείνοντας πως σκοπός της Τεχνητής Νοημοσύνης είναι η ανάπτυξη συστημάτων που αναπαράγουν την ανθρώπινη σκέψη ή η κατασκευή συστημάτων που σκέφτονται λογικά. Άλλοι, επικεντρώνονται στη συμπεριφορά, αναφέροντας πως στόχος της είναι η δημιουργία συστημάτων που έχουν την ικανότητα να αναπαράγουν τη συμπεριφορά του ανθρώπου ή συστημάτων που αντιδρούν σύμφωνα με τη λογική. Μια γενική περιγραφή, η οποία συνδυάζει τα περισσότερα από τα παραπάνω στοιχεία, υποστηρίζει πως *«Τεχνητή Νοημοσύνη είναι ο τομέας της Επιστήμης των Υπολογιστών που ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων 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 και κατανόηση εικόνων, η μάθηση, η εξαγωγή συμπερασμάτων, η κατανόηση φυσικής γλώσσας, κτλπ»* [8].

Η Τεχνητή Νοημοσύνη δύναται να διακριθεί σε δύο κατηγορίες ανάλογα με την προσέγγιση που ακολουθείται για την παραγωγή της ευφυούς συμπεριφοράς [8]. Η Κλασική ή Συμβολική Τεχνητή Νοημοσύνη προσπαθεί να μιμηθεί την ανθρώπινη νοημοσύνη μέσω της κατασκευής συστημάτων που βασίζονται σε σύμβολα τα οποία αναπαριστούν έννοιες ή σχέσεις μεταξύ των εννοιών. Αντιπροσωπευτικά παραδείγματα αποτελούν τα συστήματα που χρησιμοποιούν αναπαράσταση γνώσης όπως λογική ή κανόνες. Στον αντίποδα, η Υπολογιστική Νοημοσύνη ή, εναλλακτικά, η Συνδετική Τεχνητή Νοημοσύνη, προσδίδει στις μηχανές ιδιότητες ευφυΐας πορσωμιώνοντας βιολογικές διεργασίες, όπως η εξέλιξη των ειδών και ο μηχανισμός λειτουργίας του ανθρώπινου εγκεφάλου. Βασικοί εκπρόσωποι της συγκεκριμένης κατηγορίας είναι οι γενετικοί αλγόριθμοι και τα Τεχνητά Νευρωνικά Δίκτυα. Στο σημείο αυτό, αξίζει να διευκρινιστεί ότι παρόλο που

όλες οι τεχνικές Τεχνητής Νοημοσύνης επιστρατεύουν υπολογιστικές μεθόδους, ο όρος «Υπολογιστική Νοημοσύνη» χρησιμοποιείται ευρέως για να περιγράψει μη-συμβολικές μεθόδους. Ένας άλλος διαχωρισμός της Τεχνητής Νοημοσύνης πραγματοποιείται με γνώμονα τον στόχο των μεθόδων της. Από τη μία πλευρά, η Αδύναμη ή Περιορισμένη Τεχνητή Νοημοσύνη αποσκοπεί στην ανάπτυξη συστημάτων που απλά προσομοιώνουν την ανθρώπινη σκέψη, ενώ αντίθετα η Ισχυρή ή Γενική Τεχνητή Νοημοσύνη επικεντρώνεται στη δημιουργία μηχανών που έχουν την ικανότητα να σκέφτονται πραγματικά.

Τα θεμέλια της Τεχνητής Νοημοσύνης τέθηκαν στην αρχαιότητα, όταν ο Αριστοτέλης πρότεινε μια σειρά κανόνων που περιέγραφαν τη διαδικασία της «ορθής σκέψης» και αποτέλεσαν τους δομικούς λίθους για την ανάπτυξη του ερευνητικού πεδίου της λογικής. Εντούτοις, η πρώτη επίσημη εργασία παρουσιάστηκε το 1943 από τους Warren McCulloch και Walter Pitts και αφορούσε τη δημιουργία ενός μοντέλου Τεχνητών Νευρωνικών Δικτύων για τον υπολογισμό μαθηματικών συναρτήσεων. Λίγα χρόνια αργότερα, το 1950, ο πατέρας της Τεχνητής Νοημοσύνης, Alan Turing, πρότεινε ένα παιχνίδι μίμησης το οποίο έμεινε στην ιστορία ως «Δοκιμασία Turing» και είχε ως στόχο να απαντήσει στο ερώτημα «Μπορούν οι μηχανές να σκέφτονται». Στη συγκεκριμένη δοκιμασία, συμμετέχουν τρεις παίκτες, δύο άνθρωποι και μια μηχανή. Ο ένας από τους δύο ανθρώπους, έχει το ρόλο του εξεταστή και θέτει ερωτήσεις στους άλλους δύο παίκτες με σκοπό να διαπιστώσει ποιος είναι το φυσικό πρόσωπο και ποιος ο υπολογιστής. Αν μετά από ορισμένο πλήθος ερωτήσεων ο εξεταστής δεν ανταποκριθεί με επιτυχία στη δοκιμασία θεωρείται ότι ο υπολογιστής διαθέτει νοημοσύνη. Ορόσημο στην ιστορία της Τεχνητής Νοημοσύνης αποτελεί επίσης η διοργάνωση του συνεδρίου με θέμα τη θεωρία αυτομάτων, τα νευρωνικά δίκτυα και τη μελέτη της ευφυίας από τους John McCarthy, Marvin Minsky και Claude Shannon το 1956 στο Dartmouth College. Η συγκεκριμένη συνάντηση, κατά τη διάρκεια της οποίας αποφασίστηκε η υιοθέτηση του όρου «Τεχνητή Νοημοσύνη» για την περιγραφή του εν λόγω πεδίου, διαδραμάτισε καθοριστικό ρόλο στη μετέπειτα εξέλιξη της ερευνητικής προοχής [8].

Συνοπτικά, διακρίνονται τέσσερις περίοδοι στην ιστορία της Τεχνητής Νοημοσύνης [9]. Στην προϊστορική περίοδο, η Τεχνητή Νοημοσύνη υπήρχε μόνο υπό την μορφή θεωρητικών περιγραφών και αναφορών. Στη συνέχεια, ακολούθησε η κλασική περίοδος, η οποία πιστεύεται πως ξεκίνησε το 1950 με την εργασία του Αμερικανού επιστήμονα και Πατέρα της Θεωρίας Υπολογισμού Claude Shannon με τίτλο «*Programming a Computer for Playing Chess*» [10]. Η έρευνα εκείνη την εποχή, αφορούσε κυρίως τα προβλήματα αναζήτησης στον τομέα των παιγνίων και την απόδειξη θεωρημάτων. Το τέλος της κλασικής περιόδου σηματοδοτήθηκε από τη δημοσίευση «*Computers and thought*» των Feigenbaum και Feldman το 1963 [11]. Ακολούθησε η ρομαντική περίοδος, η οποία διήρκησε έως τα μέσα της δεκαετίας του 1970 και χαρακτηρίστηκε από την ανάπτυξη μηχανών που είχαν την ικανότητα να κατανοούν τη φυσική γλώσσα. Τέλος, η μοντέρνα περίοδος εκτείνεται από το δεύτερο μισό της δεκαετίας του 1970 έως τα τέλη της δεκαετίας του 1980. Η έρευνα τότε αφιερώθηκε στην ανάπτυξη συστημάτων βασισμένων

στη γνώση και στην επίλυση πρακτικών προβλημάτων με απώτερο σκοπό την εμπορική εκμετάλλευση της Τεχνητής Νοημοσύνης. Άξιο αναφοράς, είναι το σύστημα MYCIN το οποίο αναπτύχθηκε στις αρχές της δεκαετίας του 1970 από το πανεπιστήμιο Stanford και είχε ως στόχο την υποβοήθηση της διάγνωσης μολυσματικών ασθενειών και την πρόταση της κατάλληλης θεραπευτικής αντιμετώπισης [12].

Σήμερα, έπειτα από δεκαετίες έρευνας, διανύουμε τη μεταμοντέρνα εποχή της Τεχνητής Νοημοσύνης, με την τελευταία να βρίσκει πραγματική εφαρμογή, έχοντας παρεισφρήσει στους περισσότερους τομείς της καθημερινότητας. Στο διαδίκτυο, τα συστήματα συστάσεων παράγουν εξατομικευμένες προτάσεις προϊόντων ή υπηρεσιών, τα φίλτρα περιορισμού της ανεπιθύμητης αλληλογραφίας ταξινομούν αυτόματα τα ηλεκτρονικά μηνύματα, ενώ παράλληλα, προσωπικοί ψηφιακοί βοηθοί, όπως η Google Assistant της Google, η Alexa της Amazon ή η Siri της Apple, επικοινωνούν μέσω φωνητικών εντολών με τους χρήστες των smartphone και πραγματοποιούν ενέργειες προκειμένου να ικανοποιήσουν κάποιο αίτημά τους. Ακόμη, ο κλάδος των οικονομικών και των επιχειρήσεων αξιοποιεί ευφυείς μηχανισμούς στην αυτοματοποίηση της ροής των εργασιών, στην αναγνώριση μη εξουσιοδοτημένης χρήσης πιστωτικών καρτών και στην πραγματοποίηση διαδικτυακών συναλλαγών [8]. Στις μεταφορές, η Τεχνητή Νοημοσύνη έχει εφαρμοστεί στην ανάπτυξη συστημάτων έγκαιρης προειδοποίησης του οδηγού σε περιπτώσεις κινδύνου, στην εύρεση της βέλτιστης διαδρομής, στην αυτόνομη οδήγηση και στη ρύθμιση της οδικής κυκλοφορίας [13]. Η αγροτική παραγωγή είναι ένας τομέας που επίσης μπορεί να επωφεληθεί από μεθόδους Τεχνητής Νοημοσύνης, μέσω της ανάπτυξης εργαλείων παρακολούθησης των ζώων, εντοπισμού ασθενειών σε καλλιέργειες [14] και πρόβλεψης των καιρικών φαινομένων [15]. Τέλος, τεχνολογίες Τεχνητής Νοημοσύνης έχουν αποδειχθεί ιδιαίτερας αποτελεσματικής στην Ιατρική [16], στην Αστρονομία [17], στην εκπαίδευση [18], και στη Νομική [19].

2.1 Περιοχές της Τεχνητής Νοημοσύνης

Η Τεχνητή Νοημοσύνη συνιστά ένα σύνθετο πεδίο που περιλαμβάνει διάφορες επιστημονικές περιοχές. Ανάμεσα στις σημαντικότερες εξ αυτών βρίσκονται η μηχανική και η βαθιά μάθηση, η τεχνητή όραση και η επεξεργασία φυσικής γλώσσας.

Μηχανική Μάθηση:

Η μηχανική μάθηση αναφέρεται στην ικανότητα των μηχανών να επιτελούν διεργασίες χωρίς να έχουν προγραμματιστεί ρητά και να βελτιώνουν αυτόματα την απόδοσή τους σε αυτές, αποκλειστικά βάσει της εμπειρίας τους [8] [20]. Οι αλγόριθμοι μηχανικής μάθησης καταφέρνουν να εξάγουν πολύτιμη γνώση και να πραγματοποιούν προβλέψεις μέσω της εκπαίδευσής τους σε σύνολα δεδομένων, δίχως την ανάγκη ύπαρξης κάποιας προκαθορισμένης γνώσης [8]. Ένα υποσύνολο της μηχανικής μάθησης, η βαθιά μάθηση, έχει γνωρίσει τεράστια άνθηση τα τελευταία χρόνια χάρις σε ένα συνδυασμό παραγόντων όπως η ραγδαία αύξηση της υπολογιστικής ισχύος και η μεγάλη διαθεσιμότητα δεδομένων. Το συγκεκριμένο πεδίο βασίζεται στη χρήση Τεχνητών Νευρωνικών Δικτύων, δηλαδή μηχανών εκμάθησης αποτελούμενων από υπολογιστικές μονάδες που καλούνται νευρώνες και λειτουργούν προσομοιώνοντας τον βιολογικό μηχανισμό του ανθρώπινου νευρικού συστήματος.

Τεχνητή Όραση:

Η Τεχνητή Όραση είναι ο τομέας της Τεχνητής Νοημοσύνης που έχει ως στόχο να καταστήσει μια μηχανή ικανή να «βλέπει», δηλαδή να επεξεργάζεται και να ερμηνεύει οπτική πληροφορία με στόχο την άντληση χρήσιμης γνώσης ή την εκτέλεση κάποιας ενέργειας. Κάποια δημοφιλή προβλήματα Τεχνητής Όρασης είναι ο εντοπισμός αντικειμένων, η αναγνώριση προσώπου, η ανίχνευση δραστηριότητας και η εκτίμηση της στάσης του ανθρώπινου σώματος [21].

Επεξεργασία Φυσικής Γλώσσας:

Μία ακόμη εξαιρετικά ενδιαφέρουσα περιοχή μελέτης, η οποία εμφανίστηκε τη δεκαετία του 1950 ως τομή της Τεχνητής Νοημοσύνης και της γλωσσολογίας, είναι η Επεξεργασία Φυσικής Γλώσσας [22]. Στόχος του συγκεκριμένου πεδίου είναι η κατανόηση, εκμάθηση και παραγωγή περιεχομένου φυσικής γλώσσας από τους υπολογιστές. Οι αρχικές προσεγγίσεις πειλάμβαναν την αυτοματοποίηση της ανάλυσης της δομής της φυσικής γλώσσας και την ανάπτυξη τεχνολογιών, όπως η μηχανική μετάφραση ή η αναγνώριση και σύνθεση φωνής. Στη σημερινή εποχή, οι ερευνητές βελτιώνουν τα συγκεκριμένα εργαλεία με σκοπό να τα αξιοποιήσουν σε προβλήματα του πραγματικού κόσμου. Ορισμένα ενδεικτικά παραδείγματα σχετικών εφαρμογών αφορούν την εξόρυξη γνώσης από τα κοινωνικά δίκτυα, τη δημιουργία διαλογικών φωνητικών συστημάτων (spoken dialogue systems) και την αυτόματη αναγνώριση της γνώμης των καταναλωτών για ένα προϊόν ή κάποια υπηρεσία [23].

2.2 Τεχνητή Νοημοσύνη στην Ιατρική

Τα τελευταία πενήντα χρόνια, η ταχεία εξέλιξη της Τεχνητής Νοημοσύνης έχει θέσει νέες βάσεις στην Ιατρική. Η άνθιση των πεδίων της μηχανικής μάθησης και της βαθιάς μάθησης, συνέβαλε σημαντικά στη μετάβαση από τα παραδοσιακά μοντέλα προς την εξατομικευμένη ιατρική φροντίδα. Ωστόσο, από τη «γέννηση» της Τεχνητής Νοημοσύνης έως ότου καταστεί εφικτή η εφαρμογή της στην Ιατρική, έπρεπε να υπερπηδηθούν κάποια σημαντικά εμπόδια. Τα πρώτα βήματα προς αυτή την κατεύθυνση έγιναν τις δεκαετίες 1950-1970 με την ψηφιοποίηση των ιατρικών δεδομένων [24]. Η ανάπτυξη του πρώτου συστήματος αναζήτησης βιοϊατρικών πληροφοριών με την ονομασία MEDLARS (Medical Literature Analysis and Retrieval System) και της μηχανής αναζήτησης PubMed από την Εθνική Βιβλιοθήκη της Ιατρικής (National Library of Medicine – NLM) των ΗΠΑ τη δεκαετία του 1960, συντέλεσαν σημαντικά στη μετέπειτα πρόοδο της Βιοϊατρικής. Ακόμη, τη συγκεκριμένη χρονική περίοδο δημιουργήθηκαν οι πρώτες βάσεις δεδομένων Κλινικής Πληροφορικής (Clinical Informatics) καθώς και τα πρώτα συστήματα ιατρικών αρχείων. Τα παραπάνω γεγονότα έθεσαν τα θεμέλια για τη μελλοντική εφαρμογή της Τεχνητής Νοημοσύνης στον κλάδο της Υγείας.

Τα χρόνια που μεσολάβησαν από τη δεκαετία του 1970 έως τις αρχές του 2000, χαρακτηρίστηκαν ως «Χειμώνας της Τεχνητής Νοημοσύνης», εξαιτίας του μειωμένου ενδιαφέροντος και της ελλιπούς χρηματοδότησης για την έρευνα στο συγκεκριμένο γνωστικό αντικείμενο. Παρά τις δυσκολίες αυτές, η συνεργασία ανάμεσα στους πρωτοπόρους του κλάδου συνεχίστηκε. Χαρακτηριστικό παράδειγμα, αποτελεί η διοργάνωση του πρώτου workshop με θέμα την εφαρμογή της Τεχνητής Νοημοσύνης στην Ιατρική, χρηματοδοτούμενο από το Εθνικό Ινστιτούτο Υγείας (National Institute of Health – NIH) των ΗΠΑ, στο πανεπιστήμιο Rutgers το 1975. Παράλληλα, αναπτύχθηκαν κάποια από τα πρώτα συστήματα υποστήριξης κλινικών αποφάσεων. Στα τέλη της δεκαετίας του 1990, το ενδιαφέρον για τη μηχανική μάθηση αναζωπυρώθηκε και ως εκ τούτου ενισχύθηκε η προοπτική ενσωμάτωσης σχετικών εφαρμογών στην Ιατρική [24]. Έκτοτε, ο ρυθμός ανάπτυξης ευφών συστημάτων στο χώρο της υγείας επιταχύνεται θεαματικά. Η μεγάλη διαθεσιμότητα δεδομένων, η δημιουργία εξελιγμένων αλγορίθμων μηχανικής μάθησης, η ραγδαία αύξηση της επεξεργαστικής ισχύος και του αποθηκευτικού χώρου των υπολογιστικών συστημάτων συνιστούν μερικούς μόνο από τους παράγοντες που συντέλεσαν καθοριστικά στην αλματώδη πρόοδο της Τεχνητής Νοημοσύνης στην Ιατρική. Καίριο ρόλο στη σύγχρονη ιστορία της εφαρμογής της Τεχνητής Νοημοσύνης στον κλάδο της Υγείας είχε η δημιουργία του υπερυπολογιστή Watson από την IBM το 2007. Το σύστημα αυτό, βασιζόμενο σε τεχνικές Επεξεργασίας Φυσικής Γλώσσας (Natural Language Processing – NLP), άνοιξε νέους ορίζοντες στη διαδικασία λήψης κλινικών αποφάσεων σύμφωνα με τις αρχές της Βασισμένης σε Ενδείξεις Ιατρικής (Evidence Based Medicine – EBM). Ταυτόχρονα, κυρίως με τη συμβολή της βαθιάς μάθησης, η Τεχνητή Νοημοσύνη

έχει βρει εφαρμογή σε πολυάριθμους τομείς της Ιατρικής, όπως η παθολογία, η δερματολογία, η οφθαλμολογία, η καρδιολογία, η γαστρεντερολογία και η ψυχιατρική [25].

Αδιαμφισβήτητα, ένας τομέας στον οποίο η Τεχνητή Νοημοσύνη έχει σημειώσει μεγάλη επιτυχία είναι η στήριξη της ιατρικής διάγνωσης μέσω της ερμηνείας και ανάλυσης ιατρικών εικόνων. Ο εντοπισμός και η αξιολόγηση των ιατρικών ευρημάτων συνιστά συχνά μια δύσκολη δοκιμασία, ενώ δε παύει πάντα να υπεισέρχεται το στοιχείο της υποκειμενικότητας του διαγνώστη. Έχει παρατηρηθεί ότι 1-3 στις 10 μαστογραφίες χαρακτηρίζονται εσφαλμένα ως αρνητικές, ενώ στα δύο τρίτα των περιπτώσεων αυτών ο γιατρός έκανε λάθος εκτίμηση, αδυνατώντας να διαγνώσει τον καρκίνο του μαστού. Τέτοιου είδους λάθη οφείλονται συχνά σε παράγοντες όπως η χαμηλή ποιότητα των εικόνων, η οπτική κόπωση του κλινικού ή η περιπλοκότητα των ίδιων των ιατρικών δεδομένων [26]. Όπως γίνεται φανερό με βάση τα ήδη λεχθέντα, μία δεύτερη εκτίμηση θα μπορούσε να μειώσει σημαντικά τα περιστατικά εσφαλμένης διάγνωσης.

Οι επιστήμονες είχαν αναγνωρίσει τη συγκεκριμένη ανάγκη ήδη από τη δεκαετία του 1960, όταν εμφανίστηκε για πρώτη φορά η ιδέα των αυτοματοποιημένων συστημάτων διάγνωσης (Automated Computer Diagnosis – ACD), όπου η διάγνωση τίθεται αποκλειστικά από τον υπολογιστή χωρίς να λαμβάνεται υπόψη η γνώμη του γιατρού. Εντούτοις, οι αρχικές προσπάθειες ανάπτυξης τέτοιων συστημάτων δε στέφθηκαν με επιτυχία, εξαιτίας της χαμηλής ισχύος των υπολογιστών, της έλλειψης εξελιγμένων τεχνικών επεξεργασίας εικόνας και της μικρής διαθεσιμότητας ιατρικών δεδομένων. Στις αρχές της δεκαετίας του 1980, αφού διαπιστώθηκε πως η απαίτηση για την ανάπτυξη ενός συστήματος που θα μπορούσε να αντικαταστήσει τον ρόλο του γιατρού δεν ήταν εφικτή, το ερευνητικό ενδιαφέρον προσανατολίστηκε στην υποβοηθούμενη από τον υπολογιστή διάγνωση (Computer Aided Diagnosis – CAD), η οποία λειτουργεί επικουρικά στη λήψη των κλινικών αποφάσεων. Τα συστήματα αυτά δέχονται ως είσοδο δεδομένα, όπως ακτίνες X, τομογραφικές εικόνες ή εικόνες υπερήχων, με σκοπό να παράξουν μία πρόβλεψη που θα λειτουργήσει συνεργατικά με την εκτίμηση του γιατρού για την διαμόρφωση της τελικής διάγνωσης [27]. Τέτοια συστήματα βασιζόμενα σε μεθόδους Τεχνητής Νοημοσύνης, και ειδικότερα στη βαθιά μάθηση, έχουν επιτύχει αντίστοιχη διαγνωστική ακρίβεια με τους επαγγελματίες σε ασθένειες όπως η διαβητική αμφιβληστροειδοπάθεια [28] και ο καρκίνος του δέρματος [29]. Παράλληλα, σε άλλες περιπτώσεις, όπως η διάγνωση του καρκίνου του μαστού, οι αλγόριθμοι μηχανικής μάθησης έχουν αποδειχθεί αποτελεσματικότεροι από έμπειρους παθολόγους [30].

