



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Αυτόματη ανίχνευση ατράκτων ύπνου με δίκτυα
LSTM (Long-Short Term Memory),
BILSTM (Bidirectional LSTM) και
GRU (Gated Recurrent Unit)**

ΘΕΟΔΩΡΟΠΟΥΛΟΥ ΕΛΕΝΗ
Αριθμός Μητρώου: 48017022

Επιβλέπων Καθηγητής
Ερρίκος Χάιμ Βεντούρας

Αθήνα 17/7/2023

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Ερρίκος Βεντούρας
Καθηγητής

Παντελεήμων Ασβεστάς
Καθηγητής

Αικατερίνη Σκουρολιάκου
Καθηγήτρια

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η υπογράφουσα Θεοδωροπούλου Ελένη του Βασιλείου, με αριθμό μητρώου 48017022 φοιτήτρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

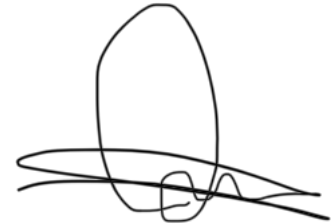
«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, 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

17/7/2023

Η Δηλούσα



Περίληψη

Ο κύριος σκοπός της παρούσας Διατριβής ήταν να δοκιμαστούν νευρωνικά δίκτυα τύπου μακροχρόνιας-βραχυχρόνιας μνήμης (Long-Short Term Memory - LSTM), που μπορούν να διακρίνουν κυματομορφές ατράκτων ή μη-ατράκτων σε ένα ηλεκτροεγκεφαλογράφημα (ΗΕΓ) ύπνου. Οι άτρακτοι του ύπνου είναι ρυθμικές κυματομορφές, που υπάρχουν στο ΗΕΓ ύπνου και χρησιμοποιούνται για τον καθορισμό του σταδίου του ύπνου. Χρησιμοποιώντας το Matlab εξερευνήσαμε δίκτυα LSTM, αμφίδρομα δίκτυα LSTM (BILSTM) και δίκτυα «αναδρομικών μονάδων πύλης» (Gated Recurrent Unit - GRU). Χρησιμοποιήθηκαν δεδομένα από τη δημόσια διαθέσιμη βάση δεδομένων «Dreams Sleep Spindle Database», που αποτελούνταν από 8 αποσπάσματα καταγραφής 30 λεπτών ενός κεντρικού καναλιού ΗΕΓ. 90 περιπτώσεις χρησιμοποιήθηκαν για εκπαίδευση, 26 για επικύρωση και 10 για δοκιμές. Σε κάθε σύνολο υπήρχε ίσος αριθμός ατράκτων και μη-ατράκτων. Η ακρίβεια κυμαίνονταν από 46% έως 100%. Μετά την ολοκλήρωση δοκιμών με όλα τα δίκτυα και τη δοκιμή διαφόρων τιμών για τον ρυθμό εκμάθησης και τη δομή των επιπέδων, τα καλύτερα αποτελέσματα δόθηκαν από το δίκτυο GRU, χρησιμοποιώντας τις υπερπαραμέτρους που προτείνονται από το Matlab.

Λέξεις κλειδιά: Ηλεκτροεγκεφαλογραφία, άτρακτοι, δίκτυα LSTM

ABSTRACT

The main purpose of the present Thesis was to test neural networks, of the Long-Short Term Memory (LSTM) type, that can discriminate spindle or non-spindle waveforms in a sleep electroencephalogram (EEG). Sleep spindles are rhythmic waveforms, present in sleep EEG that are used to define the stage of sleep. Using Matlab we explored LSTM, bi-directional LSTM (BILSTM) and General Recurrent Unit (GRU) networks. Data from the publicly available ‘Dreams Sleep Spindle Database’ were used, consisting of 8 excerpts of 30 minutes of a central EEG channel recording. 90 cases were used for training, 26 for validation and 10 for testing. In each set an equal number of spindle and non-spindle segments existed. Accuracies ranged from 46% to 100%. After completing trials with all of the networks and testing various values for the learning rate and the structure of the layers, the best results were given by the GRU network, using the hyperparameters that are suggested by Matlab.

Keywords: Electroencephalography, spindles, LSTM networks

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα Καθηγητή μου κ.Ερρίκο Βεντούρα για την πολύτιμη καθοδήγηση του, τις εύστοχες συμβουλές και την υπομονή του καθ'όλη τη διαδικασία εκπόνησης και συγγραφής της παρούσας Διπλωματικής Εργασίας.

Ακόμα, θα ήθελα να ευχαριστήσω τη μητέρα μου για την προσφορά της σε όλο το διάστημα των σπουδών μου καθώς και τους φίλους και συναδέλφους που με στήριξαν σε όλη αυτή τη διαδρομή.

ΠΕΡΙΕΧΟΜΕΝΑ

ΕΙΣΑΓΩΓΗ	8
1. Εγκέφαλος, ηλεκτροεγκεφαλογραφία, ύπνος	9
1.1 Ανατομία ανθρώπινου εγκεφάλου	11
1.2 Ηλεκτροεγκεφαλογραφία (HEΓ): ιστορική αναδρομή	12
1.3 Ηλεκτροεγκεφαλογραφία: βασικές τεχνικές.....	12
1.4 Ύπνος: στάδια και HEΓ	13
1.5 Ο μηχανισμός παραγωγής υπνικών ατράκτων	15
1.6 Παθολογικές καταστάσεις σχετιζόμενες με τις ατράκτους -σχιζοφρένεια.....	16
2. Συστήματα αυτόματης ανίχνευσης ατράκτων	18
2.1 Χαρακτηριστικές κυματομορφές στο ηλεκτροεγκεφαλογράφημα	18
2.2 Περιγραφή συστημάτων αυτόματης ανίχνευσης ατράκτων	21
2.2.1 Προσαρμοσμένο φιλτράρισμα (Matched Filtering)	21
2.2.2 Σύνθετη αποδιαμόρφωση (Complex Demodulation - CDM).....	22
2.2.3 Εντοπισμός ατράκτων μέσω μετασχηματισμού Fourier και είσοδο των αποτελεσμάτων σε γνωστούς ταξινομητές	22
2.2.4 Εύρεση ατράκτων συνδυάζοντας Κρυφά Μοντέλα Μαρκόβ (HMM - Hidden Markov Models) και Μηχανές Υποστήριξης Διανυσμάτων (SVM - (Support Vector Machines).....	23
3. Βαθεία Μάθηση και Νευρωνικά Δίκτυα	25
3.1 Βαθεία Μάθηση	25
3.2 Νευρωνικά Δίκτυα	25
3.2.1 Κατηγορίες συναρτήσεων ενεργοποίησης.....	27
3.2.2 Πλεονεκτήματα νευρωνικών δικτύων	30
3.3.1 Συνελκτικά νευρωνικά δίκτυα CNN (Convolutional Neural Network)	31
3.3.2 Αναδρομικά νευρωνικά δίκτυα - RNN (Recurrent Neural Network).....	32
3.3.3 Παραγωγικά αντιπαλικά δίκτυα - GAN (Generative Adversarial Network).33	
3.3 LSTM (Long Short Term Memory).....	33
3.4 BiLSTM (Bidirectional Long Short Term Memory).....	36
3.5 GRU (Gated Recurrent Unit).....	36
4. Μεθοδολογία και αποτελέσματα	38
4.1 Βάση δεδομένων και επιλογή δεδομένων.....	38
4.2 Διαχωρισμός δεδομένων	38
4.2.1 Εφαρμογή κυλιόμενου παραθύρου για κατασκευή μητρών	39
4.3 Επιλογή υπερπαραμέτρων και μετρικές επίδοσης	41
4.4 Αποτελέσματα και παρατηρήσεις.....	43
4.4.1 LSTM 1 κρυφού στρώματος (LSTM-1 Layer).....	43
4.4.2 BiLSTM 1 κρυφού στρώματος (BiLSTM-1 Layer)	46
4.4.3 LSTM δύο κρυφών στρωμάτων (LSTM-2 Layers)	48
4.4.4 GRU 1 κρυφού στρώματος (GRU-1 Layer)	50
4.4.5 GRU 2 κρυφών στρωμάτων (GRU-2 Layers)	53
4.5 Συνολικός σχολιασμός αποτελεσμάτων – συμπεράσματα	55
Αναφορές - Πηγές.....	57
Παράρτημα: Matlab	61

ΕΙΣΑΓΩΓΗ

Η παρούσα Διπλωματική Εργασία αναπτύχθηκε στα πλαίσια ολοκλήρωσης του πενταετούς προγράμματος σπουδών του Τμήματος Μηχανικών Βιοϊατρικής του Πανεπιστημίου Δυτικής Αττικής. Αντικείμενο της εργασίας αυτής ήταν η χρήση αλγορίθμων βαθιάς μάθησης τύπου Long-Short Term Memory (LSTM) για την αυτοματοποιημένη ανίχνευση ατράκτων του ύπνου σε ηλεκτροεγκεφαλογράφημα (HEΓ). Η εργασία αυτή χρησιμοποιεί μια δημόσια διαθέσιμη βάση δεδομένων HEΓ ύπνου με προσημειωμένες ατράκτους. Η επιλογή ατράκτων στα δεδομένα, καθώς και η προεπεξεργασία του HEΓ έλαβαν χώρα σε προηγούμενη Διπλωματική Εργασία του Τμήματος [1].

Στο πρώτο κεφάλαιο αναφέρεται το θεωρητικό υπόβαθρο σχετικά με την ανατομία του εγκεφάλου, τα σήματα που παράγονται κατά την ηλεκτροεγκεφαλογραφία, ο τρόπος συλλογής και επεξεργασίας τους. Ακόμα περιγράφονται οι άτρακτοι του ύπνου, η σημασία κατανόησης και διαχωρισμού των κυματομορφών αυτών σε σχέση με το υπόλοιπο σήμα καθώς και οι παθολογίες που τυχόν συνδέονται με την εμφάνισή τους.

Στο δεύτερο κεφάλαιο αναφέρονται προσπάθειες ανίχνευσης των σημάτων αυτών μέσω των εργαλείων Μηχανικής και Βαθείας Μάθησης, οι μεθοδολογίες και οι δείκτες που χρησιμοποιήθηκαν καθώς και τα αποτελέσματα που παράχθηκαν.

Στο τρίτο κεφάλαιο αναλύεται η δομή των Νευρωνικών Δικτύων και ιδιαίτερα των δικτύων LSTM που επιλέξαμε (LSTM, BILSTM, GRU). Για την υλοποίηση των δικτύων χρησιμοποιήθηκαν τα εργαλεία του υπολογιστικού πακέτου και της γλώσσας προγραμματισμού Matlab. Αναφέρονται αναλυτικά οι συνδέσεις των νευρώνων, οι διαφορές και οι δυνατότητες των τριών δικτύων σε ένα ευρύ φάσμα δοκιμών.


Στο τέταρτο κεφάλαιο αναλύεται διεξοδικά η ερευνητική δουλειά που παράχθηκε κατά τη διάρκεια αυτής της Διπλωματικής Εργασίας, συνοδευόμενη με τα αποτελέσματα των δοκιμών και μια συζήτηση επί των αποτελεσμάτων.

1. Εγκέφαλος, ηλεκτροεγκεφαλογραφία, ύπνος

1.1 Ανατομία ανθρώπινου εγκεφάλου

Σύμφωνα με την Keith Moore και τους συνεργάτες της [2], ο εγκέφαλος υπόκειται σε διάφορες διαιρέσεις, από τις οποίες πιο αντιπροσωπευτική είναι η ‘εμβρυολογική’. Σύμφωνα με αυτή ο εγκέφαλος διαιρείται σε πέντε “μοίρες”: τον τελικό, τον διάμεσο, το μέσο, τον οπίσθιο και τον έσχατο εγκέφαλο (προμήκης μυελός και τέταρτη κοιλία). Ο τελικός εγκέφαλος αποτελείται από τα εγκεφαλικά ημισφαίρια (δεξί , αριστερό), τους συνδέσμους και τις πλάγιες κοιλίες. Τα εγκεφαλικά ημισφαίρια διαιρούνται περαιτέρω στο νεοχιτώνιο (μετωπιαίος λοβός, βρεγματικός λοβός, κροταφικός λοβός, ινιακός λοβός, “νήσος του Reil”) και στον ρινικό εγκέφαλο.

Στα επόμενα θα αναφερόμαστε σε αριθμημένες περιοχές των λοβών («πεδία», «περιοχές»), οι οποίες αριθμούνται σύμφωνα με το σύστημα του Brodmann και δείχνονται στην Εικόνα 1.1.



Εικόνα 1.1 Περιοχές Brodmann [23]


Μετωπιαίος λοβός: Ο μετωπιαίος λοβός έχει τρεις επιφάνειες: άνω, έσω και κάτω. Η άνω επιφάνεια ξεκινά από το μετωπιαίο πόλο και καταλήγει στην κεντρική αύλακα οπισθίως. Το κατώτερο όριο της έσω επιφάνειας είναι η αύλακα του προσαγωγίου, ενώ το οπίσθιο όριο της

κάτω επιφάνειας αποτελεί η πρόσθια διάτρητη ουσία. Η πρόσθια κεντρική έλικα και το παράκεντρο λοβίο αποτελούν το πεδίο 4 κατά Brodmann, τον πρωτοταγή κινητικό φλοιό, υπεύθυνο για την ενεργοποίηση της κίνησης. Το αρχικό τμήμα της άνω και της μέσης μετωπιαίας έλικας το οποίο είναι πλησίον στην πρόσθια κεντρική έλικα αποτελεί το πεδίο 6. Το εσωτερικό τμήμα της περιοχής αυτής αποτελεί τον συμπληρωματικό κινητικό φλοιό, ενώ το περιφερικό αποτελεί την προκινητική περιοχή. Η κύρια λειτουργία της είναι η εκμάθηση κινήσεων και ο σχεδιασμός τους, καθώς και η κινητική ενεργοποίηση του άνω άκρου. Το επόμενο τμήμα είναι η περιοχή 8, που αποτελεί το μετωπιαίο οφθαλμικό πεδίο, υπεύθυνο για την εκούσια κίνηση των οφθαλμών. Οι περιοχές 9, 10, 11 και 46 αποτελούν τον προμετωπιαίο φλοιό και σχετίζεται με τη μνήμη, τη διαμόρφωση της προσωπικότητας και τα γνωστικά ζητήματα. Οι περιοχές 44, 45 αποτελούν μέρη της περιοχής 'Broca' η οποία είναι υπεύθυνη για την έκφραση της ομιλίας.

Βρεγματικός λοβός: Ο βρεγματικός λοβός βρίσκεται ανάμεσα στους υπολοίπους και εμφανίζει άνω και έσω επιφάνεια. Διαχωρίζεται από τον μετωπιαίο λοβό μέσω της κεντρικής αύλακας στην άνω επιφάνεια και μέσω της επιχείλιας αύλακας στην εσωτερική. Το όριο μεταξύ ινιακού και βρεγματικού είναι η βρεγματοϊνιακή και η εγκάρσια ινιακή αύλακα. Η οπίσθια κεντρική έλικα καταλαμβάνεται από τις περιοχές 1, 2, 3 κατά 'Brodmann' και εκεί εδράζεται ο πρωτοταγής σωματοαισθητικός φλοιός, υπεύθυνος για τη σωματοαισθητική αντίληψη. Η περιοχή 39 ευθύνεται για σημαντικές λειτουργίες οπτικής επεξεργασίας, όπως είναι η αναγνώριση προσώπων και η ανάγνωση. Επιπρόσθετα, εμπλέκεται στη χωρική απεικόνιση, σε λειτουργίες οπτικοκινητικής φύσης, στην ορθογραφική μνήμη και τέλος στα μαθηματικά.

Κροταφικός λοβός: Ο οπίσθιος κλάδος της σχισμής του Sylvius διαχωρίζει τον κροταφικό από τον βρεγματικό λοβό. Ο φλοιός της άνω κροταφικής έλικας αντιστοιχεί κυρίως στην περιοχή 22 που αποτελεί το μνημονικό ή συνειρμικό ακουστικό κέντρο, όπου λαμβάνει χώρα η συσχέτιση των πρόσφατων ακουσμάτων με εκείνα του παρελθόντος. Τα πεδία 41, 42 αποτελούν τον ακουστικό φλοιό, όπου γίνεται η καταγραφή των συχνοτήτων. Στο επικρατούν ημισφαίριο, οι περιοχές 21, 22, 42 αποτελούν την περιοχή 'Wernicke', δηλαδή το κέντρο αντίληψης της ομιλίας. Η περιοχή 28 είναι η κύρια είσοδος προς τον ιππόκαμπο και κατ'αυτόν τον τρόπο είναι σημαντική για την κωδικοποίηση και ενοποίηση της μνήμης. Αξίζει να αναφερθεί ότι είναι από τις πρώτες περιοχές που επηρεάζονται στη νόσο του 'Alzheimer'. Οι περιοχές 34, 35 σχετίζονται με συναισθηματικές καταστάσεις.

Ινιακός λοβός: Ο ινιακός λοβός αποτελεί τον μικρότερο λοβό. Έχει σχήμα πυραμίδας, της οποίας η κορυφή αντιστοιχεί στον ινιακό πόλο και συνέχεται με το οπίσθιο πέρας του βρεγματικού και κροταφικού λοβού. Η κάτω επιφάνεια είναι υπόκοιλη και διαχωρίζεται από την παρεγκεφαλίδα. Ο φλοιός του ινιακού πόλου αποτελεί το πεδίο 17 και συνιστά τον πρωτοταγή οπτικό φλοιό. Η περιοχή 18 περιβάλλει την περιοχή 17 και αποτελεί τον δευτεροταγή οπτικό φλοιό, χρησιμεύει στην αναγνώριση των χρωμάτων. Είναι άξιο αναφοράς ότι παρά το μικρό μέγεθός του, στον οπτικό φλοιό απαντάται το 1/10 των κυττάρων του εγκεφαλικού φλοιού.



Εικόνα 1.2 Λοβοί ανθρώπινου εγκεφάλου [24]

1.2 Ηλεκτροεγκεφαλογραφία (ΗΕΓ): ιστορική αναδρομή

Ο Vittorio A. Sironi στο άρθρο του [3] αναφέρει ότι στις αρχές του 19^{ου} αιώνα ο Giovanni Aldini, καθηγητής του Πανεπιστημίου της Μπολόνια, χρησιμοποίησε ηλεκτρική φλοική διέγερση στους εγκεφάλους φυλακισμένων. Το 1804 διαπίστωσε πως η ηλεκτρική διέγερση προκαλούσε «γκριμάτσες» στο πρόσωπο. Αυτό τον οδήγησε στο συμπέρασμα ότι ο φλοιός μπορεί να διεγερθεί και να αποτελέσει θεραπευτικό εργαλείο σε νευροψυχιατρικές ανωμαλίες. Το 1809 ο Luigi Rolando χρησιμοποίησε γαλβανικό ρεύμα για να διεγείρει το φλοιό διαφόρων ζώων και διερεύνησε τις λειτουργίες των διαφόρων ζωνών του

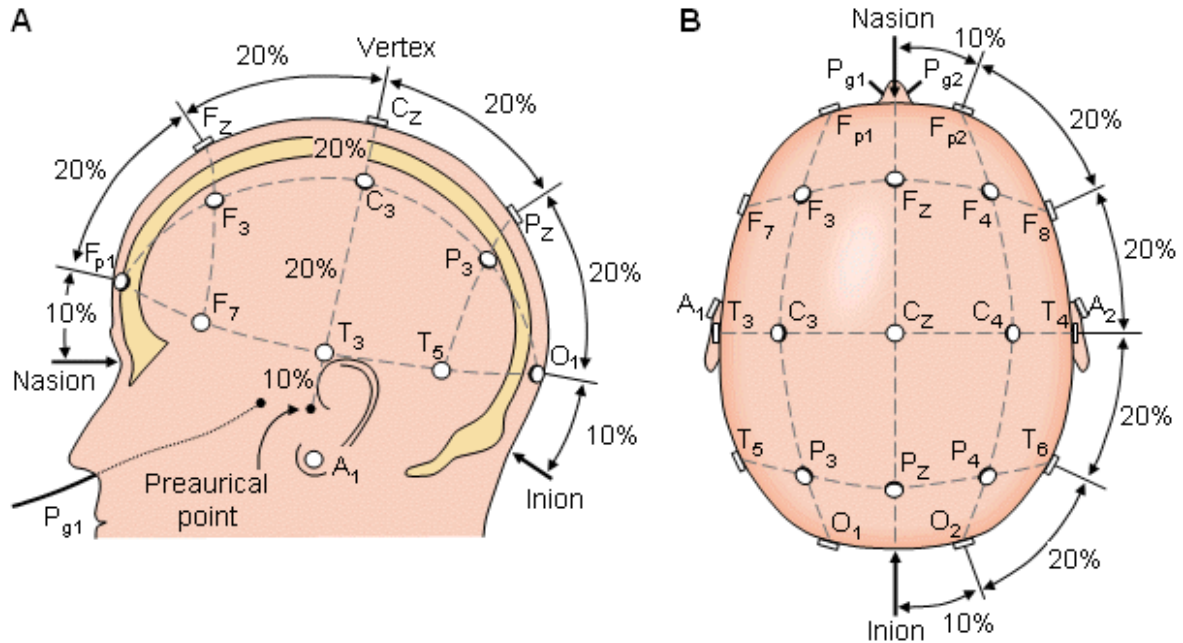
εγκεφάλου, ενώ το 1870 οι Gustav Fritsch και Eduard Hitzing έδειξαν ότι η ηλεκτρική διέγερση σε συγκεκριμένη περιοχή του εγκεφάλου των σκύλων προκαλούσε μυϊκή σύσπαση. Το 1874 ο αμερικανός φυσικός Robert Bartholow ήταν ο πρώτος που κατέγραψε ευρήματα από ηλεκτρική διέγερση στον εγκεφαλικό φλοιό σε ζύπνιο άνθρωπο.

