



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Χρήση Νευρωνικών Δικτύων Πρόσθιας Τροφοδότησης με Χρονικές Καθυστερήσεις για την Ανίχνευση Επιληπτικών Κρίσεων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δασκαλάκης-Παπατζανάκης Ι. Γεώργιος

Επιβλέπουσα : Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

Αθήνα, Μάρτιος 2013



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Χρήση Νευρωνικών Δικτύων Πρόσθιας Τροφοδότησης με Χρονικές Καθυστερήσεις για την Ανίχνευση Επιληπτικών Κρίσεων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Δασκαλάκης-Παπατζανάκης Ι. Γεώργιος

Επιβλέπουσα : Κωνσταντίνα Σ. Νικήτα
Καθηγήτρια Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 19^η Μαρτίου 2013.

.....
Κ. Νικήτα
Καθηγήτρια Ε.Μ.Π.

.....
Δ.-Δ. Κουτσούρης
Καθηγητής Ε.Μ.Π.

.....
Γ. Ματσόπουλος
Επ. Καθηγητής
Ε.Μ.Π.

Αθήνα, Μάρτιος 2013

.....
Γεώργιος Ι. Δασκαλάκης-Παπατζανάκης
Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Γεώργιος Δασκαλάκης-Παπατζανάκης, 2013.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Στην παρούσα διπλωματική εργασία διερευνάται η δυνατότητα χρήσης τεχνητών νευρωνικών δικτύων (ΤΝΔ) για την ανίχνευση επιληπτικών κρίσεων. Αρχικά εξετάστηκε η δυνατότητα χρήσης δικτύων πρόσθιας τροφοδότησης με χρονικές καθυστερήσεις για την πρόβλεψη μελλοντικών τιμών του ηλεκτροεγκεφαλογράφηματος (ΗΕΓ). Συγκεκριμένα έγιναν δοκιμές πάνω σε ΗΕΓ δεδομένα βάθους που προήλθαν από τη βάση δεδομένων του Πανεπιστημίου του Freiburg τα οποία μετά από φιλτράρισμα παρουσιάστηκαν απευθείας στο νευρωνικό δίκτυο, το οποίο εκπαιδεύτηκε να προβλέπει ένα βήμα μπροστά. Έγιναν δοκιμές με δίκτυα 4 έως 60 νευρώνων και 4 έως 60 καθυστερήσεων και αξιολογήθηκε η απόδοσή τους με βάση το μέσο τετραγωνικό και το μέσο απόλυτο σφάλμα ώστε να καταλήξουμε στο μέγεθος του δικτύου που θα χρησιμοποιήσουμε. Τα αποτελέσματα της πρόβλεψης για ένα βήμα μπροστά ήταν ικανοποιητικά και έτσι δοκιμάσαμε να χρησιμοποιήσουμε τα δίκτυα για πρόβλεψη πολλαπλών βημάτων. Κάτι τέτοιο ωστόσο δεν έγινε εφικτό. Στη συνέχεια αναπτύχθηκε ένας αλγόριθμος ανίχνευσης επιληπτικών κρίσεων ο οποίος χρησιμοποιεί το σφάλμα των παραπάνω δικτύων για να ανιχνεύσει επιληπτικές κρίσεις, βασιζόμενος στην παρατήρηση ότι το επιληπτικό ΗΕΓ είναι πιο απρόβλεπτο από το κανονικό (μεσοκρισικό) ΗΕΓ. Ο αλγόριθμος αυτός εφαρμόζεται στη συνέχεια με τη χρήση δικτύων 16 νευρώνων και 32 καθυστερήσεων καθώς και δικτύων 16 νευρώνων και 100 καθυστερήσεων σε έξι ασθενείς της βάσης δεδομένων, σε καθένα από τα τρία εστιακά κανάλια ξεχωριστά. Παρουσιάζονται τα αποτελέσματα αυτής της εφαρμογής, τα οποία ποικίλλουν από ασθενή σε ασθενή, όντας ωστόσο αρκετά ενθαρρυντικά συνολικά.

Λέξεις κλειδιά: Επιληψία, πρόβλεψη τιμών χρονοσειράς, ανίχνευση επιληπτικών κρίσεων, εγκεφαλογράφημα, τεχνητά νευρωνικά δίκτυα, γραμμή καθυστέρησης απαγωγών.

Abstract

In this thesis we investigate the use artificial neural networks (ANN) to detect epileptic seizures. Specifically we examine the usability of time delay feedforward neural networks (TLFN) for the prediction of future electroencephalographic (EEG) timesteps. Specific tests were performed on depth EEG data of the database of the University of Freiburg, which were filtered and then presented directly to the neural networks, and used to train the networks to predict one step ahead. We tested networks ranging from 4 to 60 neurons and from 4 to 60 delays and their performance was evaluated based on the mean squared and mean absolute error in order to conclude to the optimum size of the ANN for the task of prediction. The results of the one-step ahead prediction were satisfactory and therefore we tried to use the networks for multistep prediction. The outcome of multistep prediction however was not successful. We subsequently developed a seizure detection algorithm that uses the prediction error of these networks to detect seizures based on the observation that epileptic EEG is more unpredictable than normal (interictal) EEG. This algorithm is then applied using TLFNs of 16 neurons and 100 delays and 16 neurons and 32 delays to six patients from the database, to each of the three focal channels separately. Finally, the results of this application are presented, results which vary from patient to patient, but are overall quite encouraging.

Keywords: Epilepsy, timeseries prediction, seizure detection, electroencephalography, artificial neural networks, tapped delay line.

Ευχαριστίες

Αρχικά θα ήθελα να ευχαριστήσω την καθηγήτρια κ. Νικήτα, για την ανάθεση και την επίβλεψη αυτής της διπλωματικής εργασίας.

Η διπλωματική αυτή δεν θα είχε ολοκληρωθεί χωρίς την ουσιαστική βοήθεια, τις πολύτιμες συμβουλές και διορθώσεις του Δρ Γιώργου Τσιρογιάννη, τον οποίο ευχαριστώ βαθύτατα.

Ευχαριστώ ,τέλος, την Δρ. Λάγια Πολυχρονάκη για τη στήριξη και το βοηθητικό υλικό που προσέφερε.

Περιεχόμενα

Κεφάλαιο 1: Πρόλογος

1.1 Σκοπός της εργασίας.....	18
1.2 Δομή της εργασίας.....	18

Κεφάλαιο 2: Γενικά Στοιχεία

2.1 Ο ανθρώπινος εγκέφαλος.....	20
2.2 Νευρώνας	
2.2.1. Ο νευρώνας και η δομή του.....	21
2.2.2. Η ηλεκτρική λειτουργία του νευρώνα.....	22
2.3 Ηλεκτροεγκεφαλογράφημα	
2.3.1. Γενικά στοιχεία.....	23
2.3.2. Εγκεφαλικοί ρυθμοί.....	25
2.3.3. Παράσιτα ΗΕΓ.....	26
2.3.4. Επεμβατικό Ηλεκτροεγκεφαλογράφημα.....	26
2.3.5. Σύγκριση επεμβατικού ΗΕΓ και ΗΕΓ επιφανείας.....	27
2.3.6. Χρησιμότητα Ηλεκτροεγκεφαλογραφήματος.....	28
2.4 Επιληψία	
2.4.1. Γενικά στοιχεία.....	28
2.4.2. Ταξινόμηση επιληπτικών κρίσεων.....	29
2.5 Ανίχνευση και πρόβλεψη επιληπτικών κρίσεων.....	30
2.6 Τα δεδομένα	
2.6.1. Η βάση δεδομένων του Freiburg.....	32
2.6.2. Προεπεξεργασία Δεδομένων.....	32
2.7 Βιβλιογραφία.....	33

Κεφάλαιο 3: Τεχνητά Νευρωνικά Δίκτυα

3.1 Εισαγωγή – Ιστορική Αναδρομή.....	35
3.2 Μοντέλο τεχνητού νευρώνα.....	35
3.3 Αρχιτεκτονικές Δικτύων.....	38
3.4 Μάθηση και Εκπαίδευση Νευρωνικών Δικτύων.....	39
3.5 Αλγόριθμοι Εκπαίδευσης	
3.5.1. Αλγόριθμοι εκπαίδευσης Νευρώνα.....	40

3.5.2. Ο Αλγόριθμος Backpropagation.....	41
3.6 Δυναμικά Οδηγούμενα και Αναδρομικά Δίκτυα.....	42
3.7 Βιβλιογραφία.....	44

Κεφάλαιο 4: Ανάπτυξη ΤΝΔ για πρόβλεψη ΗΕΓ τιμών

4.1 Εισαγωγή.....	46
4.2 Τα δίκτυα.....	46
4.3 Εύρεση βέλτιστου μεγέθους δικτύου.....	47
4.4 Πρόβλεψη ένα βήμα μπροστά στο χρόνο (one-step-ahead prediction).....	56
4.5 Πρόβλεψη για πολλαπλά βήματα (multistep prediction).....	60
4.6 Βιβλιογραφία.....	66

Κεφάλαιο 5: Ανίχνευση επιληπτικών κρίσεων

5.1 Εισαγωγή.....	67
5.2 Περιγραφή του αλγορίθμου για την ανίχνευση των επιληπτικών κρίσεων	
5.2.1. Βήμα 1ο: Εκπαίδευση δικτύων.....	67
5.2.2. Τα δίκτυα.....	68
5.2.3. Βήμα 2ο: Εξαγωγή σφαλμάτων.....	69
5.2.4. Βήμα 3ο: Άθροιση σφαλμάτων.....	70
5.2.5. Βήμα 4ο: Κατωφλίωση.....	71
5.2.6. Βήμα 5ο: Εφαρμογή χρονικού παραθύρου.....	71
5.2.7. Βήμα 6ο: Εξαγωγή αποτελεσμάτων.....	72
5.3 Εκτέλεση του αλγορίθμου και παράμετροι που μεταβάλλονται.....	73
5.4 Απόδοση του αλγορίθμου.....	75
5.5 Αποτελέσματα	
5.5.1. Ασθενής 9.....	75
5.5.2. Ασθενής 3.....	83
5.5.3. Ασθενής 1.....	87
5.5.4. Ασθενής 19.....	91
5.5.5. Ασθενής 16.....	95
5.5.6. Ασθενής 5.....	101
5.5.7. Συγκεντρωτικά Αποτελέσματα.....	105
5.6 Βιβλιογραφία.....	106

Κεφάλαιο 6: Συμπεράσματα και Συζήτηση

6.1	Συμπεράσματα ως προς την πρόβλεψη ΗΕΓ τιμών.....	107
6.2	Συμπεράσματα εφαρμογής του αλγορίθμου ανίχνευσης επιληπτικών κρίσεων.....	107
6.3	Συζήτηση και προτάσεις για μελλοντική έρευνα.....	108

Παράρτημα: Εργαλεία και Κώδικας MATLAB

Π1.	Σχεδιαγράμματα Δικτύων.....	110
Π2.	Κώδικας και Εντολές του Matlab	
Π2.1	Φόρτωση και Προεπεξεργασία Δεδομένων.....	111
Π2.2	Εκπαίδευση Δικτύων.....	113
Π2.3	Αλγόριθμος Ανίχνευσης Επιληπτικών κρίσεων.....	114
Π2.4	Γραφικές Παραστάσεις.....	125

Κατάλογος Σχημάτων

Κεφάλαιο 2

Σχήμα 2.1 Οι εγκεφαλικοί λοβοί.....	20
Σχήμα 2.2 Η δομή του νευρώνα.....	21
Σχήμα 2.3 Δυναμικό δράσης. Η διαφορά δυναμικού που αποτυπώνεται στο σχήμα είναι το V (εσωκυττάριου χώρου)- V (εξωκυττάριου χώρου) συναρτήσει του χρόνου.....	23
Σχήμα 2.4: Διεθνές σύστημα τοποθέτησης ηλεκτροδίων 10-20	24
Σχήμα 2.5: Οι εγκεφαλικοί ρυθμοί.....	26
Σχήμα 2.6: Επέμβαση για τοποθέτηση ενδοκράνιων ηλεκτροδίων.....	27
Σχήμα 2.7: Λειτουργία συσκευής κλειστού βρόχου.....	31

Κεφάλαιο 3

Σχήμα 3.1: Μη γραμμικό μοντέλο νευρώνα.....	36
Σχήμα 3.2: Λογιστική Συνάρτηση.....	37
Σχήμα 3.3: α) Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου, β) Πολυεπίπεδο Δίκτυο Πρόσθιας Τροφοδότησης, γ) Αναδρομικό Δίκτυο.....	39
Σχήμα 3.4: Γραμμή καθυστέρησης απαγωγών αποτελούμενη από p βαθμίδες.....	43
Σχήμα 3.5: Σχεδιάγραμμα TLFN.....	44

Κεφάλαιο 4

Σχήμα 4.1: Μεταβολή μέσου τετραγωνικού σφάλματος πρόβλεψης για τα δεδομένα εκπαίδευσης των δικτύων.....	51
Σχήμα 4.2: Μεταβολή μέσου απόλυτου σφάλματος πρόβλεψης για μεσοκρισικά δεδομένα.....	53
Σχήμα 4.3: Μεταβολή μέσου τετραγωνικού σφάλματος πρόβλεψης για μεσοκρισικά δεδομένα.....	55

Σχήμα 4.4: Το δίκτυο που χρησιμοποιήθηκε για τις προσομοιώσεις.....	56
Σχήμα 4.5: Σφάλματα πρόβλεψης κατά την έναρξη της κρίσης.....	57
Σχήμα 4.6: Σφάλματα πρόβλεψης κατά την έναρξη της κρίσης μεγέθυνση.....	58
Σχήμα 4.7: Προβλεφθέν και πραγματικό σήμα.....	59
Σχήμα 4.8: Προβλεφθέν και πραγματικό σήμα μεγέθυνση.....	59
Σχήμα 4.9: Closed loop net.....	60
Σχήμα 4.10: Πρόβλεψη για ένα(1) βήμα.....	62
Σχήμα 4.11: Πρόβλεψη για δύο(2) βήματα.....	62
Σχήμα 4.12: Πρόβλεψη για δέκα(10) βήματα	63
Σχήμα 4.13: Πρόβλεψη για εικοσιένα(21) βήματα	63
Σχήμα 4.14: Πρόβλεψη για πενήντα ένα (51) βήματα	64
Σχήμα 4.15: Πρόβλεψη για εκατόν ένα (101) βήματα	64
Σχήμα 4.16: Πρόβλεψη για διακόσια ένα (201) βήματα	65
Σχήμα 4.17: Έξοδος νευρωνικού για πρόβλεψη 500 βημάτων.....	65

Κεφάλαιο 5

Σχήμα 5.1: Παράδειγμα πραγματικού και προβλεπόμενου ΗΕΓ.....	69
Σχήμα 5.2: Σφάλμα τέταρτης κρίσης ασθενή 9, για παράθυρο κινούμενων μέσων=700.....	74
Σχήμα 5.3: Θέσεις ηλεκτροδίων ασθενή 9.....	75
Σχήμα 5.4: Η πρώτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 29.871.....	80
Σχήμα 5.5: Η δεύτερη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 88504.....	81
Σχήμα 5.6: Η τρίτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.363.....	81

Σχήμα 5.7: Η τέταρτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 10.000 και τελειώνει στο 42.466.....	82
Σχήμα 5.8: Η πέμπτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 43.320.....	82
Σχήμα 5.9: Θέσεις ηλεκτροδίων ασθενή 3.....	83
Σχήμα 5.10: Η πρώτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 47.808.....	85
Σχήμα 5.11: Η δεύτερη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 50.400.....	85
Σχήμα 5.12: Η τρίτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 49.843.....	86
Σχήμα 5.13: Η τέταρτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 44.156.....	86
Σχήμα 5.14: Η πέμπτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 26.398.....	87
Σχήμα 5.15: Θέσεις ηλεκτροδίων ασθενή 1.....	88
Σχήμα 5.16: Η πρώτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 24.990.....	90
Σχήμα 5.17: Η δεύτερη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 24.743.....	90
Σχήμα 5.18: Η τρίτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.845.....	91
Σχήμα 5.19: Η τέταρτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.882.....	91
Σχήμα 5.20: Θέσεις ηλεκτροδίων ασθενή 19.....	92
Σχήμα 5.21: Η πρώτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 5.000 και τελειώνει στο 10.931.....	94
Σχήμα 5.22: Η δεύτερη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.914.....	94
Σχήμα 5.23: Η τρίτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 22.785.....	95

Σχήμα 5.24: Η τέταρτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 22.214.....	95
Σχήμα 5.25: Θέσεις ηλεκτροδίων του ασθενή 16.....	96
Σχήμα 5.26: Η πρώτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 63.676.....	98
Σχήμα 5.27: Η δεύτερη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 43.992.....	98
Σχήμα 5.28: Η τρίτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 44.667.....	99
Σχήμα 5.29: Η τέταρτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 42.254.....	99
Σχήμα 5.30: Η πέμπτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 60.345.....	100
Σχήμα 5.31: Θέσεις ηλεκτροδίων του ασθενή 5.....	101
Σχήμα 5.32: Η πρώτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.834.....	103
Σχήμα 5.33: Η δεύτερη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 27.133.....	104
Σχήμα 5.34: Η τρίτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.704.....	104
Σχήμα 5.35: Η τέταρτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.910.....	105
Σχήμα 5.36: Η πέμπτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 58.868.....	105