Εκτός από τις ιατρικές εικόνες, τα τελευταία χρόνια πραγματοποιούνται εντατικές προσπάθειες συλλογής και δημοσιοποίησης στην επιστημονική κοινότητα άλλων τύπων κλινικών δεδομένων, τα οποία μπορούν επίσης να αξιοποιηθούν από τις μεθόδους της Τεχνητής Νοημοσύνης προς όφελος της υγειονομικής περίθαλψης. Τα δεδομένα του ανθρώπινου γονιδιώματος αποδεικνύονται χρήσιμα σε προβλήματα όπως η ανακάλυψη βιοδεικτών σχετιζόμενων με διάφορες ασθένειες και η ανάλυση του ανθρώπινου γονιδιώματος, ανοίγοντας το δρόμο προς την ευρεία εφαρμογή της Ιατρικής Ακρίβειας.

Μία επιπλέον σημαντική πηγή ιατρικών δεδομένων αποτελεί ο Ηλεκτρονικός Φάκελος Υγείας (Electronic Health Record – HER) των ασθενών. Κάποιες ενδεικτικές εφαρμογές επεξεργασίας των συγκεκριμένων πληροφοριών αποτελούν η ανάπτυξη συστημάτων για την πρόβλεψη της έκβασης του ασθενούς, της απόκρισής του σε μια συγκεκριμένη θεραπεία, της νοσοκομειακής επανεισαγωγής και της διάρκειας νοσηλείας. Τέλος, οι φορετές συσκευές (wearable devices), όπως τα «έξυπνα ρολόγια» (smart watches), οι οποίες προσφέρουν συνεχή μέτρηση και καταγραφή των φυσιολογικών παραμέτρων, μπορούν επίσης να συνεισφέρουν στον εντοπισμό πιθανών παθολογιών εφόσον τροφοδοτηθούν με τα δεδομένα που παράγονται από αυτές κατάλληλα μοντέλα μηχανικής μάθησης.

Η παρακολούθηση των ασθενών, τόσο εντός όσο και εκτός νοσοκομείου, αποτελεί έναν ακόμη τομέα στον οποίο μπορούν να φανούν χρήσιμες οι τεχνολογίες Τεχνητής Νοημοσύνης. Οι συσκευές που χρησιμοποιούνται τυπικά για αυτό το σκοπό παράγουν μεγάλες ποσότητες δεδομένων και σε περίπτωση που συνδεθούν με κάποιο ευφυή μηχανισμό μπορούν να ειδοποιήσουν έγκαιρα για αλλαγές στην κατάσταση της υγείας του ασθενούς. Σε παθήσεις όπως η καρδιακή ανεπάρκεια, ο διαβήτης και η ημικρανία έχουν παρατηρηθεί καλύτερα κλινικά αποτελέσματα με την ενσωμάτωση ευφυών μηχανισμών στην απομακρυσμένη παρακολούθηση [31]. Ακόμη, πολλές φορές, αφότου παρέλθη το διάστημα νοσηλείας, απαιτείται επιπλέον παρακολούθηση του ασθενούς. Ωστόσο, η μετάβαση στο νοσοκομείο δεν είναι πάντα εύκολη, ιδιαίτερα όταν οι ασθενείς δεν διαθέτουν αυτονομία, όπως οι ηλικιωμένοι, ή βρίσκονται σε δυσπρόσιτες περιοχές. Στις περιπτώσεις αυτές, τα ευφυή συστήματα θα μπορούσαν να συνεισφέρουν στην απομακρυσμένη αξιολόγηση της κατάστασης της υγείας τους από τους ειδικούς, μειώνοντας το κόστος παράτασης της διάρκειας νοσηλείας και προσφέροντας μεγαλύτερη ευελιξία.

Επιπρόσθετα, η Τεχνητή Νοημοσύνη μπορεί να αυξήσει την ενεργή συμμετοχή και την αφοσίωση των ασθενών στη θεραπευτική διαδικασία. Έχει αποδειχθεί πως όταν οι ασθενείς ενθαρρύνονται να συμμετέχουν ενεργά στη διαδικασία της προτεινόμενης θεραπείας τείνουν να συμμορφώνονται ευκολότερα στις ιατρικές υποδείξεις, με αποτέλεσμα να παρουσιάζουν καλύτερα κλινικά αποτελέσματα και υψηλότερη ικανοποίηση αναφορικά με τις υπηρεσίες που δέχθηκαν [16]. Ως εκ τούτου, η ενίσχυση της εμπλοκής του πάσχοντα στην διαδικασία της θεραπευτικής αντιμετώπισης πρέπει να αποτελεί πρωταρχικό στόχο για τους παρόχους υγείας. Στην προσπάθεια αυτή, θα μπορούσε να συνεισφέρει η Τεχνητή Νοημοσύνη μέσω της ανάπτυξης προσωπικών ψηφιακών βοηθών που θα υπενθυμίζουν, για παράδειγμα, στους ασθενείς την κατάλληλη ώρα για τη λήψη της φαρμακευτικής αγωγής ή θα σχεδιάζουν εξατομικευμένο πρόγραμμα ασκήσεων γυμναστικής βάσει των ιδιαίτερων χαρακτηριστικών τους. Τα συγκεκριμένα συστήματα, μπορούν να δημιουργήσουν στον χρήστη την εντύπωση πως αλληλεπιδρά με ένα ον που διαθέτει ενσυναίσθηση και ενδιαφέρεται πραγματικά για την επιτυχή έκβαση της θεραπείας, μειώνοντας κατά αυτό τον τρόπο το φόρτο εργασίας των επαγ-

γελματιών υγείας και βελτιώνοντας την ποιότητα των υπηρεσιών [32].

Τέλος, η ρομποτικά υποβοηθούμενη χειρουργική συνιστά ένα ακόμα ακόμα τομέα ενσωμάτωσης της Τεχνητής Νοημοσύνης στην Ιατρική. Το εγκεκριμένο από την Αμερικανική Υπηρεσία Τροφίμων και Φαρμάκων (Food and Drug Administration) ρομποτικό σύστημα «da Vinci» χρησιμοποιείται ευρέως σε χειρουργικές επεμβάσεις. Το συγκεκριμένο σύστημα παρουσιάστηκε για πρώτη φορά στις ΗΠΑ το 1995, ενώ η πρώτη του χρήση στην κλινική πρακτική πραγματοποιήθηκε το 1997 και το 1998 έγινε διαθέσιμο στην αγορά. Στις ειδικότητες που έχουν υιοθετήσει τη χρήση του συγκαταλέγονται η καρδιολογία, η ουρολογία, η ωτορινολαρυγγολογία και η γυναικολογία [33]. Κάποια από τα πλεονεκτήματα εφαρμογής της συγκεκριμένης τεχνολογίας, η οποία σχεδιάστηκε για να συνδυάσει τις ικανότητες του γιατρού με την ακρίβεια και τη συνέπεια στο αποτέλεσμα που διακρίνουν τα ρομποτικά συστήματα, είναι η διεύρυνση του οπτικού πεδίου, η αύξηση της ακρίβειας κινήσεων, η μείωση του απαιτούμενου χρόνου νοσηλείας και η ελάττωση του μετεγχειρητικού πόνου. Μελλοντικά, πιστεύεται πως θα χρησιμοποιούνται αυτόνομα ρομποτικά συστήματα βασισμένα στην Τεχνητή Νοημοσύνη, τα οποία δε θα λειτουργούν απλά υποβοηθητικά, αλλά θα διενεργούν εξ'ολοκλήρου τις χειρουργικές επεμβάσεις χωρίς τη συμμετοχή του γιατρού. Ακόμα, ευφυή συστήματα θα μπορούσαν να καταστήσουν εφικτή την διεξαγωγή της επέμβασης από απόσταση.

Εκτός των παραπάνω, έχουν διερευνηθεί και πολλές άλλες περιπτώσεις αξιοποίησης της Τεχνητής Νοημοσύνης για τη βελτίωση των υπηρεσιών υγείας. Ορισμένες εξ αυτών είναι η κατασκευή μοντέλων για την ανακάλυψη νέων φαρμάκων [34], η επιστράτευση της μηχανικής μάθησης στη βελτιστοποίηση της διαχείρισης των νοσοκομειακών πόρων και του ανθρώπινου δυναμικού [35] και η χρήση συστημάτων επαυξημένης και εικονικής πραγματικότητας για την εκπαίδευση των γιατρών [32]. Ωστόσο, παρά την πολλά υποσχόμενη συνεισφορά της Τεχνητής Νοημοσύνης στην αναβάθμιση της ποιότητας των υπηρεσιών υγείας, δε παύουν να υπάρχουν και κάποιοι σημαντικοί περιορισμοί όσον αφορά τη χρήση της στην κλινική πράξη. Καταρχάς, πριν την ενσωμάτωση ευφυών αλγορίθμων στην καθημερινή ιατρική ρουτίνα, είναι απαραίτητη η επιπλέον επικύρωση, αποσφαλμάτωση και προσαρμογή των συγκεκριμένων μοντέλων ούτως ώστε αυτά να παρέχουν όσο το δυνατόν πιο αξιόπιστες εκτιμήσεις όταν τροφοδοτηθούν με άγνωστα δεδομένα. Ένα άλλο σημαντικό ζήτημα αφορά την λήψη ενεργειών για τη διαφύλαξη της ιδιωτικότητας των ασθενών και τη διασφάλιση της προστασίας των ιατρικών δεδομένων που συλλέγονται, αποθηκεύονται και υπόκεινται σε επεξεργασία με σκοπό την κατασκευή μεθόδων μηχανικής μάθησης. Ακόμη, εγείρονται ηθικά διλήμματα τα οποία πρέπει να απαντηθούν, όπως η ανάληψη ευθύνης σε περίπτωση λανθασμένης απόφασης της μηχανής και ο καθορισμός των κριτηρίων σύμφωνα με τα οποία λαμβάνεται εν τέλει η ορθή απόφαση στις διαφορετικές περιπτώσεις.

2.3 Μηχανική Μάθηση

Όπως αναφέρθηκε παραπάνω, η μηχανική μάθηση συνιστά έναν τομέα της Τεχνητής Νοημοσύνης που αφορά τη σχεδίαση, ανάπτυξη και μελέτη αλγορίθμων οι οποίοι, ως επακόλουθο της εκπαίδευσής τους σε πρωτογενή δεδομένα, αντλούν πολύτιμη γνώση και πραγματοποιούν προβλέψεις. Κατά καιρούς, έχουν διατυπωθεί διάφοροι ορισμοί του πεδίου. Ο πρωτοπόρος της Τεχνητής Νοημοσύνης Arthur Samuel, ο οποίος επινόησε τον όρο «μηχανική μάθηση» πρότεινε το 1959 πως πρόκειται για «το πεδίο που δίνει τη δυνατότητα στους υπολογιστές να μάθουν χωρίς να έχουν προγραμματιστεί ρητά» [36]. Μερικά χρόνια αργότερα, το 1987, ο επιστήμονας Jaime Carbonell, ο οποίος διαδραμάτισε σημαντικό ρόλο στην ανάπτυξη εργαλείων και τεχνολογιών επεξεργασίας φυσικής γλώσσας, χαρακτήρισε τη μηχανική μάθηση ως «πεδίο που μελετά υπολογιστικές μεθόδους για την απόκτηση νέας γνώσης, νέων δεξιοτήτων και νέων τρόπων οργάνωσης της υπάρχουσας γνώσης» [37]. Ένας ακόμη σημαντικός ορισμός διατυπώθηκε το 1997 από τον επιστήμονα Tom Mitchell, ο οποίος υποστήριξε πως «Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μια κατηγορία εργασιών T και μια μετρική απόδοσης P , αν η απόδοσή του σε εργασίες της T , όπως μετράται από την P , βελτιώνεται με την εμπειρία E » [38].

2.3.1 Είδη Μηχανικής Μάθησης

Επιβλεπόμενη Μάθηση

Στην επιβλεπόμενη μάθηση, το σύστημα εκπαιδεύεται σε ένα σύνολο δεδομένων της μορφής $(x_i, y_i)_{i=1}^n$ αποτελούμενο από γνωστά παραδείγματα, κάθε ένα από τα οποία σχηματίζεται από ένα ζεύγος εισόδου-εξόδου. Κάθε στοιχείο x_i είναι ένα διάνυσμα χαρακτηριστικών, στο οποίο αντιστοιχεί μία τιμή εξόδου y_i που ονομάζεται ετικέτα (label) και καθοδηγεί τη διαδικασία της μάθησης. Οι μεταβλητές εισόδου κάθε παραδείγματος αναφέρονται ως ανεξάρτητες μεταβλητές, ενώ η τιμή της εξόδου αποτελεί την εξαρτημένη μεταβλητή. Μέσω της εκπαίδευσης πραγματοποιείται η εκμάθηση μιας συνάρτησης αντιστοίχισης εισόδων σε επιθυμητές εξόδους η οποία περιγράφει τα δεδομένα και καλείται συνάρτηση στόχος (target function). Η διαδικασία της επιβλεπόμενης μάθησης περιγράφεται ως [39]:

«Δοθέντος ενός συνόλου δεδομένων εκπαίδευσης αποτελούμενο από N παραδείγματα ζευγών εισόδου - εξόδου $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, όπου κάθε y_i παράχθηκε από μία άγνωστη συνάρτηση $y = f(x)$, ανακάθισε μια συνάρτηση h η οποία προσεγγίζει την πραγματική συνάρτηση f .»

Σκοπός είναι η κατασκευή ενός μοντέλου με υψηλή ικανότητα γενίκευσης, το οποίο όταν δεχθεί ως είσοδο δεδομένα με άγνωστη έξοδο, θα πραγματοποιεί μια επιτυχή πρόβλεψη της τιμής της εξόδου. Στον παραπάνω ορισμό, η συνάρτηση h καλείται υπόθεση και αποτελεί το προκύπτον μοντέλο. Προκειμένου να υπολογιστεί η απόδοσή του, το μοντέλο τροφοδοτείται με ένα σύνολο δεδομένων ελέγχου, το οποίο απαρτίζεται από νέα παραδείγματα, διαφορετικά από εκείνα του συνόλου δεδομένων εκπαίδευσης, και προσπαθεί να προβλέψει την επιθυμητή έξοδο για κάθε ένα από αυτά. Τα προβλήματα επιβλεπόμενης μηχανικής μάθησης διακρίνονται κατά κύριο λόγο σε προβλήματα ταξινόμησης (classification) και προβλήματα παλινδρόμησης (regression).

Μη επιβλεπόμενη Μάθηση

Στη μη επιβλεπόμενη μάθηση το σύστημα τροφοδοτείται με ένα σύνολο μη επισημασμένων (unlabeled) δεδομένων $(x_i)_{i=1}^n$. Ομοίως με την επιβλεπόμενη μάθηση, κάθε στοιχείο x_i αποτελεί ένα διάνυσμα χαρακτηριστικών, ωστόσο δεν είναι γνωστή εκ των προτέρων η επιθυμητή έξοδος y_i για τη δεδομένη είσοδο. Σκοπός είναι η κατασκευή ενός μοντέλου το οποίο θα δέχεται ένα διάνυσμα χαρακτηριστικών x και θα το αντιστοιχίζει σε κάποια τιμή, όπως συμβαίνει στα προβλήματα συστάδοποίησης (clustering), ή θα το μετατρέπει σε ένα άλλο διάνυσμα, όπως απαιτείται στα προβλήματα μείωσης διαστατικότητας (dimensionality reduction).

Ημιεπιβλεπόμενη Μάθηση

Η ημιεπιβλεπόμενη μάθηση θεωρείται συνδυασμός των δύο προηγούμενων τύπων μάθησης. Ο στόχος των μεθόδων της ταυτίζεται με εκείνον των αλγορίθμων επιβλεπόμενης μάθησης, ωστόσο μόνο ένα, μικρό συνήθως, μέρος του συνόλου δεδομένων περιέχει ετικέτες. Δηλαδή, χρησιμοποιούνται τόσο πρότυπα των οποίων η κλάση είναι γνωστή, όσο και πρότυπα με άγνωστη κλάση. Σε πολλές πρακτικές εφαρμογές, συμπεριλαμβανομένων της διάγνωσης ασθενειών, της αναγνώρισης φωνής και της ταξινόμησης εγγράφων, η διαθεσιμότητα μη επισημασμένων δεδομένων είναι ιδιαίτερος υψηλή, ενώ

η προσθήκη ετικετών συνιστά συχνά μία απαιτητική, δαπανηρή και χρονοβόρα διαδικασία που προϋποθέτει την συμβολή κάποιου ειδικού] [40]. Στις περιπτώσεις αυτές, οι μέθοδοι ημιεπιβλεπόμενης μάθησης μπορούν να αξιοποιήσουν τα συγκεκριμένα δεδομένα, με στόχο την κατασκευή μοντέλων με υψηλότερη απόδοση από τα αντίστοιχα μοντέλα επιβλεπόμενης μάθησης. Παρόλο που εκ πρώτης όψεως δεν καθίσταται εύκολα αντιληπτό πώς η προσθήκη μη επισημασμένων δεδομένων θα μπορούσε να ωφελήσει το μοντέλο, αφού διαισθητικά φαίνεται πως θα είχε ως αποτέλεσμα την ενίσχυση της αβεβαιότητας στο πρόβλημα, σε μία δεύτερη ανάγνωση διαπιστώνεται πως τα μη επισημασμένα δεδομένα αυξάνουν το μέγεθος του συνόλου δεδομένων εκπαίδευσης και προσδίδουν επιπλέον πληροφορία για το πρόβλημα, από την οποία ένας αλγόριθμος μάθησης θα μπορούσε να βελτιωθεί [26]. Η ημιεπιβλεπόμενη μάθηση εφαρμόζεται επίσης σε προβλήματα συσταδοποίησης, όπου τα επισημασμένα δεδομένα καθοδηγούν τον αλγόριθμο, προσφέροντας πληροφορία αναφορικά με τα σημεία τα οποία πρέπει υποχρεωτικά να ανήκουν στην ίδια ή σε διαφορετικές συστάδες.

Ενισχυτική Μάθηση

Στην ενισχυτική μάθηση, η ανακάλυψη της γνώσης συντελείται από έναν πράκτορα ο οποίος αλληλεπιδρά με ένα δυναμικό περιβάλλον μέσω της διαδικασίας δοκιμής-λάθους (trial - error). Συγκεκριμένα, σε κάθε βήμα ο πράκτορας λαμβάνει ως είσοδο μια ένδειξη για την τρέχουσα κατάσταση του περιβάλλοντος και, βάσει αυτής, πραγματοποιεί μια ενέργεια η οποία αποτελεί την παραγόμενη έξοδο. Η εκτέλεση της ενέργειας του πράκτορα έχει ως αποτέλεσμα την μεταβολή της κατάστασης του περιβάλλοντος και την επιστροφή στον πρώτο μιας ανταμοιβής, δηλαδή μιας τιμής που αντικατοπτρίζει την επίδοσή του [41]. Η ανταμοιβή μπορεί να λαμβάνεται είτε τακτικά είτε σποραδικά. Για παράδειγμα, σε παιχνίδια όπως το πινγκ-πονγκ κάθε πόντος μπορεί να θεωρηθεί ανταμοιβή, ενώ στο σκάκι η ανταμοιβή επιστρέφεται μόνο στο τέλος του παιχνιδιού [39]. Η παραπάνω διαδικασία έχει ως στόχο την εύρεση μιας πολιτικής αντιστοίχισης καταστάσεων σε ενέργειες η οποία θα οδηγήσει τον πράκτορα στη μεγιστοποίηση της σωρευτικής ανταμοιβής του [41]. Όταν ο πράκτορας καλείται να επιλέξει την επόμενη ενέργεια, βρίσκεται συχνά αντιμέτωπος με το δίλλημα της εξερεύνησης ή εκμετάλλευσης (exploration or exploitation). Αφενός, σε περίπτωση που προτιμήσει μία κίνηση που ήδη γνωρίζει πως είναι αποτελεσματική, δηλαδή αν εκμεταλλευτεί την κατακτηθείσα γνώση, ίσως οδηγηθεί ταχύτερα στη μεγιστοποίηση της ανταμοιβής. Ωστόσο, με αυτό τον τρόπο ίσως χάσει την ευκαιρία να ανακαλύψει ενέργειες που θα αποδεικνύονταν βέλτιστες [42]. Η ενισχυτική μάθηση διαφοροποιείται από την επιβλεπόμενη μάθηση καθώς στην πρώτη δεν υπάρχουν ετικέτες που αναπριστούν την επιθυμητή έξοδο. Αντίθετα, μετά από κάθε ενέργεια ο πράκτορας λαμβάνει μία απολαβή χωρίς να του γνωστοποιείται ποια ήταν στην πραγματικότητα η επιλογή που θα επέφερε το βέλτιστο

αποτέλεσμα [41]. Ακόμη, παρόλο που η μη επιβλεπόμενη μάθηση δεν διέπεται επίσης από την εκ των προτέρων γνώση της επιθυμητής εξόδου, δεν ταυτίζεται με την ενισχυτική μάθηση αφού σκοπός της δεύτερης είναι η μεγιστοποίηση μιας ανταμοιβής και όχι η ανακάλυψη δομών στα δεδομένα [42].

2.3.2 Ταξινόμηση

Τα μοντέλα επιβλεπόμενης μάθησης των οποίων η έξοδος λαμβάνει διακριτές τιμές καλούνται μοντέλα ταξινόμησης (classification). Η ταξινόμηση μπορεί να είναι είτε δυαδική, είτε πολλαπλών κλάσεων (multiclass). Στην πρώτη περίπτωση, οι κλάσεις στις οποίες ταξινομούνται τα παραδείγματα είναι δύο, ενώ στη δεύτερη περισσότερες. Παρόλο που στην πλειονότητα των προβλημάτων κάθε παρατήρηση ανήκει υποχρεωτικά σε μία μόνο κλάση, υπάρχουν προβλήματα ταξινόμησης πολλαπλών ετικετών (multilabel classification), όπου κάθε παρατήρηση μπορεί να αντιστοιχίζεται ταυτόχρονα σε περισσότερες από μία ετικέτες. Κάποιες από τις σημαντικότερες μεθόδους ταξινόμησης είναι η Λογιστική Παλινδρόμηση, ο ταξινομητής K-πλησιέστερων γειτόνων (KNN), τα Δέντρα Αποφάσεων, τα Τυχαία Δάση, η ταξινόμηση κατά Bayes οι Μηχανές Διανυσμάτων Στήριξης (Support Vector Machine – SVM), και τα Τεχνητά Νευρωνικά Δίκτυα. Τα τελευταία θα περιγραφούν αναλυτικά στο επόμενο κεφάλαιο.

