



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

**ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ**

Αυτόματη ανίχνευση ατράκτων του ύπνου με τεχνικές βαθιάς μάθησης

**ΣΑΡΑΚΗΝΟΣ ΣΤΑΥΡΟΣ
Αριθμός Μητρώου: 48016100**

**Επιβλέπων Καθηγητής
Ερρίκος Χάιμ Βεντούρας**

Αθήνα 02/06/2022

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Ερρίκος-Χάιμ Βεντούρας
Καθηγητής

Παντελεήμων Ασβεστάς
Αναπληρωτής Καθηγητής

Νεκτάριος Καλύβας
Αναπληρωτής Καθηγητής

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο υπογράφων Σταύρος Σαρακηνός του Ευαγγέλου-Στέφανου, με αριθμό μητρώου 48016100 φοιτητής του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία

6-7-2022

Ο Δηλών

Σταύρος Σαρακηνός



Ευχαριστίες

Η παρούσα διπλωματική εργασία δεν θα μπορούσε να είχε ολοκληρωθεί χωρίς την πολύτιμη βοήθεια του καθηγητή μου, Δρ. Βεντούρα Ερρίκου. Οφείλω να τον ευχαριστήσω για την ευκαιρία που μου έδωσε, για την υπομονή του και για την στάση του ως καθηγητή όλα αυτά τα χρόνια που ήμουν φοιτητής.

Τέλος θα ήθελα να ευχαριστήσω τους φίλους και την οικογένεια μου, για την στήριξη τους όλα αυτά τα χρόνια..

Περίληψη

Η παρούσα διπλωματική εργασία εκπονήθηκε στα πλαίσια ολοκλήρωσης των προπτυχιακών σπουδών για το τμήμα Βιοϊατρικής Μηχανικής του Πανεπιστημίου Δυτικής Αττικής. Σκοπός της εργασίας ήταν η ανάπτυξη ενός δικτύου Βαθείας Μάθησης, το οποίο θα μπορεί να χαρακτηρίσει μια δοθείσα κυματομορφή ως υπνική άτρακτο ή μη-άτρακτο.

Στο Πρώτο Κεφάλαιο γίνεται λόγος για τον εγκέφαλο ως μέρος του Κεντρικού Νευρικού Συστήματος, καθώς και για το βιοσήμα που παράγει, καταγράφεται και τέλος επεξεργάζεται. Αναφέρεται η διαδικασία του ύπνου και παρουσιάζονται τα στάδιά του, μαζί με τις χαρακτηριστικές κυματομορφές του ηλεκτροεγκεφαλογράφηματος που συναντιούνται σε αυτόν. Αναλύεται ο τρόπος παραγωγής των υπνικών ατράκτων, τα χαρακτηριστικά που τις διαφοροποιούν από άλλες κυματομορφές και ο ρόλος που επιτελούν.

Στο Δεύτερο Κεφάλαιο γίνεται αναφορά στην πληθώρα συστημάτων που έχουν ήδη αναπτυχθεί για την ανίχνευση των ατράκτων. Παρουσιάζεται η εφαρμογή των ποικίλων αλγόριθμων που υπάρχουν για την ανίχνευση των ατράκτων (π.χ. *Matching Pursuit*, *Bayesian Algorithm*) και ειδικοί δείκτες που εξάγονται από τα χαρακτηριστικά των ατράκτων ως κυματομορφή. Τέλος, παρουσιάζονται συστήματα Τεχνητών Νευρωνικών Δικτύων, υποκατηγορία της Βαθείας Μάθησης, που εκπαιδεύονται σε δείγματα ατράκτων και μη, αναπτύσσοντας τη δική τους «κρίση» για την κατηγοριοποίηση μιας κυματομορφής ως άτρακτο ή μη.

Στο Τρίτο Κεφάλαιο αναλύεται διεξοδικά η φύση, αρχιτεκτονική και ο ρόλος ενός Τεχνητού Νευρωνικού Δικτύου. Ιδιαίτερη βαρύτητα δίδεται στην διαδικασία της εκπαίδευσης και του *Backpropagation* αλγόριθμου. Εξετάζεται λεπτομερώς η παραλλαγή των *LSTM* νευρώνων, κύριο πεδίο της εργασίας.

Στο Τέταρτο Κεφάλαιο αναλύεται η επεξεργασία που υφίσταται το ηλεκτροεγκεφαλογράφημα προκειμένου να εξαχθούν οι άτρακτοι και τα αντι-παραδείγματα (μη-άτρακτοι) για την ολοκλήρωση της εκπαίδευσης. Παρουσιάζεται η δομή και αρχιτεκτονική του Τεχνητού Νευρωνικού Δικτύου που αναπτύχθηκε, μαζί με τα αποτελέσματα της εκπαίδευσης.

Το Πέμπτο Κεφάλαιο αποτελεί πεδίο συζήτησης και σχολιασμού των αποτελεσμάτων, ενώ στο Παράρτημα 1 παρουσιάζεται η *Python*, γλώσσα προγραμματισμού και το *Keras*, την πλατφόρμα που αναπτύχθηκε ο αλγόριθμος.

Λέξεις Κλειδιά: *Αλγόριθμος Βαθείας Μάθησης, Τεχνητό Νευρωνικό Δίκτυο, ηλεκτροεγκεφαλογράφημα, υπνικές άτρακτοι, Python, Keras*

Abstract

This Thesis was prepared as part of completing the undergraduate studies at the Department of Biomedical Engineering of the University of West Attica. The purpose of the work was the development of a Deep Learning network, which will be able to characterize a given waveform as sleep spindle or non-spindle. The First Chapter describes the brain as part of the Central Nervous System, as well as the biosignal produced, recorded and finally processed. The process of sleep is mentioned and its stages are presented, along with the characteristic EEG waveforms found in it. The way sleep spindles are produced, the characteristics that differentiate them from other waveforms and the role they play are analyzed.

In the Second Chapter reference is made to the multitude of systems that have already been developed for the detection of spindles. The application of the various algorithms that exist for spindle detection (e.g., Matching Pursuit, Bayesian Algorithm) and special indicators extracted from spindle characteristics as a waveform are presented. Finally, Artificial Neural Network systems, a subclass of Deep Learning, are presented that are trained on spindle and non-spindle samples, developing their own "judgment" to categorize a waveform as spindle or non-spindle.

In Chapter Three, the nature, architecture and role of an Artificial Neural Network is thoroughly analyzed. Special emphasis is given to the training process and the Backpropagation algorithm. The variation of LSTM neurons, the main area of the present work, is examined in detail.

Chapter Four analyzes the processing of the EEG in order to extract the spindles and counter-examples (non-spindles) to complete the training. The structure and architecture of the developed Artificial Neural Network is presented, along with the training results.

The Fifth Chapter is devoted to discussing and commenting on the results, while Appendix 1 presents Python, a programming language, and Keras, the platform on which the algorithm was developed.

Keywords: *Deep Learning Algorithm, Artificial Neural Network, Electroencephalogram, sleep spindles, Python, Keras.*

ΠΕΡΙΕΧΟΜΕΝΑ

Κεφάλαιο 1. Ηλεκτροεγκεφαλογραφία: Παραγωγή σήματος, καταγραφή και κυματομορφές	8
ΕΙΣΑΓΩΓΗ.....	8
1. Ηλεκτροεγκεφαλογραφία: Παραγωγή σήματος, καταγραφή και κυματομορφές.....	8
1.1 Ιστορική αναδρομή.....	8
1.2 Εγκέφαλος και νευρικά κύτταρα	9
1.3 Διέγερση νευρώνα και παραγωγή σήματος	11
1.4 Ηλεκτρόδια και καταγραφή	13
1.5 Κυματομορφές ΗΕΓ	16
1.6 Ύπνος και άτρακτοι	17
Κεφάλαιο 2. Ύπνικες άτρακτοι: Προηγούμενες μέθοδοι αυτόματης ανίχνευσης	20
2.1 Γενικά χαρακτηριστικά συστημάτων.....	20
2.2 Συστήματα αυτόματης ανίχνευσης ατράκτων	22
2.2.1 Ανίχνευση ατράκτων με χρήση αλγόριθμου Matching Pursuit	22
2.2.2 Αλγόριθμος με δέντρο απόφασης	23
2.2.3 Ανίχνευση ατράκτων με αλγόριθμο Bayes	24
2.2.4 Ανάπτυξη ειδικού δείκτη "σίγμα" για ανίχνευση ατράκτων	24
2.2.5 Ανίχνευσης ατράκτων προσομοιώνοντας την οπτική ανίχνευση των ειδικών	25
2.2.6 Ανίχνευση ατράκτων με βάση ένα κανονικοποιημένο μοντέλο	26
2.2.7 Αλγόριθμος ανίχνευσης ατράκτων βασισμένος στα ταλαντώσης του ΗΕΓ	27
2.2.8 Αλγόριθμοι ανίχνευσης ατράκτων με χρήση ΤΝΔ	27
Κεφάλαιο 3. Βαθιά μάθηση και δίκτυα Long-Short Term Memory	30
3.1 Μηχανική Μάθηση και Βαθιά Μάθηση	30
3.2 Τεχνητά Νευρωνικά Δίκτυα.....	31
3.2.1 Κατηγορίες ΤΝΔ	31
3.2.2 Συμπεριφορά νευρώνων και εκπαίδευση Δικτύου	33
3.3 Το πρόβλημα της μάθησης και ο Backpropagation αλγόριθμος	37
3.4 Long-Short Term Memory (LSTM)	42
3.4.1 Ροή πληροφορίας και διαχείριση δεδομένων από ένα LSTM block	42
3.4.2. Backpropagation through time - BPTT	43
3.5 Υπερπαράμετροι ΤΝΔ	45
Κεφάλαιο 4. Ανάλυση αλγόριθμου που αναπτύχθηκε και παρουσίαση αποτελεσμάτων.....	48
4.1 Τα δεδομένα που χρησιμοποιήθηκαν	48
4.2 Εξαγωγή και επεξεργασία – Φιλτράρισμα και εφαρμογή κυλιόμενου παράθυρου	49
4.2.1 Φιλτράρισμα δειγμάτων.....	50
4.2.2 Εφαρμογή κυλιόμενου παράθυρου	52
4.2.3 Δημιουργία dataset.....	52
4.3 Στήσιμο δικτύου - Υπερπαράμετροι και Αρχιτεκτονική	53
4.3.1 Υπερπαράμετροι, εκπαίδευση και παρουσίαση αποτελεσμάτων	54
4.3.2 Εκπαίδευση με διαφορετική αρχιτεκτονική δικτύου	63
Κεφάλαιο 5. Συζήτηση & Συμπεράσματα	66
Αναφορές - Πηγές.....	67
Παράρτημα : Python, TensorFlow & Keras	70

ΚΕΦΑΛΑΙΟ 1

Ηλεκτροεγκεφαλογραφία: Παραγωγή σήματος, καταγραφή και κυματομορφές

Εισαγωγή


Στο παρόν κεφάλαιο γίνεται αναφορά στη βασική δομή του εγκεφάλου. Αναλύεται ο τρόπος παραγωγής του σήματος που ανιχνεύεται στην ηλεκτροεγκεφαλογραφία και ο τρόπος απαγωγής του. Εξετάζεται το ηλεκτροεγκεφαλογράφημα ενός εγκεφάλου σε εγρήγορση αλλά και το ηλεκτροεγκεφαλογράφημα του ύπνου. Γίνεται ανάλυση της φυσιολογίας των υπνικών ατράκτων, κυματομορφές που συναντώνται κατά τη διάρκεια του ύπνου και αποτελούν αντικείμενο της διερεύνησης της παρούσας εργασίας.

1.1 Ιστορική αναδρομή

Η πρώτη καταγεγραμμένη αναφορά του ανθρώπινου εγκεφάλου συναντάται στον χειρουργικό πάπυρο του Edwin Smith (Edwin Smith Surgical Papyrus), που γράφτηκε κατά τον 17^ο αιώνα π.Χ. στην Αρχαία Αίγυπτο [1]. Έκτοτε ο άνθρωπος εγκέφαλος υπήρξε αντικείμενο μελέτης, πειραμάτων και φιλοσοφικών συζητήσεων.

Η Εγκυκλοπαίδεια Φιλοσοφίας του Στάνφορντ (Stanford Encyclopedia of Philosophy) σε άρθρο της που δημοσίευσε το 2003, αναφέρει πως ο Αλκμαίων ο Κροτωνιάτης (γεννημένος το 510 π.Χ.) ήταν ο πρώτος που χαρακτήρισε τον εγκέφαλο ως θεμέλιο λίθο των σκέψεων και των συναισθημάτων, ενώ είχε ανακαλύψει ότι τα όργανα του σώματος συνδέονται με αυτόν. Σπουδαία συνεισφορά στην μελέτη του εγκεφάλου έγινε από τον Hans Berger (1873-1941), Γερμανό ψυχίατρο. Προκειμένου να μελετήσει την φυσιολογία των ψυχικών γεγονότων, επικεντρώθηκε στην έρευνα της ηλεκτρικής δραστηριότητας του εγκεφάλου και το 1929 δημοσιεύει την πρώτη έρευνα στο ηλεκτροεγκεφαλογράφημα (HEΓ) [2]. Στο παραπάνω άρθρο καταγράφηκαν HEΓ ασθενών διαφόρων ηλικιών και φύλων [3].

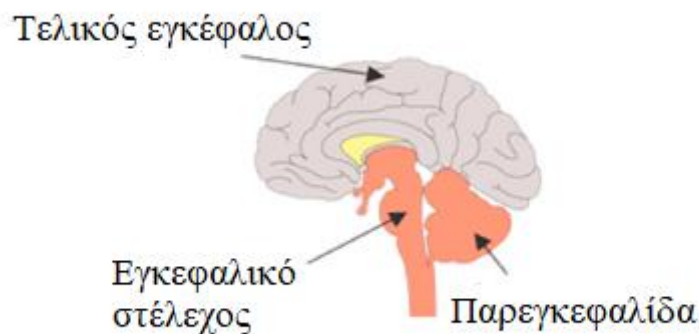
Η εφεύρεση του Hans Berger άνοιξε τον δρόμο για την αναίμακτη μελέτη του ανθρώπινου εγκεφάλου.



Εικόνα 1.1: Ορισμένα από τα ΗΕΓ σήματα που κατέγραψε ο Hans Berger και δημοσίευσε το 1929 [3].

1.2 Εγκέφαλος και νευρικά κύτταρα


Ο ανθρώπινος εγκέφαλος όντας το κεντρικό όργανο του νευρικού συστήματος, είναι υπεύθυνος για τον συντονισμό και τη ρύθμιση των δραστηριοτήτων του οργανισμού. Βρίσκεται εντός του κρανίου της κεφαλής και όπως φαίνεται στην Εικόνα 1.2.1 αποτελείται από τρία κύρια τμήματα. Το πρώτο και μεγαλύτερο εκ των τριών, είναι ο τελικός εγκέφαλος. Χωρίζεται σε δύο ημισφαίρια και η εξωτερική του επιφάνεια ονομάζεται εγκεφαλικός φλοιός. Τα ημισφαίρια με τη σειρά τους χωρίζονται σε τέσσερεις λοβούς, τον μετωπιαίο, τον βρεγματικό, τον κροταφικό και τον ινιακό [4].



Εικόνα 1.2: Τα τρία κύρια τμήματα του εγκεφάλου [1].

Ο μετωπιαίος λοβός είναι υπεύθυνος για τη συμπεριφορά και τα συναισθήματα του ανθρώπου. Συμβάλει στην παραγωγή λόγου, εξαιτίας της περιοχής Broca (Μπροκά), όπου ελέγχει την κίνηση της γλώσσας και του στόματος. Επίσης στον μετωπιαίο λοβό βρίσκονται τα κέντρα ελέγχου της κίνησης του σώματος. Ο βρεγματικός λοβός είναι υπεύθυνος για την κατανόηση της γλώσσας και των λέξεων. Σε αυτόν βρίσκονται τα κέντρα αντίληψης πόνου, αφής και θερμοκρασίας, ενώ ερμηνεύει οπτικά και ηχητικά σήματα. Από τα παραπάνω συμπεραίνουμε ότι ο βρεγματικός λοβός συμβάλει στην

οπτική και χωρική αντίληψη. Η περιοχή Wernicke (Βερνικέ) στον κροταφικό, όπως και στον βρεγματικό λοβό, είναι ο λόγος που και ο κροταφικός λοβός συμβάλει στην κατανόηση της γλώσσας. Επίσης, εκεί συναντώνται τα κέντρα ακοής και μνήμης. Τέλος ο ινιακός λοβός και αυτός με τη σειρά του αναλύει χαρακτηριστικά της όρασης, όπως το χρώμα, την παρουσία ή απουσία φωτός και την κίνηση. Ο εγκέφαλος παίρνει τη χαρακτηριστική μορφή του από τις έλικες και τις αύλακες που παρεμβάλλονται μεταξύ αυτών. Για παράδειγμα η πρόσθια κεντρική έλικα ή αλλιώς κινητικός φλοιός (motor strip), χωρίζεται από την οπίσθια κεντρική έλικα ή αλλιώς σωματοαισθητικός φλοιός (sensory strip), με την κεντρική αύλακα [5].



Εικόνα 1.3: Οι λοβοί του εγκεφάλου. (Όπου frontal lobe: Μετωπιαίος λοβός, parietal lobe: Βρεγματικός λοβός, Temporal lobe: Κροταφικός λοβός, occipital lobe: Ινιακός λοβός, Broca area: Περιοχή Μπρόκας, Wernicke area: Περιοχή Βερνικέ, motor strip: κινητικός φλοιός, sensory strip: σωματοαισθητικός φλοιός) [97].

Δεύτερο τμήμα του εγκεφάλου είναι το εγκεφαλικό στέλεχος, το οποίο αποτελεί σημείο σύνδεσης του εγκεφάλου με την σπονδυλική στήλη. Θεωρείται το αρχαιότερο μέρος του Κεντρικού Νευρικού Συστήματος που αναπτύχθηκε και είναι υπεύθυνο για τη ρύθμιση ζωτικών λειτουργιών όπως η συχνότητα των καρδιακών παλμών, πίεσης του αίματος και του ρυθμού της αναπνοής. Επίσης ρυθμίζει τον ύπνο και την αφύπνιση. Τέλος η παρεγκεφαλίδα, που βρίσκεται στο πίσω μέρος του εγκεφάλου. Κύρια λειτουργία της, ο έλεγχος της κίνησης καθώς εκεί καταλήγουν όλες οι πληροφορίες που προέρχονται από τις αισθητήριες και κινητικές οδούς του εγκεφάλου [2].

Ο νευρικός ιστός συγκροτείται από δύο κατηγορίες κυττάρων, τα νευρικά κύτταρα (ή νευρώνες) και τα νευρογλοιακά κύτταρα (ή νευρογλοία), με τα νευρογλοιακά κύτταρα να υπερτερούν κατά πολύ σε αριθμό έναντι των νευρώνων (Kandel et al., 2000). Τα νευρογλοία έχουν κυρίως υποστηρικτικό ρόλο, προσφέροντας σταθερότητα

και δομική συνοχή στο νευρικό σύστημα, μονώνοντας τους νευρώνες, ρυθμίζοντας τις συγκεντρώσεις ιόντων Καλίου και Νατρίου στο εξωκυττάριο περιβάλλον των νευρώνων και φιλτράροντας ουσίες που φτάνουν στον εγκέφαλο. Τα νευρογλοιακά κύτταρα ωστόσο δεν μεταφέρουν χημικό σήμα [7].

Οι νευρώνες με την σειρά τους είναι υπεύθυνοι για τη μετάδοση και λήψη ηλεκτροχημικών σημάτων σε όλο το σώμα. Η παραπάνω διαδικασία γίνεται εφικτή εξαιτίας των νευρικών συνάψεων, φαινόμενο που παρατηρείται όταν οι νευρώνες πλησιάζουν πολύ ο ένας τον άλλον. Γενικά δεν υπάρχει κυτταροπλασματική συνέχεια μεταξύ των νευρικών κυττάρων και έτσι οι γειτονικές μεμβράνες χωρίζονται από ένα στενό στρώμα εξωκυτταρικού υγρού, το συναπτικό χάσμα [Βεντούρας, 2015].

Η δομή ενός νευρικού κυττάρου και η σύνδεση μεταξύ άλλων νευρώνων, φαίνεται στην παρακάτω εικόνα.




Εικόνα 1.4: Αν και οι νευρώνες ποικίλουν σε σχήμα και σε μέγεθος, όλοι τους αποτελούνται από τέσσερα μέρη: το κυρίως σώμα, τους δένδριτες, τον άξονα και τις απολήξεις του [8].

1.3 Διέγερση νευρώνα και παραγωγή σήματος

Το νευρικό κύτταρο έχει διττή κατάσταση λειτουργίας, είτε σε ηρεμία είτε σε διέγερση. Σε κανονικές συνθήκες βρίσκεται σε κατάσταση ηρεμίας με διαφορά δυναμικού -75 mV , με τον θετικό ακροδέκτη του βολτόμετρου εντός της κυτταρικής μεμβράνης και τον αρνητικό ακροδέκτη στο εξωκυττάριο περιβάλλον, θεωρώντας έτσι ότι η μεμβράνη είναι πολωμένη. Στην κατάσταση αυτή, το κύτταρο «επικοινωνεί» με το περιβάλλον του μέσω ιοντικών διόδων, αντλία νατρίου-καλίου,

αντλία χλωρίου, με τα παραπάνω να βρίσκονται στην κυτταρική μεμβράνη. Προκειμένου να επιτευχθεί η «επικοινωνία» μεταξύ νευρώνων, πρέπει το κύτταρο να παράξει ένα δυναμικό δράσης και άρα ο νευρώνας να σταματήσει να βρίσκεται σε κατάσταση ηρεμίας. Η παραγωγή του δυναμικού δράσης απαιτεί ηλεκτρική ή χημική διέγερση, η οποία αλλάζει την ενδοκυττάρια ροή ιόντων. Όταν το δυναμικό δράσης ξεπεράσει την τιμή κατωφλίου (από -55 mV έως -60 mV), απελευθερώνονται ιόντα από τασοελεγχόμενες διόδους. Η ακαριαία αυτή εκροή ιόντων έχει σαν αποτέλεσμα το ενδοκυττάριο περιβάλλον να αποκτά όλο και μεγαλύτερο θετικό φορτίο, μιας και το πλήθος των τασοελεγχόμενων διόδων που ανοίγουν αυξάνεται. Το δυναμικό της μεμβράνης γίνεται όλο και λιγότερο αρνητικό (εκπόλωση), μέχρι που φτάνει την τελική θετική τιμή των $+10\text{ mV}$ περίπου. Με το πέρας της παραπάνω διαδικασίας το κύτταρο επιστρέφει σε κατάσταση ηρεμίας και η μεμβράνη επαναπολώνεται. Το δυναμικό δράσης «ταξιδεύει» σε μεγάλες αξονικές αποστάσεις χωρίς να ελαττώνεται σε ένταση. Η μορφή του δυναμικού δράσης φαίνεται στο παρακάτω γράφημα. Η παραπάνω διαδικασία συμβάλει στη δημιουργία των μετασυναπτικών δυναμικών. Εάν η μετασυναπτική μεμβράνη αποπολωθεί, τότε το δυναμικό χαρακτηρίζεται ως Μετασυναπτικό Δυναμικό Διέγερσης (ΜΣΔ) (Excitatory Post-Synaptic Potential – EPSP), ενώ εάν η μετασυναπτική μεμβράνη υπερπολωθεί το δυναμικό χαρακτηρίζεται ως Μετασυναπτικό Δυναμικό Αναστολής (ΜΔΑ) (Inhibitory Post-Synaptic Potential – IPSP). Το ΜΣΔ και το ΜΔΑ είναι ο τρόπος με τον οποίο οι νευρώνες «επικοινωνούν» μεταξύ τους [8-10].



Εικόνα 1.5: Το δυναμικό δράσης ενός νευρώνα [8].