Κατάλογος Πινάκων

Κεφάλαιο 4

Πίνακας 4.1: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 4-20 καθυστερήσεις.....	49
Πίνακας 4.2: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 24-40 καθυστερήσεις.....	50
Πίνακας 4.3: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 44-60 καθυστερήσεις.....	50
Πίνακας 4.4: Μεσοκριτικό μέσο απόλυτο σφάλμα για 4-20 καθυστερήσεις.....	52
Πίνακας 4.5: Μεσοκριτικό μέσο απόλυτο σφάλμα για 24-40 καθυστερήσεις.....	52
Πίνακας 4.6: Μεσοκριτικό μέσο απόλυτο σφάλμα για 44-60 καθυστερήσεις.....	53
Πίνακας 4.7: Μεσοκριτικό μέσο τετραγωνικό σφάλμα για 4-20 καθυστερήσεις.....	54
Πίνακας 4.8: Μεσοκριτικό μέσο τετραγωνικό σφάλμα για 24-40 καθυστερήσεις.....	54
Πίνακας 4.9: Μεσοκριτικό μέσο τετραγωνικό σφάλμα για 44-60 καθυστερήσεις.....	55
Πίνακας 4.10: Μέσο απόλυτο σφάλμα πρόβλεψης για πολλαπλά βήματα.....	61

Κεφάλαιο 5

Πίνακας 5.1: Αριθμός ΨΑ για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	76
Πίνακας 5.2: Αριθμός ΨΑ για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	76
Πίνακας 5.3: ΨΑ/h για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	76
Πίνακας 5.4: ΨΑ/h για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	76
Πίνακας 5.5: Μέση καθυστέρηση ανίχνευσης (sec) για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	77
Πίνακας 5.6: Μέση καθυστέρηση ανίχνευσης (sec) για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	77
Πίνακας 5.7: ΨΑ για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	77
Πίνακας 5.8: ΨΑ για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	77
Πίνακας 5.9: ΨΑ ανά ώρα για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	78

Πίνακας 5.10: ΨΑ ανά ώρα για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	78
Πίνακας 5.11: Μέση καθυστέρηση (sec) για ασθενή 9 και δίκτυα 32 καθυστερήσεων.....	78
Πίνακας 5.12: Μέση καθυστέρηση (sec) για ασθενή 9 και δίκτυα 100 καθυστερήσεων.....	78
Πίνακας 5.13: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 9.....	79
Πίνακας 5.14: Καθυστερήσεις ανίχνευσης (sec) για τις επιληψίες του ασθενή 9, πρώτο κατώφλι.....	79
Πίνακας 5.15: Καθυστερήσεις ανίχνευσης (sec) για τις επιληψίες του ασθενή 9, δεύτερο κατώφλι.....	79
Πίνακας 5.16: ΨΑ ανά ώρα για ασθενή 3 και δίκτυα 32 καθυστερήσεων.....	83
Πίνακας 5.17 :ΨΑ ανά ώρα για ασθενή 3 και δίκτυα 100 καθυστερήσεων.....	83
Πίνακας 5.18: Μέση καθυστέρηση (sec) για ασθενή 3 και δίκτυα 32 καθυστερήσεων.....	84
Πίνακας 5.19: Μέση καθυστέρηση (sec) για ασθενή 3 και δίκτυα 100 καθυστερήσεων.....	84
Πίνακας 5.20: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 3.....	84
Πίνακας 5.21: ΨΑ ανά ώρα για ασθενή 1 και δίκτυα 32 καθυστερήσεων.....	88
Πίνακας 5.22: ΨΑ ανά ώρα για ασθενή 1 και δίκτυα 100 καθυστερήσεων.....	88
Πίνακας 5.23: Μέση καθυστέρηση (sec) για ασθενή 1 και δίκτυα 32 καθυστερήσεων.....	89
Πίνακας 5.24: Μέση καθυστέρηση (sec) για ασθενή 1 και δίκτυα 100 καθυστερήσεων.....	89
Πίνακας 5.25: ΨΑ ανά ώρα για ασθενή 19 και δίκτυα 32 καθυστερήσεων.....	92
Πίνακας 5.26: ΨΑ ανά ώρα για ασθενή 19 και δίκτυα 100 καθυστερήσεων.....	92
Πίνακας 5.27: Μέση καθυστέρηση (sec) για ασθενή 19 και δίκτυα 32 καθυστερήσεων.....	93
Πίνακας 5.28: Μέση καθυστέρηση (sec) για ασθενή 19 και δίκτυα 100 καθυστερήσεων.....	93
Πίνακας 5.29: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 19.....	93
Πίνακας 5.30: ΨΑ ανά ώρα για ασθενή 16 και δίκτυα 32 καθυστερήσεων.....	96
Πίνακας 5.31: ΨΑ ανά ώρα για ασθενή 16 και δίκτυα 100 καθυστερήσεων.....	96
Πίνακας 5.32: Μέση καθυστέρηση (sec) για ασθενή 16 και δίκτυα 32 καθυστερήσεων.....	97

Πίνακας 5.33: Μέση καθυστέρηση ασθενή 16 για (sec) και δίκτυα 100 καθυστερήσεων....	97
Πίνακας 5.34: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 16.....	100
Πίνακας 5.35: ΨΑ ανά ώρα για ασθενή 5 και δίκτυα 32 καθυστερήσεων.....	101
Πίνακας 5.36: ΨΑ ανά ώρα για ασθενή 5 και δίκτυα 100 καθυστερήσεων.....	101
Πίνακας 5.37: Μέση καθυστέρηση (sec) για ασθενή 5 και δίκτυο 32 καθυστερήσεων.....	102
Πίνακας 5.38: Μέση καθυστέρηση (sec) για ασθενή 5 και δίκτυο 100 καθυστερήσεων.....	102
Πίνακας 5.39: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 5.....	102
Πίνακας 5.40: Συγκεντρωτικές τιμές με τα καλύτερα αποτελέσματα του κάθε ασθενή με βάση τη μέση καθυστέρηση ανίχνευσης.....	105
Πίνακας 5.41: Συγκεντρωτικές τιμές με τα καλύτερα αποτελέσματα του κάθε ασθενή με βάση την ειδικότητα ανίχνευσης.....	106

Κεφάλαιο 1 : Πρόλογος

1.1 Σκοπός της Εργασίας

Σκοπός της παρούσας διπλωματικής εργασίας είναι η μελέτη της χρήσης τεχνητών νευρωνικών δικτύων (ΤΝΔ) σε δεδομένα ηλεκτροεγκεφαλογραφήματος (ΗΕΓ). Πιο συγκεκριμένα, σκοπός μας ήταν η διερεύνηση της δυνατότητας χρήσης νευρωνικών δικτύων για την πρόβλεψη μελλοντικών τιμών ΗΕΓ βάθους με βάση προηγούμενες τιμές του ΗΕΓ. Έτσι, μετά από βιβλιογραφική επισκόπηση της μέχρι τώρα έρευνας στον τομέα της πρόβλεψης και ανίχνευσης επιληπτικών κρίσεων, εκπαιδεύσαμε νευρωνικά δίκτυα με χρονικές καθυστερήσεις στην είσοδο τους ώστε να τα τροφοδοτήσουμε απευθείας με το ΗΕΓ σήμα και να προβλέψουν τις μελλοντικές τιμές του σήματος με βάση τις παρελθούσες τιμές. Αρχικά στόχος ήταν με βάση τα αποτελέσματα της πρόβλεψης μελλοντικών τιμών να προσπαθήσουμε να προβλέψουμε τις επερχόμενες επιληπτικές κρίσεις. Ωστόσο η πρόβλεψη των τιμών του ΗΕΓ για επαρκή βήματα στο μέλλον δεν κατέστη δυνατή.

Έτσι, αποφασίσαμε στη συνέχεια να εξετάσουμε το κατά πόσο είναι δυνατή η χρήση τέτοιων δικτύων για την ανίχνευση επιληπτικών κρίσεων. Παρατηρήσαμε κατά τη χρήση των ΤΝΔ για πρόβλεψη ΗΕΓ τιμών ότι οι τιμές του επιληπτικού κομματιού του ΗΕΓ ήταν λιγότερο “προβλέψιμες” από ότι οι υπόλοιπες τιμές. Αναπτύχθηκε λοιπόν ένας αλγόριθμος που χρησιμοποιεί αυτό το χαρακτηριστικό για να κάνει ανίχνευση επιληπτικών κρίσεων. Στη συνέχεια ο αλγόριθμος αυτός εφαρμόστηκε για έξι ασθενείς της βάσης δεδομένων του Πανεπιστημίου του Freiburg, και αξιολογήθηκαν τα αποτελέσματα του. Για την αξιολόγηση αυτή δόθηκε ιδιαίτερο βάρος στο να αποτιμηθεί το πόσο συστηματικά παρατηρείται το χαρακτηριστικό το επιληπτικό ΗΕΓ να είναι πιο απρόβλεπτο από το κανονικό και δευτερευόντως αξιολογήθηκε η επίδοση του αλγορίθμου αυτού καθεαυτού για την ανίχνευση επιληπτικών κρίσεων.

Για όλες τις προσομοιώσεις νευρωνικών δικτύων χρησιμοποιήθηκε το Neural Network Toolbox του Matlab©. Η προεπεξεργασία των δεδομένων έγινε επίσης με τη χρήση ρουτινών του Matlab. Έγινε ακόμα χρήση του πακέτου EEGLab για οπτικοποίηση του ΗΕΓ όπου αυτό χρειάστηκε.

1.2 Δομή της εργασίας

Στο κεφάλαιο 2 αναφερόμαστε στη νευροφυσιολογία του εγκεφάλου και παρουσιάζουμε την βασική του μονάδα, τον νευρώνα. Παρουσιάζεται η ηλεκτρική λειτουργία του νευρώνα, οι ηλεκτροχημικές αλληλεπιδράσεις μεταξύ νευρώνων και στη συνέχεια η

καταγραφή της προκύπτουσας ηλεκτρικής δραστηριότητας του εγκεφάλου από το ηλεκτροεγκεφαλογράφημα (HEΓ). Γίνεται αναφορά σε διατάξεις καταγραφής του HEΓ, στους εγκεφαλικούς ρυθμούς που παρατηρούνται σε αυτό, στα παράσιτα του και στη χρησιμότητά του. Αναφερόμαστε ακόμα στο επεμβατικό HEΓ και στις διαφορές του με το HEΓ επιφανείας. Γίνεται επίσης μια αναφορά στην επιληψία, την παθολογία της και την ταξινόμηση των επιληπτικών κρίσεων καθώς και στην μέχρι τώρα προσπάθεια για αυτόματη ανίχνευση και πρόβλεψη επιληπτικών κρίσεων. Τέλος, παρουσιάζουμε τη βάση δεδομένων του Freiburg και την προεπεξεργασία που έγινε στα δεδομένα.

Στο **κεφάλαιο 3** παρουσιάζονται τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ). Γίνεται μια μικρή ιστορική αναδρομή, αναφερόμαστε στο βασικό μαθηματικό μοντέλο νευρώνα που χρησιμοποιείται και στα επιμέρους του χαρακτηριστικά. Στη συνέχεια κάνουμε μια γενικότερη αναφορά στη μηχανική μάθηση καθώς και στην επιβλεπόμενη εκπαίδευση νευρωνικών δικτύων. Αναφερόμαστε στο πώς εκπαιδεύεται ένας νευρώνας και στη συνέχεια παρουσιάζεται ο αλγόριθμος Backpropagation για την εκπαίδευση πολυεπίπεδων δικτύων. Τέλος αναφερόμαστε στις δομές που χρησιμοποιούνται για να ενσωματώσουμε χρονική μνήμη στα νευρωνικά δίκτυα και παρουσιάζουμε τα δίκτυα που ενσωματώνουν γραμμή καθυστέρησης απαγωγών στην είσοδό τους, δυναμικά δηλαδή δίκτυα.

Στο **κεφάλαιο 4** αναλύεται η προσπάθεια που έγινε για την πρόβλεψη HEΓ τιμών. Αρχικά αναλύουμε το σκεπτικό των πειραματισμών και των επιλογών που έγιναν. Στη συνέχεια αναφερόμαστε στο πώς εκπαιδεύοντας δίκτυα διαφορετικού μεγέθους με το ίδιο δείγμα εκπαίδευσης καταλήξαμε να χρησιμοποιήσουμε ένα συγκεκριμένο μέγεθος δικτύου για τις προσομοιώσεις μας. Παρουσιάζονται τα αποτελέσματα της παραπάνω εκπαίδευσης δικτύων, καθώς και τα αποτελέσματα της πρόβλεψης HEΓ τιμών με το δίκτυο που επιλέχθηκε για ένα και παραπάνω βήματα στο μέλλον για δεδομένα του ασθενή 5. Αξιολογείται η επίδοση του δικτύου.

Στο **κεφάλαιο 5** προτείνουμε έναν αλγόριθμο για την ανίχνευση των επιληπτικών κρίσεων με τη χρησιμοποίηση του σφάλματος των δικτύων που αναπτύξαμε για την πρόβλεψη HEΓ τιμών. Αναλύουμε τον αλγόριθμο, τις παραμέτρους τρεξίματος του και το γιατί επιλέχθηκαν να είναι αυτές, καθώς και το πώς περιμένουμε η μεταβολή συγκεκριμένων παραμέτρων να επηρεάσει την απόδοση του αλγορίθμου. Στη συνέχεια παραθέτουμε τα αποτελέσματα του τρεξίματος του αλγορίθμου αυτού για τα δεδομένα έξι ασθενών, μαζί με ένα μικρό σχολιασμό σχετικά με τα αποτελέσματα του κάθε ασθενούς ξεχωριστά.

Στο **κεφάλαιο 6** υπάρχουν κάποια συγκεντρωτικά αποτελέσματα από όλες τις προσομοιώσεις που τρέξαμε και συζήτηση πάνω σε αυτά. Υπάρχουν επίσης κάποιες προτάσεις για μελλοντική έρευνα.


Κεφάλαιο 2: Γενικά Στοιχεία

2.1 Ο Ανθρώπινος Εγκέφαλος

Ο ανθρώπινος εγκέφαλος αποτελεί το κύριο μέρος του κεντρικού νευρικού συστήματος. Είναι το πιο πολύπλοκο και θα μπορούσαμε να πούμε το πιο ενδιαφέρον κομμάτι της ανθρώπινης φυσιολογίας, καθώς είναι υπεύθυνος για τη δημιουργία των σκέψεων, για τη μνήμη, τον έλεγχο των δραστηριοτήτων του σώματος και των συναισθημάτων. Βρίσκεται μέσα στο κρανίο και “πλέει” μέσα στο εγκεφαλονωτιαίο υγρό. Έχει μάζα της τάξης του 1,5 kg. Βασική δομική και λειτουργική μονάδα του εγκεφάλου είναι ο νευρώνας. Στον εγκέφαλο βρίσκονται 10^{10} νευρώνες [1] οι οποίοι σχηματίζουν ένα πολύπλοκο δίκτυο και συνδέονται μεταξύ τους σε 10^{14} με 10^{15} σημεία, τα οποία ονομάζονται συνάψεις. Στον εγκέφαλο υπάρχουν επίσης νευρογλοιακά κύτταρα τριπλάσια σχεδόν σε αριθμό από τους νευρώνες [2], που είναι μη νευρικά κύτταρα που παρέχουν υποστηρικτικές λειτουργίες στους νευρώνες, όπως προστασία, διατήρηση της ομοιόστασης κ.α.

Ο ανθρώπινος εγκέφαλος βρίσκεται μέσα στο κρανίο και αποτελείται από τον κυρίως εγκέφαλο, την παρεγκεφαλίδα και το εγκεφαλικό στέλεχος. Ο κυρίως εγκέφαλος αποτελείται από δύο εγκεφαλικά ημισφαίρια[3] και το εξωτερικό του μέρος ονομάζεται εγκεφαλικός φλοιός. Ο εγκεφαλικός φλοιός περιλαμβάνει περίπου 100 δισεκατομμύρια νευρώνες οι οποίοι είναι ισχυρά διασυνδεδεμένοι μεταξύ τους (η επιφάνεια ενός μεγάλου νευρώνα που βρίσκεται στον φλοιό μπορεί να καλύπτεται με έως και 10^5 συνάψεις).[4]

Κάθε εγκεφαλικό ημισφαίριο αποτελείται από 5 λοβούς : τον μετωπιαίο (frontal), τον βρεγματικό (parietal), τον ινιακό(occipital), τον κροταφικό (temporal) και τον μεταιχμιακό. Στο παρακάτω σχήμα βλέπουμε τους τέσσερις από τους πέντε λοβούς (ο μεταιχμιακός βρίσκεται εσωτερικά και μπορεί να φανεί μόνο σε τομή) καθώς και την παρεγκεφαλίδα.[3]



Σχήμα 2.1 Οι εγκεφαλικοί λοβοί*


* Εικόνα τροποποιημένη από <http://www.dentalarticles.com/visual/d/brain-side-view.php>

2.2 Νευρώνας

2.2.1 Ο νευρώνας και η δομή του

Οι νευρώνες είναι υπεύθυνοι για την επεξεργασία πληροφορίας και τη μετάδοση σημάτων. Αποτελούνται από το σώμα (κυρίως νευρικό κύτταρο) και τις αποφυάδες (νευρίτες) (Σχήμα 2.2). Οι νευρίτες με τη σειρά τους χωρίζονται σε δύο κατηγορίες, τον νευροάξονα και τους δενδρίτες. Ο νευροάξονας (ή απλά άξονας) είναι μια νηματοειδής προέκταση του κυρίως νευρικού κυττάρου [1]. Κατά μήκος του άξονα ταξιδεύουν οι νευρικές ώσεις, κατευθυνόμενες προς την απόληξη του νευρώνα, δηλαδή την προσυναπτική μεμβράνη που είναι κομμάτι των συνάψεων. Μπορούμε δηλαδή να πούμε ότι ο άξονας αποτελεί την έξοδο του νευρώνα. Οι δενδρίτες είναι διακλαδισμένες αποφύσεις του νευρώνα και βρίσκονται σε επαφή με τις απολήξεις αξόνων άλλων νευρώνων και αποτελούν τις εισόδους του νευρώνα.