Ενώ λοιπόν πολλοί ερευνητές είχαν ασχοληθεί με τη διέγερση, οι Dale Purves et.al [4] αναφέρουν ότι η πρώτη καταγραφή ηλεκτρικής δραστηριότητας στην εκτιθέμενη επιφάνεια του εγκεφαλικού φλοιού έγινε το 1875 στο κεφάλι ενός πιθήκου, ωστόσο έως το 1929 δεν είχε γίνει η αντίστοιχη καταγραφή σε ανθρώπινο εγκεφαλικό φλοιό. Πρώτος ασχολήθηκε ο Hans Berger, ένας ψυχίατρος στο Πανεπιστήμιο της Jena στην Γερμανία. Το πείραμα αυτό αποτέλεσε σημαντικό κατόρθωμα για την κατανόηση νευρολογικών καταστάσεων εφόσον δεν υπήρχαν άλλες απεικονιστικές τεχνικές. Έκτοτε, το ηλεκτροεγκεφαλογράφημα (ΗΕΓ) έλαβε αρνητικές αντιδράσεις λόγω της πολυπλοκότητας του και των περιορισμένων του δυνατοτήτων, κυρίως όμως έλαβε θετικές αντιδράσεις διότι ήταν ένα βήμα πιο κοντά στην κατανόηση της ανθρώπινης σκέψης, αλλά κυρίως βοήθησε στη μελέτη νευρολογικών ασθενειών.


1.3 Ηλεκτροεγκεφαλογραφία: βασικές τεχνικές

Η μέθοδος καταγραφής του ηλεκτροεγκεφαλογραφήματος συνίσταται στην τοποθέτηση σετ ηλεκτροδίων σε συγκεκριμένες ανατομικές θέσεις στη δερματική επιφάνεια του κρανίου. Ο τρόπος τοποθέτησης των ηλεκτροδίων στο κρανίο υπακούει στον παγκοσμίως αποδεκτό κανόνα «10-20» και εφαρμόζεται σε εξετάσεις ηλεκτροεγκεφαλογραφίας, πολυϋπνογραφία (μελέτης ύπνου) ή σε ερευνητικές διαδικασίες. Το σύστημα 10-20 βασίζεται στη σχέση μεταξύ της τοποθεσίας του ηλεκτροδίου και την περιοχή που βρίσκεται κάτω από αυτό στον φλοιό, καλύπτοντας έτσι όλες τις περιοχές του εγκεφάλου. Το 10-20 αντικατοπτρίζει την απόσταση των ηλεκτροδίων, η οποία είναι 10% ή 20% της συνολικής απόστασης που μπορεί να «διανυθεί» επί της δερματικής επιφάνειας του κρανίου σε δύο διευθύνσεις (είτε από αριστερά προς τα δεξιά, από το ένα αυτί στο άλλο, είτε από μπροστά προς τα πίσω, από την κορυφή της μύτης ως το πίσω ινιακό άκρο) όπως φαίνεται στην Εικόνα 1.3. Στην Εικόνα 1.4 φαίνονται οι θέσεις των ηλεκτροδίων. Τα μονά νούμερα υποδεικνύουν ότι είμαστε στο αριστερό ημισφαίριο, τα ζυγά νούμερα υποδεικνύουν ότι είμαστε στο δεξί ημισφαίριο ενώ το γράμμα z υποδεικνύει πως είμαστε στο κέντρο. Τα νούμερα αυξάνουν όσο απομακρυνόμαστε από τη μέση γραμμή. Τα γράμματα υποδεικνύουν το σημείο που βρίσκεται κάθε ηλεκτρόδιο σχετικά με την περιοχή του εγκεφάλου (C=central, F= frontal, T=temporal, P=parietal, O= occipital). Περιοχές που έχουν 2 γράμματα

χρησιμοποιούνται σε συστήματα μεγαλύτερης ακρίβειας. Τα γράμματα M, ή A που εμφανίζονται κάποιες φορές αντιστοιχούν στους μαστοειδείς ή στους λοβούς των αυτιών και χρησιμοποιούνται ως γείωση για την ανάλυση του σήματος.



Εικόνα 1.3: Παγκόσμιο σύστημα τοποθέτησης ηλεκτροδίων ΗΕΓ 10-20 [25]



Εικόνα 1.4 Αριστερή και δεξιά όψη εγκεφαλικού φλοιού. Θέσεις ηλεκτροδίων καταγραφής ΗΕΓ [32]

1.4 Ύπνος: στάδια και ΗΕΓ


Οι Dale Purves et.al [5] αναφέρουν ότι ο φυσιολογικός ανθρώπινος κύκλος ύπνου και εγρήγορσης υποδηλώνει ότι, σε συγκεκριμένες χρονικές στιγμές ενεργοποιούνται ποικίλα νευρωνικά συστήματα ενώ άλλα απενεργοποιούνται. Για αιώνες θεωρούνταν ότι ο ύπνος είναι μια παθητική διαδικασία με μοναδικό σκοπό την αναζωογόνηση του ανθρώπου, ώσπου το 1953 οι Nathaniel Kleitman

και Eugene Aserinsky έδειξαν ότι ο ύπνος αποτελείται από διαφορετικά στάδια, τα οποία επισυμβαίνουν με χαρακτηριστική αλληλουχία.

Κατά τη διάρκεια της πρώτης ώρας ύπνου γίνεται είσοδος στα τέσσερα διαδοχικά στάδια του ύπνου. Ο διαχωρισμός των σταδίων γίνεται μέσω ηλεκτροεγκεφαλογραφικών στοιχείων (πλάτος, περίοδος/μήκος κύματος). Στο στάδιο I του ύπνου, αυτό που αισθανόμαστε ως «υπνηλία», το φάσμα των συχνοτήτων που εμφανίζεται στο ΗΕΓ μετατοπίζεται σε μικρότερες τιμές και ελαφρώς μεγαλύτερα μήκη κύματος από ότι στην φάση εγρήγορσης («ξύπνιος»). Έπειτα, οδηγούμαστε στο στάδιο II του ύπνου που χαρακτηρίζεται από περαιτέρω μείωση της συχνότητας και αύξηση του μήκους κύματος, ενώ στα μεσοδιαστήματα εμφανίζονται ομάδες υψίσυχνων κυμάτων τα οποία αποκαλούνται άτρακτοι του ύπνου και αποτελούν το κύριο αντικείμενο της παρούσας Διπλωματικής Εργασίας. Οι άτρακτοι αποτελούν περιοδικές εκφορτίσεις συχνότητας περίπου 12-16 Hz που διαρκούν 1-2 δευτερόλεπτα και είναι αποτέλεσμα αλληλεπίδρασης θαλαμικών και φλοιϊκών νευρώνων. Οι συχνότητες των ατράκτων μπορεί να επεκτείνονται από 11 έως 16 περίπου Hz. Στο στάδιο III του ύπνου ο αριθμός των ατράκτων μειώνεται, ενώ το πλάτος των εγκεφαλικών κυμάτων αυξάνεται και η συχνότητα συνεχίζει μειούμενη. Το βαθύτερο στάδιο του ύπνου, στάδιο IV ή ύπνος βραδέων κυμάτων, αποτελείται από δραστηριότητα πολύ χαμηλής συχνότητας (0,5-2Hz) και μεγάλου πλάτους εκφορτίσεις που ονομάζονται κύματα δέλτα. Τα κύματα δέλτα αντικατοπτρίζουν μια συγχρονισμένη ηλεκτρική δραστηριότητα των φλοιωδών νευρώνων.

Τα τέσσερα παραπάνω στάδια αποτελούν τον ύπνο non-REM (non-rapid eye movement) με στάδιο μεγαλύτερης διάρκειας το στάδιο IV, όπως φαίνεται στην Εικόνα 1.5. Μετά την περίοδο των κυμάτων δέλτα, οι καταγραφές δείχνουν ότι τα στάδια του ύπνου αντιστρέφονται και μπαίνουμε σε μία κατάσταση που καλείται ύπνος REM (rapid eye movement). Κατά την περίοδο αυτή τα σήματα που λαμβάνουμε είναι σχεδόν όμοια με αυτά ενός ατόμου σε εγρήγορση. Η περίοδος αυτή διαρκεί περίπου 10 λεπτά και στη συνέχεια το άτομο επιστρέφει στον non-REM ύπνο.

Συνεπώς, ένας τυπικός οκτάωρος ύπνος αποτελείται από εναλλαγές των δύο βασικών περιόδων REM & non-REM. Η συνολική διάρκεια της περιόδου REM μειώνεται όσο αυξάνεται η ηλικία του ανθρώπου, όμως οι λόγοι της μεταβολής αυτής δεν είναι ακόμα γνωστοί.



Εικόνα 1.5 : Στάδια ύπνου [26]

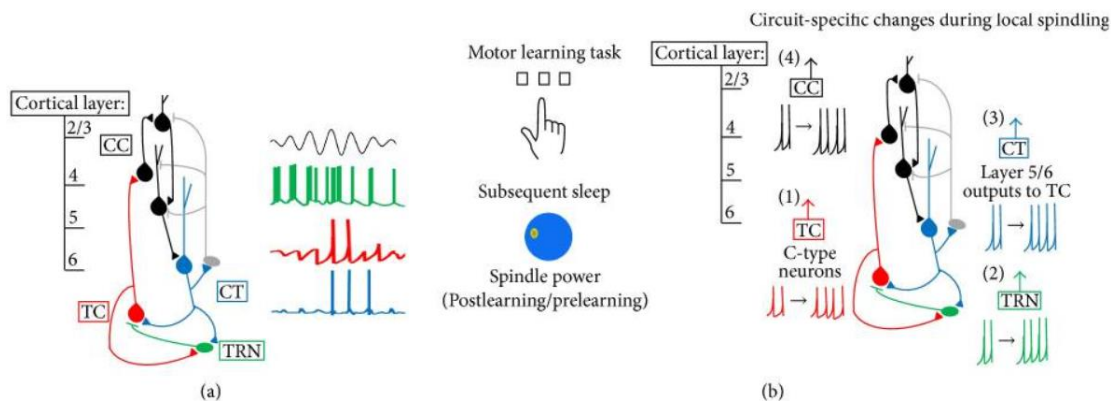
1.5 Ο μηχανισμός παραγωγής υπνικών ατράκτων

Στο άρθρο της Brittany C. Clawson και συνεργατών της [6] αναφέρεται ότι ούτε η τοπολογία ούτε η μορφολογία των ατράκτων παραμένει ίδια καθ'όλη τη διάρκεια της ζωής και αυτό εξηγεί τις διαφορές της δομής αλλά και της λειτουργίας του εγκεφάλου κατά το πέρασμα των ετών.

Οι υπνικές άτρακτοι είναι κορυφώσεις στην ταλαντούμενη δραστηριότητα ενός ΗΕΓ και είναι χαρακτηριστικές κυματομορφές κατά τη διάρκεια του NREM ύπνου. Η διάρκεια τους κυμαίνεται από 0.5-2 δευτερόλεπτα. Η παρουσία τους είναι συχνότερη κατά τη φάση 2 και εντοπίζονται σε μετωπιο-βρεγματικές και στις προμετωπιαίες περιοχές.

Οι υπνικές άτρακτοι όπως αναφέρει και η Χαρά Τσέκου [7] παράγονται εξαιτίας των συγχρονισμένων εκφορτίσεων των θαλαμοφλοιωδών (TC-thalamocortical) και θαλαμικών νευρώνων (TRN-thalamic reticular neurons). Η έναρξή τους οφείλεται στη διέγερση των φλοιοθαλαμικών νευρώνων (CT), οι οποίοι συγχρονίζουν τις ταλαντώσεις των ατράκτων στο θαλαμοφλοιικό δίκτυο. Πιο συγκεκριμένα, οι επαναλαμβανόμενες αιχμές στα ειδικά νευρωνικά κύτταρα («GABAεργικά») παράγουν ρυθμικά ανασταλτικά μετασυναπτικά δυναμικά σε TC νευρώνες. Η δραστηριότητα αυτή προκαλεί ανατροφοδοτικές ριπές αιχμών οι οποίες μεταφέρονται σε φλοιικές περιοχές και παράγουν μετασυναπτικά δυναμικά στα αντίστοιχα κύτταρα, συνοδευόμενα από παραγωγή ηλεκτρικών δυναμικών. Το

δίκτυο του θαλάμου είναι υψίστης σημασίας στην παραγωγή των ατράκτων.

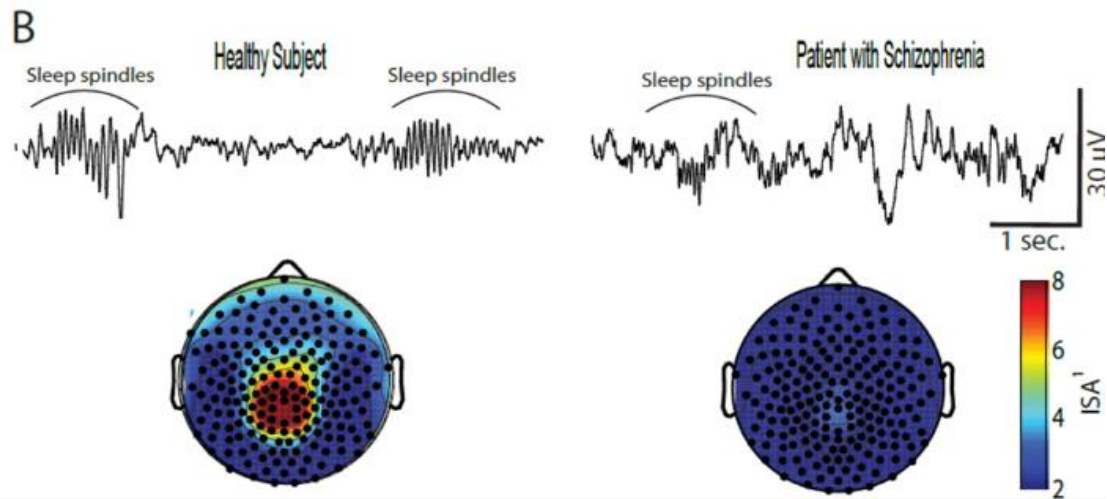


Εικόνα 1.6: Συνοπτικό διάγραμμα μηχανισμού παραγωγής ατράκτων [6]

1.6 Παθολογικές καταστάσεις σχετιζόμενες με τις ατράκτους -σχιζοφρένεια

Σύμφωνα με το άρθρο των Yingyi Zhang et.al [8], η σχιζοφρένεια είναι μια καταστρεπτική νοητική ασθένεια η οποία αφορά περίπου το 1% του πληθυσμού παγκοσμίως. Τη σχιζοφρένεια καθώς και άλλες παρεμφερείς ψυχωτικές καταστάσεις μπορεί να τις διαγνώσει κανείς είτε λόγω των «θετικών» συμπτωμάτων (π.χ. παραισθήσεις) είτε μέσω «αρνητικών» (π.χ. απάθεια). Ωστόσο, το βασικότερο κοινό τους στοιχείο, το οποίο βιώνουν οι περισσότεροι ψυχωτικοί ασθενείς και φανερώνεται ακόμα και στα πολύ αρχικά στάδια της νόσου είναι οι διαταραχές του ύπνου και η αϋπνία. Η συμπτωματολογία αυτή οδήγησε διάφορους επιστήμονες να ψάξουν στη σύνδεση μεταξύ του ύπνου και της παθοφυσιολογίας των ασθενειών αυτών.

Στη χρόνια σχιζοφρένεια παρατηρούνται ανωμαλίες τόσο στις υπνικές ατράκτους όσο και στα βραδέα κύματα. Στις ανωμαλίες εντάσσονται διάφορες παράμετροι όπως η τοπογραφική κατανομή και η σχέση τους μεταξύ των νευρωνικών και μοριακών/γενετικών μηχανισμών, ενώ ερευνάται και η σύνδεση μεταξύ των κυμάτων/ατράκτων με νοητικές ανεπάρκειες. Η μείωση σε παραμέτρους των ατράκτων, συμπεριλαμβανομένης της έντασης, του πλάτους, της διάρκειας και της πυκνότητας έχει εντοπιστεί σε αρκετούς ασθενείς που πάσχουν από σχιζοφρένεια. Το βασικότερο χαρακτηριστικό των πασχόντων είναι η μειωμένη πυκνότητα των ατράκτων όπως δείχνει η Εικόνα 1.7.



Εικόνα 1.7: Σύγκριση πυκνότητας υπνικών ατράκτων μεταξύ υγιούς ατόμου και ατόμου που πάσχει από σχιζοφρένεια [27]

2. Συστήματα αυτόματης ανίχνευσης ατράκτων

Στο κεφάλαιο αυτό αναλύονται οι βασικότερες κυματομορφές που εμφανίζονται στο ηλεκτροεγκεφαλογράφημα εκτός των υπνικών ατράκτων (ή κυμάτων σίγμα όπως αναφέρονται σε κάποιες βιβλιογραφικές αναφορές). Σε δεύτερο στάδιο αναφέρονται διάφορες ερευνητικές προσεγγίσεις που χρησιμοποιούνται για την αυτόματη ανίχνευση ατράκτων. Οι περισσότερες έχουν ασχοληθεί με την ανάλυση και ταξινόμηση των κυριότερων κυματομορφών που εμφανίζονται στο ΗΕΓ. Αρκετές εργασίες έχουν αναφερθεί σε προηγούμενη διπλωματική εργασία όποτε κρίνω σκόπιμο να μην συμπεριληφθούν στην παρούσα ερευνητική δουλειά. Για περισσότερες προσεγγίσεις μπορείτε να συμβουλευτείτε τη Διπλωματική Εργασία με τίτλο 'Ανάπτυξη αλγόριθμου βαθιής μάθησης για ανίχνευση υπνικών ατράκτων στο ηλεκτροεγκεφαλογράφημα' από τον κ.Σαρακηνό Σταύρο [1].

2.1 Χαρακτηριστικές κυματομορφές στο ηλεκτροεγκεφαλογράφημα


Οι κυματομορφές που εμφανίζονται στο ΗΕΓ σύμφωνα με τους Chetan S. Nayak et.al [9] μπορούν να χαρακτηριστούν με βάση την τοποθεσία, το πλάτος, τη συχνότητα, τη μορφολογία, τη συνέχεια (ρυθμική, διακοπτόμενη, συνεχής), τη συμμετρία καθώς και την αντιδραστικότητα. Η κυριότερη παράμετρος που λαμβάνεται υπόψη είναι το εύρος συχνότητας και οι κυματομορφές ονομάζονται χρησιμοποιώντας ελληνικά γράμματα (άλφα ρυθμός, θήτα ρυθμός κλπ). Ακόμα, έχουν βρεθεί ταλαντώσεις μικρής συχνότητας (Infra-Slow oscillation - ISO) και υψηλής συχνότητας (HFO) που φαίνεται πως έχουν κλινική σημασία.

Ένα συμβατικό ΗΕΓ εστιάζει στην ανάλυση κυματομορφών με συχνότητα μεταξύ 0,5 -70Hz. Η ανάλυση αυτή προκύπτει μετά από πέρασμα του ΗΕΓ σε βαθυπερατό φίλτρο. Υπάρχουν βέβαια περιπτώσεις που το ΗΕΓ μελετάται χωρίς φίλτρο, ώστε να ερευνηθεί μεγαλύτερο εύρος συχνοτήτων, ωστόσο στις παρακάτω προσεγγίσεις χρησιμοποιείται το παραπάνω φιλτράρισμα.

- Ταλαντώσεις εξαιρετικής χαμηλής συχνότητας (Infra-Slow oscillation - ISO) (<0.5 Hz). ISO είναι η κυρίαρχη κυματομορφή σε πρόωρα νεογνά έχει συχνότητα από 0.01 έως 0.1 Hz και έχει παροδική και αυθόρμητη δραστηριότητα με σημαντικό ρόλο στις νευρικές συνάψεις ιδίως στη νεογνική ηλικία όπου δεν έχει αναπτυχθεί πλήρως η αισθητική οδός. Ακόμα, οι ISO εμφανίζονται

και κατά τη διάρκεια του non-REM ύπνου σε συχνότητες 0.02 έως 0.2 Hz.