2.3.3 Παλινδρόμηση

Τα μοντέλα επιβλεπόμενης μάθησης των οποίων η έξοδος είναι συνεχής ονομάζονται μοντέλα παλινδρόμησης (regression). Η πιο δημοφιλής μέθοδος αυτής της κατηγορίας είναι η γραμμική παλινδρόμηση. Άλλες ευρέως χρησιμοποιούμενες τεχνικές είναι η παλινδρόμηση με Δέντρα Αποφάσεων, η παλινδρόμηση με Τυχαία Δάση και η παλινδρόμηση μέσω Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM).

2.3.4 Συσταδοποίηση

Σε ένα πρόβλημα συσταδοποίησης, ο αλγόριθμος καλείται να ανακαλύψει εγγενείς δομές και τάσεις στα δεδομένα, χωρίς την καθοδήγηση κάποιας πρότερης γνώσης, με στόχο να τα αντιστοιχήσει σε ένα πεπερασμένο σύνολο άγνωστων συστάδων (clusters)

βάσει της ομοιότητάς τους. Το σύνολο των παραγόμενων συστάδων πρέπει ιδανικά να χαρακτηρίζεται από υψηλή ομοιότητα μεταξύ των σημείων εντός της κάθε συστάδας και, παράλληλα, χαμηλή ομοιότητα ανάμεσα στα σημεία που ανήκουν σε διαφορετικές συστάδες. Καθοριστικής σημασίας στη συσταδοποίηση είναι η χρήση ενός κατάλληλου κριτηρίου το οποίο θα ορίζει πόσο «όμοια» ή «ανόμοια» είναι τα διανύσματα των χαρακτηριστικών καθώς και η επιλογή του αλγορίθμου, αφού πολλές φορές διαφορετικοί αλγόριθμοι παράγουν διαφορετικά αποτελέσματα τα οποία στη συνέχεια χρίζουν περαιτέρω αξιολόγησης.

Δύο βασικά είδη συσταδοποίησης είναι η Διαμεριστική Συσταδοποίηση (Partitional Clustering) και η Ιεραρχική Συσταδοποίηση (Hierarchical Clustering). Η πρώτη, δοθέντος ενός συνόλου δεδομένων αποτελούμενο από N σημεία, κατασκευάζει K ($N \geq K$) α-συσχέτιστες συστάδες, κάθε μία από τις οποίες περιέχει τουλάχιστον ένα σημείο. Στις μεθόδους αυτές, πραγματοποιείται μια αρχική ανάθεση των δεδομένων σε συστάδες και στη συνέχεια οι συστάδες επαναπροσδιορίζονται έως ότου εκπληρωθεί κάποιο κριτήριο τερματισμού. Πολλές μέθοδοι διαμεριστικής συσταδοποίησης έχουν ως στόχο την ελαχιστοποίηση κάποιας αντικειμενικής συνάρτησης [43]. Χαρακτηριστικό παράδειγμα αποτελεί ο αλγόριθμος K -μέσων (K -means) ο οποίος έχει ως στόχο την ελαχιστοποίηση της παρακάτω συνάρτησης (εξίσωση 1.1) η οποία στηρίζεται στο άθροισμα των τετραγώνων των σφαλμάτων [44]:

$$SSE(C) = \sum_{i=1}^k \sum_{x_j \in C_i} \|x_j - \mu_i\|^2 \quad (1.1)$$

όπου Σ μια συσταδοποίηση της μορφής C_1, C_2, \dots, C_k με k πλήθος συστάδων και μ_i ο μέσος όλων των σημείων της συστάδας C_i .

Αντίθετα, η ιεραρχική συσταδοποίηση δημιουργεί μια ακολουθία ένθετων διαμερίσεων που μπορούν να οπτικοποιηθούν με τη χρήση δενδρικών γραφημάτων τα οποία καλούνται δενδρογράμματα. Τα συγκεκριμένα γραφήματα ιεραρχούν τις συστάδες με τέτοιο τρόπο ώστε το χαμηλότερο επίπεδο, το οποίο αναπαριστά τα φύλλα του δένδρου, να αποτελείται από ξεχωριστές συστάδες για κάθε σημείο, ενώ το υψηλότερο επίπεδο, το οποίο συμβολίζει τη ρίζα, να περιλαμβάνει μία συστάδα η οποία περιέχει όλα τα σημεία. Με τη σειρά τους, οι ιεραρχικοί αλγόριθμοι διακρίνονται σε συσσωρευτικούς (agglomerative) και διαιρετικούς (divisive). Οι συσσωρευτικοί αλγόριθμοι λειτουργούν συνθετικά, αναθέτοντας αρχικά κάθε σημείο σε μία ξεχωριστή συστάδα και συγχωνεύοντας επαναληπτικά τις συστάδες με την μεγαλύτερη ομοιότητα έως ότου δημιουργηθεί μία τελική συστάδα στην οποία ανήκουν όλα τα σημεία. Απεναντίας, οι διαιρετικοί αλγόριθμοι ακολουθούν την αντίστροφη διαδικασία, δηλαδή θεωρούν αρχικά το σύνολο των σημείων ως μία συστάδα και στη συνέχεια σε κάθε βήμα διαχωρίζουν μία συστάδα μέχρι η κάθε συστάδα να αποτελείται από ένα μόνο σημείο [44].

Ένα ακόμη είδος συσταδοποίησης είναι η βασισμένη στην πυκνότητα συσταδοποίηση.

Οι συστάδες που παράγονται από τους συγκεκριμένους αλγόριθμους σχηματίζονται από πυκνές περιοχές σημείων ανάμεσα στις οποίες παρεμβάλλονται περιοχές χαμηλής πυκνότητας. Ο συγκεκριμένος τύπος συσταδοποίησης είναι ιδιαίτερα χρήσιμος σε περιπτώσεις κοίλων συστάδων, όπου πολλές φορές σημεία τα οποία ανήκουν στην ίδια συστάδα έχουν μεγαλύτερη απόσταση από τα σημεία διαφορετικών συστάδων. Ένας δημοφιλής αλγόριθμος είναι ο DBSCAN. Μία ακόμη κατηγορία μεθόδων αποτελεί η συσταδοποίηση βασισμένη σε γράφους. Σε αυτήν, τα δεδομένα οργανώνονται σε γράφους των οποίων οι κορυφές αναπαριστούν τα σημεία που ο αλγόριθμος καλείται να ομαδοποιήσει και οι ακμές περιλαμβάνουν βάρη που ποσοτικοποιούν την ομοιότητα μεταξύ των προσιπιπόντων κόμβων. Πολλές από αυτές τις μεθόδους λειτουργούν κατασκευάζοντας τη μήτρα ομοιότητας, η οποία όταν είναι θετικά ημιορισμένη μπορεί να θεωρηθεί μήτρα πυρήνα. Βάσει αυτού, μπορεί να ειπωθεί πως υπάρχει σύνδεση μεταξύ των δύο αυτών κατηγοριών συσταδοποίησης [44].

Καθώς στη συσταδοποίηση δεν υπάρχει κάποια δεδομένη αλήθεια αναφορικά με τα δεδομένα, η αξιολόγηση των αποτελεσμάτων δεν είναι τόσο εύκολη όσο στην περίπτωση της ταξινόμησης. Η επαλήθευση της εγκυρότητας και η αξιολόγηση των συστάδων (cluster validation and assessment) περιλαμβάνει κατά κύριο λόγο την αποτίμηση συσταδοποίησης (clustering evaluation), τη σταθερότητα συσταδοποίησης (clustering stability) και την τάση συσταδοποίησης (clustering tendency). Η πρώτη μετρά την ποιότητα των αποτελεσμάτων, η δεύτερη αφορά την ευαισθησία του αποτελέσματος στις διάφορες παραμέτρους, όπως ο αριθμός των συστάδων k , ενώ η τελευταία εκτιμά κατά πόσο το σύνολο των δεδομένων περιέχει κάποιες εγγενείς δομές και, επομένως, θεωρείται κατάλληλο για την εφαρμογή μεθόδων συσταδοποίησης. Οι παραπάνω διαδικασίες βασίζονται σε μέτρα και στατιστικές εγκυρότητας που διακρίνονται σε τρεις κατηγορίες. Τα εξωτερικά μέτρα χρησιμοποιούν κριτήρια τα οποία δεν προκύπτουν άμεσα από το σύνολο δεδομένων, αλλά στηρίζονται σε εξωγενή πληροφορία, όπως η ύπαρξη ετικετών. Τα εσωτερικά μέτρα βασίζονται σε κριτήρια που πηγάζουν αποκλειστικά από τα δεδομένα, όπως μετρικές απόστασης εντός κάποιας συστάδας ή μεταξύ διαφορετικών συστάδων. Τέλος, τα σχετικά μέτρα συγκρίνουν διαφορετικά αποτελέσματα συσταδοποίησης, τα οποία συνήθως παράγονται από διαφορετικούς συνδυασμούς τιμών των παραμέτρων του ίδιου αλγόριθμου [44].

2.3.5 Μείωση Διαστατικότητας

Σε πολλές πραγματικές εφαρμογές χρησιμοποιούνται δεδομένα πολλών διαστάσεων, όπως γονιδιακά δεδομένα, εικόνες ή κείμενο. Κοινό στοιχείο των δεδομένων αυτών είναι ότι το πλήθος των χαρακτηριστικών p είναι πολύ μεγάλο, πολλές φορές μεγαλύτερο από τον αριθμό των παρατηρήσεων n . Όταν ισχύει ότι $p \gg n$, παρουσιάζονται ορι-

σμένες προκλήσεις για τις μεθόδους μάθησης. Κάποια από τα προφανή προβλήματα αποτελούν οι υψηλές απαιτήσεις σε αποθηκευτικό χώρο και υπολογιστική ισχύ καθώς και ο απαγορευτικός χρόνος εκτέλεσης. Εκτός όμως από τις παραπάνω δυσκολίες, τα «small n, large p» δεδομένα έχουν ορισμένες επιπλέον ιδιότητες οι οποίες επιδρούν κατασταλτικά στην απόδοση των μοντέλων μάθησης.

Η απόδοση ενός ταξινομητή καθορίζεται από την αλληλοσυσχέτιση μεταξύ του μεγέθους του δείγματος, του πλήθους των χαρακτηριστικών και της πολυπλοκότητας του μοντέλου [45]. Διαισθητικά, θα μπορούσε να γίνει η υπόθεση πως όσο περισσότερα χαρακτηριστικά υπάρχουν στο σύνολο των δεδομένων, τόσο περισσότερη πληροφορία για το πρόβλημα είναι διαθέσιμη, και επομένως τόσο αποτελεσματικότερο θα είναι το μοντέλο που θα κατασκευαστεί. Ωστόσο, προκειμένου να εκτιμηθεί μια συνάρτηση με συγκεκριμένη ακρίβεια, ο αριθμός των παραδειγμάτων εκπαίδευσης που απαιτείται αυξάνει εκθετικά με τον αριθμό των μεταβλητών είόδου, δηλαδή των χαρακτηριστικών του προβλήματος [46]. Ο Αμερικανός μαθηματικός Richard Ernest Bellman ήταν ο πρώτος που αναφέρθηκε στο συγκεκριμένο φαινόμενο με τον χαρακτηρισμό «*Κατάρα της διαστατικότητας*» το 1961 [47]. Σήμερα, ο όρος αυτός έχει επικρατήσει να χρησιμοποιείται για να περιγράψει οποιαδήποτε δυσκολία παρουσιάζεται εξαιτίας του μεγάλου πλήθους χαρακτηριστικών ενός προβλήματος [48]. Επομένως, όταν το πλήθος των δειγμάτων είναι σταθερό, η μεγάλη αύξηση των διαστάσεων συνεπάγεται μειωμένη απόδοση του μοντέλου.

Η προσθήκη διαστάσεων οδηγεί στην αύξηση του όγκου του χώρου των χαρακτηριστικών, με αποτέλεσμα τα δεδομένα να καθίστανται αραιά. Σε τέτοιες περιπτώσεις, είναι εφικτή η εύρεση μιας ευθείας η οποία διαχωρίζει τέλεια τις παρατηρήσεις. Είναι γεγονός ότι όσο αυξάνεται η διαστατικότητα, τόσο πιο εύκολος είναι ο διαχωρισμός των δεδομένων. Ωστόσο, το παραπάνω φαινόμενο παρατηρείται εξαιτίας της εκθετικής αύξησης της αραιότητας του χώρου των χαρακτηριστικών, και όχι ως επακόλουθο της εκμάθησης κάποιας ουσιαστικής γνώσης από τον ταξινομητή. Ως εκ τούτου, το μοντέλο, ενώ είναι εξαιρετικά αποτελεσματικό στο σύνολο των δεδομένων εκπαίδευσης, έχει μικρή ικανότητα γενίκευσης, δηλαδή παρουσιάζει ιδιαίτερα χαμηλή απόδοση όταν κληθεί να ταξινομήσει άγνωστα παραδείγματα. Το παραπάνω φαινόμενο ονομάζεται «υπερπροσαρμογή» (overfitting) και αποτελεί μία από τις σημαντικότερες προκλήσεις της υψηλής διαστατικότητας.

Μια ακόμη συνέπεια της αραιότητας είναι πως δημιουργείται η εντύπωση ότι όλα τα σημεία ισαπέχουν, γεγονός που επιδρά αρνητικά στις μεθόδους που βασίζονται σε κάποιο μέτρο απόστασης. Πιο αναλυτικά, καθώς αυξάνει το πλήθος των διαστάσεων, ο λόγος των αποστάσεων του κοντινότερου προς τον περισσότερο απομακρυσμένο γείτονα ενός σημείου τείνει στο 1, δηλαδή κάθε παρατήρηση φαίνεται να ισαπέχει από όλες τις υπόλοιπες [49]. Στην περίπτωση του αλγορίθμου K-Κοντινότερων Γειτόνων (K-NN) με χρήση της ευκλείδειας απόστασης, η τιμή της απόστασης του περισσότερο απομακρυσμένου γείτονα ενός σημείου προσεγγίζει εκείνη της απόστασης του εγγύτερου γείτονα


όταν οι διαστάσεις αυξηθούν μόλις στις 15 [50]. Επομένως, σε αυτού του είδους τα προβλήματα, η επιλογή της κλάσης βάσει ενός κριτηρίου απόστασης δεν λειτουργεί αποτελεσματικά. Επιπλέον, στη συσταδοποίηση, όπου οι περισσότερες τεχνικές βασίζονται σε ένα μέτρο απόστασης το οποίο προσδιορίζει την ομοιότητα μεταξύ των σημείων, προκειμένου οι συστάδες που θα προκύψουν να έχουν ουσιαστική σημασία, πρέπει οι αποστάσεις μεταξύ των σημείων της ίδιας συστάδας να είναι μικρότερες συγκριτικά με τις αποστάσεις τους από τα σημεία που ανήκουν στις υπόλοιπες συστάδες. Κατά συνέπεια, όταν όλα τα δείγματα δίνουν την εντύπωση πως είναι εξίσου όμοια ή ανόμοια δεν είναι εφικτός ο σχηματισμός ομάδων που θα παρέχουν κάποια χρήσιμη πληροφορία.

Προκειμένου να αμβλυνθούν οι συνέπειες της υψηλής διαστατικότητας, εφαρμόζονται τεχνικές μείωσης διάστασης οι οποίες στοχεύουν στην εύρεση μιας αντιπροσωπευτικής αναπαραστάσης χαμηλών διαστάσεων των δεδομένων [51]. Αυτές οι μέθοδοι, διακρίνονται σε δύο κατηγορίες ανάλογα με την προσέγγιση που ακολουθούν. Οι τεχνικές επιλογής χαρακτηριστικών (feature selection) ή μείωσης χαρακτηριστικών (feature reduction) λειτουργούν επιλέγοντας ένα υποσύνολο αντιπροσωπευτικών μεταβλητών, δηλαδή μεταβλητών που παρέχουν σημαντική πληροφορία για τη διάκριση μεταξύ των κλάσεων, και απορρίπτουν τις υπόλοιπες. Το βέλτιστο υποσύνολο θεωρείται εκείνο το οποίο αποτελείται από τις λιγότερες μεταβλητές και, παράλληλα, περιέχει την περισσότερη χρήσιμη πληροφορία [52]. Αντιθέτως, οι μέθοδοι εξαγωγής χαρακτηριστικών (feature extraction) παράγουν έναν νέο υποχώρο χαμηλών διαστάσεων, εφαρμόζοντας κατάλληλους μετασχηματισμούς στα αρχικά χαρακτηριστικά. Δηλαδή, δημιουργούν νέες μεταβλητές οι οποίες συνοψίζουν το μεγαλύτερο μέρος της πληροφορίας, ως συνδυασμό των ήδη υπάρχοντων [52]. Οι μέθοδοι επιλογής χαρακτηριστικών δύνανται να κατηγοριοποιηθούν περαιτέρω σε μεθόδους φιλτραρίσματος (filter methods), μεθόδους αναδίπλωσης (wrapper methods) και ενσωματωμένες μεθόδους (embedded methods) με βάση τον τρόπο με τον οποίο σχετίζονται με τον ταξινομητή. Οι τεχνικές εξαγωγής χαρακτηριστικών διακρίνονται σε Γραμμικές και μη Γραμμικές. Κάποιες από τις πιο αντιπροσωπευτικές γραμμικές μεθόδους είναι η Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis – PCA), η Ανάλυση Ανεξάρτητων Συνιστωσών (Independent Component Analysis – ICA) και η Γραμμική Διακριτική Ανάλυση (Linear Discriminant Analysis – LDA). Αντίστοιχα, χαρακτηριστικοί εκπρόσωποι μη γραμμικών τεχνικών αποτελούν η PCA πυρήνα (Kernel PCA), ο t-SNE και ο ISOMAP.

Κεφάλαιο 3

Τεχνητά Νευρωνικά Δίκτυα

Όπως αναφέρθηκε παραπάνω, τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks) είναι μαθηματικά μοντέλα που προσωμοιώνουν τη λειτουργία των βιολογικών νευρωνικών δικτύων του ανθρώπινου εγκεφάλου, δηλαδή τον μηχανισμό μέσω του οποίου συντελείται η διαδικασία της μάθησης στους έμβιους οργανισμούς. Αναλυτικότερα, ο ανθρώπινος εγκέφαλος αποτελείται από κύτταρα που καλούνται νευρώνες. Κάθε νευρώνας (Σχήμα 3.1) απαρτίζεται από τους δενδρίτες, οι οποίοι δέχονται τα εισερχόμενα σήματα, το σώμα που συνιστά το κέντρο επεξεργασίας του σήματος εισόδου, και τον άξονα, ο οποίος συνδέεται μέσω συνάψεων με τους δενδρίτες των επόμενων νευρώνων και μεταδίδει σε αυτούς ένα ηλεκτροχημικό σήμα. Εκτιμάται πως ο εγκέφαλος του ανθρώπου διαθέτει πάνω από 10^{11} νευρώνες και 10^{14} συνάψεις. Όταν το συνολικό φορτίο το οποίο λαμβάνεται από τους δενδρίτες υπερβαίνει ένα κατώφλι, το ουδό ενεργοποίησης (firing threshold), πυροδοτείται κατά μήκος του άξονα ένα ηλεκτροχημικό σήμα. Η μάθηση στους βιολογικούς οργανισμούς πραγματοποιείται μέσω της μεταβολής των δυνάμεων των συναπτικών συνδέσεων βάσει εξωτερικών ερεθισμάτων.



Σχήμα 3.1: Βιολογικός νευρώνας [53]

Κατ' αντιστοιχία, τα Τεχνητά Νευρωνικά Δίκτυα αποτελούνται από υπολογιστικές μονάδες που ονομάζονται νευρώνες. Οι μονάδες αυτές οργανώνονται σε διαφορετικά επίπεδα και συνδέονται μεταξύ τους χρησιμοποιώντας βάρη τα οποία προσδιορίζουν τη σημαντικότητα κάθε σύνδεσης. Η μάθηση συνιστά το στάδιο κατά το οποίο πραγματοποιείται ο προσδιορισμός των κατάλληλων τιμών των βαρών του μοντέλου, χρησιμοποιώντας ένα σύνολο δεδομένων εκπαίδευσης. Τα δεδομένα αυτά αποτελούνται συνήθως από γνωστά παραδείγματα εισόδου - εξόδου, όπως εικονοστοιχεία ως είσοδο και ετικέτες που αντιπροσωπεύουν την κλάση στην οποία ανήκει κάθε εικόνα ως εξόδο. Κατά τη διάρκεια της εκπαίδευσης, τα βάρη επαναπροσδιορίζονται με βάση τα γνωστά παραδείγματα, προκειμένου τελικά το μοντέλο να καταστεί ικανό να πραγματοποιεί προβλέψεις όταν τροφοδοτηθεί με άγνωστα δεδομένα. Τα Τεχνητά Νευρωνικά Δίκτυα μπορούν να διακριθούν σε δύο ευρείες κατηγορίες ανάλογα με την αρχιτεκτονική τους. Τα δίκτυα εμπρόσθιας τροφοδότησης αποτελούν τη συνηθέστερη μορφή νευρωνικών δικτύων και χαρακτηρίζονται από καταναγκαστική ροή της πληροφορίας προς τα εμπρός, δηλαδή οι νευρώνες ενός επιπέδου δεν επιτρέπεται να λαμβάνουν ως είσοδο τις εξόδους των νευρώνων που ανήκουν στο ίδιο ή σε επόμενο επίπεδο. Αντίθετα, τα επανατροφοδοτούμενα δίκτυα (Recurrent Neural Networks - RNN) περιέχουν τουλάχιστον μία ανάδραση, είτε μεταξύ νευρώνων του ίδιου επιπέδου είτε ανάμεσα σε νευρώνες διαφορετικών επιπέδων. Ακόμη, είναι πιθανό να υπάρχει ανάδραση η οποία να ξεκινάει από έναν νευρώνα και να καταλήγει στον ίδιο.