Στις επιφάνειες των δενδριτών και του σώματος βρίσκονται πολλές μικρές απολήξεις, τα συναπτικά κομβία, τα οποία δημιουργούν τις συνάψεις. Οι συνάψεις είναι τα σημεία στα οποία ο νευρώνας έρχεται σε ηλεκτροχημική επαφή με άλλους νευρώνες για να τους μεταδώσει σήματα. Αποτελούνται από την προσυναπτική μεμβράνη, το συναπτικό χάσμα και τη μετασυναπτική μεμβράνη. Μέσω της μετασυναπτικής μεμβράνης των συνάψεων που βρίσκονται στους δενδρίτες (ή το σώμα), συλλέγονται τα σήματα που εκπέμπονται από τις απολήξεις του νευροάξονα και μεταδίδονται στο σώμα του νευρώνα. Κάθε νευρώνας είναι ταυτόχρονα προσυναπτικός σε πολλές συνάψεις και μετασυναπτικός σε πολλές άλλες [5].



Σχήμα 2.2 Η δομή του νευρώνα [1]

Ολόκληρος ο νευρώνας, μαζί με τον άξονα και τους δενδρίτες, καλύπτεται από κυτταρική μεμβράνη. Η μεμβράνη αυτή έχει πάχος περίπου 8-10nm. Αποτελείται από ένα διμοριακό

λιπιδικό στρώμα, που είναι αδιαπέραστο από τα περισσότερα βιολογικά ενεργά μόρια, στο οποίο υπάρχουν ενσωματωμένα πρωτεϊνικά μόρια, τα οποία κάνουν την μεμβράνη διαπερατή σε πολλές αναγκαίες για τη λειτουργία του κυττάρου ουσίες. Έτσι, ο συνδυασμός των δύο παραπάνω στοιχείων κάνει την κυτταρική μεμβράνη ουσιαστικά ημιπερατή.[1]

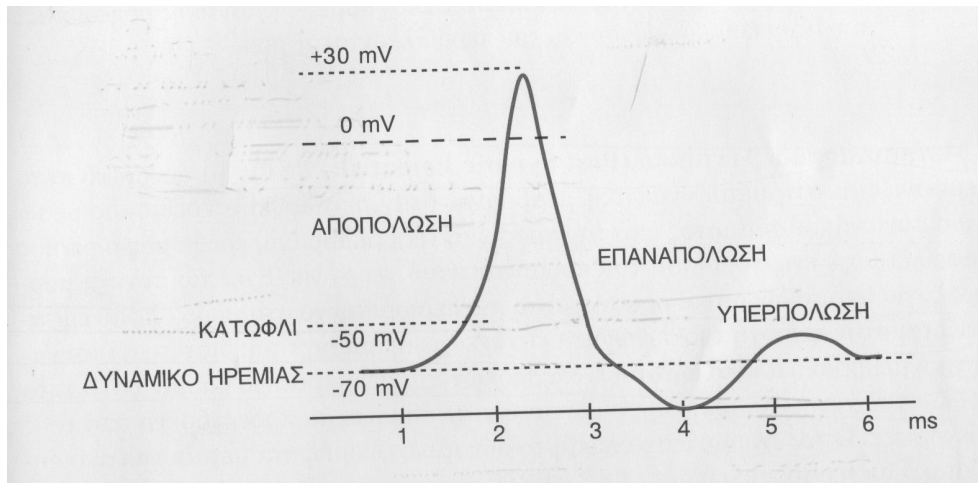
2.2.2 Η ηλεκτρική λειτουργία του νευρώνα

Κατά μήκος της μεμβράνης του νευρώνα διατηρείται σε κατάσταση ηρεμίας μία διαφορά ηλεκτρικού δυναμικού, τέτοια ώστε το εσωτερικό του κυττάρου να βρίσκεται σε αρνητικό δυναμικό ως προς τον εξωτερικό χώρο. Το δυναμικό ηρεμίας για τα νευρωνικά κύτταρα είναι περίπου ίσο με -70 mV και οφείλεται στην άνιση κατανομή ιόντων μεταξύ των δύο πλευρών της μεμβράνης. Η κατανομή αυτή διατηρείται από τη μεταβολική δραστηριότητα του κυττάρου, και κατά κύριο λόγο εξαιτίας της ύπαρξης της αντλίας νατρίου καλίου. Η αντλία αυτή προκαλεί τη μετατόπιση περισσότερων θετικών ιόντων νατρίου προς τα έξω και λιγότερων θετικών ιόντων καλίου προς τα μέσα σε αναλογία τρία ιόντα νατρίου προς δύο ιόντα καλίου. Επειδή στο εσωτερικό του νευρώνα υπάρχουν πολλά αρνητικά ιόντα που δεν μπορούν να διαχυθούν μέσω της μεμβράνης, η έξοδος των θετικά φορτισμένων ιόντων νατρίου από το σώμα του νευρώνα έχει σαν αποτέλεσμα να μην εξισορροπούνται τα αρνητικά ιόντα από άλλα θετικά και ως εκ τούτου το εσωτερικό του νευρώνα να φορτίζεται αρνητικά.[6] Η αύξηση της τιμής του δυναμικού της μεμβράνης ονομάζεται αποπόλωση, ενώ η μείωση της υπερπόλωση.

Κατά μήκος της μεμβράνης των νευρώνων δημιουργούνται δύο είδη διαμεμβρανικής ρευματικής ροής, που σχετίζονται με τη μετάδοση και επεξεργασία πληροφοριών μεταξύ των νευρώνων, και προκαλούν τα εξής διαφορετικής φύσης δυναμικά : α) δυναμικό δράσης και β) μετασυναπτικό δυναμικό [1].

α) Δυναμικό Δράσης (action potential)

Όταν ένας νευρώνας έχει αποπολωθεί εξαιτίας των ερεθισμάτων που φθάνουν από τους δενδρίτες τόσο ώστε το δυναμικό της μεμβράνης του να ξεπεράσει μια τιμή κατωφλίου, ξεκινάει μια διαδικασία θετικής ανατροφοδότησης, ο νευρώνας ενεργοποιείται και παράγει ένα δυναμικό δράσης. Ως δυναμικό δράσης νοείται μία ραγδαία μεταβολή (περίπου 100 mV) του ηλεκτρικού δυναμικού κατά μήκος της μεμβράνης που διαρκεί περίπου 1 ms. Στην συνέχεια ακολουθεί επιστροφή στην αρχική κατάσταση ηρεμίας αφού συμβεί επαναπόλωση και υπερπόλωση. (Σχήμα 2.3). Αυτή η κρουστική ώση διαδίδεται ταχύτατα κατά μήκος του άξονα, αναπαράγοντας τον κύκλο πόλωση-αποπόλωση-πόλωση και τη συνακόλουθη ροή μέσα και έξω από την κυτταρική μεμβράνη.[1]



Σχήμα 2.3 Δυναμικό δράσης. Η διαφορά δυναμικού που αποτυπώνεται στο σχήμα είναι το $V(\text{εσωκυττάρειου χώρου})-V(\text{εξωκυττάρειου χώρου})$ συναρτήσει του χρόνου (Κουτσούρης και συν 2003).

β) Μετασυναπτικό Δυναμικό (Post-Synaptic Potential- PSP)

Το δυναμικό αυτό εμφανίζεται στη μετασυναπτική μεμβράνη, όταν μεταδοθεί ο ερεθισμός μέσω του συναπτικού χάσματος από την προσυναπτική μεμβράνη, ερεθισμός ο οποίος οφείλεται σε ενεργοποίηση του προσυναπτικού νευρώνα. Έχει πιο συνεχή μορφολογία από τα δυναμικά δράσης, είναι πιο περιορισμένο στο χώρο – αφού εμφανίζεται στην περιοχή της σύναψης – και έχει χαμηλότερη τιμή, διότι η μετασυναπτική μεμβράνη αποπολώνεται (οπότε και το δυναμικό ονομάζεται μετασυναπτικό δυναμικό διέγερσης - EPSP) ή υπερπολώνεται (μετασυναπτικό δυναμικό καταστολής - IPSP) σε μικρότερο βαθμό από ότι το σώμα του νευρώνα, όπου αθροίζονται όλα τα σήματα τα προερχόμενα από τους δενδρίτες. Μια εγκεφαλική σύναψη είναι συνήθως μόνο διεγείρουσα (μπορεί να εμφανιστεί μόνο EPSP) ή μόνο κατασταλτική (μπορεί να εμφανιστεί μόνο IPSP). [1]


2.3 Ηλεκτροεγκεφαλογράφημα (ΗΕΓ)

2.3.1 Γενικά στοιχεία

Ηλεκτροεγκεφαλογράφημα είναι η καταγραφή της μεταβολής της ηλεκτρικής δραστηριότητας του εγκεφάλου με το χρόνο. Η πρώτη τέτοια καταγραφή για τον ανθρώπινο εγκέφαλο έγινε από τον Γερμανό ψυχίατρο H. Berger το 1924. Το ΗΕΓ στηρίζεται στην καταγραφή των διαφορών δυναμικού, οι οποίες παρουσιάζονται σε σημεία της εξωτερικής δερματικής επιφάνειας του ανθρώπινου κεφαλιού. Τα δυναμικά αυτά αντιστοιχούν στα ηλεκτρικά δυναμικά που αναπτύσσονται στο εσωτερικό του εγκεφάλου κατά την διάρκεια της λειτουργίας του, όπως αναλύσαμε παραπάνω. Πιο συγκεκριμένα, πρόκειται για την αποτύπωση της ηλεκτρικής δραστηριότητας του εγκεφαλικού φλοιού,

καθώς πλέον υπάρχουν επαρκείς αποδείξεις ότι οι πηγές που δημιουργούν τα ΗΕΓ κύματα βρίσκονται στο φλοιό.[3] Για να κάνουμε την καταγραφή αυτή εκμεταλλευόμαστε το γεγονός ότι ο εγκεφαλικός ιστός, οι μήνιγγες (που περιβάλλουν τον εγκέφαλο), το κρανίο και το δέρμα άγουν το ηλεκτρικό ρεύμα, και έτσι τα ρεύματα που δημιουργούνται από την εγκεφαλική δραστηριότητα διαχέονται μέχρι την εξωτερική δερματική επιφάνεια. Τα μετρούμενα ηλεκτρικά σήματα είναι ασθενή και κυμαίνονται από περίπου 1μV ως 100μV. Ανακύπτει έτσι η ανάγκη για μεγάλη προσοχή και ακρίβεια κατά την μέτρησή τους, αλλά και η ανάγκη να υπάρξει ενίσχυση του σήματος για να μπορεί να γίνει η καταγραφή του. Συντελεστές ενίσχυσης της τάξης του 10^5 είναι συνηθισμένοι.

Για την καταγραφή του ΗΕΓ χρησιμοποιούμε ηλεκτρόδια που αποτελούνται από τον συνδυασμό ενός μετάλλου με ένα άλας του (συνηθέστερα ένα συνδυασμό αργύρου (Ag) και χλωριούχου αργύρου (AgCl)) σε συνδυασμό με ηλεκτρολύτη που περιέχει κυρίως ανιόντα χλωρίου. Τα ηλεκτρόδια έρχονται σε άμεση επαφή με το δέρμα του κεφαλιού, σε σημεία στα οποία έχει προηγηθεί καθαρισμός του δέρματος με οινόπνευμα για να επιτύχουμε αντίσταση επαφής μικρότερη των 5 kΩ. Υπάρχουν διάφορα πρότυπα που καθορίζουν τα σημεία τοποθέτησης των ηλεκτροδίων πάνω στο κεφάλι. Το πιο συνηθισμένο είναι το Διεθνές Σύστημα 10-20, κατά το οποίο επιλέγουμε το 20% της απόστασης μεταξύ των δύο αυτιών ως την απόσταση ανάμεσα σε δύο οποιαδήποτε ηλεκτρόδια και το 10% της αποστάσεως των δύο αυτιών ως την απόσταση από το αυτί ως το κοντινότερο προς αυτό ηλεκτρόδιο (Σχήμα 2.4).



Σχήμα 2.4: Διεθνές σύστημα τοποθέτησης ηλεκτροδίων 10–20¹

Το σήμα που καταγράφει κάθε στιγμή ο ηλεκτροεγκεφαλογράφος είναι η διαφορά μεταξύ των δυναμικών δύο ηλεκτροδίων για εκείνη τη χρονική στιγμή. Ως προς το ποια ηλεκτρόδια θα επιλέξουμε για να παίρνουμε τη διαφορά τους υπάρχουν δύο επιλογές[1]: μπορούμε να έχουμε διπολική μέτρηση ή μονοπολική μέτρηση (μέτρηση με αναφορά). Κατά την διπολική μέτρηση το σήμα προκύπτει ως διαφορά δυναμικού δύο περιοχών με εγκεφαλική

1 Σχήμα από <http://www.bem.fi/book/13/13.htm>

λειτουργία (ενεργών περιοχών). Αντίθετα , στη μονοπολική μέτρηση παίρνουμε τη διαφορά δυναμικού ενός ηλεκτροδίου ενεργής περιοχής με ένα ηλεκτρόδιο ανενεργής περιοχής, δηλαδή ένα ηλεκτρόδιο που είναι τοποθετημένο για παράδειγμα στο αυτί ή σε κάποιο σημείο στο λαιμό από όπου θεωρούμε ότι δεν καταγράφεται καθόλου εγκεφαλική δραστηριότητα.

2.3.2 Εγκεφαλικοί ρυθμοί


Βασικό χαρακτηριστικό του ΗΕΓ είναι η ύπαρξη (ή μη) ρυθμών, συγκεκριμένων δηλαδή κυματομορφών που χαρακτηρίζονται από το φασματικό τους περιεχόμενο, το οποίο βρίσκεται μέσα σε καθορισμένες ζώνες συχνοτήτων. Οι βασικοί ρυθμοί είναι οι παρακάτω[1] (Σχήμα 2.5):

Ρυθμός δέλτα: αποτελείται από κύματα συχνότητας μικρότερης των 4 Hz και πλάτους 10 έως 300μV. Εμφανίζονται κυρίως κατά των ύπνο στους ενήλικες και είναι εξέχων ρυθμός του ΗΕΓ νεογνών και μικρών παιδιών. Δεν παρατηρούνται στο φυσιολογικό ΗΕΓ ηρεμίας ενηλίκου, οπότε η πιθανή παρουσία τους σχετίζεται με εγκεφαλική ανωμαλία.

Ρυθμός θήτα: αποτελείται από κύματα συχνότητας 4 έως 7 Hz και πλάτους 50 έως 150μV. Συνήθως εμφανίζεται στο ΗΕΓ εγρήγορσης ενηλίκων. Φαίνεται να συνδέεται με μηχανισμούς καταστολής, είτε στην είσοδο στη φάση χαλάρωσης , είτε σε φάσεις αυξημένης προσοχής[1].

Ρυθμός άλφα: αποτελείται από κύματα συχνότητας 8 έως 13 Hz και πλάτους 20 έως 60μV. Ο ρυθμός άλφα είναι ο βασικός ρυθμός του φυσιολογικού ΗΕΓ ενηλίκου και εμφανίζεται σε περίπου 75% των ενηλίκων. Το κλείσιμο των ματιών προκαλεί αύξηση του ρυθμού άλφα, ενώ αντίθετα , μείωση της δραστηριότητας α έχει συσχετισθεί με αισθητηριακό ερεθισμό ή πνευματική δραστηριότητα.

Ρυθμός βήτα: αποτελείται από κύματα συχνότητας μεγαλύτερης των 14 Hz και πλάτους 5-20μV. Είναι ο κυρίαρχος ρυθμός που εμφανίζεται κατά την φάση εγρήγορσης ενός φυσιολογικού ατόμου. Απουσία του ρυθμού αυτού μπορεί να σχετίζεται με την ύπαρξη κάποιας ανωμαλίας.




Σχήμα 2.5: Οι εγκεφαλικοί ρυθμοί

2.3.3 Παράσιτα ΗΕΓ

Παράσιτο ονομάζεται κάθε δυναμικό μη-εγκεφαλικής προέλευσης που παρεισφύει στην ΗΕΓ καταγραφή και δημιουργεί προβλήματα στην ερμηνεία του ΗΕΓ, καθώς είτε το μιμείται είτε το παραμορφώνει. Τα παράσιτα διακρίνονται σε βιολογικά, που προέρχονται από τη λειτουργία του σώματος του ασθενή στον οποίο γίνεται η καταγραφή και είναι για παράδειγμα μυικά, καρδιαγγειακά ηλεκτροδερμικά (λόγω της λειτουργίας των ιδρωτοποιών αδένων κ.α), και τεχνητά (ή μη βιολογικά) που οφείλονται σε προβλήματα λειτουργίας του συστήματος καταγραφής του ΗΕΓ και είναι για παράδειγμα παράσιτα ηλεκτροδίων (κακή επαφή, φθορά, υψηλές αντιστάσεις), παράσιτα της ΗΕΓ συσκευής ή εξωτερικούς παράγοντες, όπως είναι η γραμμή τροφοδοσίας ρεύματος που παράγει ένα πολύ συνηθισμένο παράσιτο στα 50Hz.

2.3.4 Επεμβατικό Ηλεκτροεγκεφαλογράφημα

Το ΗΕΓ που περιγράψαμε ως τώρα, που καταγράφει τη διαφορά των ηλεκτρικών δυναμικών στην επιφάνεια του ανθρώπινου κεφαλιού ονομάζεται ΗΕΓ επιφανείας. Υπάρχει και το ΗΕΓ βάθους που ονομάζεται και επεμβατικό ΗΕΓ, καθώς για την πραγματοποιηθεί χρειάζεται ο ασθενής να εγχειρησθεί και να τοποθετηθούν ηλεκτρόδια απευθείας μέσα στον εγκέφαλο. Ένα τέτοιο ενδοκράνιο ηλεκτρόδιο καταγράφει ηλεκτρικά δυναμικά από πολύ πιο περιορισμένη χωρική έκταση σε σχέση με ένα ηλεκτρόδιο επιφανείας (νευρώνες που απέχουν περισσότερο από ένα εκατοστό από το σημείο καταγραφής έχουν αμελητέα συνεισφορά στο καταγραφόμενο σήμα [7]).