- Ρυθμός δέλτα (0.5-4Hz). Ο ρυθμός δέλτα φυσιολογικά εμφανίζεται στο στάδιο βαθέως ύπνου (στάδια III και κυρίως IV) και κυριαρχεί στις μετωπιοκεντρικές περιοχές του εγκεφάλου. Παθολογικοί δέλτα ρυθμοί φαίνονται σε καταστάσεις αφύπνισης σε περιπτώσεις εγκεφαλοπάθειας και εγκεφαλικών δυσλειτουργιών. Διακοπτόμενη λειτουργία του δέλτα ρυθμού εμφανίζεται μετωπιαία σε ενήλικες ενώ ινιακά στα παιδιά . Λειτουργία που εντοπίζεται κυρίως κροταφικά δείχνει ότι το άτομο πάσχει από παροδική επιληψία .
- Ρυθμός θήτα (4-7 Hz). Ο ρυθμός θήτα εμφανίζεται από το στάδιο της υπνηλίας (N1) έως και το στάδιο N2. Κατά κύριο λόγο κυριαρχεί σε μετωπιοκεντρικές περιοχές του εγκεφάλου και μεταναστεύει προς τα πίσω για να αντικαταστήσει τον ρυθμό άλφα σε περίπτωση πρόωρης υπνηλίας. Στην εγρήγορση, σε καταστάσεις έντονης συναισθηματικής φόρτισης φαίνεται ενισχυμένος ο ρυθμός θήτα και σε ενήλικες και σε παιδιά. Εμφάνιση του ρυθμού θήτα στην εγρήγορση (κατάσταση «awake») υποδεικνύει εστιακή εγκεφαλική δυσλειτουργία.
- Ρυθμός άλφα (8-12Hz). Ο οπίσθιος κυρίαρχος ρυθμός άλφα είναι χαρακτηριστικός σε φυσιολογικά ΗΕΓ ανθρώπου σε εγρήγορση στον ινιακό λοβό. Είναι η πιο χαρακτηριστική κυματομορφή σε ένα φυσιολογικό ΗΕΓ ενήλικου ατόμου με μάτια κλειστά. Ο ρυθμός άλφα φτάνει τα 8 Hz μέχρι την ηλικία των 3 ετών και υπό φυσιολογικές συνθήκες δε μειώνεται μέχρι και τα 90 περίπου έτη. Γρήγορες εναλλαγές του άλφα ρυθμού είναι αναμενόμενες σε φυσιολογικά άτομα, ωστόσο αργές εναλλαγές υποδεικνύουν γενικευμένη εγκεφαλική δυσλειτουργία.
- Ρυθμός βήτα (13-30Hz). Ο ρυθμός βήτα είναι ο πιο συχνά εμφανιζόμενος ρυθμός σε ενήλικες και παιδιά με μάτια ανοικτά. Είναι ορατός κυρίως σε μετωπιαίες και κεντρικές περιοχές του εγκεφάλου και μειώνεται όσο μετακινούμαστε προς τον ινιακό λοβό. Το πλάτος της κυματομορφής είναι συνήθως 10-20 mV και σπάνια υπερβαίνει τα 30 mV. Αυξάνεται κατά τη διάρκεια της φάσης υπνηλίας και σταδιακά μειώνεται στις φάσεις N2 και N3. Η αύξηση του πλάτους και η ποιότητα της κυματομορφής μπορεί να οφείλεται σε χρήση ηρεμιστικών (π.χ. βενζοδιαζεπίνες). Κεντρική, τοπική ή ημισφαιρική πτώση του ρυθμού βήτα οφείλεται σε φλοιικό τραυματισμό ή σε υποσκληρίδια ή επισκληρίδια συλλογή υγρού.




Εικόνα 2.1: Σήματα που εντοπίζονται σε φυσιολογικό ΗΕΓ [28]

- Κ-σύμπλεγμα (K-complex)

Ο Mustafa H. Gandhi [10] αναφέρει ότι τα Κ-συμπλέγματα είναι κυματομορφές που εντοπίζονται στο ΗΕΓ και συγκεκριμένα στο στάδιο 2 του NRem ύπνου, στο ίδιο στάδιο που εντοπίζονται οι υπνικές άτρακτοι και αποτελούν, αυτά και οι άτρακτοι, δύο από τα σημαντικότερα χαρακτηριστικά αυτού του σταδίου.

Το Κ-σύμπλεγμα είναι ένα ευκρινές, με πολύ φανερά όρια, υψηλής τάσης, διφασικό κύμα το οποίο διαρκεί για παραπάνω από 0,5 δευτερόλεπτα και χαρακτηρίζεται ως το μεγαλύτερης διάρκειας γεγονός σε ένα υγιές ΗΕΓ. Αρχικά, εμφανίζεται με μία μικρή θετική κυματομορφή με διάρκεια της τάξης των 200ms, ακολουθούμενη από ένα μεγάλο αρνητικό σύμπλεγμα με διάρκεια 550ms και τελικά, μια μεγάλης διάρκειας θετική κορυφή στα 900ms. Η πρώτη κορυφή, η μικρότερη, δεν είναι απαραίτητο να εμφανίζεται σε κάθε συμβάν.

Τα Κ-συμπλέγματα μπορεί να είναι αυθόρμητα (π.χ. να συμβούν κατά τη διάρκεια διακοπής της αναπνοής) ή να είναι αντίδραση σε κάποιο εξωτερικό ερέθισμα (π.χ. ερέθισμα στο δέρμα). Παρόλο που τα Κ-συμπλέγματα εντοπίζονται σε ευρεία περιοχή του εγκεφάλου, εμφανίζονται κατά κόρον στον άνω μετωπιαίο φλοιό.



Εικόνα 2.2: Κυματομορφή K-συμπλέγματος και υπνικής ατράκτου [29]

2.2-Περιγραφή συστημάτων αυτόματης ανίχνευσης ατράκτων

2.2.1 Προσαρμοσμένο φιλτράρισμα (Matched Filtering)

Οι Marc Jobert et.al [11] περιγράφουν την διαδικασία προσαρμοσμένου φιλτραρίσματος για την εύρεση ατράκτων ύπνου καθώς και K-συμπλεγμάτων (K-complex). Η διαδικασία προσαρμοσμένου φιλτραρίσματος χρησιμοποιείται γενικά για να αναγνωριστεί κάποιο γνωστό σήμα σε περιβάλλον θορύβου. Έτσι, δημιούργησαν ένα σύστημα το οποίο συγκρίνει ένα καταγραφόμενο σήμα ηλεκτροεγκεφαλογραφίας με βάση κάποιο πρότυπο που έχει εισαχθεί προηγουμένως. Το σύστημα αυτό στη συνέχεια ποσοτικοποιεί την ομοιότητα μεταξύ του δοθέντος και του προτύπου σήματος. Αρχικά, ορίζονται κάποιες παράμετροι του ιδανικού σήματος. Στην περίπτωση αυτή, έχουν ορίσει κάποια όρια συχνότητας και διάρκεια μικρότερη των 0,5 δευτερολέπτων. Ανάλογα με το πόσο ταιριάζουν τα δύο σήματα ταξινομούνται σε δύο καταστάσεις '0' ή '1'. Εφόσον το σύστημα έχει εκπαιδευτεί ορθά, περιμένουμε να δούμε στην έξοδο την κατάσταση '0' μόνο όταν υπάρχει άτρακτος στην είσοδο.

Η μέθοδος δοκιμάστηκε σε μελέτες ύπνου οκτώ εθελοντών χωρίς παθολογικά ευρήματα ηλικίας μεταξύ 26 και 37 ετών. Η επαλήθευση αποτελούταν από δύο στάδια. Σε πρώτο στάδιο χρησιμοποιήθηκε φάση εκπαίδευσης όπου προσαρμόστηκε το κατώφλι ώστε να μεγιστοποιήσει το ποσοστό των κυματομορφών που αντιστοιχούν όντως σε άτρακτο ενώ παράλληλα να μειώσει τον αριθμό των λανθασμένων ευρημάτων. Σε δεύτερο στάδιο χρησιμοποιήθηκαν καταγραφές ΗΕΓ διαφορετικές σε σχέση με αυτές της προηγούμενης φάσης και τα αποτελέσματα

συγκρίθηκαν με αυτά που είχαν σημειωθεί από γιατρό μέσω οπτικής αξιολόγησης. Σχετικά με τις ατράκτους που εντόπισε το αυτόματο σύστημα, 16% εξ αυτών δεν εντοπίστηκαν από την οπτική αξιολόγηση (ψευδώς θετικά), ενώ το 80% εντοπίστηκε και από το σύστημα και μέσω της οπτικής αξιολόγησης (ορθώς θετικά). Σχετικά με τα Κ-συμπλέγματα, από αυτά που ανίχνευσε το σύστημα, μόνο 9% ήταν ψευδώς θετικά αποτελέσματα, ενώ επιτεύχθηκε συμφωνία μεταξύ των δύο μεθόδων (οπτικής και αυτόματης) στο 85% (ορθώς θετικά).

2.2.2 Σύνθετη αποδιαμόρφωση (Complex Demodulation - CDM)

Οι Jiabin Li et.al [12] περιγράφουν τη διαδικασία σύνθετης αποδιαμόρφωσης για την εύρεση ατράκτων σε τέσσερα στάδια. Αρχικά, εντοπίζονται και αποκόπτονται τα α-κύματα και τα παράσιτα από την κίνηση των ματιών και των μυών. Στη συνέχεια χρησιμοποιείται ο αλγόριθμος της σύνθετης αποδιαμόρφωσης CDM για να εισάγει το εναλλασσόμενο πλάτος των ατράκτων (11-16Hz). Μετά από την ανάλυση, υπολογίζεται ένα σετ 4 παραμέτρων, δύο εκ των οποίων σχετίζονται με μορφολογικά χαρακτηριστικά των καμπυλών (μέγιστο πλάτος και μέση κλίση) και δύο με τον λόγο ισχύος της φασματικής ζώνης ατράκτων ως προς τις ζώνες α και θ ρυθμού και με βάση αυτές τις τιμές σχεδιάζεται και εκπαιδεύεται ένα δέντρο απόφασης. Τα αποτελέσματα έδειξαν ολική ακρίβεια από 76 ως 90.

2.2.3 Εντοπισμός ατράκτων μέσω μετασχηματισμού Fourier και είσοδο των αποτελεσμάτων σε γνωστούς ταξινομητές

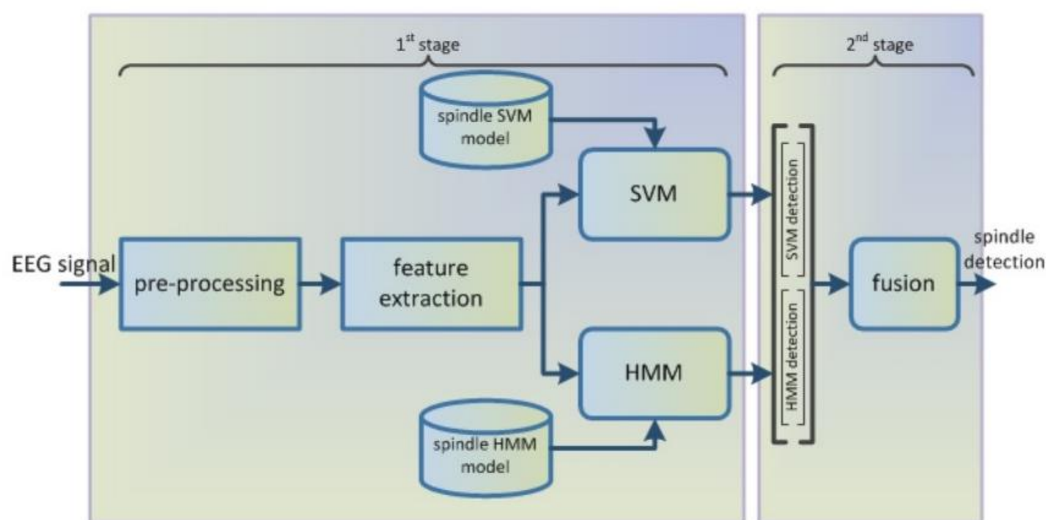
Οι Wessam Al-Salman et.al [13] χρησιμοποίησαν δεδομένα από δύο ανοιχτές βάσεις δεδομένων: DREAMS και Montreal Archive Sleep Studies (MASS), τα οποία αναλύθηκαν σε περιβάλλον Matlab. Η εύρεση των ατράκτων χωρίζεται σε δύο στάδια εκπαίδευσης (training) και ελέγχου (testing). Τα σήματα που παράγονται από το ΗΕΓ χωρίζονται σε τμήματα μέσω της τεχνικής του «κυλιόμενου παραθύρου» και το μέγεθος του παραθύρου έχει οριστεί στα 0.5 δευτερόλεπτα με υπερκάλυψη 0.4 δευτερόλεπτα (έγιναν προσπάθειες και με παράθυρα 0.25, 1.0, 1.5, 2.0, ωστόσο τα καλύτερα αποτελέσματα ήταν με παράθυρο 0.5). Κάθε τμήμα υφίσταται μετασχηματισμό Fourier και αναγνωρίζονται οι βασικές επιθυμητές ζώνες συχνότητας (α,β,θ,δ,γ). Για κάθε ζώνη συχνότητας εξάγονται 10 στατιστικά χαρακτηριστικά (median, maximum, minimum, mean, mode, range, standard deviation, variation, skewness, kurtosis) και για κάθε τμήμα ΗΕΓ εξάγονται 50 χαρακτηριστικά. Τα εξαγόμενα χαρακτηριστικά χρησιμοποιούνται ως είσοδος σε τέσσερις διαφορετικούς ταξινομητές: 1) Ταξινομητής ελάχιστου τετραγώνου (LS-SVM / Least-

squares support vector machine), 2) K- κοντινότεροι γείτονες (K-nearest neighbor), 3) K-μέσο (K-means), 4) Δέντρο απόφασης (C4.5 decision tree).

Οι παραπάνω ταξινομητές χρησιμοποιήθηκαν διότι προηγούμενες μελέτες έδειξαν ότι είναι πολύ αποδοτικοί σε επεξεργασία βιοσημάτων. Τα αποτελέσματα της μελέτης έδειξαν ότι την μέγιστη επίδοση πέτυχε η τεχνική LS-SVM με ποσοστό ολικής ακρίβειας (total accuracy) 97,9%.

2.2.4 Εύρεση ατράκτων συνδυάζοντας Κρυφά Μοντέλα Μαρκόβ (HMM - Hidden Markov Models) και Μηχανές Υποστήριξης Διανυσμάτων (SVM - (Support Vector Machines)

Οι Mporas et.al [14] αποφάσισαν να συνδυάσουν αλγορίθμους HMM και SVM λόγω της εξαιρετικής τους απόδοσης σε άλλες ερευνητικές δουλειές που είχαν να κάνουν με επεξεργασία σήματος. Η αναγνώριση ατράκτων στην παρούσα προσέγγιση γίνεται σε δύο στάδια. Στο πρώτο στάδιο γίνεται προ-επεξεργασία του σήματος, παραμετροποιείται και γίνεται επεξεργασία ξεχωριστά σε HMM και SVM. Στο δεύτερο στάδιο τα αποτελέσματα των δύο αλγορίθμων ενώνονται με μία μέθοδο «σύντηξης» «fusion» μέθοδο ώστε να δώσουν το τελικό αποτέλεσμα σχετικά με την εύρεση των ατράκτων. Παρακάτω στην Εικόνα 2.5 φαίνεται το block διάγραμμα των διαδικασιών που ακολουθούνται:



Εικόνα 2.5: Διάγραμμα υλοποίησης διαδικασιών HMM και SVM [14]

Για την υλοποίηση των μοντέλων HMM και SVM χρησιμοποιήθηκαν τα εργαλεία WEKA και HTK. Συγκεκριμένα, για το μοντέλο SVM χρησιμοποίησαν τους αλγορίθμους SMO (Sequential Minimal Optimization) και RBF kernel (Radial Basis Function kernel).

Οι παράμετροι C και γ εμπειρικά επιλέχθηκαν σε 1 και 0,01 αντίστοιχα. Οι παραπάνω αλγόριθμοι χρησιμοποιήθηκαν και στο μοντέλο σύντηξης. Για το μοντέλο HMM, χρησιμοποιήθηκε τρισδιάστατη αρχιτεκτονική μοντέλου HMM, της οποίας οι καταστάσεις ήταν μια μίξη από οκτώ γκαουσιανές κατανομές. Οι παράμετροι του HMM υπολογιστήκαν μέσω του αλγορίθμου Baum-Welch.

Τα δεδομένα ΗΕΓ που χρησιμοποιήθηκαν καταγράφηκαν από την Ιατρική Σχολή του Πανεπιστημίου Πατρών. Η συχνότητα δειγματοληψίας ήταν 2500Hz, χρησιμοποιώντας 64 κανάλια. Η διάρκεια ήταν περίπου 401 λεπτά και βρέθηκαν 1228 συμβάματα υπνικών ατράκτων μέσω αξιολόγησης ειδικών. Στα δεδομένα εκπαίδευσης και ελέγχου δεν υπάρχει επικάλυψη.

Για την αποσύνθεση του σήματος χρησιμοποιήθηκαν παράθυρα 0,5 δευτερολέπτων με μετατόπιση/κύλιση 0,1 δευτερολέπτου. Για κάθε παράθυρο η δυναμική φασματική πυκνότητα υπολογίστηκε από το εύρος της συχνότητας 10-20Hz με ακρίβεια 1Hz.

Η ακρίβεια από το SVM μοντέλο ήταν 88% ενώ τα ψευδώς θετικά και ψευδώς αρνητικά ήταν περίπου 11,5%. Στο μοντέλο HMM βρέθηκε συνολική ακρίβεια περίπου 87% ωστόσο τα ποσοστά ψευδώς θετικών και ψευδώς αρνητικών αποτελεσμάτων ήταν 15% και 13% αντίστοιχα. Θα πρέπει να σημειωθεί ότι στο 24% των δειγμάτων τα δύο μοντέλα έδωσαν εντελώς διαφορετικές αποφάσεις, συνεπώς υπάρχει η ανάγκη συνδυασμού των δύο μεθόδων. Όταν οι δύο μέθοδοι συνδυάστηκαν, τα ψευδώς αρνητικά ήταν περίπου 12%, αλλά μειώθηκαν σημαντικότερα τα ψευδώς θετικά στο 3%.

3. Βαθεία Μάθηση και Νευρωνικά Δίκτυα

Εισαγωγή

Στο παρόν κεφάλαιο αναλύεται το θεωρητικό υπόβαθρο σχετικά με τη βαθειά μάθηση και τα νευρωνικά δίκτυα. Αναλύονται τα νευρωνικά δίκτυα που χρησιμοποιούνται κυρίως στην ιατρική έρευνα και δίνονται παραδείγματα στα οποία φαίνεται η καταλληλότητα του καθενός. Τέλος, περιγράφονται τα νευρωνικά δίκτυα τα οποία χρησιμοποιήθηκαν στην παρούσα ερευνητική εργασία.

3.1 Βαθεία Μάθηση

Στο άρθρο της η Shania Kennedy [15] γράφει ότι η βαθειά μάθηση (DL- Deep Learning) αποτελεί υποκατηγορία της μηχανικής μάθησης (ML-Machine Learning) και βασίζεται στον τρόπο με τον οποίο συνδέονται και αλληλεπιδρούν οι νευρώνες μεταξύ τους, ώστε να επεξεργαστούν πληροφορίες. Για να μιμηθεί τη σύνδεση αυτή χρησιμοποιείται αλγοριθμική αρχιτεκτονική γνωστή ως νευρωνικά δίκτυα (NN- Neural Networks). Αναλύοντας πως τα δεδομένα φιλτράρονται μεταξύ των στρωμάτων των νευρωνικών δικτύων και πως αλληλεπιδρά το ένα με το άλλο, ο αλγόριθμος βαθειάς μάθησης «μαθαίνει» να κάνει συσχετίσεις και συνδέσεις μεταξύ των δεδομένων.

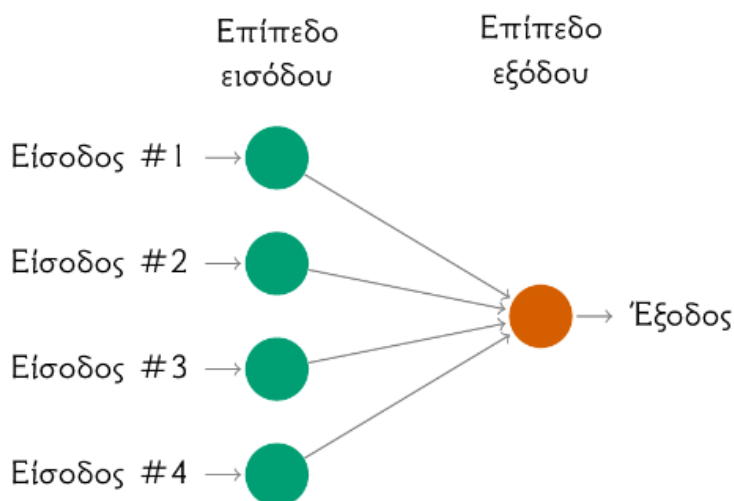
3.2 Νευρωνικά Δίκτυα

Σύμφωνα με τον Simon Haykin [16] το έργο στο επιστημονικό πεδίο των τεχνητών νευρωνικών δικτύων βασίστηκε στο γεγονός ότι ο ανθρώπινος εγκέφαλος εκτελεί τους υπολογισμούς με εντελώς διαφορετικό τρόπο από το συμβατικό ψηφιακό υπολογιστή. Ο εγκέφαλος είναι ένας εξαιρετικά πολύπλοκος, μη γραμμικός, παράλληλος υπολογιστής που έχει τη δυνατότητα να οργανώνει τα δομικά του στοιχεία, γνωστά ως νευρώνες, με τρόπο ώστε να εκτελούν συγκεκριμένους υπολογισμούς, με ταχύτητα πολλαπλάσια από αυτή του γρηγορότερου ψηφιακού υπολογιστή που υπάρχει σήμερα.

