



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ, ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΠΑΡΚΙΝΣΟΝ ΜΕΣΩ ΒΑΔΙΣΗΣ ΜΕ ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΕΙΡΗΝΗ ΝΤΑΡΟΥΪΣ

Επιβλέπων : Ανδρέας – Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

Αθήνα, Σεπτέμβριος 2020



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ, ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΠΑΡΚΙΝΣΟΝ ΜΕΣΩ ΒΑΔΙΣΗΣ ΜΕ ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΕΙΡΗΝΗ ΝΤΑΡΟΥΪΣ

Επιβλέπων: Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24^η Σεπτέμβρη 2020.

.....
Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

.....
Στέφανος Κόλλιας
Καθηγητής Ε.Μ.Π

.....
Γεώργιος Στάμου
Αν. Καθηγητής Ε.Μ.Π

Αθήνα, Σεπτέμβριος 2020

.....
ΕΙΡΗΝΗ ΝΤΑΡΟΥΪΣ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών
Ε.Μ.Π.

Copyright © Ειρήνη Νταρουΐς, 2020.

Με επιφύλαξη παντός δικαιώματος. All rights reserved. Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός μοντέλου για την αναγνώριση της νόσου του Parkinson, με χρήση αλγορίθμων μηχανικής μάθησης. Η χρήση της τεχνητής νοημοσύνης και της μηχανικής μάθησης για την ιατρική διάγνωση είναι πεδίο εντατικής μελέτης, με μεγάλη εξέλιξη τα τελευταία χρόνια. Συγκεκριμένα για τη νόσο Parkinson, η διάγνωση αποτελεί πρόκληση, καθώς αυτή γίνεται με κλινική εξέταση και εξαρτάται σε μεγάλο βαθμό από την κρίση και την εμπειρία του γιατρού. Αξίζει, λοιπόν, να μελετηθεί κατά πόσο η μηχανική μάθηση είναι σε θέση να παρέχει ένα συστηματικό εργαλείο για την διάγνωση της ασθένειας.

Για το πειραματικό κομμάτι, η βάση δεδομένων που χρησιμοποιήθηκε για την ανάπτυξη και εκπαίδευση των μοντέλων αποτελείται από δεδομένα από αισθητήρες που καταγράφουν την δύναμη αντίδρασης του δαπέδου (VGRF) κατά τη βάρδια τόσο ασθενών με τη νόσο, όσο και υγιών ανθρώπων. Ειδικότερα, εστίασαμε σε τεχνικές βαθιάς μάθησης, δοκιμάζοντας διαφορετικά μοντέλα με συνελκτικά νευρωνικά δίκτυα (CNN) και δίκτυα μακράς-βραχείας μνήμης (LSTM). Πιο συγκεκριμένα, αρχικά υλοποιήθηκε ένα απλό μοντέλο με συνελκτικά και πλήρως συνδεδεμένα επίπεδα. Στη συνέχεια, αναπτύχθηκε ένα υβριδικό μοντέλο με CNN-LSTM επίπεδα. Το CNN κομμάτι χρησιμοποιήθηκε για να εξάγει χαρακτηριστικά από τις εισόδους, τα οποία δόθηκαν ως είσοδος στο LSTM κομμάτι για αναγνώριση μεγαλύτερων χρονικών εξαρτήσεων, και έτσι την καλύτερη κατηγοριοποίηση σε ασθενή ή υγιή. Περαιτέρω, υλοποιήθηκε ένα βαθύ Συνελκτικό Νευρωνικό Δίκτυο, στο οποίο το μοναδικό επίπεδο υποδειγματοληψίας, ήταν το καθολικό επίπεδο υποδειγματοληψίας μέσου όρου (Global Average Pooling), περιορίζοντας το πρόβλημα της υπερπροσαρμογής που υπήρχε σε άλλες υλοποιήσεις. Παράλληλα, υλοποιήθηκαν και δύο μοντέλα με κλασικές μεθόδους μηχανικής μάθησης, με χρήση των «Κ-Κοντινότεροι Γείτονες» και «Μηχανές Διανυσμάτων Υποστήριξης» ως μοντέλα αναφοράς για τη σύγκριση και αξιολόγηση της απόδοσης των βαθιών νευρωνικών. Τα μοντέλα αυτά, χρησιμοποιήθηκαν, αφού πρώτα έγινε στατιστική εξαγωγή χαρακτηριστικών των δεδομένων των αισθητήρων. Για την απόδοση χρησιμοποιήθηκαν διάφορες μετρικές. Οι τεχνικές βαθιάς μάθησης πέτυχαν καλύτερα αποτελέσματα στην κατηγοριοποίηση, σε σύγκριση με τις άλλες μεθόδους, όπου η εξαγωγή χαρακτηριστικών είχε γίνει χειροκίνητα. Μάλιστα, το υβριδικό CNN-LSTM μοντέλο και το βαθύ Συνελκτικό με Global Average Pooling επίπεδο, είχαν τα πιο αξιόλογα αποτελέσματα, πετυχαίνοντας συνολική ορθότητα 94% και 95% αντίστοιχα.

Λέξεις-κλειδιά

Νόσος Parkinson, Μηχανική Μάθηση, Βαθιά Μάθηση, Νευρωνικά Δίκτυα, Συνελκτικά Δίκτυα, Νευρώνες Μακράς και Βραχείας Μνήμης, Υβριδικό μοντέλο, Επιβλεπόμενη μάθηση, Δυναμική ταξινόμηση

Abstract

The scope of this thesis is the development of a model for Parkinson's disease diagnosis, using machine learning techniques. Artificial intelligence and Machine Learning for medical diagnosis is a field with intensive research, demonstrating significant progress over the last few years. As far as Parkinson's disease is concerned, diagnosis is a challenging task for doctors, since it is based on clinical examination, and depends heavily on doctor's estimation and experience. Therefore, the possibility of leveraging machine learning techniques to develop a systematic tool would bring significant added value to objective and timely diagnosis of Parkinson's disease.

The dataset used for the development and training of the models, is composed from sensors' records, calculating the Virtual Ground Reaction Force (VGFR), during the gait of both patients and control subjects. Deep learning methods are proposed to process GRF to accurately categorize gait pattern, based on convolutional and long-short term memory neural network architectures. Initially, a model with convolutional and fully-connected layers was implemented. Afterwards, a hybrid model with Convolutional and LSTM layers was applied. The main idea behind this approach is to use the CNN part as feature extractor that supplies the LSTM part with the most discriminative features of the input achieving in parallel dimensionality reduction. Additionally, a Deep Convolutional Model was implemented, with only one pooling layer, and specifically a Global Average Pooling layer. Thus, the problem of overfitting, occurred in other models, was drastically lessened. Alongside, two models with classical machine learning methods (kNN and SVM) are implemented, as a baseline in order to compare them with the neural networks. Statistical feature extraction was performed, before feeding the data to these models. Several metrics are used to evaluate the performance of the models. Deep learning considerably achieved better classification results, compared to the other models with the handcrafted features. In fact, the hybrid CNN-LSTM model and the Deep Convolutional model had the best results, achieving accuracy performance of 94% and 95%, respectively.

Keywords

Parkinson Disease, Machine Learning, Deep Learning, Neural Network, Convolutional Neural Network, Long-short Term memory, Hybrid model, Supervised Learning, Binary classification

Ευχαριστίες

Η εκπόνηση της παρούσας διπλωματικής εργασίας κλείνει τον κύκλο σπουδών μου στη σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών Ε.Μ.Π. Θα ήθελα να εκφράσω τις ευχαριστίες μου στον επιβλέποντα της διπλωματικής μου εργασίας, κ. Ανδρέα Σταφυλοπάτη, καθηγητή Ε.Μ.Π, για την ευκαιρία που μου έδωσε να ασχοληθώ με ένα τόσο ενδιαφέρον θέμα. Επίσης, θα ήθελα να ευχαριστήσω θερμά τον Γιώργο Ιωάννου, υποψήφιο διδάκτορα Ε.Μ.Π, για την καθοριστικής σημασίας συμβολή του στην εκπόνηση της παρούσας διπλωματικής εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω τους γονείς μου, τα αδέρφια μου, τον Σταύρο και τους φίλους μου για τη στήριξη κατά τη διάρκεια της διπλωματικής εργασίας.

Περιεχόμενα

Abstract	7
Ευχαριστίες.....	9
ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ.....	12
1.1 Εισαγωγή	12
1.2 Οργάνωση Εργασίας.....	15
Κεφάλαιο 2: Βιβλιογραφικές αναφορές.....	16
ΚΕΦΑΛΑΙΟ 3: ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ	19
3.1 Τεχνητή νοημοσύνη- Μηχανική μάθηση	19
3.2 Ο αλγόριθμος Κ-Κοντινότεροι γείτονες (KNN).....	21
3.3 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	22
3.3.1 Τεχνητός Νευρώνας	22
3.3.2 Βασικές αρχές Τεχνητών Νευρωνικών Δικτύων.....	23
3.4 ΕΚΠΑΙΔΕΥΣΗ	26
3.4.1 Συναρτήσεις κόστους.....	28
3.4.2 Βελτιστοποίηση	29
3.5 ΜΕΤΡΙΚΕΣ ΑΞΙΟΛΟΓΗΣΗΣ.....	30
3.6 Συνελκτικά νευρωνικά δίκτυα (CNN).....	32
Τρόπος λειτουργίας των CNN	32
3.7 ΑΝΑΔΡΟΜΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	35
3.7.1 Εκπαίδευση αναδρομικών νευρωνικών δικτύων.....	36
3.7.2 Δίκτυα Μακράς Βραχείας Μνήμης.....	36
3.8 Μηχανές διανυσμάτων υποστήριξης – SVM	39
3.8.1 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΤΩΝ SVM	40
3.9 Στατιστική εξαγωγή χαρακτηριστικών.....	42
ΚΕΦΑΛΑΙΟ 4: ΥΛΟΠΟΙΗΣΗ.....	44
4.1 Δεδομένα	44
4.2 Μοντέλα SVM και KNN	45
4.3 Μοντέλα Βαθιάς Μάθησης	47
4.3.1 Προεπεξεργασία δεδομένων	47
4.3.2 ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ ΤΩΝ ΜΟΝΤΕΛΩΝ.....	48
4.4 ΕΡΓΑΛΕΙΑ.....	53
ΚΕΦΑΛΑΙΟ 5: ΑΠΟΤΕΛΕΣΜΑΤΑ - ΣΥΜΠΕΡΑΣΜΑΤΑ	55
5.1 Αποτελέσματα και συμπεράσματα	55
5.2 Σύνοψη και μελλοντικές κατευθύνσεις	60
ΚΕΦΑΛΑΙΟ 6: ΒΙΒΛΙΟΓΡΑΦΙΑ.....	62

ΚΕΦΑΛΑΙΟ 1: ΕΙΣΑΓΩΓΗ

1.1 Εισαγωγή

Στις μέρες μας, η μηχανική μάθηση αποτελεί έναν τομέα της τεχνολογίας που αναπτύσσεται με ταχύτατους ρυθμούς μέρα με τη μέρα. Παρατηρείται μία μεταστροφή προς τον χώρο της μηχανικής μάθησης, τόσο σε ερευνητικό πεδίο, με δεκάδες περιοδικά και συνέδρια να δημοσιεύονται και να διεξάγονται συνεχώς, όσο και σε πρακτικές και εμπορικές εφαρμογές της ζωής μας. Αυτό που κάνει τα μοντέλα μηχανικής μάθησης να ξεχωρίζουν είναι η ικανότητα τους, αξιοποιώντας ένα σύνολο δεδομένων, να εκπαιδεύονται πάνω σε αυτό, με σκοπό την τέλεση χρήσιμων λειτουργιών, όπως η ταξινόμηση ή πρόβλεψη στο μέλλον. Τομείς στους οποίους γίνεται εκτενής χρήση της μηχανικής μάθησης και των νευρωνικών δικτύων περιλαμβάνουν την όραση υπολογιστών και την επεξεργασία φυσικής γλώσσας. Οι τομείς αυτοί έχουν αναπτυχθεί και εξελιχθεί πολύ με τη χρήση της μηχανικής μάθησης και είναι άρρηκτα συνδεδεμένοι με αυτήν. Ωστόσο, η μηχανική μάθηση χρησιμοποιείται και σε πολλούς άλλους τομείς. Ορισμένοι από αυτούς είναι οι χρηματοοικονομικές υπηρεσίες, η λιανική πώληση, πχ με πρόβλεψη ζήτησης και στοχευμένο μάρκετινγκ, και ο τομέας των μέσων δικτύωσης, πχ με προσωποποιημένο περιεχόμενο και εξατομικευμένες προτάσεις.

Ένα άλλο πολύ σημαντικό πεδίο εφαρμογής της μηχανικής μάθησης τα τελευταία χρόνια είναι η **ιατρική**, βελτιώνοντας τις υπηρεσίες υγείας. Μία πολύ σημαντική εφαρμογή της είναι η συμβολή στη διάγνωση διαφόρων ασθενειών. Παραδείγματος χάριν, η εφαρμογή IBM Watson Genomics, με βάση αλληλουχίας του γονιδιώματος βοηθάει τους γιατρούς να κάνουν μία έγκαιρη διάγνωση όγκων[2]. Επίσης, αλγόριθμοι μηχανικής μάθησης αναγνώρισης ανωμαλιών (anomaly detection), χρησιμοποιούνται ώστε να προβλέψουν πιθανές επιπλοκές, όπως εγκεφαλικά, προειδοποιώντας το υγειονομικό προσωπικό για επικείμενους κινδύνους των ασθενών. Για παράδειγμα, στο νοσοκομείο EL Camino, ερευνητές συνδύασαν ηλεκτρονικές ιατρικές εγγραφές για τη δημιουργία ενός εργαλείου πρόβλεψης πτώσης του ασθενούς [30]. Άλλοι τομείς στην υγεία, στους οποίους αξιοποιείται η μηχανική μάθηση, είναι στην ανακάλυψη φαρμάκων, στην συμβολή σε κλινικές δοκιμές και στην ιατρική έρευνα, βοηθώντας και επιταχύνοντας πολλές

χρονοβόρες διαδικασίες. Μάλιστα, ερευνητές από την Ιρλανδία και τις Ηνωμένες Πολιτείες συνεργάστηκαν σε μία έρευνα για ανεπιθύμητες παρενέργειες φαρμάκων, όπου με χρήση νευρωνικών δικτύων και ανάλυση κειμένου, ανέλυσαν δεδομένα από πάνω 300.000 ιατρικά περιοδικά, μια διαδικασία που αν γινόταν χειροκίνητα θα απαιτούσε χρόνια.

Στην παρούσα διπλωματική εργασία, μελετάται η συμβολή της μηχανικής μάθησης στην **διάγνωση της νόσου Parkinson**. Η νόσος Parkinson είναι μια προοδευτική και εκφυλιστική νευρολογική διαταραχή, η οποία προκαλεί απώλεια ελέγχου των σωματικών κινήσεων. Πρώτη φορά περιγράφηκε από τον Άγγλο γιατρό James Parkinson το 1817 στην μονογραφία του «An Essay on the Shaking Palsy» [1]. Στην εργασία του αυτή περιγράφοντας έξι ασθενείς με τα συμπτώματα της νόσου εισήγαγε πρώτη φορά τον όρο «τρομώδης παράλυση» και περιέγραψε με αρκετή σαφήνεια τη νόσο. Στις μέρες μας, πάνω από 5 εκατομμύρια άνθρωποι εμφανίζουν την νόσο. Επιδημιολογικές μελέτες, μάλιστα, αναφέρουν ότι περί το έτος 2040 η νόσος του Parkinson θα αποτελεί τη δεύτερη συχνότερη αιτία θανάτου μετά τον καρκίνο, ενώ είναι η δεύτερη σε σειρά συχνότητας νευροεκφυλιστική νόσος μετά τη νόσο του Alzheimer.

Στα άτομα με Νόσο Parkinson μία χημική ουσία στον εγκέφαλο, η ντοπαμίνη, η οποία βοηθά να μεταφέρονται τα σήματα εντός του εγκεφάλου, μειώνεται βαθμιαία. Τα συμπτώματα της νόσου καλύπτουν ένα ευρύ φάσμα διάφορων λειτουργιών. Σε αυτά περιλαμβάνονται η αίσθηση κόπωσης και απώλεια δύναμης, η χαμηλή φωνή, η υποβάθμιση της ποιότητας γραφής, ακόμη και ψυχικές διαταραχές. Πολλά αφορούν την **διαταραχή του κινητικού ελέγχου**, με τα πιο κοινά να είναι η δυσκαμψία στα άκρα, ο τρόμος ηρεμίας, η μειωμένη ισορροπία, η βραδυκινησία και η αστάθεια και τα επεισόδια παγώματος (freezing). Δυστυχώς, δεν υπάρχει μία πρότυπη θεραπεία για τη νόσο. Ειδικότερα, η αντιμετώπιση για τη νόσο ποικίλει ανάλογα με το στάδιο στο οποίο βρίσκεται ο ασθενής και περιλαμβάνει από φυσική και νοητική άσκηση, πρόσληψη φαρμάκων, έως και χειρουργική αντιμετώπιση. Εστιάζει, κυρίως στην επιβράδυνση της εξέλιξης της νόσου και στην ύφεση των συμπτωμάτων. Για αυτό, είναι πολύ σημαντική η έγκαιρη διάγνωση στα αρχικά στάδια της ασθένειας.

Η διάγνωση της νόσου Parkinson αποτελεί πρόκληση για τους γιατρούς, διότι αυτή συνίσταται από κλινική εξέταση με βάση τα συμπτώματα των ασθενών και όχι από κάποια καθορισμένη_αιματολογική ή βιοχημική εξέταση. Βασίζεται στα κλινικά διαγνωστικά κριτήρια της United Kingdom Parkinson's Disease Society Brain Bank (UPDRS) [] .