Σχήμα 2.6: Επέμβαση για τοποθέτηση ενδοκράνιων ηλεκτροδίων¹

Για μια τέτοια καταγραφή μπορεί να χρησιμοποιηθεί οποιοσδήποτε συνδυασμός ενδοκράνιων ηλεκτροδίων τα οποία μπορεί να είναι σε μορφή πλέγματος (grid), ταινίας (strip) ή βελονοειδή (depth electrodes). Τα ηλεκτρόδια σε μορφή ταινίας βρίσκονται προσκολλημένα σε μια ταινία και τοποθετούνται στην υποσκληρίδιο φλοιώδη περιοχή του εγκεφάλου. Χρησιμοποιούνται όταν η προς εξέταση περιοχή είναι περιορισμένης χωρικής έκτασης. Τα ηλεκτρόδια σε μορφή πλέγματος είναι πολλαπλά ηλεκτρόδια που βρίσκονται προσκολλημένα σε ένα πλέγμα και τοποθετούνται επίσης στην υποσκληρίδιο φλοιώδη περιοχή του εγκεφάλου. Χρησιμοποιούνται όταν η προς εξέταση περιοχή έχει μεγαλύτερη έκταση. Τα βελονοειδή (ή εν τω βάθει) ηλεκτρόδια έχουν τη μορφή λεπτού καλωδίου, και χρησιμοποιούνται για πρόσβαση σε βαθύτερες εγκεφαλικές δομές, όπως είναι η αμυγδαλή και ο ιππόκαμπος. [3]

2.3.5 Σύγκριση επεμβατικού ΗΕΓ και ΗΕΓ επιφανείας

Το ΗΕΓ επιφανείας είναι ένα εργαλείο ευρείας κλίμακας με την έννοια ότι η δραστηριότητα που καταγράφει αποτελεί το μέσο όρο συναπτικών δυναμικών προερχόμενων από τμήματα ιστών που μπορεί να περιλαμβάνουν πολύ μεγάλο αριθμό νευρώνων (χονδρικά μεταξύ 100 εκατομμυρίων και 1 δισεκατομμυρίου). Η επιφανειακή ΗΕΓ καταγραφή αποτελεί ένα χωρικό μέσο των ηλεκτρικών δυναμικών που γίνεται με τυχαίο τρόπο, και επιβάλλεται από την εξάπλωση των παραγόμενων ρευμάτων μέσω χωρικής αγωγιμότητας στο κεφάλι. Αντιθέτως, η χρήση ενδοκράνιων καταγραφών μπορεί να οδηγήσει σε πολύ πιο εντοπισμένη πληροφορία, παρέχοντας μόνο πολύ περιορισμένη χωρική κάλυψη, αποτυγχάνοντας όμως παράλληλα έτσι να αποτυπώσει την «μεγάλη εικόνα» της εγκεφαλικής λειτουργίας. Έτσι, στην πράξη, τα ενδοκράνια ΗΕΓ δεδομένα παρέχουν *διαφορετική* πληροφορία, όχι περισσότερη πληροφορία, σε σχέση με τα δεδομένα επιφανείας. [3], [4]

¹ Εικόνα από http://professionals.epilepsy.com/page/surgery_electrodes.html

Ένα άλλο πλεονέκτημα του επεμβατικού ΗΕΓ είναι ότι οι ενδοκράνιες ΗΕΓ καταγραφές χαρακτηρίζονται από υψηλότερο σηματοθορυβικό λόγο και υψηλότερη χωρική διακριτική ικανότητα, ενώ μπορεί να θεωρηθούν βασικά απαλλαγμένες παρασίτων [3] σε σχέση με το ΗΕΓ επιφανείας.

Ωστόσο, το ΗΕΓ βάθους συνήθως αποφεύγεται εξαιτίας της ανάγκης για χειρουργική επέμβαση για την τοποθέτηση των ηλεκτροδίων και των πιθανών επιπλοκών στον ασθενή. Επίσης το ΗΕΓ επιφανείας μας παρέχει όπως είπαμε μια καλύτερη γενική εικόνα της λειτουργίας του εγκεφάλου του ασθενή, κι έτσι ειδικά για τη διάγνωση και των εντοπισμό των εστιών της επιληψίας το προτιμούμε και καταφεύγουμε στο ΗΕΓ βάθους μόνο σε περιπτώσεις ασθενών που το ΗΕΓ επιφανείας έχει αποτύχει να εντοπίσει την εστία της επιληψίας και ταυτόχρονα έχουμε μια συγκεκριμένη υπόθεση που να μπορεί να επιβεβαιωθεί από τα ηλεκτρόδια του ΗΕΓ βάθους για το ποια μπορεί να είναι αυτή η εστία[8].

2.3.6 Χρησιμότητα ηλεκτροεγκεφαλογραφήματος

Η χρήση του ΗΕΓ στη Νευρολογία είναι ευρύτατη, καθώς αποτελεί μέθοδο φθηνή, ανώδυνη και απλή στην εφαρμογή της. Από τη μελέτη του ΗΕΓ μπορούν να εξαχθούν ιδιαίτερα χρήσιμα συμπεράσματα για τη εξέλιξη του Κεντρικού Νευρικού Συστήματος ενός ανθρώπου από τη γέννηση του έως την ενηλικίωση. Επίσης, το ΗΕΓ μπορεί να δώσει χρήσιμα στοιχεία στην περίπτωση εγκεφαλοπαθειών (π.χ. Νόσο Jacobs-Kreutzfeldt, Alzheimer) ή για την περίπτωση επιληψίας, όπου χρησιμεύει ως το κύριο μέσο, τόσο για τη διάγνωση της βαρύτητας της νόσου όσο και για την υποβοήθηση της διάγνωσης και της πρόγνωσης [9]. Το ΗΕΓ μελετάται ακόμη στις περιπτώσεις κρανιοεγκεφαλικών κακώσεων, κώματος, άνοιας, αυξημένης ενδοκρανιακής πίεσης και αποτελεί βασικό εργαλείο για την μελέτη του ύπνου.

2.4 Επιληψία

2.4.1. Γενικά στοιχεία

Η επιληψία μια από τις πιο συνηθισμένες εγκεφαλικές διαταραχές, η πιο συνηθισμένη μετά το εγκεφαλικό επεισόδιο. Το 10% των ανθρώπων βιώνει τουλάχιστον μια επιληπτική κρίση στη διάρκεια της ζωής τους, ενώ 50 περίπου εκατομμύρια άτομα παγκοσμίως πάσχουν από χρόνια εμφάνιση επιληπτικών κρίσεων, την οποία ονομάζουμε επιληψία. Στις περισσότερες περιπτώσεις (δύο τρίτα περίπου των ασθενών), χορηγείται αγωγή αντιεπιληπτικών φαρμάκων που κατορθώνει να ελέγξει τα συμπτώματα της επιληψίας. Επίσης 8-10% των ασθενών μπορεί να θεραπευτεί με τη βοήθεια χειρουργικής επέμβασης. Το υπόλοιπο 25% των ασθενών πάσχουν από φαρμακοανθεκτική επιληψία[10][11][12], δεν υπάρχουν δηλαδή διαθέσιμες φαρμακευτικές αγωγές για τις οποίες να μπορεί να επιτευχθεί έλεγχος των κρίσεων[13], και δεν υπάρχει επεμβατική λύση για την ασθένειά τους. Επιπλέον η επιληψία παρουσιάζει αρκετά μεγάλη θνησιμότητα και κινδύνους τραυματισμού[14], ο κυριότερος παράγοντας για αυτό είναι η ξαφνική και τις περισσότερες φορές απροειδοποίητη εμφάνιση

των επιληπτικών κρίσεων.

Σήμερα, αντιλαμβανόμαστε το εξέχον κλινικό χαρακτηριστικό της επιληψίας, την επιληπτική κρίση, ως την ξαφνική εμφάνιση διαλείπουσας δυσλειτουργίας του εγκεφάλου. [3]. Πρόσφατα, η Διεθνής Ένωση Κατά της Επιληψίας (International League against Epilepsy – ILAE) πρότεινε [15] τον ορισμό της επιληπτικής κρίσης ως «παροδική εμφάνιση σημείων και συμπτωμάτων λόγω μη-φυσιολογικής υπερβολικής (excessive) ή σύγχρονης (synchronous) νευρωνικής δραστηριότητας στον εγκέφαλο» και της επιληψίας ως την «χρόνια κατάσταση του εγκεφάλου που χαρακτηρίζεται από μια διαρκή κλίση για δημιουργία επιληπτικών κρίσεων και από τις νευροβιολογικές, γνωσιακές, ψυχολογικές, και κοινωνικές συνέπειες αυτής της κατάστασης».

2.4.2 Ταξινόμηση επιληπτικών κρίσεων

Υπάρχουν πολλά είδη επιληπτικών κρίσεων και αρκετοί τρόποι να τις κατηγοριοποιήσουμε. Όλες σχεδόν οι επιληπτικές κρίσεις μπορούν να ταξινομηθούν σε δύο γενικές κατηγορίες (που προτάθηκαν από την ILAE 1981)[16]. Η μια κατηγορία είναι οι γενικευμένες κρίσεις, των οποίων η έναρξη σχετίζεται με το μεγαλύτερο μέρος του εγκεφάλου ή και ολόκληρο τον εγκέφαλο και η άλλη οι μερικές ή εστιακές κρίσεις, οι οποίες ξεκινούν από ένα μόνο μέρος του εγκεφάλου (εστία).

Οι εστιακές κρίσεις έχουν κλινικές ή ΗΕΓ ενδείξεις εντοπισμένης έναρξης, αλλά η λέξη εστιακή δεν υποδηλώνει έναν σαφώς διακρινόμενο τόπο. Οι γενικευμένες κρίσεις χαρακτηρίζονται από εκτεταμένη εμπλοκή αμφοτερόπλευρων των εγκεφαλικών ημισφαιρίων κατά τη λήξη τους, συνήθως συνοδευόμενη από απώλεια συνείδησης. [3]

Στις γενικευμένες κρίσεις περιλαμβάνονται:

- Τονικοκλονικές κρίσεις (ή grand mal) που περιλαμβάνει το ξαφνικό πέσιμο του ασθενούς στο έδαφος και ακαμψία του σώματος (τονικό κομμάτι της κρίσης), ακολουθούμενο από τυπικές σπασμοδικές κινήσεις (κλονικό κομμάτι της κρίσης) και συνοδευόμενο -κάποιες φορές- από δάγκωμα της γλώσσας ή του στόματος και ακράτεια ούρων.[3] Διαρκούν δύο ή τρία λεπτά και κατά την διάρκεια αυτή ο ασθενής χάνει τις αισθήσεις του.
- Αφαιρέσεις (ή petit mal) που διαρκούν συνήθως λίγα δευτερόλεπτα , και εκδηλώνονται με ξαφνική απώλεια συνειδήσεως που συνοδεύεται από αφηρημένο κενό βλέμμα και στροφή των βολβών του ματιού.
- Μυοκλονικές κρίσεις, που εκδηλώνονται με ξαφνικές συσπάσεις των μυών και έχουν ως αποτέλεσμα σύντομα και αιφνίδια μυϊκά ξεσπάσματα οποιασδήποτε ομάδας μυών.
- Κλονικές κρίσεις, κατά τη διάρκεια των οποίων παρατηρούνται ρυθμικές μυϊκές συσπάσεις και σχετίζονται περισσότερο με τα άνω άκρα, το λαιμό και το πρόσωπο, [3]

- Τονικές κρίσεις , που σχετίζονται με ξαφνική σκλήρυνση των μυών και πτώση στο έδαφος και συνήθως διαρκούν ελάχιστα.[17]
- Ατονικές κρίσεις, που σχετίζονται με ξαφνική απώλεια του μυϊκού τόνου και άμεση κατάρρευση του ασθενούς.

Στις εστιακές κρίσεις περιλαμβάνονται:

- απλές εστιακές (simple partial), Στις απλές εστιακές η συνείδηση διατηρείται και έχουμε μονόπλευρη ημισφαιρική συμμετοχή.
- σύνθετες εστιακές (complex partial) Οι σύνθετες εστιακές χαρακτηρίζονται από επισκότηση ή απώλεια της συνείδησης και αμφοτερόπλευρη ημισφαιρική συμμετοχή, διαρκούν δύο έως πέντε λεπτά και τις επιπτώσεις στην συμπεριφορά του ατόμου τις καθορίζει το τμήμα του εγκεφάλου που προσβάλλεται.[18]
- εστιακές που γενικεύονται δευτερογενώς (secondary generalized) που είναι γενικευμένες τονικοκλονικές κρίσεις που εξελίσσονται ευθέως είτε από μια απλή εστιακή είτε από μια σύνθετη εστιακή κρίση. [3]

2.5 Ανίχνευση και πρόβλεψη επιληπτικών κρίσεων

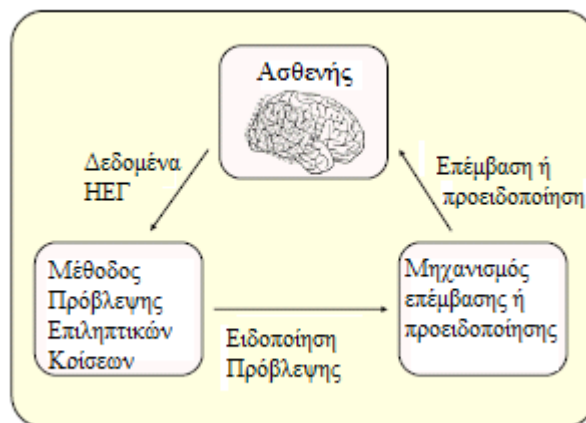
Οι πρώτες προσπάθειες για αυτόματη ανίχνευση επιληπτικών κρίσεων ήταν στον τομέα της αυτόματης καταγραφής τους για κλινική χρήση. Η λογική ήταν να καταγράφονται οι επιληπτικές κρίσεις αυτόματα, ώστε οι ειδικοί γιατροί να μην χρειάζεται να εξετάζουν δεκάδες ώρες ΗΕΓ και να μην καταγράφονται δεκάδες ώρες ΗΕΓ ,αλλά μόνο επιλεγμένα από τον υπολογιστή κομμάτια [19]. Σε μια τέτοια καταγραφή, προτεραιότητα αποτελούσε το να μην παραλείπονται κρίσεις (υψηλή ευαισθησία δηλαδή), ενώ η αντίθετα η ύπαρξη ψευδών ανιχνεύσεων δεν αποτελούσε ιδιαίτερο πρόβλημα, καθώς η μόνη τους παρενέργεια ήταν η καταγραφή περισσότερων ωρών ΗΕΓ. Παρόλο που σήμερα έχουμε λύσει το πρόβλημα του αποθηκευτικού χώρου μεγάλου μήκους ΗΕΓ καταγραφών με τη βοήθεια της σύγχρονης τεχνολογίας (HDD, DVD), η ανάγκη για αυτοματοποιημένη ανίχνευση των κρίσεων παραμένει, καθώς η χειρουργική αντιμετώπιση της επιληψίας (για την οποία απαιτούνται πολλές ώρες video-EEG καταγραφών) γίνεται όλο και πιο διαδεδομένη[3].

Πέρα όμως από την συμβολή στον προεγχειρητικό έλεγχο, η έγκαιρη ανίχνευση κρίσεων (early detection) ή η πιθανή πρόβλεψή τους, αν τελικά επιτευχθεί, μπορεί να βοηθήσει σημαντικά και στην βελτίωση της ζωής των επιληπτικών. Μια από της πλέον δυσάρεστες παραμέτρους της νόσου είναι η αβεβαιότητα για τη στιγμή έλευσης της κρίσης, πράγμα που πέρα από τον κίνδυνο τραυματισμού για τον ασθενή, έχει σαν αποτέλεσμα ο ασθενής να ζει με συνεχές άγχος και να επηρεάζονται σε σημαντικό βαθμό όλες οι δραστηριότητες της καθημερινής του ζωής. Ένα πιθανό σύστημα έγκαιρης ειδοποίησης που θα ήταν για παράδειγμα εμφυτευμένο στον εγκέφαλο του ασθενούς και θα τον προειδοποιούσε έστω και

λίγα δευτερόλεπτα πριν για την επερχόμενη κρίση θα βελτίωνε σημαντικά την ποιότητα της ζωής του.

Πέρα από την απλή προειδοποίηση του ασθενούς, ένα άλλο σημαντικό κίνητρο διεξαγωγής έρευνας για αυτόματη πρόβλεψη επιληπτικών κρίσεων είναι η πιθανότητα ανάπτυξης θεραπευτικών εμφυτεύσιμων συσκευών κλειστού-βρόχου (Σχήμα 2.7). Οι συσκευές αυτές θα μπορούσαν αμέσως μετά την πρόβλεψη της κρίσης να παρέχουν κάποια μορφή τοπικού ερεθίσματος ώστε να αναστείλουν την κρίση ή να μειώσουν τη διάρκεια και τις συνέπειές της. Μερικά παραδείγματα τέτοιων ερεθισμάτων που έχουν προταθεί είναι ηλεκτρικά ερεθίσματα, τοπική έγχυση φαρμάκου και ερεθισμός πνευμονογαστρικού νεύρου[3].