Αν θέλουμε να δώσουμε έναν ακριβή ορισμό, τότε μπορούμε να γράψουμε το εξής: Ένα νευρωνικό δίκτυο είναι ένας τεράστιος παράλληλος επεξεργαστής με κατανεμημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από τη φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση και να την καθιστά διαθέσιμη για χρήση. Μοιάζει με τον ανθρώπινο εγκέφαλο σε δύο βασικά σημεία:

- 1) Το δίκτυο προσλαμβάνει γνώση από το περιβάλλον του μέσω μιας διαδικασίας μάθησης (training).
- 2) Η ισχύς των συνδέσεων μεταξύ των νευρώνων, που αποκαλείται συναπτικό βάρος, χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτιέται.


Σύμφωνα με τους Rob J Hyndman et.al [17], ένα νευρωνικό δίκτυο μπορεί να θεωρηθεί και ως δίκτυο νευρώνων που είναι οργανωμένο σε επίπεδα. Οι παράγοντες πρόβλεψης αποτελούν την είσοδο και σχηματίζουν το κάτω επίπεδο ενώ οι προβλέψεις αποτελούν την έξοδο και σχηματίζουν το ανώτερο επίπεδο. Μπορεί επίσης να υπάρχουν ενδιάμεσα επίπεδα που περιέχουν κρυμμένους νευρώνες (hidden units). Τα απλούστερα δίκτυα δεν περιέχουν κρυφά επίπεδα και είναι ισοδύναμα με γραμμικές παλινδρομήσεις. Στην Εικόνα 3.1 φαίνεται η δομή ενός απλού δικτύου.



Εικόνα 3.1: Νευρωνικό δίκτυο ισοδύναμο με μια γραμμική παλινδρόμηση [17]

Οι συντελεστές που συνδέονται με τις προβλέψεις ονομάζονται βάρη (bias). Τα βάρη επιλέγονται στο πλαίσιο του νευρωνικού δικτύου χρησιμοποιώντας έναν αλγόριθμο εκμάθησης που ελαχιστοποιεί μια συνάρτηση κόστους.

Αν προστεθούν ένα ή περισσότερα επίπεδα το δίκτυο παύει να είναι γραμμικό, όπως φαίνεται στην Εικόνα 3.2.



Εικόνα 3.2 Παράδειγμα νευρωνικού δικτύου με τέσσερις εισόδους και ένα κρυφό επίπεδο με τρεις κρυμμένους νευρώνες [17]


Το δίκτυο αυτό είναι εμπρόσθιας διάδοσης και κάθε επίπεδο λαμβάνει εισόδους από το προηγούμενο. Οι έξοδοι των κόμβων σε ένα επίπεδο είναι εισοδοί στο επόμενο κ.ο.κ. Οι εισοδοί σε κάθε κόμβο συνδυάζονται χρησιμοποιώντας έναν σταθμισμένο γραμμικό συνδυασμό και στη συνέχεια το αποτέλεσμα τροποποιείται από μια γραμμική συνάρτηση (συνάρτηση ενεργοποίησης).

Η διαδικασία μέσω της οποίας επιτυγχάνεται η μάθηση αποκαλείται αλγόριθμος μάθησης και η λειτουργία του είναι να τροποποιεί τα συναπτικά βάρη του δικτύου με τον κατάλληλο τρόπο για την επίτευξη του επιθυμητού στόχου.

3.2.1 Κατηγορίες συναρτήσεων ενεργοποίησης


Σε άρθρο του ο Sagar Sharma [18] αναφέρει ότι οι συναρτήσεις ενεργοποίησης μπορούν να διαχωριστούν σε δύο βασικές κατηγορίες: α) γραμμικές και β) μη γραμμικές. Συχνότερα χρησιμοποιούμενες στα νευρωνικά δίκτυα είναι οι μη γραμμικές, διότι βοηθούν το μοντέλο να προσαρμοστεί σε μια πληθώρα δεδομένων και να τα ξεχωρίσει πριν την έξοδο.

1) Σιγμοειδής συνάρτηση (Sigmoid function)




Η σιγμοειδής συνάρτηση έχει εύρος τιμών από 0 έως 1. Για το λόγο αυτό χρησιμοποιείται σε μοντέλα τα οποία στην έξοδο τους πρέπει να προβλέψουν πιθανότητα, είτε σε μοντέλα δυαδικής κατηγοριοποίησης.

2) Υπερβολική εφαπτομένη (Hyperbolic Tangent function)




Η υπερβολική εφαπτομένη έχει εύρος τιμών από -1 έως 1. Το θετικό της είναι ότι λαμβάνει στην είσοδο αρνητικές τιμές και παράγει καλύτερα αποτελέσματα όσο αυξάνονται τα κρυφά επίπεδα.

3) Rectified Linear Unit (ReLU)



Η συνάρτηση ReLU είναι η πιο συχνά χρησιμοποιούμενη συνάρτηση ενεργοποίησης και χρησιμοποιείται και στα νευρωνικά δίκτυα αλλά και στη βαθιά μάθηση. Το εύρος της είναι από το 0 έως το άπειρο. Η $f(z)$ είναι μηδέν όταν το z είναι ίσο ή μικρότερο του μηδενός. Το πρόβλημα της συνάρτησης αυτής είναι ότι οι αρνητικές τιμές γίνονται αυτομάτως 0 και αυτό ελαττώνει τη δυνατότητα του μοντέλου να εκπαιδευτεί σωστά.

4) Leaky ReLU



Η συνάρτηση leaky ReLU δημιουργήθηκε για να λύσει το πρόβλημα το οποίο δημιουργούσε η ReLU σχετικά με το εύρος τιμών. Όπως φαίνεται και στο διάγραμμα υπάρχει ένας παράγοντας a με τον οποίο πολλαπλασιάζεται η συνάρτηση και πλέον το εύρος τιμών δεν ξεκινάει από το 0. Συνήθως ο παράγοντας a είναι 0.01, ωστόσο μπορεί να πάρει

οποιαδήποτε τιμή και τότε η συνάρτηση ονομάζεται “Randomized ReLU”.

3.2.2 Πλεονεκτήματα νευρωνικών δικτύων

Τα νευρωνικά δίκτυα προσφέρουν τα ακόλουθα πλεονεκτήματα και δυνατότητες:

Α) Μη γραμμικότητα: Η μη γραμμικότητα είναι εξαιρετικά σημαντική ιδιότητα, κυρίως εάν ο υποκείμενος φυσικός μηχανισμός που είναι υπεύθυνος για την παραγωγή του σήματος εισόδου (π.χ. ομιλία) είναι εκ φύσεως μη γραμμικός.

Β) Αντιστοίχιση εισόδου-εξόδου: Η επιβλεπόμενη μάθηση συνίσταται στην τροποποίηση των συναπτικών βαρών ενός νευρωνικού δικτύου εφαρμόζοντας ένα σύνολο χαρακτηρισμένων παραδειγμάτων εκπαίδευσης. Κάθε παράδειγμα αποτελείται από ένα μοναδικό σήμα εισόδου (πολυδιάστατο) και μια αντίστοιχη επιθυμητή απόκριση. Στο δίκτυο εισάγεται τυχαία ένα παράδειγμα από το σύνολο και τα συναπτικά βάρη του δικτύου τροποποιούνται έτσι ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της επιθυμητής απόκρισης και της πραγματικής απόκρισης του δικτύου που παράγεται από το σήμα εισόδου, σύμφωνα με ένα κατάλληλο στατιστικό κριτήριο. Η εκπαίδευση επαναλαμβάνεται για πολλά παραδείγματα του συνόλου εκπαίδευσης μέχρι το δίκτυο να φτάσει σε μια ευσταθή κατάσταση, όπου δεν υπάρχουν περαιτέρω σημαντικές μεταβολές στα συναπτικά βάρη. Στη συνέχεια τα παραδείγματα μπορούν να χρησιμοποιηθούν εκ νέου με άλλη σειρά, βελτιώνοντας την εκπαίδευση του δικτύου. Έτσι, το δίκτυο μαθαίνει από τα παραδείγματα κατασκευάζοντας μια αντιστοίχιση εισόδου-εξόδου για το δοθέν πρόβλημα.

Γ) Προσαρμοστικότητα: Τα νευρωνικά δίκτυα έχουν εγγενή δυνατότητα να προσαρμόζουν τα συναπτικά βάρη τους ανάλογα με τις μεταβολές που γίνονται στο περιβάλλον τους. Όταν λειτουργεί σε ένα μη στατικό περιβάλλον (μεταβολή χρόνου), ένα νευρωνικό δίκτυο μπορεί να σχεδιαστεί ώστε να μεταβάλλει τα συναπτικά βάρη του σε πραγματικό χρόνο. Για την ορθή αξιοποίηση των ιδιοτήτων της προσαρμοστικότητας, οι κύριες σταθερές χρόνου του δικτύου θα πρέπει να έχουν επαρκή διάρκεια έτσι ώστε το σύστημα να αγνοεί τις πλασματικές διαταραχές, και ταυτόχρονα μικρή διάρκεια ώστε το σύστημα να ανταποκρίνεται επαρκώς στις μεταβολές του περιβάλλοντος που έχουν σημασία (δίλλημα σταθερότητας – πλαστικότητας).

Δ) Ενδεικτική απόκριση: Στο χώρο ταξινόμησης προτύπων, ένα νευρωνικό δίκτυο μπορεί να παρέχει πληροφορία όχι μόνο για το ποιο συγκεκριμένο πρότυπο θα επιλεγεί, αλλά επίσης σχετικά με το βαθμό

εμπιστοσύνης στη ληφθείσα απόφαση. Αυτή η δεύτερη πληροφορία είναι χρήσιμη για την απόρριψη «πλασματικών» μοτίβων και συνεπώς για τη βελτίωση της ακρίβειας του δικτύου.

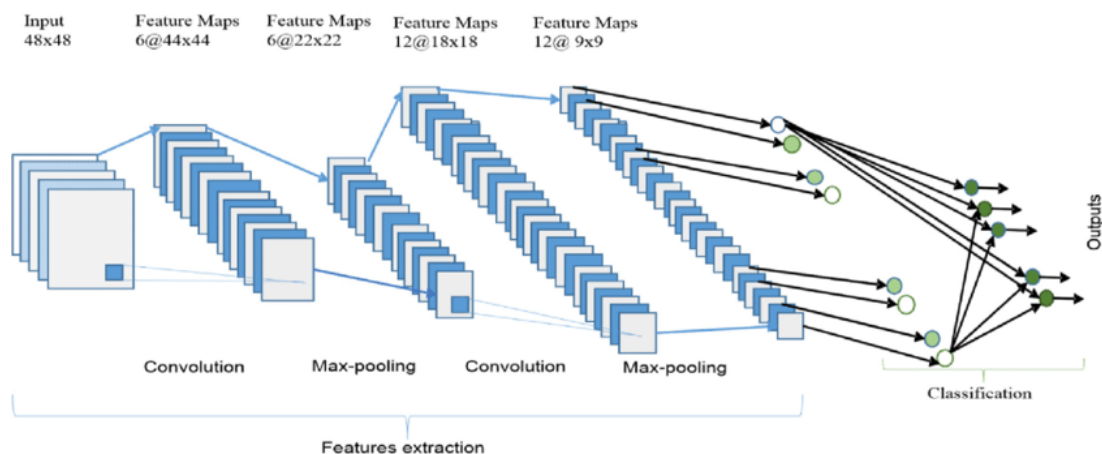
Ε) Δυνατότητα υλοποίησης σε τεχνολογία μεγάλης κλίμακας ολοκλήρωσης (VSLI).

ΣΤ) Αναλογία με τη νευροφυσιολογία του εγκεφάλου: Η σχεδίαση ενός νευρωνικού δικτύου δανείζεται στοιχεία από τη λειτουργία του ανθρώπινου εγκεφάλου, ο οποίος είναι η ζωντανή απόδειξη ότι η εύρωστη, παράλληλη επεξεργασία δεν είναι μόνο φυσικά εφικτή, αλλά επίσης γρήγορη και ισχυρή. Οι νευροβιολόγοι αντιμετωπίζουν τα νευρωνικά δίκτυα ως ένα ερευνητικό εργαλείο για την ερμηνεία νευροβιολογικών φαινομένων. Από την άλλη, οι μηχανικοί αναζητούν στον τομέα της νευροβιολογίας νέες ιδέες για επίλυση προβλημάτων που είναι πολύ πιο πολύπλοκα από αυτά που βασίζονται στις συμβατικές τεχνικές σχεδίασης.

3.3.1 Συνελκτικά νευρωνικά δίκτυα CNN (Convolutional Neural Network)

Τα CNN δίκτυα είναι ένας τύπος νευρωνικών δικτύων που χρησιμεύουν κυρίως στην ταξινόμηση οπτικών δεδομένων. Χρησιμοποιούνται για να αναλύσουν εικόνες και να εξάγουν χαρακτηριστικά από αυτές, ώστε να ταξινομήσουν τις εικόνες σε διάφορες κατηγορίες.


Η ταξινόμηση εικόνων είναι ένα πολύ σημαντικό εργαλείο σε χώρους όπως η ιατρική απεικόνιση διότι δίνει τη δυνατότητα διάγνωσης διαφόρων καταστάσεων και συμβάλει στην βελτίωση λήψης αποφάσεων. Τα δίκτυα CNN υπολογίζουν σχέσης συνέλιξης μεταξύ των εικόνων που τους δίνονται ως παραδείγματα εκμάθησης και αυτές οι σχέσεις στην συνέχεια αποτυπώνονται στα συναπτικά βάρη του δικτύου.



Εικόνα 3.3: Παράδειγμα συνελκτικού νευρωνικού δικτύου [30]

3.2.2 Αναδρομικά νευρωνικά δίκτυα - RNN (Recurrent Neural Network)

Τα RNN δίκτυα χρησιμοποιούν ακολουθιακά δεδομένα ή δεδομένα τα οποία εξαρτώνται από τον χρόνο. Συχνά χρησιμοποιούνται για να λύσουν προβλήματα σχετικά με την επεξεργασία του λόγου, μετάφραση γλωσσών, αναγνώριση φωνής και περιγραφή εικόνων. Η λειτουργία τους βασίζεται στην εξάρτηση των δεδομένων εισόδου-εξόδου με χρονικά και κατευθυντηριακά αναδρομικό τρόπο, κάτι το οποίο δε συμβαίνει στα υπόλοιπα νευρωνικά δίκτυα, όπως φαίνεται στην Εικόνα 3.4. Χρονική αναδρομή σημαίνει ότι τα αποτελέσματα εκπαίδευσης από ένα προηγούμενο χρονικά παράδειγμα τροποποιούν την επίδραση εκπαίδευσης που θα έχει ένα επόμενο και χρονικά συσχετισμένο δείγμα εκπαίδευσης. Κατευθυντηριακή αναδρομή (bi-directionality) σημαίνει ότι η «φορά» που ενεργοποιούνται οι νευρώνες στη διαδικασία εκπαίδευσης είναι και από το στρώμα εισόδου προς το στρώμα εισόδου και (μετά) αντίστροφα από το στρώμα εξόδου προς το στρώμα εισόδου και πάλι από την αρχή, «προς τα μπρος-προς τα πίσω» (forward-backward).

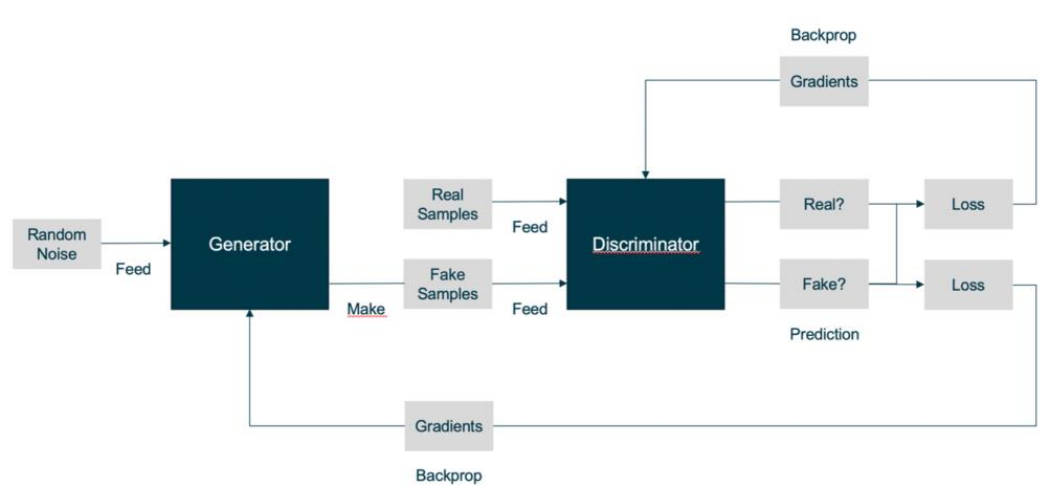


Εικόνα 3.4: Παράδειγμα αναδρομικού νευρωνικού δικτύου [31]

3.2.3 Παραγωγικά αντιπαλικά δίκτυα - GAN (Generative Adversarial Network)

Τα GANs χρησιμοποιήθηκαν πρώτη φορά από τον Ian Goodfellow και τους συνεργάτες του [19]. Η λογική πίσω από αυτά τα δίκτυα είναι ότι χρησιμοποιούνται δύο διαφορετικά νευρωνικά δίκτυα τα οποία διαγωνίζονται μεταξύ τους σε ένα παιχνίδι μηδενικού αθροίσματος ‘zero-sum game’, όπου το κέρδος του ενός είναι αυτόματα η ήττα του άλλου. Τα δύο νευρωνικά δίκτυα χαρακτηρίζονται ως «δημιουργό» ‘generator’ και ως «μεροληπτικό»/«διαχωριστικό» ‘discriminator’.

Συνήθως, χρησιμοποιούνται σε εικόνες (π.χ. εικόνες MRI), βίντεο και παραγωγή φωνής.



Εικόνα 3.5: Παράδειγμα αντιπαλικών νευρωνικών δικτύων [19]

3.3 LSTM (Long Short Term Memory)

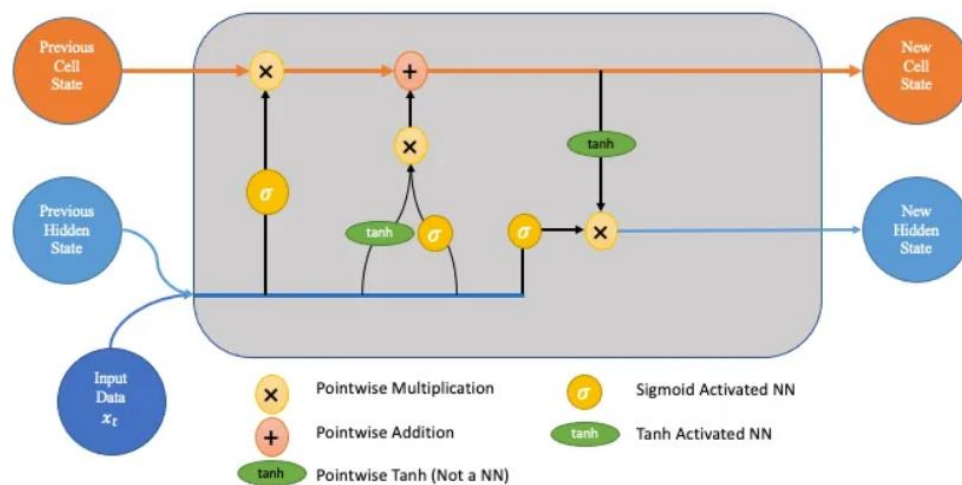
Στο άρθρο του ο Rian Dolphin [20] εξηγεί ότι τα δίκτυα μακροχρόνιας-βραχυχρόνιας μνήμης (Long-Short Term Memory – LSTM) δημιουργήθηκαν λόγω της ανάγκης να ξεπεραστεί το πρόβλημα που παρουσιάζουν προηγούμενα αναδρομικά νευρωνικά δίκτυα, το οποίο συνίσταται στο ότι δεν μπορούν να «θυμούνται» αλυσίδες μακρών χρονοσειρών. Αυτό μοιάζει με το όριο που έχουμε οι περισσότεροι άνθρωποι στο πόσο μήκος από νότες μπορεί να έχει μια μελωδία που θυμόμαστε. Τα LSTM, όπως και πολλά άλλα δίκτυα τύπου RNN, περιέχουν συνδέσεις ανάδρασης τα οποία τα ξεχωρίζουν από τα παραδοσιακά δίκτυα feedforward. Η ιδιότητα αυτή τους επιτρέπει να επεξεργάζονται ολόκληρες σειρές δεδομένων (π.χ. χρονοσειρές) χωρίς να χρειάζεται να μελετούν κάθε σημείο της σειράς ανεξάρτητα, αντιθέτως, συγκρατούν χρήσιμες πληροφορίες για τα προηγούμενα δεδομένα ώστε να βοηθήσουν στην επεξεργασία των καινούριων. Το βασικό όμως χαρακτηριστικό των δικτύων LSTM είναι ότι έχουν ενσωματωμένο

μηχανισμό που παρέχει ισορροπία ανάμεσα σε «μικρής διάρκειας» (short-term) και «μακράς διάρκειας» (long-term) εκμάθηση χρονοσειρών, σταθμίζοντας πότε πρέπει να υπερισχύσει η εκμάθηση μακρών χρονοσειρών και πότε σύντομων, όπως εισάγονται διαδοχικές χρονοσειρές εκμάθησης. Συνεπώς, τα LSTM δίκτυα είναι πολύ χρήσιμα σε περιπτώσεις επεξεργασίας ακολουθιών όπως κείμενο, ομιλία και γενικώς οτιδήποτε εμπεριέχει χρονική εξάρτηση.