Συγκεκριμένα, οι γιατροί εξετάζουν **πιθανή βραδυκίνηση**, σε συνδυασμό με το αν τα υποκείμενα πληρούν τουλάχιστον ένα από τα παρακάτω:

- 1. Δυσκαμψία**
- 2. Τρόμος ηρεμίας 4-6 Hz**
- 3. Διαταραχή ισορροπίας.**

Έτσι, η ανάλυση της κίνησης, είναι ένα σημαντικό κριτήριο στη διάγνωση του Parkinson.

Η εργασία αυτή, όπως έχει αναφερθεί και πρωτίτερα, έχει ως σκοπό την ανάπτυξη ενός συστήματος με χρήση της Μηχανικής Μάθησης, που θα μπορούσε να αποτελέσει ένα βοηθητικό εργαλείο στα χέρια των γιατρών για τη διάγνωση του Parkinson στα αρχικά στάδια, αναλύοντας δεδομένα βάρδισης ασθενών με τη νόσο. Τα δεδομένα που χρησιμοποιήθηκαν λήφθηκαν από το Physionet[18]. Η βάση δεδομένων αποτελείται από δεδομένα από 93 ασθενείς με νόσο Parkinson και 73 υγιείς ανθρώπους. Συγκεκριμένα, περιλαμβάνει καταγραφές από αισθητήρες, τοποθετημένους στα κάτω άκρα των υποκειμένων, κατά την διάρκεια της κίνησης τους για χρονική διάρκεια 2 λεπτά. Στην παρούσα εργασία, η προσοχή εστιάστηκε στην βαθιά μάθηση, η οποία είναι κλάδος της Μηχανικής Μάθησης που καταπιάνεται με πιο περίπλοκες και συνήθως μη γραμμικές αρχιτεκτονικές αλγορίθμων. Δύο αρχιτεκτονικές βαθιάς μάθησης είχαν τα καλύτερα αποτελέσματα, με την υλοποίηση τους και τα αποτελέσματα να αναλύονται εκτενώς στο κεφάλαιο [4^ο](#) και [5^ο](#) αντίστοιχα. Επιπρόσθετα, συγκρίνουμε τις μεθόδους αυτές με κλασικές μεθόδους μηχανικής μάθησης, και συγκεκριμένα τις μεθόδους «Κ-Κοντινότεροι Γείτονες» και «Μηχανές Διανυσμάτων Υποστήριξης».

1.2 Οργάνωση Εργασίας

Η παρούσα διπλωματική εργασία κατανέμεται σε πέντε κεφάλαια. Στο κεφάλαιο 2, περιγράφονται συνοπτικά παρεμφερείς εργασίες που έχουν προηγηθεί σχετικές με το αντικείμενο της διπλωματικής εργασίας. Στο κεφάλαιο 3, πρόκειται να περιγραφεί αναλυτικά το θεωρητικό υπόβαθρο, πάνω στο οποίο βασίστηκε η εργασία και αποτελεί βασική προϋπόθεση για την κατανόηση της. Αρχικά, γίνεται αναφορά σε βασικές έννοιες για την μηχανική μάθηση. Στη συνέχεια, αναλύονται σε θεωρητικό επίπεδο οι αλγόριθμοι και οι τεχνικές μηχανικής μάθησης που χρησιμοποιούνται στην παρούσα εργασία. Στο κεφάλαιο 4, περιγράφεται η μεθοδολογία που επιλέχθηκε. Από την ανάλυση της προεπεξεργασίας των δεδομένων, η οποία αποτελεί βασικό στοιχείο της επιτυχίας των μοντέλων, μέχρι τα βήματα της υλοποίησης των αλγορίθμων δίνεται η δυνατότητα στον αναγνώστη της ολοκληρωμένης κατανόησης των μοντέλων, που δημιουργήθηκαν στα πλαίσια της εργασίας. Στο κεφάλαιο 5, παρουσιάζονται τα αποτελέσματα των μοντέλων, εξάγοντας τα συμπεράσματα της διπλωματικής και παρέχοντας κατευθυντήριες ιδέες για την εξέλιξη τους.

Κεφάλαιο 2: Ανασκόπηση βιβλιογραφίας

Στο κεφάλαιο αυτό, παρατίθενται συγγενείς έρευνες και εργασίες γύρω από το πεδίο της νόσου Parkinson. Είναι γεγονός πως τα τελευταία χρόνια, έχουν γίνει πολλές μελέτες για το πρόβλημα της διάγνωσης, όσο και της αναγνώρισης της σοβαρότητας του Parkinson. Τα δεδομένα που χρησιμοποιούνται για την εκμάθηση των μοντέλων ποικίλουν.

Αρχικά, έχουν γίνει πολλές έρευνες πάνω σε δεδομένα φωνής και σημάτων ομιλίας. Οι (Indira R. Et al.,2014) [6] πρότειναν μία τεχνική μηχανικής μάθησης για την διάγνωση του Parkinson μέσω της ομιλίας. Συγκεκριμένα, χρησιμοποίησαν fuzzy C-means ομαδοποίηση και την αναγνώριση μοτίβων για την διάκριση μεταξύ Παρκινσονιακών και μη, πετυχαίνοντας ακρίβεια 68% και ευαισθησία 75,34%. Οι (A. Tsanas et al.,2011) [7] από σήματα ομιλίας, εξήγαγαν 132 χαρακτηριστικά δυσφωνίας. Χρησιμοποιώντας αλγορίθμους για την επιλογή χαρακτηριστικών, εξήγαγαν ένα υποσύλλο των χαρακτηριστικών αυτών, το οποίο δόθηκε ως είσοδος στους ταξινομητές «Τυχαία δάση» (Random Forest) και Support Vector Machines. Χρησιμοποιώντας ένα μικρό σύνολο από ασθενείς, κατάφεραν να διαχωρίσουν τους ασθενείς με τη νόσο από τους υγιείς με ορθότητα 99%. Οι (Ma C., et, al,2014) με δεδομένα σημάτων ομιλίας πρότειναν ένα υβριδικό μοντέλο, το «Kernel-Based Extreme Learning Machine with Subtractive Clustering Features Weighting (SCFW-KELM)» [11]. Το κομμάτι SCFW χρησιμοποιείται ως εργαλείο προεπεξεργασίας για την μείωση της διακύμανσης των χαρακτηριστικών του συνόλου δεδομένων, ενώ το KELM είναι ο ταξινομητής για τη διάγνωση της ασθένειας. Τα αποτελέσματα συγκρίθηκαν και με κλασικές μεθόδους SVM, KNN, ELM, πετυχαίνοντας τα υψηλότερα αποτελέσματα, καθώς από αποτελέσματα διαφόρων ιατρικών εξετάσεων που πραγματοποιήθηκαν σε ασθενείς, πέτυχαν ορθότητα έως και 99%.

Οι (Wu D et al, 2010) [31], αξιοποίησαν δεδομένα από καταγραφές ηλεκτροδίων, στο εσωτερικό του κρανίου για την πρόβλεψη δραστηριότητας σχετικής με την έναρξη του συμπτώματος του τρόμου. Χρησιμοποιήθηκε ένα Νευρωνικό Δίκτυο Ακτινικής Βάσης (RBF), σε συνδυασμό με τις μεθόδους «Βελτιστοποίηση Σμήνους Σωματιδίων» (Particle Swarm Optimization) και «Ανάλυση Κύριων Συνιστωσών» (Principle Component Analysis), πετυχαίνοντας ορθότητα 89%.

Επίσης, με χρήση δεδομένων μαγνητικής τομογραφίας (MRI), οι (Salvatore et al., 2013) [9] και οι (Morales et al., 2013) [10] πρότειναν μοντέλα με χρήση της τεχνικής SVM, πετυχαίνοντας ακρίβεια 90% και 70% αντίστοιχα. Κατά τη βιβλιογραφική αναζήτηση για την εκπόνηση της παρούσας διπλωματικής εργασίας, διαπίστωσα ότι οι γιατροί δεν χρησιμοποιούν την μαγνητική τομογραφία ως μέθοδο διάγνωσης της νόσου Parkinson, αλλά η χρήση του είναι μόνο για αποκλεισμό άλλων αιτιών παρκινσονισμού. Για αυτό το λόγο, τα αποτελέσματα των συγκεκριμένων ερευνών κρίνονται αμφίβολα.

Συγγραφείς	Τεχνική μηχανικής μάθησης	Περιγραφή δεδομένων	Απόδοση
Indira R.	fuzzy C- means	Σήματα ομιλίας	68.04 ακρίβεια, 75.34% sensitivity
A.Tsanas	SVM, RF	Σήματα ομιλίας	98.6% ακρίβεια
Ma	SCFWKELM	Σήματα ομιλίας	99.49% ακρίβεια
Wu	Radial Basis Function NN	Καταγραφές ηλεκτροδίων	89,91%
Salvatore	SVM	MRI	90% ακρίβεια
Morales	SVM	MRI	70% ακρίβεια
Imanne El Maachi	CNN + FC network	Σήματα κατά την βάρδιση	85.3% ακρίβεια
Ali Saad	Bayesian Naive Classifier (BNC)	video	74.31% ακρίβεια
Cho X.	LDA	Μοτίβα βάρδισης	95%
Johri	CNN+ANN	Σήματα κατά την βάρδιση + Σήματα ομιλίας	88%-89% ακρίβεια

Πίνακας 1: Παλαιότερες επιστημονικές μελέτες για τη διάγνωση του Parkinson, με μεθόδους μηχανικής μάθησης.

Με χρήση δεδομένων κατά την διάρκεια της βάρδισης, και συγκεκριμένα σε μορφή βίντεο από ασθενείς με τη νόσο Parkinson, ο Ali Saad κ.α έκανε αναγνώριση του συμπτώματος «freezing», με χρήση Bayesian Belief Network. Οι (Imanne El Maachi et al., 2019) [12], χρησιμοποιώντας δεδομένα από αισθητήρες κατά την βάρδιση των ασθενών, πρότειναν ένα μοντέλο για τη διάγνωση και για την πρόβλεψη της σοβαρότητας της νόσου, το οποίο αποτελείται από ένα Συνελκτικό Νευρωνικό Δίκτυο ακολουθούμενο από ένα πλήρως συνδεδεμένο δίκτυο, με 85.3% ακρίβεια στην πρόβλεψη της σοβαρότητας της νόσου. Οι (Cho C., et al., 2009) [32] πρότειναν ένα σύστημα που συνδυάζει την Γραμμική Διακριτική Ανάλυση (Linear Discriminant Analysis) με τη μέθοδο Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis) για την ανίχνευση μοτίβων στη βάρδιση ασθενών με Parkinson, χρησιμοποιώντας υπολογιστική όραση. Τα πειραματικά αποτελέσματα έδειξαν ότι το ποσοστό αναγνώρισης της βάρδισης ατόμων με τη νόσο είναι 95%. Επίσης,, οι (Johri et al., 2019) [3] συνδύασαν δεδομένα από την βάρδιση των ασθενών και από ηχογραφήσεις της φωνής των υποκειμένων. Η προσέγγιση τους αφορούσε τη δημιουργία δύο μοντέλων, ένα βαθύ συνελκτικό δίκτυο με είσοδο τα δεδομένα από τη βάρδιση, και σε ένα τεχνητό νευρωνικό δίκτυο 3 επιπέδων με είσοδο τις ηχογραφήσεις, με απώτερο σκοπό τη συγχώνευση των δύο μοντέλων.

Στον πίνακα 1 φαίνονται συγκεντρωμένες οι εργασίες για τα πρόβλημα της διάγνωσης που προαναφέρθηκαν, με τις τεχνικές Μηχανικής Μάθησης και τα δεδομένα που χρησιμοποιήθηκαν, καθώς και τα αποτελέσματα των μεθόδων.

ΚΕΦΑΛΑΙΟ 3: ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

Στο κεφάλαιο αυτό περιγράφονται έννοιες και ορισμοί για τους αλγορίθμους και τις αρχιτεκτονικές που έχουν χρησιμοποιηθεί στα πλαίσια της διπλωματικής εργασίας. Για την πλήρη κατανόηση τους κρίνεται απαραίτητη μία σύντομη αναφορά και σε γενικότερες έννοιες που αφορούν τον κλάδο της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης.

3.1 Τεχνητή νοημοσύνη- Μηχανική μάθηση

Ένας γενικότερος ορισμός για την τεχνητή νοημοσύνη την ορίζει ως τον τομέα της Επιστήμης των Υπολογιστών που ασχολείται με τη σχεδίαση και την υλοποίηση προγραμμάτων, τα οποία είναι ικανά να μιμηθούν τις ανθρώπινες γνωστικές ικανότητες, εμφανίζοντας έτσι χαρακτηριστικά που αποδίδουμε σε ανθρώπινη συμπεριφορά, όπως για παράδειγμα η επίλυση προβλημάτων, η αντίληψη μέσω όρασης, η μάθηση, η εξαγωγή συμπερασμάτων, η κατανόηση φυσικής γλώσσας κτλ. Παρόλο που είναι ένα σχετικά νέο πεδίο, η τεχνητή νοημοσύνη εξελίσσεται διαρκώς και αποτελεί σημείο τομής πολλών επιστημών, όπως της ψυχολογίας, της φιλοσοφίας, της νευρολογίας, της γλωσσολογίας και της μηχανικής. Διακρίνεται στη συμβολική τεχνητή νοημοσύνη, που βασίζεται στην κατανόηση νοητικών διεργασιών και ασχολείται με την προσομοίωση της ανθρώπινης νοημοσύνης, προσεγγίζοντας τη με αλγορίθμους και συστήματα που βασίζονται στη γνώση, και στην μη συμβολική τεχνητή νοημοσύνη, που βασίζεται στη μίμηση βιολογικών διεργασιών, όπως η λειτουργία του εγκεφάλου.

Για να ορίσουμε επαρκώς την μηχανική μάθηση αρχικά πρέπει να αποσαφηνίσουμε τι εννοούμε με τον όρο μάθηση. Η μάθηση σε ένα φυσικό ή τεχνητό σύστημα επεξεργασίας πληροφορίας είναι άρρηκτα συνδεδεμένη με την ικανότητα στην πρόσκτηση γνώσης κατά την αλληλεπίδραση του συστήματος με το περιβάλλον, μέσα στο οποίο δραστηριοποιείται και την ικανότητα του να βελτιώνει με την επανάληψη τον τρόπο με τον οποίο εκτελεί μία ενέργεια, και συνεπώς και την απόδοση του. Η μηχανική μάθηση αποτελεί κλάδο της Τεχνητής Νοημοσύνης και ασχολείται με τη μελέτη αλγορίθμων που βελτιώνουν την συμπεριφορά τους σε κάποια εργασία που τους έχει ανατεθεί χρησιμοποιώντας την εμπειρία τους. Είναι, δηλαδή, η ικανότητα ενός υπολογιστικού συστήματος να δημιουργεί μοντέλα ή πρότυπα από ένα σύνολο δεδομένων.

Ο τομέας της Μηχανικής Μάθησης αναπτύσσει τρεις τρόπους μάθησης, ανάλογους με τους τρόπους με τους οποίους μαθαίνει ο άνθρωπος: επιβλεπόμενη μάθηση, μη επιβλεπόμενη μάθηση και ενισχυτική μάθηση.

Η Επιβλεπόμενη Μάθηση(Supervised Learning) είναι η διαδικασία όπου ο αλγόριθμος κατασκευάζει μια συνάρτηση που απεικονίζει δεδομένες εισόδους (σύνολο εκπαίδευσης) σε γνωστές επιθυμητές εξόδους, με απώτερο στόχο τη γενίκευση της συνάρτησης αυτής και για εισόδους με άγνωστη έξοδο. Χρησιμοποιείται σε προβλήματα ταξινόμησης, πρόγνωσης, διερμηνείας.

Η Μη Επιβλεπόμενη Μάθηση(Unsupervised Learning), όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων, ανακαλύπτοντας συσχετίσεις ή ομάδες, δημιουργώντας πρότυπα, χωρίς να γνωρίζει τις επιθυμητές εξόδους. Χρησιμοποιείται σε προβλήματα ανάλυσης συσχετίσμων, ομαδοποίησης κ.ά.

Η Ενισχυτική Μάθηση (Reinforcement Learning), όπου ο αλγόριθμος μαθαίνει για μια στρατηγική ενεργειών μέσα από μια αλληλεπίδραση με το περιβάλλον. Χρησιμοποιείται κυρίως σε προβλήματα Σχεδιασμού, όπως για παράδειγμα ο έλεγχος κίνησης ρομπότ και η βελτιστοποίηση εργασιών σε εργοστασιακούς χώρους.

Σήμερα, η Μηχανική Μάθηση βρίσκει εφαρμογή σε πολλούς τομείς στη ζωή μας, όπως την οικονομία, την ιατρική, την βιοπληροφορική, το χρηματιστήριο, τις διαδικτυακές εφαρμογές, με την παράλληλη εξέλιξη νέων μεθόδων και πρακτικών και στο ερευνητικό πεδίο.

Βαθιά Μάθηση(Deep Learning)


Με τον όρο Deep Learning, νοείται ο κλάδος της Μηχανικής Μάθησης που καταπιάνεται με πιο περίπλοκες και συνήθως μη γραμμικές αρχιτεκτονικές αλγορίθμων, με στόχο την εξαγωγή πιο σύνθετων χαρακτηριστικών από τα διάφορα δεδομένα. Κατά τη διαδικασία της μάθησης, ένα σήμα από τη στιγμή της εισόδου δέχεται πολλούς μετασχηματισμούς και αναπροσαρμογές μέχρι την έξοδο, όπου οι μετασχηματισμοί και οι αναπροσαρμογές ουσιαστικά αφορούν τον αριθμό των διάφορων επιπέδων(layers), με τα οποία είναι δομημένος ένας Deep Learning αλγόριθμος. Οι τεχνικές Deep Learning συναντώνται μέσω των Τεχνητών Νευρωνικών Δικτύων, τα οποία θα αναλυθούν εκτενώς στην [παράγραφο 3.3](#).