Παραπάνω μιλήσαμε τόσο για έγκαιρη ανίχνευση (early detection) των κρίσεων όσο και για πρόβλεψή τους. Η βασική διαφορά αυτών των δύο είναι ότι όταν αν μιλάμε για πρόβλεψή αναφερόμαστε συνήθως στην ανίχνευση ενός προ-επιληπτικού (pre-ictal) σταδίου που προηγείται της επιληψίας. Η έρευνα που έχει γίνει στον τομέα της προβλεψιμότητας των επιληπτικών κρίσεων ξεκίνησε από τη δεκαετία του 1970 με τη δουλειά των Viglione και Wlash [20] σε ασθενείς με επιληπτικές κρίσεις αφαίρεσης. Από τότε έχουν γίνει πολλές μελέτες, που στηρίχθηκαν στην ανάλυση του ΗΕΓ στο πεδίο του χρόνου, της συχνότητας, της μη γραμμικής δυναμικής και της θεωρίας του χάους καθώς και σε εργαλεία της τεχνητής νοημοσύνης όπως είναι τα νευρωνικά δίκτυα [21][22][20][3]. Ακόμα δεν έχει προκύψει κάποιο στέρεο και κλινικά εφαρμόσιμο συμπέρασμα για το αν οι επιληπτικές κρίσεις είναι πράγματι προβλέψιμες[20] και πολλές μελέτες που με αρκετά αισιόδοξα αποτελέσματα δεν κατάφεραν να τα αναπαράγουν για να καταλήξουν σε κλινική εφαρμογή. Υπάρχουν ωστόσο σημαντικές ενδείξεις ότι κάτι τέτοιο μπορεί να συμβεί στο μέλλον[20], και ειδικά για την επιληψία κροταφικού λοβού[22].



Σχήμα 2.7: Λειτουργία συσκευής κλειστού βρόχου*

* Εικόνα τροποποιημένη από <https://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project>

2.6 Τα δεδομένα

2.6.1. Η βάση δεδομένων του Freiburg

Για τις προσομοιώσεις που έγιναν και την εφαρμογή του αλγορίθμου ανίχνευσης που αναπτύχθηκε, έγινε η χρήση της βάσης δεδομένων του Πανεπιστημίου του Freiburg, που μπορεί να βρεθεί στο <http://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project/eeg-database> και είναι διαθέσιμη δωρεάν σε ερευνητικές ομάδες μετά από σχετική αίτηση. Περιέχει δεδομένα από ΗΕΓ βάρθους 21 ασθενών που πάσχουν από μη φαρμακευτικά θεραπεύσιμη εστιακή επιληψία. Τα δεδομένα έχουν καταγραφεί κατά τη διαδικασία του προ-εγχειρητικού ελέγχου στο Κέντρο για την Επιληψία του Πανεπιστημίου του Freiburg στη Γερμανία με τη χρήση διαφορετικών συνδυασμών ηλεκτροδίων πλέγματος, ταινίας και βελονοειδών ηλεκτροδίων. Συνολικά στη βάση δεδομένων υπάρχουν καταγραφές για 11 ασθενείς με επιληψία έσω κροταφικού λοβού , 8 με επιληψία με εστία τον ιπποκαμπο και 2 με εστίες και στα δύο. Τα ΗΕΓ δεδομένα καταγράφηκαν με τη χρήση ενός Neurofile NT συστήματος για την καταγραφή ψηφιακού βίντεο-ΗΕΓ με 128 κανάλια και συχνότητα δειγματοληψίας 256Hz. Για την ψηφιακή μετατροπή των καταγραφών χρησιμοποιήθηκε ένας 16-bit μετατροπέας αναλογικού σήματος σε ψηφιακό. Τα αρχικά δεδομένα ήταν εντελώς αφιλτράριστα.

Για κάθε ασθενή υπάρχουν καταγραφές από 6 σημεία, 3 εστιακά και 3 μη εστιακά. Τα δεδομένα είναι χωρισμένα σε 2 σύνολα, τα επιληπτικά δεδομένα (ictal) , όπου πρόκειται για δεδομένα που περιέχουν επιληπτικές κρίσεις, αλλά και τουλάχιστον 50 λεπτά προ-επιληπτικής δραστηριότητας , και τα μεσοκρυσικά (interictal) δεδομένα, στα οποία δεν συμβαίνει καμία επιληπτική κρίση. Για όλους τους ασθενείς υπήρχαν διαθέσιμες τουλάχιστον 24 ώρες μεσοκρυσικής καταγραφής , είτε συνεχόμενες, είτε σε με 2-3 ξεχωριστές περιόδους καταγραφής συνολικού χρόνου 24 τουλάχιστον ωρών.

Στο κεφάλαιο 5 της παρούσας διπλωματικής υπάρχει αναλυτική περιγραφή σχετικά με τα ηλεκτρόδια που χρησιμοποιήθηκαν και την τοποθέτηση τους στον κάθε ασθενή, καθώς και πληροφορίες για το είδος και τα χαρακτηριστικά της επιληψίας που εμφανίζει ο κάθε ένας από τους 6 ασθενείς τα δεδομένα των οποίων χρησιμοποιήθηκαν στην εργασία.

2.6.2. Προεπεξεργασία δεδομένων

Αρχικά προεπεξεργαστήκαμε τα δεδομένα με τη χρήση 3 φίλτρων.

Χρησιμοποιήθηκε ένα φίλτρο αποκοπής (notch) για να κοπεί το παράσιτο των 50Hz που προέρχεται από τη γραμμή τροφοδοσίας του ηλεκτρικού ρεύματος. Είναι το μοναδικό τεχνητό παράσιτο το οποίο θεωρήσαμε ότι παρατηρείται στα δεδομένα μας. Κόψαμε λοιπόν τη συνιστώσα με συχνότητα 50Hz με τη χρήση του φίλτρου αποκοπής με την εντολή `iirnotch` του Matlab. Το φιλτράρισμα έγινε για κάθε ένα από τα 6 κανάλια ξεχωριστά.

Στη συνέχεια έγινε re-referencing των καναλιών , αφαιρώντας από το κάθε ένα για κάθε δείγμα (sample) τη μέση τιμή όλων των καναλιών για τη χρονική στιγμή εκείνη. Με αυτό

τον τρόπο προσπαθούμε να εξαλείψουμε από το κάθε κανάλι τις επιδράσεις από τα υπόλοιπα, να κρατήσουμε δηλαδή τις καταγραφόμενες τιμές δυναμικού που αντιστοιχούν μόνο στο συγκεκριμένο εστιακό σημείο και να απορρίψουμε όποιες επιρροές πιθανόν προέρχονται από τα υπόλοιπα σημεία καταγραφής.

Τέλος, με τη βοήθεια ενός ζωνοπερατού φίλτρου κρατήσαμε μόνο το σήμα με συχνότητες μεταξύ 0,5 και 120 Hz. Αυτό έγινε με τη χρήση ενός φίλτρου butterworth με μηδενική φάση (zero phase shifting) , ώστε να μην υπάρξει μεταβολή στη φάση του σήματος κατά το φιλτράρισμα.

2.7 Βιβλιογραφία

- [1] Δ. Κουτσούρης et Al., *Εισαγωγή στην Βιοϊατρική Τεχνολογία και Ανάλυση Ιατρικών Σημάτων*. Τζιολας, 2003.
- [2] D. Fitzpatrick, D.Purves, G. Agustine, *Neuroscience*. 2008.
- [3] Γεωργία - Σταυρούλα Εμμ. Πολυχρονάκη, “Ανάπτυξη Μεθοδολογιών βασισμένων σε μεγέθη μη-γραμμικής δυναμικής για την ανάλυση δεδομένων επιληψιας,” Διδακτορική Διατριβή, 2011.
- [4] P. L. Nunez and R. Srinivasan, *Electric Fields of the Brain: The Neurophysics of EEG*. 2006.
- [5] Γεώργιος Α. Τσιρογιάννης, “Ανάπτυξη υπολογιστικών μοντέλων βιολογικών νευρωνικών δικτύων για τη μελέτη του ρόλου της ισχύος διασύνδεσης των νευρώνων,” Διδακτορική Διατριβή, ΕΜΠ, 2009.
- [6] Δημήτρης Κ. Παπαδημητρίου, “Μη γραμμική επεξεργασία ηλεκτροεγκεφαλογραφηματος επιφανειας για την προβλεψη επιληπτικων κρισεων,” Διπλωματική Εργασία, 2008.
- [7] J. P. Lachaux, D. Rudrauf, and P. Kahane, “Intracranial EEG and human brain mapping.,” *Journal of physiology, Paris*, vol. 97, no. 4–6, pp. 613–28, 2004.
- [8] S. Noachtar and J. Rémi, “The role of EEG in epilepsy: a critical review.,” *Epilepsy & behavior : E&B*, vol. 15, no. 1, pp. 22–33, May 2009.
- [9] Γιώργος Α. Γιαννακάκης, “Ανάλυση ηλεκτροεγκεφαλογραφικού σήματος με εφαρμογές στην επιληψία και τις μαθησιακές δυσκολίες,” Μεταπτυχιακή Διπλωματική Εργασία, 2005.
- [10] A. B. Gardner, H. Hall, and A. M. Krieger, “One-Class Novelty Detection for Seizure Analysis from Intracranial EEG,” *Journal of Machine Learning Research*, vol. 7, pp. 1025 – 1044, 2006.
- [11] T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, “Automatic seizure detection based on time-frequency analysis and artificial neural networks.,” *Computational intelligence and neuroscience*, vol. 2007, p. 80510, Jan. 2007.
- [12] H. Choi, R. L. Sell, L. Lenert, R. R. Goodman, F. G. Gilliam, and J. B. Wong,

- “Epilepsy Surgery for Pharmacoresistant Temporal Lobe Epilepsy,” vol. 300, no. 21, pp. 2497–2505, 2008.
- [13] J.Jr. Engel, “Introduction to temporal lobe epilepsy,” vol. 26, pp. 41–50, 1996.
- [14] P. Ryvlin and P. K. Alexandra Montavont, “<http://www.jle.com/e-docs/00/04/11/49/article.md>.” .
- [15] R. S. Fisher, E. Beghi, A. Berg, A. Carpio, L. Forsgren, D. C. Hesdorffer, W. A. Hauser, K. Malmgren, S. Shinnar, N. Temkin, D. Thurman, and T. Tomson, “Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE).,” *Epilepsia*, vol. 46, no. 10, pp. 1698–9; author reply 1701–2, Oct. 2005.
- [16] ILAE, “Proposal for Revised Clinical and Electroencephalographic Classification of Epileptic Seizures,” pp. 489–501, 1981.
- [17] “(<http://www.epilepsysociety.org.uk/AboutEpilepsy/Whatisepilepsy/Back2Basicsarticles/Seizuresclassification>).” .
- [18] Χ. Π . Χαντζής, “Εφαρμογή της μεθόδου Ανάλυσης Ανεξάρτητων Συνιστωσών (ICA) σε Ηλεκτροεγκεφαλογράφημα (ΗΕΓ) Επιληψίας,” Διπλωματική Εργασία, 2006.
- [19] J. Gotman, “Automatic seizure detection: improvements and evaluation,” vol. 4, pp. 317–324, 1989.
- [20] F. Mormann, R. G. Andrzejak, C. E. Elger, and K. Lehnertz, “Seizure prediction: the long and winding road.,” *Brain : a journal of neurology*, vol. 130, no. Pt 2, pp. 314–33, Feb. 2007.
- [21] K. K. Jerger, T. I. Netoff, J. T. Francis, T. Sauer, L. Pecora, S. L. Weinstein, and S. J. Schiff, “Early seizure detection.,” *Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society*, vol. 18, no. 3, pp. 259–68, May 2001.
- [22] B. Litt and J. Echaz, “Prediction of epileptic seizures,” *The Lancet Neurology*, vol. 1, no. 1, pp. 22–30, May 2002.

Κεφάλαιο 3: Τεχνητά Νευρωνικά Δίκτυα

3.1 Εισαγωγή - Ιστορική Αναδρομή

Τα τεχνητά νευρωνικά δίκτυα (ANN- artificial neural networks) είναι εργαλεία υπολογιστικής νοημοσύνης. Πρόκειται ουσιαστικά για μαθηματικά μοντέλα βασισμένα στη λειτουργία των βιολογικών νευρώνων. Αναπτύχθηκαν σε μια προσπάθεια να απομακρυνθούμε από τον κλασική δομή των υπολογιστών και τη χρήση ακολουθιακών αλγορίθμων για τη λύση προβλημάτων. Τα ΤΝΔ προτείνουν μια διαφορετική προσέγγιση ως προς τον τρόπο υπολογισμού (computation) ο οποίος βασίζεται στη λειτουργία του εγκεφάλου. Πρόκειται για μια ιδιαίτερη προσέγγιση στη δημιουργία συστημάτων με νοημοσύνη, καθώς αποφεύγουν να αναπαραστήσουν ρητά τη γνώση και να υιοθετήσουν ειδικά σχεδιασμένους αλγορίθμους αναζήτησης[1].

Παρατηρώντας την εκπληκτική ικανότητα του εγκεφάλου να λύνει σύνθετα και πολύπλοκα προβλήματα, καθώς και το γεγονός ότι ο ανθρώπινος εγκέφαλος είναι ένα τρομερά “παράλληλο” υπολογιστικό σύστημα (εξαιρετικά πολύπλοκος, μη γραμμικός παράλληλος υπολογιστής [2]), προσπαθήσαμε με τα ΤΝΔ να μιμηθούμε αυτά τα χαρακτηριστικά του. Ένα άλλο πολύ σημαντικό χαρακτηριστικό του εγκεφάλου που προσπαθήσαμε να μιμηθούμε είναι η πλαστικότητα του, η ικανότητα δηλαδή του νευρικού συστήματος να εξελίσσεται και να προσαρμόζεται ανάλογα με το περιβάλλον του. Το παραπάνω είναι συνυφασμένο με την ικανότητα της μάθησης.

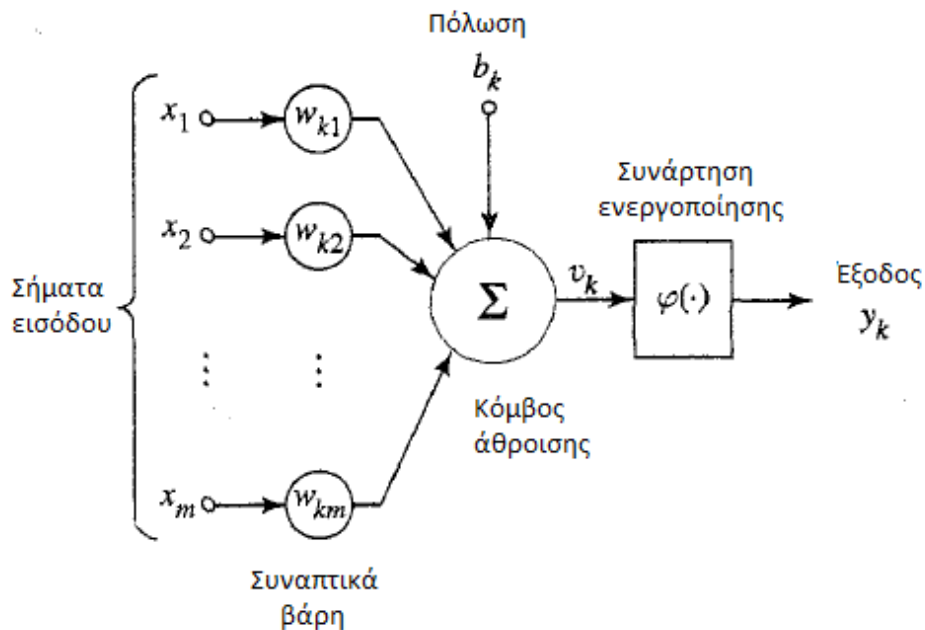
Το πρώτο μοντέλο τεχνητού νευρώνα προτάθηκε από τους McCulloch και Pitts το 1943 σε μια προσπάθεια μοντελοποίησης της λειτουργίας των εγκεφαλικών νευρώνων.[3] Στη συνέχεια εμφανίστηκε το 1958 το perceptron του Rosenblatt που βασιζόταν στο μοντέλο McCulloch-Pitts και ήταν το πρώτο μοντέλο νευρώνα που μπορούσε να περιγραφεί αλγοριθμικά καθώς και το πρώτο μοντέλο μάθησης με επίβλεψη[4]. Σκοπός του ήταν η ταξινόμηση γραμμικά διαχωρίσιμων προτύπων. Μια επόμενη προσέγγιση τεχνητού νευρώνα έρχεται το 1960 από τον τομέα της αναγνώρισης συστημάτων, όταν οι Widrow και Hoff πρότειναν τη χρήση ενός μεμονωμένου γραμμικού νευρώνα για τη υλοποίηση ενός προσαρμοστικού φίλτρου και ανέπτυξαν για την εκπαίδευσή του τον αλγόριθμο ελαχίστων μέσων τετραγώνων (LMS) [5]. Στα χρόνια που ακολούθησαν προτάθηκαν πολλές διαφορετικές προσεγγίσεις πάνω στην αρχιτεκτονική και τους αλγορίθμους εκπαίδευσης των νευρωνικών δικτύων. Τα δίκτυα TLFN που χρησιμοποιούνται στην παρούσα διπλωματική πρωτοχρησιμοποιήθηκαν το 1989 [6] για αναγνώριση φωνημάτων.

3.2 Μοντέλο τεχνητού νευρώνα

Ένα βιολογικό νευρωνικό δίκτυο, όπως περιγράψαμε και στο προηγούμενο κεφάλαιο, αποτελείται από απλές μονάδες επεξεργασίας (νευρώνες), οι οποίες συνδέονται μεταξύ τους

με περίπλοκο τρόπο και λειτουργούν μαζικά παράλληλα. Στα τεχνητά νευρωνικά δίκτυα προσομοιώνουμε αυτό τον τρόπο λειτουργίας χρησιμοποιώντας σαν βασική μονάδα επεξεργασίας πληροφορίας ένα μη γραμμικό μοντέλο νευρώνα (Σχήμα 3.1).

ΜΗ ΓΡΑΜΜΙΚΟ ΜΟΝΤΕΛΟ ΝΕΥΡΩΝΑ



Σχήμα 3.1: Μη γραμμικό μοντέλο νευρώνα [2]

Το μοντέλο αυτό αποτελείται από τρία βασικά στοιχεία:

1. Ένα σύνολο συνάψεων ή διασυνδέσεων (που αντιστοιχούν στις συνάψεις του βιολογικού νευρώνα). Μέσω των διασυνδέσεων αυτών τα σήματα εισόδου x_m πολλαπλασιάζονται με ένα συναπτικό βάρος w_{km} πριν καταλήξουν στον κόμβο άθροισης.
2. Έναν αθροιστή, ο οποίος αθροίζει τα σταθμισμένα σήματα εισόδου, καθώς και την πόλωση του νευρώνα. Παράγεται έτσι ένα τοπικό πεδίο u_k ίσο με

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$


3. Μια συνάρτηση ενεργοποίησης (activation function), που συμβολίζεται ως $\varphi(\cdot)$ και είναι ένα είδος φίλτρου που διαμορφώνει την τελική τιμή του σήματος εξόδου y_k . Η συνάρτηση αυτή είναι τις περισσότερες φορές μη-γραμμική.