Η κύρια πηγή του ΗΕΓ προέρχεται από τον εγκεφαλικό φλοιό και δημιουργεί τρισδιάστατα δυναμικά πεδία, τα οποία καταγράφονται ως δισδιάστατα πεδία συναρτήσει της τάσης και του χρόνου [Olejniczak, 2006]. Εξετάζοντας την περιοχή σύναψης μεταξύ δυο νευρώνων, παρατηρείται ότι κατά τη δημιουργία

μετασυναπτικού δυναμικού, στην εξωκυτταρική περιοχή κοντά στο σώμα του νευρώνα υπάρχει λιγότερο αρνητικό φορτίο, συγκριτικά με την εξωκυτταρική περιοχή της σύναψης. Αποτέλεσμα αυτής της διαφοράς δυναμικού είναι η δημιουργία ενός ασθενούς ηλεκτρικού διπόλου, το οποίο αποτελεί πηγή ιοντικής ροής κατά την οποία, αρνητικά ιόντα από την εξωκυτταρική περιοχή της σύναψης μεταφέρονται στην εξωκυτταρική περιοχή του σώματος και αντίστοιχα, θετικά ιόντα από την εξωκυτταρική περιοχή του σώματος μεταφέρονται στην εξωκυτταρική περιοχή της σύναψης [8, 11]. Δεδομένου ότι η παραπάνω διαδικασία δεν πραγματοποιείται μόνο για ένα ζεύγος νευρώνων, αλλά για μια ομάδα νευρώνων το αποτέλεσμα της διέγερσης θα είναι η παραγωγή ενός ισχυρού ηλεκτρικού διπόλου. Το δίπολο αυτό θα είναι το άθροισμα των επιμέρους διπόλων και η έντασή του εξαρτάται από το πλήθος των νευρών των οποίων τα δίπολα αθροίζονται (Kandel et al., 2000).

1.4 Ηλεκτρόδια και καταγραφή

Το ΗΕΓ μπορεί να καταγραφεί χάρη στην αγωγή ρεύματος που συμβαίνει στους ιστούς του εγκεφάλου, του κρανίου και του δέρματος, κατά την οποία το ρεύμα ρέει μέσω των ιστών, από την πηγή παραγωγής (νευρώνες) στο ηλεκτρόδιο καταγραφής [12].


Ο πιο διαδεδομένος τρόπος τοποθέτησης των ηλεκτροδίων του ΗΕΓ είναι το Διεθνές Σύστημα 10-20 (Sleep, 2006), ενώ προτιμάται και σύμφωνα με την επιτροπή μεθόδων για κλινική εξέταση του ΗΕΓ (1957).



Εικόνα 1.6: (α) Προβολή τοποθέτησης ηλεκτροδίων σε Οριζόντιο επίπεδο, (β) Προβολή τοποθέτησης ηλεκτροδίων σε Στεφανιαίο επίπεδο, (γ) Προβολή τοποθέτησης ηλεκτροδίων σε Οβελιαίο επίπεδο [13].

Όπου Fp (Frontal pole -), F (Frontal -), C (Central -), P (Parietal -), O (Occipital -), Nasion (Ριζορρίνιο, σημείο ένωσης των δύο ρινικών οστών με το μετωπιαίο οστό) και Inion (Ινιακό οστό).

Όπως φαίνεται στην Εικόνα 1.4.1, η απόσταση από το Ριζορρίνιο, το αφτί και το Ινιακό οστό, μέχρι το πρώτο (κοντινότερο) ηλεκτρόδιο είναι το 10% της συνολικής απόστασης. Το 20% της συνολικής απόστασης χαρακτηρίζεται ως η απόσταση μεταξύ δύο ηλεκτροδίων, εξ ου και το όνομα του συστήματος, 10-20. Κατά αυτόν τον τρόπο η θέση των ηλεκτροδίων καθορίζεται από σταθερά σημεία αναφοράς στο κρανίο και όχι αυθαίρετα, βασική προϋπόθεση για την σωστή καταγραφή του ΗΕΓ, σύμφωνα με την επιτροπή κλινικών μεθόδων για την κλινική εξέταση της ηλεκτροεγκεφαλογραφίας [13].



Εικόνα 1.7: Άλλη μια προβολή των ηλεκτροδίων του Διεθνούς Συστήματος 10-20. Το κάθε ηλεκτρόδιο έχει χαρακτηριστικό όνομα, που υποδεικνύει την θέση του. Υπάρχει επίσης και συγκεκριμένο σύστημα αρίθμησης των ηλεκτροδίων, με τους μονούς αριθμούς να αντιστοιχούν στο αριστερό ημισφαίριο και τους ζυγούς αριθμούς στο δεξί [14].


Τα ηλεκτρόδια λειτουργούν ως η βασική διεπαφή μεταξύ των ηλεκτρικών φαινομένων του σώματος και των ηλεκτρονικών διατάξεων απαγωγής και επεξεργασίας των δυναμικών που προκύπτουν από αυτά τα φαινόμενα [Βεντούρας, Ε. Χ., 2006]. Ο τύπος των ηλεκτροδίων που χρησιμοποιούνται είναι στην πλειονότητα δερματικής επιφάνειας για λόγους ευκολίας, κάνοντας έτσι την όλη διαδικασία αναίμακτη. Αποτελούνται από Άργυρο/Χλωριούχο άργυρο (Ag-AgCl), και έχουν κυκλικό σχήμα με διάμετρο από 1 έως 3 mm. Η εφαρμογή τους συνοδεύεται με χρήση ειδικού αγωγίμου gel, το οποίο ιδανικά θα δημιουργήσει μια αγωγή για το δυναμικό παρά τον αλληπάλληλο αριθμό κακών αγωγών όπως το κρανίο, νεκρά κύτταρα δέρματος, τρίχες και αέρας. Το σήμα που λαμβάνεται στην συνέχεια οδηγείται σε ενισχυτή όπου και φιλτράρεται, αναλογο-ψηφιακό μετατροπέα (A/D converter) και τέλος καταγράφεται [1,8,11].

1.5 Κυματομορφές ΗΕΓ

Το πλάτος ενός φυσιολογικού ΗΕΓ σε εγρήγορση, μετρημένο με ηλεκτρόδια στο κεφάλι κυμαίνεται στο εύρος 10-100 μV [Blinowska, Durka, 2006]. Η μορφολογία των εγκεφαλικών κυμάτων είναι άρρηκτα συνδεδεμένη με την εκάστοτε εγκεφαλική δραστηριότητα. Τα κύματα στο ΗΕΓ μεταβάλλονται σημαντικά μεταξύ ξύπνιου και ύπνου, ενώ τις περισσότερες φορές είναι ακανόνιστα και δύσκολα παρατηρείται μια γενική μορφή. Η μορφολογία ενός φυσιολογικού ΗΕΓ μπορεί να κατηγοριοποιηθεί σε τέσσερις ρυθμούς ημιτονοειδούς δραστηριότητας: (i) ρυθμός Άλφα, (ii) ρυθμός Βήτα, (iii) ρυθμός Θήτα και (iv) ρυθμός Δέλτα [16].

Ο ρυθμός Άλφα εμφανίζεται στις συχνότητες 8-13 Hz και οι κυματομορφές σε Άλφα ρυθμό προέρχονται κυρίως από τις οπίσθιες περιοχές του εγκεφάλου. Ο ρυθμός Άλφα «εξαφανίζεται» όταν ο εξεταζόμενος ανοίγει τα μάτια ή/και όταν επικεντρώνεται σε συγκεκριμένη διανοητική λειτουργία [17]. Ο ρυθμός Βήτα χαρακτηρίζεται από συχνότητες στο εύρος 14-30 Hz. Καταγράφεται κυρίως στις βρεγματικές και μετωπιαίες περιοχές του κρανίου και χωρίζεται σε δύο τύπους: Βήτα I και Βήτα II. Τα κύματα Βήτα I έχουν σχεδόν διπλάσια συχνότητα από εκείνα των Άλφα και επηρεάζονται από την νοητική δραστηριότητα, αντίστροφα από τα Άλφα, ενώ τα Βήτα II εμφανίζονται κατά τη διάρκεια ιδιαίτερα έντονης νοητικής δραστηριότητας [16,17]. Τα κύματα Θήτα ανήκουν στο εύρος συχνοτήτων 4-7 Hz και εμφανίζονται στην βρεγματική και κροταφιαία περιοχή. Είναι συνήθως ένδειξη παθολογικής κατάστασης, ή εκκίνηση ύπνου, αλλά μπορεί να εμφανιστεί και σε φυσιολογικό ΗΕΓ υπό περιπτώσεις νοητικής πίεσης. Τέλος τα κύματα Δέλτα, έχουν εύρος συχνοτήτων μικρότερο των 4 Hz και προέρχονται από τον φλοιό του εγκεφάλου. Εμφανίζονται μόνο στον ύπνο και οποιαδήποτε παρουσία τους σε ΗΕΓ εγρήγορσης συνδέεται με παθολογική κατάσταση [16,17].

Στην παρακάτω εικόνα παρουσιάζονται οι κυματομορφές.



Εικόνα 1.8: Καταγραφές ΗΕΓ όπου επικρατούν συγκεκριμένοι ρυθμοί. Με σειρά εμφάνισης: Beta (Βήτα 14-30 Hz), Alfa (Άλφα 8-13 Hz), Theta (Θήτα, 4-7 Hz) και Delta (Δέλτα, 4 Hz <) [1].

1.6 Ύπνος και άτρακτοι

Ο ύπνος ακολουθεί κερκάρδιο κύκλο περίπου μιας ημέρας και η περιοδικότητά του έγκειται σε γενετικούς και περιβαλλοντολογικούς παράγοντες όπως η ώρα, ύπαρξη ή απουσία φωτός, ωράριο εργασίας και ωράριο γευμάτων [18].


Ανέκαθεν θεωρούταν απαραίτητος για την υγιή και φυσιολογική λειτουργία του ανθρώπινου οργανισμού και το 1951 ολοκληρώθηκε η πρώτη συνεχόμενη ολονύχτια καταγραφή της κίνησης των οφθαλμών ανθρώπου κατά τη διάρκεια του ύπνου, με την χρήση ΗΕΓ και ηλεκτροοφθαλμογραφήματος (ΗΟΓ) [Aserinsky, 1996]. Λίγα χρόνια αργότερα, το 1953, δημοσιεύεται η διδακτορική διατριβή του Dr. Aserinsky του Πανεπιστημίου του Σικάγο, τμήμα Φυσιολογίας [19] και μαζί με τον Dr. Kleitman την ίδια χρονιά θα παρατηρήσουν μετά από εργαστηριακή έρευνα και πειράματα ότι η σύνδεση μεταξύ οφθαλμικών κινήσεων, χαρακτηριστικές επαναλαμβανόμενες κυματομορφές στο ΗΕΓ και δραστηριότητα του Αυτόνομου Νευρικού Συστήματος (ΑΝΣ), είναι συνδεδεμένες μεταξύ τους και δεν εμφανίζονται τυχαία. Λαμβάνοντας υπόψη αυτά τα φαινόμενα φυσιολογίας και ενδεχομένως την παρουσία ονείρων, κατέληξαν στο συμπέρασμα ότι όλα τα παραπάνω είναι δημιουργήματα ενός συγκεκριμένου επιπέδου του εγκεφαλικού φλοιού που η δραστηριότητά του συναντάται κατά τη διάρκεια του ύπνου [20], αναθεωρώντας την μέχρι τότε αντίληψη ότι ο ύπνος ήταν μια παθητική διαδικασία.

Η ανακάλυψη της οφθαλμικής κίνησης κατά τη διάρκεια του ύπνου, χώρισε τον ύπνο σε δύο χαρακτηριστικά στάδια:

(α) Ύπνος γρήγορων κινήσεων των ματιών ή αλλιώς ύπνος REM (Rapid Eye Movement), ο λεγόμενος «παράδοξος» ύπνος και

(β) Ύπνος χωρίς γρήγορες κινήσεις των ματιών ή αλλιώς ύπνος NREM (Non Rapid Eye Movement), ήρεμος ύπνος.

Η εμφάνιση των σταδίων είναι περιοδική και γίνεται 4 με 6 φορές κατά τη διάρκεια του ύπνου, με μέσο χρόνο 90 λεπτά για το κάθε στάδιο. Ο ύπνος χωρίζεται σε 5 φάσεις: Εγρήγορηση, N1, N2, N3 και REM, όπου N1, N2 και N3 είναι φάσεις του NREM σταδίου και με το πέρας της κάθε φάσης το υποκείμενο «μπαίνει» όλο και σε πιο βαθύ ύπνο. Η πλειονότητα του ύπνου γίνεται στη φάση N2 [21,22].



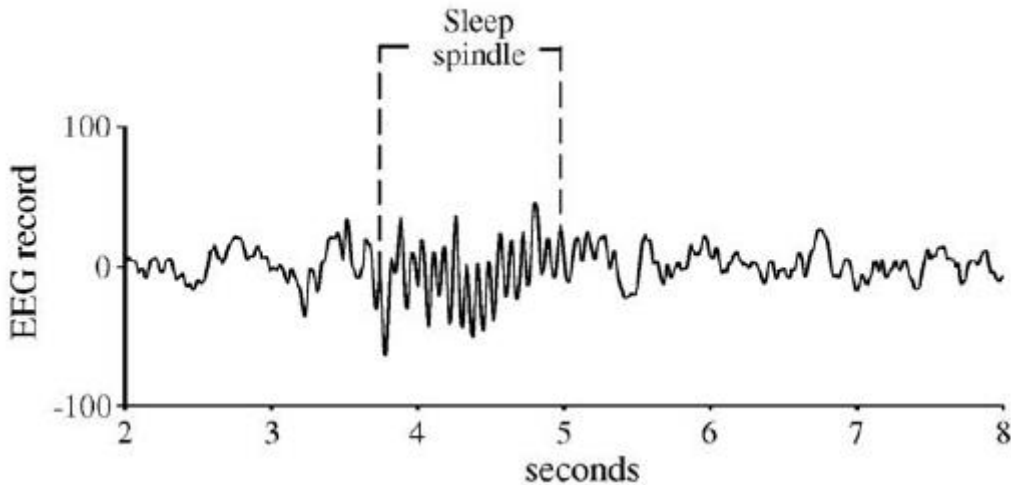
Εικόνα 1.9: Στην εικόνα αυτή φαίνεται καθαρά ο κύκλος του ύπνου. Παρουσιάζονται επίσης και οι κυματομορφές του ΗΕΓ που κυριαρχούν στο εκάστοτε στάδιο. Σημαντικό είναι το γεγονός ότι το στάδιο N1 και το στάδιο REM παρουσιάζουν ομοιότητα στο ΗΕΓ. Οι υπνικές άτρακτοι, που θα μας απασχολήσουν στη συνέχεια, εμφανίζονται κυρίως στο N2 και προηγούνται του συμπλέγματος-K (K-complex) [23].

Πλέον η μελέτη του ύπνου γίνεται με την πολυυπνογραφία (polysomnography – PSG), όπου λαμβάνεται μια μεγάλη ποικιλία βιομετρήσεων από τον εξεταζόμενο κατά τη διάρκεια του ύπνου όπως, ΗΕΓ, ΗΟΓ, ηλεκτροκαρδιογράφημα (ΗΚΓ), ηλεκτρομυογράφημα (ΗΜΓ), κίνηση των άκρων, αναπνευστικά δεδομένα, κορεσμός οξυγόνου, επίπεδα διοξειδίου του άνθρακα, θέση σώματος και παρατήρηση συμπεριφοράς εξεταζόμενου. Σύμφωνα με τον Αμερικανικό Όμιλο Τεχνολόγων Ύπνου (American Association of Sleep Technologists – AAST), η καταγραφή θα πρέπει να γίνει όσο το δυνατόν πιο κοντά στις ώρες που κοιμάται ο εξεταζόμενος συνήθως, ενώ το δωμάτιο όπου θα πραγματοποιηθούν οι μετρήσεις θα πρέπει να είναι ασφαλές, ήσυχο, σκοτεινό και άνετο. Τα ηλεκτρόδια του ΗΕΓ τοποθετούνται σύμφωνα με το Διεθνές Σύστημα 10-20 που προαναφέρθηκε [24].

Οι υπνικές άτρακτοι ή απλά άτρακτοι είναι από τις πιο χαρακτηριστικές κυματομορφές του ΗΕΓ και συναντώνται σε όλο τον NREM ύπνο, με τις περισσότερες στο στάδιο 2 [23,25].

Η άτρακτος ορίζεται ως ένα πλήθος ρυθμικών κυμάτων μεταβαλλόμενου πλάτους το οποίο αυξάνεται στα πρώτα στάδια της εκδήλωσης, ενώ μειώνεται προς το τέλος. Ονομάζονται άτρακτοι διότι η μορφολογία τους μοιάζει με το αδράχτι του αργαλειού. Η άτρακτος είναι σύντομη χρονικά με διάρκεια από 0,5 έως και 3 δευτερόλεπτα (Astori et al., 2013). Συνήθως κυμαίνεται στο εύρος συχνοτήτων των 12-14 Hz ενώ σε ορισμένες περιπτώσεις ξεπερνάει τα όρια φτάνοντας τα 16 Hz, ενώ είναι πιθανό να πέσει και στα 11 Hz. Η Αμερικάνικη Ακαδημία Ιατρικής Ύπνου (American Academy of Sleep Medicine – AASM) έχει λάβει τα ανάλογα μέτρα για την αναγνώριση των ατράκτων στο εύρος 11-16 Hz [26].

Το πλάτος ποικίλει αλλά συνήθως είναι κάτω από 50 μV σε έναν ενήλικα [27].



Εικόνα 1.10: Εδώ διακρίνεται μια καλά ορισμένη άτρακτος [27].

Όσον αφορά τους ηλεκτροφυσιολογικούς μηχανισμούς τους, οι άτρακτοι εξαρτώνται από τις μεταβολές των δυναμικών της μεμβράνης των θαλαμοφλοιϊκών νευρώνων που ταλαντεύονται στο εύρος συχνοτήτων των ατράκτων, σε μία ενδιάμεση κατάσταση υπερπόλωσης [25].

Οι νευρώνες που συμμετέχουν στην παραγωγή ατράκτων βρίσκονται στον δικτυωτό σχηματισμό του θαλάμου του εγκεφάλου και είναι GABAεργικοί νευρώνες. Παράγουν δηλαδή το γάμμα-αμινοβουτυρικό οξύ (ή GABA), κύριος ανασταλτικός νευροδιαβιβαστής [28]. Σπανιότερα θα συναντήσουμε ατράκτους που προέρχονται από την περιοχή του ιππόκαμπου [29].

Ο ρόλος των ατράκτων δεν έχει γίνει ακόμα πλήρως κατανοητός, ωστόσο πιστεύεται ότι σχετίζονται με τη παγίωση της μνήμης, την ανάπτυξη του εγκεφαλικού φλοιού και τη διατήρηση της «αποσύνδεσης» από το περιβάλλον μέσω «θαλαμικών πυλών» κατά τη διάρκεια του ύπνου [29-31]. Επιπρόσθετα οι άτακτοι, όταν δεν εμφανίζονται συχνά, μπορεί να αποτελούν ένδειξη ψυχιατρικής ασθένειας, όπως η σχιζοφρένεια [32, 33].

ΚΕΦΑΛΑΙΟ 2

Υπνικές άτρακτοι: Προηγούμενες μέθοδοι αυτόματης ανίχνευσης

Εισαγωγή

Στο παρόν κεφάλαιο γίνεται μια αναφορά στα ήδη υπάρχοντα συστήματα ανίχνευσης υπνικών ατράκτων. Η ανίχνευση πραγματοποιείται με διάφορους αλγόριθμους επεξεργασίας και εξαγωγής μορφολογικών χαρακτηριστικών (πλάτους και συχνότητας) του ΗΕΓ. Σε ορισμένες περιπτώσεις οι αλγόριθμοι συνδυάζονται με την ανάπτυξη Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ), των οποίων η λειτουργία αναλύεται στο επόμενο κεφάλαιο.

2.1 Γενικά χαρακτηριστικά συστημάτων

Η οπτική ανίχνευση ατράκτων αποτελεί μια χρονοβόρα και κουραστική διαδικασία. Οι ειδικοί έχοντας να ανιχνεύσουν ακόμα και χίλιες ατράκτους σε ένα ΗΕΓ ύπνου, είναι πιθανό να υποπέσουν σε σφάλματα με αποτέλεσμα μια ανακριβή απόφαση. Πέραν της λανθασμένης διάγνωσης, σημαντικό πρόβλημα είναι και η υποκειμενικότητα του κάθε ειδικού, με αποτέλεσμα ορισμένες κυματομορφές να χαρακτηριστούν ως άτρακτοι από κάποιους, ενώ από άλλους όχι. Για την επίλυση των παραπάνω, θεωρήθηκε επιτακτική ανάγκη η δημιουργία συστημάτων που θα ανιχνεύουν τις ατράκτους με μεγαλύτερη «αντικειμενικότητα», ακρίβεια και ταχύτητα [34, 35].

Σημαντικό ρόλο στον έλεγχο της αξιοπιστίας τέτοιων συστημάτων, έχει ο Πίνακας Σύγχυσης - ΠΣ (Confusion Matrix – CM).

	PREDICTED POSITIVE	PREDICTED NEGATIVE
TRUE POSITIVE	TP	FN
TRUE NEGATIVE	FP	TN

Πίνακας 2.1: Παράδειγμα ενός Πίνακα Σύγχυσης για προβλήματα δυαδικής κατηγοριοποίησης. Όπου TP (True Positive) είναι Αληθώς Θετικό, TN (True Negative) είναι Αληθώς Αρνητικό, FN (False Negative) είναι Ψευδώς Αρνητικό και FP (False Positive) είναι Ψευδώς Θετικό [36].

Έχοντας λοιπόν ένα σύστημα ανίχνευσης ατράκτων, όπου θεωρούμε οποιαδήποτε άλλη κυματομορφή πέραν των ατράκτων ως μη-άτρακτο, εννοούμε με τους όρους:

- True Positive, οι άτρακτοι οι οποίες ορθά ανιχνεύθηκαν ως άτρακτοι
- True Negative, οι μη-άτρακτοι οι οποίες ορθά ανιχνεύθηκαν ως μη-άτρακτοι
- False Negative, οι άτρακτοι οι οποίες λανθασμένα ανιχνεύθηκαν ως μη-άτρακτοι
- False Positive, οι μη-άτρακτοι οι οποίες λανθασμένα ανιχνεύθηκαν ως άτρακτοι

Από τον ΠΣ, προκύπτει ένα σύνολο παραμέτρων, όπως [36, 37]:

$$\text{ευαισθησία (sensitivity)} = \text{TP rate} = \frac{TP}{TP+FN} \quad (1)$$

$$\text{ειδικότητα (specificity)} = \frac{TN}{FP+TN} \quad (2)$$

$$\text{FP rate} = 1 - \text{specificity} = \frac{FP}{FP+TN} \quad (3)$$

$$\text{FP proportion} = \frac{FP}{TP+FN} \quad (4)$$

$$\text{FP amount} = \frac{FP}{TP+FP} \quad (5)$$

$$\text{(συνολική) ακρίβεια (accuracy)} = \frac{TP+TN}{TP+FP+TN+FN} \quad (6)$$

$$\text{(συνολικό) σφάλμα (error)} = \frac{FP+FN}{TP+FP+TN+FN} \quad (7)$$

$$\text{Θετική προγνωστική τιμή (Positive Predictive Value -PPV)} = \frac{TP}{TP+FP} \quad (8)$$

$$F_1 \text{ score} = 2 \frac{(\text{Sensitivity} * \text{Precision})}{(\text{Sensitivity} + \text{Precision})} \quad (9)$$

Εμπόδια στην αξιολόγηση συστημάτων ανίχνευσης προβάλλουν οι διαφορετικές βάσεις δεδομένων που χρησιμοποιούνται και η διαφορά στα στάνταρ των ειδικών για την ανίχνευση. Για τους παραπάνω λόγους, αυτές οι παράμετροι έχουν ιδιαίτερη σημασία στην αξιολόγηση των ανιχνευτών. Γενικά, το ιδανικό σύστημα ανίχνευσης θα πρέπει να έχει όσο το δυνατόν μικρότερες τις τιμές των FN και FP [38, 39].

2.2 Συστήματα αυτόματης ανίχνευσης ατράκτων

Οι Schimicek *et al.* (1994), ανέπτυξαν έναν από τους πρώτους ανιχνευτές υπνικών ατράκτων, χρησιμοποιώντας ένα ζωνοπερατό φίλτρο (Band Pass Filter – BPF) και κατωφλίωση πλάτους του ΗΕΓ σήματος [39]. Έκτοτε πολλά συστήματα χρησιμοποιούν τον μετασχηματισμό Fourier και BPF για την ανίχνευση ατράκτων (Huupponen *et al.*, 2007; Dunman *et al.*, 2009; Bodizs *et al.*, 2009; Nonclercq *et al.*, 2013). Οι Causa *et al.* (2010), ανέπτυξαν ανιχνευτή που υπολόγιζε τη στιγμιαία συχνότητα και πλάτος με τη χρήση Hilbert-Huang transform (HHT) [34, 39]. Σε ορισμένα συστήματα η ανίχνευση και κατηγοριοποίηση ατράκτων γίνεται με χρήση ΤΝΔ [25, 46-48].