Σε ένα βασικό επίπεδο, η έξοδος των LSTM εξαρτάται από τρεις παράγοντες:

- A) Η μακροπρόθεσμη μνήμη του δικτύου (cell state)
- B) Η έξοδος στο προηγούμενο σημείο της χρονοσειράς (previous hidden state)
- Γ) Τα δεδομένα εισόδου στο συγκεκριμένο χρονικό σημείο.

Τα LSTM χρησιμοποιούν μια σειρά από πύλες οι οποίες ελέγχουν πως διαρρέεται η πληροφορία στα διάφορα στάδια, και πως τελικά εξέρχεται. Οι τρεις βασικές πύλες είναι οι εξής: forget gate, input gate, output gate. Η κάθε μια μπορεί να θεωρηθεί ως φίλτρο και είναι από μόνη της ένα νέο νευρωνικό δίκτυο. Στην παρακάτω εικόνα φαίνονται οι συνδέσεις μεταξύ των καταστάσεων και των πυλών:



Εικόνα 3.6: Σχεδιάγραμμα LSTM δικτύου [20]

Στο πρώτο βήμα της διαδικασίας ασχολούμαστε με την forget gate. Εκεί αποφασίζουμε ποια από τα δεδομένα είναι χρήσιμο να εισάγουμε και από την προηγούμενη hidden state αλλά και ως νέα δεδομένα. Για τον σκοπό αυτό οι δύο πύλες ενώνονται σε ένα νευρωνικό δίκτυο. Αυτό το δίκτυο παράγει ένα διάνυσμα όπου κάθε στοιχείο βρίσκεται στο ενδιάμεσο μεταξύ $[0,1]$ (χρησιμοποιείται σιγμοειδής συνάρτηση). Αυτό το δίκτυο είναι εκπαιδευμένο ώστε όταν ένα στοιχείο είναι κοντά στο 0 το θεωρεί μη σχετικό ενώ όταν είναι κοντά στο 1 σχετικό. Το διάνυσμα

αυτό λοιπόν λειτουργεί ως ‘φίλτρο’ το οποίο επιτρέπει να περάσουν περισσότερες πληροφορίες των δεδομένων που βρίσκονται κοντά στο 1. Οι εξαγόμενες τιμές ξαναπερνούν στην προηγούμενη cell state και πολλαπλασιάζονται. Οι τιμές που ήταν κοντά στο 0 πολλαπλασιάζονται με έναν αριθμό κοντά στο 0 και επηρεάζουν λιγότερο τα επόμενα βήματα. Συνοπτικά, η forget gate αποφασίζει ποια δεδομένα πρέπει να «ξεχαστούν» (έχουν μικρότερο βάρος) και ποια πρέπει να χρησιμοποιηθούν στις παρακάτω διαδικασίες.

Το δεύτερο βήμα αφορά τη «νέα» μνήμη δικτύου και την πύλη εισόδου (input gate). Ο στόχος σε αυτό το βήμα είναι να καθοριστεί ποιες νέες πληροφορίες θα προστεθούν στην cell state. Η νέα μνήμη δικτύου καθώς και η πύλη εισόδου αποτελούν από μόνες τους νευρωνικά δίκτυα και δέχονται τις ίδιες εισόδους, την προηγούμενη hidden state και τα νέα δεδομένα.

Η νέα μνήμη δικτύου είναι ένα νευρωνικό δίκτυο με συνάρτηση ενεργοποίησης υπερβολικής εφαπτομένης (tanh), η οποία μαθαίνει πως να συνδυάζει την προηγούμενη κατάσταση (hidden state) με τα νέα δεδομένα εισόδου δημιουργώντας ένα ‘διάνυσμα νέας μνήμης’. Το διάνυσμα αυτό περιέχει πληροφορίες από τα νέα δεδομένα εισόδου χρησιμοποιώντας το πλαίσιο της hidden state. Επιλέγεται η εφαπτομένη διότι έχει τιμές από $[-1,1]$ και δίνει τη δυνατότητα αρνητικών τιμών σε περίπτωση που θέλουμε να μειώσουμε την επίδραση κάποιων νέων δεδομένων στη cell state.

Το πρόβλημα που δημιουργεί όμως αυτό το διάνυσμα είναι ότι δε μπορεί να ελέγξει αν τα νέα δεδομένα που εισάγονται είναι ωφέλιμο να προστεθούν στη μνήμη. Το πρόβλημα αυτό λύνει η πύλη εισόδου η οποία έχει σιγμοειδή συνάρτηση ενεργοποίησης $[0,1]$ και δρα ως φίλτρο, αναγνωρίζοντας ποια στοιχεία του διανύσματος είναι άξια να συκρατηθούν στη μνήμη με τον ίδιο τρόπο που λειτουργεί και η forget gate.

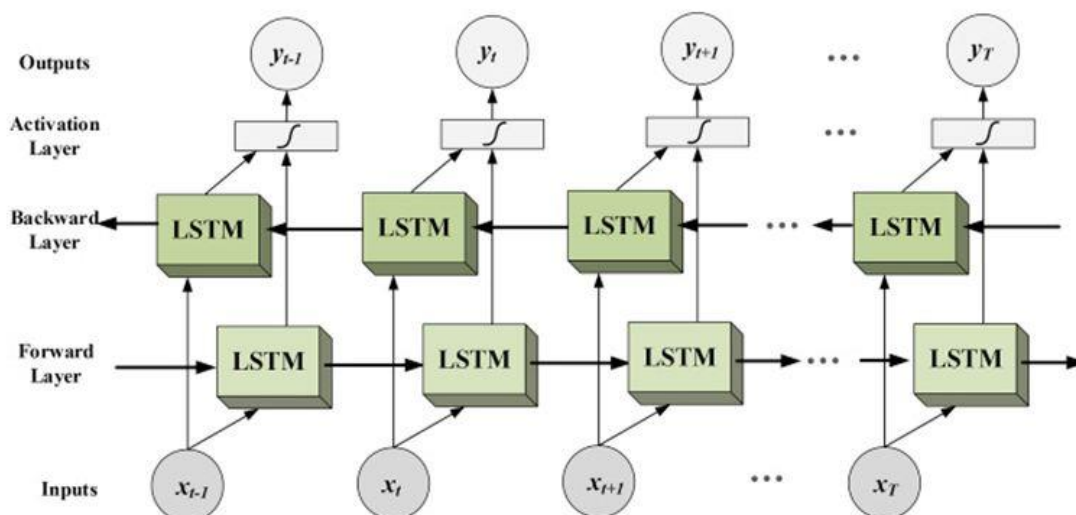
Η έξοδος από τα δύο παραπάνω βήματα προστίθεται στην cell state και έχει ως αποτέλεσμα την «τελική» «βραχυ-μακροπρόθεσμη» μνήμη του δικτύου.

Αφού έχει ενημερωθεί η μνήμη του δικτύου, το τελευταίο στάδιο αποτελεί η πύλη εξόδου η οποία αποφασίζει τη νέα hidden state. Η πύλη εξόδου δρα επίσης ως φίλτρο και έχει σιγμοειδή ενεργοποίηση.

Πρέπει να σημειωθεί ότι παρότι η πύλη εξόδου είναι το τελευταίο στάδιο της διαδικασίας για να έχει νόημα ένα LSTM δίκτυο η διαδικασία αυτή πρέπει να επαναληφθεί αρκετές φορές ώστε το δίκτυο να θεωρείται ικανό να προβλέπει σωστά.

3.4 BILSTM (Bidirectional Long Short Term Memory)

Σύμφωνα με τον Yugesh Verma [21] η «αμφιδρομικότητα» (bi-directionality) ονομάζεται η διαδικασία η οποία κάνει οποιοδήποτε νευρωνικό δίκτυο να «διαβάσει» την πληροφορία που δέχεται και προς δύο κατευθύνσεις (οπισθοδρομικά και εμπροσθοδρομικά) (βλ. και παραπάνω). Έτσι λοιπόν σε Bidirectional LSTM (BiLSTM ή BILSTM) δίκτυα η είσοδος «ρέει» προς δύο κατευθύνσεις σε αντίθεση με το απλό LSTM όπου η κατεύθυνση είναι μονόδρομη, από το στρώμα εισόδου στο τελικό στρώμα εξόδου. Συνεπώς σε δίκτυα BILSTM, συγκρατείται ταυτόχρονα και η παρελθοντική και η “μελλοντική” πληροφορία (με την έννοια της τιμής εξόδου του δικτύου που θα ληφθεί ως είσοδος σε ανάστροφο δίκτυο) για τα αποτελέσματα εξόδου. Η δομή ενός τέτοιου δικτύου φαίνεται στην Εικόνα 3.7:



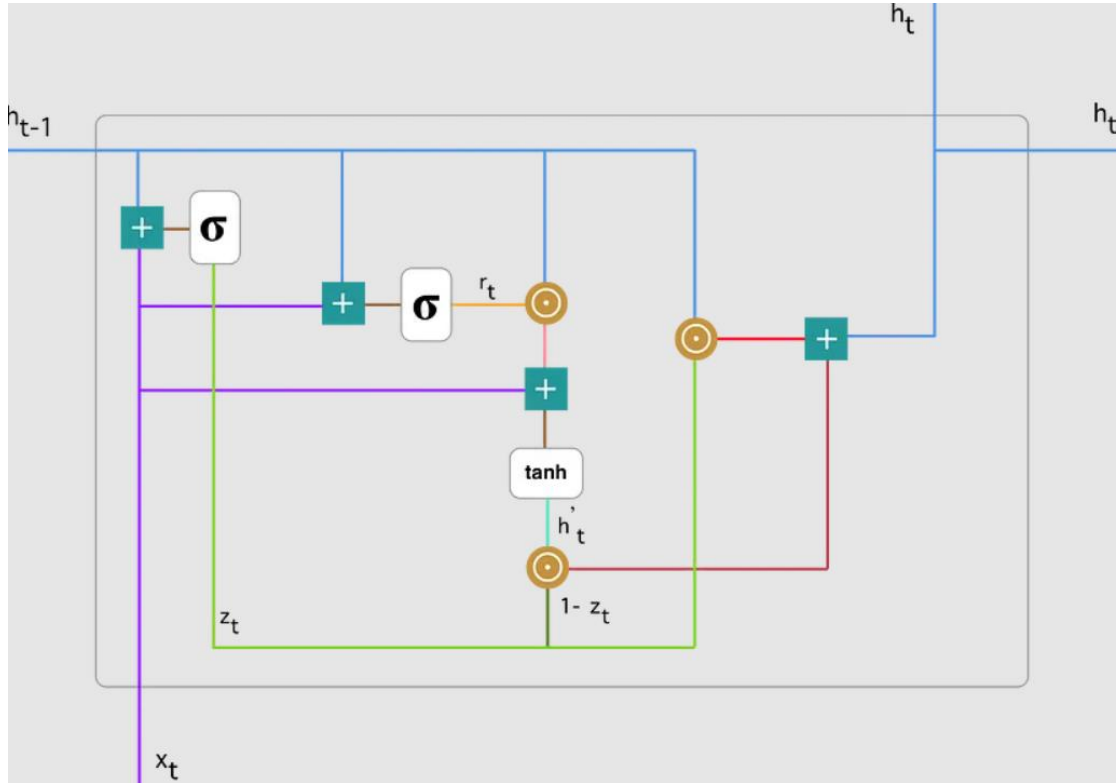
Εικόνα 3.7: Σχεδιάγραμμα BiLSTM δικτύου [21]

Τέτοιου είδους δίκτυα χρησιμοποιούνται κυρίως σε ταξινόμηση κειμένου, αναγνώριση λόγου και προβλεπτικά μοντέλα.

3.5 GRU (Gated Recurrent Unit)

Σύμφωνα με το άρθρο του Simeon Kostadinov [22] το δίκτυο «αναδρομικών μονάδων πύλης» (Gated Recurrent Units – GRU) αποτελεί έναν μηχανισμό των αναδρομικών νευρωνικών δικτύων το οποίο προτάθηκε πρώτη φορά το 2014 από τους Kyunghyun Cho et.al και σκοπεύει να λύσει το πρόβλημα των «εξαφανιζόμενων κλίσεων» (vanishing gradient problem). Διατηρεί αρκετές ομοιότητες σε σχέση με τα LSTM με τη διαφορά ότι διαθέτει δύο επιπλέον πύλες update και reset. Οι πύλες αυτές ουσιαστικά είναι δύο διανύσματα τα οποία

αποφασίζουν ποιες πληροφορίες θα παραχθούν στην έξοδο. Το σπουδαίο με αυτές τις πύλες είναι ότι μπορούν να εκπαιδευτούν από πριν και να συγκρατήσουν σημαντικές πληροφορίες ή να αφαιρέσουν πληροφορίες τις οποίες θεωρούν άσχετες με την προβλεπόμενη έξοδο. Το βασικό σχεδιάγραμμα φαίνεται στην Εικόνα 3.8:



Εικόνα 3.8: Ανάλυση διαδικασιών: "σ" ορίζει τη σιγμοειδή συνάρτηση, "tanh" υπερβολική εφαπτομένη. Το κυκλικό σύμβολο υποδεικνύει το αποτέλεσμα πολλαπλασιασμού πινάκων "Hadamard product" [22]

4. Μεθοδολογία και αποτελέσματα

Εισαγωγή

Στο παρακάτω κεφάλαιο περιγράφεται η προετοιμασία για την εισαγωγή των δεδομένων στο προγραμματιστικό περιβάλλον του Matlab, οι υπερπαραμέτροι που χρησιμοποιήθηκαν, οι πίνακες και γραφήματα των αποτελεσμάτων με συμπεράσματα για κάθε είδους δικτύου που διερευνήθηκε.

4.1 Βάση δεδομένων και επιλογή δεδομένων

Τα δεδομένα ΗΕΓ που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία είναι τα ίδια που χρησιμοποιήθηκαν στην Διπλωματική Εργασία του κ.Σ.Σαρακηνού. Στην Εργασία αυτή είχε γίνει η κατάλληλη προεπεξεργασία (φιλτράρισμα) των δεδομένων από τη βάση δεδομένων “DREAMS”. Στη βάση δεδομένων DREAMS έχουν εξαχθεί οκτώ ηλεκτροεγκεφαλογραφήματα διάρκειας 30 λεπτών (το ΗΕΓ παράχθηκε από μελέτη ύπνου, ωστόσο για το πρόγραμμα DREAMS χρησιμοποιήθηκαν κομμάτια 30 λεπτών). Το πρόγραμμα αυτό ήταν σύμπραξη του εργαστηρίου MONS-TCTS (Stéphanie Devuyst, Thierry Dutoit) και στο Πανεπιστήμιο Libre De Bruxelles CHU de Charleroi Sleep Laboratory (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) Licence.

4.2 Διαχωρισμός δεδομένων

Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση των δικτύων είναι φιλτραρισμένα τμήματα ΗΕΓ που έχουν χρονική διάρκεια ενός δευτερολέπτου. Τα τμήματα αυτά είτε ανήκαν σε ατράκτους είτε όχι και ήταν αντίστοιχα 63 για κάθε μία από τις δύο κατηγορίες («άτρακτος»/«μη- άτρακτος»). Κάθε τέτοιο τμήμα ΗΕΓ στη συνέχεια θα το ονομάζουμε «παραδείγμα». Εφόσον η συχνότητα δειγματοληψίας είναι 200Hz, το μήκος των δεδομένων κάθε τμήματος ΗΕΓ είναι 200 τιμές μV . Το σύνολο παραδειγμάτων αποτελείται από 126 «παραδείγματα» και χωρίζεται στα εξής 3 υποσύνολα παραδειγμάτων: 90 για εκπαίδευση (σύνολο «Xtrain»), 26 για επικύρωση (Xval) και 10 για έλεγχο (Xtest). Θα πρέπει να σημειωθεί ότι ο αριθμός παραδειγμάτων ατράκτων και μη ατράκτων είναι ίδιος ανά υποσύνολο. Αντίστοιχα, δημιουργήθηκαν και τρία υποσύνολα δεδομένων εξόδου με τις τιμές που θα έπρεπε θεωρητικά να έχουμε ως έξοδο, σε περίπτωση επιτυχούς

ταξινόμησης (Y_{train} , Y_{val} , Y_{test}), όπου τιμή εξόδου 1 αντιστοιχεί σε άτρακτο και 0 σε μη-άτρακτο.

4.2.1 Εφαρμογή κυλιόμενου παραθύρου για κατασκευή μητρών

Στα νευρωνικά δίκτυα τα οποία δεν είναι αναδρομικά (non-recurrent), αφού αποφασίσουμε την δομή του δικτύου (δηλ. αριθμός νευρώνων εισόδου=αριθμός στοιχείων-διάσταση του διανύσματος εισόδου, αριθμός στρωμάτων, αριθμός νευρώνων ανά στρώμα, είδος συνάρτησης ενεργοποίησης των νευρώνων κλπ.) συγκροτούμε ένα αριθμό M από διανύσματα εισόδου, έστω διάστασης k το καθένα, τα οποία ανήκουν στις διάφορες τάξεις/κατηγορίες/κλάσεις που θέλουμε να ξεχωρίζουμε/ταξινομούμε. Στη συνέχεια, με κάποιον κανόνα παρουσιάζουμε τα διανύσματα εισόδου και εκπαιδεύουμε το δίκτυο. Τα M αυτά διανύσματα δεν έχουν σχέση το ένα με το άλλο χρονική, ακόμη κι αν ανήκουν στην ίδια κατηγορία. Σίγουρα έχουν κάποια μορφολογική σχέση, μια κοινή δομή στα χαρακτηριστικά τους, δηλ. στα στοιχεία του διανύσματος εισόδου, που ακριβώς επιδιώκουμε να «μάθει» το δίκτυο, όμως δεν υπάρχει κάποια χρονική σχέση/αλληλουχία μεταξύ των διανύσματος M . Με αυτή την έννοια λέμε ότι τα διανύσματα εισόδου είναι «στατικά».

Απεναντίας, όταν θέλουμε να ταξινομήσουμε σήματα που είναι χρονοσειρές πρέπει να δίνουμε στο εκπαιδευόμενο δίκτυο διανύσματα εισόδου που έχουν την πληροφορία της χρονικής αλληλουχίας των χρονοσειρών. Τα στοιχεία του διανύσματος εισόδου είναι είτε τα διαδοχικά χρονικά δείγματα της χρονοσειράς (όπως στη δική μας περίπτωση) είτε παράμετροι που εξάγονται από τα διαδοχικά χρονικά δείγματα. Έτσι, τα στοιχεία του διανύσματος εισόδου από την φύση του σήματος εξαρτώνται από τη χρονική αλληλουχία των δειγμάτων. Τα διανύσματα εισόδου M πρέπει να αντικατοπτρίζουν αυτή την πληροφορία. Άρα τα διανύσματα M χωρίζονται σε υποσύνολα και σε κάθε υποσύνολο υπάρχει μια αλληλουχία χρονικής εξάρτησης μεταξύ των διανυσμάτων. Αν π.χ. έχουμε υποσύνολα με N διανύσματα ($M < N$), αυτά τα N διανύσματα κάθε υποσυνόλου μπορεί να είναι διαδοχικά διανύσματα μιας χρονοσειράς που αντιστοιχεί σε μία κλάση/κατηγορία. Τα δε διανύσματα αυτά μπορεί να επικαλύπτονται χρονικά ή όχι (πάντως αν δεν επικαλύπτονται, συνήθως το ένα διάνυσμα αποτελεί «συνέχεια», χωρίς κενό δειγμάτων, του άλλου). Αυτό φαίνεται πολύ καλά στον τρόπο που πολλές φορές μαθαίνουν οι μουσικοί κάποια μουσικά κομμάτια. Διαβάζουν ή/και ακούν νότες, που η μία ακολουθεί την άλλη με «νόημα» («ρυθμός», «σκοπός», «μοτίβο»). Όταν καλούνται

να μάθουν το μουσικό «κομμάτι», μαθαίνουν διαδοχικά, ακολουθιακά συνδεδεμένα τμήματα και πολλές φορές τα τμήματα αυτά επικαλύπτονται χρονικά, ώστε να διευκολύνεται η μετάβαση στον χρόνο.

Ένα από τα βασικά χαρακτηριστικά των ακολουθιακών δικτύων και ειδικά του δικτύου LSTM (και των παραγώγων αυτού δικτύων, δηλ του bi-LSTM και του GRU) είναι ότι είναι ακριβώς σχεδιασμένα για να μπορούν να «μαθαίνουν» τέτοιες χρονοσειρές. Χρειάζονται λοιπόν διαδοχικές ακολουθίες διανυσμάτων εισόδου που να συνδέονται χρονικά μεταξύ τους και να ανήκουν στην ίδια κατηγορία/κλάση.