Η πιο απλή συνάρτηση που μπορεί να χρησιμοποιηθεί ως συνάρτηση ενεργοποίησης είναι η βηματική συνάρτηση (Heavyside), η οποία μπορεί να πάρει μόνο τις τιμές 0 και 1. Εναλλακτικά μπορεί να χρησιμοποιηθεί και η συνάρτηση προσήμου, που παίρνει τις τιμές -1,0,1. Με τη χρήση δηλαδή των παραπάνω συναρτήσεων ο νευρώνας παίρνει μια τιμή σαν είσοδο και βγάζει σαν έξοδο μια εκ των δύο συγκεκριμένων τιμών. Όπως είναι λοιπόν αναμενόμενο, και οι δύο παραπάνω συναρτήσεις ενεργοποίησης χρησιμοποιούνται για δίκτυα που κάνουν ταξινόμηση προτύπων.

Πολλές φορές ωστόσο οι παραπάνω συναρτήσεις δεν βολεύουν, κυρίως γιατί όταν συνδέουμε πολλούς νευρώνες μεταξύ τους για να φτιάξουν ένα πολυεπίπεδο νευρωνικό δίκτυο είναι αναγκαίο οι συναρτήσεις ενεργοποίησης των επιμέρους νευρώνων να είναι διαφορίσιμες. Αυτό όπως θα εξηγήσουμε παρακάτω είναι αναγκαίο για την εκπαίδευση των δικτύων. Την απαίτηση αυτή ικανοποιεί η λογιστική συνάρτηση, που ορίζεται από τον τύπο

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (3.2)$$

όπου το a ονομάζεται παράμετρος κλίσης. Η συνάρτηση αυτή είναι μια σιγμοειδής συνάρτηση. Η γραφική παράσταση της λογιστικής συνάρτησης φαίνεται στο παρακάτω σχήμα:



Σχήμα 3.2: Λογιστική Συνάρτηση

Όπως αναφέραμε και παραπάνω, είναι αρκετές φορές χρήσιμο οι συναρτήσεις μας να έχουν πεδίο τιμών -1 έως +1, αντί για 0 έως +1 που έχει η λογιστική. Στην περίπτωση των σιγμοειδών, μια τέτοια συνάρτηση είναι η συνάρτηση υπερβολικής εφαπτομένης, με εξίσωση:

$$\varphi(v) = \tanh(v) \quad (3.3)$$

Τέλος, αν θέλουμε ένα νευρώνα που να χρησιμοποιηθεί για να προσεγγίζει συναρτήσεις, χρειάζεται μια συνάρτηση ενεργοποίησης που το πεδίο τιμών της να μην περιορίζεται σε μερικές συγκεκριμένες τιμές ή σε ένα διάστημα τιμών αλλά να μπορεί να παίρνει οποιαδήποτε τιμή. Μια τέτοια συνάρτηση είναι η απλή γραμμική συνάρτηση.

Η τελική έξοδος του νευρώνα υπολογίζεται όπως φαίνεται και από τα παραπάνω με βάση τον τύπο:

$$y_k = \varphi(u_k + b_k) \quad (3.4)$$

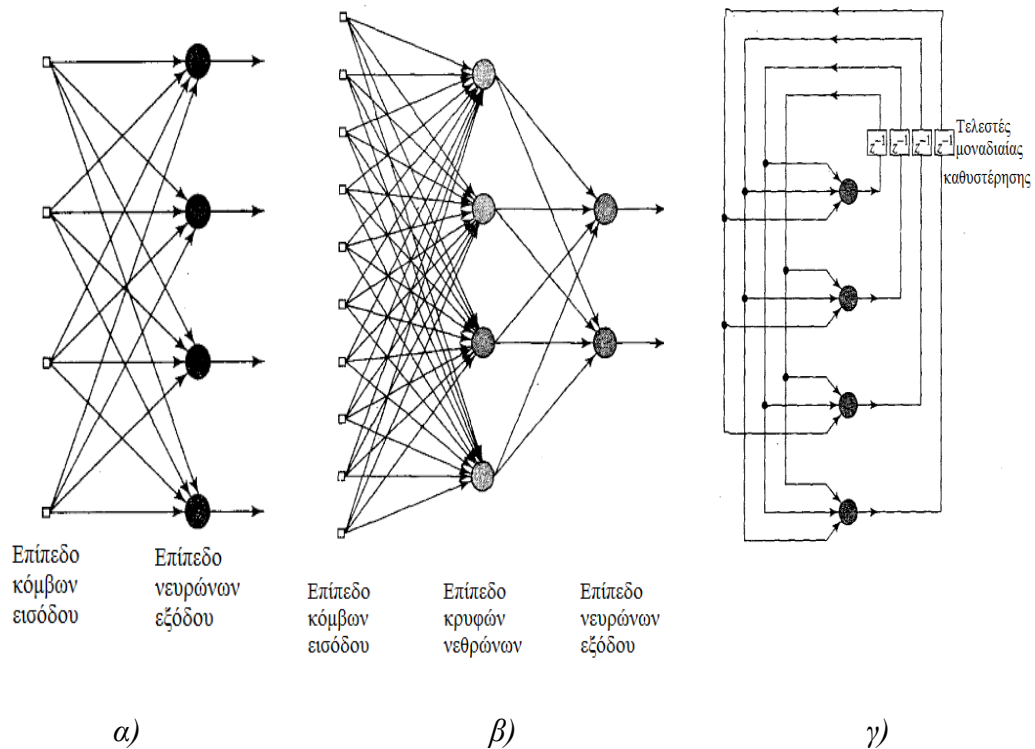
Οι ομοιότητες του παραπάνω μαθηματικού μοντέλου με ένα βιολογικό νευρώνα είναι εμφανείς. Έχουμε είσοδο πληροφορίας από τους προηγούμενους νευρώνες, και με βάση την τιμή αυτών των εισόδων και το πώς έχει μάθει να αντιδρά σε αυτές ο νευρώνας παίρνουμε μια έξοδο, η οποία μπορεί να κατευθύνεται σε άλλους νευρώνες στο πλαίσιο ενός δικτύου νευρώνων. Συγκεκριμένα για μια μη γραμμική συνάρτηση ενεργοποίησης έχουμε και την αντιστοιχία με το κατώφλι των βιολογικών νευρώνων που σχετίζεται με το δυναμικό ενεργοποίησης.

3.3 Αρχιτεκτονικές Δικτύων

Πολλοί τέτοιοι νευρώνες σαν αυτόν που περιγράφηκε παραπάνω συνδέονται μεταξύ τους βάση συγκεκριμένων αρχιτεκτονικών για τη δημιουργία ενός τεχνητού νευρωνικού δικτύου (ΤΝΔ). Το διάνυσμα του σήματος εισόδου τροφοδοτείται σε έναν ή περισσότερους νευρώνες και στη συνέχεια η έξοδος των νευρώνων αυτών μπορεί να λειτουργήσει ως είσοδος για άλλους νευρώνες και ούτω κάθε εξής μέχρι να φτάσουμε στην τελική έξοδο του δικτύου μας. Οι αρχιτεκτονικές με περισσότερους από ένα νευρώνες μπορούν να κατηγοριοποιηθούν σε τρεις κατηγορίες με βάση τον αριθμό των κρυφών επιπέδων τους και την παρουσία ή μη ανάδρασης [2].

- 1) **Ενός επιπέδου Δίκτυα πρόσθιας τροφοδότησης** (Σχήμα 3.3α). Τα λέμε ενός επιπέδου καθώς το επίπεδο των εισόδων δεν προσμετρείται επειδή δεν εκτελείται σε αυτό κανένας υπολογισμός. Επίσης δεν υπάρχουν συνδέσεις από το επίπεδο εξόδου στο επίπεδο εισόδου (ανάδραση) ή συνδέσεις μεταξύ των νευρώνων του επιπέδου.
- 2) **Πολυεπίπεδα δίκτυα πρόσθιας τροφοδότησης** (Multilayer perceptron – Σχήμα 3.3β). Σε αυτή την αρχιτεκτονική έχουμε παραπάνω από ένα επίπεδα, ενώ συνδέσεις από επόμενο προς προηγούμενο στη σειρά επίπεδο (δηλαδή συνδέσεις ανάδρασης) δεν είναι επιτρεπτές, και για το λόγο αυτό ονομάζονται δίκτυα πρόσθιας τροφοδότησης (Feedforward Networks). Ακόμα, είναι επιτρεπτές συνδέσεις μόνο σε γειτονικά επίπεδα, δηλαδή από το k επίπεδο μπορούμε να πάμε μόνο στο $k+1$ κι όχι στο $k+2$ ή στα επόμενα.
- 3) **Αναδρομικά δίκτυα** (Σχήμα 3.3γ). Έτσι ονομάζονται τα δίκτυα που έχουν τουλάχιστον ένα βρόχο ανάδρασης. Ανάδραση (feedback) θεωρούμε ότι υπάρχει σε ένα δυναμικό σύστημα όταν η έξοδος ενός στοιχείου του συστήματος επηρεάζει εν μέρει την είσοδο σε αυτό το συγκεκριμένο στοιχείο, προκαλώντας έτσι την εμφάνιση μιας ή περισσότερων κλειστών διαδρομών για τη μετάδοση του σήματος στο σύστημα.[2]

Στο παρακάτω σχήμα φαίνονται τα τρία είδη των αρχιτεκτονικών που περιγράφονται παραπάνω.



Σχήμα 3.3: α) Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου, β) Πολυεπίπεδο Δίκτυο Πρόσθιας Τροφοδότησης, γ) Αναδρομικό Δίκτυο

3.4 Μάθηση και Εκπαίδευση Νευρωνικών δικτύων

Ένα από τα πιο ενδιαφέροντα πεδία της τεχνητής νοημοσύνης είναι αυτό της μηχανικής μάθησης. Ίσως το πιο βασικό χαρακτηριστικό του ανθρώπινου εγκεφάλου είναι η ικανότητά του να μαθαίνει και με βάση νέα δεδομένα που του παρουσιάζονται να αλλάζει τον τρόπο που αντιδρά. Αντίθετα, τα κλασικά αλγοριθμικά μοντέλα στην πληροφορική, δρουν με βάση κανόνες που έχουν προκαθοριστεί κατά την δημιουργία του προγράμματος και δεν μπορούν να ενσωματώσουν άλλη γνώση πέρα από τις γνώσεις που έχει ο προγραμματιστής κατά την ανάπτυξή τους. Είναι επόμενο ότι εργαλεία όπως τα νευρωνικά δίκτυα που εμφανίζουν ικανότητα μηχανικής μάθησης να παρουσιάζουν ιδιαίτερο ενδιαφέρον και να μας ιδιαίτερα χρήσιμα σε προβλήματα που δεν έχουμε εξ αρχής επαρκή γνώση ώστε να φτιάξουμε ένα αλγόριθμο που να τα αντιμετωπίζει.

Αρχικά, όπως και στον κλασικό προγραμματισμό, ένα κομμάτι πρότερης πληροφορίας ενσωματώνεται στο νευρωνικό δίκτυο κατά το σχεδιασμό του μέσω συγκεκριμένων επιλογών που έχουν σχέση με την αρχιτεκτονική και την τοπολογία του δικτύου. Έτσι, με βάση τις γνώσεις μας για την εργασία την οποία θα κληθεί να διεκπεραιώσει το δίκτυο,

επιλέγουμε για παράδειγμα το μέγεθος του δικτύου που θα χρησιμοποιήσουμε ή μπορούμε να επιλέξουμε να χρησιμοποιήσουμε ένα μερικώς συνδεδεμένο δίκτυο αντί για ένα πλήρως συνδεδεμένο. Πέρα όμως από αυτή την πρότερη γνώση που ενσωματώνεται στο δίκτυο κατά την σχεδίαση του, ένα νευρωνικό δίκτυο έχει την ικανότητα να μαθαίνει με βάση παρατηρήσεις επί του “περιβάλλοντος” (μετρήσεις). Για να το κάνει αυτό, πρέπει αυτές οι μετρήσεις να του δοθούν σε μια μορφή (αναπαράσταση γνώσης) που να μπορεί να τις αξιοποιήσει. Στη συνέχεια με τη χρήση ενός αλγορίθμου εκπαίδευσης το νευρωνικό δίκτυο “εξάγει” γνώση από τα δεδομένα. Σε ένα perceptron η γνώση που αποκτά το δίκτυο από τον έξω κόσμο κωδικοποιείται και αποθηκεύεται στα συναπτικά βάρη του ΤΝΔ.

Συγκεκριμένα, στην επιβλεπόμενη μάθηση (που χρησιμοποιείται και για τα νευρωνικά δίκτυα της παρούσας εργασίας) θεωρούμε ότι έχουμε έναν εκπαιδευτή που έχει γνώση του περιβάλλοντος, ενώ το νευρωνικό δεν έχει. Παρουσιάζουμε στο νευρωνικό κάποια παραδείγματα εισόδου-εξόδου, δεδομένα δηλαδή για τα οποία ξέρουμε την επιθυμητή έξοδο. Στη συνέχεια υπολογίζουμε το σφάλμα, τη διαφορά δηλαδή της επιθυμητής απόκρισης του δικτύου από την πραγματική του απόκριση. Στη συνέχεια και με βάση το σφάλμα ή κάποιο μέτρο απόδοσης που βασίζεται στο σφάλμα, όπως το μέσο τετραγωνικό σφάλμα ή το άθροισμα των τετραγώνων των σφαλμάτων, προσαρμόζουμε τις παραμέτρους του δικτύου μας. Εκτελώντας τη διαδικασία αυτή επαναληπτικά μπορούμε να φτάσουμε το σύστημα μας σε μια κατάσταση τέτοια ώστε για κάθε είσοδο από το σύνολο των παραδειγμάτων εισόδου-εξόδου μας να έχουμε την επιθυμητή έξοδο, με μια στατιστική απόκλιση. Η τιμή της απόκλισης αυτής μπορεί να χρησιμοποιηθεί και ως κριτήριο τερματισμού του επαναληπτικού αλγορίθμου της μάθησης. Έτσι, με αυτή τη διαδικασία μπορούμε να πούμε ότι το νευρωνικό δίκτυο αποκτά τη γνώση του εκπαιδευτή, τη γνώση δηλαδή που περιέχεται στο σύνολο εκπαίδευσης (training set). Πέρα από την επιβλεπόμενη μάθηση, άλλα είδη νευρωνικών δικτύων, όπως είναι οι χάρτες αυτο-οργάνωσης εκπαιδεύονται με μη-επιβλεπόμενη μάθηση, χωρίς δηλαδή εκπαιδευτή.

Μια ικανότητα των νευρωνικών δικτύων βασική για τη μάθηση είναι η ικανότητα της γενίκευσης. Αυτό συνίσταται στο ότι μετά από την παραπάνω εκπαίδευση, τα νευρωνικά δίκτυα έχουν συνήθως την ικανότητα να γενικεύουν την γνώση που απέκτησαν από το δείγμα εκπαίδευσης. Μπορούν δηλαδή μετά το πέρας της εκπαίδευσης να χρησιμοποιήσουν την πληροφορία που “έμαθαν” κατά την εκπαίδευση και σε άλλα δεδομένα, που δεν ανήκουν στο δείγμα εκπαίδευσης, με επιτυχία. Ένα παράδειγμα είναι ότι αν έχουμε ένα νευρωνικό δίκτυο που κάνει ταξινόμηση προτύπων σε δύο κατηγορίες με βάση κάποιο χαρακτηριστικό, μετά από την εκπαίδευση με ένα σύνολο παραδειγμάτων που ξέρουμε σε ποιο πρότυπο ανήκει το καθένα, μπορούμε να το χρησιμοποιήσουμε για να διαχωρίσει πρότυπα σε αυτές τις δύο κατηγορίες που δεν του έχουν ξαναπαρουσιαστεί, δηλαδή που ουσιαστικά ούτε εμείς ξέρουμε που ανήκουν.

3.5 Αλγόριθμοι Εκπαίδευσης

3.5.1 Αλγόριθμοι Εκπαίδευσης Νευρώνα

Όπως αναφέραμε και παραπάνω, η επιβλεπόμενη εκπαίδευση των νευρωνικών δικτύων γίνεται παρουσιάζοντας στο δίκτυο ένα σύνολο εκπαίδευσης και αλλάζοντας επαναληπτικά

τις τιμές των βαρών του έτσι ώστε οι έξοδος του δικτύου να πλησιάσει όσο πιο πολύ γίνεται την επιθυμητή έξοδο.

Το βασικό σημείο στο οποίο διαφοροποιούνται οι αλγόριθμοι εκπαίδευσης είναι ο τρόπος με τον οποίο μεταβάλλουν τις τιμές των βαρών κατά την επίβλεψη. Στην περίπτωση που έχουμε να εκπαιδεύσουμε μόνο ένα νευρώνα, ο πιο απλός τρόπος είναι να μεταβάλλουμε τις τιμές των βαρών με βάση το σήμα σφάλματος $e(i) = d(i) - y(i)$, όπου $d(i)$ η επιθυμητή έξοδος του νευρώνα και $y(i)$ η πραγματική του έξοδος.