2.2.1 Ανίχνευση ατράκτων με χρήση αλγόριθμου Matching Pursuit

Ο αλγόριθμος Matching Pursuit (MP) χρησιμοποιείται για τον υπολογισμό αναπαραστάσεων προσαρμοστικού σήματος (Mallat and Zhang, 1993). Αποτέλεσμα της εφαρμογής του αλγόριθμου είναι η αποσύνθεση του αρχικού σήματος σε ένα σύνολο κυματομορφών, επιλεγμένες από μια πληθώρα συναρτήσεων. Ένα σύνολο Gabor συναρτήσεων, μαζί με Fourier και την κρουστική συνάρτηση πραγματοποιούν τον παραπάνω μετασχηματισμό, από το πεδίο του χρόνου στο πεδίο των συχνοτήτων. Με την εφαρμογή του αλγόριθμου MP, το σήμα πλέον μπορεί να αναπαρασταθεί σε επίπεδο χρόνου-συχνότητας συναρτήσει της τάσης [40, 41].

Ο αλγόριθμος MP χρησιμοποιήθηκε σε συνδυασμό με έναν ανιχνευτή κατωφλίου (Amplitude Threshold – AT) για την ανίχνευση υπνικών ατράκτων από τους Schönwald, *et al.*, (2006). Το σήμα φιλτράρεται σταδιακά από ποικίλα φίλτρα. Αρχικά από ένα NOTCH 60 Hz, στη συνέχεια από κατωπερατό φίλτρο (Low Pass Filter – LPF) με συχνότητα αποκοπής 70 Hz, μετά από 0,5 Hz υψιπερατό (High Pass Filter – HPF) και τέλος από LPF 32 Hz. Οι κυματομορφές που προέκυπταν από την «διάσπαση» του αρχικού σήματος, μετά την εφαρμογή του MP, θα έπρεπε να έχουν κεντρική συχνότητα στο εύρος (11 – 15) Hz και τιμή τάσης μεγαλύτερη από τη δοθείσα τιμή του AT για να χαρακτηριστούν ως άτρακτοι. Παράλληλα δόθηκαν τα καταγεγραμμένα ΗΕΓ σε δύο ειδικούς για οπτική ανίχνευση των ατράκτων με κριτήριο ύπαρξης, την κύρια συχνότητα στα (12 – 14) Hz και χρονική διάρκεια τουλάχιστον 0,5 δευτερόλεπτα. Ύστερα από δοκιμές επιλέχθηκε η τιμή του AT ίση με 58,8 για το στάδιο 2 του NREM ύπνου και 46,6 για όλα τα υπόλοιπα στάδια του ύπνου μαζί. Οι τιμές της ευαισθησίας και της ειδικότητας για τον MP ήταν 80,6% και 81,2% για τις δυο τιμές AT αντίστοιχα [40].

Με παρόμοιο τρόπο χρησιμοποιήσαν τον αλγόριθμο MP και οι LaRocco, J., *et al.*, (2018). Ο ανιχνευτής που αναπτύχθηκε αρχικά αποδομούσε το σήμα και το αναπαριστούσε σε ένα πλέγμα παραμέτρων. Στη συνέχεια αξιολογούσε τις παραμέτρους βάσει των θεωρητικών τιμών για τις ατράκτους και επέλεγε τις καλύτερες εξ αυτών με κριτήριο την «θέση» στο Gabor γράφημα. Τα χαρακτηριστικά των ατράκτων βασίζονταν σχεδόν αποκλειστικά στο πλήθος των Gabor συναρτήσεων ανά δευτερόλεπτο που χρησιμοποιούνταν για την αναπαράσταση του σήματος και ενός κατωφλίου T_b , όπως και προηγουμένως [42].

2.2.2 Αλγόριθμος με δέντρο απόφασης

Οι Dunman *et al.*, (2009) ανέπτυξαν σύστημα ανίχνευσης που βασίζεται σε δέντρο απόφασης. Αρχικά το ΗΕΓ φιλτράρεται από ζωνοπερατό φίλτρο στο εύρος (0,5-35) Hz. Το ΗΕΓ στον υφίσταται 3 στάδια επεξεργασίας.

Αρχικά εφαρμόζεται ο Short Time Fourier Transform (STFT), αναλύοντας το σήμα στις συχνότητες που αποτελείται. Η τεχνική αυτή αναγνωρίζει ως άτρακτο το μέρος του σήματος για το οποίο το κανονικοποιημένο πλάτος ισούται με 1 και η συχνότητα είναι κοντά στα 12 Hz. Θα πρέπει επίσης το κανονικοποιημένο πλάτος στις γειτονικές συχνότητες να είναι μικρότερο από 1. Εν συνεχεία το σήμα αποδιαμορφώνεται με τον μετασχηματισμό κυματιδίων (wavelet transform) και δημιουργούνται τέσσερις ομάδες με κριτήριο την συχνότητα, 0-8 Hz, 8-16 Hz, 16-32 Hz και 32-64 Hz. Η ομάδα όπου ελέγχεται για ύπαρξη ατράκτων είναι εκείνη με εύρος συχνοτήτων 8-16 Hz. Το σήμα από αυτή την ομάδα υφίσταται περαιτέρω επεξεργασία. Εφαρμόζεται Teager Energy Operator (TEO), ενεργειακός τελεστής κατά τον οποίο, «οξύνονται» οι απότομες εναλλαγές πλάτους και «αμβλύνονται» οι πιο ήπιες μόλις εφαρμοστεί σε ένα σήμα. Για να ανιχνευθεί μια άτρακτος από τον TEO, το πλάτος της ατράκτου θα πρέπει να είναι μεγαλύτερο από το 60% του μέσου πλάτους του σήματος και να διαρκεί για τουλάχιστον 0,5 δευτερόλεπτα. Εφαρμόζεται επίσης και ο αλγόριθμος Multiple Signal Classification (MUSIC) κατά τον οποίο δημιουργείται ένα ψευδοφάσμα που περιέχει αιχμηρές κορυφές όταν οι συχνότητες του σήματος συσχετίζονται με συχνότητες ημιτονοειδών συναρτήσεων που παρομοιάζουν τις ατράκτους.

Για να χαρακτηριστεί τμήμα του ΗΕΓ ως άτρακτος από το παραπάνω σύστημα θα πρέπει να έχει αναγνωριστεί ως τέτοια και από τις τρεις μεθόδους που αναλύθηκαν, TEO, MUSIC και STFT. Το παραπάνω σύστημα παρουσιάζει συνολική ευαισθησία (sensitivity) 96,17% και ειδικότητα (specificity) 95,54% για τις 14019 ατράκτους που δοκιμάστηκαν [37].

2.2.3 Ανίχνευση ατράκτων με αλγόριθμο Bayes

Η ανάπτυξη αλγόριθμου Bayes (Bayesian algorithm) δίνει τη δυνατότητα στο σύστημα να ανιχνεύει τις ατράκτους στο ΗΕΓ βάσει πιθανοτήτων. Το σύστημα που ανέπτυξαν οι Babadi *et al.*, (2012) βασίζεται στη διαφορά των συναρτήσεων

πυκνότητας πιθανότητας μεταξύ των κυματομορφών που χαρακτηρίζονται ως άτρακτοι και εκείνων που χαρακτηρίζονται ως οποιαδήποτε άλλη κυματομορφή.

Με την υπόθεση ότι οι παράμετροι που χαρακτηρίζουν μια άτρακτο μπορούν να εξαχθούν με την ανάλυση πολλών εξ αυτών, δημιουργήθηκε μια βάση δεδομένων από ατράκτους οπτικά ανιχνευμένες από ειδικούς. Εφαρμόζοντας τον μετασχηματισμό Karhunen-Loeve (KL), υπολογίζονται τα ιδιοδιανύσματα των ατράκτων και στη συνέχεια το φάσμα τους, το οποίο φανερώνει την κατανομή της ενέργειας της ατράκτου από τα δεδομένα που προκύπτουν από τις ιδιοσυναρτήσεις. Στη συνέχεια δυο βάσεις δεδομένων δημιουργήθηκαν, με την πρώτη να περιέχει αποκλειστικά κυματομορφές ατράκτων και την δεύτερη να περιέχει οποιοσδήποτε κυματομορφές εκτός ατράκτων. Οι βάσεις δεδομένων περιείχαν σήματα ΗΕΓ διάρκειας 0,5 δευτερολέπτων. Για την ανίχνευση, οι παραπάνω κυματομορφές προβλήθηκαν στις ιδιοσυναρτήσεις των ατράκτων που υπολογίστηκαν αρχικά, με αποτέλεσμα την παραγωγή ενός εύρους συντελεστών από το κάθε σύνολο. Οι συντελεστές αυτοί χρησιμοποιήθηκαν για τον υπολογισμό των πιθανοτήτων πυκνότητας. Η παραπάνω διαδικασία αποτελεί τον αλγόριθμο Bayes, ο οποίος επιστρέφει την πιθανότητα ύπαρξης ατράκτου. Εάν αυτή η πιθανότητα είναι μεγαλύτερη από μια συγκεκριμένη τιμή P_{TH} και η κυματομορφή διαρκεί για τουλάχιστον 0,5 δευτερόλεπτα, τότε χαρακτηρίζεται ως άτρακτος. Ο παραπάνω αλγόριθμος παρουσιάζει ευαισθησία 96,0 % και ειδικότητα 97,2 % [43].

2.2.4 Ανάπτυξη ειδικού δείκτη «σίγμα» για ανίχνευση ατράκτων

Οι Huupponen *et al.*[44] συνέκριναν τέσσερις διαφορετικές μεθόδους για την ανίχνευση διμερών ατράκτων. Με τον όρο διμερής άτρακτος εννοείται η ανίχνευση ατράκτων στα κεντρικά κανάλια ΗΕΓ των δύο ημισφαιρίων (C3, C4), ταυτόχρονα.

Η πρώτη μέθοδος χρησιμοποιούσε έναν δείκτη «σίγμα» σε συνδυασμό με το φάσμα του FFT και την ανάλυση του πλάτους των ατράκτων, μετά από φίλτρο Filter Impulse Response (FIR). Η δεύτερη μέθοδος χρησιμοποιούσε μόνο τον δείκτη «σίγμα». Η τρίτη ήταν βασισμένη σε ανιχνευτές ασαφούς λογικής, ενώ η τέταρτη έκανε χρήση σταθερού κατωφλίου ανίχνευσης ατράκτων.

Ο έλεγχος των παραπάνω μεθόδων έγινε σε ολονύχτιες καταγραφές, που σύμφωνα με ειδικούς περιείχαν 6043 διμερείς ατράκτους. Τα καλύτερα αποτελέσματα για την εκάστοτε μέθοδο συναντιούνται στο 2-NREM στάδιο. Για την πρώτη μέθοδο, η οποία είχε και τα καλύτερα αποτελέσματα, έδειξε TPrate 70%, ειδικότητα 98,6% και FPrate 32%. Τα χειρότερα αποτελέσματα προέκυψαν από την τέταρτη μέθοδο, με TPrate 70%, ειδικότητα 67,7% και FPrate 46%.

2.2.5 Ανίχνευση ατράκτων προσομοιώνοντας την οπτική ανίχνευση ειδικών

Η μέθοδος που ανέπτυξαν οι Causa *et al.*, (2010) βασίζεται σε μη γραμμικούς αλγόριθμους, στην τεχνική empirical-mode decomposition (EMD), στον μετασχηματισμό Hilbert-Huang Transform (HHT) και σε ασαφή λογική. Ο συγκεκριμένος τρόπος ανίχνευσης προσφέρει βελτιωμένη διακριτική ικανότητα στο πεδίο του χρόνου και στο πεδίο των συχνοτήτων (με τους EMD και HHT αντίστοιχα), ενώ μέσω της ασαφούς λογικής μπορεί να μιμηθεί τον τρόπο ανίχνευσης ατράκτων των ειδικών (Causa *et al.*, 2010). Με τον αλγόριθμο EMD, επιτυγχάνεται η αποσύνθεση του σήματος, δημιουργώντας τις «συναρτήσεις ενδογενών συνιστωσών (intrinsic-mode functions – IMFs), όπου κάθε μία αποτελείται από στοιχεία αποκλειστικά ιδίων συχνοτήτων. Ενώ με τον μετασχηματισμό HHT είναι εφικτή η αναπαράσταση του σήματος στο πεδίο του χρόνου και των συχνοτήτων ταυτόχρονα. Ο αλγόριθμος που αναπτύχθηκε για την ανίχνευση ατράκτων αποτελείται από 4 στάδια:

- Στο 1^ο στάδιο υπολογίζεται ο FFT του ΗΕΓ και στη συνέχεια ανιχνεύονται οι πιθανές ζώνες ύπαρξης ατράκτων. Για να χαρακτηριστεί τμήμα του ΗΕΓ ως τέτοιο, θα πρέπει η τιμή της Μέσης Ισχύος (Average Power – AP) για τις ζώνες δέλτα και σίγμα να είναι μεγαλύτερες από ένα εμπειρικά ορισμένο κατώφλι. Η AP για τη ζώνη των υψηλών συχνοτήτων (30-60 Hz) θα πρέπει να είναι μικρότερη από μια συγκεκριμένη τιμή κατωφλίου, προς αποφυγή ζωνών πλούσιων σε θόρυβο. Εάν ισχύουν τα παραπάνω, το τμήμα του ΗΕΓ χαρακτηρίζεται ως πιθανό για ύπαρξη ατράκτων.
- Το 2^ο στάδιο χαρακτηρίζεται ως στάδιο ανίχνευσης υποψήφιων ατράκτων και εφαρμόζονται οι EMD και HHT, αποκλειστικά στα τμήματα του ΗΕΓ που υποδεικνύονται από το πρώτο. Μετά την εφαρμογή των παραπάνω αλγόριθμων, τα νέα τμήματα ελέγχονται με κριτήριο την συχνότητα και το πλάτος, τα οποία πρέπει να είναι μεταξύ συγκεκριμένων ορίων, αλλά και της χρονικής διάρκειάς τους, η οποία πρέπει να είναι τουλάχιστον 0,5 δευτερόλεπτα. Εάν δύο διαφορετικά τμήματα πληρούν τις προϋποθέσεις και απέχουν χρονικά λιγότερο από 0,2 δευτερόλεπτα, τότε τα τμήματα αυτά ενώνονται, θεωρώντας ως στιγμή εκκίνησης την αρχή του πρώτου παλμού και στιγμή λήξης το τέλος του δεύτερου. Αυτή η διαδικασία «διόρθωσης» γίνεται για να ξεπεραστούν τυχόν αλλοιώσεις του σήματος που προέρχονται από τον θόρυβο. Τα τμήματα του ΗΕΓ που πληρούν τα κριτήρια του 2^{ου} σταδίου περνάνε στο τρίτο στάδιο.
- Το 3^ο στάδιο αποσκοπεί στον αποκλεισμό των FP ατράκτων που ανιχνεύθηκαν από το δεύτερο στάδιο. Η διαδικασία αυτή πραγματοποιείται με το φιλτράρισμα από ζωνοπερατό φίλτρο με συχνότητες αποκοπής (0,5-25) Hz και στη συνέχεια υπολογίζεται το πλάτος, η συχνότητα και η συμμετρία κάθε τμήματος. Εμπειρικά ορισμένα κατώφλια βοηθάνε στην διαδικασία αποκλεισμού. Το νέο σύνολο υποψήφιων ατράκτων περνάει στο τέταρτο και τελικό στάδιο.

- Το 4^ο στάδιο μιμείται την διαδικασία οπτικής ανίχνευσης των ειδικών με χρονικά κριτήρια, μέσω αλγόριθμων ασαφούς λογικής. Οι άτρακτοι συνήθως βρίσκονται «ενταγμένες» σε κυματομορφές μικρότερης συχνότητας και μεγάλου πλάτους, με αποτέλεσμα πολλές από αυτές να χαθούν στην ανίχνευση. Όπως στο δεύτερο στάδιο έτσι και σε αυτό, πραγματοποιείται ένωση των υποψήφιων ατράκτων. Σε πρώτη φάση οι παλμοί που απέχουν χρονικά λιγότερο από 0,25 δευτερόλεπτα ενώνονται, ενώ η διαδικασία επαναλαμβάνεται για παλμούς που απέχουν 0,5 δευτερόλεπτα. Τελικά, ως άτρακτος ανιχνεύεται οποιαδήποτε κυματομορφή πληροί τα κριτήρια του 4^{ου} σταδίου και έχει χρονική διάρκεια μεγαλύτερη των 0,5 δευτερολέπτων. Ειδική περίπτωση αποτελούν οι κυματομορφές στα εύρη συχνοτήτων δέλτα και σίγμα, όπου πρέπει η τιμή του AP (υπολογισμός όπως και στο Στάδιο 1) για την εκάστοτε συχνότητα, να είναι μεγαλύτερη από εμπειρικά ορισμένα κατώφλια. Σε αυτή την περίπτωση, για να ανιχνευθεί άτρακτος αρκεί η κυματομορφή να έχει χρονική διάρκεια μεγαλύτερη των 0,4 και 0,3 δευτερολέπτων για την δέλτα και σίγμα συχνότητα αντίστοιχα.

Χρησιμοποιήθηκαν συνολικά 56 ολονύκτιες καταγραφές, με τις 27 από αυτές να χρησιμοποιούνται για την εκπαίδευση του αλγόριθμου, τις 10 για επιβεβαίωση και τις 19 για τον έλεγχο του. Ο παραπάνω αλγόριθμος παρουσιάζει ευαισθησία 88,2%, ειδικότητα 89,7% και 11.9% FP rate. Τα καλύτερα αποτελέσματα προκύπτουν στην ανίχνευση ατράκτων στο 2-NREM στάδιο του ύπνου με ευαισθησία 92,2%, ειδικότητα 90.1% και 8.9% FP rate [43].

2.2.6 Ανίχνευση ατράκτων με βάση ένα κανονικοποιημένο μοντέλο

Οι Nonclercq *et al.* (2013) ανέπτυξαν αλγόριθμο που δημιουργεί μοντέλα κανονικών κατανομών πλάτους και συχνότητας των ατράκτων, με εφαρμογή της μεθόδου Εκτιμητή Μέγιστης Πιθανοφάνειας (Maximum Likelihood Estimation - MLE).

Πριν την δημιουργία των κατανομών, τα χαρακτηριστικά του σήματος εξήχθησαν με τον υπολογισμό του Root Mean Square (RMS) και του φάσματος μέσω του FFT. Η παραπάνω επιλογή είναι απόρροια της θεωρίας ότι η ανίχνευση ατράκτων δεν βασίζεται σε αυστηρές τιμές πλάτους και συχνότητας αλλά υπάρχει ένα εύρος ορίων για τις τιμές. Προς απόδειξη της παραπάνω θεωρίας, ο αλγόριθμος ελέγχθηκε δύο φορές.

Την πρώτη χρησιμοποιήθηκαν σταθερά κατώφλια για την συχνότητα και το πλάτος, ενώ τη δεύτερη χρησιμοποιήθηκε η παραπάνω μοντελοποίηση. Ο αλγόριθμος εκπαιδεύτηκε και ελέγχθηκε αρχικά, με ατράκτους που είχαν ανιχνευθεί οπτικά με τη βοήθεια ειδικού από επτά ΗΕΓ υγείων μαρτύρων (Study 1 – S1). Με την εκπαίδευση δημιουργήθηκε μια πρότυπη κανονική κατανομή. Τα αποτελέσματα του αλγόριθμου για την S1 ήταν: (i) TPrate 56,4%, FPrate 1,8% και specificity 98,5% για σταθερά κατώφλια και (ii) TPrate 78,5%, FPrate 5.9% και specificity 94,2% για την μοντελοποίηση.

Προκειμένου ο αλγόριθμος να δοκιμαστεί και σε δυσκολότερες κλινικές συνθήκες, μια δεύτερη έρευνα (Study 2 – S2) πραγματοποιήθηκε, όπου ο αλγόριθμος κλήθηκε να ανιχνεύσει ατράκτους από ΗΕΓ έξι ενήλικων με διάφορες ασθένειες. Τα αποτελέσματα του αλγόριθμου για την S2 ήταν: (i) TPrate 26,4%, FPrate 0,5% και specificity 99,7% για σταθερά κατώφλια και (ii) TPrate 75,1%, FPrate 3,8% και specificity 96,7% για την μοντελοποίηση.

Ο αλγόριθμος αναγνώριζε την άτρακτο όταν το πλάτος και η συχνότητα άνηκαν στο 90% του Διαστήματος Ανοχής (Tolerance Interval – TI) της πρότυπης κανονικής κατανομής και όταν είχε χρονική διάρκεια μεγαλύτερη των 0,5 δευτερολέπτων.

Συμπέρασμα των Nonclercq *et al.* ήταν ότι και στις δύο έρευνες (S1 και S2), η μοντελοποίηση λειτούργησε θετικά ως προς την ανίχνευση των ατράκτων ενισχύοντας την διαγνωστική ικανότητα του αλγόριθμου [35].

2.2.7 Αλγόριθμος ανίχνευσης ατράκτων βασισμένος στις ταλαντώσεις του ΗΕΓ

Οι Parekh *et al.* (2015), δημιούργησαν αλγόριθμο (DETOKS) που διαχωρίζει το ΗΕΓ σε τρεις παράγοντες: (α) Στιγμιαίες κορυφές, (β) Στοιχεία χαμηλής συχνότητας και (γ) Ταλαντώσεις, δηλαδή τα ρυθμικά τμήματα του ΗΕΓ. Οι άτρακτοι υπάγονται στις ταλαντώσεις.

Χρησιμοποιείται BPF στο εύρος (11,5 – 15,5) Hz και ελάχιστο χρονικό όριο για ύπαρξη ατράκτου ορίζονται τα 0,5 δευτερόλεπτα, ενώ μέγιστο τα 3 δευτερόλεπτα. Εν συνεχεία χρησιμοποιείται ο Teager Kaiser Energy Operator (ΤΚΕΟ), και μετά από την εφαρμογή κατωφλίου ο αλγόριθμος επιστρέφει εάν η υπό εξέταση ταλάντωση είναι άτρακτος ή όχι.

Ο παραπάνω αλγόριθμος παρουσιάζει F1 score 70% και PPV, Recall κυμαίνονται στα 60% - 80% [45].

2.2.8 Αλγόριθμοι ανίχνευσης ατράκτων με χρήση ΤΝΔ

Οι Ventouras *et al.* (2005) ανέπτυξαν αλγόριθμο όπου η ανίχνευση ατράκτων πραγματοποιείται με χρήση ΤΝΔ, βασισμένο σε Multi-Layer Perceptron (MLP) αρχιτεκτονική. Το ΗΕΓ αρχικά φιλτραρίστηκε με BP FIR, στο εύρος (1,5-16) Hz και στη συνέχεια έγινε υποδειγματοληψία στα 128Hz. Το γεγονός ότι δεν εξάγονται χαρακτηριστικά πλάτους ή συχνότητας από το ΗΕΓ, έχει σαν αποτέλεσμα το πλήθος νευρώνων εισόδου του ΤΝΔ να είναι ίσο με τον αριθμό των δειγμάτων του χρονικού παραθύρου που χρησιμοποιείται για έλεγχο, που ήταν διάρκειας 0,5 δευτερολέπτων, άρα υπήρχαν 64 νευρώνες στο στρώμα εισόδου. Το δίκτυο είχε 30 νευρώνες στο δεύτερο επίπεδο, ενώ για το τελευταίο (έξοδος του ΤΝΔ) χρησιμοποιήθηκαν 2 νευρώνες. Το ΤΝΔ λειτουργεί πρακτικά ως ένας δυαδικός κατηγοριοποιητής με έξοδο (1,0) όταν ανιχνεύεται άτρακτος και (0,1) όταν δεν ανιχνεύεται άτρακτος. Η εκπαίδευση πραγματοποιήθηκε με δείγματα από ΗΕΓ υγιούς ενήλικα. Τα δείγματα ήταν αυστηρά ορισμένες άτρακτοι και μη-άτρακτοι, οπτικά ανιχνευμένες από δύο

ειδικούς. Το ΤΝΔ παρουσίαζε ευαισθησία που κυμαινόταν από 79,2% έως 87,5%, ειδικότητα από 88,4% έως 97,3% και FPrate από 3,8% έως 15,5% [25]. Επιπλέον ιδιαίτερο χαρακτηριστικό της μεθόδου είναι ότι δίνει και εκτίμηση της αρχής και του τέλους κάθε ανιχνεύομενης ατράκτου.