3.2 Ο αλγόριθμος K-Κοντινότεροι γείτονες (KNN)

Ο αλγόριθμος K Κοντινότεροι Γείτονες (K Nearest Neighbors – KNN) είναι μια γνωστή και ευρεία χρησιμοποιούμενη τεχνική κατηγοριοποίησης που στηρίζεται στη χρήση μέτρων βασισμένων στην απόσταση. Στον αλγόριθμο KNN γίνεται η παραδοχή ότι τα διάφορα παραδείγματα μπορούν να αναπαρασταθούν ως σημεία σε κάποιον n-διάστατο Ευκλείδιο χώρο R^n , όπου n ο αριθμός των χαρακτηριστικών. Κάθε νέα περίπτωση τοποθετείται στο χώρο ως νέο σημείο και η τιμή του προσδιορίζεται με βάση τον χαρακτηρισμό των K γειτονικών σημείων. Ο αλγόριθμος KNN είναι instance-based, δηλαδή όταν είναι το σύστημα να κληθεί να αποφασίσει για μια νέα περίπτωση, εξετάζει εκείνη τη στιγμή τη σχέση της με τα ήδη αποθηκευμένα παραδείγματα. Συγκεκριμένα, οι κοντινότεροι γείτονες υπολογίζονται συνήθως με βάση της Ευκλείδιας απόστασης τους. Για παράδειγμα η απόσταση μεταξύ των σημείων x και y όπου $(a_1(x), \dots, a_n(x))$ τα χαρακτηριστικά του x και $(a_1(y), \dots, a_n(y))$ τα χαρακτηριστικά του y, είναι:

$$d(x, y) = \sqrt{\sum_{i=1}^{i=n} ((a_i(x) - a_i(y))^2)}$$

Αξίζει να σημειωθεί ότι το τελικό αποτέλεσμα του αλγορίθμου είναι ευαίσθητο στην τιμή που θα επιλεγεί για το K, δηλαδή πόσοι κοντινότεροι γείτονες θα χρησιμοποιηθούν για την κατηγοριοποίηση.

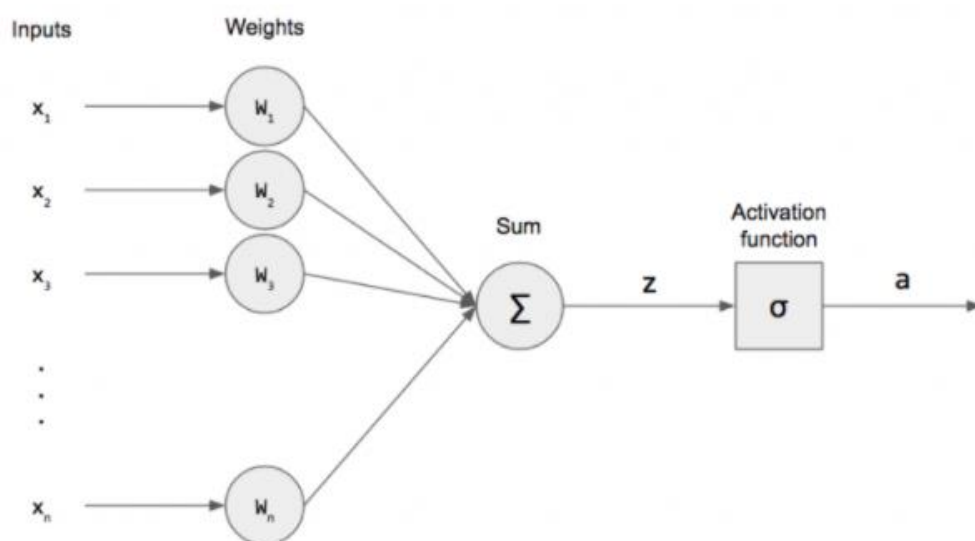


Εικόνα 3.1: Ο αλγόριθμος KNN, με K=3 για την ταξινόμηση του στοιχείου-αστέρι.

3.3 ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.3.1 Τεχνητός Νευρώνας

Η έννοια του τεχνητού νευρώνα εμφανίστηκε το 1958 από τον Rosenblatt, με το όνομα «Perceptron». Ο τεχνητός νευρώνας (artificial neuron) είναι ένα υπολογιστικό μοντέλο, τα μέρη του οποίου μπορεί να αντιστοιχιστούν άμεσα με αυτά του βιολογικού νευρώνα. Ένας βιολογικός νευρώνας αποτελείται από το σώμα, τους δενδρίτες, μέσω τους οποίων λαμβάνει σήματα από γειτονικούς νευρώνες (σημεία εισόδου) και τον άξονα, που είναι η έξοδος του νευρώνα. Αντίστοιχα, ο τεχνητός νευρώνας αποτελείται από το σώμα, δέχεται κάποια σήματα εισόδου, και βγάζει μόνο μία έξοδο. Η αρχιτεκτονική του τεχνητού νευρώνα φαίνεται και στην παρακάτω εικόνα.



Εικόνα 3.2: Ο τεχνητός νευρώνας δέχεται σήματα εισόδου, τα οποία αφού μετασχηματίζονται από τα βάρη και τις πόλωσης, αθροίζονται και περνάνε από τη συνάρτηση ενεργοποίησης για να παραχθεί η έξοδος.

Τα x_i είναι οι εισοδοί του νευρώνα, οι οποίες πολλαπλασιάζονται με τα βάρη w_i . Το σώμα του νευρώνα αποτελείται από 2 μέρη. Το 1^ο μέρος είναι ο αθροιστής (sum), ο οποίος προσθέτει τα σταθμισμένα από τα βάρη σήματα εισόδου μαζί με μία πόλωση, που συμβολίζεται με w_0 ή b . Το 2^ο μέρος του σώματος του νευρώνα είναι η συνάρτηση ενεργοποίησης f , όπου τροφοδοτείται το άθροισμα και ανάλογα την τιμή του η έξοδος είναι


0 ή 1, δηλαδή ο νευρώνας απενεργοποιείται ή ενεργοποιείται. Η μαθηματική έκφραση είναι:

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right)$$

3.3.2 Βασικές αρχές Τεχνητών Νευρωνικών Δικτύων

Τα Τεχνητά Νευρωνικά Δίκτυα είναι αλγόριθμος επιβλεπόμενης μάθησης που αποτελούνται από ένα πλήθος τεχνητών νευρώνων οργανωμένων σε δομές παρόμοιες με αυτές του ανθρώπινου εγκεφάλου.

Συνήθως, οι τεχνητοί νευρώνες ενός τεχνητού νευρωνικού δικτύου οργανώνονται σε διάφορα επίπεδα (layers) παράλληλης διάταξης, για την επίλυση σύνθετων προβλημάτων. Οι αρχιτεκτονικές με πολλά επίπεδα με νευρώνες-Perceptrons ονομάζονται **Multi-Layer Perceptrons** (MLP). Το πρώτο επίπεδο ονομάζεται **επίπεδο εισόδου** (input layer) και χρησιμοποιείται για την εισαγωγή δεδομένων. Στη συνέχεια, μπορεί να ακολουθούν ένα ή περισσότερα **κρυφά επίπεδα** (hidden layers). Ένα κρυφό επίπεδο συνδέει το προηγούμενο και το επόμενο κατά σειρά επίπεδο νευρώνων. Ο αριθμός των νευρώνων σε κάθε κρυφό επίπεδο, καθώς και ο αριθμός των κρυφών επιπέδων ορίζονται από τον σχεδιαστή. Τέλος, υπάρχει το **επίπεδο εξόδου** (output layer), όπου σε αυτά εμφανίζονται τα τελικά αποτελέσματα μετά το τέλος της εκμάθησης και ο αριθμός των νευρώνων είναι ίσος με το πλήθος των πιθανών εξόδων.



Εικόνα 3.3: Απεικόνιση Τεχνητού Νευρωνικού Δικτύου

Οι νευρώνες στα ΤΝΔ μπορεί να είναι πλήρως (fully connected) ή μερικώς συνδεδεμένοι (partially connected). **Πλήρως συνδεδεμένοι** είναι εκείνοι οι οποίοι συνδέονται με όλους τους υπόλοιπους νευρώνες. Σε κάθε άλλη περίπτωση οι νευρώνες είναι **μερικώς συνδεδεμένοι**. Ανάλογα με τον τρόπο διασύνδεσης των νευρώνων ενός τεχνητού νευρωνικού δικτύου, τα ΤΝΔ χωρίζονται σε νευρωνικά δίκτυα πρόσθιας τροφοδότησης (feedforward) και σε νευρωνικά δίκτυα με **ανατροφοδότηση** (feedback). Στα δίκτυα με **πρόσθια τροφοδότηση** δεν υπάρχουν συνδέσεις μεταξύ των νευρώνων ενός επιπέδου και νευρώνων προηγούμενου επιπέδου. Αντίθετα, στα νευρωνικά δίκτυα με ανατροφοδότηση (feedback), υπάρχουν συνδέσεις μεταξύ των νευρώνων ενός επιπέδου και νευρώνων προηγούμενου επιπέδου ή συνδέσεις μεταξύ νευρώνων ίδιου επιπέδου.


ΣΥΝΑΡΤΗΣΗ ΕΝΕΡΓΟΠΟΙΗΣΗΣ

Οι συναρτήσεις ενεργοποίησης (Activation Functions) έχουν ζωτική σημασία στα Τεχνητά Νευρωνικά Δίκτυα, καθώς μέσω αυτών εισάγεται η μη γραμμικότητα σε αυτά. Χωρίς την συνάρτηση ενεργοποίησης, το σήμα εξόδου θα ήταν μια απλή γραμμική συνάρτηση, με περιορισμένη ισχύ και κακή απόδοση στην πλειοψηφία των προβλημάτων. Οι πιο διαδεδομένες συναρτήσεις ενεργοποίησης είναι οι εξής:

- ❖ Η **Σιγμοειδής συνάρτηση** (sigmoid function), η οποία υπολογίζεται από τον τύπο:

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$$

και έχει την ακόλουθη κυματομορφή:




Η σιγμοειδής συνάρτηση, αποτελεί την πιο ευρέως διαδεδομένη συνάρτηση ενεργοποίησης στα νευρωνικά δίκτυα, καθώς παραπέμπει μέσω του συνόλου τιμών της, περιορίζοντας την είσοδο της στο διάστημα $[0,1]$, στις δύο καταστάσεις, όπου ένας νευρώνας

μπορεί να επέλθει. Έτσι, έχουμε 0, όταν ο νευρώνας είναι πλήρως απενεργοποιημένος και 1, όταν ο νευρώνας είναι ενεργός στην μέγιστη συχνότητα. Στην σιγμοειδή συνάρτηση, η τιμή εξόδου, που παίρνει ο νευρώνας δεν είναι κεντραρισμένη γύρω από το 0, γεγονός το οποίο δημιουργεί ορισμένα προβλήματα.

❖ Η **Υπερβολική Εφαπτομένη** (\tanh), η οποία υπολογίζεται από τον τύπο:

$$f(x) = \tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

και έχει την ακόλουθη κυματομορφή:




Σε αντίθεση με την σιγμοειδή, η τιμή εξόδου που παράγει ένας νευρώνας με χρήση της υπερβολικής συνάρτησης ενεργοποίησης, παραμένει κεντραρισμένη γύρω από το 0.

❖ Η **Ανορθωμένη Γραμμική Μονάδα** (Rectified Linear function), ή αλλιώς RELU περιγράφεται από την εξίσωση:

$$f(x) = (0, \max)$$

και έχει την ακόλουθη κυματομορφή:




Πρόκειται για την πιο συχνά χρησιμοποιούμενη συνάρτηση ενεργοποίησης στις σύγχρονες εφαρμογές των βαθιών νευρωνικών δικτύων, προσφέροντας με γρήγορο και εύκολα υπολογίσιμο τρόπο την τελική τιμή εξόδου του νευρώνα. Η διαδικασία αυτή, επιτυγχάνεται ουσιαστικά με την σύγκριση του αθροίσματος S των γινομένων των βαρών, επί τις τιμές εισόδου του νευρώνα με το 0. Έτσι, η RELU οδηγεί μέσω της γραμμικότητας της συνάρτησης και της μη-κορεσμένης τιμής εξόδου που παράγει, στην επιτυχή εκπαίδευση του νευρωνικού δικτύου.

- ❖ Η Κανονικοποιημένη Εκθετική Συνάρτηση (Softmax function), η οποία υπολογίζεται από τον τύπο:

$$\text{Softmax}(y_j) = \frac{e^{y_j}}{\sum_{j=0}^N e^{y_j}}$$

και έχει την ακόλουθη κυματομορφή:



Η συνάρτηση ενεργοποίησης Softmax κανονικοποιεί τις τιμές εξόδου, ώστε να κατανεμηθούν στο διάστημα $[0,1]$ και να αθροίζονται στην μονάδα.

3.4 ΕΚΠΑΙΔΕΥΣΗ

Όπως αναφέρθηκε και προηγουμένως, ένα νευρωνικό δίκτυο ορίζεται από τα βάρη του, τις τιμές της πόλωσης και τη συνάρτηση ενεργοποίησης. Η εκπαίδευση ενός τέτοιου δικτύου αναφέρεται στη χρήση ενός ή περισσότερων συνόλων εκπαίδευσης για τον υπολογισμό αυτών των παραμέτρων. Κατά τη διάρκεια της εκπαίδευσης, γνωρίζουμε την επιθυμητή απόκριση του κάθε νευρώνα εξόδου ενός πολυεπίπεδου νευρωνικού δικτύου. Ωστόσο, δεν γνωρίζουμε ποιες πρέπει να είναι οι τιμές των εξόδων των κρυφών νευρώνων. Ο αλγόριθμος οπισθοδιάδοσης σφάλματος (**backpropagation algorithm**) αποτελεί το εργαλείο της επιλογής για την εύρεση των τιμών των βαρών και των πολώσεων σε ένα δίκτυο

πολλαπλών επιπέδων και αναλύεται στη συνέχεια. Αυτή η εκπαίδευση περιλαμβάνει τέσσερα βήματα:

1. Τη διαβίβαση στο δίκτυο των διανυσμάτων προτύπων
2. Ένα πέρασμα προς τα εμπρός μέσω του δικτύου για την ταξινόμηση όλων των προτύπων του συνόλου προτύπων και τον προσδιορισμό του σφάλματος ταξινόμησης.
3. Ένα πέρασμα προς τα πίσω στο δίκτυο το οποίο τροφοδοτεί το σφάλμα εξόδου πίσω στο δίκτυο έτσι ώστε να υπολογιστούν οι μεταβολές που απαιτούνται για την ενημέρωση των παραμέτρων.
4. Την ενημέρωση των βαρών και των τιμών της πόλωσης στο δίκτυο

Τα βήματα αυτά επαναλαμβάνονται συνεχώς, μέχρι το σφάλμα να προσεγγίσει ένα αποδεκτό επίπεδο.

Για την εκπαίδευση των νευρωνικών, η επικρατούσα τεχνική είναι η διάσπαση του συνόλου των δεδομένων σε **Σύνολο Εκπαίδευσης (Training Set)** και σε **Σύνολο Αξιολόγησης (Test Set)**, τα οποία χρησιμοποιούνται για την αξιολόγηση του μοντέλου, με βάση τις μετρικές που περιγράφονται αναλυτικά στο υποκεφάλαιο [3.5](#).

Σε αυτό το σημείο κρίνεται απαραίτητος ο διαχωρισμός των εννοιών παράμετρος και υπερπαράμετρος. Οι παράμετροι του δικτύου είναι τα εκπαιδεύσιμα στοιχεία του δικτύου, δηλαδή τα βάρη και οι πολώσεις. Οι υπερπαράμετροι είναι στοιχεία που αφορούν το πώς εκπαιδεύεται το δίκτυο, ή καθορίζουν τη δομή του, παραδείγματος χάριν το βάθος και το πλάτος δικτύου, ο ρυθμός εκμάθησης κ.ά. Οι υπερπαράμετροι παίζουν καθοριστικό ρόλο στην απόδοση του δικτύου.

Πρόβλημα Υπερπροσαρμογής

Με τον όρο υπερπροσαρμογή στα δεδομένα εκπαίδευσης (data overfitting) ορίζουμε το φαινόμενο όπου το μοντέλο «απομνημονεύει» τις περιπτώσεις οι οποίες υπάρχουν στο σύνολο εκπαίδευσης, αντί να εκπαιδεύεται ουσιαστικά, ενσωματώνοντας «κανόνες» γενικότερης ισχύος. Ένα υπερβολικά προσαρμοσμένο μοντέλο ενσωματώνει και τον θόρυβο των δεδομένων. Ακόμα όμως και όταν δεν υπάρχει θόρυβος, η υπερβολική προσαρμογή του μοντέλου στα συγκεκριμένα δεδομένα θα το εμποδίσει να προβλέψει σωστά την κλάση νέων παρατηρήσεων. Η υπερπροσαρμογή παρουσιάζεται όταν ένα μοντέλο είναι υπερβολικά περίπλοκο. Το μοντέλο αυτό είναι ικανό να αφομοιώσει τις ιδιαιτερότητες των δεδομένων εκπαίδευσης, αντί να καταγράψει σχέσεις γενικότερης ισχύος. Ένα υπερπροσαρμοσμένο μοντέλο επιτυγχάνει εξαιρετικά υψηλές επιδόσεις έναντι των δεδομένων εκπαίδευσης, οι

επιδόσεις του όμως έναντι άγνωστων παρατηρήσεων δεν είναι ικανοποιητικές. Για τον λόγο αυτό, εξαιρετικά υψηλός ρυθμός ακρίβειας έναντι του συνόλου εκπαίδευσης, όχι μόνον δεν είναι ασφαλές μέτρο της επιτυχίας του μοντέλου, αλλά αποτελεί ένδειξη πιθανής υπερπροσαρμογής του. Για να μπορέσει να αποφευχθεί η υπερπροσαρμογή, ένα μέρος του συνόλου δεδομένων χρησιμοποιείται ως σύνολο επικύρωσης, το οποίο δεν συμμετέχει στην εκπαίδευση, αλλά δείχνει πως αποδίδει το μοντέλο σε δεδομένα άγνωστα κατά τη διάρκεια της εκπαίδευσης του.