Για να ικανοποιήσουμε εμείς αυτή την απαίτηση ξεκινάμε από κάθε παράδειγμα (έχουμε 126), που είναι μια χρονοσειρά 200 δειγμάτων και ανήκει σε μία από τις δύο κατηγορίες μας (άτριακτος/μη-άτριακτος) και στην συνέχεια δημιουργούμε την εξής χρονική ακολουθία («υπο»)παραδειγμάτων: Ξεκινάμε με τα πρώτα 100 δείγματα του παραδείγματος. Αυτά θα αποτελέσουν ένα διάνυσμα εισόδου. Άρα τα δίκτυα μας θα έχουνε στρώμα εισόδου 100 στοιχείων (ένα για κάθε δείγμα του ΗΕΓ). Στη συνέχεια δημιουργούμε ένα 2^ο διάνυσμα εισόδου, λαμβάνοντας τα δείγματα από το 2^ο ως και το 101^ο. Άρα κυλίουμε ένα παράθυρο μήκους 100 δειγμάτων κατά μήκος του ΗΕΓ των 200 δειγμάτων με βήμα κύλισης 1 δείγμα ΗΕΓ. Αυτή η διαδικασία ολοκληρώνεται στο 100^ο διάνυσμα εισόδου που έχει πρώτο στοιχείο το 100^ο δείγμα και τελευταίο το 199^ο δείγμα. Άρα δημιουργούμε 100 διανύσματα εισόδου («υπο»)παραδείγματα, χρονικά αλληλεξαρτώμενα, για κάθε ένα από τα αρχικά μας παραδείγματα. Θα εξακολουθήσουμε να αναφερόμαστε σε «παράδειγμα» (εκπαίδευσης/επικύρωσης/ελέγχου), αλλά πλέον θα εννοούμε το σύνολο των 100 διανυσμάτων εισόδου (100 στοιχείων έκαστο) που προκύπτουν με την παραπάνω διαδικασία.

Αυτός είναι και ο τρόπος που το Matlab μεταχειρίζεται τα «παραδείγματα» εισόδου. Για να εισάγουμε λοιπόν τα δεδομένα στο Matlab χρειαζόταν να χρησιμοποιήσουμε πίνακες 100x100. Για να γίνει αυτό εφαρμόσαμε το κυλιόμενο παράθυρο με βήμα $n=1$ και μήκος $l=100$, με «χειρονακτικό» τρόπο. Έστω ότι χρησιμοποιούμε ως παράδειγμα τις 200 τιμές οποιουδήποτε παραδείγματος. Τοποθετήσαμε όλες τις τιμές στην 1^η στήλη του Excel (A), άρα έχουμε τιμές από A1-A200. Στη συνέχεια «μεταθέσαμε» τις τιμές των κελιών από A2 ως και A101 και τις τοποθετήσαμε ως τιμές στα κελιά της 2^η στήλης (B) από το B1 κελί ως το κελί B100. Έτσι λοιπόν στην 2^η στήλη έχουμε το δεύτερο διάνυσμα εισόδου, το 2^ο «υπο»)παράδειγμα. Συνεχίσαμε, έως ότου στην 100^η στήλη του excel (CV) να έχουμε τις τιμές από A100 ως και A199. Φυσικά διαγράφουμε τα στοιχεία A101 ως A200 που πλέον δεν χρειαζόμαστε. Έχουμε λοιπόν δημιουργήσει τα 100 «υπο»)παραδείγματα υπό μορφή μιας μήτρας 100x100 στοιχείων για όλο το πλήθος δεδομένων

του εκάστου παραδείγματος. Συνολικά, κατασκευάσαμε 90 τέτοιες μήτρες για τη φάση εκπαίδευσης, 26 μήτρες για τη φάση επικύρωσης και 10 μήτρες για τη φάση ελέγχου.

4.3 Επιλογή υπερπαραμέτρων και μετρικές επίδοσης

Οι υπερπαραμέτροι είναι μεταβλητές οι οποίες καθορίζουν την αρχιτεκτονική του δικτύου (π.χ Number of Hidden Units) και μεταβλητές οι οποίες καθορίζουν πως θα εκπαιδευτεί ένα δίκτυο (π.χ Learning Rate). Η επιλογή των περισσότερων υπερπαραμέτρων έγινε αυτόματα από το σύστημα, ωστόσο για να έχουμε συγκρίσιμα αποτελέσματα κάναμε αλλαγές στον αριθμό των Hidden Units και το Learning Rate όπως φαίνεται στους παρακάτω πίνακες.

Εκπαίδευση σε ένα στρώμα (1 Layer):

- Αριθμός κρυφών μονάδων (Number of Hidden Units): Ο αριθμός των Hidden Units που επιλέχθηκε ήταν από 1 έως 200 με ενδιάμεσες τιμές (1,2,5,50,70,100,200). Ο όρος «κρυφός» αναφέρεται στο γεγονός ότι αυτό το μέρος του νευρωνικού δικτύου δεν είναι άμεσα ορατό ούτε από την είσοδο ούτε από την έξοδο του δικτύου. Η λειτουργία των κρυφών μονάδων είναι να παρεμβαίνουν μεταξύ της εισόδου και της εξόδου του δικτύου με κάποιο χρήσιμο τρόπο. Προσθέτοντας κρυφά επίπεδα κάποιες φορές το δίκτυο έχει τη δυνατότητα να εξάγει στατιστικά υψηλότερης τάξης πληροφορίες από την είσοδο του.
- Ρυθμός εκπαίδευσης (Learning Rate): Ο ρυθμός εκπαίδευσης καθορίζει τη συχνότητα με την οποία επικαιροποιούνται οι παράμετροι των νευρώνων. Εάν ο ρυθμός είναι μεγάλος (π.χ ≥ 0.1) είναι πιθανό να προσπεράσει κάποιες παραμέτρους που είναι σημαντικές για την εκπαίδευση. Αντίστοιχα, εάν είναι πολύ μικρός η διαδικασία θα είναι αρκετά χρονοβόρα και ενδεχομένως μη αποτελεσματική. Όσο μειώνουμε τον ρυθμό εκπαίδευσης θα πρέπει να αυξάνουμε τον αριθμό εποχών. Το ιδανικό LR που προτείνεται από το Matlab είναι το 0.001. Στις δοκιμές μας χρησιμοποιήσαμε LR 0.1, 0.01, 0.05, 0.001 και 0.0001 κρατώντας τον αριθμό των εποχών σταθερό.
- Εποχές (Epochs): Ο αριθμός εποχών, δηλ. επαναλήψεων των βημάτων λειτουργίας του δικτύου για κάθε παράδειγμα εισόδου είναι σταθερός στις 1000. Αυτή η τιμή προέκυψε και από τα συμπεράσματα από την Διπλωματική του κ. Σ.Σαρακηνού και από προκαταρκτικές δικές μας δοκιμές.

Εκπαίδευση σε δύο στρώματα (2 Layers):

- Αριθμός κρυφών μονάδων (Number of Hidden Units): Ο αριθμός κρυφών μονάδων έγινε συνδυαστικά ως εξής: 15/10, 20/15, 30/20, 50/35, 75/50, 125/100.
- Ρυθμός εκπαίδευσης (Learning Rate): Χρησιμοποιήθηκαν οι ίδιοι ρυθμοί όπως και στην εκπαίδευση με ένα στρώμα.
- Απόρριψη (Dropout): Το dropout είναι μια 'τεχνική' η οποία χρησιμοποιείται ώστε να προλαμβάνει το μοντέλο από την «υπερεκμάθηση», «υπερταίριασμα» (overfitting). Απόρριψη σημαίνει ότι μερικές συνδέσεις στο δίκτυο, από εποχή σε εποχή, «αφαιρούνται» (μηδενίζονται). Αν η τιμή του dropout είναι π.χ. 0,3 σημαίνει ότι μηδενίζεται (με τυχαίο τρόπο) το 30% των συνδέσεων. Χρησιμοποιήθηκαν οι εξής συνδυασμοί: 0/0, 0,2/0,2, 0,4/0,4, 0,5/0,5, δηλ. σε κάθε περίπτωση είχαμε ίδια τιμή dropout και για τα δύο στρώματα..

Δεν χρησιμοποιήθηκαν όλοι οι παραπάνω συνδυασμοί σε όλα τα δίκτυα. Έγιναν αρχικές (ευρείες) επιλογές δοκιμών και στη συνέχεια, προχωρώντας από κατηγορία δικτύων σε επόμενη, λαμβάναμε υπόψη τα ήδη υπάρχοντα πλέον αποτελέσματα, ώστε να κατεθυνόμαστε σε μια πιο «οικονομική» επιλογή υπερπαραμέτρων, όπου αυτό ήταν δυνατό.

Οι μετρικές επίδοσης που χρησιμοποιήσαμε είναι η (συνολική) ακρίβεια (accuracy) και η απώλεια διασταυρούμενης εντροπίας (cross-entropy loss).

Η (συνολική) ακρίβεια ορίζεται ως ο λόγος του αριθμού των ορθώς ανιχνευθέντων τμημάτων ΗΕΓ (είτε ατράκτων είτε μη-ατράκτων) προς το σύνολο των τμημάτων ΗΕΓ τα οποία δίνονται στο δίκτυο προς εξέταση (δηλ. προς απόφαση κατηγοριοποίησης). Απλούστερα είναι το αθροιστικό ποσοστό «ορθώς θετικών» αποφάσεων και «ορθώς αρνητικών» αποφάσεων. Ορθώς θετικές είναι οι αποφάσεις όπου τμήματα ΗΕΓ που ήταν άτρακτοι ανιχνεύθηκαν/ κατηγοριοποιήθηκαν ως άτρακτοι και ορθώς αρνητικές είναι οι αποφάσεις όπου τμήματα ΗΕΓ που δεν ήταν άτρακτοι ανιχνεύθηκαν/κατηγοριοποιήθηκαν ως μη-άτρακτοι.

Η απώλεια διασταυρούμενης εντροπίας (cross-entropy loss), την οποία θα αναφέρουμε στα επόμενα απλά ως απώλεια (loss), δείχνει πόσο αποκλίνει (κατά μέσο όρο σε όλο το δείγμα) η πραγματική έξοδος ενός δικτύου από την επιθυμητή (ιδανική-θεωρητική) έξοδο του δικτύου. Υπολογίζεται ως ένας σταθμισμένος μέσος όρος, ανά κλάση (εμείς έχουμε δύο κλάσεις), των τιμών εξόδου του τελευταίου στρώματος των δικτύων, όταν αυτό το στρώμα χρησιμοποιεί συνάρτηση ενεργοποίησης softmax. Οι δε τιμές εξόδου, δηλ. οι τιμές της συνάρτησης ενεργοποίησης τύπου softmax εκφράζουν πιθανότητες να ανήκει ένα

δείγμα σε μία κλάση. Αυτό συμβαίνει διότι η συνάρτηση softmax κανονικοποιεί την τιμή των δεδομένων εισόδου της έτσι ώστε να βρίσκονται οι έξοδοί της στο διάστημα από 0 έως 1. Μπορούμε να θεωρούμε την έξοδο της συνάρτησης softmax ως κατανομή πιθανότητας. Αυτό που ενδιαφέρει είναι ότι κατά την διάρκεια της εκπαίδευσης η απώλεια πρέπει να μειώνεται ταχέως (δηλ. σε μικρό αριθμό επαναλήψεων) και ομαλά (δηλ. μονότονα) προς το ελάχιστό της που είναι η μηδενική τιμή.

4.4 Αποτελέσματα και παρατηρήσεις

Παρακάτω παρατίθενται αναλυτικά οι πίνακες Excel με τα αποτελέσματα.

4.4.1 LSTM 1 κρυφού στρώματος (LSTM-1 Layer)

Στον παρακάτω πίνακα δίνονται τα αποτελέσματα εκπαίδευσης (ακρίβεια επικύρωσης - validation accuracy) και δοκιμής (ακρίβεια δοκιμής - testing accuracy) για τους διάφορους συνδυασμούς αριθμού μονάδων LSTM στο κρυφό στρώμα (hidden units) και ρυθμού εκπαίδευσης (learning rate - LR). Δίνεται επίσης ο χρόνος που χρειάστηκε για να γίνουν 1000 επαναλήψεις (εποχές), σε κάθε περίπτωση. .


Δίκτυο: LSTM				
hidden units	learning rate	validation accuracy	testing accuracy (acc)	elapsed time
1	0.1	73,08%	0.8	1:43
1	0.01	92,31%	0.5	1:30
1	0.005	84,62%	0.6	1:22
1	0.001	53,85%	0.6	1:33
1	0.0001	65,38%	0.9	1:24
2	0.1	73,08%	0.7	3:00
2	0.01	80,77%	0.9	3:06
2	0.005	69,23%	0.6	2:38
2	0.001	80,77%	0.7	1:37
2	0.0001	84,62%	0.9	1:40
5	0.1	92,31%	0.8	4:19
5	0.01	88,46%	0.8	2:48
5	0.005	84,62%	0.9	2:15
5	0.001	80,77%	0.7	2:32
5	0.0001	61,54%	0.7	2:53
50	0.1	61,54%	0.7	16:20
50	0.01	73,08%	0.7	11:39
50	0.005	73,08%	0.8	8:12
50	0.001	92,31%	0.8	7:33
50	0.0001	96,15%	0.9	6:29
70	0.1	69,23%	0.7	19:31
70	0.01	65,38%	0.9	11:19
70	0.005	73,08%	0.9	10:40
70	0.001	92,31%	0.9	7:23
70	0.0001	96,15%	0.9	7:19
100	0.1	92,31%	0.9	24:04
100	0.01	57,69%	1	16:21
100	0.005	61,54%	0.9	16:04
100	0.001	88,46%	0.8	9:26
100	0.0001	96,15%	0.9	9:09
200	0.1	69,23%	0.8	49:49
200	0.01	73,08%	0.8	34:33
200	0.005	69,23%	0.9	24:30
200	0.001	88,46%	0.9	17:17
200	0.0001	96,15%	0.9	17:24

Πίνακας 4.1: Με ανοιχτό πράσινο σημειώνονται συνδυασμοί όπου και οι δύο τιμές ακρίβειας είναι >90%.

Σημειώνουμε ότι επιλέξαμε να ελέγχουμε και τις δύο επιδόσεις ακρίβειας ταυτόχρονα και όχι μόνο την ακρίβεια δοκιμής διότι έχουμε μικρό αριθμό τμημάτων ΗΕΓ ατράκτων και μη ατράκτων στα δεδομένα δοκιμής μας (10+10). Έτσι πιστεύουμε ότι έχουμε ένα πιο αντικειμενικό

δείκτη της επίδοσης του δικτύου σε κάθε επιλογή υπερπαραμέτρων και αριθμού κρυφών νευρώνων που επιλέξαμε να ελέγξουμε.

Επιπλέον από όσα φαίνονται στον παραπάνω πίνακα, παρατηρήσαμε ότι σχεδόν για όλες τις τιμές κρυφών επιπέδων, όταν ο ρυθμός εκπαίδευσης (LR) είναι 0.1, 0.01 και 0.005 έχουμε σε κάποιες «στιγμές» της διαδικασίας εκπαίδευσης του δικτύου έντονη αστάθεια στο ρυθμό που μεταβάλλεται η συνολική ακρίβεια (accuracy). Αυτό το δείχνουμε για μία από τις περιπτώσεις του Πίνακα 4.1 στην Εικόνα 4.1.



Εικόνα 4.5: Παράδειγμα αστάθειας δικτύου με LR 0,1

Το γεγονός αυτό μας επηρεάζει αρνητικά, διότι δεν γνωρίζουμε πότε ακριβώς να σταματήσουμε τις επαναλήψεις σε πραγματικά δεδομένα, στα οποία δεν θα έχουμε δυνατότητα ελέγχου της ακρίβειας. Αυτή η συμπεριφορά είναι εξηγήσιμη και αναμενόμενη, διότι εξ ορισμού «μεγάλο» LR συνεπάγεται και απότομες μεταβάσεις σε νέα σημεία ισορροπίας στο ενεργειακό πεδίο του χώρου των χαρακτηριστικών. Αυτό που δεν γνωρίζουμε εκ των προτέρων και η παραπάνω διερεύνηση μας δίνει ως αποτέλεσμα είναι από ποια τιμή του LR και κάτω η εκμάθηση δεν εμφανίζει τις παραπάνω αστάθειες. Σύμφωνα με τα δικά μας δεδομένα και τις δοκιμές μας, η χρήση 1000 εποχών με LR 0.001 και 0.0001 αποδεικνύεται καλή επιλογή, τόσο από άποψη επιδόσεων ακρίβειας, όσο και κυρίως από άποψη ευστάθειας για μετέπειτα χρήση δεδομένων, όπου δε θα γνωρίζουμε που υπάρχει και που όχι άτρακτος.

Με βάση λοιπόν όλα τα παραπάνω, βέλτιστες επιδόσεις επετεύχθησαν για LR 0.0001, παρόμοιες για 50,70,100 ή 200

μονάδες/νευρώνες. Γνωρίζουμε ότι δίκτυα με μικρότερο αριθμό νευρώνων λειτουργούν ταχύτερα, άρα είναι προτιμητέα σε εφαρμογές παραγματικού χρόνου. Σημειώνουμε ότι αναφερόμαστε στον χρόνο λειτουργίας ενός δικτύου που έχει ήδη εκπαιδευθεί και έχει «έτοιμα» και σταθερά τα βάρη του και την δομή του, και όχι στους χρόνους που έχουμε στον Πίνακα 4.1, όπου εμφανίζονται οι χρόνοι εκπαίδευσης. Συνεπώς μπορούμε να χρησιμοποιούμε 50 μονάδες ώστε να μην καθυστερούν οι υπολογισμοί όταν το δίκτυο εκπαιδευμένο πλέον χρησιμοποιηθεί σε πραγματικά δεδομένα.

4.4.2 BiLSTM 1 κρυφού στρώματος (BiLSTM-1 Layer)

Στον Πίνακα 4.2 φαίνονται τα αποτελέσματα των δοκιμών που έγιναν για δίκτυα BiLSTM με ένα στρώμα. Οι παράμετροι των δοκιμών είναι ίδιες με αυτές που έγιναν για τα δίκτυα LSTM της προηγούμενης υποενότητας, ώστε να μπορούμε να συγκρίνουμε τις επιδόσεις. Υπήρξαν περιπτώσεις όπου και οι δύο παράμετροι ακρίβειας ήταν ίσες ή πάνω από 90% και, γενικά, όταν ήταν $LR=0,001$ ή $0,0001$, για δίκτυα με 50 νευρώνες και πάνω οι ακρίβειες ήταν αμφοτέρως άνω του 80%. Όμως δεν μπορεί να στοιχειοθετηθεί κάποια «σταθερά» καλύτερη επίδοση του BiLSTM σε σχέση με το LSTM και λαμβάνοντας υπόψη ότι ο φόρτος υπολογισμών είναι τουλάχιστον διπλάσιος από κάθε αντίστοιχο (ίσου αριθμού νευρώνων) LSTM δίκτυο, δεν προχωρήσαμε παραπέρα την έρευνα για δίκτυα Bi-LSTM.

ΑΥΤΟΜΑΤΗ ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΥΠΙΝΟΥ ΜΕ ΔΙΚΤΥΑ LSTM (LONG-SHORT TERM MEMORY), BiLSTM (BIDIRECTIONAL LSTM) ΚΑΙ GRU (GATED RECURRENT UNIT)

Δίκτυο: BiLSTM				
hidden units	learning rate	validation accuracy	testing accuracy (acc)	elapsed time
1	0.1	50%	0.6	2:06
1	0.01	46,15%	0.1	2:24
1	0.005	61,54%	0.4	2:33
1	0.001	88,46%	0.7	2:24
1	0.0001	46,15%	0.4	2:18
2	0.1	57,69%	0.6	2:51
2	0.01	80,77%	0.9	2:54
2	0.005	76,92%	0.8	3:09
2	0.001	57,69%	0.8	3:56
2	0.0001	57,69%	0.8	3:13
5	0.1	53,85%	0.6	4:50
5	0.01	73,08%	0.7	4:49
5	0.005	88,46%	0.9	5:29
5	0.001	69,23%	1	4:35
5	0.0001	50%	0.6	4:22
50	0.1	96,15%	1	20:54
50	0.01	65,38%	0.8	18:34:00
50	0.005	84,62%	1	15:06
50	0.001	92,31%	0.9	12:12
50	0.0001	80,77%	1	11:04
70	0.1	80,77%	0.9	26:45:00
70	0.01	69,23%	1	22:03
70	0.005	69,23%	0.9	19:46
70	0.001	92,31%	0.9	15:04
70	0.0001	88,46%	0.9	15:15
100	0.1	76,92%	0.9	56:09
100	0.01	73,08%	1	31:30:00
100	0.005	80,77%	1	34:12:00
100	0.001	88,46%	0.9	19:25
100	0.0001	92,31%	0.9	19:32
200	0.1	96,15%	0.9	72:00:00
200	0.01	73,08%	0.9	61:59:00
200	0.005	73,08%	1	47:09:00
200	0.001	88,46%	0.9	32:45:00
200	0.0001	96,15%	0.9	32:55:00

Πίνακας 4.2: Με ανοιχτό πράσινο σημειώνονται συνδυασμοί όπου και οι δύο τιμές ακρίβειας είναι >90%.