Ο Sinha (2008) ανέπτυξε Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ) (Artificial Neural Network – ANN), με σκοπό την ανίχνευση υπνικών ατράκτων. Το ΗΕΓ φιλτραρίστηκε με ζωνοπερατό φίλτρο IIR τύπου Butterworth με χαμηλή συχνότητα αποκοπής τα 0,25 Hz και υψηλή τα 35 Hz. Το δίκτυο αναγνώριζε και τον REM ύπνο και την εγρήγορση. Έγινε ο Fast Fourier Transform (FFT) για το φάσμα συχνοτήτων που αποτελούν το σήμα του ΗΕΓ. Οι συντελεστές κυματομορφών εξήχθησαν με τη χρήση κυματιδίων Daubechies. Οι 64 αυτοί συντελεστές εισήχθησαν σε ισάριθμους νευρώνες στο επίπεδο εισόδου του Δικτύου. Το ΤΝΔ με 3 επίπεδα, είχε 64 νευρώνες ως είσοδο, 14 νευρώνες στο κρυφό επίπεδο και 3 νευρώνες στην έξοδο. Ως άτρακτος χαρακτηριζόταν το τμήμα του ΗΕΓ για το οποίο η έξοδος ήταν 1-0-0. Παράλληλα, το ΗΕΓ εξετάστηκε οπτικά από ειδικούς όπου ανιχνεύθηκαν 380 άτρακτοι. Το ΤΝΔ που αναπτύχθηκε, συμφωνούσε κατά 96,84% με τους ειδικούς, ανιχνεύοντας 368 άτρακτους [46].

Στο σύστημα που ανέπτυξαν οι Güneş *et al.* (2011) υπολογίστηκαν χαρακτηριστικά από το πεδίο του χρόνου όπως μέση τιμή (Mean Value), τυπική απόκλιση (Standard Deviation), μέγιστη κορυφή πλάτους (Maximum Peak Value), στρέβλωση (Skewness), κύρτωση (Kurtosis) και παράγοντας σχήματος (Shape Factor).

Ο τρόπος υπολογισμού των παραπάνω τιμών φαίνεται στον **Πίνακα 2.2**

1.	Mean Value	$X_m = \sum_{n=1}^N x(n)/N$
2.	Standard Deviation	$X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N - 1}}$
3.	Maximum Peak Value	$X_p = \max x(n) $
4.	Skewness	$X_{ske} = \frac{\sum_{n=1}^N (x(n) - x_m)^3}{(N-1)x_{std}^3}$
5.	Kurtosis	$X_{kur} = \frac{\sum_{n=1}^N (x(n) - x_m)^4}{(N-1)x_{std}^4}$
6.	Shape Factor	$SF = \frac{X_{rms}}{\frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) }}$

Πίνακας 2.2: Χαρακτηριστικά υπολογισμένα από το πεδίο του χρόνου.

Η «μετάβαση» από το πεδίο του χρόνου στο πεδίο των συχνοτήτων έγινε με χρήση της μεθόδου Welch. Κατά τη μέθοδο αυτή το σήμα χωρίζεται σε επικαλυπτόμενα

τιμήματα και στη συνέχεια εφαρμόζονται χαρακτηριστικά παράθυρα, υπολογίζονται τα περιοδογράμματα και λαμβάνεται ο κυλιόμενος μέσος όρος αυτών.

Τα χαρακτηριστικά που υπολογίστηκαν από το πεδίο των συχνοτήτων είναι η ελάχιστη και η μέγιστη τιμή, η τυπική απόκλιση και η μέση τιμή. Αναγράφονται στον **Πίνακα 2.3**

1.	Minimum Value	$X_p = \min x(n) $
2.	Maximum Value	$X_p = \max x(n) $
3.	Standard Deviation	$X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - x_m)^2}{N - 1}}$
4.	Mean Value	$X_m = \sum_{n=1}^N x(n)N$

Πίνακας 2.3: Χαρακτηριστικά υπολογισμένα από το πεδίο των συχνοτήτων.

Στη δεύτερη φάση του συστήματος ανίχνευσης βρίσκεται ένα Τεχνητό Νευρωνικό Δίκτυο και έγινε χρήση του αλγόριθμου Levenberg-Marquardt (Levenberg-Marquardt Algorithm – LMA), που είναι αλγόριθμος υπολογισμού ελάχιστων τετραγώνων βασισμένος στο μέγιστο αριθμό γειτόνων, ο οποίος λειτουργεί ως ταξινομητής. Το ΤΝΔ είχε 4 νευρώνες στο επίπεδο εισόδου και 1 νευρώνα στο επίπεδο εξόδου. Μετά από δοκιμές βρέθηκε ότι ο ιδανικός αριθμός νευρώνων για το μοναδικό ενδιάμεσο επίπεδο είναι 10. Οι βάσεις δεδομένων που χρησιμοποιήθηκαν ήταν τρεις. Η πρώτη αποτελούταν αποκλειστικά από χαρακτηριστικά υπολογισμένα από το πεδίο του χρόνου και το δίκτυο παρουσίαζε ακρίβεια κατηγοριοποίησης 100%. Η δεύτερη αποτελούταν αποκλειστικά από χαρακτηριστικά υπολογισμένα από το πεδίο των συχνοτήτων και το δίκτυο παρουσίαζε ακρίβεια κατηγοριοποίησης 56,86%. Η τρίτη και τελευταία βάση δεδομένων αποτελούταν από έναν συνδυασμό χαρακτηριστικών και από τα δύο πεδία με το δίκτυο να παρουσιάζει ακρίβεια κατηγοριοποίησης 93,84% [47].

Οι Chambon *et al.* (2018), ανέπτυξαν ΤΝΔ που ως είσοδο έχει ακατέργαστο σήμα ΗΕΓ. Ως έξοδο, το δίκτυο επιστρέφει τη χρονική στιγμή εμφάνισης και τη διάρκεια της ατράκτου. Για την εκπαίδευση του δικτύου χρησιμοποιήθηκαν άτρακτοι 15 ΗΕΓ σημάτων οπτικά ανιχνευμένες από δύο ειδικούς, με περίπου 500 άτρακτους ανά καταγραφή. Η ακρίβεια που παρουσίαζε το δίκτυο κυμαίνεται από 60% έως 70%, χρησιμοποιώντας τον δείκτη Intersection over Union (Διατομή προς Ένωση, Δείκτης Jaccard) [48].

ΚΕΦΑΛΑΙΟ 3

Βαθιά Μάθηση και δίκτυα Long-Short Term Memory

Εισαγωγή

Στο παρόν κεφάλαιο αναλύονται οι έννοιες Βαθιά και Μηχανική Μάθηση, ενώ περιγράφεται η δομή και λειτουργία των ΤΝΔ. Αναφέρονται τα στάδια της εκπαίδευσης και οι παράμετροι που συμβάλουν στο τελικό αποτέλεσμα. Περιγράφεται επίσης και η ειδική κατηγορία των ΤΝΔ που χρησιμοποιούμε στην παρούσα εργασία, τα Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Network - (RNN) και συγκεκριμένα η παραλλαγή τους τα δίκτυα Μνήμης Μακράς-Βραχείας Διάρκειας (Long Short-Term Memory LSTM networks).

3.1 Μηχανική Μάθηση και Βαθιά Μάθηση

Η ανάγκη για κατανόηση των αιτίων των παθολογιών και ασθενειών και κατά επέκταση για παροχή όλο και καλύτερων ιατρικών υπηρεσιών, αποτελεί το κεντρικό πεδίο έρευνας των επιστημών υγείας εδώ και δύο αιώνες. Λαμβάνοντας υπόψη την τεχνολογική ανάπτυξη, την πολυπλοκότητα αλλά και την ποικιλία των βιολογικών μετρήσεων στις μέρες μας, σύγχρονες τεχνικές όπως η Μηχανική Μάθηση - MM (Machine Learning – ML), η οποία αποτελεί πεδίο της Τεχνητής Νοημοσύνης - ΤΝ (Artificial Intelligence – AI), χρησιμοποιείται για την αναγνώριση, κατηγοριοποίηση και πρόβλεψη δεδομένων βιολογικής σημασίας [49,50].

Η συμβατική MM θα μπορούσε να χωριστεί σε δύο μεγάλες κατηγορίες: (α) επιβλεπόμενη (supervised) και (β) μη επιβλεπόμενη (unsupervised) (Mahmud *et al.*, 2018).

Η διαφορά των δύο κατηγοριών έγκειται στη φύση των δεδομένων που επεξεργάζονται. Στην επιβλεπόμενη MM τα δεδομένα, είναι ήδη διαχωρισμένα σε κατηγορίες από ειδικούς, ενώ στην μη επιβλεπόμενη MM το μοντέλο που αναπτύσσεται καλείται από μόνο του να κάνει τον παραπάνω διαχωρισμό, βρίσκοντας ομοιότητες και διαφορές στα δεδομένα. Μερικές επιβλεπόμενες τεχνικές είναι: τα ΤΝΔ, γραμμικοί κατηγοριοποιητές, στατιστικά δίκτυα Bayes, τεχνική κ-πλησιεστέρων γειτόνων (k-nearest neighbours - kNN), Κρυφά Μαρκοβιανά Μοντέλα (Hidden Markov Models - HMM) και δέντρα απόφασης. Αντιθέτως, χαρακτηριστικές μη επιβλεπόμενες τεχνικές είναι: expectation maximization, k-means, αλγόριθμοι ασαφούς λογικής. Η Βαθιά Μάθηση – BM (Deep Learning – DL) είναι μια υποκατηγορία της MM, όπου τα δίκτυα που χρησιμοποιούνται έχουν, κυρίως στα πολυάριθμα ενδιάμεσα στρώματά τους πολύ μεγάλο αριθμό μονάδων (νευρώνων), γεγονός που τα καθιστά ικανά να εξάγουν μια πληθώρα χαρακτηριστικών, από μία μεγάλη βάση δεδομένων που χρησιμοποιούνται για εκπαίδευση και να επιλύουν προβλήματα που ήταν δυσεπίλυτα με της τεχνικές προηγούμενες τεχνικές «ρηχής» μάθησης (shallow learning techniques) [51-54].

Στο παρόν κεφάλαιο θα αναλύσουμε την λειτουργία των ΤΝΔ, μια κατηγορία της ΜΜ, που χρησιμοποιούν μεθόδους της ΒΜ για διαμόρφωση αποφάσεων.

3.2 Τεχνητά Νευρωνικά Δίκτυα

Τα ΤΝΔ είναι «συστήματα» που μέσω της εκπαίδευσης, ανακαλύπτουν μια α priori σχέση μεταξύ των δεδομένων που επεξεργάζονται και λαμβάνουν μια απόφαση σχετικά με τα εν λόγω δεδομένα [50,55].

Αποτελούνται από απλές μονάδες επεξεργασίας δεδομένων, τους νευρώνες, οι οποίοι εμπνευσμένοι από τους βιολογικούς νευρώνες του ΚΝΣ, λαμβάνουν ένα σήμα εισόδου, το επεξεργάζονται και δίνουν μια τιμή στην έξοδό τους. Κάθε νευρώνας συνδέεται με τουλάχιστον έναν ακόμα και κάθε σύνδεση χαρακτηρίζεται από τον συντελεστή βαρύτητας (weight coefficient) ή αλλιώς βάρος, που είναι μια πραγματική τιμή. Ο συντελεστής αυτός εκφράζει τη σημασία της εκάστοτε σύνδεσης στο ΤΝΔ και τη συμβολή που έχει στο τελικό αποτέλεσμα. Εξετάζοντας τη χρήση των ΤΝΔ πιο γενικευμένα μπορούμε να πούμε ότι αυτό που αποσκοπούμε από την χρήση τους είναι η απεικόνιση των διανυσμάτων εισόδου, στα ανάλογα διανύσματα εξόδου. Αποτελούν χαρακτηριστική μέθοδο επεξεργασίας πληροφορίας και βρίσκουν εφαρμογή σε θέματα όπως η προσέγγιση μαθηματικών συναρτήσεων, ταξινόμηση δεδομένων σε κλάσεις, προβλήματα βελτιστοποίησης και άλλα [56,57].

Η διαδικασία που προαναφέρθηκε γίνεται μέσω της εκπαίδευσης, η οποία μεταφράζεται με όρους μαθηματικού φορμαλισμού στο «κούρδισμα» των συντελεστών βαρύτητας κατά τον βέλτιστο τρόπο και θα αναλυθεί στη συνέχεια.

3.2.1 Κατηγορίες ΤΝΔ

Τα Νευρωνικά Δίκτυα κατηγοριοποιούνται με βάση την αρχιτεκτονική τους και των νευρώνων που αποτελούνται.


Δύο είναι οι κύριες κατηγορίες ΤΝΔ:

- (α) Δίκτυα Ευθείας Τροφοδότησης (Feedforward Neural Networks FNN) και
- (β) Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks – RNNs).

Πολλές φορές συναντιούνται και υβριδικά μοντέλα μεταξύ των δύο κατηγοριών [51,57].


Τα FNN αποτελούνται από ένα ή περισσότερα επίπεδα (layers) για αυτό και συνήθως ονομάζονται multi-layer feedforward NN (MLF NN). Το πρώτο επίπεδο ονομάζεται επίπεδο εισόδου (input layer), το τελευταίο επίπεδο εξόδου (output layer) και τα υπόλοιπα είναι τα κρυφά επίπεδα (hidden layers).

Η πληροφορία ρέει προς μια κατεύθυνση χωρίς να «παλινδρομεί» και όλοι οι νευρώνες ενός επιπέδου, συνδέονται με όλους (ή κάποιους) του επόμενου, χωρίς να υπάρχει σύνδεση μεταξύ νευρώνων ίδιου επιπέδου [58,59].



Εικόνα 3.1: Ένα τυπικό multi-layer feed-forward NN (MLF) τριών επιπέδων [58].

Τα RNN είναι δυναμικά συστήματα τα οποία μοντελοποιούν, επεξεργάζονται και αναπαριστούν χρονικά μεταβαλλόμενα δεδομένα. Χαρακτηριστικό τους είναι η αναδρομή των δεδομένων από τους κόμβους των νευρώνων. Αυτή η ιδιότητα έχει ως αποτέλεσμα την «αντίληψη» του χρόνου από το δίκτυο, δικαιολογώντας έτσι τον όρο «δυναμικό σύστημα», αφού μπορεί να προβλέψει την έξοδο για χρονική στιγμή $t+1$, εφόσον στην είσοδο υπάρχουν δεδομένα για την χρονική στιγμή t ή και προηγούμενες. Η δομή των RNN τους προσδίδει επίσης και την ιδιότητα της μνήμης, με αποτέλεσμα να μπορούν να επεξεργαστούν εισόδους που δεν είναι ανεξάρτητες μεταξύ τους [60].




Εικόνα 3.2: Στο σχήμα δείχνεται η αρχιτεκτονική ενός RNN και το «ξε-δίπλωμα» σε βάθος χρόνου. Το μαύρο κουτί απεικονίζει την αναδρομική φύση του δικτύου. Όπου

x_t , o_t και s_t η είσοδος, έξοδος και κατάσταση του νευρώνα αντίστοιχα για την χρονική στιγμή t και αντίστοιχα για τις χρονικές στιγμές $t-1$, $t+1$ [60].

3.2.2 Συμπεριφορά νευρώνων και εκπαίδευση Δικτύου

Για να ορίσουμε όλους τους νευρώνες χρησιμοποιούμε συνάρτηση χαρτογράφησης Γ , που δημιουργεί για κάθε νευρώνα i ένα υποσύνολο $\Gamma(i) \subseteq V$, που αποτελείται από όλους τους προηγούμενους νευρώνες, για έναν δεδομένο νευρώνα. Άρα το υποσύνολο $\Gamma^{-1}(i) \subseteq V$, θα αποτελείται από όλους τους προηγούμενους νευρώνες του νευρώνα i [60].



Εικόνα 3.3: Σύνδεση μεταξύ δυο νευρώνων i και j . ω_{ij} είναι ο συντελεστής βαρύτητας της σύνδεσης των δυο νευρώνων. X_i και X_j είναι η τιμή εξόδου του εκάστοτε νευρώνα [60].

Η τιμή εξόδου, για νευρώνα i του ΤΝΔ προκύπτει από τις παρακάτω εξισώσεις, όπου f συμβολίζει την συνάρτηση ενεργοποίησης ενός νευρώνα και ξ_i είναι η «ποσότητα ενεργοποίησης» ή «ποσότητα διέγερσης» του νευρώνα[60]:

$$x_i = f(\xi_i) \quad (3.1)$$

$$\xi_i = b_i + \sum_{j \in \Gamma_i^{-1}} \omega_{ij} x_j \quad (3.2)$$

και b_i είναι μια πρόσθετη «τιμή πόλωσης» (ή απλά «πόλωση») (bias) για τον εκάστοτε νευρώνα.

Ξεκινώντας την εκπαίδευση, όλα τα βάρη αποκτούν μια αρχική τιμή. Εν συνεχεία τα στοιχεία που εισάγονται στο ΤΝΔ, προκαλούν την αρχική ενεργοποίηση των νευρώνων. Κάθε νευρώνας υπολογίζει το άθροισμα των βαρών για τους νευρώνες

που ενεργοποιήθηκαν στο προηγούμενο επίπεδο και προστίθεται πόλωση (bias), σύμφωνα με την εξίσωση (3.2).

Ένας εναλλακτικός, αλλά ισοδύναμος, τρόπος μαθηματικής μορφοποίησης της λειτουργίας ενός δικτύου είναι ο ακόλουθος: Την ποσότητα ενεργοποίησης $z(W,b)$, ακολουθεί μια συνάρτηση ενεργοποίησης $a(z)$, που έχει ως αποτέλεσμα την τιμή εξόδου του νευρώνα, η οποία λειτουργεί σαν τιμή ενεργοποίησης για τον επόμενο νευρώνα [60]:

$$z_i^k(W, b) = \sum_{j=1}^{n^{(k-1)}} (w_{i,j}^k * a_j^{(k-1)}) + b_i^k \quad (3.3)$$

$$a_i^k(z) = f(z_i^k) \quad (3.4)$$

όπου a_i^k είναι η έξοδος του νευρώνα i στο επίπεδο k και $n^{(k-1)}$ είναι το πλήθος των νευρώνων στο προηγούμενο επίπεδο. $w_{i,j}^k$ είναι το βάρος της σύνδεσης μεταξύ των νευρώνων j στο επίπεδο $(k-1)$ και του i στο επίπεδο k . $f(x)$ είναι η συνάρτηση ενεργοποίησης και τέλος b_i^k είναι το bias του εκάστοτε νευρώνα [60].

Η συνάρτηση ενεργοποίησης, χρησιμοποιεί το αποτέλεσμα της εξίσωσης (3.3) και καθορίζει εάν θα «πυροδοτηθεί» ο νευρώνας ή όχι. Υπάρχουν πολλές συναρτήσεις ενεργοποίησης (ή αλλιώς μεταφοράς) που μπορούν να επιλεγθούν από τον χρήστη [61].

- Σιγμοειδής Συνάρτηση (Sigmoid Function)

Η σιγμοειδής συνάρτηση είναι μη γραμμική και συνήθως συναντάται στο επίπεδο εξόδου των ΤΝΔ. Χρησιμοποιείται κυρίως σε ΤΝΔ που πραγματοποιούν προβλέψεις και έχουν μεγάλη επιτυχία σε προβλήματα δυαδικής κατηγοριοποίησης.

Το αποτέλεσμα προκύπτει από την εξίσωση

$$f_{act}(x) = \frac{1}{1 + \exp(-x)} \quad (3.5)$$

- Hyperbolic Tangent Function (tanh)

Η υπερβολική εφαπτομένη είναι μη γραμμική συνάρτηση με την έξοδό της να κυμαίνεται σε εύρος $[-1,1]$. Συγκριτικά με την σιγμοειδή παράγει καλύτερα αποτελέσματα στην εκπαίδευση, όταν το πλήθος των κρυφών επιπέδων αυξάνεται.

Το αποτέλεσμα προκύπτει από την εξίσωση

$$f_{act}(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (3.6)$$

- Softmax Function

Η συνάρτηση Softmax υπολογίζει την κατανομή πιθανότητας από ένα διάνυσμα πραγματικών αριθμών. Έχει εύρος από 0 έως και 1, ενώ η κύρια διαφορά της με τη σιγμοειδή συνάρτηση είναι ότι η Softmax χρησιμοποιείται σε προβλήματα κατηγοριοποίησης πολλαπλών κλάσεων.

Το αποτέλεσμα της εξόδου προκύπτει από την εξίσωση

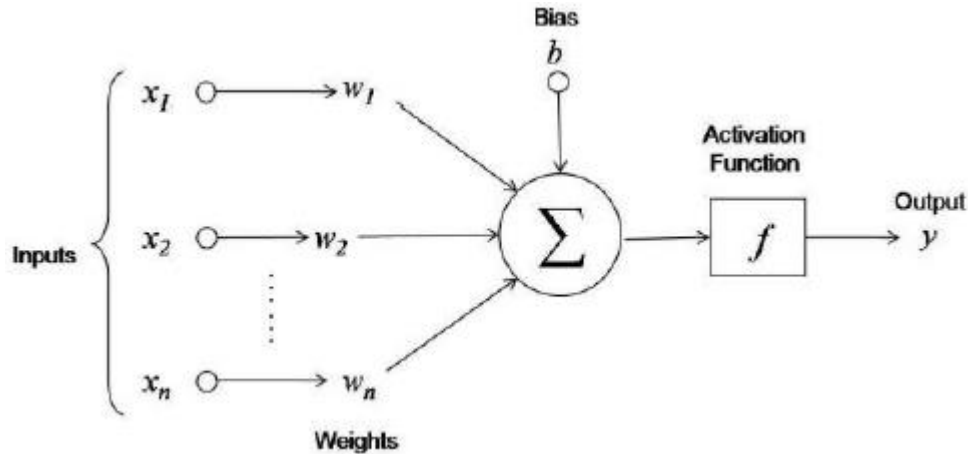
$$f_{act}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3.7)$$

- Rectified Linear Unit Function (ReLU)

Είναι η πλέον χρησιμοποιημένη συνάρτηση ενεργοποίησης, που χάρη στην γραμμικότητά της βοηθάει τα συστήματα να σταθεροποιηθούν, μαζί με την μέθοδο εκμάθησης «καθόδου/ελάττωσης κλίσης» (gradient descent). Η συνάρτηση αυτή εφαρμόζει ένα κατώφλι ενεργοποίησης σε κάθε στοιχείο εισόδου, με τα στοιχεία μικρότερα του μηδενός να μηδενίζονται ενώ τα υπόλοιπα να κρατάνε την τιμή τους.

Το αποτέλεσμα της εξόδου προκύπτει από την εξίσωση:

$$f_{act}(x) = \max(0, x) = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \quad (3.8)$$



Εικόνα 3.4: Στο σχήμα δείχνεται η σχέση μεταξύ της εξίσωσης (3.1) και της συνάρτησης ενεργοποίησης, αλλά και ο τρόπος που προκύπτει η τιμή εξόδου του νευρώνα [60].

Η συνάρτηση κόστους (loss function), χρησιμοποιείται για ορίσει την απόκλιση που έχει η τιμή εξόδου (\hat{y}) του ΤΝΔ, από την αναμενόμενη τιμή που θα έπρεπε να είχε. Σκοπός της εκπαίδευσης είναι αυτή η απόκλιση να είναι όσο το δυνατόν μικρότερη. Δυο είναι οι κύριες συναρτήσεις κόστους που χρησιμοποιούνται: (i) Cross Entropy (CE) και (ii) Mean Square Error.

Η Cross Entropy, αξιολογεί την απόδοση συστήματος όπου η έξοδος του είναι πιθανότητα με ελάχιστη τιμή το 0 και μέγιστη το 1. Η τιμή της Cross Entropy αυξάνεται καθώς η πρακτική τιμή στην έξοδο του ΤΝΔ αποκλίνει από την θεωρητική, οπότε ιδανικά θα θέλαμε ένα σύστημα με CE ίση με το 0. Επειδή η CE έχει ως όρισμα εισόδου και εξόδου πιθανότητα, χρησιμοποιείται μαζί με τη συνάρτηση ενεργοποίησης Softmax.