3.4.1 Συναρτήσεις κόστους

Στο σημείο αυτό, κρίνεται αναγκαία η αναφορά στις συναρτήσεις κόστους, με τις οποίες γίνεται ο έλεγχος της επίδοσης των Τεχνητών Νευρωνικών Δικτύων. Η σύγκριση πραγματοποιείται ανάμεσα στις εξόδους του δικτύου, και τις αναμενόμενες (πραγματικές) τιμές. Οι πιο συνηθισμένες συναρτήσεις κόστους είναι:

- **Cross Entropy Loss:** Συγκρίνει τις πιθανοτικές κατανομές των τιμών, που πρόβλεψε το μοντέλο και των πραγματικών τιμών. Το σφάλμα αυξάνεται καθώς αποκλίνουν οι δύο κατανομές. Δίνεται από τον τύπο:

$$H(P, Q) = - \sum P(x) \log(Q(x))$$

Όπου P, Q οι πιθανοτικές κατανομές των πραγματικών και προβλεπόμενων τιμών αντίστοιχα.

- **Mean Squared Error:** Υπολογίζει τον μέσο όρο των σφαλμάτων και δίνεται από τον τύπο:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

όπου Y_i οι πραγματικές τιμές και \hat{Y}_i οι προβλέψεις.

- **Mean Absolute Error:** Υπολογίζει τον μέσο όρο της απόλυτης τιμής των σφαλμάτων και δίνεται από τον τύπο:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

Στον παρακάτω πίνακα φαίνονται και οι εξισώσεις σε κάθε βήμα της διαδικασίας εκπαίδευσης ενός πλήρως συνδεδεμένου δικτύου πρόσθιας τροφοδότησης, πολλαπλών επιπέδων, με χρήση του αλγορίθμου οπισθοδιάδοσης σφάλματος.

Βήμα	Περιγραφή	Εξισώσεις
Βήμα 1	Πρότυπα εισόδου	$\mathbf{A}(1) = \mathbf{X}$
Βήμα 2	Πέρασμα προς τα εμπρός	Για $\ell = 2, \dots, L$, υπολόγισε $\mathbf{Z}(\ell) = \mathbf{W}(\ell)\mathbf{A}(\ell-1) + \mathbf{B}(\ell)$; $\mathbf{A}(\ell) = h(\mathbf{Z}(\ell))$; $h'(\mathbf{Z}(\ell))$ και $\mathbf{D}(L) = (\mathbf{A}(L) - \mathbf{R}) \odot h'(\mathbf{Z}(L))$
Βήμα 3	Backpropagation	Για $\ell = L-1, L-2, \dots, 2$, υπολόγισε $\mathbf{D}(\ell) = (\mathbf{W}^T(\ell+1)\mathbf{D}(\ell+1)) \odot h'(\mathbf{Z}(\ell))$
Βήμα 4	Ενημέρωση βαρών και τιμών πόλωσης	Για $\ell = 2, \dots, L$, θέσε $\mathbf{W}(\ell) = \mathbf{W}(\ell) - \alpha \mathbf{D}(\ell) \mathbf{A}^T(\ell-1)$, $\mathbf{b}(\ell) = \mathbf{b}(\ell) - \alpha \sum_{k=1}^{n_p} \delta_k(\ell)$ και $\mathbf{B}(\ell) =$ συνένωσε $\{\mathbf{b}(\ell)\}$ όπου $\delta_k(\ell)$ οι στήλες του $\mathbf{D}(\ell)$ <small>n_p φορές</small>

Εικόνα 3.4: Η διαδικασία εκπαίδευσης ενός πλήρως συνδεδεμένου δικτύου πρόσθιας τροφοδότησης, πολλαπλών επιπέδων, με χρήση του αλγορίθμου οπισθοδιάδοσης σφάλματος. (πηγή: Ψηφιακή Επεξεργασία Εικόνων, Rafael C. Gonzalez, Richard E. Woods, επιστημονική επιμέλεια: Στέφανος Κόλλιας)

3.4.2 Βελτιστοποίηση

Οι αλγόριθμοι βελτιστοποίησης έχουν ως σκοπό την ελαχιστοποίηση της συνάρτησης κόστους. Οι εσωτερικές παράμετροι ενός μοντέλου έχουν ζωτική σημασία για την αποτελεσματική εκπαίδευση του μοντέλου. Αυτός είναι ο λόγος που χρησιμοποιούμε αλγορίθμους βελτιστοποίησης για τον υπολογισμό και ενημέρωση των βέλτιστων τιμών των παραμέτρων του μοντέλου. Οι βασικές μετρικές που καθορίζουν την αποτελεσματικότητα ενός αλγορίθμου βελτιστοποίησης είναι η ταχύτητα της σύγκλισης (δηλαδή η διαδικασία εύρεσης του ελαχίστου) και η δυνατότητα γενίκευσης (δηλαδή η ανταπόκριση του μοντέλου σε νέα δεδομένα). Στη συνέχεια, αναλύεται η ευρέως χρησιμοποιούμενη τεχνική της Κατάβασης Κλίσης (Gradient descent).

Αλγόριθμος Κατάβασης Κλίσης

Η Κατάβαση Κλίσης (Gradient descent) είναι ο απλούστερος αλγόριθμος βελτιστοποίησης μίας συνάρτησης. Έστω συνάρτηση κόστους L που αποτελείται από παραμέτρους θ . Δεδομένου ότι έχουμε στη διάθεση μας την κλίση της συνάρτησης $\nabla_{\theta} L$ (δηλαδή την 1^η παράγωγο), τότε οι παράμετροι υπολογίζονται από τον παρακάτω κανόνα:

$$\theta \leftarrow \theta - \alpha \nabla_{\theta} L$$

όπου το α ονομάζεται συντελεστής εκμάθησης (learning rate).

Η τιμή της συνάρτησης L όσο και της κλίσης της υπολογίζονται πάνω σε ένα σύνολο δεδομένων, το οποίο ονομάζεται batch. Αν το σύνολο αυτό επιλέγεται τυχαία από τα δεδομένα μας τότε ο αλγόριθμος ονομάζεται στοχαστική κατάβαση κλίσης (stochastic gradient descent).

Στο σημείο αυτό φαίνεται ξεκάθαρα πως επηρεάζει το πρόβλημα της εξαφάνισης παραγώγου (vanishing gradient), καθώς εάν η κλίση γίνει μηδέν τότε ο συγκεκριμένος αλγόριθμος δεν μπορεί να ανανεώσει τις παραμέτρους θ .

3.5 ΜΕΤΡΙΚΕΣ ΑΞΙΟΛΟΓΗΣΗΣ

Οι Μετρικές Αξιολόγησης είναι συναρτήσεις που χρησιμοποιούνται για να κρίνουν την απόδοση του μοντέλου. Η διαφορά της μετρικής με τη συνάρτηση κόστους (σφάλματος) είναι ότι τα αποτελέσματα από την αξιολόγηση δεν χρησιμοποιούνται κατά την εκπαίδευση του μοντέλου. Δηλαδή, οι μετρικές εφαρμόζονται στα δεδομένα αξιολόγησης. Πριν αναφέρουμε τις μετρικές αξιολόγησης, που χρησιμοποιούνται, θα αναφερθούν κάποιοι όροι που χρησιμοποιούνται για τον χαρακτηρισμό των προβλέψεων. Συγκεκριμένα:

- ❖ True Positive – TP: Αληθώς θετική ονομάζεται μια πρόβλεψη που εκτιμήθηκε ότι ανήκει σε μία συγκεκριμένη κλάση και αυτό ισχύει.
- ❖ False Positive – FP: Ψευδώς θετική ονομάζεται μία πρόβλεψη που εκτιμήθηκε ότι ανήκει σε μία συγκεκριμένη κλάση, ενώ αυτό δεν ισχύει
- ❖ True Negative – TN: Αληθώς αρνητική ονομάζεται μια πρόβλεψη που εκτιμήθηκε ότι δεν ανήκει σε μία κλάση και αυτό ισχύει.
- ❖ False Negative – FN: Ψευδώς αρνητική ονομάζεται μια πρόβλεψη που εκτιμήθηκε ότι δεν ανήκει σε μία κλάση, ενώ αυτό δεν ισχύει.

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

Εικόνα 3.5: Confusion Matrix

Οι μετρικές αξιολόγησης που χρησιμοποιούνται είναι:

- **Ορθότητα - Accuracy** : Το μέτρο της εκφράζει πόσο ακριβής είναι η πρόβλεψη του μοντέλου σε σχέση με τα πραγματικά δεδομένα. Δηλαδή, το ποσοστό επιτυχίας του μοντέλου στην ταξινόμηση των δειγμάτων στις σωστές κατηγορίες επί του συνόλου των δεδομένων.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

- **Ακρίβεια - Precision**: Το μέτρο της εκφράζει το ποσοστό των σωστών προβλέψεων μιας κλάσης προς το συνολικών προβλέψεων της κλάσης. Δηλαδή,

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

- **Ανάκληση - Recall**: Είναι ο λόγος των σωστών προβλέψεων μιας κλάσης προς το σύνολο των προβλέψεων που κατετάγησαν σωστά στην κατηγορία και των προβλέψεων που λανθασμένα δεν κατετάγησαν στην κατηγορία. Δηλαδή,


$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

- **F1 score** – Η μετρική αυτή συνδυάζει την ακρίβεια και την ανάκληση, αφού αποτελεί τον αρμονικό μέσο όρο της ακρίβειας και της ανάκλησης.

$$\text{F1 score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

3.6 Συνελκτικὰ νευρωνικά δίκτυα (CNN)

Τα Συνελκτικὰ Νευρωνικά Δίκτυα (CNN) είναι μια ειδική κατηγορία νευρωνικών δικτύων, τα οποία είναι κατάλληλα για την επεξεργασία πληροφορίας που μπορεί να αναπαρασταθεί σε μορφή πλέγματος. Τα CNN βρίσκουν εφαρμογή σε αναγνώριση εικόνων και βίντεο, κατηγοριοποίηση εικόνας, ανάλυση ιατρικών εικόνων, σε χρονοσειρές και σε επεξεργασία φυσικής γλώσσας. Όπως δηλώνει και το όνομα τους, βασίζονται στη μαθηματική διαδικασία της συνέλιξης.



Εικόνα 3.6: Αριστερά: Τεχνητό νευρωνικό δίκτυο. Δεξιά: Συνελκτικό νευρωνικό δίκτυο

Τρόπος λειτουργίας των CNN

Η είσοδος της συνέλιξης είναι είτε ακατέργαστα δεδομένα είτε κάποιος χάρτης χαρακτηριστικών που προέρχεται από προηγούμενα επίπεδα CNN. Ένα φίλτρο ή πυρήνας «σαρώνει» κατά πλάτος και κατά ύψος στα δεδομένα εισόδου και παράγει τα συνελκτικά χαρακτηριστικά. Συγκεκριμένα, η είσοδος περνάει ακολουθιακά από διαδοχικά επίπεδα επεξεργασίας, προκειμένου να εξαχθεί η τελική πρόβλεψη του δικτύου. Η διαδικασία αυτή είναι σειριακή, και ακολουθείται από μία άλλη διαδικασία, για την εκπαίδευση του δικτύου, την οπισθοδιάδοση σφάλματος.

Επίπεδα των Συνελκτικών Νευρωνικών δικτύων

Ένα Βαθύ Συνελκτικό Νευρωνικό Δίκτυο αποτελείται από έναν αριθμό από συνελκτικά και υποδειγματοληπτικά επίπεδα, τα οποία συνήθως ακολουθούνται από πλήρως συνδεδεμένα επίπεδα. Τα διαφορετικά επίπεδα του CNN αναλύονται διεξοδικά ακολούθως.

Επίπεδο Συνέλιξης

Το επίπεδο της Συνέλιξης χρησιμοποιεί ένα σύνολο από φίλτρα τα οποία εντοπίζουν την παρουσία συγκεκριμένων χαρακτηριστικών ή μοτίβων που παρουσιάζονται στα δεδομένα εισόδου. Το κάθε φίλτρο «σαρώνει» κατά πλάτος και κατά ύψος την είσοδο και με τη μέθοδο της συνέλιξης δημιουργεί διαδοχικά ένα νέο πίνακα που ονομάζεται χάρτης χαρακτηριστικών (feature map).

Οι υπερπαραμέτροι που καθορίζουν την χωρική διάταξη και το μέγεθος της εξόδου από ένα συνελκτικό επίπεδο είναι:

1. Μέγεθος φίλτρου: Κάθε φίλτρο έχει μικρότερο μέγεθος από το πλάτος και το ύψος του μεγέθους της εισόδου.
2. Βάθος εξόδου: Αντιστοιχεί στο πλήθος των φίλτρων που θα χρησιμοποιηθούν για τον εντοπισμό των χαρακτηριστικών της εισόδου
3. Βήμα(stride): Ρυθμίζει το βήμα της μετακίνησης του παράθυρου του συρούμενου φίλτρου. Όσο πιο μεγάλο είναι το βήμα, τόσο πιο μικρή θα είναι η διάσταση της εξόδου
4. Γέμισμα περιθωρίου (Padding): Το μέγεθος του γεμίματος γύρω από τα σύνορα του εισόδου.

Η σχέση, που προσδιορίζει τις διαστάσεις του χάρτη χαρακτηριστικών είναι:

$$(N + 2 * P - F) / S + 1$$

Όπου:

- N = διάσταση της εισόδου
- P = γέμισμα περιθωρίου με μηδενικά (Padding)
- F = διαστάσεις του φίλτρου
- S = Άλμα (Stride)


Επίπεδο Υποδειγματοληψίας (Subsampling/Pooling Layer)

Για να μην κάνουμε το CNN υπερβολικά ειαίσθητο στις σχετικές θέσεις των χαρακτηριστικών (γεγονός που μπορεί να οδηγήσει στην υπερεκπαίδευση), η ακρίβεια των χαρακτηριστικών πρέπει να μειωθεί. Αυτό μπορεί να επιτευχθεί με την υποδειγματοληψία του χάρτη χαρακτηριστικών. Για αυτό το λόγο, στα περισσότερα CNNs ένα συνελκτικό επίπεδο ακολουθείται από ένα επίπεδο υποδειγματοληψίας. Κάθε χάρτης χαρακτηριστικών που προκύπτει από το συνελκτικό επίπεδο, αποτελεί είσοδο στο επίπεδο υποδειγματοληψίας

και εκτελείται η διαδικασία της συγκέντρωσης(pooling). Τα δύο είδη συγκέντρωσης που συναντώνται συνήθως στα CNNs είναι:

- Max Pooling: Επιλέγεται η μέγιστη από τις τιμές του πίνακα.
- Average Pooling: Υπολογίζεται ο μέσος όρος των τιμών του πίνακα.


Η μείωση της ακρίβειας κάνει το δίκτυο λιγότερο ευαίσθητο στις διαφορές μεταξύ των δειγμάτων της ίδιας κλάσης. Επίσης, οι χάρτες χαρακτηριστικών είναι πιο εύρωστοι απέναντι σε θόρυβο και παραμόρφωση. Η μείωση των διαστάσεων οδηγεί σε λιγότερους υπολογισμούς και μειώνει σημαντικά την πιθανότητα υπερεκπαίδευσης.



Εικόνα 3.7: Η πράξη της συνέλιξης του πίνακα με το φίλτρο, ακολουθούμενο από υποδειγματοληψία μεγίστου.

Πλήρως συνδεδεμένο Επίπεδο (Fully- Connected Layer)

Τα Fully-Connected Layers αποτελούν μία αρχιτεκτονική πολλών επιπέδων με νευρώνες, η οποία χρησιμοποιεί μια συνάρτηση ενεργοποίησης στην έξοδο της και κάθε νευρώνας του ενός επιπέδου συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου. Στο πρόβλημα της ταξινόμησης(classification), ο ρόλος του Πλήρως Συνδεδεμένου Επιπέδου είναι χρησιμοποιώντας τα χαρακτηριστικά που έχουν εξαχθεί από τα συνελικτικά και συγκεντρωτικά επίπεδα να ταξινομήσει την είσοδο στις διαφορετικές κλάσεις, βασισμένο στα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου. Επίσης, τα Fully-Connected Layers χρησιμοποιούνται για την εκμάθηση μη γραμμικών συνδυασμών των χαρακτηριστικών, οι οποίοι παίζουν ρόλο στην ταξινόμηση.



Εικόνα 3.8: Μία τυπική αρχιτεκτονική Συνελικτικού νευρωνικού Δικτύου

3.7 ΑΝΑΔΡΟΜΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Τα αναδρομικά νευρωνικά δίκτυα ή ανατροφοδοτούμενα δίκτυα (RNN) είναι μια ειδική κατηγορία τεχνητών νευρωνικών δικτύων. Το κύριο χαρακτηριστικό τους που τα διαφοροποιεί από τα feedforward δίκτυα είναι ότι περιέχουν τουλάχιστον μία ανάδραση ανάμεσα στους κόμβους του ίδιου επιπέδου ή κόμβους διαφορετικών επιπέδων. Η ιδιότητα αυτή τους προσδίδει δύο πολύ σημαντικά χαρακτηριστικά έναντι των feedforward δικτύων. Το πρώτο είναι αυτό της αντίληψης του χρόνου και το δεύτερο είναι η εισαγωγή της μνήμης στα νευρωνικά δίκτυα. Τα αναδρομικά δίκτυα μπορούν να χρησιμοποιηθούν αποδοτικά σε θέματα που περιλαμβάνουν το φιλτράρισμα και την πρόβλεψη πληροφοριών, την κατάταξη δεδομένων σε κλάσεις, την μοντελοποίηση στοχαστικών ακολουθιών, την συμπίεση δεδομένων κ.α.. Κάποιοι από τους τομείς στους οποίους χρησιμοποιούνται αποδοτικά ή έχουν καταδείξει πολλά υποσχόμενα αποτελέσματα είναι οι τηλεπικοινωνίες, ο έλεγχος χημικών εγκαταστάσεων, ο έλεγχος μηχανών και γεννητριών, η ρομποτική, η αναγνώριση ομιλίας, η παραγωγή meta πληροφοριών από εικόνες, η ανάλυση δεδομένων σε βίντεο, η μετάφραση και η αυτόματη συγγραφή κειμένου ή κώδικα.