Στο perceptron του Rosenblatt για παράδειγμα, το διάνυσμα βαρών προσαρμόζεται με βάση το παραπάνω σφάλμα πολλαπλασιασμένο επί μια θετική σταθερά μικρότερη από μονάδα, που ονομάζεται παράμετρος ρυθμού μάθησης και συμβολίζεται η , και επί το διάνυσμα εισόδων του νευρώνα $x(n)$. Συγκεκριμένα η προσαρμογή του διανύσματος βαρών $w(n)$ γίνεται με βάση τον τύπο:

$$w(n+1) = w(n) + \eta [d(n) - y(n)] x(n) \quad (3.5)$$

Μεταγενέστεροι αλγόριθμοι όπως ο αλγόριθμος ελαχίστων μέσων τετραγώνων, ανάγουν το πρόβλημα της εκπαίδευσης σε ένα πρόβλημα βελτιστοποίησης κάνοντας χρήση μιας συνάρτησης κόστους $E(w)$ όπου w το διάνυσμα βαρών. Τέτοιοι αλγόριθμοι στοχεύουν στην ελαχιστοποίηση της στιγμιαίας τιμής της συνάρτησης αυτής, και καθώς η συνάρτηση αυτή είναι συνεχώς διαφορίσιμη αυτό σημαίνει ότι ψάχνουμε να βρούμε μια βέλτιστη λύση \hat{w} τέτοια ώστε $\nabla E(\hat{w}) = 0$. Ενδεικτικά αναφέρουμε ότι για τον αλγόριθμο ελαχίστων μέσων τετραγώνων η συνάρτηση κόστους είναι $E(\hat{w}) = \frac{1}{2} e^2(n)$, όπου $e(n)$ το σφάλμα.

3.5.2 Ο αλγόριθμος Backpropagation

Όταν έχουμε ένα δίκτυο που αποτελείται από πολλούς νευρώνες, και ειδικά όταν οι νευρώνες αυτοί είναι οργανωμένοι σε παραπάνω από ένα επίπεδα η εργασία της εκπαίδευσης του νευρωνικού δικτύου γίνεται πιο πολύπλοκη. Το βασικό ερώτημα σε αυτή την περίπτωση είναι το πώς προσαρμόζεται σε κάθε βήμα το διάνυσμα βαρών ενός νευρώνα που ανήκει σε ένα κρυφό επίπεδο του δικτύου. Την απάντηση σε αυτό το ερώτημα δίνει ο αλγόριθμος backpropagation ή BK, που χρησιμοποιείται για την εκπαίδευση πολυεπίπεδων perceptrons.

Ένα ιδιαίτερο χαρακτηριστικό του αλγορίθμου αυτού είναι ότι κάνει δύο περάσματα υπολογισμών, ένα προς τα εμπρός και ένα προς τα πίσω. Στο πέρασμα προς τα εμπρός ξεκινάμε από το πρώτο κρυφό επίπεδο (που τροφοδοτείται από το επίπεδο εισόδου) και υπολογίζουμε τις εξόδους του κάθε νευρώνα προχωρώντας προς τα μπροστά μέχρι να φτάσουμε στην έξοδο του δικτύου. Σε αυτό το πέρασμα τα βάρη διατηρούνται αναλλοίωτα. Στη συνέχεια κάνουμε ένα πέρασμα προς τα πίσω, ξεκινώντας από το επίπεδο εξόδου όπου υπολογίζουμε για κάθε νευρώνα το σφάλμα (επιθυμητή έξοδος-πραγματική έξοδος) και στη συνέχεια το σήμα σφάλματος διαδίδεται προς τα πίσω μέχρι το πρώτο κρυφό επίπεδο του δικτύου. Στο πέρασμα αυτό έχουμε δηλαδή οπισθοδιάδοση του σφάλματος.

Κατά την οπισθοδιάδοση του σφάλματος, τα βάρη του δικτύου προσαρμόζονται με βάση την τοπική κλίση $\delta(n)$ του νευρώνα. Η τοπική κλίση για τους νευρώνες εξόδου υπολογίζεται με βάση τον τύπο $\delta(n) = e(n)\phi'(v(n))$ όπου $e(n)$ το σφάλμα εξόδου του νευρώνα. Σε έναν κρυφό νευρώνα που δεν μπορούμε να αποδώσουμε υπαιτιότητα για το σφάλμα εξόδου απευθείας, του αποδίδουμε υπαιτιότητα με βάση τις συνδέσεις του με τους νευρώνες του επόμενου επιπέδου και τις τοπικές κλίσεις των νευρώνων αυτών. Έτσι η τοπική κλίση ενός κρυφού νευρώνα υπολογίζεται ως η παράγωγος της συνάρτησης ενεργοποίησης του νευρώνα επί το άθροισμα των τοπικών κλίσεων των νευρώνων του επόμενου επιπέδου με τους οποίους συνδέεται, επί τα αντίστοιχα συναπτικά βάρη[2]. Δηλαδή η τοπική κλίση ενός νευρώνα που βρίσκεται στο επίπεδο l υπολογίζεται ως εξής:

$$\delta(n) = \phi'(v(n)) \sum_k \delta_k^{l+1}(n) w_{kj}^{(l+1)}(n) \quad (3.6)$$

Η μεταβολή της τιμής των βαρών γίνεται μετά τον υπολογισμό της τοπικής κλίσης με βάση τον τύπο:

$$w(n+1) = w(n) + a[w(n-1)] + \eta \delta(n) y(n) \quad (3.7)$$

Ο αλγόριθμος αυτός επαναλαμβάνεται έως ότου φτάσουμε σε ένα μέγιστο αριθμό εποχών που έχει καθοριστεί εξαρχής για την εκπαίδευση του δικτύου ή όταν ο απόλυτος ρυθμός μεταβολής του τετραγωνικού σφάλματος ανά εποχή γίνει αρκετά μικρός. Ένα άλλο κριτήριο τερματισμού του αλγορίθμου BK που παράλληλα βελτιώνει την ικανότητα γενίκευσης του δικτύου μας είναι η μέθοδος πρώιμου τερματισμού της εκπαίδευσης. Σε αυτή τη μέθοδο χωρίζουμε το διαθέσιμο δείγμα εκπαίδευσης σε ένα υποσύνολο παραδειγμάτων για εκπαίδευση, ένα υποσύνολο επικύρωσης και ένα υποσύνολο ελέγχου. Παρουσιάζουμε στο δίκτυο τα δεδομένα εκπαίδευσης αλλά μετράμε την απόδοσή του με βάση το σύνολο επικύρωσης. Όταν η επίδοση του δικτύου στο σύνολο επικύρωσης σταματήσει να βελτιώνεται σταματάμε την εκπαίδευση. Για να αποφύγουμε την υπερπροσαρμογή (overfitting) στα δεδομένα του συνόλου επικύρωσης, χρησιμοποιούμε το σύνολο ελέγχου που είναι ξεχωριστό από τα άλλα δύο και χρησιμεύει ουσιαστικά για να εκτιμήσουμε την απόδοση γενίκευσης του ΤΝΔ.


Τα δίκτυα που χρησιμοποιούνται στην παρούσα εργασία εκπαιδεύτηκαν με τη χρήση του αλγορίθμου backpropagation με τη βελτιστοποίηση Levenberg-Marquadt. Πρόκειται για την πιο γρήγορη έκδοση του αλγορίθμου backpropagation που υπάρχει διαθέσιμη στο Neural Network Toolbox του Matlab[7]

3.6 Δυναμικά Οδηγούμενα και Αναδρομικά Δίκτυα

Πολλές φορές βρισκόμαστε αντιμέτωποι με προβλήματα τεχνητής νοημοσύνης που εμπεριέχουν σε μεγάλο βαθμό την έννοια του χρόνου. Για να μπορέσουμε να λύσουμε τέτοια προβλήματα με νευρωνικά δίκτυα είναι αναγκαίο να ενσωματώσουμε στα δίκτυα αυτά μια μορφή αναπαράστασης της χρονικής αυτής διάστασης των δεδομένων μας, να κάνουμε δηλαδή τα ΤΝΔ που χρησιμοποιούμε δυναμικά. Για να κάνουμε ένα δίκτυο

δυναμικό πρέπει να ενσωματώσουμε σε αυτό μνήμη ώστε να μπορέσουμε να επεξεργαστούμε την χρονική πληροφορία.

Μπορούμε να χωρίσουμε τα είδη των μνημών σε μακροπρόθεσμες (long-term) και βραχυπρόθεσμες (short-term). Στις μακροπρόθεσμες μνήμες αποθηκεύεται η πληροφορία που μαθαίνεται κατά την διαδικασία της εκπαίδευσης και σε ένα ΤΝΔ αυτό τον ρόλο παίζουν τα συναπτικά του βάρη. Παρόλαυτά αν έχουμε απέναντι μας ένα πρόβλημα με χρονική διάσταση πρέπει να ενσωματώσουμε στο νευρωνικό δίκτυο κάποιας μορφής βραχυπρόθεσμη μνήμη. Ο πιο απλός τρόπος για να το κάνουμε αυτό είναι με χρονικές καθυστερήσεις (time delays)[2], [8]. Συνήθως χρησιμοποιούμε ένα στατικό perceptron πολλών επιπέδων στο οποίο ενσωματώνεται μια γραμμή καθυστέρησης απαγωγών αποτελούμενη από p βαθμίδες (Σχήμα 3.9).



Σχήμα 3.4: Γραμμή καθυστέρησης απαγωγών αποτελούμενη από p βαθμίδες

Κάθε βαθμίδα εισάγει καθυστέρηση κατά 1 χρονική μονάδα, δηλαδή


$$G(z) = z^{-1} \quad (3.8)$$

Μια γραμμή καθυστερήσεων απαγωγών όπως η παραπάνω με $p+1$ βαθμίδες λέμε ότι είναι p τάξης. Τα βασικά χαρακτηριστικά μιας μνήμης είναι το βάθος(depth) της και η ανάλυσή της (resolution). Βάθος ονομάζουμε την πιο παλιά χρονική στιγμή για την οποία η μνήμη κρατάει πληροφορία, η παραπάνω δηλαδή γραμμή καθυστερήσεων έχει βάθος $D=p$. Ανάλυση ονομάζεται ο αριθμός των taps που κρατάει η μνήμη για κάθε μονάδα χρόνου, δηλαδή για την παραπάνω γραμμή $R=1$, αφού σε κάθε μονάδα χρόνου αντιστοιχεί μια μόνο καθυστέρηση.

Προσθέτοντας μια τέτοια γραμμή στην είσοδο του δικτύου μας έχουμε την παρούσα και παρελθοντική τιμή του σήματος εισόδου, $u_n, u_{n-1}, \dots, u_{n-p+1}$. Ένα τέτοιο δίκτυο ονομάζεται δίκτυο πρόσθιας τροφοδότησης με χρονικές καθυστερήσεις (time lagged feedforward network - TLFN). Ένα τέτοιο δίκτυο φαίνεται στο σχήμα 3.5. Στη γραμμή μνήμης μπορούμε να ανατροφοδοτήσουμε και τις εξόδους του νευρωνικού και να προκύψει ένα μη γραμμικό αυτοπαλινδρομικό μοντέλο με εξωγενείς εισόδους(NARX).

Για να εκπαιδύσουμε ένα TFLN δίκτυο χρησιμοποιούμε τον κλασικό αλγόριθμο ΒΚ που περιγράψαμε παραπάνω. Η έξοδος της γραμμής απαγωγών αποτελεί εδώ το διάνυσμα εισόδων του δικτύου. Αν ωστόσο θέλουμε να εκπαιδύσουμε ένα δίκτυο με ανάδραση, τότε

χρησιμοποιούμε τον αλγόριθμο οπισθοδιάδοσης στο χρόνο (BPTT) , που είναι μια επέκταση του κανονικού ΒΚ και υλοποιείται ουσιαστικά ξεδιπλώνοντας (unfolding) τη χρονική λειτουργία του δικτύου σε ένα πολυεπίπεδο δίκτυο πρόσθιας τροφοδότησης, η τοπολογία του οποίου αυξάνεται κατά ένα επίπεδο σε κάθε χρονικό βήμα.



Σχήμα 3.5: Σχεδιάγραμμα TLFN [2]

3.7 Βιβλιογραφία

- [1] Ι. Βλαχάβας, *Τεχνητή Νοημοσύνη*, 3rd ed. Γκιούρδας Εκδοτική, 2006.
- [2] S. Haykin, "Neural Networks: A Comprehensive Foundation," 1998.
- [3] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," vol. 5, pp. 115–133, 1943.
- [4] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain.," *Psychological review*, vol. 65, no. 6, pp. 386–408, Nov. 1958.
- [5] B. Widrow and M. E. Hoff, "Adaptive Switching Circuits." 1960.
- [6] A. Waibel, T. Hanazawa, G. Hinton, K. Shikano, and K. J. Lang, "Phoneme Recognition Using Time-Delay Neural Networks." 1989.
- [7] "<http://www.mathworks.com/help/nnet/ref/trainlm.html>."

- [8] M. C. Mozer, “Neural net architectures for temporal sequence processing,” pp. 243–264, 2007.

Κεφάλαιο 4 : Ανάπτυξη ΤΝΔ για πρόβλεψη ΗΕΓ τιμών

4.1 Εισαγωγή

Η δοκιμή της χρήσης νευρωνικών δικτύων πρόσθιας τροφοδότησης με χρονικές καθυστερήσεις στο ΗΕΓ είχε σε πρώτο στάδιο ως στόχο απλά την πρόβλεψη των μελλοντικών ΗΕΓ τιμών. Για να γίνει αυτό, το εγκεφαλικό σήμα που καταγράφεται από τον εγκεφαλογράφο αντιμετωπίστηκε ως μια χρονοσειρά και τροφοδοτήθηκε μετά από την προεπεξεργασία του στην είσοδο των δικτύων. Στην έξοδό τους τα δίκτυα, μετά την εκπαίδευσή τους, θα έβγαζαν τις μελλοντικές τιμές του σήματος όπως αυτά τις προβλέπουν βασιζόμενα μόνο στις προηγούμενες τιμές.

Πέρα από τη γενικότερη αρχιτεκτονική των δικτύων (δηλ. TLFN), έπρεπε να γίνουν διάφορες επιλογές σε σχέση κυρίως με το μέγεθος του δείγματος εκπαίδευσης και τον αριθμό των νευρώνων και των καθυστερήσεων του δικτύου που θα χρησιμοποιούσαμε για την πρόβλεψη των τιμών. Οι επιλογές αυτές έγιναν μετά από εκτενείς πειραματισμούς που περιλάμβαναν εκπαίδευση και αξιολόγηση της απόδοσης πολλών διαφορετικών δικτύων και περιγράφονται στην παράγραφο 4.3.

Στη συνέχεια το δίκτυο με τα χαρακτηριστικά που επιλέχθηκαν στο παραπάνω βήμα χρησιμοποιήθηκε για να προβλέψει ένα βήμα μπροστά, να προβλέψει δηλαδή μόνο μια τιμή στο μέλλον με βάση την είσοδό του. Τέλος, το παραπάνω δίκτυο με μια επιπρόσθετη ανατροφοδότηση της εξόδου του στην είσοδό του χρησιμοποιήθηκε για να προβλέψει παραπάνω από μια τιμές μπροστά. Τα αποτελέσματα των παραπάνω προσομοιώσεων παρουσιάζονται και σχολιάζονται στις παραγράφους 4.4 και 4.5.

4.2 Τα δίκτυα

Για τις προσομοιώσεις που έγιναν επιλέχθηκε ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης με χρονικές καθυστερήσεις (TLFN), αποτελούμενο από N νευρώνες και D καθυστερήσεις (delays), όπου οι τιμές N και D μεταβάλλονται κατά τους πειραματισμούς.

Η επιλογή των δικτύων TLFN για την εργασία της πρόβλεψης έγινε λαμβάνοντας υπόψιν διάφορα δεδομένα. Καταρχήν τα δίκτυα TLFN χρησιμοποιούνται ευρέως για παρόμοιες εργασίες όπου προσπαθούμε να προβλέψουμε μελλοντικές τιμές μιας χρονοσειράς βασιζόμενοι μόνο σε παρελθούσες τιμές της ίδιας χρονοσειράς, και ειδικά σε περιπτώσεις που αντιμετωπίζονται χρονοσειρές για τις οποίες δεν ξέρουμε με βάση ποιους κανόνες μεταβάλλεται η τιμή τους [1–4]. Ιδιαίτερο ενδιαφέρον είχε επίσης το γεγονός ότι με τη χρήση της συγκεκριμένης αρχιτεκτονικής καλούμαστε αντί να τροφοδοτήσουμε τα δίκτυα με κάποιο χαρακτηριστικό (feature) του ΗΕΓ, να τα τροφοδοτήσουμε με το ίδιο το ΗΕΓ, κάτι που δεν φαίνεται να έχει ξαναδοκιμαστεί σύμφωνα με τη βιβλιογραφική επισκόπηση

που έγινε. Δεδομένου λοιπόν και της μη ύπαρξης πρότερης βιβλιογραφικής πληροφορίας, επιλέξαμε την απλούστερη δυνατή αρχιτεκτονική για τα δίκτυα αποφεύγοντας ως πούμε να έχουμε καταναμημένες (distributed) χρονικές καθυστερήσεις, ή να έχουμε κάποιο πιο περίπλοκο είδος μνήμης, όπως μνήμη γάμμα για παράδειγμα. Τέλος, η συγκεκριμένη αρχιτεκτονική δικτύων υποστηρίζεται από το περιβάλλον προγραμματισμού Matlab και είναι η βασική αρχιτεκτονική δικτύου που χρησιμοποιείται από το συγκεκριμένο περιβάλλον για την πρόβλεψη μελλοντικών τιμών χρονοσειράς. Στο Matlab μπορούν να δημιουργηθούν TLFN δίκτυα μεταβλητού μεγέθους και παραμέτρων με λίγες μόνο εντολές, διευκολύνοντας έτσι τη μεταβολή των παραμέτρων των δικτύων κατά τη φάση των εκτενών πειραματισμών που έγιναν.