Η Cross entropy, όταν το σύστημα καλείται να κατηγοριοποιήσει δεδομένα που ανήκουν σε περισσότερες από 2 κλάσεις, υπολογίζεται από:

$$Loss_{CE}(y, \hat{y}) = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (3.9)$$

όπου N το πλήθος των δεδομένων εξόδου, y η θεωρητική τιμή και \hat{y} η τιμή στην έξοδο του ΤΝΔ.

Όταν το πλήθος των κλάσεων είναι 2 χρησιμοποιείται η Binary Cross Entropy, που υπολογίζεται από

$$Loss_BCE(y, \hat{y}) = -\frac{1}{N} \sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) \quad (3.10)$$

Η Mean Square Error (MSE), υπολογίζει το μέσο τετράγωνο της διαφοράς της απόστασης των πραγματικών από τις θεωρητικές τιμές. Όπως προηγουμένως έτσι κι εδώ το ιδανικό αποτέλεσμα θα ήταν το 0 [62].

Υπολογίζεται από:

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.11)$$

3.3 Το πρόβλημα της μάθησης και ο Backpropagation αλγόριθμος

Ορίσαμε προηγουμένως τα FNN ως δίκτυα των οποίων οι νευρώνες είναι υπολογιστικές μονάδες που μεταδίδουν αριθμητική πληροφορία μεταξύ τους. Επί της ουσίας το δίκτυο είναι μια αναπαράσταση αλυσιδωτών συναρτήσεων που μεταφέρουν το διάνυσμα από τον είσοδο του δικτύου, στην έξοδο. Το σύνολο των συναρτήσεων αυτών ορίζουν μια νέα συνάρτηση, τη *συνάρτηση του δικτύου* φ . Ο σκοπός της μάθησης είναι η εύρεση των τιμών που πρέπει να έχουν τα βάρη (weights) των νευρώνων, ώστε η συνάρτηση φ να είναι όσο το δυνατόν πιο κοντά στην επιθυμητή τελική συνάρτηση εξόδου f . Ωστόσο, η συνάρτηση πολλές φορές δεν είναι εκ των προτέρων γνωστή f , αλλά υπολογίζεται κατά προσέγγιση μέσω παραδειγμάτων.

Πριν την ανακάλυψη του αλγορίθμου οπίσθιας ανατροφοδότησης (Backpropagation Algorithm – BPA), τα βάρη και οι πολώσεις (biases) καθορίζονταν από τον αλγόριθμο «καθόδου/ελάττωσης κλίσης» (*gradient descent*) για τη συνάρτηση κόστους. Αυτή η μέθοδος ωστόσο είχε το μειονέκτημα ότι η συνάρτηση κόστους δεν αποδίδει συγκεκριμένη τιμή για τους νευρώνες των ενδιάμεσων επιπέδων.

Το παραπάνω πρόβλημα καλείται να λύσει ο BPA, που πρωτοεμφανίστηκε το 1970. Ο BPA υπολογίζει την ανάδελτα της συνάρτησης κόστους ως προς τα βάρη του δικτύου, ως σύνολο και όχι για κάθε βάρος μεμονωμένα. Για να γίνει αυτό απαιτείται μια βάση δεδομένων (dataset), η οποία αποτελείται από ζεύγη εισόδου - εξόδου (\vec{x}_i, \vec{y}_i) , όπου \vec{x}_i το διάνυσμα εισόδου και \vec{y}_i το επιθυμητό διάνυσμα εξόδου.

Μια ολοκληρωμένη βάση δεδομένων ορίζεται ως:

$$X = \{(\vec{x}_1, \vec{y}_1), \dots, (\vec{x}_N, \vec{y}_N)\} \quad (3.12)$$

Για να οριστούν οι παράμετροι (θ) των νευρώνων του FNN χρησιμοποιείται:

w_{ij}^k : για το βάρος μεταξύ νευρώνα j στο επίπεδο l_k και του νευρώνα i στο επίπεδο l_{k-1}

b_i^k : για το *bias* του νευρώνα i στο επίπεδο l_k

a_i^k : άθροισμα τιμών προηγούμενων νευρώνων και *bias* (activation) για τον νευρώνα i στο επίπεδο l_k (βλ. εξίσωση 3.15 παρακάτω)

o_i^k : έξοδος νευρώνα i στο επίπεδο l_k

r_k : πλήθος νευρώνων στο επίπεδο l_k

g : συνάρτηση ενεργοποίησης για νευρώνες κρυφού επιπέδου

g_o : συνάρτηση ενεργοποίησης για νευρώνες επιπέδου εξόδου

Ορίζεται επίσης η συνάρτηση κόστους $E(X, \theta)$ που απεικονίζει την διαφορά της επιθυμητής εξόδου \vec{y}_i από αυτή που έχει υπολογιστεί, $\widehat{\vec{y}}_i$ για είσοδο \vec{x}_i με ζεύγος $(\vec{x}_i, \vec{y}_i) \in X$ και τιμές για παραμέτρους νευρώνων θ . Στην κλασική BPA η συνάρτηση κόστους είναι η Mean Squared Error, άρα:

$$E(X, \theta) = \frac{1}{2N} \sum_{i=1}^N (\widehat{y}_i - y_i)^2 \quad (3.13)$$

Από εδώ και πέρα θα θεωρούμε την παράγωγο συνάρτησης $f(x)$ ως $f'(x)$ και το *bias* b_i^k θα «ενσωματωθεί» στο w_{0i}^k με σταθερή έξοδο $o_0^{k-1} = 1$ για τον νευρώνα 0 στο επίπεδο $k - 1$.

Δηλαδή,

$$w_{0i}^k = b_i^k \quad (3.14)$$

και άρα η έξοδος του κάθε νευρώνα θα προκύπτει από την εξίσωση

$$a_i^k = b_i^k + \sum_{j=1}^{r_{k-1}} w_{ji}^k o_j^{k-1} = \sum_{j=0}^{r_{k-1}} w_{ji}^k o_j^{k-1} \quad (3.15)$$

Άρα ο αλγόριθμος, βάσει των παραπάνω, προσπαθεί να ελαχιστοποιήσει το κόστος, υπολογίζοντας για κάθε w_{ij}^k την τιμή του $\frac{\partial E}{\partial w_{ij}^k}$.

Μπορούμε λοιπόν να θεωρήσουμε ότι το ελάχιστο της συνάρτησης κόστους μπορεί να υπολογιστεί ως το άθροισμα του υπολογισμού του παραπάνω διαφορικού για κάθε ζεύγος εισόδου – εξόδου της βάσης δεδομένων.

Δηλαδή,

$$\frac{\partial E(X, \theta)}{\partial w_{ij}^k} = \frac{1}{N} \sum_{d=1}^N \frac{\partial}{\partial w_{ij}^k} \left(\frac{1}{2} (\hat{y}_d - y_d)^2 \right) = \frac{1}{N} \sum_{d=1}^N \frac{\partial E_d}{\partial w_{ij}^k} \quad (3.16)$$

Η παραγωγή στον τύπο του BPA ξεκινάει με εφαρμογή του «κανόνα αλυσίδας» (chain rule) στην συνάρτηση κόστους:

$$\frac{\partial E}{\partial w_{ij}^k} = \frac{\partial E}{\partial a_j^k} \frac{\partial a_j^k}{\partial w_{ij}^k} \quad (3.17)$$

Όπου ως διαφορικό κόστος (σφάλμα) ορίζεται το

$$\delta_j^k = \frac{\partial E}{\partial a_j^k} \quad (3.18)$$

και

$$\frac{\partial a_j^k}{\partial w_{ij}^k} = \frac{\partial}{\partial w_{ij}^k} \left(\sum_{l=0}^{r_{k-1}} w_{il}^k o_l^{k-1} \right) = o_i^{k-1} \quad (3.19)$$

και άρα η μερική παράγωγος της συνάρτησης κόστους E ως προς το βάρος w_{ij}^k είναι:

$$\frac{\partial E}{\partial w_{ij}^k} = \delta_j^k o_i^{k-1} \quad (3.20)$$

Γίνεται λοιπόν αντιληπτό ότι η μερική παράγωγος ενός βάρους είναι απόρροια του σφάλματος δ_j^k από τον νευρώνα j του επιπέδου k και της εξόδου o_i^{k-1} , από τον νευρώνα i του επιπέδου $k-1$.

Ο ΒΡΑ ξεκινάει από το επίπεδο εξόδου και προσπαθεί να ορίσει τιμή για το δ_1^m , όπου 1 θεωρούμε το πλήθος των νευρώνων για το επίπεδο εξόδου.

Εκφράζοντας την συνάρτηση κόστους ως προς την τιμή a_1^m (αφού το δ_1^m είναι μερική παράγωγος ως προς το a_1^m), προκύπτει:

$$E = \frac{1}{2}(\hat{y} - y)^2 = \frac{1}{2}(g_o(a_1^m) - y)^2 \quad (3.21)$$

όπου $g_o(x)$ η συνάρτηση ενεργοποίησης του επιπέδου εξόδου.

Με μερική παραγωγή και εφαρμόζοντας τον κανόνα αλυσίδας, έχουμε

$$\delta_1^m = (g_o(a_1^m) - y)g'_o(a_1^m) = (\hat{y} - y)g'_o(a_1^m) \quad (3.22)$$

Βάσει των παραπάνω, η μερική παράγωγος της συνάρτησης κόστους E μπορεί να γραφτεί ως προς το βάρος του επιπέδου εξόδου w_{i1}^m :

$$\frac{\partial E}{\partial w_{i1}^m} = \delta_1^m o_{i1}^{m-1} = (\hat{y} - y) g'_o(a_1^m) o_i^{m-1} \quad (3.23)$$

Και για να υπολογιστεί η μερική παράγωγος για τα υπόλοιπα επίπεδα, χρησιμοποιείται το κόστος δ_j^k , στα επίπεδα $1 \leq k \leq m$

$$\delta_j^k = \frac{\partial E}{\partial a_j^k} = \sum_{l=1}^{r^{k+1}} \frac{\partial E}{\partial a_j^{k+1}} \frac{\partial a_j^{k+1}}{\partial a_j^k} \quad (3.24)$$

όπου το l κυμαίνεται από 1 έως r^{k+1} , το πλήθος των νευρώνων του επόμενου επιπέδου.

Στην παραπάνω εξίσωση πλέον εμφανίζεται ο παράγοντας κόστους δ_l^{k+1}

$$\delta_j^k = \sum_{l=1}^{r^{k+1}} \delta_l^{k+1} \frac{\partial a_j^{k+1}}{\partial a_j^k} \quad (3.25)$$

και επειδή

$$a_i^{k+1} = \sum_{l=1}^{r^k} w_{jl}^{k+1} g(a_j^k) \quad (3.26)$$

προκύπτει ότι

$$\frac{\partial a_i^{k+1}}{\partial a_j^k} = w_{jl}^{k+1} g'(a_j^k) \quad (3.27)$$

Και από τις εξισώσεις (3.25), (3.27), προκύπτει η βασική εξίσωση του BPA

$$\delta_j^k = g'(a_j^k) \sum_{l=1}^{r^{k+1}} w_{jl}^{k+1} \delta_l^{k+1}$$

Και άρα η μερική παράγωγος της συνάρτησης κόστους E ως προς το w_{ij}^k , στα επίπεδα $1 \leq k \leq m$ είναι:

$$\frac{\partial E}{\partial w_{ij}^k} = \delta_j^k o_i^{k-1} = g'(a_j^k) o_i^{k-1} \sum_{l=1}^{r^{k+1}} w_{jl}^{k+1} \delta_l^{k+1} \quad (3.28)$$

Τέλος τα βάρη ανανεώνονται σύμφωνα με την εξίσωση:

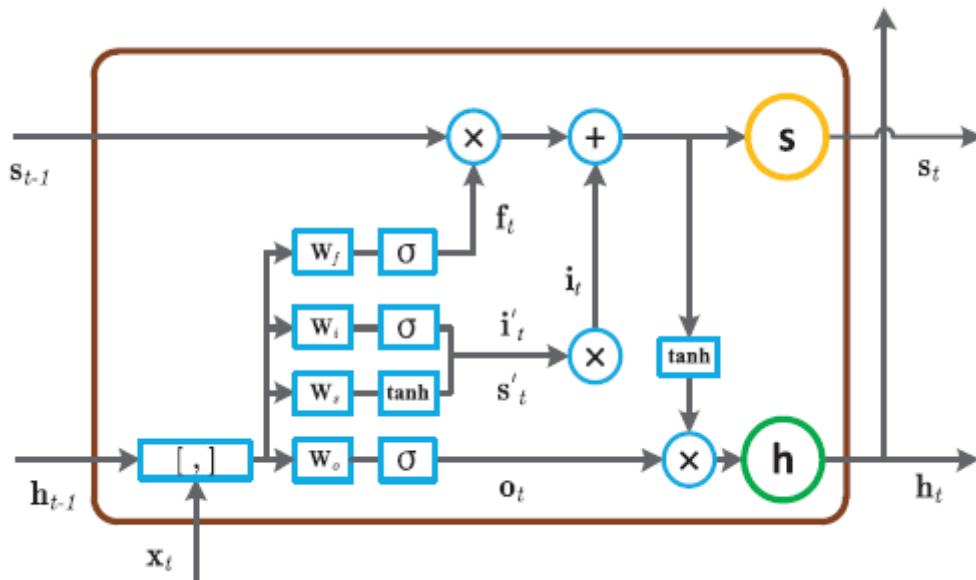
$$\Delta w_{ij}^k = -lr \frac{\partial E(X, \theta)}{\partial w_{ij}^k} \quad (3.29)$$

όπου lr είναι ο *learning rate* (ρυθμός εκπαίδευσης), που αποτελεί υπερπαραμέτρο του δικτύου [63-65].

3.4 Long – Short Term Memory (LSTM)

Η κύρια ιδέα ενός LSTM δικτύου είναι η δημιουργία μιας μονάδας μνήμης που μπορεί να διατηρεί την κατάσταση της σε βάθος χρόνου, με χρήση μη γραμμικών «πυλών» (δηλ. συναρτήσεων) που κανονικοποιούν την ροή της πληροφορία από και προς τους νευρώνες [Greff et al, 2017].

Για να αναλυθεί η ροή της πληροφορίας σε ένα δίκτυο LSTM, ορίζεται x^t το διάνυσμα εισόδου για χρονική στιγμή t .



Εικόνα 3.5: Απεικόνιση ενός LSTM νευρώνα (LSTM block) [65].

3.4.1 Ροή πληροφορίας και διαχείριση δεδομένων από ένα LSTM block

Ένας νευρώνας LSTM έχει τη δυνατότητα να «κρατάει», μέρος ή ολόκληρη την πληροφορία που διέρχεται από αυτόν. Η διαδικασία αυτή γίνεται μέσω των «πυλών» (gates), οι οποίες αποτελούνται από μια σιγμοειδή συνάρτηση ενεργοποίησης και το σημειακό γινόμενο διανυσμάτων. Τρεις είναι οι πύλες που ρυθμίζουν την κατάσταση του νευρώνα.

Η πρώτη διεργασία του νευρώνα, για χρονική στιγμή t , είναι να καθορίσει τι πληροφορία θα κρατήσει από την προηγούμενη κατάστασή του. Αυτή η ενέργεια πραγματοποιείται από την Forget Gate και καθορίζεται από την προηγούμενη κατάσταση h_{t-1} και την τρέχουσα είσοδο x_t . Για έξοδο της σιγμοειδούς συνάρτησης ίση με το 0, δεν αποθηκεύεται πληροφορία από την προηγούμενη κατάσταση, ενώ για έξοδο ίση με 1 αποθηκεύεται ολόκληρη η πληροφορία.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.30)$$

Σε δεύτερη φάση, καθορίζεται τι πληροφορία θα αποθηκευτεί στον νευρώνα από την νέα του είσοδο. Αυτή η ενέργεια συμβαίνει σε δύο βήματα. Αρχικά μια σιγμοειδής συνάρτηση «πύλης εισόδου» (Input Gate), καθορίζει ποιες τιμές θα ανανεωθούν.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.31)$$

Εν συνεχεία μια υπερβολική εφαπτομένη (\tanh) δημιουργεί διάνυσμα \tilde{C}_t πιθανών τιμών που θα εισαχθούν στην κατάσταση του νευρώνα.

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3.32)$$

Τελικά, οι δυο παραπάνω διεργασίες συνδυάζονται για να ενημερώσουν την νέα κατάσταση του νευρώνα, C_t την χρονική στιγμή t , βάσει της παλαιάς, C_{t-1} .

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.33)$$

Τέλος, η έξοδος του νευρώνα βασίζεται στην κατάστασή του. Όπως προηγουμένως, έτσι κι εδώ, αρχικά η κατάσταση του νευρώνα φιλτράρεται με μια σιγμοειδή συνάρτηση για να καθοριστεί τι πληροφορία θα εξαχθεί.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.34)$$

Η κατάσταση του νευρώνα κανονικοποιείται σε εύρος $[-1,1]$ από μια \tanh και τέλος πολλαπλασιάζεται με την έξοδο της σιγμοειδούς συνάρτησης που προαναφέρθηκε. Η έξοδος είναι το αποτέλεσμα αυτού του πολλαπλασιασμού [65-71]:

$$h_t = o_t * \tanh(C_t) \quad (3.35)$$

3.4.2 Backpropagation through time – BPTT

Ο αλγόριθμος του Backpropagation διαφοροποιείται όταν εφαρμόζεται στα Αναδρομικά Νευρωνικά Δίκτυα (RNN), καθώς η ροή δεδομένων δεν είναι μονόδρομη (από το επίπεδο εισόδου στο επίπεδο εξόδου). Για την εφαρμογή του BPTT, αρκεί να φανταστούμε το RNN ως ένα «ξεδιπλωμένο» FNN (βλ. Εικόνα 3.2).

Η δομή των RNN ορίζεται από την εξίσωση

$$s_t = f_W(s_{t-1}, x_t) \quad (3.36)$$

όπου s_t είναι το διάνυσμα κατάστασης του νευρώνα τη χρονική στιγμή t .

Η παραπάνω εξίσωση μπορεί να γραφτεί και ως

$$s_t = \varphi(W_s s_{t-1} + W_x x_t) \quad (3.37)$$

όπου φ η συνάρτηση ενεργοποίησης.

Το διάνυσμα εξόδου μπορεί να γραφτεί ως

$$y_t = W_y s_t \quad (3.38)$$

και η συνάρτηση κόστους την χρονική στιγμή t είναι:

$$E_t = (d_t - y_t)^2 \quad (3.39)$$

Τα W_x , W_y και W_s αντιπροσωπεύουν τους πίνακες των βαρών που συνδέουν το επίπεδο εισόδου με το επίπεδο κατάστασης, το επίπεδο κατάστασης με το επίπεδο εξόδου και την κατάσταση της προηγούμενης χρονικής στιγμής με την κατάσταση της επόμενης αντίστοιχα.

Όπως προαναφέρθηκε η ιδιαιτερότητα των RNN είναι ότι για την έξοδο του νευρώνα την χρονική στιγμή $t + 1$, λαμβάνεται υπόψη η κατάσταση s_t του νευρώνα την χρονική στιγμή t . Για αυτό τον λόγο η σύγκλιση με τεχνική gradient descent, της συνάρτησης κόστους προς επόμενες καταστάσεις δεν εξαρτάται αποκλειστικά από την είσοδο του νευρώνα, αλλά και από την τρέχουσα κατάστασή του.

Για την ανανέωση των παραπάνω πινάκων ισχύει:

$$\frac{\partial E}{\partial W} = \sum_{i=t+1}^{t+N} \frac{\partial E}{\partial s_{t+N}} \frac{\partial s_{t+N}}{\partial s_i} \frac{\partial s_i}{\partial W} \quad (3.40)$$

$$h_t = W_{hx}x_t + W_{hh}h_{t-1} \quad (3.41)$$

και η έξοδος του νευρώνα [63,64,72,73] είναι:


$$o_t = W_{qh}h_t \quad (3.42)$$

3.5 Υπερπαράμετροι ΤΝΔ

Οι υπερπαράμετροι ενός ΤΝΔ είναι επιπλέον ρυθμίσεις που επηρεάζουν την δομή του την εκπαίδευσή του. Ορίζονται πριν από την εκκίνηση της εκπαίδευσης και η επιλογή τους γίνεται είτε από τον χρήστη, είτε μέσω αλγόριθμων [74].

Κύριες υπερπαράμετροι είναι οι παρακάτω:

Ρυθμός εκπαίδευσης (Learning rate): Όπως προαναφέρθηκε ο ρυθμός εκπαίδευσης καθορίζει την συχνότητα με την οποία επικαιροποιούνται οι παράμετροι των νευρώνων (βάρη και πολώσεις). Εάν είναι πολύ μεγάλος τότε είναι πιθανό οι ιδανικοί παράμετροι να «προσπεραστούν» από τον αλγόριθμο και να μην βρεθούν ποτέ, ενώ εάν ο ρυθμός είναι πολύ μικρός τότε η διαδικασία ενημέρωσης θα είναι χρονοβόρα και ατελέσφορη. Γενικά όσο μικρότερος είναι ο ρυθμός εκπαίδευσης, τόσο μεγαλύτερος θα πρέπει να είναι ο αριθμός των «εποχών» (βλ. παρακάτω) εκπαίδευσης.



Εικόνα 3.6: Στην πρώτη περίπτωση ο ρυθμός εκπαίδευσης είναι αρκετά μικρός και δεν μπορεί να «ξεφύγει» από το τοπικό ελάχιστο. Στη δεύτερη έχει τέτοια τιμή ώστε να είναι ικανός να βρει το ολικό ελάχιστο. Τέλος στην τρίτη είναι αρκετά μεγάλος με αποτέλεσμα να μην σταθεροποιηθεί ποτέ η εκπαίδευση [75].

Ρυθμός μείωσης (Decay rate): Υπερπαράμετρος που ελαττώνει την τιμή του ρυθμού εκπαίδευσης κάθε φορά που ολοκληρώνεται μια «εποχή», ή ανακαλύπτεται ένα τοπικό ελάχιστο. Η μείωση μπορεί να είναι εκθετική ή διακριτή σε συγκεκριμένες τιμές [76,77].

Ορμή (Momentum): Μέθοδος που επιταχύνει την διαδικασία της εκπαίδευσης, βοηθώντας την εύρεση του τοπικού (ή ολικού) ελάχιστου [78].

Εποχές (Epochs): Ο BP αλγόριθμος πραγματοποιείται περισσότερες από μια φορές στα δεδομένα. Κάθε φορά που όλα τα δεδομένα εκπαίδευσης επεξεργάζονται από τον αλγόριθμο, ολοκληρώνεται μια «εποχή» [79].

Μέγεθος παρτίδας (Batch size): Ως μέγεθος παρτίδας ορίζεται το σύνολο των δεδομένων που εισέρχονται στο ΤΝΔ για να υλοποιηθεί ένας πλήρης κύκλος εκπαίδευσης. Όταν το πλήθος των δεδομένων στα οποία εκπαιδεύεται το ΤΝΔ είναι μεγάλο, τότε συνηθίζεται να «σπάει» σε παρτίδες, προκειμένου να διευκολυνθεί η διαδικασία και να γίνει ταχύτερα [66,67,79].

Βελτιστοποιητής (Optimizer): Είναι ο αλγόριθμος με τον οποίο το δίκτυο εκπαιδεύεται και ανανεώνει τα χαρακτηριστικά του. Ο πιο συνηθισμένος είναι ο «καθόδου/ελάττωσης κλίσης» (Gradient Descent – GD) στον οποίο αναφερθήκαμε και παραπάνω. Στην παρούσα εργασία χρησιμοποιήθηκε η στοχαστική παραλλαγή του Stochastic Gradient Descent - SGD, κατά την οποία βρίσκεται το ολικό ελάχιστο σε τυχαία επιλεγμένα δεδομένα του συνόλου δεδομένων (dataset). Πλεονεκτήματα της παραλλαγής SGD έναντι του κλασικού GD, είναι η συχνότητα ανανέωσης των τιμών βάρους και η χρήση λιγότερης μνήμης και υπολογιστικής ισχύος. Το κύριο πλεονέκτημα είναι το γεγονός ότι η εκπαίδευση σπάνια έως ποτέ δεν θα έχει τα ίδια αποτελέσματα και ως υπάρχουν οι ίδιες συνθήκες εκπαίδευσης, δεδομένης της στοχαστικής φύσης του αλγόριθμου [79,80].