Ένα αναδρομικό δίκτυο μετασχηματίζει κάθε νέα είσοδο, με τρόπο που εξαρτάται από την ίδια την είσοδο, αλλά και από προηγούμενες εισόδους που έχει δεχτεί. Για να γίνει πιο κατανοητό, θεωρούμε ένα RNN ενός επιπέδου, που την χρονική στιγμή t δέχεται την είσοδο x_t και παράγει την έξοδο y_t :

$$y_t = f(x_t, y_{t-1}) = f(x_t, f(x_{t-1}, y_{t-2})) = \dots = f(x_t, (f(x_{t-1}, \dots, f(x_1, y_0))).$$

Η γενικότερη εξίσωση είναι:

$$y_t = f(x_t, y_{t-1}) = f(W * x_t + U * y_{t-1} + b)$$


6

Όπου:

- f : συνάρτηση ενεργοποίησης
- W : διάνυσμα βαρών που επιδρά πάνω στην είσοδο x_t
- U : διάνυσμα βαρών το οποίο επιδρά πάνω στην έξοδο την προηγούμενη χρονική στιγμή
- b : διάνυσμα πόλωσης

3.7.1 Εκπαίδευση αναδρομικών νευρωνικών δικτύων


Ο αλγόριθμος του backpropagation δεν μπορεί να μεταφερθεί ως έχει στα αναδρομικά, για το λόγο ότι προϋποθέτει την ύπαρξη ακυκλικών συνδέσεων μεταξύ των κόμβων του δικτύου, έτσι ώστε να γίνει η οπισθοδιάδοση σφάλματος. Για αυτό, για την εκπαίδευση των recurrent χρησιμοποιείται μια παραλλαγή τους, ο αλγόριθμος **backpropagation through time**, που «ξεδιπλώνει» τις συνδέσεις μεταξύ των κόμβων σε ξεχωριστά χρονικά βήματα, δημιουργώντας πανομοιότυπα αντίγραφα και ανακατευθύνει τις συνδέσεις μεταξύ αυτών, ώστε να προκύψει ένα feedforward δίκτυο, όπως φαίνεται στην εικόνα .



Εικόνα 3.9: Αριστερά: Το αρχικό RNN Δεξιά: Το feedforward δίκτυο που προκύπτει μετά το «ξεδίπλωμα» στο χρόνο

3.7.2 Δίκτυα Μακράς Βραχείας Μνήμης

Τα RNN καθίστανται αδύνατα στο να μοντελοποιήσουν χρονικές εξαρτήσεις μεγάλης διάρκειας, καθώς εμφανίζεται το πρόβλημα της «εξαφάνισης κλίσης» (Vanishing Gradient). Συγκεκριμένα, όπως έχει προαναφερθεί οι αλγόριθμοι εκπαίδευσης χρησιμοποιούν τις παραγώγους για τον υπολογισμό παραμέτρων. Οι κλίσεις, όμως, σε μεγάλης διάρκειας εξαρτήσεις, αποτελούν συνθέσεις μερικών παραγώγων που τείνουν να εξασθενούν τείνοντας στο μηδέν. Έτσι, η εκπαίδευση του μοντέλου είναι αδύνατη.




Εικόνα 3.10: Το πρόβλημα της εξασθένησης των εξαρτήσεων στα RNN με την πάροδο του χρόνου

Για να ξεπεραστεί αυτό το πρόβλημα των συσχετίσεων που βρίσκονται μακριά μεταξύ τους, έχουν δοκιμαστεί πολλές προσεγγίσεις, που ουσιαστικά αποτελούν μικρές ή μεγάλες μεταποιήσεις των αναδρομικών νευρωνικών δικτύων, όπως η εισαγωγή χρονικής καθυστέρησης, η εφαρμογή της διάδοσης του σφάλματος σε διακριτούς χρόνους ή η εισαγωγή κάποιων σταθερών στα δίκτυα. Η τεχνική, όμως, που έχει επικρατήσει και έχει να αναδείξει τα καλύτερα αποτελέσματα σε τέτοιου είδους αλλά και σε πολλές άλλες εφαρμογές, είναι αυτή των δικτύων Μακράς Βραχεία Μνήμης (Long Short Term Memory δικτύα-LSTM). Εισήχθησαν πρώτη φορά το 1997 από τους Sepp Hochreiter και Jürgen Schmidhuber και η συγκράτηση πληροφοριών στη μνήμη για μεγάλα χρονικά διαστήματα είναι το βασικό εξ' ορισμού χαρακτηριστικό της λειτουργίας τους. Σχεδόν όλα τα state of the art αποτελέσματα των αναδρομικών νευρωνικών δικτύων έχουν επιτευχθεί με τη χρήση αυτών.

Αρχιτεκτονική και Λειτουργία των Δικτύων LSTM

Η αρχιτεκτονική των LSTM μοιάζει αρκετά με αυτή των υπόλοιπων RNN, με την έννοια ότι απαρτίζονται και αυτά από ένα αριθμό νευρώνων συνδεδεμένων αλυσιδωτά μεταξύ τους σε κάθε επίπεδο. Η διαφορά βρίσκεται στο ότι οι μονάδες (modules ή blocks) που βρίσκονται στα εσωτερικά επίπεδα του δικτύου περιέχουν κάποια επιπλέον στοιχεία και ονομάζονται σε αυτή την περίπτωση μονάδες μνήμης (memory blocks). Πιο συγκεκριμένα, κάθε μονάδα των LSTM αποτελείται από ένα ή περισσότερα κελιά μνήμης που συνδέονται μεταξύ τους και τρία ακόμη στοιχεία, τις πύλες εισόδου, εξόδου και επιλεκτικής συγκράτησης (forget gate), οι οποίες είναι αντιστοίχως υπεύθυνες για τις λειτουργίες εγγραφής, ανάγνωσης και επαναφοράς των κελιών. Η χρήση αυτών των πυλών διασφαλίζει την αποθήκευση και πρόσβαση στις πληροφορίες ακόμα και με την πάροδο μεγάλων χρονικών περιόδων ή πολλών βημάτων.



Εικόνα 3.11: Στα εσωτερικό της μονάδας του LSTM

Η λειτουργία του LSTM συνοψίζεται ως εξής:

1^ο βήμα: Αποφασίζει ποιο μέρος της πληροφορίας θα αποδεσμεύσει από τη μνήμη, μέσω της πύλης forget, το οποίο δέχεται την έξοδο του προηγούμενου επιπέδου και την είσοδο για να εξάγει μια τιμή 0-1, μέσω της σιγμοειδούς.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

2^ο βήμα: Στο βήμα αυτό θα παρθεί η απόφαση για το ποια στοιχεία της νέας πληροφορίας θα συγκρατηθούν στη μνήμη του δικτύου. Η διαδικασία περιλαμβάνει δύο βήματα, με το πρώτο να περιλαμβάνει την πύλη εισόδου που ξεχωρίζει ποιες από τις υπάρχουσες πληροφορίες θα παραμείνουν στη μνήμη και το δεύτερο να δημιουργεί ένα νέο διάνυσμα \tilde{C}_t με τις υποψήφιες τιμές που πρόκειται να προστεθούν σε αυτή.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$$

3^ο βήμα: Γίνεται ενημέρωση της κατάστασης της μνήμης από C_{t-1} σε C_t , πολλαπλασιάζοντας την παλιά κατάσταση C_{t-1} με τα δεδομένα της f_t που αποφασίστηκε να αποδεσμεύσουμε στο προηγούμενο βήμα και προσθέτοντας ένα ποσοστό των νέων υποψήφιων τιμών $i_t * \tilde{C}_t$.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

4^ο βήμα: Αφορά την εξαγωγή του αποτελέσματος h_t , που θα γίνει είσοδος στο επόμενο επίπεδο και αποτελεί μια φιλτραρισμένη εκδοχή της κατάστασης της μνήμης. Αρχικά, γίνεται το πέρασμα της πληροφορίας εισόδου από μια σιγμοειδή συνάρτηση για να προσδιορισθεί ποιο κομμάτι αυτής θα προωθηθεί ως την έξοδο. Έπειτα εισέρχεται το περιεχόμενο της

μνήμης μέσω της συνάρτησης της υπερβολικής εφαπτομένης (για να ωθήσει τις τιμές του διανύσματος στο διάστημα -1 έως 1) και πολλαπλασιάζεται με την έξοδο της σιγμοειδούς για να γίνει η προώθηση μόνο των κομματιών που έχουν προσδιορισθεί.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

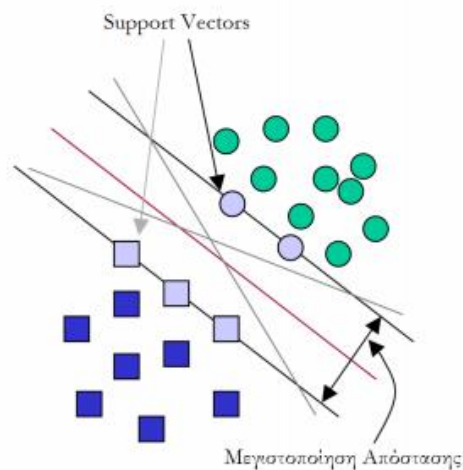
$$h_t = o_t * \tanh(C_t)$$

3.8 Μηχανές διανυσμάτων υποστήριξης – SVM

Η βασική ιδέα των Μηχανών Διανυσμάτων Υποστήριξης (SVM) είναι η εξεύρεση ενός βέλτιστου υπερεπιπέδου (hypersurface) το οποίο διαχωρίζει τα γραμμικά διαχωριζόμενα πρότυπα εισόδου. Παρόλα αυτά η διαδικασία αυτή μπορεί να γενικευθεί για πρότυπα τα οποία δεν είναι γραμμικά διαχωριζόμενα, μέσω κατάλληλων μετασχηματισμών στην αρχική πληροφορία έτσι ώστε να μεταφερθεί σε έναν νέο χώρο μέσω συγκεκριμένων συναρτήσεων πυρήνα (kernel functions). Κάποια από τα ισχυρά χαρακτηριστικά του SVM και των συναρτήσεων πυρήνα του είναι τα εξής:

- Έχουν τμηματική σχεδίαση η οποία επιτρέπει την αυτόνομη ενσωμάτωση και σχεδίαση των χαρακτηριστικών τους
- Δεν επηρεάζονται από τοπικά ελάχιστα
- Δεν έχουν πρόβλημα στην κατηγοριοποίηση δεδομένων πολλών διαστάσεων

Στην πράξη τα SVM αποτελούνται από τα σημεία δεδομένων της εισόδου που βρίσκονται πολύ κοντά στην επιφάνεια απόφασης. Τα σημεία αυτά ονομάζονται Διανύσματα Υποστήριξης (**Support Vectors**). Είναι ουσιαστικά τα σημεία αυτά που είναι τα πιο δύσκολα στην κατηγοριοποίηση. Ακριβώς για αυτόν τον λόγο, έχουν άμεση επιρροή στην εύρεση της βέλτιστης τοποθεσίας του επιπέδου απόφασης (decision surface). Όπως φαίνεται και στο σχήμα υπάρχουν πολλές λύσεις για διαχωρισμό των δεδομένων. Παρόλα αυτά ο SVM προσπαθεί να βρει την βέλτιστη λύση για τον διαχωρισμό τους. Αυτό που καταφέρνει ο αλγόριθμος είναι να βρει τα συγκεκριμένα σημεία τα οποία μεγιστοποιούν την απόσταση ανάμεσα στο επίπεδο διαχωρισμού και τις ξεχωριστές κλάσεις.



Εικόνα 3.12: Διάφορες λύσεις (γκρι) για τον διαχωρισμό των δεδομένων και η βέλτιστη(κοκκινο).

3.8.1 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΤΩΝ SVM

Ο κλασικός αλγόριθμος του SVM είναι ένας μη-πιθανοτικός δυαδικός ταξινομητής, το οποίο σημαίνει ότι προβλέπει, για κάθε δεδομένο εισόδου, σε ποια από δύο συγκεκριμένες κλάσεις ανήκει. Διαισθητικά, ένα μοντέλο του SVM είναι μία αναπαράσταση των δειγμάτων εισόδου σαν σημεία στον χώρο, τοποθετημένα έτσι ώστε τα δείγματα των ξεχωριστών κατηγοριών να χωρίζονται με ένα ξεκάθαρο κενό το οποίο είναι όσο το δυνατόν πιο φαρδύ. Έπειτα τα νέα δείγματα τοποθετούνται στον ίδιο χώρο και η πρόβλεψη για το σε ποιά κλάση ανήκουν εξαρτάται από την μεριά της διαχωριστικής επιφάνειας που βρίσκονται.

Πιο τυπικά, ένα SVM δημιουργεί ένα υπερεπίπεδο ή ένα σετ υπερεπιπέδων σε έναν χώρο πολλών ή απείρων διαστάσεων, τα οποία μπορούν να χρησιμοποιηθούν για ταξινόμηση, παλινδρόμηση (regression) ή άλλες διαδικασίες. Φυσικά, για να επιτύχουμε έναν καλό διαχωρισμό των κλάσεων πρέπει να επιλέξουμε ένα υπερεπίπεδο το οποίο έχει την μεγαλύτερη απόσταση από τα πιο κοντινά σημεία εκπαίδευσης κάθε κλάσης, αφού γενικά όσο μεγαλύτερο είναι αυτό το κενό τόσο μικρότερο θα είναι το σφάλμα γενικοποίησης του ταξινομητή.

Παρόλο που το αρχικό πρόβλημα μπορεί να διατυπωθεί σε έναν χώρο περιορισμένων διαστάσεων, συχνά σε αυτόν τον χώρο τα σετ που πρέπει να διαχωριστούν δεν είναι γραμμικά διαχωρίσιμα. Για αυτόν τον λόγο προτάθηκε το πρόβλημα μεταφέρεται από τον αρχικό χώρο

περιορισμένων διαστάσεων σε έναν χώρο πολύ περισσότερων διαστάσεων ο οποίος κάνει τον διαχωρισμό πιο εύκολο. Τα συστήματα SVM χρησιμοποιούν μια διαδικασία μεταφοράς σε έναν μεγαλύτερο χώρο έτσι ώστε να γίνει πιο εύκολος αλλά και πιο αποδοτικός ο υπολογισμός των εσωτερικών γινομένων ανάμεσα στα διανύσματα του αρχικού χώρου. Τα γινόμενα στον μεγαλύτερης τάξης χώρο ορίζονται μέσω μιας συνάρτησης πυρήνα $k(X, x)$ η οποία μπορεί να επιλεγεί κατάλληλα για το κάθε πρόβλημα. Η τιμή που παράγει ένας SVM είναι στενά συνδεδεμένη με την συνάρτηση πυρήνα που χρησιμοποιείται σε κάθε περίπτωση και παρακάτω παραθέτουμε τις εξόδους ενός SVM ανάλογα με την συνάρτηση πυρήνα που χρησιμοποιείται:

- Πολυωνυμική

$$[x^T y + \theta]^p$$

- Γκαουσιανή RBF

$$e^{-\|x-y\|^2/(2\sigma^2)}$$

- Σιγμοειδής

$$\tanh(ax^T y + \theta)$$

Τα υπερεπίπεδα στον μεγαλύτερο χώρο ορίζονται σαν το σύνολο των σημείων για τα οποία το γινόμενο με ένα διάνυσμα είναι σταθερό.

3.9 Στατιστική εξαγωγή χαρακτηριστικών

Οι χρονοσειρές χαρακτηρίζονται από μεγάλη διαστατικότητα, και αυτό καθιστά δύσκολο τον χειρισμό τους. Για τη μείωση της διαστατικότητας των δεδομένων, μια προσέγγιση είναι η εξαγωγή χαρακτηριστικών από αυτά, δημιουργώντας μία υψηλού επιπέδου αναπαράσταση τους. Η στατιστική μπορεί να χρησιμοποιηθεί για την εξαγωγή χαρακτηριστικών από μια χρονοσειρά, απεικονίζοντας διαφορετικές ιδιότητες της, όπως τη μεταβλητότητα, το σχήμα, την κεντρική τάση (central tendency) κτλ. Στο πλαίσιο της διπλωματικής υπολογίστηκαν τα εξής χαρακτηριστικά για κάθε μία χρονοσειρά:

A) Αριθμητικός μέσος - Mean

Ο αριθμητικός μέσος μ είναι ο μέσος όρος από τις τιμές x_1, x_2, \dots, x_n που βρίσκονται μέσα σε ένα χρονικό πλαίσιο. Υπολογίζεται από τον τύπο:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i$$

B) Τυπική απόκλιση – Standard deviation

Η τυπική απόκλιση σ μετρά το ποσό της μεταβολής ή της διασποράς των τιμών x_1, x_2, \dots, x_n και υπολογίζεται από τον τύπο:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$$

Γ) Κύρτωση – Kurtosis

Η κύρτωση και μετράει το βαθμό συγκέντρωσης των δεδομένων γύρω από τη μέση τιμή. Η κύρτωση δείχνει την αιχμηρότητα ή την πλάτυνση της κατανομής. Υπολογίζεται από τον τύπο:

$$K_u = \frac{\mu_4}{\sigma^4}$$

όπου το μ_4 υπολογίζεται από τον τύπο:

$$\mu_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4$$

Δ) Ασσυμετρία – Skewness

Η ασυμμετρία των δεδομένων υπολογίζεται από τον τύπο:

$$Sk = \frac{\mu_3}{\sigma^3}$$

όπου το μ_3 υπολογίζεται από τον τύπο:

$$\mu_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^3$$

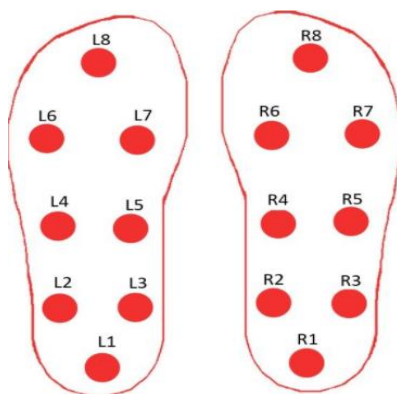
Επίσης, εκτός από τα προαναφερθείσες μετρήσεις, για κάθε χρονοσειρά υπολογίστηκαν και βασικές στατιστικές συναρτήσεις, όπως το μέγιστο, το ελάχιστο και η διάμεσος.