Η ιδέα για την ανάπτυξη ενός μαθηματικού μοντέλου που θα προσωμοιώνει τη λειτουργία του ανθρώπινου εγκεφάλου θεωρείται πως παρουσιάστηκε πρώτη φορά το 1943 από τον νευροφυσιολόγο Warren McCulloch και τον δεκαοκτάχρονο, τότε, πρωτοετή φοιτητή μαθηματικών Walter Pitts [54]. Οι δύο ερευνητές πρότειναν το πρώτο μοντέλο Τεχνητού Νευρωνικού Δικτύου, υποστηρίζοντας πως ένα νευρωνικό δίκτυο απαρτίζεται από πληθώρα νευρώνων, ενώ παράλληλα, παρομοίωσαν το μηχανισμό λειτουργίας των νευρώνων και των συνάψεών τους με εκείνο ενός ηλεκτρικού κυκλώματος [55]. Λίγα χρόνια αργότερα, το 1949, ο Donald Hebb στο βιβλίο του *"The organization of behavior"* πρότεινε πως οι νευρωνικές συνδέσεις ενισχύονται κάθε φορά που χρησιμοποιούνται και πως το γεγονός αυτό διαδραματίζει κομβικό ρόλο στη διαδικασία της μάθησης [56]. Ισοχυρίστηκε πως όταν δύο νευρώνες πυροδοτούνται την ίδια στιγμή, η σύνδεση μεταξύ τους ενδυναμώνεται. Ως απόρροια των παραπάνω, το 1958, ο Frank Rosenblatt, βασισμένος στο μοντέλο των McCulloch και Pitts και στο έργο του Hebb, πρότεινε το μοντέλο του αισθητήρα (perceptron), το οποίο αποτέλεσε τη βάση για την ανάπτυξη των σύγχρονων νευρωνικών δικτύων [57]. Το συγκεκριμένο μοντέλο είναι εμπνευσμένο από εκείνο των McCulloch και Pitts, ωστόσο παρουσιάζει ορισμένες σημαντικές διαφορές, όπως το γεγονός πως οι είσοδοι δεν περιορίζονται σε δυαδικές τιμές και πως τα βάρη καθορίζονται μέσω ενός μηχανισμού εκμάθησης. Δυο χρόνια αργότερα, το 1960, οι μηχανικοί Bernard Widrow και Marcian Hoff ανέπτυξαν το μοντέλο ADALINE (Adaptive Linear Element), στο οποίο η ανανέωση των τιμών των βαρών πραγματοποιείται με τη μέθοδο των Ελάχιστων Μέσων Τετραγώνων (Least Mean Squares - LMS) [58].

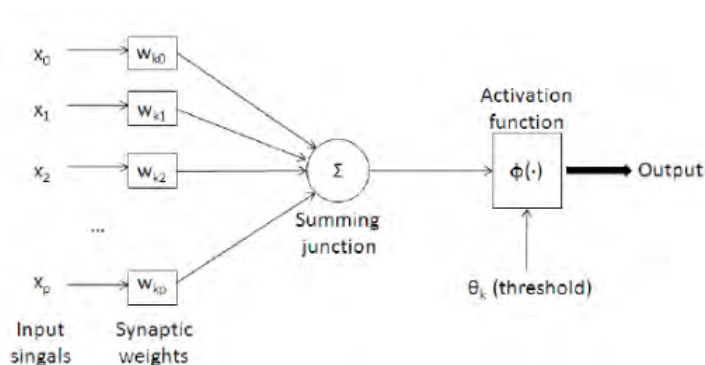
Το MADALINE (Many ADALINEs), που δημιουργήθηκε την ίδια χρονιά, ήταν το πρώτο μοντέλο νευρωνικών δικτύων που εφαρμόστηκε σε πρόβλημα του πραγματικού κόσμου, αφού αξιολογήθηκε για τον περιορισμό της ηχούς στις τηλεφωνικές γραμμές.

Έπειτα από τις παραπάνω εξελίξεις, ακολούθησε μια περίοδος μειωμένου ενδιαφέροντος και απογοήτευσης, με την έρευνα να οδηγείται σε τέλμα και τις υψηλές προσδοκίες που είχαν δημιουργηθεί να μην έχουν εκπληρωθεί. Η έκδοση του βιβλίου των Minsky και Papert με τίτλο *"Perceptrons: An Introduction to Computational Geometry"* το 1969, ενίσχυσε περαιτέρω το ήδη αρνητικό κλίμα [59]. Στο συγκεκριμένο έργο, οι συγγραφείς επισήμαναν τις περιορισμένες ικανότητες του perceptron, αποδεικνύοντας πως το απλό αυτό μοντέλο αδυνατούσε να λύσει μη γραμμικώς διαχωρίσιμα προβλήματα, όπως η μοντελοποίηση της πύλης XOR. Εντούτοις, το συγκεκριμένο διάστημα, πραγματοποιήθηκαν κάποια σημαντικά βήματα προόδου στο πεδίο, όπως η ανάπτυξη του αλγορίθμου οπισθοδιάδοσης σφάλματος (back-propagation) από τον Paul Werbos το 1974, η αξία της οποίας όμως δεν αναγνωρίστηκε έως και τα μέσα της δεκαετίας του 1980. Το 1982, ο John Hopfield απέδειξε με μαθηματικό τρόπο πως ένα αναδρομικό νευρωνικό δίκτυο μπορεί να αξιοποιηθεί ως αποθηκευτικός χώρος. Το έργο του προκάλεσε τον θαυμασμό πολλών επιφανών επιστημόνων της εποχής και συνέβαλε σημαντικά στην ανάκαμψη του πεδίου [60]. Έπειτα, το 1986, οι Rumelhart, Hinton και Williams θεμελίωσαν με μαθηματικό τρόπο και παρουσίασαν αναλυτικά τον αλγόριθμο οπισθοδιάδοσης σφάλματος που είχε προταθεί νωρίτερα από τον Werbos, με αποτέλεσμα η μέθοδος να προσελκύσει την προσοχή της επιστημονικής κοινότητας και, εν τέλει, να καθιερωθεί ως η δημοφιλέστερη τεχνική εκπαίδευσης νευρωνικών δικτύων [61]. Από τότε έως σήμερα, έχει σημειωθεί αλματώδης πρόοδος στο πεδίο, με τα νευρωνικά δίκτυα να έχουν εξελιχθεί σε ανεξάρτητη επιστημονική περιοχή. Οι αλγόριθμοι βαθιάς μάθησης έχουν καταφέρει να αντιμετωπίσουν προβλήματα που παρέμεναν άλυτα για χρόνια από τις παραδοσιακές μεθόδους μηχανικής μάθησης. Η ικανότητά τους να ανακαλύπτουν εγγενείς δομές σε δεδομένα υψηλής διαστατικότητας, τους καθιστά ιδιαίτερος αποτελεσματικούς σε προβλήματα όπως η ταξινόμηση εικόνων, η αναγνώριση φωνής, η πρόβλεψη της επίδρασης μεταλλάξεων στην γονιδιακή έκφραση, η ανάλυση συναισθήματος και η αυτόματη μετάφραση [62].

3.1 Μοντέλο Τεχνητού Νευρώνα

Ο τεχνητός νευρώνας συνιστά την απλούστερη υπολογιστική μονάδα που προσεγγίζει το μηχανισμό λειτουργίας ενός βιολογικού νευρώνα. Συγκεκριμένα, κάθε νευρώνας δέχεται ένα σύνολο εισόδων x_1, x_2, \dots, x_p , κάθε μία από τις οποίες πολλαπλασιάζεται με μία τιμή βάρους $w_{k1}, w_{k2}, \dots, w_{kp}$. Οι τιμές των βαρών στον τεχνητό νευρώνα αντιστοιχούν στα βάρη των συναπτικών συνδέσεων των βιολογικών νευρώνων. Ουσιαστικά, πραγματοποιείται ο υπολογισμός του εσωτερικού γινομένου των διανυσμάτων x και w . Η είσοδος x_0 λαμβάνει πάντα την τιμή 1 και πολλαπλασιάζεται με το βάρος που της αναλογεί, το οποίο συμβολίζεται ως w_{k0} . Το συγκεκριμένο σήμα εισόδου καλείται πόλωση (bias). Εφόσον, το x_0 αποτελεί σταθερά με τιμή 1, η πόλωση αναφέρεται πρακτικά στην αντίστοιχη τιμή βάρους της εισόδου, δηλαδή στο w_{k0} . Στη συνέχεια, οι παραπάνω ποσότητες εισέρχονται στο σώμα του τεχνητού νευρώνα, το οποίο αποτελείται από τον αθροιστή και τη συνάρτηση ενεργοποίησης. Ο αθροιστής, όπως υποδηλώνει και η ονομασία του, αθροίζει τα γινόμενα $x_i \cdot w_{ki}$, όπου $i=0, \dots, p$. Το αποτέλεσμα του αθροιστή λαμβάνεται ως είσοδος από την συνάρτηση ενεργοποίησης ϕ , η οποία παράγει την τελική έξοδο y [8]. Βάσει των παραπάνω, η έξοδος y μπορεί να υπολογιστεί από την παρακάτω σχέση (εξίσωση 3.1):

$$y = \phi \left(\sum_{i=0}^p w_{ki} \cdot x_i \right) \quad (3.1)$$



Σχήμα 3.2: Μαθηματικό μοντέλο τεχνητού νευρώνα [63]

3.2 Συναρτήσεις Ενεργοποίησης

3.2.1 Βηματική Συνάρτηση

Η βηματική συνάρτηση (step function) (εξίσωση 3.2) αποτελεί μία από τις απλούστερες συναρτήσεις ενεργοποίησης. Η έξοδος λαμβάνει την τιμή 0, όταν η είσοδος είναι μικρότερη από ένα κατώφλι θ , και 1 όταν η είσοδος είναι μεγαλύτερη ή ίση από αυτό το κατώφλι [64].

$$f(S) = \begin{cases} 1, & S \geq \theta \\ 0, & S < \theta \end{cases} \quad (3.2)$$

Μία παραλλαγή της βηματικής συνάρτησης είναι η συνάρτηση προσήμου (sign function) (εξίσωση 3.3) στην οποία η έξοδος λαμβάνει την τιμή 1 στην περίπτωση που η είσοδος ισούται ή υπερβαίνει μία τιμή κατωφλίου θ , διαφορετικά λαμβάνει την τιμή -1 [65].

$$f(S) = \begin{cases} 1, & S \geq \theta \\ -1, & S < \theta \end{cases} \quad (3.3)$$


Οι παραπάνω συναρτήσεις, χάρις στην απλότητά τους, θεωρούνται κατάλληλες για γραμμικά προβλήματα δυαδικής ταξινόμησης, όπως η μοντελοποίηση των λογικών πυλών AND ή OR, τα οποία μπορούν να επιλυθούν από έναν μόνο αισθητήρα. Ωστόσο, σε σύνθετα νευρωνικά δίκτυα δεν είναι αποτελεσματικές, καθώς ο αλγόριθμος οπισθοδιάδοσης σφάλματος που χρησιμοποιείται στην πλειονότητα των περιπτώσεων για την εκπαίδευση των δικτύων απαιτεί τη χρήση παραγωγίσιμων συναρτήσεων ενεργοποίησης.

3.2.2 Σιγμοειδής Συνάρτηση

Η σιγμοειδής συνάρτηση (εξίσωση 3.4) αποτελεί μία μη γραμμική, συνεχή και παραγωγίσιμη συνάρτηση. Η ονομασία της, προκύπτει από τη μορφή της γραφικής της παράστασης, η οποία θυμίζει το γράμμα "S". Η συγκεκριμένη συνάρτηση λαμβάνει ως είσοδο έναν πραγματικό αριθμό και τον αντιστοιχίζει σε μία τιμή του διαστήματος $[0, 1]$ [8]. Ωστόσο, ένα σημαντικό μειονέκτημα της σιγμοειδούς συνάρτησης είναι πως η πρώτη της παράγωγος λαμβάνει πολύ χαμηλές τιμές, με την υψηλότερη τιμή που μπορεί να λάβει να είναι το 0.25 (Σχήμα 3.3). Συνεπώς, σε νευρωνικά δίκτυα αποτελούμενα από μεγάλο πλήθος κρυφών επιπέδων, κατά την εφαρμογή του αλγορίθμου οπισθοδιάδοσης σφάλματος, εξαιτίας των διαδοχικών πολλαπλασιασμών ποσοτήτων μικρότερων της μονάδας, οι μεταβολές των βαρών των αρχικών επιπέδων τείνουν να είναι πολύ μικρότερες συγκριτικά με εκείνες των επόμενων επιπέδων. Το φαινόμενο αυτό, καλείται πρόβλημα εξαφάνισης της κλίσης (vanishing gradient problem) [66]. Ένα επιπλέον μειονέκτημα της σιγμοειδούς συνάρτησης είναι ότι δεν είναι συμμετρική ως προς το 0.

$$f(S) = \frac{1}{1 + e^{-aS}} \quad (3.4)$$

Στην παραπάνω εξίσωση, το a ρυθμίζει την ταχύτητα μετάβασης μεταξύ των δύο ακραίων τιμών.



Σχήμα 3.3: Γράφημα σιγμοειδούς συνάρτησης (μπλε χρώμα) και της πρώτης παραγώγου της (πράσινο χρώμα) [67]

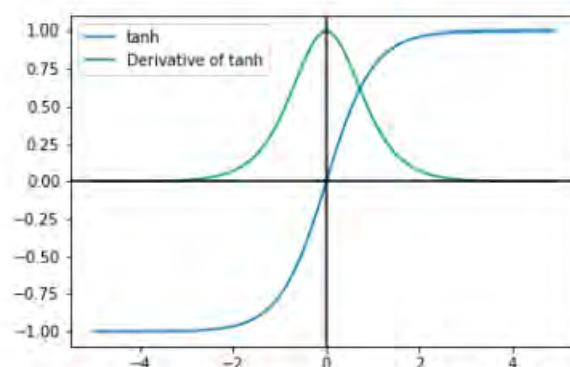
3.2.3 Υπερβολική Εφαπτομένη

Η υπερβολική εφαπτομένη (hyperbolic tangent) (εξίσωση 3.5) εμφανίζει μεγάλη ομοιότητα με τη σιγμοειδή συνάρτηση, με τη διαφορά πως αντιστοιχίζει έναν πραγματικό αριθμό στο διάστημα $[-1,1]$ [8]. Όπως γίνεται αντιληπτό, η συγκεκριμένη συνάρτηση είναι συμμετρική ως προς το 0, ωστόσο, ομοίως με τη σιγμοειδή συνάρτηση, είναι και αυτή επιρρεπής στο πρόβλημα εξαφάνισης της κλίσης. Η υπερβολική εφαπτομένη προτιμάται σε περιπτώσεις όπου απαιτείται η έξοδος να λαμβάνει τόσο θετικές όσο και αρνητικές τιμές.

$$f(S) = \tanh(S) = \frac{e^{a \cdot S} - e^{-a \cdot S}}{e^{a \cdot S} + e^{-a \cdot S}} \quad (3.5)$$

Ομοίως με προηγουμένως, το a είναι ένας συντελεστής ρύθμισης της ταχύτητας μετάβασης μεταξύ των δύο ακραίων τιμών. Ουσιαστικά, η σιγμοειδής συνάρτηση και η υπερβολική εφαπτομένη συνδέονται με την παρακάτω σχέση (εξίσωση 3.6) [8]:

$$\tanh(S) = 2 \cdot \text{sigmoid}(2 \cdot S) - 1 \quad (3.6)$$



Σχήμα 3.4: Γράφημα υπερβολικής εφαπτομένης (μπλε χρώμα) και της πρώτης παραγώγου της (πράσινο χρώμα) [67]

3.2.4 Rectified Linear Unit (ReLU)

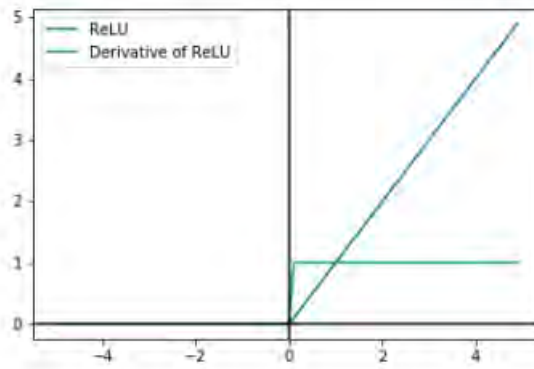
Η συνάρτηση ReLU (εξίσωση 3.7) είναι μία από τις δημοφιλέστερες συναρτήσεις ενεργοποίησης. Για τιμές εισόδου που υπερβαίνουν το μηδέν, η συνάρτηση παράγει την ίδια την τιμή, ενώ σε αντίθετη περίπτωση η έξοδος μηδενίζεται. Καθώς η έξοδος για αρνητικές τιμές ισούται με το μηδέν, οι ενεργοποιήσεις των νευρώνων στο δίκτυο είναι αραιότερες με αποτέλεσμα να μειώνονται το υπολογιστικό κόστος και ο απαιτούμενος χρόνος υπολογισμών. Ωστόσο, το χαρακτηριστικό αυτό μπορεί να οδηγήσει ένα μεγάλο μέρος των νευρώνων του δικτύου να μην πυροδοτούνται ανεξαρτήτως των δεδομένων. Όταν ένας νευρώνας βρεθεί σε αυτή την κατάσταση, τα βάρη του παύουν να ανανεώνονται κατά τη διάρκεια της εκπαίδευσης, ενώ παράλληλα, η έξοδος του δε διαφοροποιείται πλέον βάσει των περιπτώσεων εισόδου και, επομένως, σταματά να συνεισφέρει στη διάκριση των κλάσεων. Στην περίπτωση αυτή, ο νευρώνας θεωρείται “νεκρός” με το συγκεκριμένο φαινόμενο να αναφέρεται συχνά ως “dying ReLU”. Η “νέκρωση” των νευρώνων δε συνιστά πάντα πρόβλημα. Όταν όμως το πλήθος τους υπερβεί ένα αποδεκτό όριο, ένα μεγάλο μέρος του δικτύου καταλήγει ανενεργό. Επιπλέον, δεν είναι επιθυμητό να νεκρώνεται μεγάλος αριθμός νευρώνων στα αρχικά στάδια της εκπαίδευσης, όταν ακόμα η απόδοση του μοντέλου δεν είναι αρκετά καλή [66].

$$f(u) = \max\{0, u\} \quad (3.7)$$

Προκειμένου να αντιμετωπιστεί το πρόβλημα που περιγράφηκε παραπάνω, μπορεί να χρησιμοποιηθεί μια τροποποιημένη εκδοχή της ReLU, η Leaky ReLU (εξίσωση 3.8), η οποία σε περίπτωση αρνητικών εισόδων μπορεί να προωθήσει μια μικρή κλίση προς τα πίσω [66].

$$f(u) = \begin{cases} a \cdot u, & u \leq 0 \\ u, & u > 0 \end{cases} \quad (3.8)$$

Στην παραπάνω σχέση, η υπερπαραμέτρος $a < 1$ καθορίζει το ρυθμό με τον οποίο διαρρέεται η κλίση προς τα πίσω.



Σχήμα 3.5: Γράφημα ReLU (μπλε χρώμα) και της πρώτης παραγώγου της (πράσινο χρώμα) [67]

3.2.5 Softmax

Η συνάρτηση ενεργοποίησης softmax είναι ιδιαίτερως χρήσιμη σε προβλήματα ταξινόμησης πολλαπλών κλάσεων, όπου χρησιμοποιείται συνήθως στο επίπεδο εξόδου με σκοπό να εκφράσει την έξοδο του δικτύου ως πιθανότητα η είσοδος να ανήκει σε κάποια από τις κλάσεις. Η ιδιαιτερότητα της συγκεκριμένης συνάρτησης σε σχέση με τις προηγούμενες είναι ότι προκειμένου να παραχθεί η τιμή ενός νευρώνα του επιπέδου εξόδου λαμβάνονται υπόψη και οι εισοδοί των υπόλοιπων νευρώνων του ίδιου επιπέδου, αφού, δεδομένου ότι κάθε έξοδος αντιστοιχεί σε μία τιμή πιθανότητας, απαιτείται το άθροισμα όλων των εξόδων να ισούται με 1 [8]. Η συνάρτηση softmax περιγράφεται ως (εξίσωση 3.9):


$$\phi_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (3.9)$$

όπου k ο αριθμός των κλάσεων, z_i η είσοδος και ϕ_i η έξοδος του i -στού νευρώνα εξόδου.

3.3 Πολυεπίπεδα Νευρωνικά Δίκτυα

Τα Τεχνητά Νευρωνικά Δίκτυα πολλαπλών επιπέδων (Multi-Layer Perceptrons – MLP), συνιστούν αρχιτεκτονικές νευρωνικών δικτύων εμπρόσθιας τροφοδότησης, αποτελούμενες από ένα πλήθος νευρώνων οργανωμένων σε διαφορετικά επίπεδα. Κάθε πολυεπίπεδο δίκτυο απαρτίζεται από ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου. Ο ρόλος των νευρώνων του επιπέδου εισόδου είναι απλώς να λαμβάνουν δεδομένα και ως εκ τούτου δε διαθέτουν βάρη ή κάποια συνάρτηση ενεργοποίησης. Οι νευρώνες των κρυφών επιπέδων που ακολουθούν επεξεργάζονται την πληροφορία που εισήχθη στο δίκτυο από το επίπεδο εισόδου και, τελικά, το επίπεδο εξόδου παράγει τα αποτελέσματα του δικτύου. Όταν όλοι οι νευρώνες ενός επιπέδου συνδέονται με όλους τους νευρώνες του επόμενου επιπέδου, το δίκτυο καλείται πλήρως συνδεδεμένο (fully-connected), ενώ στην αντίθετη περίπτωση αναφέρεται ως μερικώς συνδεδεμένο (partially connected) [8].