Σύνολο δεδομένων (Dataset): Για την εκπαίδευση ενός ΤΝΔ, αλλά και για την αξιολόγησή του, απαιτούνται δεδομένα. Π.χ. όταν οι LeCun, et, al., (1989) δημιούργησαν ΤΝΔ που διακρίνει χειρόγραφους αριθμούς από 0 έως 9, χρησιμοποίησαν ένα πλήθος στοιχείων που απεικόνιζαν το 0, πλήθος στοιχείων που απεικόνιζαν τον 1, κ.ο.κ. Όλα τα στοιχεία ανήκουν σε ένα σύνολο που ονομάζεται βάση δεδομένων σύνολο δεδομένων [81].

Η βάση δεδομένων περιέχει το σύνολο των στοιχείων που συμβάλουν στην εκπαίδευση και στην αξιολόγηση του δικτύου. Χωρίζεται σε 3 σύνολα (sets):

(i) Σύνολο εκπαίδευσης (Training set), το σύνολο το οποίο περιέχει τα στοιχεία τα οποία εκπαιδεύουν το δίκτυο,

(ii) Σύνολο επικύρωσης/πιστοποίησης (Validation set), το οποίο περιέχει στοιχεία τα οποία αξιολογούν το δίκτυο κατά τη διάρκεια της εκπαίδευσης. Είναι δείκτης της ποιότητας της εκπαίδευσης. Τέλος,

(iii) Σύνολο δοκιμής (Test set), το οποίο περιέχει στοιχεία που αξιολογούν το δίκτυο μετά το πέρας της εκπαίδευσης [81,82].

«Υπερ-εκπαίδευση και υπο-εκπαίδευση» (Overfitting & Underfitting): Η υπερ-εκπαίδευση και η υπο-εκπαίδευση είναι περιπτώσεις όπου η εκπαίδευση του ΤΝΔ έχει αποτύχει. Ως υπερ-εκπαίδευση ορίζεται η αδυναμία του ΤΝΔ να γενικεύει σε

άγνωστα δεδομένα. Σε αυτή την περίπτωση, το δίκτυο έχει «μάθει» με μεγάλη λεπτομέρεια τα δεδομένα στα οποία εκπαιδεύεται. Τρόπος αντιμετώπισης είναι η αύξηση του Dropout (βλ. παρακάτω). Αντιθέτως η υπο-εκπαίδευση είναι η αδυναμία του δικτύου να «κατανοήσει», δηλ. να κατηγοριοποιήσει σωστά, ακόμα και μόνο τα δεδομένα στα οποία εκπαιδεύεται. Τρόπος αντιμετώπισης είναι η αύξηση του συνόλου εκπαίδευσης [83].

Απόρριψη (Dropout): Η απόρριψη είναι τεχνική που «απενεργοποιεί» ορισμένους νευρώνες από ένα δοθέν επίπεδο του ΤΝΔ. Χρησιμοποιείται προκειμένου να αποφευχθεί η εξάρτηση της εξόδου του ΤΝΔ, σε βαθμό πέραν του δέοντος (το οποίο βέβαια δεν γνωρίζουμε εκ των προτέρων) , από τα δεδομένα εκπαίδευσης. Σύμφωνα με τους Bluche, et, al., (2015), όταν το ΤΝΔ περιέχει LSTM νευρώνες το Dropout αξιοποιείται όταν βρίσκεται κοντά στην είσοδο και την έξοδο του ΤΝΔ [84,85]¹.

¹ Στα επόμενα θα χρησιμοποιούμε τους αγγλικούς όρους των υπερπαραμέτρων, καθόσον οι ελληνικοί δεν έχουν ακόμη παγιωθεί και είναι ευκολότερο να αναγνωριστούν οι ξένοι όροι από έναν αναγνώστη που θα διαβάσει απευθείας τις επόμενες ενότητες, ενδιαφερόμενος μόνο για τα αποτελέσματα της παρούσας εργασίας.

ΚΕΦΑΛΑΙΟ 4

Ανάλυση αλγόριθμου που αναπτύχθηκε και παρουσίαση αποτελεσμάτων

Εισαγωγή


Στο παρόν κεφάλαιο αναλύεται ο αλγόριθμος που αναπτύχθηκε στα πλαίσια της παρούσης εργασίας. Το αρχικό σήμα του ΗΕΓ αρχικά φιλτράρεται και επιλέγονται τα τμήματα του οποίου αντιστοιχούν στις ατράκτους και τμήματα που αντιστοιχούν σε μη-ατράκτους. Εν συνεχεία η εφαρμογή ενός κυλιόμενου παραθύρου αυξάνει το πλήθος των δειγμάτων, διευκολύνοντας τελικά την εκπαίδευση του δικτύου. Παρουσιάζονται διάφορες αρχιτεκτονικές του δικτύου και τελικά τα αποτελέσματα της μάθησης.

4.1. Τα δεδομένα που χρησιμοποιήθηκαν

Τα σήματα ΗΕΓ, που χρησιμοποιήθηκαν στην παρούσα εργασία, αντλήθηκαν από τη βάση δεδομένων *Dream Database* του Πανεπιστημίου MONS (TCTS Laboratory) των Stéphanie Devuyst και Thierry Dutoit και του Ελεύθερου Πανεπιστημίου των Βρυξελλών (Charleroi Sleep Laboratory) της Myriam Kerkhofs, υπό τους όρους Αναφορά-Μη Εμπορική-Παρόμοια Διανομή 3.0 μη εισαγόμενη άδεια (Attribution-NonCommercial-NoDerivs 3.0 Unported (CC BY-NC-ND 3.0) License).

Πρόκειται για καταγραφές που έγιναν σε εργαστήριο ύπνου νοσοκομείου με πολυγράφο 32 καναλιών (BrainnetTM System, MEDATEC, Brussels, Belgium), ενώ για την αποθήκευσή τους χρησιμοποιήθηκε το πρότυπο European Data Format (EDF). Η διάρκεια των σημάτων είναι 30 λεπτά με συχνότητα δειγματοληψίας 200 Hz.


Η *Dream Database* περιέχει οκτώ ΗΕΓ διάρκειας 30 λεπτών, με συχνότητα καταγραφής 200 Hz. Δύο ειδικοί ιατροί ύπνου κλήθηκαν να ανιχνεύσουν (μεταξύ άλλων χαρακτηριστικών κυματομορφών) τις υπνικές ατράκτους και κατέγραψαν τα αποτελέσματά τους σε οκτώ διαφορετικά αρχεία, ένα για κάθε ΗΕΓ. Το κάθε αρχείο είχε δύο στήλες, η πρώτη υποδείκνυε την χρονική στιγμή εκκίνησης της ατράκτου και η δεύτερη την χρονική της διάρκεια.



Εικόνα 4.1: Αφιλτράριστο σήμα ΗΕΓ διάρκειας 10 δευτερολέπτων.

4.2. Εξαγωγή και επεξεργασία δειγμάτων – Φιλτράρισμα και εφαρμογή κυλιώμενου παράθυρου

Το Dataset που χρησιμοποιήθηκε για την εκπαίδευση του ΤΝΔ αποτελείται από παραδείγματα διάρκειας ενός δευτερολέπτου. Δεδομένου ότι η συχνότητα δειγματοληψίας είναι $f_{sampling} = 200 \text{ Hz}$, το «μήκος» (length) κάθε δείγματος θα είναι ίσο με 200 τιμές μV . Η επιλογή των ατράκτων έγινε με γνώμονα την ανίχνευση ενός εκ των δύο ειδικών (διότι μόνο ένας εξ αυτών έδινε και την διάρκεια της ατράκτου), ενώ για τις μη-ατράκτους, που προέρχονταν από τμήματα του ΗΕΓ όπου δεν είχε ανιχνευθεί άτρακτος, εφαρμόστηκε αυστηρό άνω κατώφλι επιλογής στα 5 μV κατά απόλυτη τιμή, αφού το ΗΕΓ πέρασε πρώτα από ζωνοπερατό φίλτρο (Band Pass Filter – BPF) στο εύρος των [11-16] Hz.

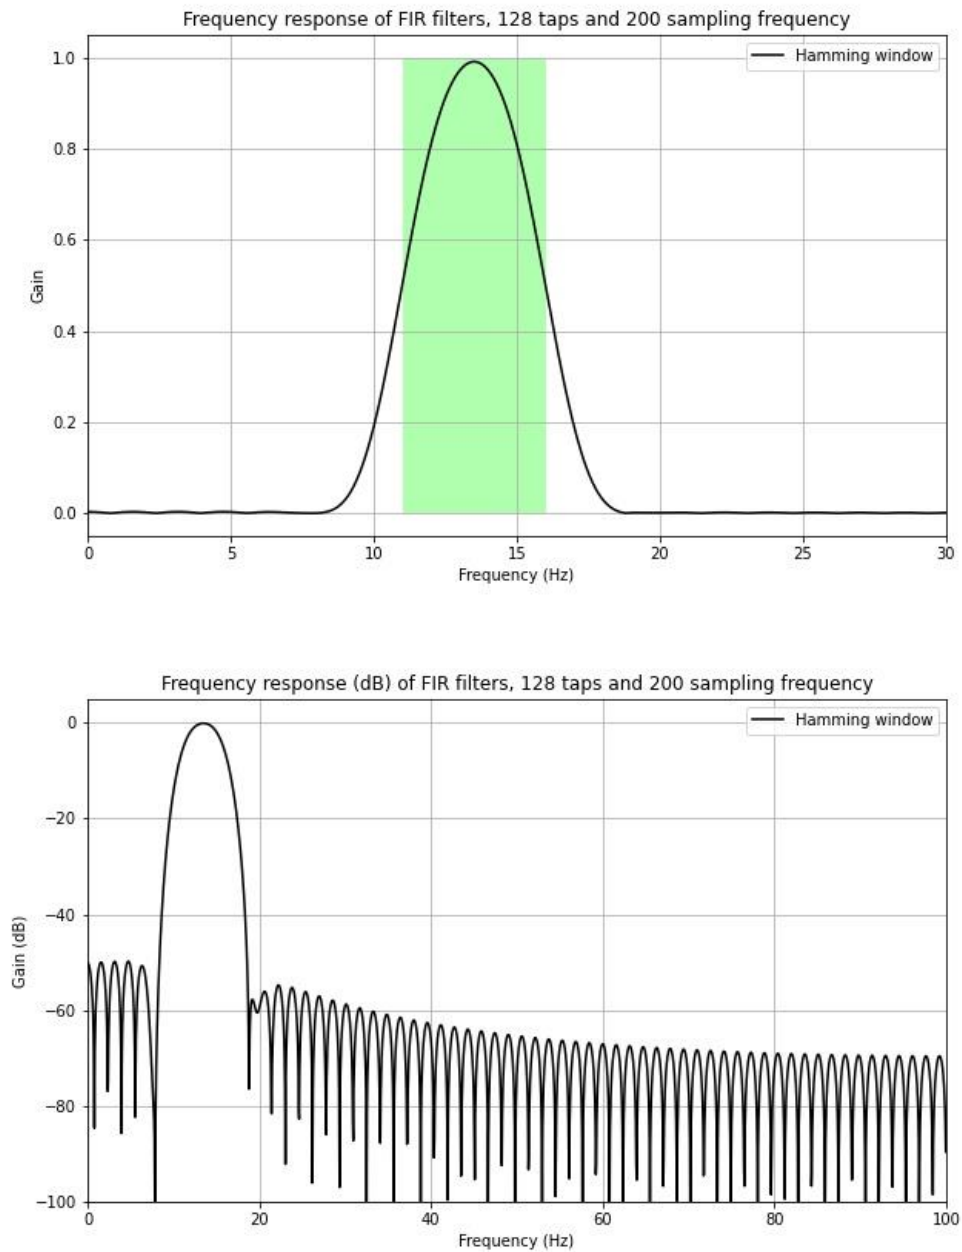


Εικόνα 4.2: Στο πάνω γράφημα απεικονίζεται ένα τμήμα ατράκτου (ακατέργαστη και φιλτραρισμένη) ενώ στο κάτω ένα τμήμα μη-ατράκτου (ακατέργαστη και φιλτραρισμένη).

4.2.1 Φιλτράρισμα δειγμάτων

Απαραίτητο κρίθηκε το φιλτράρισμα για την περαιτέρω επεξεργασία των δειγμάτων. Επιλέχθηκε Finite Impulse Response (FIR) ζωνοπερατό φίλτρο με συχνότητες αποκοπής 11 και 16 Hz, για να καλυφθεί όλο το εύρος συχνοτήτων που εμφανίζουν οι άτρακτοι [86].

Το φίλτρο εφαρμόστηκε με παράθυρο Hamming (Hamming Window), ένα από τα πιο χρησιμοποιημένα και καλύτερα βάσει του Signal to Noise Ratio (SNR) που δίνει για επεξεργασία ΗΕΓ σήματος [87].



Εικόνα 4.3: (α) Εδώ απεικονίζεται η απόκριση συχνότητας. Με πράσινο απεικονίζεται το ιδανικό φίλτρο, ενώ με μαύρο το πραγματικό που υλοποιεί το λογισμικό (β) Απεικονίζεται η απόκριση συχνότητας σε dB.

4.2.2 Εφαρμογή κυλιόμενου παράθυρου

Μετά το φιλτράρισμα το κάθε τμήμα διάρκειας 1 sec (“δείγμα» εκπαίδευσης/πιστοποίησης/ελέγχου, δεν πρέπει να συγχέεται με το δείγμα του διεγματολήπτη, δηλ. την μεμονωμένη τιμή δυναμικού ανά 5msec) ξεχωριστά υπεβλήθη σε κυλιόμενο παράθυρο, με μήκος $l = 100$ και με βήμα $n = 1$. Η τεχνική αυτή είχε σαν αποτέλεσμα τη δημιουργία 100 «υπο-δειγμάτων» με όρια $[i, i + l - 1]$, όπου i η αρχή του «υπο-δείγματος» και $i \in [1, 101]$ [88].

Ο λόγος που έγινε η δημιουργία των υπο-δειγμάτων ήταν για να δημιουργήσουμε ακολουθίες συνδεδεμένων χρονοσειρών, όπως απαιτεί η τεχνική LSTM.

Τα στοιχεία των δειγμάτων ήταν αρχικά ένας δισδιάστατος πίνακας $[126 \times 200]$, όπου 126 αντιστοιχεί στο πλήθος των δειγμάτων και το 200 στο πλήθος τιμών μV της καταγραφής, διάρκειας ενός δευτερόλεπτου. Το κυλιόμενο παράθυρο είχε σαν αποτέλεσμα την μεταβολή αυτού του πίνακα σε πίνακα διαστάσεων $[126, 100, 100]$.

Η παραπάνω μορφή/διάταξη στηλών και γραμμών των μητρώων επιλέχθηκε γιατί τα δεδομένα έπρεπε να «τροφοδοτηθούν» στο Keras σε μορφή $[k, m, n]$ (Βλ. Παράρτημα 1).

4.2.3 Δημιουργία dataset

Το Dataset, σύμφωνα με όσα έχουν γραφτεί στα προηγούμενα κεφάλαια, χωρίστηκε σε τρεις κατηγορίες:

	Κατηγορία	Διαστάσεις Πίνακα	Ποσοστό επί των συνολικών δειγμάτων	Πλήθος ατράκτων / Πλήθος μη-ατράκτων
(i)	X train	[90,100,100]	~70%	45 / 45
(ii)	X val	[26,100,100]	~20%	13 / 13
(iii)	X test	[10,100,100]	~10%	5 / 5

Πίνακας 4.1: Τα σύνολα που χρησιμοποιήθηκαν για την εκπαίδευση, την πιστοποίηση και τον έλεγχο του δικτύου.

Δημιουργήθηκαν και αντίστοιχοι πίνακες για τις θεωρητικές τιμές που πρέπει να έχει στην έξοδο του το TND, αναλόγως το δείγμα εισόδου. Δεδομένου ότι η έξοδος του TND ήταν μόνο ένας νευρώνας, θα έπρεπε για είσοδο δείγματος ατράκτου η έξοδος να έχει τιμή «1» και για είσοδο δείγματος μη-ατράκτου η έξοδος να έχει τιμή «0».

Επομένως, έχουμε:

	Κατηγορία	Διαστάσεις Πίνακα	Ποσοστό επί των συνολικών δειγμάτων	Πλήθος ατράκτων / Πλήθος μη-ατράκτων
(i)	Y train	[90,1]	~70%	45 / 45
(ii)	Y val	[26,1]	~20%	13 / 13
(iii)	Y test	[10,1]	~10%	5 / 5

Πίνακας 4.2: Τα σύνολα που χρησιμοποιήθηκαν για τα θεωρητικά αποτελέσματα που πρέπει να έχει η έξοδος του δικτύου.

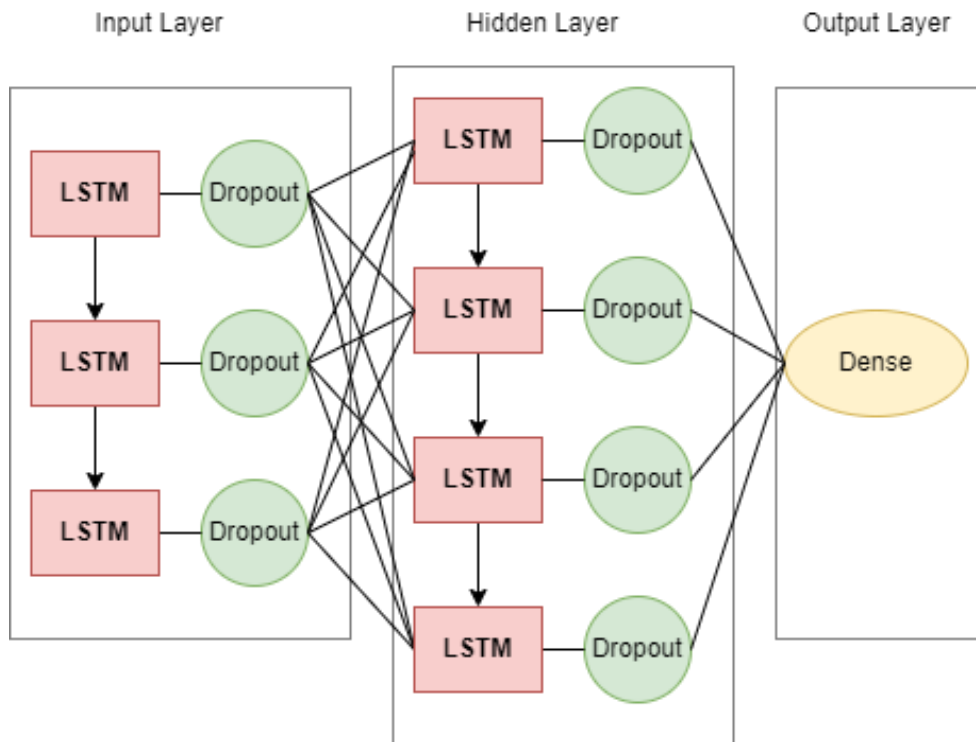
Ιδιαίτερη σημασία για τη σωστή εκπαίδευση, έχει η αντιστοιχία των συνόλων X και Y. Για παράδειγμα έστω ότι η ακολουθία (X train [k-1], X train [k], X train [k+1]), «μεταφράζεται» σε (άτρακτος, άτρακτος, μη-άτρακτος) θα πρέπει τότε και το (Y train [k-1], Y train [k], Y train [k+1]), να «μεταφράζεται» σε (άτρακτος, άτρακτος, μη-άτρακτος) ή βάσει των ανωτέρω (1,1,0). Ομοίως και για τα υπόλοιπα σύνολα πιστοποίησης και ελέγχου (validation & test sets).

4.3 Στήσιμο Δικτύου – Υπερπαράμετροι και Αρχιτεκτονικές

Στα πλαίσια της παρούσας διπλωματικής εργασίας, αναπτύχθηκαν και εκπαιδεύτηκαν αρκετά ΤΝΔ, με το επίπεδο εισόδου και τα ενδιάμεσα να αποτελούνται όλα αποκλειστικά από νευρώνες LSTM. Όλα τα δίκτυα είχαν τρία επίπεδα:

- i. Είσοδος
- ii. Κρυφό επίπεδο
- iii. Έξοδος

Η Έξοδος όπως προαναφέρθηκε είχε έναν απλό νευρώνα με σιγμοειδή συνάρτηση ενεργοποίησης, αρκετό για να καλύψει τις ανάγκες δυαδικής κατηγοριοποίησης. Για τιμή του τελικού νευρώνα μεγαλύτερη ή ίση με 0,5, η κυματομορφή εισόδου χαρακτηριζόταν ως άτρακτος, ενώ για μικρότερη του 0, ως μη-άτρακτος.



Εικόνα 4.4: Εδώ παρουσιάζεται η δομή ενός Δικτύου που εκπαιδεύτηκε για την ανίχνευση ατράκτων. Το επίπεδο εισόδου έχει τρεις νευρώνες LSTM, ενώ το ενδιάμεσο τέσσερις. Το Dropout δεν πρέπει να θεωρείται σαν ξεχωριστό επίπεδο ή ξεχωριστός νευρώνας. Στην εικόνα αυτή παρουσιάζεται το Dropout κατ' αυτόν τον τρόπο, για να γίνει κατανοητό ότι εφαρμόζεται σε κάθε νευρώνα .

4.3.1 Υπερπαράμετροι, εκπαίδευση και παρουσίαση αποτελεσμάτων

Αρχικά το σύνολο υπερπαράμετρων που επιλέχθηκαν ήταν το:

Set 1

- learning rate = 0,01
- momentum = 0,7
- decay rate = 0,00001 (1e-5)

Οι υπερπαράμετροι αυτές εφαρμόστηκαν σε μια πληθώρα αρχιτεκτονικών (ως προς τον αριθμό των νευρώνων των επιπέδων εισόδου και του ενδιάμεσου επιπέδου και του dropout) προς εύρεση της καλύτερης δυνατής.

Για τη συνέχεια της εργασίας να σημειωθεί ότι το όνομα του μοντέλου εξηγεί την αρχιτεκτονική και την τιμή του dropout. Δηλαδή χρησιμοποιούμε την μορφή Model_BC_D, όπου B και C αντιπροσωπεύουν το πλήθος των νευρώνων στο επίπεδο Εισόδου και στο Κρυφό επίπεδο αντίστοιχα και D = Dropout (%) / 10%.

Πρώτος δείκτης για την αξιολόγηση της εκπαίδευσης ήταν ο Πίνακας Αλήθειας που προκύπτει. Ο Πίνακας Αλήθειας προκύπτει από το Test set, το οποίο αποτελείται από 10 δείγματα.