ΚΕΦΑΛΑΙΟ 4: ΥΛΟΠΟΙΗΣΗ

Στο κεφάλαιο αυτό, περιγράφονται αρχικά τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση των μοντέλων. Επιπρόσθετα, αναλύεται η προεπεξεργασία που υπέστησαν, ώστε να δοθούν ως είσοδοι στα μοντέλα που δημιουργήθηκαν στο πλαίσιο αυτής της διπλωματικής εργασίας. Στη συνέχεια, περιγράφονται οι αρχιτεκτονικές που χρησιμοποιήθηκαν, με τις απαραίτητες επεξηγήσεις και λεπτομέρειες για την κατανόηση των μοντέλων. Τα αποτελέσματα των μοντέλων, με λεπτομερειακή περιγραφή των αποτελεσμάτων, αλλά και οι σύγκρισεις μεταξύ τους βρίσκονται στο επόμενο κεφάλαιο.

4.1 Δεδομένα

Τα δεδομένα [18] αποτελούν καταγραφές από 166 ανθρώπους (93 με τη νόσο Parkinson και 73 υγείς). Συγκεκριμένα, 8 αισθητήρες έχουν τοποθετηθεί κάτω από το κάθε πόδι του υποκειμένου (σύνολο 16 αισθητήρες), οι οποίοι καταγράφουν την κάθετη αντίδραση του δαπέδου (VGRF-Vertical Ground Reaction Force), κατά την βάρδια του για χρονικό διάστημα 2 λεπτών. Ο ρυθμός καταγραφής του κάθε αισθητήρα ήταν 100 δείγματα ανά δευτερόλεπτο, ενώ οι εγγραφές περιλαμβάνουν δύο ακόμη σήματα που αντικατοπτρίζουν το άθροισμα των 8 αισθητήρων για κάθε πόδι. Το σύνολο των δεδομένων είναι οργανωμένο σε διαφορετικά αρχεία για τον κάθε ασθενή. Το όνομα του κάθε αρχείου υποδεικνύει την κατηγορία που ανήκει ο κάθε ασθενής. Συγκεκριμένα, αν το όνομα του αρχείου περιέχει τη φράση «Pt» σημαίνει ότι το υποκείμενο έχει την νόσο Parkinson, ενώ αν το όνομα περιέχει τη φράση «Co» σημαίνει ότι το υποκείμενο δεν έχει την νόσο Parkinson.



Εικόνα 4.1: Η διάταξη με την οποία τοποθετήθηκαν οι αισθητήρες κάτω από κάθε πόδι

4.2 Μοντέλα SVM και KNN

Αρχικά, δοκιμάστηκαν κλασικές μέθοδοι μηχανικής μάθησης, οι οποίες αποτελούν πιο απλές τεχνικές. Οι τεχνικές αυτές υλοποιήθηκαν με σκοπό τα αποτελέσματα τους να λειτουργήσουν ως μετρήσεις αναφοράς για την αξιολόγηση και σύγκριση των αποτελεσμάτων των δικτύων βαθιάς μάθησης, τα οποία αναλύονται στο υποκεφάλαιο [4.3](#).

Το πρώτο βήμα ήταν η επεξεργασία των δεδομένων. Για κάθε χρονοσειρά δεδομένων έχει γίνει στατιστική εξαγωγή χαρακτηριστικών. Συγκεκριμένα, για κάθε αισθητήρα του υποκειμένου υπολογίστηκε η μέγιστη τιμή, η διάμεσος, η μέση τιμή, η τυπική απόκλιση, η ασυμμετρία και η κύρτωση. Επομένως, κάθε χρονοσειρά αναπαριστάται από ένα διάνυσμα χαρακτηριστικών (feature vector). Για κάθε υποκείμενο με 18 αισθητήρες, έχει δημιουργηθεί μια αναπαράσταση με 108 χαρακτηριστικά, μειώνοντας κατά πολύ την διαστατικότητα των δεδομένων. Το επόμενο βήμα ήταν ο διαχωρισμός των δεδομένων σε 80% δεδομένα εκπαίδευσης και 20% δεδομένα αξιολόγησης.

Στη συνέχεια, χρησιμοποιήσαμε τον K –Κοντινότερο Γείτονα (K Nearest Neighbors) και τις Μηχανές Υποστήριξης Διανυσμάτων (SVM) ως το τελικό στάδιο δύο ξεχωριστών pipeline, τα οποία αποτελούνται από μία σειρά μετασχηματισμών πάνω στα χαρακτηριστικά των δεδομένων, που εξήχθησαν από τις προηγούμενες στατιστικές συναρτήσεις, που ακολουθείται από τον αντίστοιχο εκτιμητή. Για το κάθε pipeline έχουν χρησιμοποιηθεί δύο μετασχηματιστές: Ο μετασχηματιστής κανονικοποίησης (Standard Scaler) και η Ανάλυση Κύριων Συνιστωσών (PCA). Η μέθοδος PCA είναι μια διαδικασία εξαγωγής χαρακτηριστικών, μέσω της οποίας ένα σύνολο διανυσμάτων δεδομένων προβάλλεται σε έναν νέο χώρο μικρότερης συνήθως διάστασης, εξασφαλίζοντας πως η διακύμανση των προβαλλόμενων διανυσμάτων είναι μέγιστη, το μέσο συνολικό σφάλμα προβολής είναι ελάχιστο και οι διαστάσεις των προβαλλόμενων διανυσμάτων είναι ασυσχέτιστες. Η μορφή των pipeline φαίνονται στις εικόνες 4.2 και 4.3.



Εικόνα 4.2: Pipeline με εκτιμητή-ταξινομητή: KNN



Εικόνα 4.3: Pipeline με ταξινομητή-εκτιμητή: SVM

Έγινε χρήση της μεθόδου Αναζήτησης Πλέγματος (Grid search) για να υπολογίσουμε τις ιδανικές τιμές για τις υπερπαραμέτρους στο κάθε pipeline. Η αναζήτηση πλέγματος εξετάζει διεξοδικά όλους τους συνδυασμούς των υπερπαραμέτρων, αξιολογεί το μοντέλο σε ένα σύνολο δεδομένων αξιολόγησης και διατηρεί τον καλύτερο συνδυασμό. Για την περίπτωση, που ο εκτιμητής ήταν ο KNN οι υπερπαραμέτροι για τους οποίους αναζητήσαμε τις καλύτερες τιμές ήταν:

- Αριθμός συνιστωσών (για το μετασχηματιστή PCA)
- Αριθμός k (για τον εκτιμητή kNN)

Στην περίπτωση, που ο εκτιμητής ήταν ο SVM, οι υπερπαραμέτροι ήταν:

- Αριθμός συνιστωσών
- SVM kernels
- SVM C
- SVM gamma

Για την αναζήτηση πλέγματος χρησιμοποιήθηκε η συνάρτηση GridSearchCV από τη βιβλιοθήκη scikit-learn. Οι διαφορετικές τιμές των υπερπαραμέτρων για τα δύο pipeline φαίνονται στους πίνακες. Ωστόσο, οι τιμές και τα βήματα άλλαξαν κατά τη διάρκεια, προσεγγίζοντας πιο κοντά τις τιμές των παραμέτρων που δίνουν καλή απόδοση. Η μετρική απόδοσης που χρησιμοποιήθηκε για την συνάρτηση GridSearchCV είναι το f1-score.

Παράμετροι	Πιθανές επιλογές
PCA components	10,20,30,40,50,60
K	1,2,4,6,8

Πίνακας 4.1: Οι υπερπαραμέτροι και οι πιθανές τιμές τους για την αναζήτηση πλέγματος στο pipeline με kNN εκτιμητή.

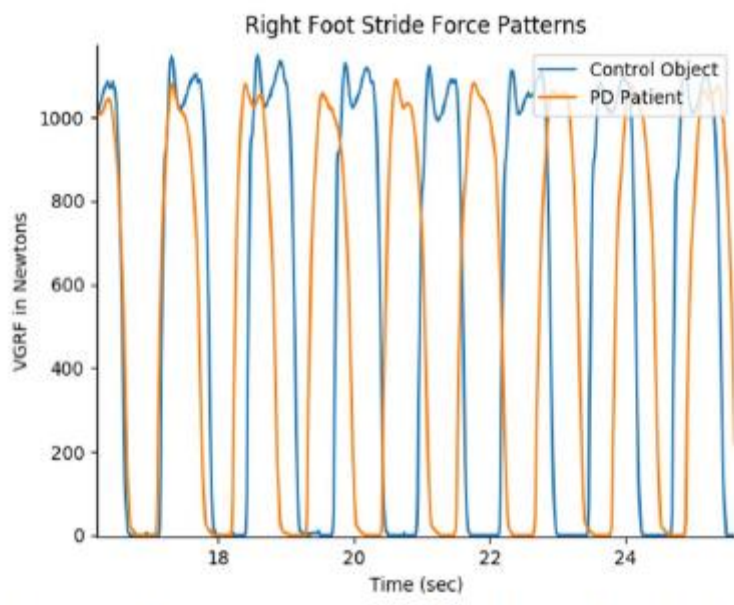
Παράμετροι	Πιθανές επιλογές
PCA components	10,20,30,40,50,60,80
Svm kernel	Linear,poly,rbf,sigmoid
C	0.5,1,5,10,15,20,30
Gamma	0.0001, 0.001, 0.01, 0.05

Πίνακας 4.2: Οι υπερπαράμετροι και οι πιθανές τιμές τους για την αναζήτηση πλέγματος στο pipeline με SVM εκτιμητή.

4.3 Μοντέλα Βαθιάς Μάθησης

4.3.1 Προεπεξεργασία δεδομένων

Για τα μοντέλα βαθιών νευρωνικών δικτύων, η αρχική διαδικασία ήταν να φτιαχτεί ένας πίνακας labels, στον οποίο ανάλογα με το όνομα του αρχείου, εισαγόταν τιμή 1, αν περιείχε τη λέξη «Pd» (ασθενής) ή 0, αν περιείχε τη λέξη «Co»(υγιής). Το επόμενο βήμα ήταν ο διαχωρισμός των δεδομένων. Το training set περιλαμβάνει το 70% των συνολικών δεδομένων, και χρησιμοποιείται για την εκπαίδευση των μοντέλων. Το σύνολο επικύρωσης περιλαμβάνει το 15% και χρησιμοποιείται για τον έλεγχο της υπερπροσαρμογής των δεδομένων και την επιλογή των βέλτιστων υπερπαραμέτρων. Το σύνολο αξιολόγησης περιλαμβάνει το υπολειπόμενο 15% και χρησιμοποιείται για την αξιολόγηση των μοντέλων. Στη συνέχεια, λόγω μεγάλης διαστατικότητας των δεδομένων και συγκεκριμένα από κάθε αισθητήρα είχαν καταγραφεί μέχρι και 12100 χρονικές στιγμές, έγινε διαχωρισμός των δεδομένων σε κομμάτια των 500 χρονικών στιγμών, οπότε το κάθε ξεχωριστό στοιχείο του πίνακα με τα δεδομένα εκπαίδευσης είχε διαστάσεις (500,18). Το τελευταίο βήμα της προεπεξεργασίας ήταν η κανονικοποίηση των δεδομένων. Συγκεκριμένα, η κανονικοποίηση, κάνει τα δεδομένα να έχουν μέση τιμή 0 και διακύμανση 1, όπως στην κανονική κατανομή. Αυτό το βήμα είναι απαραίτητο γιατί χωρίς αυτό είχαμε προβλήματα στην εκπαίδευση και το μοντέλο μας δεν είχε βέλτιστη απόδοση. Σε αυτό το σημείο, αξίζει να σημειωθεί ότι η παραπάνω προεπεξεργασία των δεδομένων έχει χρησιμοποιηθεί και στα 3 δίκτυα με Συνελκτικά και LSTM επίπεδα.



Εικόνα 4.4:Οπτικοποίηση ενός μέρους από τις χρονοσειρές από τη βάρδιση ενός ασθενή με PD και ενός υγιούς.

4.3.2 ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ ΤΩΝ ΜΟΝΤΕΛΩΝ

Στο πείραμα αυτό, η υλοποίηση στην παρούσα διπλωματική εστίασε σε τεχνικές βαθιάς μάθησης (deep learning), και στο πόσο καλά μπορούν να χειριστεί το πρόβλημα, δηλαδή την ταξινόμηση σε ασθενείς ή υγιείς.

Για την επιλογή των υπερπαραμέτρων των μοντέλων έχει χρησιμοποιηθεί η μέθοδος αναζήτησης πλέγματος.


Μοντέλο 1 – Προσέγγιση με ΣΝΔ¹

Η αρχική ιδέα ήταν η προσέγγιση της υλοποίησης από την εργασία [13] των Abdullah S Alharthi et al., με σκοπό την εξέλιξη της. Η υλοποίηση περιλαμβάνει ένα 1D CNN, για την αυτόματη εξαγωγή χαρακτηριστικών βάρδισης από τα ακατέργαστα σήματα. Ωστόσο, σύμφωνα με την εργασία τους πρώτα γινόταν διάσπαση των δεδομένων σε παράθυρα λιγότερων χρονοστιγμών, μετά κανονικοποίηση και έπειτα διαχωρισμός των δεδομένων σε δεδομένα εκπαίδευσης και δεδομένα αξιολόγησης. Στην δική μου προσέγγιση,

¹ Το μοντέλο αυτό, στη συνέχεια της διπλωματικής εργασίας, θα αναφέρεται ως «μοντέλο 1» ή «μοντέλο ΣΝΔ-MaxPooling».

ο διαχωρισμός των δεδομένων σε δεδομένα εκπαίδευσης και αξιολόγησης προηγήθηκε των άλλων δύο βημάτων, ώστε να μην υπάρχουν δεδομένα από τους ίδιους ασθενείς στο train και test set ταυτόχρονα. Η αρχιτεκτονική που υλοποιήθηκε περιλαμβάνει:

- ❖ ένα 1-D συνελκτικό στρώμα 16 φίλτρων, με μέγεθος φίλτρου 3
- ❖ ένα MaxPooling στρώμα, με μέγεθος παραθύρου 2
- ❖ ένα 1-D συνελκτικό στρώμα 16 φίλτρων, με μέγεθος φίλτρου 3
- ❖ ένα MaxPooling στρώμα, με μέγεθος παραθύρου 2
- ❖ Ένα Flatten στρώμα
- ❖ Ένα πλήρως συνδεδεμένο επίπεδο με 50 νευρώνες
- ❖ Ένα πλήρως συνδεδεμένο επίπεδο με 20 νευρώνες
- ❖ Ένα Dropout επίπεδο, με πιθανότητα 0.5
- ❖ ένα πλήρως συνδεδεμένο επίπεδο με 1 νευρώνα, που είναι και το επίπεδο εξόδου



Εικόνα 4.5: Πάνω: Αναπαράσταση της αρχιτεκτονικής του δικτύου Κάτω: Επεξήγηση του κάθε στρώματος

Από τα συνελκτικά επίπεδα γίνεται η εξαγωγή χαρακτηριστικών, ενώ τα πλήρως συνδεδεμένα επίπεδα χρησιμοποιούνται για την ταξινόμηση. Η συνάρτηση ενεργοποίησης που χρησιμοποιήθηκε είναι η RELU, ενώ στο τελευταίο επίπεδο επειδή το πρόβλημα αφορά δυαδική ταξινόμηση χρησιμοποιήθηκε η sigmoid. Για τον ίδιο λόγο η συνάρτηση κόστους που χρησιμοποιήθηκε είναι η binary cross entropy.

Το δίκτυο εκπαιδεύτηκε για 50 εποχές, με χρήση του Adam optimizer, με ρυθμό εκμάθησης 0.02. Κατά τη διάρκεια της εκπαίδευσης, αποθηκεύονταν τα βάρη, τα οποία

έδιναν καλύτερα αποτελέσματα, ως προς τη μετρική της ακρίβειας των επικυρούμενων δεδομένων (validation accuracy).

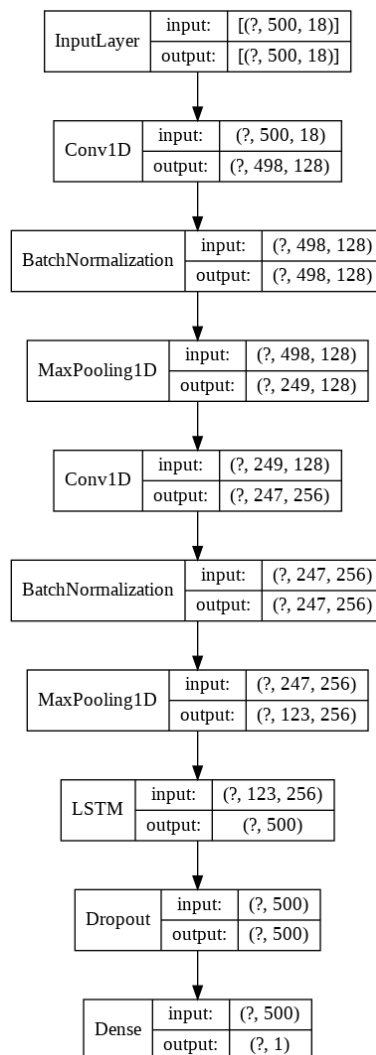
Μοντέλο 2 – Προσέγγιση με υβριδικό CNN-LSTM δίκτυο²

Το δίκτυο αποτελείται από ένα κομμάτι συνελκτικού δικτύου και ένα κομμάτι αναδρομικού δικτύου. Το CNN τμήμα, στο οποίο δίνονται ως είσοδος τα ακατέργαστα δεδομένα, αποτελείται από δύο 1-D συνελκτικά επίπεδα, ακολοθούμενα από 1 Batch normalization και 1 Max-Pooling επίπεδο έκαστο για υποδειγματοληψία. Το στρώμα Batch Normalization είναι μια τεχνική που χρησιμοποιείται για να κάνει τα νευρωνικά δίκτυα πιο γρήγορα και πιο σταθερά. Συγκεκριμένα, κανονικοποιώντας την εισόδο για κάθε mini-batch, σταθεροποιεί την διαδικασία εκμάθησης και μειώνει αισθητά τον αριθμό των εποχών, που χρειάζονται για να εκπαιδευτεί το βαθύ νευρωνικό δίκτυο.