4.4.3 LSTM δύο κρυφών στρωμάτων (LSTM-2 Layers)

Στην περίπτωση LSTM 2 κρυφών στρωμάτων, ο προτεινόμενος συνδυασμός του Matlab ήταν LR=0.001 με Dropout: 0.2/0.2.

Η στρατηγική μας βασίστηκε στη διερεύνηση κυρίως των δικτύων με κρυμμένα επίπεδα 50/35 και 75/50 τα οποία περιέχουν αριθμό επιπέδων ανά στρώμα ο οποίος είναι συγκρίσιμος με τον αριθμό ακολουθιών που έχουμε (100). Αυτή η στρατηγική ακολουθείται ευρέως σε προβλήματα ταξινόμησης με νευρωνικά δίκτυα δύο και περισσότερων επιπέδων. Επίσης συνηθίζεται το πρώτο δίκτυο να έχει περισσότερους νευρώνες από το δεύτερο (και το τρίτο κλπ. αν χρησιμοποιούμε πάνω από 2 επίπεδα) Τα δίκτυα λοιπόν με 50/35 και 75/50 νευρώνες στο 1^ο και 2^ο αντίστοιχα κρυφό δίκτυο τα ονομάζουμε «βασικά δίκτυα» στα επόμενα. Για τα δύο βασικά δίκτυα χρησιμοποιήθηκε μεγάλο εύρος δοκιμαστικών τιμών για το LR και διάφοροι συνδυασμοί για τιμές dropout, όπως φαίνεται αναλυτικά στον Πίνακα 4.2. Για τους άλλους συνδυασμούς αριθμού νευρώνων στα 2 κρυφά στρώματα που επιλέξαμε να δοκιμάσουμε (15/10, 20/15, 30/20, 125/100) για τους μεν τρεις πρώτους συνδυασμούς δοκιμάσαμε μόνο την επιλογή παραμέτρων LR & dropout που προτείνει το Matlab (0,001 & 0,2/0,2). Για τον συνδυασμό 125/100 δοκιμάσαμε επιπλέον συνδυασμούς, όπως δείχνουμε αναλυτικά και στον Πίνακα 4.3.

Στην περίπτωση των 2 κρυφών επιπέδων επιλέξαμε να καταγράψουμε και την τιμή της απώλειας (loss) διότι, σε αντίθεση με ότι παρατηρήσαμε για τις δοκιμές με 1 επίπεδο (βλ. παραπάνω), στην περίπτωση των 2 επιπέδων υπήρξαν περιπτώσεις όπου οι ακρίβειες ήταν πολύ καλές, στο πέρας των 1000 επαναλήψεων, όμως η τιμή της απώλειας είτε είχε εμφανίσει έντονες αστάθειες είτε, κυρίως, είχε τιμή πάνω από 0,5 ή και πολύ παραπάνω. Θέσαμε ένα κατώφλι στην τιμή 0,4, ως ένα όριο μεταξύ των από 0,5 και πάνω τιμών και όσων ήταν μικρότερες, λαμβάνοντας υπόψη ότι είχαμε και περιπτώσεις σχεδόν μηδενικής απώλειας. Φυσικά η τοποθέτηση ενός «κατωφλιού αποδοχής» για την τελική (στις 1000 επαναλήψεις) τιμή της απώλειας ενέχει ένα στοιχείο αυθαιρεσίας.

ΑΥΤΟΜΑΤΗ ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΥΠΙΝΟΥ ΜΕ ΔΙΚΤΥΑ LSTM (LONG-SHORT TERM MEMORY), BILSTM (BIDIRECTIONAL LSTM) ΚΑΙ GRU (GATED RECURRENT UNIT)

hidden units	learning rate	dropout	validation accuracy	testing accuracy (acc)	elapsed time	Loss
15/10	0.001	0.2/0.2	96,15%	0.7	5:43:00	0.1890
20/15	0.001	0.2/0.2	92,31%	1.0	6:01:00	0.2000
30/20	0.001	0.2/0.2	100%	0.9	7:43:00	0.0000
50/35	0.1	0/0	65,38%	0.9	22:09:00	0.1780
	0.1	0.2/0.2	76,92%	0.7	20:04:00	1.5405
	0.1	0.4/0.4	46,15%	0.7	18:27:00	0.7148
	0.01	0/0	92,31%	0.8	10:16:00	0.1000
	0.01	0.2/0.2	73,08%	0.9	14:52:00	0.8377
	0.01	0.4/0.4	88,46%	0.7	12:51:00	0.6746
	0.001	0/0	92,31%	0.9	10:27:00	0.4219
	0.001	0.2/0.2	100%	0.9	3:07:00	0.0000
	0.001	0.4/0.4	96,15%	0.9	9:13:00	0.0504
	0.0001	0/0	92,31%	0.9	8:45:00	0.4353
	0.0001	0.2/0.2	96,15%	0.9	8:43:00	0.2379
	0.0001	0.4/0.4	96,15%	0.9	8:51:00	0.2124
75/50	0.1	0/0	57,69%	0.8	0:40:00	2.0619
	0.1	0.2/0.2	69,23%	0.9	8:39:00	1.9242
	0.1	0.4/0.4	50%	0.8	2:02:00	1.8790
	0.01	0/0	96,15%	0.9	13:26:00	0.1701
	0.01	0.2/0.2	80,77%	0.8	16:15:00	0.9512
	0.01	0.4/0.4	76,92%	0.9	20:34:00	1.1695
	0.001	0/0	92,31%	0.9	11:57:00	0.5948
	0.001	0.2/0.2	100%	0.9	4:07:00	0.0000
	0.001	0.4/0.4	96,15%	0.9	11:43:00	0.2446
	0.0001	0/0	88,46%	0.9	12:37:00	0.5295
	0.0001	0.2/0.2	92,31%	0.9	13:31:00	0.2556
	0.0001	0.4/0.4	96,15%	0.9	11:54:00	0.2446
125/100	0.001	0/0	92,31%	0.9	6:26:00	0.4000
	0.001	0.2/0.2	100%	1.0	6:34:00	0.0978
	0.001	0.4/0.4	96,15%	0.9	6:24:00	0.3780
	0.0001	0/0	96,15%	0.9	20:56:00	0.2725
	0.0001	0.2/0.2	92.31	0.9	6:27:00	0.2560
	0.0001	0.4/0.4	100%	0.9	20:58:00	0.0002


Πίνακας 4.3

Περιπτώσεις όπου και οι δύο τιμές ακρίβειας είναι ίσες ή πάνω από 90% , και έχουμε μία τιμή loss <0,4, έχουν σημειωθεί με ανοιχτό πράσινο.

Στις περιπτώσεις όπου μια από τις δύο τιμές ακρίβειας είναι 100% και η άλλη ίση ή πάνω από 90% και έχουμε μία τιμή loss <0,4, έχουν σημειωθεί με σκούρο πράσινο.

Περιπτώσεις όπου ήταν loss >=0,4 έχουν σημειωθεί με κόκκινο υπόβαθρο. Ειδικά περιπτώσεις όπου ήταν loss >=0,4 αλλά οι ακρίβειες επικύρωσης και δοκιμής ήταν >=90% σημειώνονται με γκρι υπόβαθρο στα υπόλοιπα κελιά τους. Αυτό γίνεται για να

τονίσουμε ότι δεν αρκεί μόνο ο έλεγχος των ακριβειών, αλλά και της απώλειας. Τέλος, με φωτεινό πράσινο σημειώνεται η καλύτερη απόδοση του δικτύου, που ήταν για 125/100 με $LR=0.001$, $DR: 0.2/0.2$ και σχεδόν μηδαμινό loss. Παρακάτω φαίνεται και η γραφική παράσταση της εκπαίδευσης του δικτύου, όπως δίνεται από το Matlab:



Εικόνα 4.6: Γραφική παράσταση δικτύου 125/100, $LR=0.001$, $DR: 0,2/0,2$.

Από τον έλεγχο για διαφορετικές τιμές ζεύγους dropout (0/0, 0,2/0,2, 0,4/0,4) δεν μπορέσαμε να εξάγουμε κάποιο «θετικό» συμπέρασμα «επαναλαμβανόμενης» (για διάφορες δοκιμές LR και αριθμού νευρώνων) υπεροχής για κάποιον συνδυασμό. Παρατηρήσαμε όμως, ως αρνητικό συμπέρασμα, ότι σε όλες τις περιπτώσεις όπου είχαμε $LR=0,001$, αν δεν χρησιμοποιούσαμε dropout οι απώλειες αυξάνονταν περισσότερο από ότι αν είχαμε άλλο συνδυασμό τιμών dropout και σε αρκετές περιπτώσεις υπερβαίνουν το κατώφλι του 0,4. Άρα επιβεβαιώνεται ότι σε δίκτυα 2 επιπέδων πρέπει να χρησιμοποιείται η τεχνική dropout.

Τέλος, βλέπουμε ότι και για μειούμενο αριθμό νευρώνων (ως και 20/15, όχι όμως 15/10) οι επιδόσεις παραμένουν ικανοποιητικές. Αυτό έχει σημασία, διότι όπως αναφέραμε και παραπάνω δίκτυα με μικρότερο αριθμό νευρώνων λειτουργούν ταχύτερα, άρα είναι προτιμητέα σε εφαρμογές παραγωγικού χρόνου. Και βέβαια πάλι και σε αυτή την περίπτωση όσο περισσότεροι οι νευρώνες ενός δικτύου τόσο περισσότερο διαρκεί η εκπαίδευση (σε γενικές γραμμές, διότι υπάρχουν και εξαιρέσεις όπως φαίνεται στον Πίνακα 4.3).

4.4.4 GRU 1 κρυφού στρώματος (GRU-1 Layer)

Στον Πίνακα 4.4 δίνονται τα αποτελέσματα εκπαίδευσης (ακρίβεια επικύρωσης - validation accuracy) και δοκιμής (ακρίβεια δοκιμής – testing accuracy) για τους διάφορους συνδυασμούς αριθμού μονάδων GRU στο κρυφό στρώμα (hidden units) και ρυθμού εκπαίδευσης (learning rate - LR). Δίνεται επίσης η απώλεια (loss) και ο χρόνος που χρειάστηκε για να γίνουν 1000 επαναλήψεις, σε κάθε περίπτωση. Οι συνδυασμοί που επιλέχθηκαν είναι οι ίδιοι με αυτούς που δείχνονται στον Πίνακα 4.1, για δίκτυο LSTM ενός κρυφού επιπέδου.

GRU					
hidden units	learning rate	validation accuracy	testing accuracy (acc)	validation loss	elapsed time
1	0.1	50%	0.3	0.7439	1:35
1	0.01	65,38%	0.6	0.5925	1:43
1	0.005	84,62%	0.8	0.3372	2:02
1	0.001	76,92%	0.7	0.5407	1:24
1	0.0001	42,31%	0.6	0.8133	1:30
2	0.1	50%	0.4	0.7215	1:45
2	0.01	88,46%	0.5	0.4912	2:12
2	0.005	84,62%	0.8	0.324	2:14
2	0.001	80,77%	0.7	0.3758	2:04
2	0.0001	61,54%	0.7	0.7645	1:53
5	0.1	53.85%	0.6	0.6724	2:02
5	0.01	73,08%	0.9	0.8914	3:01
5	0.005	92,31%	0.9	0.2246	2:27
5	0.001	100%	0.9	0.0293	2:06
5	0.0001	65,38%	0.6	0.5797	2:13
50	0.1	73,08%	0.6	0.6204	10:12
50	0.01	88,46%	0.8	0.5171	9:36
50	0.005	73,08%	0.8	1.299	7:57
50	0.001	96,15%	0.9	0.0739	6:47
50	0.0001	96,15%	1	0.1066	5:39
70	0.1	73,08%	0.5	0.8153	16:16
70	0.01	88,46%	0.8	0.8735	15:31
70	0.005	88,46%	1	0.4092	13:40
70	0.001	96,15%	0.9	0.121	8:20
70	0.0001	96,15%	1	0.1142	7:50
100	0.1	53,85%	1	1.3906	21:00
100	0.01	80,77%	0.9	0.9825	22:40
100	0.005	76,92%	0.9	0.6636	17:11
100	0.001	100%	0.9	0.026	9:42
100	0.0001	100%	0.9	0.0325	9:32

200	0.1	92,31%	1	0.188	22:23
200	0.01	80,77%	0.9	1.988	49:19
200	0.005	80,77%	0.8	0.8044	35:50
200	0.001	84,62%	1	0.3316	24:55
200	0.0001	96,15%	0.9	0.1467	17:27

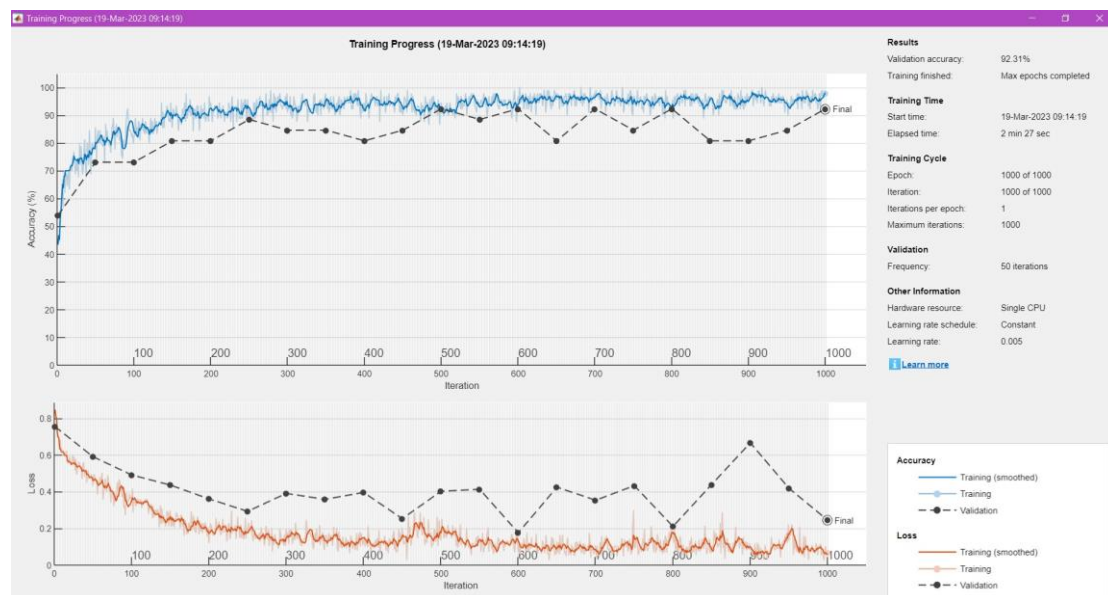
Πίνακας 4.4

Με κόκκινο σημειώνονται «προβληματικοί» συνδυασμοί (μία τουλάχιστον ακρίβεια <70% ή $loss \geq 0.4$)

Με ανοιχτό πράσινο σημειώνονται συνδυασμοί όπου και οι δύο τιμές ακρίβειας είναι $\geq 90\%$.

Με σκούρο πράσινο σημειώνονται συνδυασμοί όπου μία από τις τιμές ακρίβειας είναι 100% και η άλλη $\geq 90\%$.

Βασικό χαρακτηριστικό στα GRU δίκτυα ενός στρώματος είναι η αστάθεια στην τιμή ακρίβειας κατά την διαδικασία επανάληψης των δοκιμών, ακόμα και όταν η ακρίβεια συγκλίνει προς υψηλές τιμές και σταθεροποιείται όπως φαίνεται στην Εικόνα 4.3.



Εικόνα 4.7: Γραφική παράσταση δικτύου GRU ενός στρώματος με 5 κρυφά επίπεδα και LR 0,005.

Από τον Πίνακα 4.4 φαίνεται ότι οι καλύτερες επιδόσεις είναι για 50, 70 και 100 μονάδες/νευρώνες και, όπως φάνηκε και στις προηγούμενες κατηγορίες δικτύων που δοκιμάστηκαν, για τιμές εκπαίδευσης 0.001 και 0.0001. Για 200 νευρώνες ήταν αποδεκτές οι επιδόσεις (δηλ. ακρίβειες αμφότερες τουλάχιστον $\geq 90\%$ και $loss < 0,4$) αλλά για LR=0,0001, όχι όμως για LR=0,001.

4.4.5 GRU 2 κρυφών στρωμάτων (GRU-2 Layers)

Όπως φαίνεται και στον Πίνακα 4.5, στηριζόμενοι στα προηγούμενα αποτελέσματα εξετάσαμε το ρυθμό εκπαίδευσης για μόνο δύο τιμές: $LR=0,001$ & $0,0001$, αφού οι δοκιμές για τα άλλα είδη δικτύων έδειξαν ότι για μεγαλύτερες τιμές του ρυθμού ενδέχεται να εμφανιστεί αστάθεια και χειρότερες επιδόσεις ακρίβειας. Επίσης, όσον αφορά τον αριθμό των μονάδων σε κάθε στρώμα, κινηθήκαμε σε συνδυασμούς όπου το πρώτο στρώμα έχει περισσότερους νευρώνες από το δεύτερο και ο αριθμός των νευρώνων αυξάνεται σταδιακά στις δοκιμές μας.

Οι δοκιμές με GRU δίκτυα 2 στρωμάτων φαίνεται πως παρέχουν εξαιρετικές επιδόσεις για τους περισσότερους συνδυασμούς αριθμών κρυφών μονάδων/νευρώνων και υπερπαραμέτρων. Αξιοσημείωτες είναι δε, εκτός από τις μεγάλες τιμές ακρίβειας, οι αρκετά μικρές τιμές loss σε σχέση με τα προηγούμενα δίκτυα. Επίσης εξαλείφθηκε η «αστάθεια» που παρατηρήθηκε στα δίκτυα GRU 1 κρυφού στρώματος.

Επίσης, δεν έχει σημασία η χρήση τεχνικής dropout και χάρην απλότητας και ταχύτητας λειτουργίας σε εκπαιδευμένα δίκτυα, ακόμη και δίκτυο με 15 και 10 νευρώνες στα δύο στρώματα φαίνεται να μπορεί να εκτελέσει πολύ καλά την ταξινόμηση.

ΑΥΤΟΜΑΤΗ ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΥΠΙΝΟΥ ΜΕ ΔΙΚΤΥΑ LSTM (LONG-SHORT TERM MEMORY), BILSTM (BIDIRECTIONAL LSTM) ΚΑΙ GRU (GATED RECURRENT UNIT)

hidden units	learning rate	dropout	validation accuracy	testing accuracy (acc)	elapsed time	Loss
15/10	0.001	0/0	100%	0.9	7:01	9.08E-04
	0.001	0.2/0.2	100%	0.8	6:00	0.0049
	0.001	0.5/0.5	100%	0.9	4:50	2.67E-04
	0.0001	0/0	92,31%	0.8	5:34	0.2309
	0.0001	0.2/0.2	96,15%	0.8	3:47	0.1676
	0.0001	0.5/0.5	84,62%	1.0	4:04	0.2779
20/15	0.001	0/0	92,31%	0.9	4:53	0.4686
	0.001	0.2/0.2	92,31%	1.0	5:03	0.2774
	0.001	0.5/0.5	100%	0.9	5:10	0.0114
	0.0001	0/0	92,31%	0.9	4:54	0.171
	0.0001	0.2/0.2	96,15%	1.0	4:44	0.1151
	0.0001	0.5/0.5	96,15%	0.9	4:37	0.1251
30/20	0.001	0/0	96,15%	0.9	6:47	0.0542
	0.001	0.2/0.2	96,15%	1.0	5:49	0.1818
	0.001	0.5/0.5	100%	0.9	5:26	2.06E-04
	0.0001	0/0	96,15%	0.9	6:06	0.1001
	0.0001	0.2/0.2	96,15%	0.8	5:52	0.1467
	0.0001	0.5/0.5	96,15%	1.0	5:33	0.1275
50/35	0.001	0/0	92,31%	0.9	8:19	0.1015
	0.001	0.2/0.2	100%	0.9	10:18	0.0182
	0.001	0.5/0.5	96,15%	1.0	9:05	0.2936
	0.0001	0/0	96,15%	1.0	9:29	0.1184
	0.0001	0.2/0.2	100%	0.9	9:56	0.0232
	0.0001	0.5/0.5	100%	0.8	10:10	0.0133
75/50	0.001	0/0	96,15%	0.9	12:49	0.1413
	0.001	0.2/0.2	92,31%	0.9	14:25	0.3936
	0.001	0.5/0.5	100%	0.9	16:04	3.34E-05
	0.0001	0/0	100%	0.9	12:05	0.0468
	0.0001	0.2/0.2	100%	0.9	11:10	0.0174
	0.0001	0.5/0.5	100%	1.0	11:30	0.0433
125/100	0.001	0/0	92,31%	0.9	19:42	0.2605
	0.001	0.2/0.2	96,15%	0.9	23:59	0.1681
	0.001	0.5/0.5	96,15%	0.9	23:28	0.1505
	0.0001	0/0	96,15%	1.0	20:24	0.0849
	0.0001	0.2/0.2	96,15%	0.9	4:42	0.1143
	0.0001	0.5/0.5	100%	0.9	12:48	1.83E-02

Πίνακας 4.5

Με ανοιχτό πράσινο σημειώνονται συνδυασμοί όπου και οι δύο τιμές ακρίβειας είναι $\geq 90\%$.

Με σκούρο πράσινο σημειώνονται συνδυασμοί όπου μία από τις τιμές ακρίβειας είναι 100% και η άλλη $\geq 90\%$.