Το πλήθος των κρυφών επιπέδων αποτελεί το βάθος του νευρωνικού δικτύου. Ο αριθμός των απαιτούμενων κρυφών επιπέδων διαφοροποιείται ανάλογα με το εκάστοτε πρόβλημα προς επίλυση. Σύμφωνα με το Θεώρημα Καθολικής Προσέγγισης (Universal Approximation Theorem), ένα νευρωνικό δίκτυο το οποίο περιέχει ένα μόνο κρυφό επίπεδο με πεπερασμένο πλήθος νευρώνων μπορεί να προσεγγίσει οποιαδήποτε συνεχή συνάρτηση, ανεξαρτήτως της πολυπλοκότητάς της. Μία από τις πρώτες προσπάθειες απόδειξης του συγκεκριμένου θεωρήματος πραγματοποιήθηκε από τον George Cybenko το 1989 [68], η οποία αφορούσε αποκλειστικά τα δίκτυα που χρησιμοποιούσαν σιγμοειδείς συναρτήσεις ενεργοποίησης. Δυο χρόνια αργότερα, το 1991, ο Kurt Hornik έδειξε πως η ισχύς του θεωρήματος δεν περιορίζεται στην περίπτωση εφαρμογής της σιγμοειδούς συνάρτησης, καθώς η δυνατότητα χρησιμοποίησης των δικτύων αυτών ως καθολικούς προσεγγιστές συναρτήσεων οφείλεται στην πολυεπίπεδη εμπρόσθια αρχιτεκτονική τους και όχι στην επιλογή της συνάρτησης ενεργοποίησης [69]. Ωστόσο, πρακτικά, όταν υπάρχει ένα μόνο κρυφό επίπεδο, το πλήθος των νευρώνων που απαιτείται σε αυτό για την επίλυση ενός σύνθετου προβλήματος μπορεί να είναι απαγορευτικό. Κατά συνέπεια, στις περισσότερες περιπτώσεις επιλέγεται μια αρχιτεκτονική με περισσότερα κρυφά επίπεδα και λιγότερους νευρώνες σε κάθε ένα από αυτά, μια λύση που μειώνει σημαντικά τον αριθμό των ελεύθερων παραμέτρων του μοντέλου καθώς και την ποσότητα των απαιτούμενων δεδομένων για την εκπαίδευσή του.



Σχήμα 3.6: Πολυεπίπεδο νευρωνικό δίκτυο με δύο κρυφά επίπεδα [70]

3.4 Εκπαίδευση Νευρωνικών Δικτύων

Η εκπαίδευση συνιστά τη διαδικασία κατά την οποία πραγματοποιείται ο προσδιορισμός των τιμών των παραμέτρων του δικτύου, δηλαδή των βαρών και των πολώσεων του. Αυτό μπορεί να επιτευχθεί μέσω της ελαχιστοποίησης μιας συνάρτησης απώλειας (loss function).

3.4.1 Συνάρτηση Απώλειας

Η συνάρτηση απώλειας (loss function) χρησιμοποιείται για την ποσοτικοποίηση του σφάλματος ανάμεσα στην πρόβλεψη που πραγματοποιήθηκε από το δίκτυο και την επιθυμητή έξοδο. Η επιλογή της συνάρτησης απώλειας πραγματοποιείται ανάλογα με τη φύση του προβλήματος μηχανικής μάθησης, όπως ταξινόμηση ή παλινδρόμηση, καθώς και βάσει της ειδικότερης κατηγορίας στην οποία εντάσσεται η εφαρμογή, όπως δυαδική ταξινόμηση ή ταξινόμηση πολλαπλών κλάσεων.

Σε προβλήματα παλινδρόμησης, μια συνήθης επιλογή είναι το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE), το οποίο υπολογίζεται ως εξής (εξίσωση 3.10) [71]:

$$MSE = \frac{1}{N} \cdot \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.10)$$

όπου y_i η πραγματική τιμή εξόδου της εισόδου i , \hat{y}_i η εκτιμηθείσα τιμή της εξόδου και N το πλήθος των δειγμάτων.

Στα προβλήματα ταξινόμησης χρησιμοποιείται συχνά η Εγκάρσια Εντροπία (Cross Entropy) (εξίσωση 3.11) [72]:

$$CE = - \sum_{i=1}^N y_i \cdot \log(\hat{y}_i) \quad (3.11)$$

όπου y_i η πραγματική τιμή της εξόδου, \hat{y}_i η πιθανότητα που προέβλεψε το δίκτυο και N ο αριθμός των κλάσεων.

Σε προβλήματα δυαδικής ταξινόμησης, όπου $N=2$, η παραπάνω σχέση μπορεί να εκφραστεί ως (εξίσωση 3.12) [73]:

$$CE_b = -(y \cdot \log(\hat{y}) + (1 - y) \cdot \log(1 - \hat{y})) \quad (3.12)$$

3.4.2 Αλγόριθμοι Βελτιστοποίησης

Η επιλογή του κατάλληλου αλγορίθμου βελτιστοποίησης συνιστά ένα καίριο ζήτημα κατά την εκπαίδευση ενός νευρωνικού δικτύου. Ο πιο διαδεδομένος αλγόριθμος βελτιστοποίησης, στον οποίο βασίζονται πολλές άλλες τεχνικές αυτού του είδους, είναι η κατάβαση κλίσης (Gradient Descent). Ωστόσο, με το πέρασμα των ετών έχουν προταθεί

διάφοροι βελτιστοποιητές, με σημαντικότερους εξ αυτών τους Momentum [74], Ada-Grad [75], RMSProp, Adadelta [76] και Adam [77]. Ο τελευταίος, αποτελεί μία από τις δημοφιλέστερες επιλογές καθώς συνδυάζει τα περισσότερα από τα πλεονεκτήματα των προηγούμενων μεθόδων.

Κατάβαση Κλίσης

Η συγκεκριμένη μέθοδος αποσκοπεί στην εύρεση των παραμέτρων $\theta \in \mathbb{R}^d$ του νευρωνικού δικτύου, οι οποίες οδηγούν στην ελαχιστοποίηση μιας συνάρτησης απωλειών $J(\theta)$, μέσω του υπολογισμού της μερικής παραγώγου της συνάρτησης απωλειών $\nabla_{\theta} J(\theta)$ ως προς το διάνυσμα των παραμέτρων θ . Στη συνέχεια, οι παράμετροι του δικτύου μεταβάλλονται κατά μία μικρή ποσότητα προς την αντίθετη κατεύθυνση από αυτή της μερικής παραγώγου. Η σχέση που περιγράφει την παραπάνω διαδικασία είναι η εξής (εξίσωση 3.13) [78]:

$$\theta' = \theta - \eta \cdot \nabla_{\theta} J(\theta) \quad (3.13)$$

Στην παραπάνω σχέση, το σύμβολο η καλείται ρυθμός μάθησης (learning rate), και καθορίζει το μέγεθος των "βημάτων" που πραγματοποιούνται κάθε φορά για την εύρεση ενός σημείου ελαχίστου.

Εναλλακτικά, ξεκινώντας από ένα σημείο, το οποίο μπορεί να θεωρηθεί ως κορυφή, ακολουθείται με κάποιο βηματισμό η κατεύθυνση μείωσης της συνάρτησης απωλειών, έως ότου εντοπιστεί κάποια κοιλάδα, δηλαδή κάποιο σημείο ελαχίστου. Η επιλογή της τιμής του η είναι κρίσιμη, καθώς ένας πολύ χαμηλός ρυθμός μάθησης μπορεί να καθυστερήσει σε μεγάλο βαθμό την εκπαίδευση, ενώ αντίθετα, ένας πολύ υψηλός ρυθμός μάθησης μπορεί να οδηγήσει σε ταλάντωση γύρω από μία κοιλάδα ή απόκλιση με ασταθή τρόπο. Μια στρατηγική που θεωρείται αποτελεσματική είναι η εξασθένιση του ρυθμού μάθησης με την πάροδο του χρόνου.

Ένα βασικό μειονέκτημα του αλγορίθμου Κατάβασης Κλίσης είναι πως προκειμένου να πραγματοποιηθεί μια ανανέωση βαρών, πρέπει να υπολογιστεί η μερική παράγωγος της συνάρτησης απωλειών χρησιμοποιώντας όλο το σύνολο δεδομένων εκπαίδευσης. Το γεγονός αυτό τον καθιστά μία λιγότερο συμφέρουσα επιλογή, ειδικά στις περιπτώσεις όπου η ποσότητα των δεδομένων εκπαίδευσης είναι μεγάλη. Η Στοχαστική Κατάβαση

Κλίση (Stochastic Gradient Descent - SGD) αποτελεί μια παραλλαγή της Κατάβασης Κλίσης στην οποία οι παράμετροι ανανεώνονται για κάθε παράδειγμα εκπαίδευσης της μορφής $x^{(i)}$ - $y^{(i)}$. Η διαδικασία αυτή εκφράζεται από την παρακάτω σχέση (εξίσωση 3.14) [78]:

$$\theta' = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (3.14)$$

Μία ακόμη εκδοχή του αλγορίθμου Κατάβασης Κλίσης είναι η Κατάβαση Κλίσης με μικρά σει (Mini-batch Gradient Descent), η οποία θεωρείται ενδιάμεση λύση μεταξύ των δύο προηγούμενων επιλογών. Στη συγκεκριμένη μέθοδο, επιλέγεται με τυχαίο τρόπο ένα υποσύνολο n παραδειγμάτων του συνόλου δεδομένων εκπαίδευσης και, βάσει αυτού, πραγματοποιείται η ανανέωση των παραμέτρων του δικτύου. Στην περίπτωση αυτή, η σχέση που αποτυπώνει τη διαδικασία ενημέρωσης των βαρών ακολουθεί παρακάτω (εξίσωση 3.15) [78]:

$$\theta' = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i:i+n)}; y^{(i:i+n)}) \quad (3.15)$$

Το μέγεθος των σει διαφοροποιείται ανάλογα με την εφαρμογή, ωστόσο στις περισσότερες περιπτώσεις τα υποσύνολα που επιλέγονται περιλαμβάνουν από 50 έως 256 παραδείγματα. Παρόλο που ο συγκεκριμένος αλγόριθμος μειώνει το υπολογιστικό κόστος και τον απαιτούμενο χρόνο εκπαίδευσης, έχει το μειονέκτημα πως δεν εγγυάται καλή σύγκλιση. Πολλές φορές, ο όρος SGD αναφέρεται και στην περίπτωση της Κατάβασης Κλίσης με μικρά σει [78].

Adam

Ο Adam [77] είναι ένας από τους πιο συχνά χρησιμοποιούμενους αλγορίθμους βελτιστοποίησης, καθώς συνδυάζει την πλεονότητα των πλεονεκτημάτων των υπόλοιπων αντίστοιχων μεθόδων [66]. Ο αλγόριθμος υπολογίζει τις εκτιμήσεις της ροπής πρώτης

τάξης (μέση τιμή), m_t , και της ροπής δεύτερης τάξης (μη κεντροποιημένη διακύμανση), u_t , των κλίσεων των παραμέτρων της συνάρτησης απωλειών g_t ως εξής (εξίσωση 3.16, εξίσωση 3.17):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.16)$$

$$u_t = \beta_2 u_{t-1} + (1 - \beta_2) g_t^2 \quad (3.17)$$

Καθώς τα m_t και u_t αρχικοποιούνται ως διανύσματα μηδενικών τιμών, τείνουν να εμφανίζουν μεροληψία στο μηδέν. Προκειμένου να αντιμετωπιστεί το παραπάνω πρόβλημα, οι εκτιμήτριες των παραπάνω ποσοτήτων υπολογίζονται βάσει των παρακάτω σχέσεων (εξίσωση 3.18, εξίσωση 3.19):

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.18)$$

$$\hat{u}_t = \frac{u_t}{1 - \beta_2^t} \quad (3.19)$$

Στη συνέχεια, τα βάρη ενημερώνονται σύμφωνα με την παρακάτω σχέση (εξίσωση 3.20):

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{u}_t} + \epsilon} \cdot \hat{m}_t \quad (3.20)$$

Οι προτεινόμενες τιμές για κάθε υπερπαραμέτρο είναι οι εξής: $\beta_1=0.9$, $\beta_2=0.999$ και $\epsilon = 10^{-8}$.

3.4.3 Αλγόριθμος Οπισθοδιάδοσης Σφάλματος

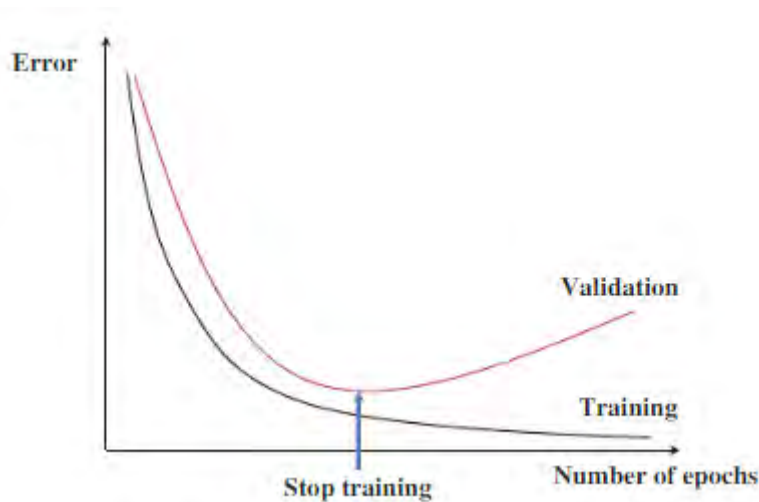
Όπως αναφέρθηκε παραπάνω, ο αλγόριθμος οπισθοδιάδοσης σφάλματος (error-back propagation) αποτελεί τη συνηθέστερη μέθοδο εκπαίδευσης νευρωνικών δικτύων, η οποία έχει αποτελέσει τη βάση για την ανάπτυξη πληθώρας άλλων αλγορίθμων. Σκοπός είναι η επαναληπτική ανανέωση των παραμέτρων του δικτύου έως ότου μειωθεί σε ικανοποιητικό βαθμό μια τιμή σφάλματος, η οποία καθορίζεται από μια συνάρτηση απώλειας. Αρχικά, τα βάρη αρχικοποιούνται συνήθως με τυχαίες τιμές και στη συνέχεια ακολουθεί μία επαναληπτική διαδικασία που περιλαμβάνει δύο φάσεις. Στο στάδιο της εμπρόσθιας διάδοσης, τροφοδοτούνται τα δεδομένα στο επίπεδο εισόδου και, στη συνέχεια, διασχίζουν όλο το δίκτυο με τους απαιτούμενους υπολογισμούς να πραγματοποιούνται χρησιμοποιώντας τις τρέχουσες παραμέτρους. Βάσει της εξόδου, υπολογίζεται η τιμή του σφάλματος ανάμεσα στην επιθυμητή έξοδο και την πρόβλεψη του δικτύου, μέσω της συνάρτησης απωλειών. Στη συνέχεια, ακολουθεί το στάδιο της οπίσθιας διάδοσης στο οποίο πραγματοποιείται η ανανέωση των βαρών. Αρχικά, υπολογίζεται η μερική παράγωγος της συνάρτησης απώλειας ως προς τις παραμέτρους του δικτύου με την εφαρμογή του κανόνα αλυσίδας του διαφορικού λογισμού, ξεκινώντας από το επίπεδο εξόδου με κατεύθυνση προς την αρχή του δικτύου. Έπειτα οι τιμές των βαρών ενημερώνονται σύμφωνα με τον χρησιμοποιούμενο αλγόριθμο βελτιστοποίησης.

3.4.4 Αποφυγή Υπερπροσαρμογής

Έγκαιρη Διακοπή

Μία συνήθης πρακτική, είναι η χρήση ενός υποσυνόλου των αρχικών δεδομένων, το οποίο καλείται σύνολο δεδομένων επαλήθευσης (validation set) και περιέχει παραδείγματα διαφορετικά από εκείνα του συνόλου εκπαίδευσης, για την αξιολόγηση της απόδοσης του δικτύου κατά τη διάρκεια της εκπαίδευσης. Η τεχνική της έγκαιρης διακοπής (early stopping) βασίζεται στην παραπάνω πρακτική, με σκοπό τον τερματισμό της εκπαίδευσης πρωτού εμφανιστεί το φαινόμενο της υπερπροσαρμογής. Αναλυτικότερα, όπως φαίνεται στο Σχήμα 3.7, στα αρχικά στάδια της διαδικασίας της εκπαίδευσης, παρατηρείται μείωση τόσο του σφάλματος εκπαίδευσης όσο και του σφάλματος επαλήθευσης. Ωστόσο, υπάρχει μια χρονική στιγμή, από την οποία και μετά το σφάλμα επαλήθευσης αρχίζει συνήθως να αυξάνεται. Το στάδιο αυτό σηματοδοτεί την αρχή της εμφάνισης της υπερκπαίδευσης. Η μέθοδος της έγκαιρης διακοπής έχει ως στόχο


την αποτροπή του παραπάνω φαινομένου μέσω της παρακολούθησης του σφάλματος επαλήθευσης και της διακοπής της εκπαίδευσης έπειτα από ένα καθορισμένο πλήθος εποχών κατά τις οποίες δεν έχει παρατηρηθεί βελτίωσή του [66].



Σχήμα 3.7: Σημείο τερματισμού της εκπαίδευσης [79]

Διάλειψη

Η μέθοδος της Διάλειψης (Dropout) βασίζεται στην απόρριψη ενός τυχαίου υποσυνόλου των κόμβων του δικτύου και των συνδέσεών τους κατά τη διάρκεια της εκπαίδευσης. Η απόρριψη ενός κόμβου συνεπάγεται αυτομάτως και την απόρριψη όλων των προσπίπτουσων ακμών του. Η τυχαιοποιημένη απόρριψη τμημάτων του δικτύου έχει ως αποτέλεσμα την ενημέρωση των βαρών βάσει μιας διαφορετικής αρχιτεκτονικής κάθε φορά. Με αυτό τον τρόπο προσομοιώνεται η λειτουργία των μεθόδων μάθησης συνόλου, με συνέπεια την αύξηση της ικανότητας γενίκευσης, χωρίς την αντίστοιχη υπολογιστική δαπάνη της εκπαίδευσης και αποθήκευσης πολλαπλών μοντέλων. [66].



Σχήμα 3.8: Εφαρμογή διάλειψης, (α) αρχικό δίκτυο, (β) αποτέλεσμα εφαρμογής διάλειψης [80]

Επαύξηση Δεδομένων

Καθοριστικό ρόλο στην εμφάνιση του φαινομένου της υπερπροσαρμογής διαδραματίζει η έλλειψη επαρκούς ποσότητας δεδομένων εκπαίδευσης. Η επαύξηση δεδομένων (data augmentation) έχει ως στόχο τον εμπλουτισμό των δεδομένων εκπαίδευσης, μέσω του μετασχηματισμού των πρωτότυπων παραδειγμάτων, με συνέπεια την αύξηση της γενικευσιμότητας του μοντέλου. Ενδεικτικά παραδείγματα μετασχηματισμών που δύνανται να εφαρμοστούν σε προβλήματα διαχείρισης εικόνων είναι η περιστοφή, η μετάθεση και ο κατοπτρισμός. Ωστόσο, αξίζει να σημειωθεί πως η συγκεκριμένη τακτική δεν είναι κατάλληλη για όλα τα προβλήματα αλλά, αντίθετα, είναι απαραίτητο να λαμβάνεται κάθε φορά υπόψη τόσο η φυσική κατανομή των εικόνων στο σύνολο των δεδομένων, όσο και η επίδραση της εφαρμογής ενός συγκεκριμένου μετασχηματισμού στη διάκριση των κλάσεων. Για παράδειγμα, αν εφαρμοστεί αναστροφή στο σύνολο δεδομένων MNIST για την αναγνώριση χειρόγραφων ψηφίων, ο αριθμός "6" θα μετατρέποταν σε "9" [66].


3.5 Συνελικτικά Νευρωνικά Δίκτυα

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks – CNN) συνιστούν μία κατηγορία πολυεπίπεδων νευρωνικών δικτύων εμπρόσθιας τροφοδότησης, τα οποία έχουν αποδειχθεί ιδιαίτερος αποτελεσματικά, μεταξύ άλλων, σε προβλήματα ταξινόμησης εικόνων και επεξεργασίας φυσικής γλώσσας [81]. Τη βάση για την ανάπτυξη των σύγχρονων συνελικτικών νευρωνικών δικτύων αποτέλεσε το μοντέλο "Neocognitron" [82], το οποίο πρότεινε το 1980 ο Kunihiko Fukushima, στηριζόμενος στα ευρήματα των Hubel και Wiesel [83] αναφορικά με τον μηχανισμό λειτουργίας του οπτικού φλοιού των ζώων. Το πρώτο συνελικτικό νευρωνικό δίκτυο θεωρείται πως παρουσιάστηκε μερικά χρόνια αργότερα, το 1998, από τους LeCun et al [84], οι οποίοι εφάρμοσαν τον αλγόριθμο οπισθοδιάδοσης σφάλματος σε μια αρχιτεκτονική τύπου Neocognitron για την αναγνώριση χειρόγραφων ψηφίων.

Τυπικά, τα δίκτυα αυτά αποτελούνται από *επίπεδα συνέλιξης (convolutional layers)*, *επίπεδα χωρικής υποδειγματοληψίας (pooling layers)* και *πλήρως συνδεδεμένα επίπεδα (fully-connected layers)*. Στα επίπεδα συνέλιξης εφαρμόζεται η συνέλιξη της εισόδου με φίλτρα, το πλήθος των οποίων ορίζεται από τον χρήστη, αλλά τα βάρη τους καθορίζονται κατά τη διάρκεια της εκπαίδευσης. Μέσω της συγκεκριμένης διαδικασίας πραγματοποιείται η εξαγωγή των χαρακτηριστικών από τα δεδομένα. Στη συνέχεια, η έξοδος των επιπέδων αυτών εισέρχεται στα επίπεδα χωρικής υποδειγματοληψίας, κύριος ρόλος των οποίων είναι να συμπυκνώνουν την πληροφορία που παράγεται από τα επίπεδα συνέλιξης. Αρχικά, το δίκτυο εντοπίζει απλά χαρακτηριστικά, όπως γραμμές, και στα επόμενα στρώματα τα συνδυάζει με σκοπό να αναγνωρίσει περισσότερο σύνθετες δομές, όπως βρόχους. Τα πλήρως συνδεδεμένα επίπεδα βρίσκονται στο τέλος του δικτύου και αξιοποιούνται για την ταξινόμηση των δεδομένων στις κλάσεις. Ένα σημαντικό χαρακτηριστικό που διαφοροποιεί τα συνελικτικά δίκτυα από τις πλήρως συνδεδεμένες πολυεπίπεδες αρχιτεκτονικές δικτύων εμπρόσθιας τροφοδότησης είναι πως αντιμετωπίζουν τις εικόνες σαν πίνακες και όχι σαν μονοδιάστατα διανύσματα. Ως αποτέλεσμα επιτυγχάνουν εξαιρετικά σημαντική μείωση του πλήθους των βαθμών ελευθερίας, ενώ παράλληλα ενσωματώνουν τη χωρική πληροφορία [8]. Παρακάτω, περιγράφεται συνοπτικά η λειτουργία των τριών ειδών επιπέδων των συνελικτικών δικτύων σε προβλήματα ταξινόμησης εικόνων.