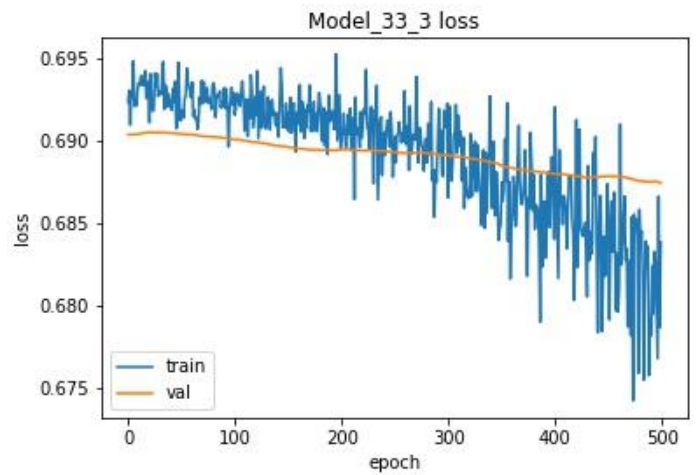





learning rate = 0.01, momentum = 0.7, decay rate = 1e-5, epochs = 500				
	Confusion Matrix		Accuracy	
Model_32_3		PREDICTED		70
	TRUE	4	1	
		2	3	
Model_33_4		PREDICTED		60
	TRUE	3	2	
		2	3	
Model_33_3		PREDICTED		60
	TRUE	4	1	
		3	2	
Model_43_4		PREDICTED		80
	TRUE	5	0	
		2	3	
Model_43_3		PREDICTED		90
	TRUE	5	0	
		1	4	

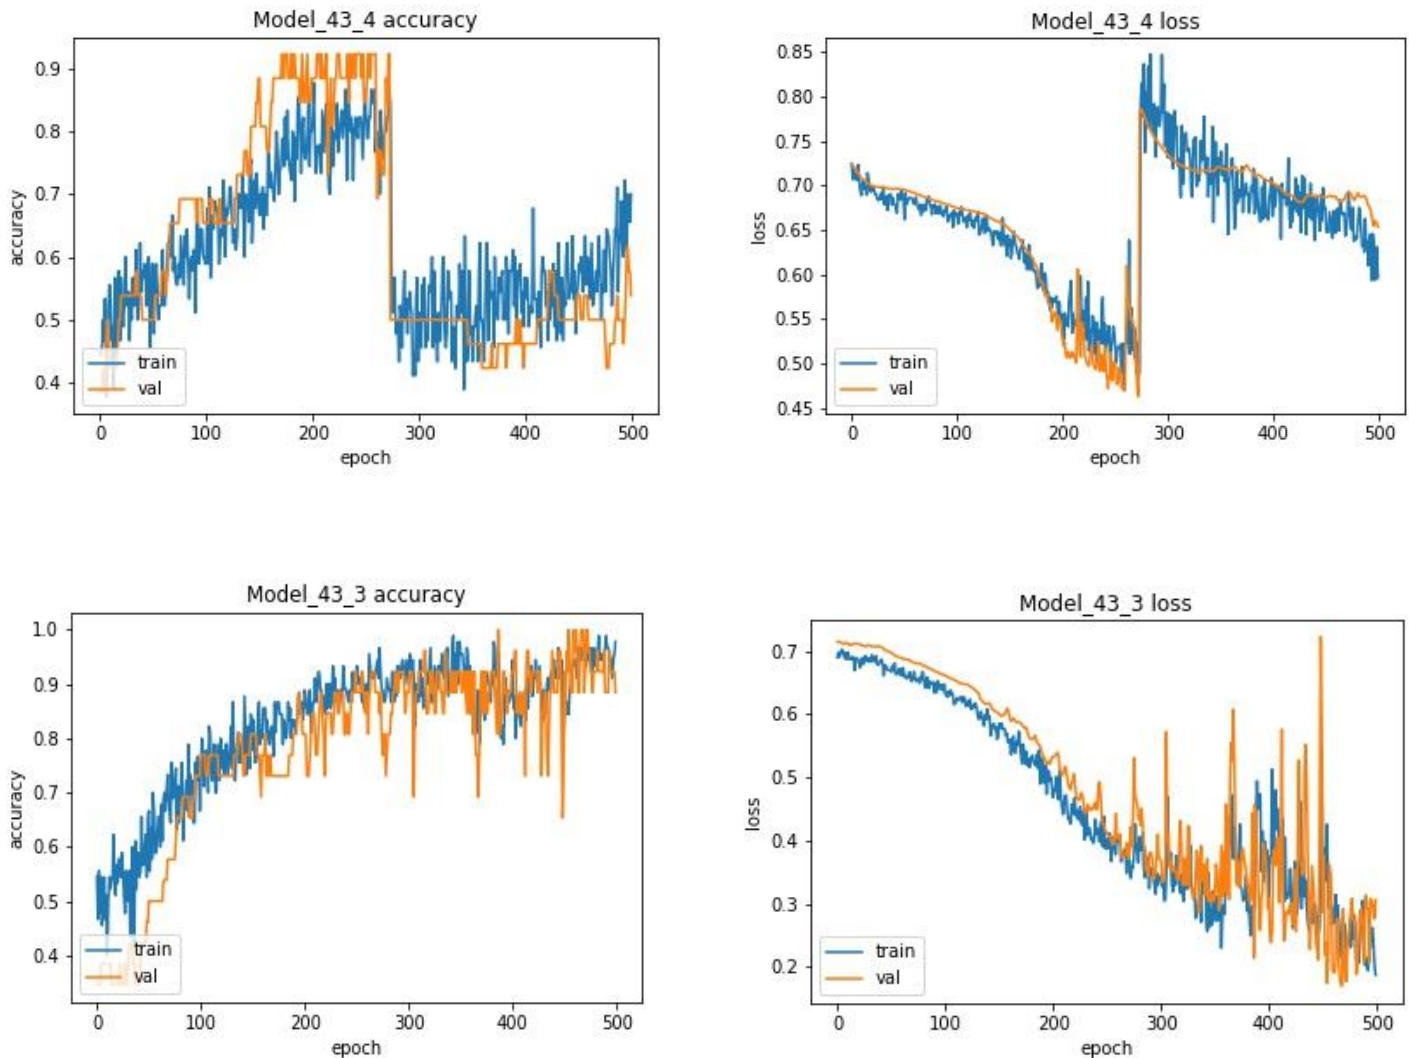
Πίνακας 4.3: Πίνακας Αλήθειας για set υπερπαραμέτρων 1 και epochs = 500.

Επίσης ιδιαίτερη σημασία για την ποιότητα της εκπαίδευσης έχουν και τα γραφήματα που παρουσιάζουν την «Ακρίβεια» (“Accuracy”) και την «Απώλεια» (“Loss”) του δικτύου, για τα σύνολα εκπαίδευσης (“train”) και πιστοποίησης (“val”). Ακολουθούν παρακάτω εικόνες που δείχνουν την εξέλιξη των παραμέτρων αυτών στην διάρκεια της εκπαίδευσης εκάστου δικτύου.

Για τον υπολογισμό της Accuracy μέσω Keras, δημιουργούνται δύο τοπικές μεταβλητές total και count. Οι μεταβλητές αυτές υπολογίζουν τη συχνότητα που η y_predicted (πραγματική έξοδος δικτύου) ισούται με την y_true (θεωρητική έξοδος δικτύου). Η τιμή της Accuracy είναι το πηλίκο $\frac{total}{count}$, όπου total: το πλήθος των τιμών που ισχύει y_predicted = y_true και count: το πλήθος των στοιχείων στο y_total (ή στο y_true)

Για τον υπολογισμό της Loss μέσω Keras αρκεί να ανατρέξουμε στην εξίσωση (3.10), μιας και στο δίκτυο που αναπτύχθηκε χρησιμοποιείται η Binary Crossentropy (Βλ. Παράρτημα 1).





Εικόνες 4.5: Γραφήματα εκπαίδευσης για σύνολο υπερπαραμέτρων 1 και 500 εποχές.

Με εξαίρεση το Model_33_4, όλα τα υπόλοιπα μοντέλα παρουσιάζουν προβλήματα στην εκπαίδευση, εκ των οποίων συχνότερο είναι το φαινόμενο εξαιρετικής αστάθειας (με πολύ μεγάλη ανεπιθύμητη αύξηση τιμών) της Απώλειας (Loss) από μια τιμή εποχών και πάνω (Model_32_3 στο διάστημα των 400 – 500 epochs, Model_43_4 στο διάστημα των 200 – 500 epochs και στο Model_43_4 στο διάστημα των 300 – 500 epochs) που συνδυάζεται με έντονη μείωση της ακρίβειας (που προηγουμένως φαινόταν να οδηγεί σε overfitting). Οι τιμές για το Model_33_3 δεν φαίνεται να μεταβάλλονται κατά τη διάρκεια της εκπαίδευσης, ενώ παρατηρείται Underfitting.

Οι παραπάνω αστάθειες, σε συνδυασμό με το γεγονός ότι δεν έχουμε κάποιο κριτήριο για να σταματήσουμε την εκπαίδευση πριν ξεκινήσει η αστάθεια επιβάλλουν την διερεύνηση και άλλων τιμών υπερπαραμέτρων.

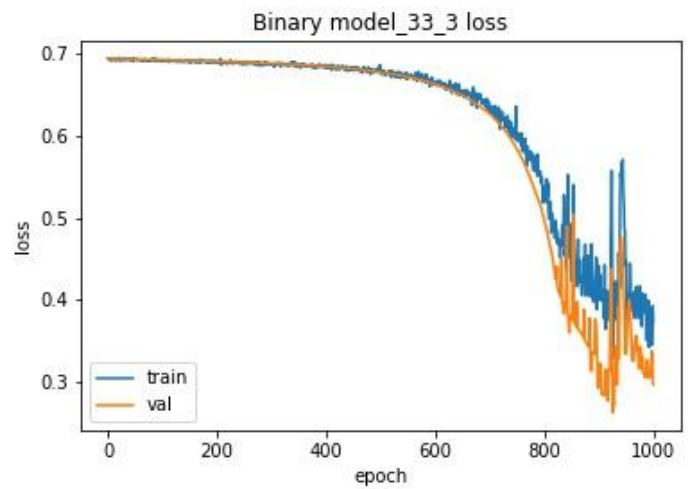
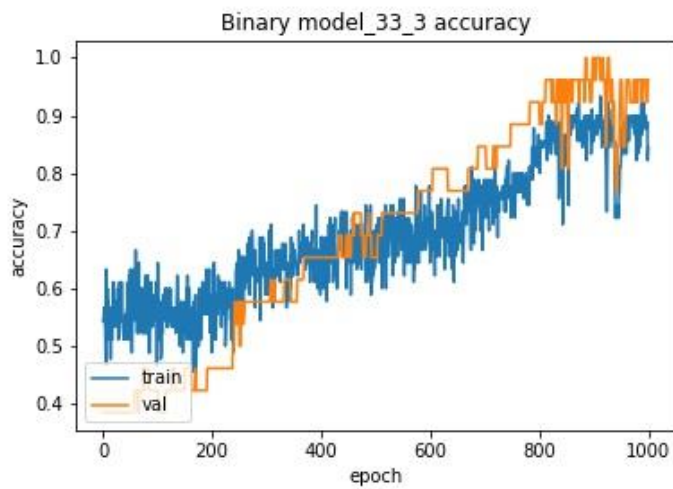

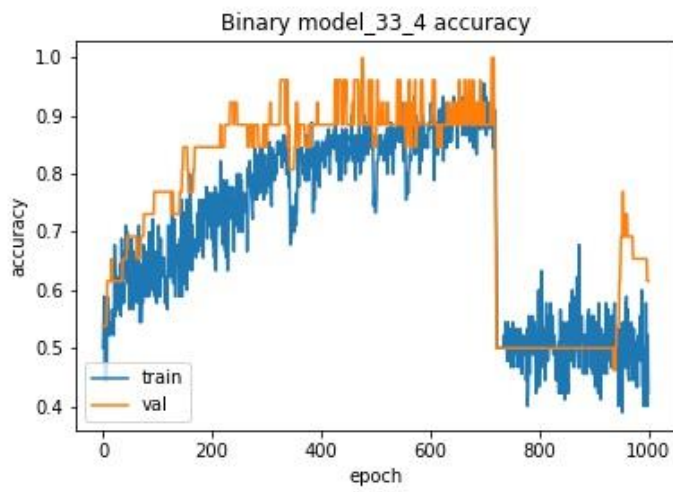

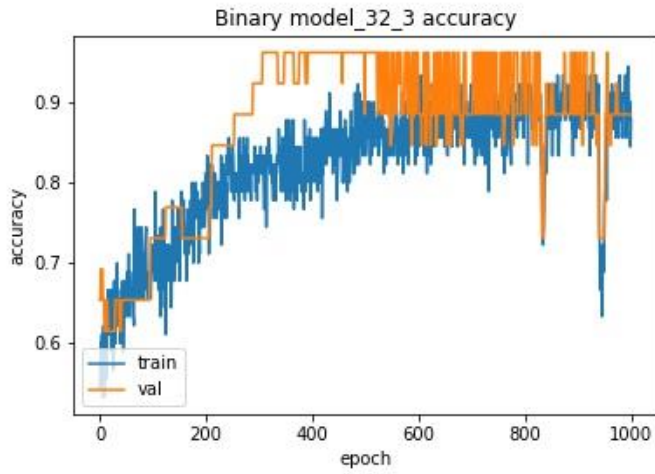
Από την άλλη, ο ομαλός τρόπος που ελαττώνεται η Απώλεια στο Model_33_4 καθ' όλη τη διάρκεια της εκπαίδευσης, στο Model_32_3 στο διάστημα 0 έως 300 epochs και στο Model_43_3 στο διάστημα 0 έως 200 epochs, αλλά και η τιμές της Ακρίβειας

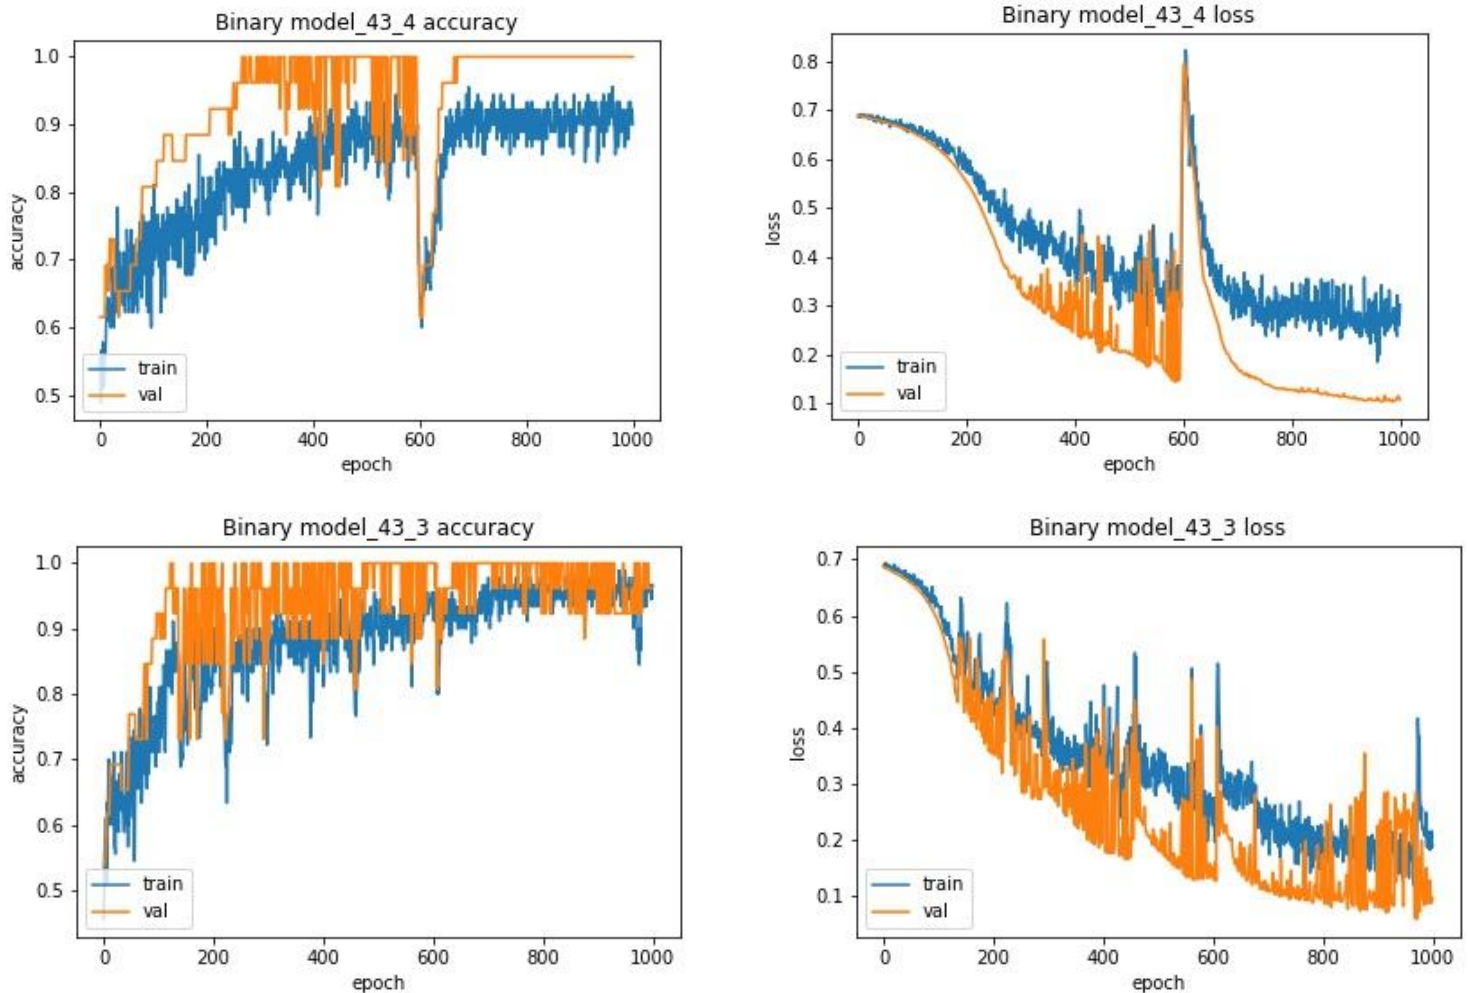
του Πίνακα Αλήθειας, δίνουν ενδείξεις ότι το τελικό αποτέλεσμα της εκπαίδευσης μπορεί να γίνει καλύτερο.

Μια πρώτη προσέγγιση είναι να επαναλάβουμε τα παραπάνω εκ νέου για 1000 εποχές. Ο Πίνακας Αλήθειας και τα γραφήματα της εκπαίδευσης παρουσιάζονται στην συνέχεια.

learning rate = 0.01, momentum = 0.7, decay rate = 1e-5, epochs = 1000				
	Confusion Matrix		Accuracy	
Model_32_3	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_33_4	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_33_3	TRUE	PREDICTED		80
		4	1	
		1	4	
Model_43_4	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_43_3	TRUE	PREDICTED		100
		5	0	
		0	5	

Πίνακας 4.4: Πίνακας Αλήθειας για σύνολο υπερπαραμέτρων 1 και 1000 εποχές.





Εικόνες 4.6: Γραφήματα εκπαίδευσης για σετ υπερπαραμέτρων 1 και epochs = 1000.

Οι τιμές του Πίνακα Αλήθειας δίνουν βελτιωμένες τιμές στις περισσότερες περιπτώσεις, όμως σε όλες τις περιπτώσεις είχαμε πάλι επεισόδια αστάθειας, όπως και για 500 εποχές, στην τιμή της Απώλειας. Κατέστη λοιπόν προφανές ότι χρειάζονται δοκιμές και άλλων τιμών για τις υπερπαραμέτρους.

Το νέο σύνολο υπερπαραμέτρων που επιλέχθηκαν ήταν το:

Set 2

- learning rate = 0,005
- momentum = 0,5
- decay rate = 0,000001 (1e-6)





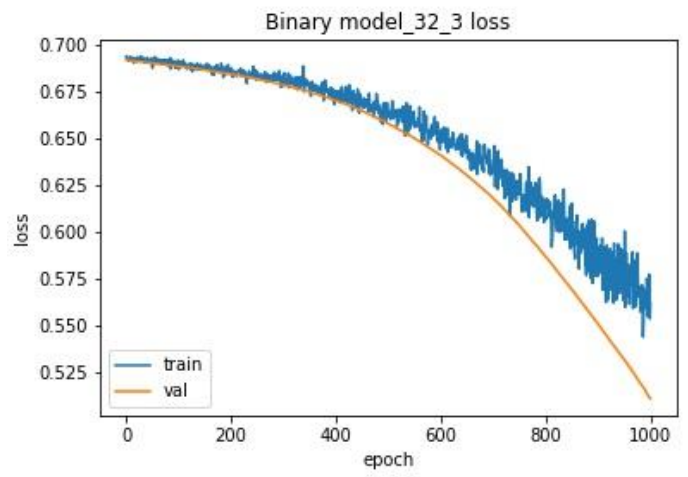

Αποτελεί γενική αρχή ότι όταν έχουμε φαινόμενα αστάθειας στην εκπαίδευση, το πιθανότερο είναι ότι οι τιμές των υπερπαραμέτρων (με κύριες τον ρυθμό εκμάθησης και το decay rate) πρέπει να μειωθούν δραστικά, αρκετές τάξεις μεγέθους (και ενδεχομένως αργότερα πάλι σταδιακά να αυξηθούν, αν δεν επιτευχθούν

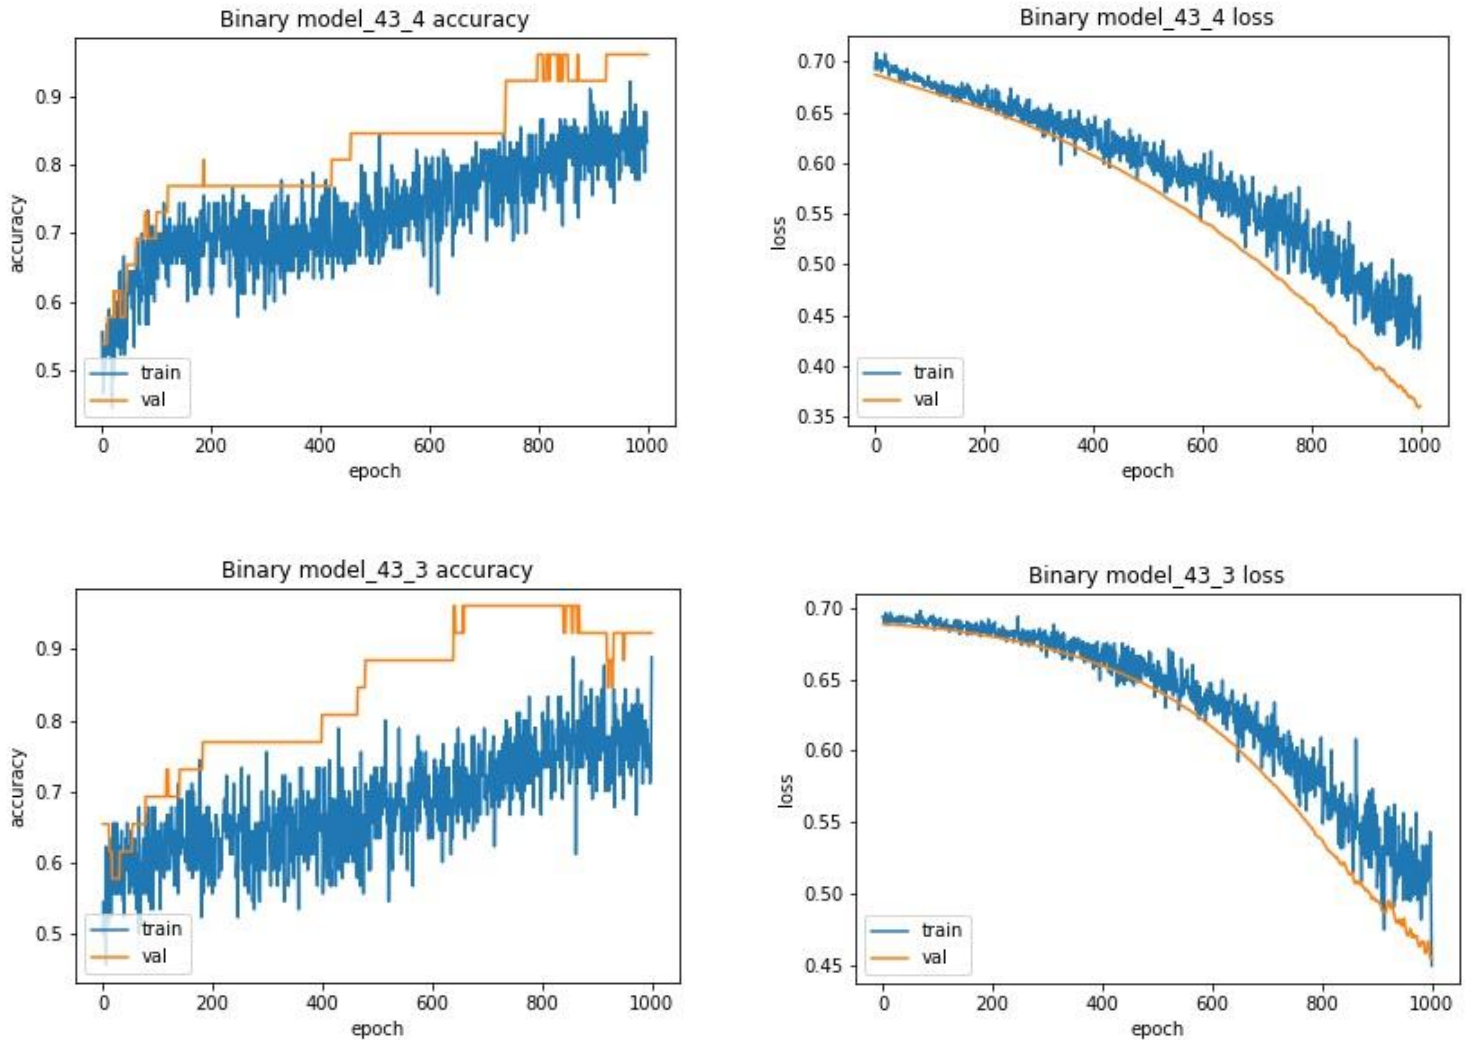
ικανοποιητικά αποτελέσματα). Για αυτό οι υπερπαραμέτροι του συνόλου 2 έχουν μικρότερες τιμές από εκείνες του συνόλου 1, ειδικότερα δε ο ρυθμός εκμάθησης και το decay rate. Επίσης εξ αρχής αποφασίστηκε να έχουμε 1000 εποχές.