4.5 Συνολικός σχολιασμός αποτελεσμάτων – συμπεράσματα

Από τις δοκιμές που κάναμε και παρουσιάσαμε παραπάνω μπορούμε να εξάγουμε τα ακόλουθα γενικά συμπεράσματα:

Για το συγκεκριμένο σύνολο ατράκτων που μελετήσαμε τα δίκτυα LSTM μπορούν να πετύχουν πολύ καλά ποσοστά ακρίβειας (έως 100% πολλές φορές). Άρα η αρχική ιδέα της έρευνας επαληθεύθηκε, ότι δηλαδή αναμένουμε τα δίκτυα LSTM, λόγω της ικανότητάς τους να ταξινομούν χρονικές ακολουθίες σημάτων, να μπορούν με επιτυχία να ταξινομούν ατράκτους του ύπνου, που και αυτές είναι σήματα εξελισσόμενα στο χρόνο που έχουν μια συγκεκριμένη χρονική «ακολουθιακή δομή» (δηλ. ημιτονοειδή σήματα). Βέβαια, η αρχική επιβεβαίωση υπήρξε με την Διπλωματική Εργασία του κ.Σαρακηνού.

Στην παρούσα Διπλωματική Εργασία, επεκτείναμε την διερεύνηση πέραν του «βασικού» δικτύου LSTM στις δύο πιο συχνά αναφερόμενες στην βιβλιογραφία παραλλαγές του, το δίκτυο Bi-LSTM και το δίκτυο GRU.

Ένα γενικό συμπέρασμα, για όλα τα είδη δικτύων που μελετήσαμε, είναι ότι τιμές ρυθμού εκμάθησης μεγαλύτερες ή ίσες του 0,001 εξαλείφουν αστάθειες που εμφανίζονται για μικρότερες τιμές.

Επίσης, από μια συγκεκριμένη τιμή αριθμού νευρώνων στο εκάστοτε στρώμα και πάνω δεν επέρχεται κάποια επιπλέον βελτίωση. Έτσι έχει σημασία να ελέγχεται στις δοκιμές ποιο είναι αυτό το «κάτω» όριο αριθμού νευρώνων και στη συνέχεια, όταν το δίκτυο θα χρησιμοποιηθεί σε άγνωστα δεδομένα, να χρησιμοποιούμε το «μικρότερο» δίκτυο, μια που θα λειτουργεί ταχύτερα από δίκτυα με μεγαλύτερο αριθμό νευρώνων.

Συγκρίνοντας τα 3 είδη δικτύων μεταξύ τους, φάνηκε ότι το Bi-LSTM δεν έδωσε κάποιο πλεονέκτημα έναντι των άλλων, οπότε εγκαταλείπεται, μια που έχει εγγενώς διπλό υπολογιστικό φόρτο από τα LSTM και τα GRU. Τα δίκτυα Bi-LSTM αναμένουμε να δώσουν πλεονέκτημα όταν η χρονική ακολουθία που θέλουμε να ταξινομούμε έχει διαφορετική εξέλιξη στην αρχή της από ότι στο τέλος της, οπότε το να μαθαίνει το δίκτυο και τις δύο ροές (ορθή/ανάδρομη) χρονικής αλληλουχιακής δομής έχει να προσφέρει πλεονεκτήματα σε σχέση με τα LSTM & GRU. Όμως οι άτρακτοι του ύπνου δεν έχουν τέτοια δομή, είναι ημιτονοειδή κύματα, που έχουν φάση ομαλής ανόδου (στην αρχή) και ομαλής καθόδου (στο τέλος τους). Άρα «ειδωμένα» και προς τα

εμπρός στο χρόνο και ανάστροφα προς τα πίσω έχουν όμοια μορφή/εξέλιξη. Μάλιστα αν τα παραδείγματα εκπαίδευσης αφορούν τμήματα όπου η άτρακτος είναι στην «κύρια» φάση της δεν υπάρχει ούτε καν αυτή η αλλαγή πλάτους.

Τα διστρωματικά δίκτυα GRU εμφάνισαν μια πολύ καλή επίδοση, ανεξαρτήτως της χρήσης dropout, ανώτερης των υπολοίπων δικτύων, επειδή πιο συχνά, στο φάσμα των δοκιμών μας, εμφάνιζαν ακρίβεια $\geq 90\%$ και για τα δύο είδη ακρίβειας.

Τέλος πρέπει να αναφέρουμε τους πολύ σοβαρούς περιορισμούς της μελέτης μας, που την περιορίζουν στο επίπεδο μιας πρώτης προκαταρκτικής μελέτης. Καταρχήν η βάση δεδομένων στην οποία στηριχθήκαμε έχει μικρό αριθμό νυκτερινών καταγραφών (μόλις 8). Και οι καταγραφόμενοι δεν ήταν υγιείς (όπως θα ταίριαζε σε μια αρχική μελέτη), αλλά με διάφορες παθολογίες. Επίσης ο αριθμός παραδειγμάτων που είχαμε για το σύνολο δοκιμής ήταν πολύ μικρός (10 ανά κατηγορία).

Προφανώς σε επόμενη μελέτη θα πρέπει να επεξεργαστούμε πολύ μεγαλύτερο αριθμό ατράκτων, από τις έστω λίγες καταγραφές της βάσης δεδομένων ώστε ο αριθμός των παραδειγμάτων για το σύνολο δοκιμής να μεγαλώσει. Τέλος, θα πρέπει να εφαρμόσουμε τεχνικές boot-strapping, όπου τα σύνολα εκπαίδευσης/επικύρωσης/δοκιμής να εναλλάσσονται και να εξάγουμε τον μέσο όρο όλων των δοκιμών.

Βιβλιογραφία

- [1] Σαρακηνός Σταύρος (2022) *Αυτόματη ανίχνευση απράκτων του ύπνου με τεχνικές βαθιάς μάθησης*, προπτυχιακή διπλωματική, Αθήνα: Πανεπιστήμιο Δυτικής Αττικής. Available from: <https://polynoe.lib.uniwa.gr/xmlui/handle/11400/2893> (Accessed 7 July 2023)
- [2] Keith L. Moore, Arthur F. Dalley, Anne M. R. Agur (2016) *Clinical Oriented Anatomy* 3rd ed. pp.968-974
- [3] Vittorio A. Sironi (2011) ‘Origin and evolution of deep brain stimulation’, *Frontiers* [online] vol. 5 , 18 August 2011. Available from: <https://www.frontiersin.org/articles/10.3389/fnint.2011.00042/full> (Accessed 19 April 2023)
- [4] Dale Purves, George J. Augustine, David Fitzpatrick, William C. Hall, Anthony Samuel LaMantia, James O. McNamara, S.Mark Williams (2004) *Neuroscience*, 3rd ed. pp.744.
- [5] Dale Purves, George J. Augustine, David Fitzpatrick, William C. Hall, Anthony Samuel LaMantia, James O. McNamara, S.Mark Williams (2004) *Neuroscience*, 3rd ed. pp.740-741
- [6] Brittany C. Clawson, Jaclyn Durkin, Sara J. Alton (2016). ‘Form and Function of Sleep Spindles across the Lifespan’[online]. Available from: [Form and Function of Sleep Spindles across the Lifespan - PMC \(nih.gov\)](#) (Accessed 23 June 2023)
- [7] Χαρά Γεωργία Τσέκου (2012) *Μελέτη νευροφυσιολογικών παραμέτρων σε ανθεκτικούς στη θεραπεία ασθενείς με σχιζοφρένεια πριν και μετά από θεραπεία με κλοζαπίνη*, PhD thesis, Αθήνα: Ψυχιατρική Κλινική Πανεπιστημίου Αθηνών, Αιγινήτειο Νοσοκομείο. Available from: <https://freader.ekt.gr/eadd/index.php?doc=41188&lang=el#p=1> (Accessed 24 June 2023)
- [8] Yingyi Zhang, Gonzalo M. Quiñones, and Fabio Ferrarellia (2019) ‘Sleep spindle and slow wave abnormalities in schizophrenia and other psychotic disorders: recent findings and future directions’ *Schizophr Res.* 221: pp29–36 [online]. Available from: [Sleep spindle and slow wave abnormalities in schizophrenia and other psychotic disorders: recent findings and future directions - PMC \(nih.gov\)](#) (Accessed 23 June 2023)
- [9] Chetan S. Nayak, Arayampambil C. Anilkumar (2023). ‘EEG Normal Waveforms’ *Statpearls* [online]. Available from: [EEG Normal Waveforms - StatPearls - NCBI Bookshelf \(nih.gov\)](#) (Accessed 5 June 2023)
- [10] Mustafa H. Gandhi (2023) ‘Physiology, K Complex’ *Statpearls* [online]. Available from: <https://www.statpearls.com/ArticleLibrary/viewarticle/31499>

(Accessed 28 May 2023)

[11] Marc Jobert, Eric Poiseau, Peter Jaehnig, Hartmut Schulz, Stanislaw Kubicki (1992) 'Pattern recognition by matched filtering: An analysis of sleep spindle and K-complex density under the influence of lormetazepam and zopiclone' *Neuropsychobiology* no. 26, pp. 100-107. Available from: https://www.researchgate.net/publication/21793679_Pattern_Recognition_by_Matched_Filtering_An_Analysis_of_Sleep_Spindle_and_K-Complex_Density_under_the_Influence_of_Lormetazepam_and_Zopiclone (Accessed 22 April 2023)

[12] Jiabin Li, Bei Wang, Takenao Sugi, Yu Zhang, Masatoshi Nakamura (2017) 'Automatic Sleep Spindle Detection with EEG Based on Complex Demodulation Method and Decision Tree Model' *Journal of Biomedical Science and Engineering* [online], vol 10, May 2017. Available from: <https://www.scirp.org/journal/paperinformation.aspx?paperid=76088> (Accessed 24 June 2023)

[13] Wessan Al-Salman, Yan Li, Peng Wen (2019) 'Detecting sleep spindles in EEGs using wavelet fourier analysis and statistical features' *Biomedical Signal Processing and Control* [online], vol 48, February 2019, pp.80-92. Available from: <https://www.sciencedirect.com/science/article/abs/pii/S1746809418302672#:~:text=The%20results%20showed%20that%20the%20Wavelet%20Fourier%20Analysis,spindles%20detection%20than%20using%20other%20wavelet%20functions.%20%E2%80%A2> (Accessed 24 June 2023)

[14] Mporas, I., Korvesis, P., Zacharaki, E.I., Megalooikonomou, V. (2013). 'Sleep Spindle Detection in EEG Signals Combining HMMs and SVMs'. In: Iliadis, L., Papadopoulos, H., Jayne, C. (eds) *Engineering Applications of Neural Networks. EANN 2013. Communications in Computer and Information Science*, vol 384. Springer, Berlin, Heidelberg. Available from: https://link.springer.com/chapter/10.1007/978-3-642-41016-1_15 (Accessed 14 May 2023)

[15] Shania Kennedy 'Types of Deep Learning & Their Uses in Healthcare' [online]. Available from: <https://healthitanalytics.com/features/types-of-deep-learning-their-uses-in-healthcare#:~:text=By%20analyzing%20how%20data%20is,the%20potential%20to%20change%20healthcare.> (Accessed 23 June 2023)

[16] Simon Haykin (2010). *Neural networks and learning machines*. 3rd ed. pp.10-11

[17] Hyndman, R.J., & Athanasopoulos, G. (2021) '*Forecasting: principles and practice*', 3rd edition (Greek translation), OTexts: Melbourne, Australia. OTexts.com/fppgr. (Accessed 23 June 2023)

[18] Sagar Sharma (2017). ‘Activation Functions in Neural Networks’ *Towards Data Science*. Available from: [Activation Functions in Neural Networks | by SAGAR SHARMA | Towards Data Science](#) (Accessed 5 June 2023)

[19] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozail, Aaron Courville, Yoshua Bengio (2014). *Generative Adversarial Nets* [online]. Available from: <https://arxiv.org/pdf/1406.2661.pdf> (Accessed 23 June 2023)

[20] Rian Dolphin (2020). ‘LSTM Networks | A Detailed Explanation’ *Towards Data Science*. Available from: <https://towardsdatascience.com/lstm-networks-a-detailed-explanation-8fae6aefc7f9> (Accessed 14 May 2023)

[21] Yugesh Verma (2021). ‘Complete Guide To Bidirectional LSTM (With Python Codes)’ *Mystery Vault*. Available from: <https://analyticsindiamag.com/complete-guide-to-bidirectional-lstm-with-python-codes/> (Accessed 24 June 2023)

[22] Simeon Kostadinov (2017). ‘Understanding GRU Networks’ *Towards Data Science*. Available from: <https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be> (Accessed 23 June 2023)

[23] <https://commons.wikimedia.org/wiki/File:Gray726-Brodman.svg> (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.1).

[24] https://el.wikipedia.org/wiki/%CE%9C%CE%B5%CF%84%CF%89%CF%80%CE%B9%CE%B1%CE%AF%CE%BF%CF%82_%CE%BB%CE%BF%CE%B2%CF%8C%CF%82 (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.2).

[25] Revati Shiram, Mahalingam Sundhararajan, Nivedita Daimiwal (2012). ‘EEG Based Cognitive Workload Assessment for Maximum Efficiency’. Available from: https://www.researchgate.net/figure/EEG-10-20-Electrode-Placement_fig1_286371237 (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.3).

[26] Caroline Brewer, Aleksandra Lasica (2021). ‘Consciousness and Sleep’. Available from: <https://teachmephysiology.com/nervous-system/sensory-system/consciousness-and-sleep/> (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.5).

[27] Ferrarelli F, Tononi G (2016). ‘Reduced sleep spindle activity point to a TRN-MD thalamus-PFC circuit dysfunction in schizophrenia’. Available from: <https://europepmc.org/article/pmc/5423439> (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.7).

[28] <https://www.dreamstime.com/royalty-free-stock-photo-normal-brain-waves-eeg-image29444815> (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 2.1).

[29] https://en.wikipedia.org/wiki/K-complex#/media/File:Stage2sleep_new.svg
(Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 2.2).

[30] https://www.researchgate.net/figure/The-overall-architecture-of-the-Convolutional-Neural-Network-CNN-includes-an-input_fig4_331540139
(Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 3.3)

[31] <https://opendatascience.com/understanding-the-mechanism-and-types-of-recurring-neural-networks/> (Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 3.4)

[32] Gonzalo M. Rojas, Carolina Alvarez, Carlos Montoya, María de la Iglesia-Vayá, Jaime Cisternas, Marcelo Gálvez (2017). Multimodal Study of Resting-State Functional Connectivity Networks using EEG electrodes position as seed. Available from: <https://www.biorxiv.org/content/biorxiv/early/2017/08/08/167585.full.pdf>
(Χρησιμοποιήθηκε αποκλειστικά ως πηγή της Εικόνας 1.4)

Παράρτημα 1: Matlab

Ο αλγόριθμος αναπτύχθηκε στο περιβάλλον του Matlab το οποίο προσφέρεται δωρεάν μέσω του Πανεπιστημίου Δυτικής Αττικής.

Στην εικόνα 5.1 φαίνεται η αρχιτεκτονική του δικτύου LSTM ενός στρώματος και οι υπερπαραμέτροι που προτείνονται από το Matlab. Οι αλλαγές που κάναμε από πλευράς μας αφορούν τον αριθμό κρυφών μονάδων «numHiddenUnits» τον οποίο αλλάζαμε σε κάθε «τρέξιμο» του κώδικα καθώς και τον ρυθμό εκπαίδευσης (Learning Rate).

```
>> numFeatures = 100;
numHiddenUnits = 100;
numClasses = 2;
layers = [ ...
sequenceInputLayer(numFeatures)
lstmLayer(numHiddenUnits,'OutputMode','last')
fullyConnectedLayer(numClasses)
softmaxLayer
classificationLayer];

options = trainingOptions('adam', ...
'ExecutionEnvironment','cpu', ...
'MaxEpochs',1000, ...
'ValidationData',{XVal,Yval}, ...
'GradientThreshold',2, ...
'Shuffle','every-epoch', ...
'Verbose',false, ...
'Plots','training-progress');

>> net = trainNetwork(XTrain,Ytrain,layers,options);
>> YPred = classify(net,XTest);
>> acc = mean(YPred == Ytest)
```

Εικόνα 5.1 Αρχιτεκτονική δικτύου LSTM ενός στρώματος

Στην Εικόνα 5.2 φαίνεται η αρχιτεκτονική του δικτύου Bi-LSTM που ακολουθεί την ίδια λογική με την παραπάνω εικόνα με τη διαφορά ότι χρησιμοποιούμε “bilstmLayer”.

```
>> numFeatures = 100;
numHiddenUnits = 2;
numClasses = 2;
layers = [ ...
sequenceInputLayer(numFeatures)
bilstmLayer(numHiddenUnits,'OutputMode','last')
fullyConnectedLayer(numClasses)
softmaxLayer
classificationLayer];

options = trainingOptions('adam', ...
'ExecutionEnvironment','cpu', ...
'MaxEpochs',1000, ...
'ValidationData',{XVal,Yval}, ...
'GradientThreshold',2, ...
'Shuffle','every-epoch', ...
'Verbose',false, ...
'Plots','training-progress');

>> net = trainNetwork(XTrain,Ytrain,layers,options);
>> YPred = classify(net,XTest);
>> acc = mean(YPred == Ytest)
```

Εικόνα 5.2 Αρχιτεκτονική δικτύου Bi-LSTM ενός στρώματος

Στην Εικόνα 5.3 φαίνεται ο κώδικας που χρησιμοποιήθηκε για τα δίκτυα LSTM δύο κρυφών στρωμάτων. Η διαφορά με τα παραπάνω είναι ότι έχουμε εισάγει την παράμετρο της απόρριψης (dropout) και την εντολή '[net,info] = trainNetwork(XTrain,Ytrain,layers,options);' η οποία μας εμφανίζει τον ακριβή αριθμό απώλειας (loss ή validation loss) όπως φαίνεται στις τελευταίες στήλες των πινάκων 4.3,4.4,4.5.

```
>> numFeatures = 100;
>> numHiddenUnits1 = 75;
numHiddenUnits2 = 50;
>> numClasses = 2;
>> layers = [ ...
sequenceInputLayer(numFeatures)
lstmLayer(numHiddenUnits1,'OutputMode','sequence')
dropoutLayer(0.2)
lstmLayer(numHiddenUnits2,'OutputMode','last')
dropoutLayer(0.2)
fullyConnectedLayer(numClasses)
softmaxLayer
classificationLayer];
>> options = trainingOptions('adam', ...
'ExecutionEnvironment','cpu', ...
'MaxEpochs',1000, ...
'ValidationData',{XVal,Yval}, ...
'GradientThreshold',2, ...
'Shuffle','every-epoch', ...
'Verbose',false, ...
'Plots','training-progress');
>> net = trainNetwork(XTrain,Ytrain,layers,options);
[net,info] = trainNetwork(XTrain,Ytrain,layers,options);
YPred = classify(net,XTest);

acc = mean(YPred == Ytest)
```

Εικόνα 5.3: Δίκτυο LSTM δύο στρωμάτων

Στις εικόνες 5.4 και 5.5 φαίνεται ο κώδικα που χρησιμοποιήθηκε για GRU δίκτυα ενός και δύο στρωμάτων αντίστοιχα.

```
numFeatures = 100;
numHiddenUnits = 100;
numClasses = 2;
layers = [ ...
    sequenceInputLayer(numFeatures)
    gruLayer(numHiddenUnits,'OutputMode','last')
    dropoutLayer(0.5)
    fullyConnectedLayer(numClasses)
    softmaxLayer
    classificationLayer];

>> miniBatchSize = 300;

options = trainingOptions('adam', ...
    'ExecutionEnvironment','cpu', ...
    'MaxEpochs',1000, ...
    'MiniBatchSize',miniBatchSize, ...
    'ValidationData',{XVal,Yval}, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'Verbose',false, ...
    'Plots','training-progress');

>> [net,info] = trainNetwork(XTrain,Ytrain,layers,options);
>> YPred = classify(net,XTest, 'MiniBatchSize',miniBatchSize);
>> acc = mean(YPred == Ytest)
```

Εικόνα 5.4: Δίκτυο GRU ενός στρώματος

```
numFeatures = 100;
numHiddenUnits1 = 125;
numHiddenUnits2 = 100;
numClasses = 2;
layers = [ ...
    sequenceInputLayer(numFeatures)
    gruLayer(numHiddenUnits1)
    dropoutLayer(0.2)
    gruLayer(numHiddenUnits2,'OutputMode','last')
    dropoutLayer(0.2)
    fullyConnectedLayer(numClasses)
    softmaxLayer
    classificationLayer];

>> miniBatchSize = 300;

options = trainingOptions('adam', ...
    'ExecutionEnvironment','cpu', ...
    'MaxEpochs',1000, ...
    'MiniBatchSize',miniBatchSize, ...
    'ValidationData',{XVal,Yval}, ...
    'GradientThreshold',2, ...
    'Shuffle','every-epoch', ...
    'Verbose',false, ...
    'Plots','training-progress');

>> [net,info] = trainNetwork(XTrain,Ytrain,layers,options);
>> YPred = classify(net,XTest, 'MiniBatchSize',miniBatchSize);
>> acc = mean(YPred == Ytest)
```

Εικόνα 5.5: Δίκτυο GRU δύο στρωμάτων