3.5.1 Επίπεδο Συνέλιξης

Το επίπεδο συνέλιξης περιέχει ένα καθορισμένο πλήθος φίλτρων συνέλιξης, κάθε ένα από τα οποία διαθέτει το ίδιο βάθος με το επίπεδο, αλλά μικρότερο χωρικό εύρος. Κατά τη διαδικασία της συνέλιξης, πραγματοποιείται ολίσηση ενός φίλτρου εντοπισμού χαρακτηριστικών, όπως ακμές ή υφές, στην εικόνα και κάθε τιμή βάρους του πρώτου πολλαπλασιάζεται με το αντίστοιχο εικονοστοιχείο. Στη συνέχεια, τα παραπάνω γινόμενα αθροίζονται ώστε να προκύψει η τελική τιμή που αντιστοιχεί στην εφαρμογή του φίλτρου στη συγκεκριμένα περιοχή της εικόνας. Η διαδικασία επαναλαμβάνεται έως ότου το φίλτρο να εφαρμοστεί σε ολόκληρη την επιφάνεια. Το αποτέλεσμα που προκύπτει από την συνέλιξη του φίλτρου με την εικόνα ονομάζεται χάρτης χαρακτηριστικών (feature map). Η παραπάνω διαδικασία φαίνεται στο Σχήμα 3.9. Μέσω της χρήσης διαφορετικών φίλτρων, καθίσταται εφικτός ο εντοπισμός ποικίλων χαρακτηριστικών. Σε περίπτωση που η εικόνα είναι έγχρωμη, δηλαδή αποτελείται από τρία διαφορετικά κανάλια (R, G, B), η συνέλιξη εφαρμόζεται συνήθως ξεχωριστά σε κάθε κανάλι, με αποτέλεσμα να προκύπτουν τρεις διαφορετικοί πίνακες, στους οποίους εφαρμόζεται element-wise πρόσθεση, προκειμένου να παραχθεί ο τελικός πίνακας [8].




Σχήμα 3.9: Διαδικασία συνέλιξης με 3x3 φίλτρο [85]

Το αποτέλεσμα της συνέλιξης είναι ένας πίνακας χαμηλότερων διαστάσεων από τον αρχικό. Συγκεκριμένα, αν σε μία εικόνα διαστάσεων $w \times w$ εφαρμοστεί ένα $k \times k$ φίλτρο, κάθε διάσταση του αποτελέσματος θα ισούται με την τιμή $w - k + 1$. Προκειμένου να αποφευχθεί η ελάττωση των διαστάσεων μπορεί να εφαρμοστεί η τεχνική padding κατά την οποία γίνεται προσθήκη επιπλέον κελιών με μηδενικές συνήθως τιμές (zero-padding) περιμετρικά του αρχικού πίνακα. Αν με p συμβολίζεται η τιμή του padding και χρησιμοποιηθεί το ίδιο $k \times k$ φίλτρο, προκειμένου ο πίνακας που θα προκύψει να έχει το ίδιο μέγεθος με τον αρχικό πρέπει $p = (k - 1)/2$ [8]. Η τεχνική zero-padding απεικονίζεται στο Σχήμα 3.10.

0	0	0	0	0	0	0	0	0
0								0
0								0
0								0
0								0
0								0
0								0
0								0
0	0	0	0	0	0	0	0	0

Σχήμα 3.10: Παράδειγμα εφαρμογής zero padding [86]

Επιπρόσθετα, το φίλτρο δεν μετακινείται απαραίτητα κατά ένα εικονοστοιχείο στην επιφάνεια της εικόνας. Αντίθετα, μπορεί να οριστεί κάποιος άλλος βηματισμός (stride). Γενικά, ισχύει ότι για είσοδο διαστάσεων $w \times w$, φίλτρο $k \times k$, padding p και βηματισμό s , η διάσταση της εξόδου θα ισούται με $(w - k + 2p) / s + 1$ [8]. Η έξοδος του επιπέδου συνέλιξης, εισέρχεται σε μία μη - γραμμική συνάρτηση, με συχνότερα χρησιμοποιούμενη τη ReLU. Πολλές φορές αυτό το βήμα θεωρείται ξεχωριστό επίπεδο και αναφέρεται ως επίπεδο απαλοιφής της γραμμικότητας.




Σχήμα 3.11: Μετακίνηση συνελκτικού φίλτρου με βηματισμό 1 [86]

3.5.2 Επίπεδο Χωρικής Υποδειγματοληψίας

Στο συγκεκριμένο επίπεδο, πραγματοποιείται μείωση της πληροφορίας που παράγεται από τα συνελκτικά επίπεδα, με ταυτόχρονη διατήρηση των σημαντικότερων χαρακτηριστικών. Υπάρχουν δύο βασικές μέθοδοι με τις οποίες μπορεί να επιτευχθεί αυτό, το μέγιστο (max pooling) και ο μέσος όρος (average pooling). Στην πρώτη περίπτωση χρησιμοποιείται ένα $k \times k$ παράθυρο το οποίο διατρέχει την έξοδο του επιπέδου συνέλιξης


με βηματισμό s . Το αποτέλεσμα της εφαρμογής του παραθύρου σε κάθε περιοχή της εξόδου αποτελεί την υψηλότερη τιμή της περιοχής. Συνήθως, όπως φαίνεται στο Σχήμα 3.12, χρησιμοποιείται ένα 2×2 παράθυρο με βηματισμό 2. Η μέθοδος του μέσου όρου ταυτίζεται με αυτή του μεγίστου, ωστόσο το αποτέλεσμα της εφαρμογής του παραθύρου σε μια περιοχή της εξόδου του επιπέδου συνέλιξης δεν είναι η μέγιστη τιμή της περιοχής, αλλά ο μέσος όρος των τιμών της. Το συγκεκριμένο επίπεδο εξάγει μια αφαιρετική αναπαράσταση και ελαττώνει το πλήθος των ελεύθερων παραμέτρων με αποτέλεσμα να μειώνει σημαντικά το υπολογιστικό κόστος και να αντιμετωπίζει την υπερπροσαρμογή. Επιπλέον, προσδίδει το χαρακτηριστικό της αμεταβλητότητας σε μικρές αλλοιώσεις της εισόδου, αφού οι τελευταίες δεν επιδρούν σημαντικά στο μέγιστο ή το μέσο όρο [8].



Σχήμα 3.12: Χωρική Υποδειγματοληψία με μέγιστο και μέσο όρο [87]

3.5.3 Πλήρως Συνδεδεμένο Επίπεδο

Αφού εντοπιστούν τα απαραίτητα χαρακτηριστικά με τη χρήση μιας αλληλουχίας επιπέδων συνέλιξης και χωρικής υποδειγματοληψίας, ακολουθούν τα πλήρως συνδεδεμένα επίπεδα, τα οποία αξιοποιούν τα χαρακτηριστικά αυτά προκειμένου να ταξινομήσουν τα δεδομένα στις διάφορες κλάσεις. Προτού εισαχθεί σε ένα πλήρως συνδεδεμένο επίπεδο, η έξοδος του προηγούμενου σταδίου υπόκειται κατάλληλη επεξεργασία ώστε να αποκτήσει τη μορφή μονοδιάστατου πίνακα. Μία μέθοδος που χρησιμοποιείται ευρέως για το σκοπό αυτό είναι η επιπέδωση (flatten), κατά την οποία η έξοδος του προηγούμενου στρώματος μετατρέπεται σε μονοδιάστατο διάνυσμα, χωρίς να υπάρξει απώλεια πληροφορίας. Στη συνέχεια, ακολουθούν συχνά δύο πλήρως συνδεδεμένα επίπεδα και, τέλος, το επίπεδο εξόδου [8]. Στο Σχήμα 3.13 παρουσιάζεται μία τυπική αρχιτεκτονική συνελκτικού δικτύου.




Σχήμα 3.13: Τυπική αρχιτεκτονική συνελκτικού δικτύου. Το αρχικό μέρος του δικτύου αποτελείται από διαδοχικά στρώματα συνέλιξης και υποδειγματοληψίας, ενώ στο τέλος ακολουθούν τα πλήρως συνδεδεμένα επίπεδα [88]

3.5.4 VGG16

Το VGG (Σχήμα 3.14) αποτελεί ένα από τα δημοφιλέστερα προεκπαιδευμένα συνελκτικά νευρωνικά δίκτυα. Η συγκεκριμένη αρχιτεκτονική αναπτύχθηκε από τους Karen Simonyan και Andrew Zisserman του πανεπιστημίου της Οξφόρδης και συμμετείχε στο διαγωνισμό ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) το 2014, χωρίς ωστόσο να αναδειχθεί η νικήτρια συμμετοχή. Οι δύο ερευνητές, στην εργασία τους «*Very Deep Convolutional Networks for Large-Scale Image Recognition*» [89] παρουσίασαν διάφορες διατάξεις του μοντέλου VGG, αποτελούμενες από διαφορετικό πλήθος επιπέδων. Η αρχιτεκτονική με το μικρότερο βάθος περιλάμβανε 8 επίπεδα συνέλιξης και 3 πλήρως συνδεδεμένα επίπεδα, ενώ εκείνη με το μεγαλύτερο, αποτελούνταν από 16 συνελκτικά και 3 πλήρως συνδεδεμένα στρώματα. Χαρακτηριστικό γνώρισμα του VGG είναι η χρήση φίλτρων μικρού μεγέθους με ταυτόχρονη αύξηση του βάθους του δικτύου. Συγκεκριμένα, προκειμένου να μειωθεί το υπολογιστικό κόστος, χωρίς αντίστοιχη μείωση της ακρίβειας, μπορεί να γίνει αντικατάσταση ενός συνελκτικού επιπέδου με μεγαλύτερου μεγέθους φίλτρα, από περισσότερα διαδοχικά συνελκτικά επίπεδα με μικρότερα φίλτρα. Για παράδειγμα, μια συνέλιξη μεγέθους 5×5 μπορεί να αντικατασταθεί από δύο διαδοχικές συνέλιξεις μεγέθους 3×3 , ενώ μια συνέλιξη μεγέθους 7×7 από τρεις διαδοχικές συνέλιξεις μεγέθους 3×3 . Ωστόσο, ένα 7×7 φίλτρο αποτελείται από $7 \times 7 \times 1 = 49$ παραμέτρους, ενώ τα τρία 3×3 φίλτρα από συνολικά $3 \times 3 \times 3 = 27$ παραμέτρους. Βάσει των παραπάνω, καθίσταται εύκολα αντιληπτό πως η επιλογή μικρότερων φίλτρων οδηγεί σε χαμηλότερο υπολογιστικό κόστος, ενώ η παράλληλη αύξηση του βάθους διασφαλίζει τη διατήρηση της αποτελεσματικότητας.

τας του δικτύου. Ένα ακόμη πλεονέκτημα των βαθύτερων δικτύων, είναι η εφαρμογή περισσότερων μη-γραμμικών ενεργοποιήσεων, η οποία οδηγεί σε αυξημένη διακριτική ικανότητα του μοντέλου [66].

Το VGG16 είναι μία εκδοχή του μοντέλου VGG, η οποία περιλαμβάνει 13 επίπεδα συνέλιξης, 5 επίπεδα χωρικής υποδειγματοληψίας και 3 πλήρως συνδεδεμένα επίπεδα. Ακόμη, χρησιμοποιούνται 3×3 συνελίξεις, με βηματισμό 1 και padding 1. Στα επίπεδα χωρικής υποδειγματοληψίας, εφαρμόζεται η τεχνική του μεγίστου (max pooling) με 2×2 παράθυρο και βήμα 2. Στο τέλος του δικτύου, υπάρχουν τρία πλήρως συνδεδεμένα επίπεδα. Τα δύο πρώτα αποτελούνται από 4096 νευρώνες. Το τελευταίο επίπεδο περιλαμβάνει 1000 νευρώνες και χρησιμοποιεί τη συνάρτηση softmax, καθώς το μοντέλο κατασκευάστηκε με στόχο να ταξινομήσει επιτυχώς ένα σύνολο έγχρωμων 224×224 εικόνων σε 1000 κλάσεις. Ένα μειονέκτημα του VGG16 είναι ο τεράστιος αριθμός παραμέτρων που διαθέτει, αφού το συνολικό πλήθος των παραμέτρων σε όλα τα επίπεδα είναι περίπου $138 \cdot 10^6$.



Σχήμα 3.14: Αρχιτεκτονική VGG16 [90]

Κεφάλαιο 4

Πρακτικό Μέρος

Στα πλαίσια της παρούσας εργασίας σχεδιάστηκαν και αναπτύχθηκαν πέντε διαφορετικές αρχιτεκτονικές συνελκτικών νευρωνικών δικτύων με στόχο την κατασκευή ενός μοντέλου πρόβλεψης του καρκίνου του παχέος εντέρου και του πνεύμονα. Το πρόβλημα που αντιμετωπίστηκε ανήκει στην κατηγορία της ταξινόμησης πολλαπλών κλάσεων, αφού κάθε μοντέλο κλήθηκε να αναγνωρίσει 5 διαφορετικές καταστάσεις: αδενοκαρκίνωμα παχέος εντέρου, καλοήθης ιστός παχέος εντέρου, αδενοκαρκίνωμα πνεύμονα, ακανθοκυτταρικό καρκίνωμα πνεύμονα και καλοήθης ιστός πνεύμονα. Στη συνέχεια, η απόδοση των πέντε μοντέλων συγκρίθηκε με εκείνη ενός εκ των ισχυρότερων προεκπαιδευμένων συνελκτικών δικτύων, του VGG16.

4.1 Προγραμματιστικά Εργαλεία

Για την υλοποίηση της συγκεκριμένης εργασίας χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python. Η Python συνιστά μία υψηλού επιπέδου γλώσσα, η οποία χαρακτηρίζεται από την ύπαρξη μεγάλου πλήθους βιβλιοθηκών που απλοποιούν σε μεγάλο βαθμό την εκτέλεση πολλών εργασιών. Το γεγονός αυτό καθιστά την εκμάθησή της μια εύκολη και γρήγορη διαδικασία συγκριτικά με άλλες γλώσσες. Ως εκ τούτου, αποτελεί μία από τις πιο διαδεδομένες γλώσσες προγραμματισμού σήμερα, ενώ παράλληλα διαθέτει μία από τις ισχυρότερες κοινότητες χρηστών. Τα βασικά εργαλεία που χρησιμοποιήθηκαν για την εκπόνηση της συγκεκριμένης εργασίας είναι η πλατφόρμα μηχανικής μάθησης ανοιχτού κώδικα TensorFlow και το API Keras, στο οποίο γίνεται ειδική αναφορά παρακάτω. Ακόμη, μεταξύ άλλων, έγινε χρήση των βιβλιοθηκών NumPy, Matplotlib και Pandas. Η βιβλιοθήκη NumPy περιλαμβάνει συναρτήσεις που


απλοποιούν σε μεγάλο βαθμό την πραγματοποίηση μαθηματικών υπολογισμών μέσω της διαχείρισης αριθμητικών πινάκων, ενώ η Matplotlib χρησιμοποιείται για την κατασκευή γραφημάτων και την οπτικοποίηση των δεδομένων. Τέλος, η βιβλιοθήκη Pandas χρησιμοποιείται κυρίως για τον καθαρισμό και την ανάλυση των δεδομένων.

Το Keras είναι ένα API (Application Programming Interface) βασισμένο στη γλώσσα προγραμματισμού Python που χρησιμοποιείται ευρέως σε εφαρμογές βαθιάς μάθησης. Χάρης στην απλότητα και το φιλικό προς το χρήστη περιβάλλον που διαθέτει, αποτελεί σήμερα ένα από τα πιο ευρέως διαδεδομένα εργαλεία βαθιάς μάθησης, ενώ παράλληλα θεωρείται ιδανικό για αρχάριους. Η κατασκευή και η εκπαίδευση ενός νευρωνικού δικτύου μέσω του Keras αποτελεί μία πολύ εύκολη διαδικασία, ακόμη και για χρήστες που δεν είναι εξοικειωμένοι με τον προγραμματισμό. Χαρακτηριστικό παράδειγμα συνιστά η διαδικασία προσθήκης ενός συνελκτικού επιπέδου σε ένα νευρωνικό δίκτυο, η οποία πραγματοποιείται με μία μόνο εντολή, την Conv2D. Ένα άλλο σημαντικό πλεονέκτημα του συγκεκριμένου εργαλείου είναι πως παρέχει τη δυνατότητα εύκολης χρησιμοποίησης ενός μεγάλου πλήθους προεκπαιδευμένων δικτύων, όπως τα VGG [89], ResNet [91], Xception [92], MobileNet [93] και DenseNet [94], διατηρώντας τα βάρη τα οποία προέκυψαν κατά την εκπαίδευση των μοντέλων στο σύνολο δεδομένων ImageNet. Τέλος, το Keras διαθέτει ένα υψηλής ποιότητας documentation, με αναλυτικές περιγραφές και επεξηγηματικά παραδείγματα, γεγονός που ενισχύει περαιτέρω τη δημοφιλία του.


4.2 Σύνολο Δεδομένων

Το σύνολο δεδομένων που χρησιμοποιήθηκε στην παρούσα εργασία είναι το “*Lung and Colon Cancer Histopathological Image Dataset (LC25000)*” [95], το οποίο δημοσιεύθηκε το 2019 από τους Borikowski et al, σε μια προσπάθεια άμβλυνσης του προβλήματος της μειωμένης διαθεσιμότητας ιατρικών δεδομένων. Το σύνολο αυτό αποτελείται από 25.000 έγχρωμες ιστοπαθολογικές εικόνες, οι οποίες ταξινομούνται στις εξής 5 κατηγορίες: αδenoκαρκίνωμα παχέος εντέρου (colon adenocarcinoma), καλοήθης ιστός παχέος εντέρου (benign colonic tissue), αδenoκαρκίνωμα πνεύμονα (lung adenocarcinoma), ακανθοκυτταρικό καρκίνωμα πνεύμονα (lung squamous cell carcinoma) και καλοήθης ιστός πνεύμονα (benign lung tissue). Το τελικό σύνολο δεδομένων προέκυψε έπειτα από την εφαρμογή της τεχνικής επαύξησης δεδομένων (data augmentation) σε ένα αρχικό δείγμα αποτελούμενο από 750 ιστοπαθολογικές εικόνες πνεύμονα και 500 ιστοπαθολογικές εικόνες παχέος εντέρου. Συγκεκριμένα, το αρχικό δείγμα περιλάμβανε 250 εικόνες για κάθε κλάση, αρχικών διαστάσεων 1024 x 768. Στη συνέχεια, πραγματοποιήθηκε περικοπή των εικόνων με χρήση της γλώσσας προγραμματισμού Python ώστε το μέγεθός τους να καταστεί τελικά 768 x 768 και εφαρμόστηκε η τεχνική


επαύξησης των δεδομένων με τη βιβλιοθήκη Augmentor. Η τελευταία διαδικασία περιλάμβανε την εφαρμογή των μετασχηματισμών της δεξιάς και αριστερής περιστροφής καθώς και της αναστροφής ως προς τον οριζόντιο και κάθετο άξονα. Εν τέλει, το αποτέλεσμα της παραπάνω επεξεργασίας, ήταν η δημιουργία ενός συνόλου 25.000 εικόνων διαστάσεων 768 x 768 που ταξινομούνται σε 5 κατηγορίες, κάθε μία από τις οποίες περιλαμβάνει 5.000 δείγματα. Στα πλαίσια της συγκεκριμένης εργασίας, αξιοποιείται ολόκληρο το σύνολο των δεδομένων με σκοπό την κατασκευή μοντέλων που θα αναγνωρίζουν τόσο τον καρκίνο του πνεύμονα όσο και τον καρκίνο του παχέος εντέρου. Εναλλακτικά, θα μπορούσε να επιλεγθεί μόνο το υποσύνολο των δεδομένων που αφορά τη μία από τις δύο περιπτώσεις και να κατασκευαστούν ξεχωριστά μοντέλα για κάθε μία από αυτές. Παρακάτω παρουσιάζονται τυχαία δείγματα κάθε κλάσης.




Σχήμα 4.1: Τυχαίες εικόνες αδενοκαρκινώματος του παχέος εντέρου




Σχήμα 4.2: Τυχαίες εικόνες καλοήθους ιστού του παχέος εντέρου



Σχήμα 4.3: Τυχαίες εικόνες αδενοκαρκινώματος του πνεύμονα



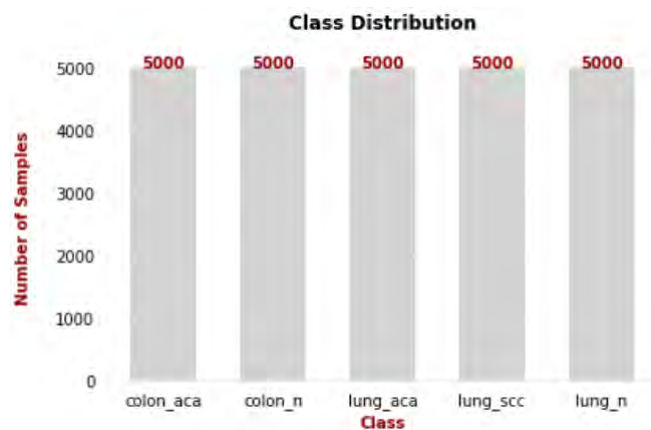
Σχήμα 4.4: Τυχαίες εικόνες ακανθοκυτταρικού καρκινώματος του πνεύμονα



Σχήμα 4.5: Τυχαίες εικόνες καλοήθους ιστού του πνεύμονα


4.3 Προεπεξεργασία Δεδομένων

Όπως φαίνεται στο παρακάτω γράφημα, το σύνολο των δεδομένων είναι ισορροπημένο, επομένως δε χρειάστηκε να εφαρμοστεί κάποια τεχνική για την αντιμετώπιση του προβλήματος της ανισορροπίας κλάσεων (class imbalance). Ο διαχωρισμός των δεδομένων πραγματοποιήθηκε σε τρία υποσύνολα. Το 70% του αρχικού συνόλου χρησιμοποιήθηκε ως σύνολο δεδομένων εκπαίδευσης (training set), το 10% ως σύνολο δεδομένων επαλήθευσης (validation set) και το υπόλοιπο 20% ως σύνολο δεδομένων ελέγχου (test set).