Στη συνέχεια παρουσιάζεται ο Πίνακας Αλήθειας, μαζί με τα γραφήματα της εκπαίδευσης.

learning rate = 0.005, momentum = 0.5, decay rate = 1e-6, epochs = 1000				
	Confusion Matrix		Accuracy	
Model_32_3	TRUE	PREDICTED		90
		4	1	
		0	5	
Model_33_4	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_33_3	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_43_4	TRUE	PREDICTED		100
		5	0	
		0	5	
Model_43_3	TRUE	PREDICTED		90
		4	1	
		1	4	

Πίνακας 4.5: Πίνακας Αλήθειας για σύνολο υπερπαραμέτρων 2 και 1000 εποχές.











Εικόνες 4.7: Γραφήματα εκπαίδευσης για σύνολο υπερπαράμετρων 2 και 1000 εποχές.

Η εικόνα που παρουσιάζουν τα γραφήματα για set υπερπαράμετρων 2 σε συνδυασμό με τις υψηλές τιμές Ακρίβειας του Πίνακα Αλήθειας, καθιστούν την εκπαίδευση επιτυχημένη. Ξεχωρίζει η ομαλότητα στο γράφημα Απώλειας του Model_33_3 και οι χαμηλές τιμές της Απώλειας για Model_43_4 και Model_43_3.

4.3.2 Εκπαίδευση με διαφορετική αρχιτεκτονική δικτύου

Για την διερεύνηση παραλλαγών της αρχιτεκτονικής του δικτύου, έγινε δοκιμή με δύο νευρώνες στην έξοδό του. Η συνάρτηση ενεργοποίησης των νευρώνων ήταν σιγμοειδής και η ανίχνευση ατράκτου αντιστοιχούσε σε έξοδο (1,0), ενώ μη-ατράκτου αντιστοιχούσε σε έξοδο (0,1).

Παρουσιάζονται ορισμένα γραφήματα που προέκυψαν από την εκπαίδευση για σύνολο υπερπαράμετρων 2 και 1000 εποχές.



Εικόνες 4.8: Γραφήματα εκπαίδευσης για σύνολο υπερπαραμέτρων 2, 1000 εποχές και δύο νευρώνες εξόδου.

Η αρχιτεκτονική αυτή γρήγορα απορρίφθηκε λόγω αστάθειας στην Απώλεια (αυξημένος αριθμός αιχμών-spikes) και συχνή «κατάρρευση» της ακρίβειας του δικτύου.

5. Συζήτηση & Συμπεράσματα

Ως συμπέρασμα μπορούμε να αναφέρουμε ότι με την διερεύνηση των υπερπαραμέτρων εντοπίστηκε ένας συνδυασμός τους που, σε σχετικά μικρό αριθμό εποχών (1000) πετυχαίνει πολύ ικανοποιητικές τιμές Ακρίβειας, με μικρές Απώλειες και χωρίς αστάθειες στην εξέλιξη των τιμών των παραμέτρων ελέγχου. Επίσης, εφόσον επιλεγθούν ορθά οι υπερπαραμέτροι, δεν έχει ιδιαίτερη σημασία η ακριβής τιμή του αριθμού των νευρώνων των ενδιάμεσων στρωμάτων και της τιμής του dropout, γεγονός που αυξάνει την εμπιστοσύνη στα αποτελέσματά μας.

Το κυριότερο μειονέκτημα της μεθόδου είναι ότι δεν έχουμε την βεβαιότητα ότι οι υψηλές επιδόσεις μπορεί να επαναληφθούν με το υπάρχον εκπαιδευμένο δίκτυο και σε άλλα σύνολα δεδομένων. Μια εξασφάλιση για αυτό θα μπορούσε να παρέχει το σταμάτημα της εκπαίδευσης όταν η τιμή της ακρίβειας στο σύνολο πιστοποίησης αγγίζει για πρώτη φορά την τιμή 0,9.

Επιπλέον, επειδή το σύνολο καταγραφών που προσφέρει η βάση είναι περιορισμένο όσον αφορά πλήθος υγιών και ασθενών, καθώς και εύρος ηλικιών και είδους παθολογιών, εγείρονται αμφιβολίες για την δυνατότητα γενίκευσης των αποτελεσμάτων.

Αναφορές – Πηγές

- [1] Michail Teplan, (2002), "Fundamental of EEG Measurment", *Measurement Science Review*, 2, 2.
- [2] Berger, H., (1929): "Über das elektroencephalogramm des menschen", *Archiv für Psychiatrie und Nervenkrankheiten*, 87, 1, 527.
- [3] İnce R, Adanır SS, Sevmez F., (2021), "The inventor of electroencephalography (EEG): Hans Berger (1873–1941)", *Child's Nervous System*, 37, 2723.
- [4] Aboalayon, Khalid A.I., Miad Faezipour, Wafaa S. Almuhammadi, and Saeid Moslehpour, (2016), "Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation", *Entropy*, 18, 272.
- [5] Kandel, E. R., Schwatz, J. H., Jessell, T. M., (2016): "Βασικές Αρχές Νευροεπιστημών", *Εκδ. Π.Χ.Πασαλιδής*.
- [6] Hiatt, J. L., Gartner, L. P., (2010): "Textbook of head and neck anatomy", *Wolters Kluwer Health/Lippincott William & Wilkins*.
- [7] Kuffler, S.W., Nicholls, J.G., (1966): "The physiology of neuroglial cells", *Ergebnisse der Physiologie und exper. Pharmakologie*, 57, 1.
- [8] Βεντούρας, Ε. Χ., (2015): "Τεχνολογία της in-vivo διαγνωστικής - Διατάξεις παραγωγής βιοηλεκτρικών σημάτων", *Εκδ.ΣΕΑΒ- Κάλλιπος*.
- [9] Tatum, W. O., Husain., A. M., Bendadis, S. R., Kaplan, P. W., (2008): "Handbook of EEG Interpretation", *Demos Medical Publishing*.
- [10] Blum, A. S., Rutkove, S. B., (2007): "The Clinical Neurophysiology Primer", *Humana Press*.
- [11] Jackson, A. F., Bolger, D. J., (2014), "The neurophysiological bases of EEG and EEG measurement: A review for the rest of us", *Psychophysiology*, 51, 1061.
- [12] Piotr Olejniczak, (2006), "Neurophysiologic Basis of EEG", *Journal of Clinical Neurophysiology*, 23, 186.
- [13] Report of the committee on methods of clinical examination in electroencephalography, (1957), *Electroencephalography and Clinical Neurophysiology*, 10, 370.
- [14] Niedermeyer, E., (1999), "The Normal EEG of the Waking Adult", In: Niedermeyer, E., Lopes da Silva, F., *Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, *Lippincott Williams & Wilkins*, pp.149-173.
- [15] Thompson, T., Steffert, T., Ros, T., Leach, J., Gruzelier, J., (2008), "EEG applications for sport and performance", *Methods*, 45, 279.
- [16] Webster, J. G., (2004): "Ιατρική Οργανολογία, Εφαρμογή και Σχεδιασμός", *Εκδ. ΕΛΛΗΝ*.
- [17] Schomer, D. L., "The Normal EEG in an Adult", In: Blum, A. S., Rutkove, S. B., (2007), "The Clinical Neurophysiology Primer", *Humana Press*.
- [18] Schupp, M., Hanning, C. D., (2003): "Physiology of Sleep", *British Journal of Anesthesia*, 3, 69.
- [19] Aserinsky, E., (1953), "Ocular motility during sleep and its application to the study of rest-activity cycles and dreaming", Doctoral dissertation, University of Chicago, Department of Physiology.
- [20] Aserinsky, E., Kleitman, N., (1953), "Regularly occurring periods of eye motility, and concomitant phenomena, during sleep", *Science*, 118, 273.
- [21] Patel, A. K., Reddy, V., Araujo, J. F., (2020), "Physiology, sleep, stages", *StatPearls*, [Internet]
- [22] Malik, J., Lo, Y. L., Wu, H. T., (2018), "Sleep-wake classification via quantifying heart rate variability by convolutional neural network", *Physiological Measurements*, 39, 8.
- [23] Carley, D. W., Farabi, S. S., (2016), "Physiology of Sleep", *Diabetes Spectrum*, 29, 1.
- [24] American Association of Sleep Technologists, (2012): "Sleep Technology, Technical Guideline: Standard Polysomnography" [Internet].
- [25] De Gennaro, L., et al., (2005): "An electroencephalographic fingerprint of human sleep", *NeuroImage*, 26, 114.
- [26] Iber, I., Ancoli-Israel, S., Chesson, A., Quan, S. F., (2007): "The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications", *American Academy of Sleep Medicine*.
- [27] Venturas, E. M., et al., (2005): "Sleep spindle detection using artificial neural networks trained with filtered time-domain EEG: A feasibility study", *Computer Methods and Programs in Biomedicine*, 78, 191.
- [28] De Gennaro, L., Ferrara, M., (2003): "Sleep spindles: An overview", *Sleep Medicine Reviews*, 7, 423.
- [29] Andrillon, T., et al., (2011): "Sleep Spindles in Humans: Insights from Intracranial EEG and Unit Recordings", *The Journal of Neuroscience*, 31, 17821.
- [30] Schabus, M., et al., (2004): "Sleep Spindles and Their Significance for Declarative Memory Consolidation", *Sleep*, 27, 1479.
- [31] Steriade, M., Timofeev, I., (2003): "Neuronal Plasticity in Thalamocortical networks during Sleep and Waking Oscillations", *Neuron*, 37, 563.

- [32] Ferrareli, F., et al., (2008): "Reduced Evoked Gamma Oscillations in the Frontal Cortex in Schizophrenia Patients: A TMS/EEG Study", *American Journal of Psychiatry*, 165, 996.
- [33] Astori, S., et al., (2013): "Manipulating sleep spindles –expanding views on sleep, memory, and disease", *Trends in Neurosciences*, 36, 738.
- [34] Causa, L., et al., (2010): "Automated Sleep-Spindle Detection in Healthy Children Polysomnograms", *IEEE Tr. Biomed. Eng.*, 57, 2135.
- [35] Nonclercq, A., et al., (2013): "Sleep spindle detection through amplitude–frequency normal modelling", *Journal of Neuroscience Methods*, 214, 192.
- [36] Sofia, V., et al., (2011): "Confusion Matrix-based Feature Selection", *Proceedings of the Twenty-second Midwest Artificial Intelligence and Cognitive Science Conference*, pp.120-127.
- [37] Duman, F., et al., (2009): "Efficient sleep spindles detection algorithm with decision tree", *Expert Systems with Applications*, 36, 9980.
- [38] Devuyst, S., et al., (2011): "Automatic Sleep Spindles Detection – Overview and Development of a Standard Proposal Assessment Method", *33rd Annual International Conference of the IEEE EMBS*, pp.1713-1716.
- [39] Liu, M., et al., (2017): "Evaluating and Improving Automatic Sleep Spindle Detection by Using Multi-Objective Evolutionary Algorithms", *Frontiers in Human Neuroscience*, 11, 1.
- [40] Schönwald, S., V., et al., (2006): "Benchmarking matching pursuit to find sleep spindles", *Journal of Neuroscience Methods*, 156, 314.
- [41] Mallat, S., G., Zhang, Z., (1993): "Matching Pursuit With Time-Frequency Dictionaries", *IEEE Tr. Signal Processing*, 41, 3397.
- [42] LaRocco, J., et al., (2018): "Spindler: Spatiotemporal adaptive matching pursuit for EEG-based spindle detection", *Journal of Neural Engineering*, 1, 23.
- [43] Babadi, B., et al., (2012): "DiBa: A Data-Driven Bayesian Algorithm for Sleep Spindle Detection", *IEEE Tr. Biomed. Eng.*, 59, 483.
- [44] Huupponen, E., et al., (2011): "Development and comparison of four sleep spindle detection methods", *Artificial Intelligence in Medicine*, 40, 157.
- [45] Parekh, A., et al., (2015): "Detection of K-complexes and sleep spindles (DETOKS) using sparse optimization", *Journal of Neuroscience Methods*, 251, 37.
- [46] Sinha, R., L., (2008): "Artificial Neural Network and Wavelet Based Automated Detection of Sleep Spindles, REM sleep and Wake States", *J Med Syst*, 32, 291.
- [47] Güneş, S., et al., (2011): "Sleep spindles recognition system based on time and frequency domain features", *Expert Systems with Applications*, 38, 2455.
- [48] Chambon, S., et al., (2018): "A DEEP LEARNING ARCHITECTURE TO DETECT EVENTS IN EEG SIGNALS DURING SLEEP", *Research Gate*, 1-6.
- [49] Tarca, A., L., et al., (2007): "Machine learning and its applications to Biology", *PLoS Computational Biology*, 3, 953.
- [50] Bini, A., S., (2018): "Artificial Intelligence, Machine Learning, Deep Learning and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care", *The Journal of Arthroplasty*, 33, 2358.
- [51] Mahmud, M., et al., (2018): "Applications of Deep Learning and Reinforcement Learning to Biological Data", *IEEE Tr. Neur. Netw. Learn. Syst.*, 29, 2063.
- [52] Bengio, Y., (2009): "Learning deep architectures for AI", *Foundations and Trends in Machine Learning*, 2,1.
- [53] Goodfellow, I., et al., (2016): *Deep Learning*, Cambridge, MA, USA, MIT Press.
- [54] Pascanu, P., et al., (2014): "How to construct deep recurrent neural networks", *ICLR*, 1-13.
- [55] Kukreja, H., (2016): "An Introduction to Artificial Neural Networks", *International Journal of Advance Research and Innovative ideas in Education*, 1, 27.
- [56] Georgevici, A., I., Terblanche, M., (2019): "Neural networks and deep learning: a brief introduction", *Intensive Care Medicine*, 45, 712.
- [57] Dargan, S., et al., (2020): "A Survey of Deep Learning and Its Applications: A New Paradigm to Machine Learning", *Archives of Computational Methods in Engineering*, 27, 1071.
- [58] Svozil, D., et al., (1997): "Introduction to multi-layer feed-forward neural networks", *Chemometrics and Intelligent Laboratory Systems*, 39, 43.
- [59] Zhang, G., et al., (1998): "Forecasting with artificial neural networks: The state of the art", *International Journal of Forecasting*, 14, 35.
- [60] Lekshmi.K.R., Sherly, E., (2016): "Automatic Speech Recognition using different Neural Network Architectures – A Survey", *International Journal of Computer Science and Information Technologies*, 7, 2422.
- [61] Nwankpa, E., C., et al., (2018): "Activation Functions: Comparison of Trends in Practice and Research for Deep Learning", *ArXiv*, 1811.03378.

- [62] Yang, L., Shami, A., (2020): "On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice", *Neurocomputing*, 415, 295.
- [63] Goodfellow, I., Bengio, Y., Courville, A., (2016): "Deep Learning", *MIT Press*, ISBN 978-0262035613.
- [64] Nielsen, M., A., (2015): "Neural Networks and Deep Learning", *Determination Press*.
- [65] Wang, P., et, al., (2018): "LSTM-Based EEG Classification in Motor Imagery Tasks", *IEEE Tr. Neural Syst. Rehab. Eng.*, 26, 2086.
- [66] Rojas, R., (1996): "Neural Networks", *Springer*.
- [67] Goodfellow, I., Bengio, Y., Courville, A., (2016): "Deep Learning", *MIT Press*, 978-0262035613
- [68] Schmidhuber, J., et, al., (2017): "LSTM: A Search Space Odyssey", *IEEE Tr. Neur. Netw. Learn. Syst.*, 28, 2222.
- [69] Hochreiter, S., Schmidhuber, J., (1997): "Long short-term memory", *Neural Computation*, 9, 1735.
- [70] Graves, A., Schmidhuber, J., (2005): "Framewise phoneme classification with bidirectional LSTM and other neural network architectures", *Neural Networks*, 18, 602.
- [71] <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [72] Werbos, P., J., (1988): "Generalization of backpropagation with application to a recurrent gas market model", *Neural Networks*, 1, 339.
- [73] Hochreiter, S., et, al., (2001): "Gradient flow in recurrent nets: The difficulty of learning long-term dependencies", *A field guide to dynamical recurrent neural networks* [Internet].
- [74] Yang, Li, Shami, Abdallah, (2020): "On hyperparameter optimization of machine learning algorithms Q: Theory and practice", *Neurocomputing*, 415, 295.
- [75] You, K., et, al., (2019): "How does learning rate decay help modern neural networks?", *arXiv*, 1908.01878.
- [76] Bergstra, J., Bengio, Y., (2012): "Random Search for Hyper-Parameter Optimization", *Journal of Machine Learning Research*, 13, 281.
- [77] Bergstra, J., Bardenet, R., Bengio, Y. and Kégl, B., (2011): "Algorithms for hyper-parameter optimization". *Advances in neural information processing systems*, 24.
- [78] Qian, N., (1999): "On the momentum term in the gradient descent learning algorithms", *Neural Networks*, 12, 145.
- [79] LeCun, Y., A., et. al., (1998): "Efficient BackPropagation", in: *Neural Networks: Tricks of the trade*, Springer, pp. 9–48.
- [80] <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6>
- [81] LeCun, Y., A., et. al., (1998): "Handwritten digit recognition with a Back-Propagation Network", *Advances in Neural Information Processing Systems*, 2.
- [82] Xu, Y., Goodacre, R., (2018): "On Splitting Training and Validation Set: A Comparative Study of Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning", *Journal of Analysis and Testing*, 2, 249.
- [83] Tetko I., V., et. al., (1995): "Neural Network Studies. 1. Comparison of Overfitting and Overtraining", *Journal of Chemical Information and Modeling*, 35, 826.
- [84] Bluche, T., et, al., (2015): "Where to apply dropout in recurrent neural networks for handwriting recognition?", *13th International Conference on Document Analysis and Recognition (ICDAR)*, pp. 681-685
- [85] Srivastava, S., et. al., (2014): "Dropout: A Simple Way to Prevent Neural Networks from Overfitting", *Journal of Machine Learning Research*, 15, 1929.
- [86] Jankel, W., R., Niedermayer, E., (1985): "Sleep spindles", *Journal of Clinical Neurophysiology*, 2, 1.
- [87] Mmeremikwu, V., O., Mbachu, C., B., (2020): "EEG Signal Improvement; Comparison of Different Windows", *World Journal of Innovative Research*, 8, 38.
- [88] Xing, X., et, al., (2019): "SAE+LSTM: A New Framework for Emotion Recognition From Multi-Channel EEG", *Frontiers in Neurorobotics*, 13, 1.
- [89] Campbell, K., et al., (1980): "Human and automatic validation of a phase-locked loop spindle detection system", *Electroencephalography and Clinical Neurophysiology*, 48, 602.
- [90] https://colab.research.google.com/?utm_source=scs-index
- [91] <https://numpy.org/>
- [92] <https://pandas.pydata.org/>
- [93] <https://matplotlib.org/>
- [94] <https://scipy.org/>
- [95] <https://www.tensorflow.org/>
- [96] <https://keras.io/>
- [97] Hines, T., (2018): "Anatomy of the Brain", *Mayfield Clinic*, Ohio, pp.1-7.

Παράρτημα 1: Python, TensorFlow & Keras

Ο αλγόριθμος αναπτύχθηκε στο δωρεάν προγραμματιστικό περιβάλλον της Google, Google Colab [90].

Η προεπεξεργασία του ΗΕΓ σήματος και το στήσιμο του ΤΝΔ έγιναν με τη γλώσσα προγραμματισμού Python (Έκδοση στο Google Colab 3.6.9). Η Python προτιμήθηκε για την ευκολία στη σύνταξη, την πληθώρα δωρεάν online πηγών και την εύκολη χρήση των βιβλιοθηκών της.

Η επεξεργασία σήματος, (εξαγωγή ατράκτων, φιλτράρισμα, εφαρμογή κυλιόμενου παραθύρου), έγιναν με χρήση βιβλιοθηκών όπως NumPy [91], Pandas [92], Matplotlib [93] και SciPy [94]. Το ΤΝΔ στήθηκε κάνοντας χρήση της βιβλιοθήκης TensorFlow [95] και του Keras (Application Programming Interface – API) [96].

Τρόπος κλήσης και ανάπτυξης των απαραίτητων βιβλιοθηκών:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
import tensorflow as tf
import tensorflow.keras as keras
from tensorflow.keras.models import Sequential, load_model
from tensorflow.keras.layers import LSTM, Dropout, Dense
```

Εδώ δημιουργείται το ΤΝΔ (αρχιτεκτονική και υπερπαράμετροι):

```
model = Sequential()

model.add(LSTM(3, input_shape = (100, 100),
              return_sequences=True, activation = 'tanh'))
model.add(Dropout(0.3))

model.add(LSTM(4, activation = 'tanh'))
model.add(Dropout(0.3))

model.add(Dense(1, activation='sigmoid'))
```

Εδώ ορίζεται ο optimizer:

```
sgd = keras.optimizers.SGD(learning_rate=0.005, momentum=0.5,
                             decay=1e-6)
```

Και τέλος συγκροτείται το μοντέλο:

```
model.compile(loss='binary_crossentropy',
              optimizer=sgd,
              metrics=['accuracy'])
```

Παράρτημα 2: «Χάρτης» συνόλων εκπαίδευσης, πιστοποίησης και ελέγχου

Στους παρακάτω πίνακες παρουσιάζεται η ακολουθία με την οποία εισάγονται τα δείγματα στο δίκτυο.

0	non_spindle	15	non_spindle	30	spindle	45	non_spindle	60	spindle	75	spindle
1	non_spindle	16	spindle	31	non_spindle	46	spindle	61	non_spindle	76	non_spindle
2	spindle	17	spindle	32	non_spindle	47	non_spindle	62	non_spindle	77	spindle
3	spindle	18	spindle	33	non_spindle	48	spindle	63	non_spindle	78	spindle
4	spindle	19	spindle	34	non_spindle	49	non_spindle	64	non_spindle	79	spindle
5	non_spindle	20	spindle	35	non_spindle	50	spindle	65	spindle	80	spindle
6	non_spindle	21	spindle	36	spindle	51	non_spindle	66	non_spindle	81	non_spindle
7	non_spindle	22	spindle	37	non_spindle	52	spindle	67	non_spindle	82	spindle
8	spindle	23	non_spindle	38	non_spindle	53	non_spindle	68	spindle	83	spindle
9	spindle	24	non_spindle	39	spindle	54	spindle	69	non_spindle	84	spindle
10	non_spindle	25	non_spindle	40	spindle	55	spindle	70	non_spindle	85	non_spindle
11	non_spindle	26	non_spindle	41	spindle	56	spindle	71	non_spindle	86	spindle
12	non_spindle	27	spindle	42	non_spindle	57	spindle	72	non_spindle	87	spindle
13	spindle	28	spindle	43	spindle	58	spindle	73	spindle	88	non_spindle
14	non_spindle	29	non_spindle	44	non_spindle	59	non_spindle	74	non_spindle	89	spindle

Πίνακας Π2.1: Η σειρά δειγμάτων (άτρακτος και μη-άτρακτος) για το X train

0	spindle	13	spindle
1	non_spindle	14	spindle
2	spindle	15	non_spindle
3	spindle	16	spindle
4	non_spindle	17	spindle
5	spindle	18	non_spindle
6	spindle	19	non_spindle
7	spindle	20	non_spindle
8	spindle	21	non_spindle
9	spindle	22	non_spindle
10	spindle	23	non_spindle
11	non_spindle	24	non_spindle
12	non_spindle	25	non_spindle

Πίνακας Π2.2: Η σειρά δειγμάτων (άτρακτος και μη-άτρακτος) για το X val

0	spindle
1	spindle
2	spindle
3	non_spindle
4	non_spindle
5	non_spindle
6	spindle
7	non_spindle
8	spindle
9	non_spindle

Πίνακας Π2.3: Η σειρά δειγμάτων (άτρακτος και μη-άτρακτος) για το X test