Η βασική ιδέα πίσω από την συγκεκριμένη προσέγγιση είναι να χρησιμοποιηθεί το CNN τμήμα, για την εξαγωγή χαρακτηριστικών, ώστε να δοθούν ως είσοδος στο κομμάτι LSTM τα πιο διακριτά χαρακτηριστικά της εισόδου με παράλληλη μείωση της διαστατικότητας. Δύο συνελκτικά επίπεδα χρησιμοποιήθηκαν σε σειρά ώστε να γίνει δυνατή η εξαγωγή χαρακτηριστικών. Ταυτόχρονα, καθώς πηγαίνουμε πιο βαθιά στο δίκτυο, πραγματοποιείται και η μείωση των διαστάσεων. Το 1D-CNN εκτελείται στη χρονική διάσταση, και εξάγονται χαρακτηριστικά γειτονικών χρονικών πλαισίων, διατηρώντας έτσι τη πληροφορία της χρονικής αλληλουχίας των δεδομένων. Ο χάρτης χαρακτηριστικών, μπορεί, έτσι να θεωρηθεί ως 1-D χρονοδιάγραμμα με πολλά κανάλια, τα οποία διατηρούν την χρονική πληροφορία. Στη συνέχεια, το αποτέλεσμα τροφοδοτείται στο κομμάτι LSTM, το οποίο είναι υπεύθυνο για την αναγνώριση και απομνημόνευση των μακροχρόνιων εξαρτήσεων μεταξύ των δεδομένων. Το τμήμα LSTM αποτελείται από ένα στώμα LSTM, ένα Dropout επίπεδο και ένα επίπεδο εξόδου, για ταξινόμηση σε μία από τις δύο κατηγορίες, υγιής ή ασθενής. Η μη γραμμική συνάρτηση RELU εφαρμόζεται ως συνάρτηση ενεργοποίησης που χρησιμοποιείται στα συνελκτικά επίπεδα. Όσο αφορά το επίπεδο εξόδου, χρησιμοποιείται η συνάρτηση ενεργοποίησης sigmoid, που ενδείκνυται για προβλήματα δυαδικής ταξινόμησης.

² Το μοντέλο αυτό, στη συνέχεια της διπλωματικής εργασίας θα αναφέρεται ως «μοντέλο 2» ή «υβριδικό μοντέλο CNN-LSTM».

Για τα δύο συνελκτικά στρώματα έχουν χρησιμοποιηθεί 128 και 256 φίλτρα αντίστοιχα, μεγέθους φίλτρου 3, ενώ για τα MaxPooling επίπεδα έχει επιλεγεί παράθυρο μεγέθους 2. Το LSTM επίπεδο αποτελείται από 500 νευρώνες. Εφόσον το πρόβλημα μου αφορά δυαδική ταξινόμηση, έχει ξανά χρησιμοποιηθεί ως συνάρτηση κόστους η binary crossentropy, ενώ για τη βελτιστοποίηση έχει χρησιμοποιηθεί ο Adam, με τις προκαθορισμένες τιμές. Το μοντέλο εκπαιδεύτηκε για 50 εποχές, και πάλι κατά τη διάρκεια της εκπαίδευσης, αποθηκεύονταν τα βάρη, τα οποία έδιναν καλύτερα αποτελέσματα, ως προς τη μετρική της ακρίβειας των επικυρούμενων δεδομένων (validation accuracy).




Εικόνα 4.6: Η αρχιτεκτονική του υβριδικού CNN-LSTM δικτύου

Μοντέλο 3 – Προσέγγιση με deep CNN ³

Το μοντέλο αυτό συνίσταται από 3 Συνελικτικά στρώματα, ακολουθούμενα από 3 Batch Normalization επίπεδα, κάνοντας την είσοδο λιγότερο ευαίσθητη στις αρχικοποιήσεις, και τη συνάρτηση ενεργοποίησης «RELU» το καθένα. Τα επίπεδα Max Pooling αφαιρέθηκαν. Οι λόγοι είναι ότι με τα MaxPooling αγνοούνται οι ακριβείς θέσεις των χαρακτηριστικών, αλλά και με τη χρήση τους μειώνεται ο αριθμός των εισόδων στο επόμενο επίπεδο εξαγωγής χαρακτηριστικών, περιορίζοντας έτσι τις πληροφορίες, οι οποίες περνάνε στο επόμενο επίπεδο. Το ιδιαίτερο στοιχείο του συγκεκριμένου δικτύου είναι ότι επιπρόσθετα των συνελικτικών επιπέδων, στη θέση των πλήρων συνδεδεμένων επιπέδων, εκτός του επιπέδου εξόδου, έχει χρησιμοποιηθεί ένα Global Average Pooling στρώμα, ακολουθούμενο από ένα πλήρες συνδεδεμένο επίπεδο για την ταξινόμηση. Αυτό έχει σαν συνέπεια την μείωση των εκπαιδευόμενων παραμέτρων του μοντέλου, συγκριτικά με τη χρήση περισσότερων πλήρως συνδεδεμένων επιπέδων, περιορίζοντας έτσι σημαντικά το πρόβλημα της υπερεκπαίδευσης. Με χρήση του GlobalAveragePooling επιπέδου υπολογίζεται η μέση τιμή για τον κάθε χάρτη χαρακτηριστικών, τροφοδοτώντας το επίπεδο εξόδου.

Τα στρώματα συνελικτικών επιπέδων έχουν μέγεθος 128, 256, 128 με μέγεθος πυρήνα 8, 5 και 3 αντίστοιχα. Για την αρχικοποίηση των βαρών (kernel_initializer) έχει χρησιμοποιηθεί η ομοιόμορφη κατανομή. Η συνάρτηση κόστους ήταν και πάλι η binary_crossentropy, ενώ το δίκτυο εκπαιδεύτηκε για 35 εποχές, με χρήση του Adam optimizer, με τις προκαθορισμένες τιμές. Στην εικόνα 4.7 απεικονίζεται η αρχιτεκτονική του δικτύου.

³ Το μοντέλο αυτό στη συνέχεια της διπλωματικής εργασίας θα αναφέρεται «μοντέλο 3» ή «μοντέλο DeepConv-GlobalAVGPool».



Εικόνα 4.7: Η αρχιτεκτονική του 3ου δικτύου

Φυσικά, δοκιμάστηκαν και άλλα παρόμοια μοντέλα, τα οποία όμως δεν είχαν αξιόλογα αποτελέσματα.

4.4 ΕΡΓΑΛΕΙΑ

Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε για την δημιουργία των αλγορίθμων είναι η **Python3**. Η Python χρησιμοποιήθηκε σε συνδυασμό με κάποιες βιβλιοθήκες, που κατέστησαν πολύ πιο εύκολη την ανάπτυξη των αλγορίθμων.

Συγκεκριμένα, η βιβλιοθήκη **NumPy** χρησιμοποιείται για χρήση πολυδιάστατων πινάκων και πράξεις με αυτούς. Έχει επίσης συναρτήσεις, στο πεδίο της γραμμικής άλγεβρας, μετασχηματισμού fourier κ.ά. Αξίζει να σημειωθεί ότι οι πίνακες της Numpy (NumPy arrays) υπερτερούν σε σχέση με τις λίστες που παρέχει η Python, τόσο σε κατανάλωση μνήμης, όσο και σε ταχύτητα.

Η **Scikit-learn** είναι μια ανοιχτού κώδικα (open-source) βιβλιοθήκη της python. Στα πλαίσια της διπλωματικής χρησιμοποιήθηκε εκτενώς σε διάφορα στάδια των αλγορίθμων,

παραδείγματος χάριν για τον διαχωρισμό του συνόλου δεδομένων, με τη συνάρτηση `train_test_split`, τη κανονικοποίηση των δεδομένων με τη συνάρτηση `Standard Scaler`, καθώς και την μέτρηση της απόδοσης των μοντέλων με την `classification_report`. Επίσης, διαθέτει αλγόριθμους για ταξινόμηση και μηχανές διανυσμάτων υποστήριξης.

Η **Scipy** περιέχει παραπάνω επιστημονικές μεθόδους και υπολογισμούς από τη `Numpy`, ενώ έχει γραφτεί με χρήση της τελευταίας. Στην παρούσα εργασία χρησιμοποιήθηκε για τη στατιστική εξαγωγή των χαρακτηριστικών.

Η **Tensorflow** είναι μια ανοιχτού κώδικα τεχνητής νοημοσύνης βιβλιοθήκη, που χρησιμοποιεί γράφους ροής δεδομένων για την κατασκευή των μοντέλων. Χρησιμοποιείται για δημιουργία βαθιών νευρωνικών δικτύων.

Η **Keras** είναι μια υψηλού επιπέδου βιβλιοθήκη, που μπορεί να χρησιμοποιηθεί από πάνω πό πολλές `deep learning` βιβλιοθήκες, όπως `Tensorflow`, `Theano`, `CNTK`. Τα μοντέλα βαθιάς μάθησης της παρούσας διπλωματικής εργασίας είναι υλοποιημένα σε `Keras` και `Tensorflow`.

ΚΕΦΑΛΑΙΟ 5: ΑΠΟΤΕΛΕΣΜΑΤΑ - ΣΥΜΠΕΡΑΣΜΑΤΑ

Στο κεφάλαιο αυτό, παρουσιάζονται τα αποτελέσματα των μετρήσεων των μοντέλων που πραγματοποιήθηκαν στα δεδομένα αξιολόγησης (test set). Επίσης, γίνεται σύγκριση μεταξύ των διαφορετικών μοντέλων, εξάγοντας τα συμπεράσματα της διπλωματικής. Τέλος, γίνεται μια σύνοψη της παρούσας εργασίας, κάνοντας προτάσεις για μελλοντικές εργασίες.

5.1 Αποτελέσματα και συμπεράσματα

Για την αξιολόγηση των μετρήσεων χρησιμοποιήθηκαν οι μετρικές ακρίβεια (precision), ανάκληση (recall), f1 για κάθε κλάση (υγιής ή ασθενής) και η μετρική ορθότητα (accuracy) συνολικά για το μοντέλο. Ήδη από το πρώτο μοντέλο deep learning (μοντέλο ΣΝΔ-MaxPooling) τα αποτελέσματα δεν ήταν απογοητευτικά, όπως φαίνεται και στον πίνακα 5.1. Όμως, κατά τη διάρκεια της εκπαίδευσης του μοντέλου υπήρχε το πρόβλημα της υπερεκπαίδευσης, παρά το γεγονός ότι είχαμε χρησιμοποιήσει και επίπεδο Dropout. Δοκιμάστηκε και η επαύξηση δεδομένων, προκειμένου να μειωθεί το overfitting, κατά την οποία χωρίσαμε τα δεδομένα σε επικαλυπτόμενα διαστήματα μεγέθους 500 timepoints, χωρίς όμως να οδηγήσει σε καλύτερα αποτελέσματα.

Κλάση	Precision	Recall	F1	Accuracy
Ασθενής	88%	89%	88%	
Υγιής	72%	70%	71%	
				83%

Πίνακας 5.1: Τα αποτελέσματα του πρώτου μοντέλου βαθιάς μάθησης

Στο μοντέλο CNN-LSTM εξήγαμε χαρακτηριστικά από τρία συνελκτικά επίπεδα, τα οποία στη συνέχεια δόθηκαν ως είσοδος σε LSTM επίπεδο για χρονική δυναμική απομνημόνευση, και έτσι ακριβέστερη ταξινόμηση στις δύο κατηγορίες, υγιής ή ασθενής. Το υβριδικό μοντέλο πέτυχε πολύ καλά αποτελέσματα, φτάνοντας accuracy 94%, όπως φαίνεται

και στον πίνακα 5.2. Στην κλάση ασθενής, οι μετρικές precision και recall έχουν τις τιμές 96% και 95% αντίστοιχα, ενώ στην κλάση υγής 90% και 92% αντίστοιχα.


Κλάση	Precision	Recall	F1	Accuracy
Υγής	90%	92%	91%	
Ασθενής	96%	95%	96%	
				94%

Πίνακας 5.2: Τα αποτελέσματα του δεύτερου μοντέλου βαθιάς μάθησης

Το τρίτο μοντέλο (Μοντέλο DeepConv-GlobalAvgPool) πέτυχε, την καλύτερη ορθότητα, πετυχαίνοντας accuracy 95%. Μάλιστα, κατά την εκπαίδευση του μοντέλου, συγκρίνοντας την μετρική accuracy στα δεδομένα εκπαίδευσης με την ίδια μετρική στα δεδομένα επικύρωσης φαίνεται ότι μειώθηκε δραστικά το πρόβλημα της υπερεκπαίδευσης, που παρουσιάστηκε στο μοντέλο 1. Σε αυτό, ζωτικής σημασίας ήταν η αντικατάσταση των πλήρως συνεδμεμένων επιπέδων μετά τα συνελκτικτικά επίπεδα, από το επίπεδο Global Average Pooling. Επίσης, με την χρήση του Batch normalization πριν από την συνάρτηση ενεργοποίησης, το μοντέλο είναι λιγότερο ευαίσθητο στις αρχικοποιήσεις.

Κλάση	Precision	Recall	F1	Accuracy
Υγής	93%	92%	92%	
Ασθενής	96%	96%	96%	
				95%

Πίνακας 5.3: Τα αποτελέσματα του τρίτου μοντέλου μηχανικής μάθησης



Εικόνα 5.1: Σύγκριση της μετρικής accuracy μεταξύ των νευρωνικών μοντέλων

Για λόγους πληρότητας, δημιουργήσαμε, αφού κάναμε εξαγωγή στατιστικών χαρακτηριστικών από τα δεδομένα, τα μοντέλα ταξινόμησης SVM και KNN, ως baseline, για να συγκρίνουμε τις αποδόσεις των νευρωνικών με άλλες μεθόδους μηχανικής μάθησης. Στη συνέχεια, παραθέτουμε τα αποτελέσματα των μοντέλων ταξινόμησης SVM και KNN.

Κλάση	Precision	Recall	F1	Accuracy
Υγιής	68%	79%	73%	
Ασθενής	79%	69%	74%	
				74%

Πίνακας 5.4: Τα αποτελέσματα του ταξινομητή KNN

Συγκεκριμένα, εξήγαμε χαρακτηριστικά με στατιστικές μεθόδους, τα οποία δόθηκαν ως είσοδος σε δύο pipelines. Τα δύο pipelines, που αποτελούνται από μία μέθοδο μείωσης διαστατικότητας, την Ανάλυση Κύριων Συνιστωσών, μία μέθοδο κανικοποίησης, τον Standard Scaler, και έναν ταξινομητή, τον KNN στο πρώτο και τα SVM στο δεύτερο, έφεραν τα αποτελέσματα που απεικονίζονται στους πίνακες 5.5 και 5.6 αντίστοιχα. Συγκριμένα, στον KNN έχουμε accuracy 74%, με αρκετά χαμηλή ακρίβεια στη κλάση «υγιής», ενώ στον SVM έχουμε accuracy 79%, με χαμηλή ανάκληση στην κλάση «υγιής». Παρατηρώντας τα

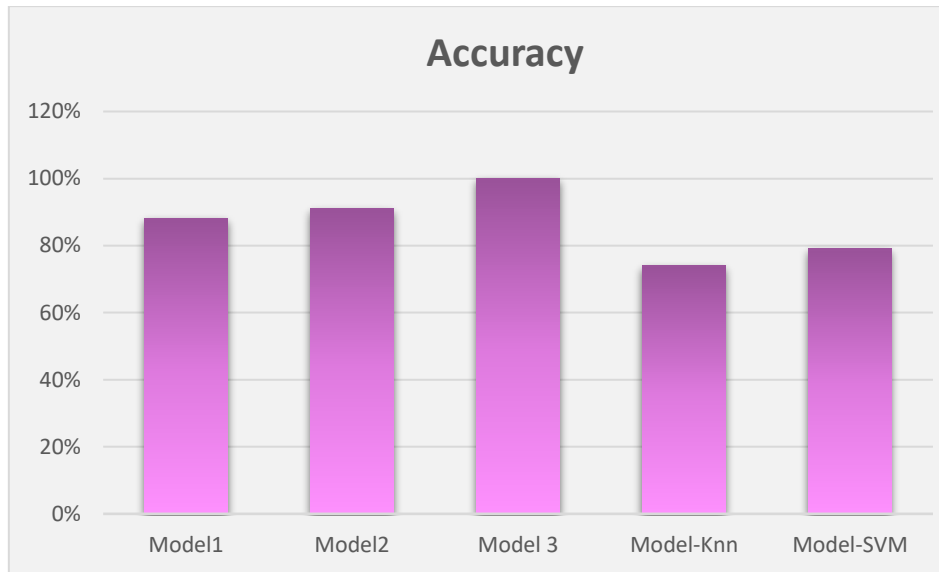
αποτελέσματα στα δύο μοντέλα αυτά, βλέπουμε ότι στην κλάση υγιής δεν έχουν καλά αποτελέσματα.