Σχήμα 4.6: Κατανομή Κλάσεων

Στο στάδιο της προεπεξεργασίας εφαρμόστηκε η τεχνική της επαύξησης των δεδομένων εκπαίδευσης. Αξίζει να σημειωθεί πως οι μετασχηματισμοί της περιστροφής των εικόνων προς τα δεξιά ή προς τα αριστερά καθώς και η αναστροφή τους ως προς τους άξονες x και y , παραλήφθηκαν, καθώς, όπως αναφέρθηκε προηγουμένως, είχαν ήδη εφαρμοστεί από τους ερευνητές πριν τη δημοσιοποίηση του συνόλου δεδομένων. Αντίθετα, πραγματοποιήθηκε ο εμπλουτισμός των δεδομένων εκπαίδευσης μέσω της μετατόπισης των εικόνων στον οριζόντιο και κάθετο άξονα, της αλλαγής της φωτεινότητας και της μεταβολής της εστίασης των αρχικών εικόνων. Στο Σχήμα 4.7 παρουσιάζονται παραδείγματα εφαρμογής κάθε ενός από τους παραπάνω μετασχηματισμούς σε μία εικόνα αδενοκαρκινώματος του παχέος εντέρου.



Σχήμα 4.7: Παραδείγματα επαύξησης δεδομένων (α) αρχική εικόνα – πάνω αριστερά, (β) μεταβολή φωτεινότητας – πάνω δεξιά, (γ) μεταβολή εστίασης – κάτω αριστερά, (δ) μετατόπιση – κάτω δεξιά

Στο Σχήμα 4.8 φαίνονται τα αποτελέσματα της εφαρμογής των παραπάνω μετασχηματισμών σε τέσσερα τυχαία δείγματα του συνόλου εκπαίδευσης.




Σχήμα 4.8: Αποτελέσματα εφαρμογής της τεχνικής επαύξησης δεδομένων σε τυχαία δείγματα

4.4 Εκπαίδευση Μοντέλων

Όπως αναφέρθηκε παραπάνω, στα πλαίσια της παρούσας εργασίας πραγματοποιήθηκε η εκπαίδευση και αξιολόγηση πέντε διαφορετικών συνελκτικών αρχιτεκτονικών. Σε όλες τις περιπτώσεις, το μέγεθος των εικόνων ορίστηκε σε 224×224 και το μέγεθος δέσμης σε (batch size) 16. Σε όλα τα επίπεδα, εκτός από εκείνο της εξόδου επιλέχθηκε ως συνάρτηση ενεργοποίησης η ReLU, ενώ στο τελευταίο επίπεδο εφαρμόστηκε η softmax. Ως βελτιστοποιητής χρησιμοποιήθηκε ο Adam και ως συνάρτηση απώλειας η categorical cross entropy. Ο ρυθμός μάθησης ορίστηκε αρχικά σε 10^{-4} , αλλά στην πορεία της εκπαίδευσης μεταβλήθηκε, καθώς χρησιμοποιήθηκε η συνάρτηση *ReduceLROnPlateau* της βιβλιοθήκης Keras. Η χρησιμοποίηση της συγκεκριμένης συνάρτησης είχε ως αποτέλεσμα, εφόσον μετά από 2 διαδοχικές εποχές δεν είχε παρατηρηθεί βελτίωση στην τιμή του σφάλματος επαλήθευσης, τη μείωση του ρυθμού μάθησης. Τέλος, ο αριθμός των εποχών ορίστηκε αρχικά σε 50, ωστόσο εφαρμόστηκε η τεχνική της έγκαιρης διακοπής (early stopping), ούτως ώστε να αποφευχθεί η υπερεκπαίδευση και να μειωθούν οι απαιτήσεις σε χρόνο και μνήμη. Συγκεκριμένα, χρησιμοποιήθηκε ως κριτήριο για τη διακοπή της εκπαίδευσης το σφάλμα επαλήθευσης, ενώ η παράμετρος "υπομονής" (patience) ορίστηκε στην τιμή 5. Η παράμετρος "υπομονής" καθορίζει το πλήθος των εποχών που πρέπει να ολοκληρωθούν δίχως να έχει παρατηρηθεί βελτίωση, προκειμένου να τερματιστεί η εκπαίδευση. Παρακάτω, ακολουθεί η περιγραφή των πέντε αρχιτεκτονικών.

• Μοντέλο 1


Το πρώτο μοντέλο αποτελείται από τρία επίπεδα συνέλιξης, κάθε ένα από τα οποία ακολουθείται από ένα επίπεδο χωρικής υποδειγματοληψίας μεγίστου, με μέγεθος παραθύρου 2 και βηματισμό 2. Στο πρώτο επίπεδο συνέλιξης χρησιμοποιήθηκαν 32 3 x 3 φίλτρα, ενώ σε κάθε επόμενο συνελκτικό στρώμα το πλήθος των φίλτρων διπλασιάζεται. Ο βηματισμός ορίστηκε στην τιμή 1, ενώ το padding ορίστηκε κατάλληλα ώστε κάθε φορά το μέγεθος της εξόδου του συνελκτικού επιπέδου να ταυτίζεται με αυτό της εισόδου. Τέλος, πραγματοποιείται επιπέδωση (flatten) και ακολουθούν 3 πλήρως συνδεδεμένα επίπεδα. Τα δύο πρώτα αποτελούνται από 512 και 256 νευρώνες αντίστοιχα, ενώ το επίπεδο εξόδου περιλαμβάνει 5 νευρώνες, προκειμένου να ταξινομήσει τα δείγματα στις πέντε διαφορετικές κλάσεις. Ο συνολικός αριθμός παραμέτρων του μοντέλου είναι 51.606.597 και η αρχιτεκτονική του παρουσιάζεται στο Σχήμα 4.9:



Σχήμα 4.9: Αρχιτεκτονική πρώτου δικτύου

• Μοντέλο 2


Η δεύτερη αρχιτεκτονική, η οποία παρουσιάζεται στο Σχήμα 4.10, είναι ίδια με την προηγούμενη με τη διαφορά πως προστέθηκαν δύο επίπεδα συνέλιξης, ένα αμέσως μετά το πρώτο συνελκτικό επίπεδο και ένα ακριβώς μετά το δεύτερο, χωρίς ενδιάμεσα να παρεμβάλλεται κάποιο στρώμα χωρικής υποδειγματοληψίας. Η χρήση δύο διαδοχικών επιπέδων συνέλιξης πριν το επίπεδο χωρικής υποδειγματοληψίας έχει ως στόχο την εξαγωγή πιο περίπλοκων αναπαραστάσεων. Ως αποτέλεσμα, το πλήθος των παραμέτρων του δικτύου αυξήθηκε σε 51.652.773.



Σχήμα 4.10: Αρχιτεκτονική δεύτερου δικτύου

• Μοντέλο 3


Το τρίτο νευρωνικό δίκτυο (Σχήμα 4.11) έχει την ίδια αρχιτεκτονική με το δεύτερο, ωστόσο, μετά το τρίτο επίπεδο χωρικής υποδειγματοληψίας, πραγματοποιήθηκε η προσθήκη ενός ακόμη συνελκτικού επιπέδου 256 φίλτρων, ακολουθούμενο από ένα επίπεδο χωρικής υποδειγματοληψίας μεγίστου. Το μοντέλο αυτό αποτελείται από συνολικά 26.257.829 παραμέτρους.



Σχήμα 4.11: Αρχιτεκτονική τρίτου δικτύου

- **Μοντέλο 4**


Η τέταρτη αρχιτεκτονική (Σχήμα 4.12) προέκυψε έπειτα από την προσθήκη ενός συνελκτικού επιπέδου με 512 φίλτρα και του αντίστοιχου επιπέδου χωρικής υποδειγματοληψίας, στο τρίτο μοντέλο, πριν το στάδιο της επιπέδωσης. Το πλήθος των παραμέτρων είναι 14.592.933.



Σχήμα 4.12: Αρχιτεκτονική τέταρτου δικτύου

• Μοντέλο 5

Το πέμπτο και τελευταίο μοντέλο (Σχήμα 4.13) προέκυψε από την προσθήκη ενός ακόμη επιπέδου συνέλιξης στην προηγούμενη αρχιτεκτονική, τόσο πριν από το πρώτο όσο και πριν από το δεύτερο επίπεδο χωρικής υποδειγματοληψίας. Το πρώτο συνελικτικό στρώμα που προστέθηκε περιλαμβάνει 32 φίλτρα, ενώ το δεύτερο 64. Συνολικά, το μοντέλο περιλαμβάνει 14.639.109 παραμέτρους.

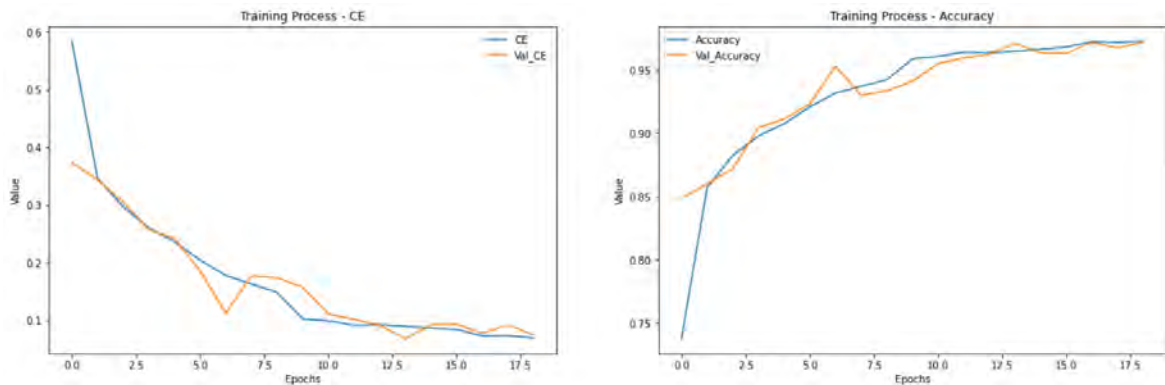


Σχήμα 4.13: Αρχιτεκτονική πέμπτου δικτύου

4.5 Αποτελέσματα

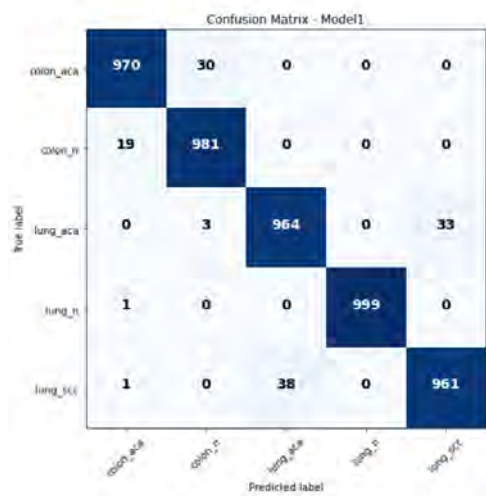
• Μοντέλο 1

Η εκπαίδευση του δικτύου τερματίστηκε μετά την ολοκλήρωση 19 εποχών. Τα γραφήματα του σφάλματος και της ακρίβειας της εκπαίδευσης και επαλήθευσης ανά εποχή παρουσιάζονται παρακάτω (Σχήμα 4.14):



Σχήμα 4.14: Γραφήματα εκπαίδευσης πρώτου δικτύου

Δεδομένου ότι το σφάλμα της εκπαίδευσης μειώνεται ομαλά έως ότου σταθεροποιηθεί, ενώ παράλληλα δεν υπάρχει μεγάλη απόκλιση μεταξύ του σφάλματος της εκπαίδευσης και του σφάλματος της επαλήθευσης, εξάγεται το συμπέρασμα ότι η εκπαίδευση πραγματοποιήθηκε με επιτυχία. Η ακρίβεια του μοντέλου στο σύνολο δεδομένων ελέγχου ήταν **97,5%** ενώ ο πίνακας σύγχυσης φαίνεται παρακάτω (Σχήμα 4.15):




Σχήμα 4.15: Πίνακας σύγχυσης πρώτου μοντέλου

Από τον πίνακα σύγχυσης, γίνεται αντιληπτό πως παρόλο που το μοντέλο παρουσιάζει υψηλή απόδοση, φαίνεται πως αδυνατεί σε ορισμένες περιπτώσεις να διακρίνει το αδενοκαρκίνωμα από τον καλοήγη ιστό του παχέος εντέρου, καθώς και το αδενοκαρκίνωμα από το ακανθοκυτταρικό καρκίνωμα του πνεύμονα.

• Μοντέλο 2

Η εκπαίδευση του συγκεκριμένου δικτύου διήρκησε 33 εποχές. Και σε αυτή την περίπτωση, τα γραφήματα (Σχήμα 4.16) υποδεικνύουν καλή προσαρμογή. Στο Σχήμα 4.17 παρουσιάζεται ο πίνακας σύγχυσης. Όπως ήταν αναμενόμενο, η απόδοση βελτιώθηκε, με την ακρίβεια να αγγίζει το **99,14%**. Η χρήση διαδοχικών συνελκτικών επιπέδων στην αρχή του δικτύου είχε ως αποτέλεσμα την ελαχιστοποίηση των σφαλμάτων κατά την ταξινόμηση των εικόνων του παχέος εντέρου, γεγονός που δείχνει πως το συγκεκριμένο μοντέλο έχει αυξημένη ικανότητα διάκρισης των εν λόγω περιπτώσεων συγκριτικά με το προηγούμενο. Ωστόσο, σε ελάχιστες περιπτώσεις εμφανίζει και αυτό δυσκολία στη διάκριση των δύο τύπων καρκινώματος του πνεύμονα.



Σχήμα 4.16: Γραφήματα εκπαίδευσης δεύτερου δικτύου


Confusion Matrix - Model2

True label \ Predicted label	colon_ace	colon_n	lung_ace	lung_n	lung_acc
colon_ace	997	3	0	0	0
colon_n	1	999	0	0	0
lung_ace	1	0	985	0	14
lung_n	0	0	0	1000	0
lung_acc	0	0	24	0	976

Σχήμα 4.17: Πίνακας σύγχυσης δεύτερου μοντέλου

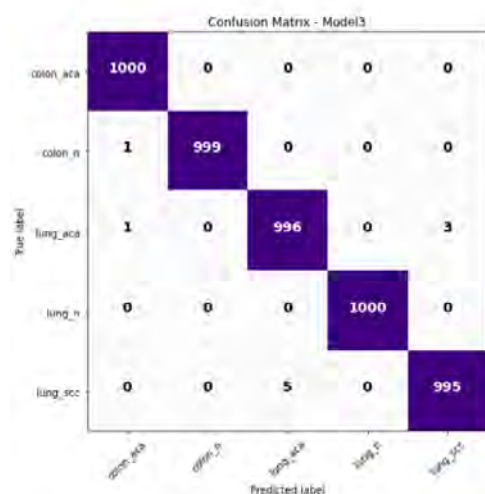
• Μοντέλο 3

Η εκπαίδευση του τρίτου μοντέλου ολοκληρώθηκε έπειτα από 30 εποχές και, όπως φαίνεται στα αντίστοιχα γραφήματα (Σχήμα 4.18), ήταν επίσης ομαλή.



Σχήμα 4.18: Γραφήματα εκπαίδευσης πρώτου δικτύου


Στο σύνολο δεδομένων ελέγχου, η απόδοση του μοντέλου ήταν σχεδόν τέλεια αφού κατάφερε να σημειώσει ακρίβεια **99,8%**. Στο Σχήμα 4.19 παρουσιάζεται ο αντίστοιχος πίνακας σύγχυσης. Η συγκεκριμένη αρχιτεκτονική είναι η βέλτιστη έως τώρα, αφού καθιστά εφικτό τον σχεδόν άψογο διαχωρισμό των δεδομένων στις πέντε κλάσεις.



Σχήμα 4.19: Πίνακας σύγχυσης τρίτου μοντέλου

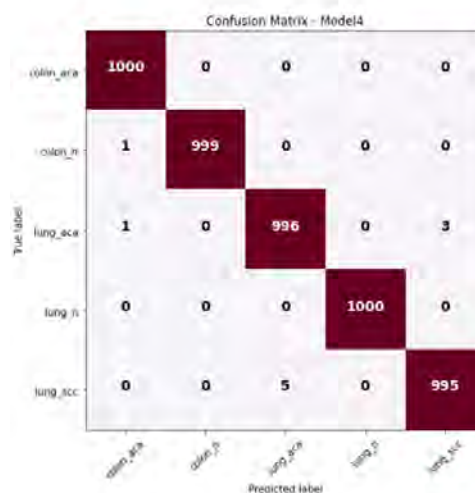
• Μοντέλο 4

Η εκπαίδευση του τέταρτου δικτύου διήρκησε 34 εποχές και, όπως και στις προηγούμενες περιπτώσεις, ήταν ομαλή (Σχήμα 4.20).



Σχήμα 4.20: Γραφήματα εκπαίδευσης τέταρτου δικτύου


Ομοίως με το τρίτο δίκτυο, η ακρίβεια του μοντέλου στο σύνολο δεδομένων ελέγχου ήταν **99,8%**, ενώ και οι υπόλοιπες μετρικές ήταν σχεδόν άψογες, όπως γίνεται αντιληπτό από τον πίνακα σύγχυσης (Σχήμα 4.21).



Σχήμα 4.21: Πίνακας σύγχυσης τέταρτου μοντέλου

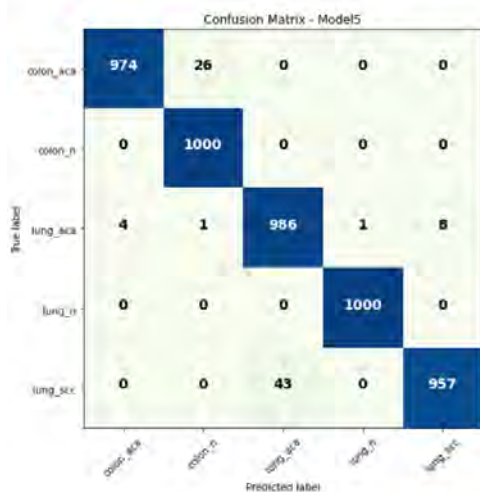
• Μοντέλο 5

Η εκπαίδευση του πέμπτου μοντέλου ολοκληρώθηκε έπειτα από 20 εποχές και τα αντίστοιχα γραφήματα φαίνονται στο Σχήμα 4.22.



Σχήμα 4.22: Γραφήματα εκπαίδευσης πέμπτου δικτύου

Κατά την εφαρμογή στο σύνολο δεδομένων ελέγχου, η απόδοση του μοντέλου ήταν χαμηλότερη συγκριτικά με αυτή των δύο προηγούμενων, αφού πέτυχε ακρίβεια **98,34%**. Από τον πίνακα σύγχυσης (Σχήμα 4.23) φαίνεται πως το μοντέλο παρουσιάζει σε ελάχιστες περιπτώσεις μειωμένη ικανότητα διάκρισης του αδενοκαρκινώματος από τον καλοήγη ιστό του παχέος εντέρου, καθώς και των δύο τύπων καρκινωμάτων του πνεύμονα. Από τα παραπάνω, συμπεραίνεται πως η ύπαρξη τριών επιπέδων συνέλιξης πριν το πρώτο και δεύτερο επίπεδο χωρικής υποδειγματοληψίας είχε ως αποτέλεσμα την εξαγωγή περισσότερο σύνθετων από το επιθυμητό αναπαραστάσεων.




Σχήμα 4.23: Πίνακας σύγχυσης πέμπτου δικτύου

VGG16


Η απόδοση των παραπάνω αρχιτεκτονικών συγκρίθηκε με εκείνη ενός εκ των δημοφιλέστερων προεκπαιδευμένων συνελκτικών δικτύων, του VGG16. Το δίκτυο χρησιμοποιήθηκε με παγωμένα τα βάρη στα αρχικά επίπεδα, ενώ τροποποιήθηκαν και εκπαιδεύτηκαν μόνο τα πλήρως συνδεδεμένα στρώματα. Αναλυτικότερα, όπως και στα προηγούμενα μοντέλα, εφαρμόστηκε επιπέδωση και ακολούθησε η προσθήκη δύο πλήρως συνδεδεμένων στρωμάτων, αποτελούμενων από 512 και 256 νευρώνες αντίστοιχα. Τέλος, ακολούθησε το επίπεδο εξόδου στο οποίο χρησιμοποιήθηκαν 5 νευρώνες, προκειμένου να καταστεί εφικτή η ταξινόμηση των εικόνων στις πέντε κλάσεις. Το συνολικό πλήθος των βαρών και των πολώσεων του δικτύου που ενημερώθηκαν κατά την εκπαίδευση (trainable weights) ήταν 12.978.181.