Κλάση	Precision	Recall	F1	Accuracy
Υγιής	82%	70%	75%	
Ασθενής	77%	87%	82%	
				79%

Πίνακας 5.5: Τα αποτελέσματα του ταξινομητή SVM

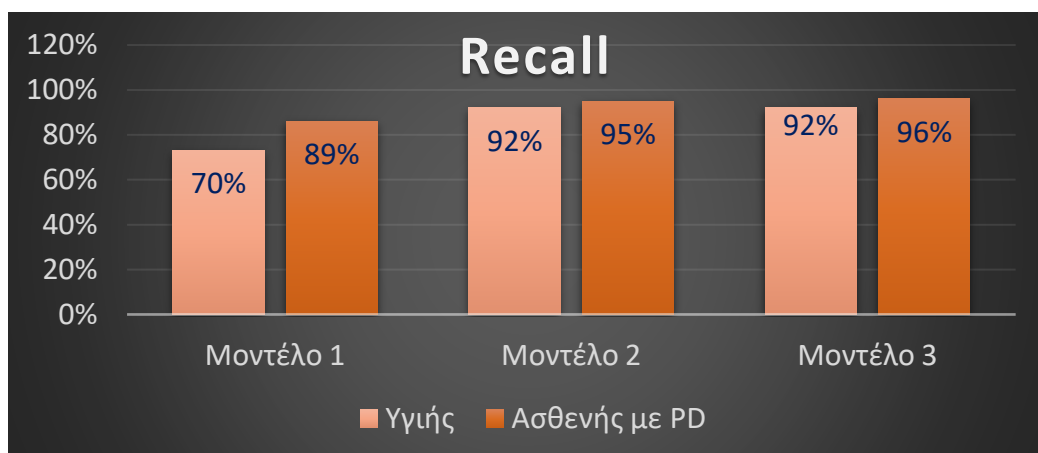
Στο σημείο αυτό πρέπει να αναφερθεί ότι τα αποτελέσματα στα μοντέλα με τους ταξινομητές KNN και SVM αφορούν την συνολική βάδιση του κάθε εξεταζόμενου. Αντίθετα, στα μοντέλα βαθιάς μάθησης, τα δεδομένα του κάθε εξεταζόμενου είχαν διασπαστεί σε κομμάτια των 500 timepoints, και τα αποτελέσματα στους πίνακες 5.1-5.3 αφορούν τα παράθυρα των 500 timepoints. Έτσι, λοιπόν, για να βγει η τελική διάγνωση του κάθε εξεταζόμενου, αλλά και να γίνει σωστά η σύγκριση των βαθιών νευρωνικών με τις άλλες μεθόδους, για κάθε άτομο θα λάβουμε υπόψη σε ποια κατηγορία έχει ταξινομηθεί η πλειοψηφία των παραθύρων του. Έτσι, αν η πλειοψηφία των παραθύρων ταξινομήθηκε στην κλάση υγιής, η διάγνωση του εξεταζόμενου είναι «υγιής», διαφορετικά «ασθενής». Υλοποιώντας αυτό, με το μοντέλο CNN-LSTM είχαμε σωστή διάγνωση για το 91% των ατόμων που ανήκουν στο σύνολο αξιολόγησης, ενώ με το μοντέλο DeepConv-GlobalAVGPooling πετύχαμε εξαιρετικά αποτελέσματα, αφού για όλους τους εξεταζόμενους έγινε η σωστή διάγνωση.

Στην εικόνα 5.2 συγκρίνονται τα αποτελέσματα των διαφορετικών μοντέλων ως προς την μετρική της ορθότητας. Είναι φανερό πως τα βαθιά νευρωνικά δίκτυα είναι πιο κατάλληλα για το πρόβλημα της διάγνωσης της νόσου, συγκριτικά με τα μοντέλα που χρησιμοποιούν τους ταξινομητές kNN και SVM.



Εικόνα 5.2: Σύγκριση των μοντέλων των νευρωνικών δικτύων με κλασικά μοντέλα μηχανικής μάθησης(KNN-SVM)

Επίσης, το βάθος και το μέγεθος του νευρωνικού δικτύου επηρεάζει την απόδοση του μοντέλου. Παρατηρείται ότι αυξάνοντας το μέγεθος του μοντέλου σε σχέση με το πρώτο μοντέλο βαθιάς μάθησης, είχαμε καλύτερα αποτελέσματα στην επίλυση του προβλήματος της διάγνωσης. Συγκεκριμένα, το πρώτο μοντέλο που χρησιμοποιεί στα συνελκτικά επίπεδα 16 και 24 φίλτρα αντίστοιχα, δεν έχει όσο καλά αποτελέσματα έχουν τα άλλα δύο υλοποιημένα μοντέλα βαθιάς μάθησης. Επίσης, η χρήση του επιπέδου υποδειγματοληψίας Global Average Pooling στη θέση των πλήρως συνδεδεμένων επιπέδων, έπαιξε καθοριστικό ρόλο στην εξάλειψη του προβλήματος της υπερεκπαίδευσης.



Εικόνα 5.3: Σύγκριση της μετρικής recall μεταξύ των νευρωνικών μοντέλων

Το υβριδικό μοντέλο, καθώς και το μοντέλο με τα συνελκτικά επίπεδα και το Global Average Pooling επίπεδο, καταφέρνουν να προβλέψουν με μεγάλη ακρίβεια την κλάση που ανήκει ο εξεταζόμενος, δηλαδή αν είναι ασθενής με νόσο Parkinson ή όχι. Ιδιαίτερη σημασία στο συγκεκριμένο πρόβλημα της διάγνωσης δίνεται στην ανάκληση, ή αλλιώς ευαισθησία. Ουσιαστικά, στο πρόβλημα της διάγνωσης, η ανάκληση αναφέρεται στην σωστή κατηγοριοποίηση των ασθενών με τη νόσο, δηλαδή να προσδιορίσει εάν το τεστ είναι αρκετά ευαίσθητο στον εντοπισμό της ασθένειας. Στο πλαίσιο της διπλωματικής, υιοθετούμε την παραδοχή ότι ένα ψευδώς αρνητικό, δηλαδή η διάγνωση ενός ασθενούς ως υγιούς, είναι πιο καταστροφικό από ένα ψευδώς θετικό, το οποίο θα τον έθετε σε μια σειρά αχρείαστων εξετάσεων. Για αυτό, λοιπόν, δίνεται μια ελαφρώς μεγαλύτερη σημασία στην μετρική της ανάκλησης, στην κλάση «ασθενής». Ωστόσο, πολύ χαμηλά επίπεδα precision, με πολύ υψηλά επίπεδα recall, πάλι δεν θα αποτελούσαν ένα επαρκές μοντέλο, αφού θα έδινε στις περισσότερες περιπτώσεις διάγνωση ύπαρξης ασθένειας. Τόσο το υβριδικό μοντέλο, όσο και το βαθύ CNN μοντέλο, πέτυχαν υψηλά ποσοστά ανάκλησης, με το πρώτο να πετυχαίνει ευαισθησία στη διάγνωση της νόσου 95% και το δεύτερο 96%.

5.2 ΣΥΝΟΨΗ ΚΑΙ ΜΕΛΛΟΝΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ

Στην παρούσα διπλωματική, μελετήθηκε η συμβολή της μηχανικής μάθησης στο κομμάτι της διάγνωσης της νόσου Parkinson, μίας εκφυλιστικής νόσου του νευρικού συστήματος, που αφορά μεγάλο μέρος του πληθυσμού. Συγκεκριμένα, με δεδομένα βάδισης από ασθενείς με τη νόσο, εστίασαμε σε τεχνικές νευρωνικών δικτύων, δημιουργώντας τρία μοντέλα βαθιών νευρωνικών δικτύων. Υλοποιήσαμε και δύο ακόμη μοντέλα μηχανικής μάθησης, με χρήση του K-κοντινότερου γείτονα και SVM, χρησιμοποιώντας τα ως μοντέλα αναφοράς για τη σύγκριση με τα μοντέλα νευρωνικών δικτύων. Από τα αποτελέσματα της διπλωματικής εργασίας, συμπεραίνουμε ότι τα νευρωνικά δίκτυα είναι τα πιο κατάλληλα για το συγκεκριμένο πρόβλημα, της ταξινόμησης δηλαδή σε ασθενή με νόσο Parkinson ή υγιή. Τα μοντέλα με την καλύτερη απόδοση είναι το υβριδικό μοντέλο με Συνελκτικά και LSTM επίπεδα, και το βαθύ συνελκτικό νευρωνικό δίκτυο, με το Global Average Pooling επίπεδο.

Μάλιστα, παρόλο που το σύνολο των δεδομένων δεν είναι πολύ μεγάλο, τα μοντέλα κατάφεραν να πετύχουν ορθότητα ίση με **94%** και **95%**, αντίστοιχα. Τα ποσοστά αυτά

αφορούν την ταξινόμηση των παράθυρων των 500 χρονοστιγμών, που είχαν χωριστεί τα δεδομένα για την βέλτιστη εκπαίδευση των μοντέλων. Ωστόσο, ο σκοπός του συστήματος, δηλαδή η διάγνωση ενός εξεταζόμενου ως προς τη νόσο Parkinson αφορά το σύνολο της βάρδισης του. Για το λόγο αυτό, για τον κάθε εξεταζόμενο συγκεντρώθηκαν οι προβλέψεις επί των παραθύρων της βάρδισης του. Έτσι, ο εξεταζόμενος κατηγοριοποιείται σε ασθενή ή υγιή, ανάλογα με την κατηγορία που ανήκει η πλειοψηφία των προβλέψεων των παραθύρων που αφορούν την βάρδιση του. Το υβριδικό μοντέλο κατάφερε να αξιολογήσει σωστά το 91% των ασθενών που ανήκουν στο σύνολο αξιολόγησης, ενώ το βαθύ συνελκτικό νευρωνικό δίκτυο κατηγοριοποίησε σωστά όλους τους εξεταζόμενους (**100%**).

Η συγκεκριμένα εργασία έχει δυνατότητες εξέλιξης. Συγκεκριμένα, σε **μελλοντικές εργασίες**, μία πιθανή επέκταση των αποτελεσμάτων των μοντέλων διάγνωσης της παρουσίας διπλωματικής, θα ήταν είναι η ανίχνευση της σοβαρότητας της νόσου (multiclass classification). Μία ακόμη πρόταση είναι να συνδυαστούν τα μοντέλα που αναπτύχθηκαν στο πλαίσιο της εργασίας, με άλλη μοντέλα, τα οποία παρουσιάζουν επίσης πολύ καλά αποτελέσματα στη διάγνωση της νόσου, αξιοποιώντας άλλου τύπου δεδομένα, όπως χαρακτηριστικά έχουν προαναφερθεί στο κεφάλαιο 1.2. Συνδυάζοντας, λοιπόν, αυτά τα μοντέλα θα μπορούσε να δημιουργηθεί ένα **υβριδικό και ενιαίο σύστημα**, το οποίο θα μπορούσε να φέρει ακόμη πιο ακριβή αποτελέσματα, και ενδεχομένως να αποτελέσει ένα πραγματικό διαγνωστικό εργαλείο. Φυσικά, βασική προϋπόθεση για τα προαναφερθέντα, είναι η συλλογή και συγκέντρωση περισσότερων δεδομένων, διότι αποτελούν αναγκαία συνθήκη για οποιαδήποτε περαιτέρω δουλειά. Κλείνοντας, είμαστε αισιόδοξοι ότι η μηχανική μάθηση και η τεχνητή νοημοσύνη θα αποτελέσουν βασικούς πυλώνες της ιατρικής επιστήμης τα επόμενα χρόνια, συμβάλλοντας στην βελτίωση σε πολλούς τομείς της.

ΚΕΦΑΛΑΙΟ 6: ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Parkinson J. An essay on the shaking palsy, 1817. [Google Scholar](#)
- [2] IBM Watson for Genomics, url: <https://www.ibm.com/products/watson-for-genomics/resources>
- [3] Shivangi, Anubhav Johri , Ashish Tripathi, Parkinson Disease Detection Using Deep Neural Networks (2019)
- [4] Yash Mitra, Vipul Rustagi, Classification of Subjects with Parkinson's Disease Using Gait Data Analysis (2018)
- [5] Shubham Bind , Arvind Kumar Tiwari , Anil Kumar Sahani, A Survey of Machine Learning Based Approaches for Parkinson Disease Prediction (2015)
- [6] Rustempasic, Indira, & Can, M. (2013). Diagnosis of Parkinson's Disease using Fuzzy C-Means Clustering and Pattern Recognition. SouthEast Europe Journal of Soft Computing
- [7] Tsanas, A., Little, M. A., McSharry, P. E., Spielman, J., & Ramig, L. O. (2012). Novel speech signal processing algorithms for highaccuracy classification of Parkinson's disease. Biomedical Engineering, IEEE Transactions on, 59(5), 1264-1271
- [8] Ali Saad, Iyad Z. Abbas Z., Mohammad A., Paul B., François G. & Dimitri L. (May 2013) "A Preliminary Study of the Causality of Freezing of Gait for Parkinson's Disease Patients: Bayesian Belief Network Approach" IJCSI International Journal of Computer Science Issues
- [9] Salvatore, C., Cerasa, A., Castiglioni, I., Gallivanone, F., Augimeri, A., Lopez, M., ... & Quattrone, A. (2014). Machine learning on brain MRI data for differential diagnosis of Parkinson's disease and Progressive Supranuclear Palsy. Journal of neuroscience methods, 222, 230-237.
- [10] Morales, D. A., Vives-Gilabert, Y., Gómez-Ansón, B., Bengoetxea, E., Larrañaga, P., Bielza, C. & Delfino, M. (2013). Predicting dementia development in Parkinson's disease using Bayesian network classifiers. Psychiatry Research: NeuroImaging, 213(2), 92-98.
- [11] Wu, D., Warwick, K., Ma, Z., Gasson, M. N., Burgess, J. G., Pan, S., & Aziz, T. Z. (2010). Prediction of Parkinson's disease tremor onset using a radial basis function neural network based on particle swarm optimization. International journal of neural systems, 20(02), 109-116.
- [12] Imanne El Maachi, Guillaume-Alexandre Bilodeau, Wassim Bouachir, Deep

- [13] Abdullah S Alharthi, Krikor B Ozanyan, Deep Learning for Ground Reaction Force Data Analysis: Application to Wide-Area Floor Sensing (2019)
- [14] Gonzalez R., Woods R, Ψηφιακή Επεξεργασία Εικόνας, Επιστημονική επιμέλεια: Κόλλιας Σ., Εκδόσεις Τζιόλα, 2018
- [15] Βασιλόπουλος, Νευρολογία, Εκδόσεις Πασχαλίδης
- [16] Βλαχάβας Ι., Κεφαλάς Π., Βασιλειάδης Ν., Κόκκορας Φ., Σακελλαρίου Η., 2011. Τεχνητή νοημοσύνη, Εκδόσεις Πανεπιστημίου Μακεδονίας
- [17] 1D-Convnet for accurate Parkinson disease detection and severity prediction from gait, [Expert Systems with Applications](#) (2019)
- [18] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- [19] Igor Kononenko, 2001, Machine learning for medical diagnosis: history, state of the art and perspective
- [20] Hossin, M.1 and Sulaiman, M.N, Hossin, 2015. A REVIEW ON EVALUATION METRICS FOR DATA CLASSIFICATION EVALUATIONS
- [21] Jenna Wiens, Erica S Shenoy, Machine Learning for Healthcare: On the Verge of a Major Shift in Healthcare Epidemiology, *Clinical Infectious Diseases*, Volume 66, Issue 1, 1 January 2018, Pages 149–153,
- [22] A. S. Walia. Types of Optimization Algorithms used in Neural Networks and Ways to Optimize Gradient Descent. <https://towardsdatascience.com/types-of-optimization-algorithms-used-in-neural-networks-and-ways-to-optimize-gradient-95ae5d39529f>, 2017b.
- [23] Motiur Rahman, , Dilshad Islam, Rokeya Jahan Mukti, Indrajit Saha,2020. A deep learning approach based on convolutional LSTM for detecting diabetes
- [24] Ayse Betul Oktay, Abdulkadir Kocer, Differential diagnosis of Parkinson and essential tremor with convolutional LSTM networks, *Biomedical Signal Processing and Control*, Volume 56, 2020, 101683, ISSN 1746-8094, <https://doi.org/10.1016/j.bspc.2019.101683>.
- [25] Xiaowu Zou, Zidong Wang, Qi Li, Weiguo Sheng, Integration of residual network and convolutional neural network along with various activation functions and global pooling for

time series classification, *Neurocomputing*, Volume 367, 2019, Pages 39-45, ISSN 0925-2312,

<https://doi.org/10.1016/j.neucom.2019.08.023>.

[26] Alex Sherstinsky, Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network, *Physica D: Nonlinear Phenomena*, Volume 404, 2020, 132306, ISSN 0167-2789, <https://doi.org/10.1016/j.physd.2019.132306>.

[27] Chen, H. L., Huang, C. C., Yu, X. G., Xu, X., Sun, X., Wang, G., & Wang, S. J. (2013). An efficient diagnosis system for detection of Parkinson's disease using fuzzy k-nearest neighbor approach.

[28] Prashanth, R., Roy, S. D., Mandal, P. K., & Ghosh, S. (2014). Parkinson's disease detection using olfactory loss and REM sleep disorder features. In *Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE* (pp. 5764-5767). IEEE.

[29] Sellam, V., & Jagadeesan, J. (2014). Classification of Normal and Pathological Voice Using SVM and RBFNN. *Journal of Signal and Information Processing*, 2014.

[30] Susan Bukunt, Christine Hunter, Sharon Perkins, Diana Russell, Lee Domanico, El Camino Hospital: Using Health Information Technology to Promote Patient Safety, *The Joint Commission Journal on Quality and Patient Safety*, Volume 31, Issue 10, 2005, Pages 561-565, ISSN 1553-7250

[31] Prediction of Parkinson's disease tremor onset using a radial basis function neural network based on particle swarm optimization, D Wu, K Warwick, Z Ma, MN Gasson, JG Burges - *International journal of neural systems*, 2010

[32] Khan T., Grenholm P. & Nyholm D. *Computer Vision Methods for Parkinsonian Gait Analysis: A Review on Patents*, 2013.