Και σε αυτή την περίπτωση, ως συνάρτηση απώλειας επιλέχθηκε η *categorical cross-entropy* και ως βελτιστοποιητής ο *Adam*. Ο ρυθμός μάθησης αρχικοποιήθηκε σε 10^{-4} και χρησιμοποιήθηκε η συνάρτηση *ReduceLROnPlateau*. Η εκπαίδευση του δικτύου ολοκληρώθηκε μετά από 17 εποχές, αφού εφαρμόστηκε η τεχνική της έγκαιρης διακοπής. Τα σχετικά γραφήματα παρουσιάζονται στο Σχήμα 4.24:



Σχήμα 4.24: Γραφήματα εκπαίδευσης VGG16 δικτύου

Η ακρίβεια του VGG16 στο σύνολο των δεδομένων ελέγχου ήταν **97,24%**. Η απόδοσή του ήταν χαμηλότερη από εκείνη όλων των προηγούμενων μοντέλων. Ακολουθεί ο πίνακας σύγχυσης (Σχήμα 4.25):



Σχήμα 4.25: Πίνακας Σύγχυσης VGG16 δικτύου

Ο Πίνακας 4.1 παρουσιάζει συγκεντρωτικά τα αποτελέσματα.

Αρχιτεκτονική	Ακρίβεια	Πλήθος Παραμέτρων
1x32-1X64-1X128-512-256-5	97.5%	51.606.597
2x32-2X64-1x128-512-256-5	99.14%	51.652.773
2x32-2X64-1x128-1x256-512-256-5	99,8%	26.257.829
2x32-2X64-1x128-1x256-1x512-512-256-5	99,8%	14.592.933
3x32-3X64-1x128-1x256-1x512-512-256-5	98.34%	14.639.109
VGG16	97.24%	12.978.181

Πίνακας 4.1: Συγκριτική Αξιολόγηση Μοντέλων

4.6 Συμπεράσματα

Στα πλαίσια της παρούσας εργασίας πραγματοποιήθηκε συγκριτική αξιολόγηση πέντε αρχιτεκτονικών συνελκτικών δικτύων στην αναγνώριση πέντε διαφορετικών περιπτώσεων καρκίνου του πνεύμονα και του παχέος εντέρου. Συγκεκριμένα, τα μοντέλα κλήθηκαν να ταξινομήσουν ένα σύνολο ιστοπαθολογικών εικόνων στις ακόλουθες κλάσεις: αδenoκαρκίνωμα παχέος εντέρου, καλοήθης ιστός παχέος εντέρου, αδenoκαρκίνωμα πνεύμονα, ακανθοκυτταρικό καρκίνωμα πνεύμονα και καλοήθης ιστός πνεύμονα. Στο στάδιο της προεπεξεργασίας, πραγματοποιήθηκε επαύξηση των δεδομένων εκπαίδευσης μέσω της μετατόπισης, της αλλαγής της φωτεινότητας και της μεταβολής της εστίασης των εικόνων. Στη συνέχεια, κατασκευάστηκαν πέντε αρχιτεκτονικές, αποτελούμενες από 3 έως 9 συνελκτικά επίπεδα, η απόδοση των οποίων συγκρίθηκε στο τέλος με εκείνη του προεκπαιδευμένου VGG16 δικτύου.

Μέσω της πειραματικής διαδικασίας, φάνηκε πως όλα τα μοντέλα έχουν υψηλή ικανότητα διάκρισης των πέντε κλάσεων. Η πρώτη και απλούστερη αρχιτεκτονική, με μόλις τρία συνελκτικά επίπεδα ακολουθούμενα από τα αντίστοιχα στρώματα χωρικής υποδειγματοληψίας, και τρία πλήρως συνδεδεμένα επίπεδα πέτυχε ακρίβεια 97,5%. Στη συνέχεια, με την αύξηση του πλήθους των επιπέδων, παρατηρήθηκε αυξητική τάση της ακρίβειας των μοντέλων. Συγκεκριμένα, όταν προστέθηκε στην πρώτη αρχιτεκτονική ένα επιπλέον επίπεδο συνέλιξης πριν το πρώτο και δεύτερο επίπεδο υποδειγματοληψίας, η ακρίβεια άγγιξε το 99,14%. Έπειτα, ακολούθησε η προσθήκη ενός ζεύγους στρωμάτων συνέλιξης-υποδειγματοληψίας πριν τα πλήρως συνδεδεμένα στρώματα του τελευταίου δικτύου για την ανάπτυξη της τρίτης αρχιτεκτονικής, η οποία είχε αξιοσημείωτη ακρίβεια της τάξης του 99,8%. Η τέταρτη αρχιτεκτονική, η οποία προέκυψε από την προσθήκη ενός ακόμη ζεύγους συνέλιξης-υποδειγματοληψίας, κατάφερε επίσης να ταξινομήσει σχεδόν άψογα τα δείγματα, πετυχαίνοντας, ομοίως με την προηγούμενη, ακρίβεια 99,8%. Ωστόσο, κατά την περαιτέρω αύξηση της πολυπλοκότητας του δικτύου, με την προσθήκη ενός τρίτου συνελκτικού επιπέδου πριν τα δύο πρώτα επίπεδα υποδειγματοληψίας, το μοντέλο παρουσίασε μειωμένη απόδοση, σημειώνοντας ακρίβεια 98,34%. Τέλος, το μοντέλο VGG16 πέτυχε ακρίβεια 97,24%. Οι δύο αρχιτεκτονικές που πέτυχαν την υψηλότερη ακρίβεια, δηλαδή η τρίτη και η τέταρτη, μπορούν να συγκριθούν περαιτέρω ως προς το πλήθος των παραμέτρων τους. Βάσει αυτού, προτιμότερη από τις δύο θεωρείται η τέταρτη, αφού αποτελείται από περίπου 11⁶ λιγότερες παραμέτρους.

Στο σύνολό τους, τα αποτελέσματα ήταν πολύ καλά, ωστόσο κρίνεται απαραίτητο να διερευνηθεί η γενικευσιμότητα των μοντέλων. Κάποιες μελλοντικές επεκτάσεις προς αυτή την κατεύθυνση θα μπορούσαν να περιλαμβάνουν την εφαρμογή τεχνικών, όπως επαύξηση χρώσης (color augmentation) και κανονικοποίηση χρώσης (stain normalization) στο στάδιο της προεπεξεργασίας. Αναλυτικότερα, ένα κοινό πρόβλημα στη διαχείριση

ιστοπαθολογικών εικόνων αφορά τις μεγάλες χρωματικές τους διακυμάνσεις, και τις σημαντικές αποκλίσεις τους σε επίπεδο αντίθεσης και φωτεινότητας, οι οποίες οφείλονται, μεταξύ άλλων, στο διαφορετικό εξοπλισμό που χρησιμοποιήθηκε για την παραγωγή τους. Επομένως, η εφαρμογή σχετικών τεχνικών, θα οδηγούσε δυνητικά σε σημαντική ενίσχυση της απόδοσης των μοντέλων σε άλλα σύνολα δεδομένων. Ακόμη, θα μπορούσε να πραγματοποιηθεί η εφαρμογή PCA whitening ή ZCA whitening. Τέλος, μία ακόμη μελλοντική εργασία θα μπορούσε να αφορά τη διεξαγωγή επιπλέον πειραμάτων με χρήση περισσότερων προεκπαιδευμένων δικτύων και διαφορετικών συνδυασμών παραμέτρων.

Βιβλιογραφία

- [1] “World Health Organization.” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/cancer>
- [2] “American Cancer Society.” [Online]. Available: <https://www.cancer.org/cancer/colon-rectal-cancer/detection-diagnosis-staging/survival-rates.html>
- [3] A. Hage Chehade, N. Abdallah, J. M. Marion, M. Oueidat, and P. Chauvet, “Lung and colon cancer classification using medical imaging: A feature engineering approach.” *Physical and Engineering Sciences in Medicine*, 45(3), 729-746., 2022.
- [4] A. Teramoto, T. Tsukamoto, Y. Kiriya, and H. Fujita, “Automated classification of lung cancer types from cytological images using deep convolutional neural networks.” *BioMed research international*, 2017.
- [5] M. Abbas, S. Bukhari, A. Syed, and S. Shah, “The histopathological diagnosis of adenocarcinoma & squamous cells carcinoma of lungs by artificial intelligence: A comparative study of convolutional neural networks,” *medRxiv*, 2020.
- [6] S. Mehmood, T. M. Ghazal, M. A. Khan, M. Zubair, M. T. Naseem, T. Faiz, and M. Ahmad, “Malignancy detection in lung and colon histopathology images using transfer learning with class selective image processing.” *IEEE Access*, 10, 25657-25668., 2022.
- [7] S. U. K. Bukhari, A. Syed, S. K. A. Bokhari, S. S. Hussain, S. U. Armaghan, and S. S. H. Shah, “The histological diagnosis of colonic adenocarcinoma by applying partial self supervised learning.” *MedRxiv*, 2020.
- [8] I. Vlahavas, P. Kefalas, N. Vasilidis, F. Kokkoras, and H. Sakellariou, *Artificial Intelligence*. 4th Edition, Thessaloniki, University of Macedonia Press, 2020.
- [9] K. Amit, “Artificial intelligence and soft computing: behavioral and cognitive modeling of the human brain.” *CRC press.*, 2018.
- [10] C. E. Shannon, “XXII. Programming a computer for playing chess,” *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, pp. 256–275, 1950.
- [11] E. A. "Feigenbaum and J. Feldman, “Computers and thought,” (Vol. 7), *McGraw-Hill: New York*, 1963.

- [12] E. H. Shortliffe, "Mycin: a rule-based computer program for advising physicians regarding antimicrobial therapy selection." *Stanford Univ Calif Dept of Computer Science.*, 1974.
- [13] R. Abduljabbar, Dia, H., S. Liyanage, and S. A. Bagloee, "Applications of artificial intelligence in transport: An overview." *Sustainability*, 11(1), 189., 2019.
- [14] N. Misra, Y. Dixit, A. Al-Mallahi, M. S. Bhullar, R. Upadhyay, and A. Martynenko, "IoT, big data, and artificial intelligence in agriculture and food industry." *IEEE Internet of things Journal*, 9(9), 6305-6324, 2020.
- [15] R. Ben Ayed and M. Hanana, "Artificial intelligence to improve the food and agriculture sector." *Journal of Food Quality*, 2021, 1-7, 2021.
- [16] D. Lee and S. N. Yoon, "Application of artificial intelligence-based technologies in the healthcare industry: Opportunities and challenges," *International Journal of Environmental Research and Public Health*, 18(1), 271., 2021.
- [17] N. M. Ball and R. J. Brunner, "Data mining and machine learning in astronomy." *International Journal of Modern Physics D*, 19(07), 1049-1106., 2010.
- [18] L. Chen, P. Chen, and Z. Lin, "Artificial intelligence in education: A review." *Ieee Access*, 8, 75264-75278., 2020.
- [19] K. Nikolskaia and V. Naumov, "Artificial intelligence in law." In *2020 International Multi-Conference on Industrial Engineering and Modern Technologies (Far-EastCon) (pp. 1-4)*. IEEE., 2020.
- [20] M. I. Jordan and T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects." *Science*, 349(6245), 255-260., 2015.
- [21] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep learning for computer vision: A brief review." *Computational intelligence and neuroscience*, 2018., 2018.
- [22] P. M. Nadkarni, L. Ohno-Machado, and W. W. Chapman, "Natural language processing: an introduction." *Journal of the American Medical Informatics Association*, 18(5), 544-551., 2011.
- [23] J. Hirschberg and C. D. Manning, "Advances in natural language processing," *Science*, 349(6245), 261-266., 2015.
- [24] V. Kaul, S. Enslin, and S. A. Gross, "History of artificial intelligence in medicine." *Gastrointestinal endoscopy*, 92(4), 807-812., 2020.
- [25] E. J. Topol, "High-performance medicine: the convergence of human and artificial intelligence." *Nature medicine*, 25(1), 44-56., 2019.
- [26] K. Koutroumbas and S. Theodoridis, "Pattern recognition." *Academic Press*, 2008.

- [27] K. Doi, "Computer-aided diagnosis in medical imaging: historical review, current status and future potential." *Computerized medical imaging and graphics*, 31(4-5), 198-211., 2007.
- [28] V. Gulshan, L. Peng, M. Coram, M. C. Stumpe, D. Wu, A. Narayanaswamy, and D. R. Webster, "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs." *Jama*, 316(22), 2402-2410., 2016.
- [29] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, and S. Thrun, "Dermatologist-level classification of skin cancer with deep neural networks." *nature*, 542(7639), 115-118, 2017.
- [30] B. E. Bejnordi, M. Veta, P. J. Van Diest, B. Van Ginneken, N. Karssemeijer, G. Litjens, and C. Consortium., "Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer," *Jama*, 318(22), 2199-2210., 2017.
- [31] Z. Jeddi and A. Bohr, "Remote patient monitoring using artificial intelligence." *In Artificial Intelligence in Healthcare (pp. 203-234). Academic Press.*, 2020.
- [32] A. Bohr and K. Memarzadeh, "The rise of artificial intelligence in healthcare applications." *. In Artificial Intelligence in healthcare (pp. 25-60). Academic Press.*, 2020.
- [33] G. Turchetti, I. Palla, F. Pierotti, and A. Cuschieri, "Economic evaluation of da vinci-assisted robotic surgery: a systematic review." *Surgical endoscopy*, 26(3), 598-606., 2012.
- [34] D. Paul, G. Sanap, S. Shenoy, D. Kalyane, K. Kalia, and R. K. Tekade, "Artificial intelligence in drug discovery and development." *Drug discovery today*, 26(1), 80., 2021.
- [35] S. Reddy, J. Fox, and M. P. Purohit, "Artificial intelligence-enabled healthcare delivery." *ournal of the Royal Society of Medicine*, 112(1), 22-28., 2019.
- [36] A. L. Samuel, "Some studies in machine learning using the game of checkers," *IBM J. Res. Develop.*, vol. 3, no. 3, pp. 210-229, Jul., 1959.
- [37] P. Langley and J. G. Carbonell, "Machine learning: techniques and foundations." 1987.
- [38] T. Mitchell, "Machine learning." (Vol. 1, No. 9), *New York: McGraw-hill*, 1997.
- [39] S. J. Russell, "Artificial intelligence a modern approach." *Pearson Education, Inc.*, 2010.
- [40] N. Al-Azzam and I. Shatnawi, "Comparing supervised and semi-supervised machine learning models on diagnosing breast cancer." *Annals of Medicine and Surgery*, 62, 53-64., 2021.

- [41] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey." *Journal of artificial intelligence research*, 4, 237-285., 1996.
- [42] R. S. Sutton and A. G. Barto, "Reinforcement learning: An introduction." *MIT press*, 2018.
- [43] C. Sammut and G. I. Webb, "Encyclopedia of machine learning." *Springer Science & Business Media.*, 2011.
- [44] M. J. Zaki and W. Meira, "Data mining and analysis: fundamental concepts and algorithms." *Cambridge University Press.*, 2014.
- [45] A. K. Jain, R. P. W. Duin, and J. Mao, "Statistical pattern recognition: A review." *IEEE Transactions on pattern analysis and machine intelligence*, 22(1), 4-37., 2000.
- [46] L. Chen, "Curse of dimensionality." In *Encyclopedia of database systems.*, 2009.
- [47] R. Bellman, "Adaptive control processes: A guided tour," *Princeton University Press.*, 1961.
- [48] M. Steinbach, L. Ertöz, and V. Kumar, "The challenges of clustering high dimensional data." In *New directions in statistical physics (pp. 273-309)*. Springer, Berlin, Heidelberg., 2004.
- [49] C. C. Aggarwal, A. Hinneburg, and D. A. Keim, "On the surprising behavior of distance metrics in high dimensional space." In *International conference on database theory (pp. 420-434)*. Springer, Berlin, Heidelberg., 2001.
- [50] R. Clarke, H. W. Resson, A. Wang, J. Xuan, M. C. Liu, E. A. Gehan, and Y. Wang, "The properties of high-dimensional data spaces: implications for exploring gene and protein expression data." *Nature reviews cancer*, 8(1), 37-49., 2008.
- [51] L. Van Der Maaten, E. Postma, and J. Van den Herik, "Dimensionality reduction: a comparative." *J Mach Learn Res*, 10(66-71), 13., 2009.
- [52] S. Khalid, T. Khalil, and S. Nasreen, "A survey of feature selection and feature extraction techniques in machine learning." In *2014 science and information conference (pp. 372-378)*. IEEE., 2014.
- [53] A. C. Neves, I. Gonzalez, J. Leander, and R. Karoumi, "A new approach to damage detection in bridges using machine learning." In *Experimental Vibration Analysis for Civil Structures: Testing, Sensing, Monitoring, and Control 7 (pp. 73-84)*. Springer International Publishing., 2018.
- [54] B. Macukow, "Neural networks—state of art, brief history, basic models and architecture." In *Computer Information Systems and Industrial Management: 15th IFIP TC8 International Conference, CISIM 2016, Vilnius, Lithuania, September 14-16, 2016, Proceedings 15 (pp. 3-14)*. Springer International Publishing., 2016.

- [55] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity." *The bulletin of mathematical biophysics*, 5, 115-133., 1943.
- [56] D. O. Hebb, "The organization of behavior: A neuropsychological theory." *Psychology Press.*, 2005.
- [57] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological review*, 65(6), 386., 1958.
- [58] B. Widrow and M. E. Hoff, "Adaptive switching circuits," *Stanford Univ Ca Stanford Electronics Labs.*, 1960.
- [59] M. Minsky and S. Papert, "Perceptron: an introduction to computational geometry." *MIT Press, Cambridge*, 1969.
- [60] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities." *Proceedings of the national academy of sciences*, 79(8), 2554-2558., 1982.
- [61] D. E. Rumelhart, "Learning internal representations by error propagation, in parallel distributed processing." *Explorations in the Microstructure of Cognition*, 318-362., 1986.
- [62] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning." *nature*, 521(7553), 436-444., 2015.
- [63] F. Martinez-Alvarez, A. Troncoso, G. Asencio-Cortes, and J. C. Riquelme, "A survey on data mining techniques applied to electricity-related time series forecasting." *Energies*, 8(11), 13162-13193, 2015.
- [64] S. Sharma, S. Sharma, and A. Athaiya, "Activation functions in neural networks." *Towards Data Sci*, 6(12), 310-316., 2017.
- [65] M. Negnevitsky, "Artificial intelligence: a guide to intelligent systems." *Pearson education.*, pp.169, 2005.
- [66] C. C. Aggarwal, "Neural networks and deep learning." *Springer*, 10(978), 3., 2018.
- [67] A. D. Rasamoelina, F. Adjailia, and P. Sinčák, "A review of activation function for artificial neural network." *In 2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI) (pp. 281-286). IEEE.*, 2020, January.
- [68] G. Cybenko, "Approximation by superpositions of a sigmoidal function." *Mathematics of control, signals and systems*, 2(4), 303-314., 1989.
- [69] K. Hornik, "Approximation capabilities of multilayer feedforward networks." *Neural networks*, 4(2), 251-257., 1991.
- [70] D. R. Guérillot and J. Bruyelle, "Uncertainty assessment in production forecast with an optimal artificial neural network." *In SPE Middle East oil & gas show and conference. OnePetro.*, 2017.

- [71] V. N. Sewdien, R. Preece, J. R. Torres, E. Rakhshani, and M. A. M. M. van der Meijden, "Assessment of critical parameters for artificial neural networks based short-term wind generation forecasting." *Renewable Energy*, 161, 878-892., 2020.
- [72] Y. Zhou, X. Wang, M. Zhang, J. Zhu, R. Zheng, and Q. Wu, "Mpce: a maximum probability based cross entropy loss function for neural network classification." *IEEE Access*, 7, 146331-146341., 2019.
- [73] S. Jadon, "A survey of loss functions for semantic segmentation." In *2020 IEEE conference on computational intelligence in bioinformatics and computational biology (CIBCB) (pp. 1-7)*. IEEE., 2020, October.
- [74] N. Qian, "On the momentum term in gradient descent learning algorithms." *Neural networks*, 12(1), 145-151., 1999.
- [75] J. Duchi, E. Hazan, and Y. Singer, "Adaptive subgradient methods for online learning and stochastic optimization." *Journal of machine learning research*, 12(7), 2011.
- [76] M. D. Zeiler, "Adadelta: an adaptive learning rate method." *arXiv preprint arXiv:1212.5701*., 2012.
- [77] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization." *arXiv preprint arXiv:1412.6980*., 2014.
- [78] S. Ruder, "An overview of gradient descent optimization algorithms." *arXiv preprint arXiv:1609.04747*., 2016.
- [79] S. Shin, T. T. Hoang, T. H. Le, and M. Y. Lee, "A new robust design method using neural network." *Journal of Nanoelectronics and Optoelectronics*, 11(1), 68-78., 2016.
- [80] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting." *The journal of machine learning research*, 15(1), 1929-1958., 2014.
- [81] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, and T. Chen, "Recent advances in convolutional neural networks." *Pattern recognition*, 77, 354-377., 2018.
- [82] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position." *Biological cybernetics*, 36(4), 193-202., 1980.
- [83] D. H. Hubel and T. N. Wiesel, "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex." *The Journal of physiology*, 160(1), 106., 1962.

- [84] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition." *Proceedings of the IEEE*, 86(11), 2278-2324., 1998.
- [85] S. A. Bello, S. Yu, C. Wang, J. M. Adam, and J. Li, "Deep learning on 3d point clouds." *Remote Sensing*, 12(11), 1729., 2020.
- [86] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network." In *2017 international conference on engineering and technology (ICET) (pp. 1-6). Ieee.*, 2017.
- [87] K. C. Santosh, N. Das, and S. Ghosh, "Deep learning models for medical imaging." *Academic Press.*, pp.53, 2021.
- [88] K. O'Shea and R. Nash, "An introduction to convolutional neural networks." *arXiv preprint arXiv:1511.08458.*, 2015.
- [89] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition." *arXiv preprint arXiv:1409.1556*, 2014.
- [90] M. Ferguson, R. Ak, Y. T. T. Lee, and K. H. Law, "Automatic localization of casting defects with convolutional neural networks." In *2017 IEEE international conference on big data (big data) (pp. 1726-1735). IEEE.*, 2017.
- [91] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition." In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).*, 2016.
- [92] F. Chollet, "Xception: Deep learning with depthwise separable convolutions." In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1251-1258).*, 2017.
- [93] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications." *arXiv preprint arXiv:1704.04861.*, 2017.
- [94] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks." In *Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).*, 2017.
- [95] A. A. Borkowski, M. M. Bui, L. B. Thomas, C. P. Wilson, L. A. DeLand, and S. M. Mastorides, "Lung and colon cancer histopathological image dataset (lc25000)." *arXiv preprint arXiv:1912.12142*, 2019.