Τα δίκτυα που χρησιμοποιήθηκαν ήταν πλήρως συνδεδεμένα (fully connected), δηλαδή το κάθε δείγμα (sample) του ΗΕΓ τροφοδοτείται από το επίπεδο εισόδου (input layer) του νευρωνικού σε κάθε έναν από τους N νευρώνες του. Στο επίπεδο εισόδου υπάρχει μια γραμμή καθυστέρησης απαγωγών (tapped delay line), η οποία ουσιαστικά παίρνει ένα παράθυρο από D δείγματα από το ΗΕΓ σήμα εισόδου, που είναι τα δείγματα τα οποία θα χρησιμοποιήσει σαν πληροφορία το νευρωνικό μας για να προβλέψει την επόμενη τιμή του ΗΕΓ.

Το κρυφό επίπεδο έχει N νευρώνες, στο οποίο η συνάρτηση μεταφοράς (transfer function) είναι η εφαπτομενική σιγμοειδής (tan-sigmoid). Το τελευταίο επίπεδο του νευρωνικού (output layer) αποτελείται από έναν μόνο νευρώνα και έχει γραμμική συνάρτηση μεταφοράς (linear transfer function). Το επίπεδο αυτό βγάζει σαν έξοδο την τιμή του $K+1$ δείγματος όπως την προβλέπει το δίκτυο.

4.3 Εύρεση βέλτιστου μεγέθους δικτύου

Πρώτος στόχος πριν την εφαρμογή της πρόβλεψης ΗΕΓ τιμών ήταν να εξετάσουμε ποιες θα ήταν οι βέλτιστες τιμές για τον αριθμό των νευρώνων και τον αριθμό των καθυστερήσεων του δικτύου μας. Πειραματιστήκαμε λοιπόν με τη μεταβολή των δύο αυτών παραμέτρων του δικτύου και μετρήσαμε πως επηρεάζει η μεταβολή αυτή την απόδοση του δικτύου. Το trial and error είναι άλλωστε ένας πολύ δημοφιλής τρόπος καθορισμού του μεγέθους ενός δικτύου[5]. Προσομοιώθηκαν λοιπόν δίκτυα 4 έως 60 νευρώνων με 4 έως 60 καθυστερήσεις, με βήμα 4 τόσο για τους νευρώνες όσο και για τα καθυστερήσεις.

Εδώ πρέπει να σημειωθεί ότι το συγκεκριμένο εύρος τιμών επιλέχθηκε επειδή η πολυπλοκότητα του δικτύου, και άρα και ο υπολογιστικός χρόνος προσομοίωσης που χρειάζεται, αυξάνεται τρομερά με την αύξηση αυτών των δύο χαρακτηριστικών. Ενδεικτικά αναφέρουμε ότι ένα δίκτυο 6 νευρώνων και 4 καθυστερήσεων έχει 30 συνδέσεις, ένα δίκτυο 20 νευρώνων και 40 καθυστερήσεων έχει 840 συνδέσεις και ένα δίκτυο 100 νευρώνων και 100 καθυστερήσεων έχει 10100 συνδέσεις. Κατά συνέπεια για να προσομοιωθεί ένα δίκτυο 60 νευρώνων με 60 καθυστερήσεις χρειάστηκε γύρω στο ένα 24ωρο για περίπου 10 επαναλήψεις (iterations). Επίσης, περίπου σε αυτές τις τιμές ο υπολογιστής στον οποίο έγιναν οι προσομοιώσεις δεν μπορεί πλέον να αντεπεξέλθει και το matlab εμφανίζει σφάλμα out of memory τερματίζοντας την προσομοίωση.

Η μέτρηση της απόδοσης των δικτύων έγινε τόσο με βάση το μέσο τετραγωνικό σφάλμα (mse - mean squared normalized error) ,που χρησιμοποιήθηκε και ως συνάρτηση επίδοσης (performance function) για την εκπαίδευση των δικτύων, όσο και με βάση το μέσο απόλυτο σφάλμα (mae - mean absolute error). Τα δύο αυτά στατιστικά υπολογίστηκαν τόσο για το δείγμα εκπαίδευσης των δικτύων όσο και για μια τυχαία μεσοκριστική περίοδο, και συγκεκριμένα για μια περίοδο 100.000 δειγμάτων (6,51 minutes).

Ένα άλλο βασικό χαρακτηριστικό της εκπαίδευσης του δικτύου, που επηρεάζει τα αποτελέσματα είναι το μέγεθος του δείγματος εκπαίδευσης. Όπως ήταν εξ αρχής αναμενόμενο (και διαπιστώθηκε με μερικές δοκιμές) όσο μεγαλύτερο είναι το δείγμα εκπαίδευσης τόσο καλύτερα είναι τα αποτελέσματά της πρόβλεψης. Είναι άλλωστε λογικό η αύξηση των διαθέσιμων δεδομένων μόνο καλό να κάνει στα αποτελέσματα της μεθόδου, καθώς έτσι αυξάνουμε τη διαθέσιμη πληροφορία που θα χρησιμοποιήσει το νευρωνικό δίκτυο για να μάθει να προβλέπει το HEG.

Επιλέξαμε λοιπόν να θέσουμε το μέγεθος του δείγματος εκπαίδευσης στην υψηλότερη δυνατή τιμή που επέτρεπαν οι διαθέσιμοι υπολογιστικοί πόροι ώστε το matlab να μην βγει out of memory. Επίσης, το μέγεθος του δείγματος εκπαίδευσης έπρεπε προφανώς να παραμείνει σταθερό για όλα τα δίκτυα που εκπαιδεύσαμε, ώστε να μπορούμε να συγκρίνουμε την απόδοση των δικτύων μόνο με βάση τα υπόλοιπα χαρακτηριστικά τους. Δυστυχώς, λόγω της υπολογιστικής πολυπλοκότητας των νευρωνικών δικτύων -ειδικά όταν έχουμε δίκτυα με πολλούς νευρώνες και πολλές καθυστερήσεις- το μέγιστο επιτρεπτό μέγεθος του δείγματος εκπαίδευσης είναι μόνο 50.000 δείγματα, δηλαδή 3,255 λεπτά μόλις.

Η εκπαίδευση των δικτύων έγινε λοιπόν με βάση τα μεσοκριστικά δεδομένα του ασθενή 5 , και συγκεκριμένα με τα πρώτα 50.000 samples της HEG καταγραφής του ασθενή. Επιλέξαμε αρχικά να δουλέψουμε με μεσοκριστικά δεδομένα , γιατί από κάποιες αρχικές προσομοιώσεις που είχαν γίνει είχε παρατηρηθεί, όπως ήταν άλλωστε και αναμενόμενο, ότι τα επιληπτικά δεδομένα είναι αρκετά πιο απρόβλεπτα – πράγμα που όπως θα γίνει σαφές επιβεβαιώσαμε και στη συνέχεια. Εδώ είναι σημαντικό να αναφέρουμε ότι θα μπορούσαμε να επανεκπαιδεύσουμε τα δίκτυα και για κάποια άλλη περίοδο του ασθενή 5 ή ακόμα καλύτερα να επανεκπαιδεύσουμε όλα τα δίκτυα και για άλλους ασθενείς, ώστε να επιβεβαιώσουμε ότι τα αποτελέσματά μας δεν έχουν να κάνουν μόνο με το HEG του συγκεκριμένου ασθενή. Κάτι τέτοιο ωστόσο θα χρειαζόταν απαγορευτικά πολύ υπολογιστικό χρόνο. Άλλωστε, όπως θα φανεί και παρακάτω, εμείς περισσότερο αυτό που θα κρατήσουμε από αυτή την προσομοίωση είναι μια γενικότερη τάση που βγαίνει εμπειρικά, και όχι μια συγκεκριμένη βέλτιστη τιμή.

Για αλγόριθμο εκπαίδευσης επιλέχθηκε το Levenberg-Marquadt backpropagation. Ένας λόγος για αυτή την επιλογή είναι ότι σύμφωνα με το εγχειρίδιο του Neural Network Toolbox του Matlab, ο αλγόριθμος αυτός είναι ο πλέον κατάλληλος τόσο ως προς τα αποτελέσματά του όσο και ως προς την ταχύτητα σύγκλισής του για το μέγεθος δείγματος εκπαίδευσης και δικτύου που χρησιμοποιούμε.[6] Ένας άλλος λόγος για αυτή την επιλογή είναι ότι ο συγκεκριμένος αλγόριθμος εκπαίδευσης χρησιμοποιείται και σε άλλες εργασίες που χρησιμοποιούν νευρωνικά δίκτυα με χρονικές καθυστερήσεις σε HEG δεδομένα [7] (όπου βέβαια εδώ τα νευρωνικά δίκτυα χρησιμοποιούνται για ταξινόμηση- όπως έχει αναφερθεί και παραπάνω, δεν έχουμε βρει στη βιβλιογραφία κάποια άλλη περίπτωση χρήσης νευρωνικού δικτύου για την απευθείας πρόβλεψη τιμών του HEG), όσο και στις

περισσότερες περιπτώσεις που χρησιμοποιούνται αναδρομικά νευρωνικά δίκτυα για την πρόβλεψη τιμών μιας χρονοσειράς σε άλλα επιστημονικά πεδία [8–11].

Το δείγμα εκπαίδευσης χωρίστηκε σε τρεις τυχαίες ομάδες: δείγμα εκπαίδευσης (training set - 70% του συνολικού δείγματος), δείγμα εκτίμησης (testing set - 15% του συνολικού δείγματος) και δείγμα επικύρωσης (validation set - 15% του συνολικού δείγματος). Για τον τερματισμό της εκπαίδευσης των δικτύων έγινε χρήση της τεχνικής του πρώιμου τερματισμού (early stopping) με βάση το δείγμα επικύρωσης. Αυτό έγινε γιατί δεν είχαμε σαν απαίτηση κάποιο συγκεκριμένο μέγεθος σφάλματος, δεδομένου της μη προβλεψιμότητας του εγκεφαλικού σήματος.

Παρακάτω φαίνονται τα δεδομένα για την απόδοση των δικτύων. Το κριτήριο του performance είναι το μέσο τετραγωνικό σφάλμα (mse). Η απόδοση αυτή βγαίνει από το το performance function του Matlab για τα δεδομένα της εκπαίδευσης και αναφέρεται στο δείγμα εκπαίδευσης.

Πίνακας 4.1: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 4-20 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	4	8	12	16	20
4	4106	3779.8	3485.6	3478.4	3172.1
8	3980.3	3648.6	3431.9	3293.1	2992.9
12	3934.5	3633.1	3341.1	3161.3	3038.2
16	3988.8	3413.6	3276.6	3246.2	3038.9
20	3927.7	3375.7	3365.8	3101	2852.1
24	4087.9	3314.2	3702.6	3161.4	3032.3
28	4119	3230.8	3240.7	3151.9	2929.7
32	3849.6	3351.7	3247.4	3106.6	3111.5
36	3972.3	3476.4	3197.4	2992.6	2922.3
40	3942.7	3474	3149.5	3451.2	3203.1
44	3887.7	3399.8	3250.4	2858.4	2841.9
48	3906.8	3312	3140.9	3087.9	2902.4
52	3915.7	3228.3	3065.5	3178.3	6673.6
56	3897.1	3402.1	3232.7	3318.6	2871.4
60	4010.5	3248.4	3157.9	3158.6	2871.1

Πίνακας 4.2: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 24-40 καθυστερήσεις

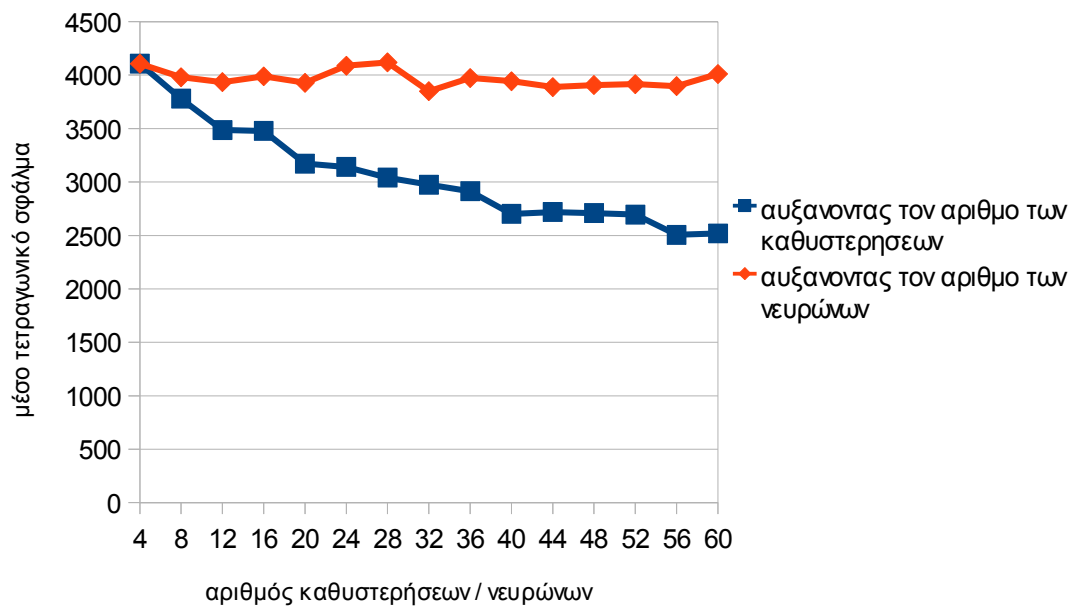
ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	24	28	32	36	40
4	3140.4	3041.1	2974.3	2914.6	2701.4
8	3022.6	2898.3	2749.4	2757	2662.3
12	3044.6	2777.1	2760.1	2769.2	2778.5
16	3028.7	2726.5	2868.9	2633.6	2605.5
20	2981.3	2758.4	2874.9	2640.1	2762.3
24	2828.7	2864.5	2730.7	48243	2605.5
28	2795.6	2639.1	2681.2	2540.1	2499.3
32	2787.7	2861.8	2782.3	2505	2334.8
36	2991.3	2763.4	2760.2	2540.5	2568.6
40	2980.9	3106	2756.6	2588.7	2515.4
44	2961.6	2749.1	2459.9	2710.1	2492.3
48	2955.7	2607.2	2575.1	2547.5	2609.9
52	2845.6	2760	2630.1	2597	2437.3
56	2817.9	2798.5	2646.4	4358.8	2496.7
60	2604.7	2849.7	2507.3	2443.5	2507.3

Πίνακας 4.3: Μέσο τετραγωνικό σφάλμα εκπαίδευσης για 44-60 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	44	48	52	56	60
4	2718.8	2709.4	2694.9	2506.2	2518.7
8	2636.3	2529.4	2520.5	2463.2	2496.9
12	2542.5	2492.5	2519	2422.8	2543.4
16	2557.5	2580.2	2492.2	96693	2302.7
20	2506.7	2680.8	2341	2407.5	2562.9
24	2969.3	2499.8	2420.1	2444.4	4848.5
28	2463.4	2390.6	2366.1	2727.8	2383.7
32	2518.1	2544.3	2323.5	2252.9	2371.3
36	2331.5	2467.9	2350.8	2458.3	2223.8
40	2770	2371.4	2353.3	2371.6	2159.1
44	2384.8	2407.2	2368.6	2281.1	2177.9
48	2380.1	2476.4	2411.6	2229.6	2142.0
52	51216	2390	2331.1	2136.1	2323.5
56	2486	2468.3	2279.6	2405.3	2387.4
60	2439.5	2318.7	2490.7	2312.9	2214.5

Αυτό που έχει αξία να παρατηρήσουμε σε σχέση με τα παραπάνω δεδομένα είναι η μεταβολή της τιμής του μέσου τετραγωνικού σφάλματος σε σχέση με την αύξηση του αριθμού των νευρώνων και σε σχέση με την αύξηση του αριθμού των καθυστερήσεων. Κάτι τέτοιο γίνεται πιο εμφανές από το παρακάτω διάγραμμα, όπου ξεκινώντας από το μέσο τετραγωνικό σφάλμα του δικτύου 4 νευρώνων και 4 καθυστερήσεων προσθέτουμε νευρώνες κρατώντας τον αριθμό των καθυστερήσεων σταθερό (κόκκινη γραμμή) ενώ στο ίδιο διάγραμμα παραθέτουμε τα μέσα τετραγωνικά σφάλματα δικτύων 4 νευρώνων και 4 έως 60 καθυστερήσεων (μπλε γραμμή).

Μεταβολή μέσου τετραγωνικού σφάλματος πρόβλεψης



Σχήμα 4.1: Μεταβολή μέσου τετραγωνικού σφάλματος πρόβλεψης για τα δεδομένα εκπαίδευσης των δικτύων.

Επίσης ενδεικτικά παρατίθεται η απόδοση αυτών των δικτύων σε άγνωστα μεσοκρισικά δεδομένα του ίδιου ασθενή, τόσο με κριτήριο το μέσο τετραγωνικό σφάλμα, όσο και το μέσο απόλυτο σφάλμα.

Παρουσιάζεται αρχικά το μέσο απόλυτο σφάλμα για τυχαίο μεσοκρισικό διάστημα.

Πίνακας 4.4: Μεσοκριτικό μέσο απόλυτο σφάλμα για 4-20 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	4	8	12	16	20
4	30,36	29,58	29	28,61	28,21
8	30,61	29,73	29,21	28,79	28,38
12	30,39	29,85	29,01	28,6	28,23
16	30,5	29,53	28,97	28,82	28,31
20	30,5	29,79	29,27	28,58	28,15
24	30,52	29,66	29,45	28,62	28,57
28	30,41	29,7	29,05	28,76	28,3
32	30,57	29,62	29	28,71	28,35
36	30,46	29,71	29,34	28,84	28,23
40	30,42	29,61	29,17	28,81	28,58
44	30,51	29,79	29,19	28,69	28,73
48	30,42	29,64	29,25	28,74	28,29
52	30,73	29,63	30,07	29,23	35,23
56	30,97	29,58	29,28	28,76	28,67
60	30,63	30,26	29,61	28,74	28,46

Πίνακας 4.5: Μεσοκριτικό μέσο απόλυτο σφάλμα για 24-40 καθυστερήσεις

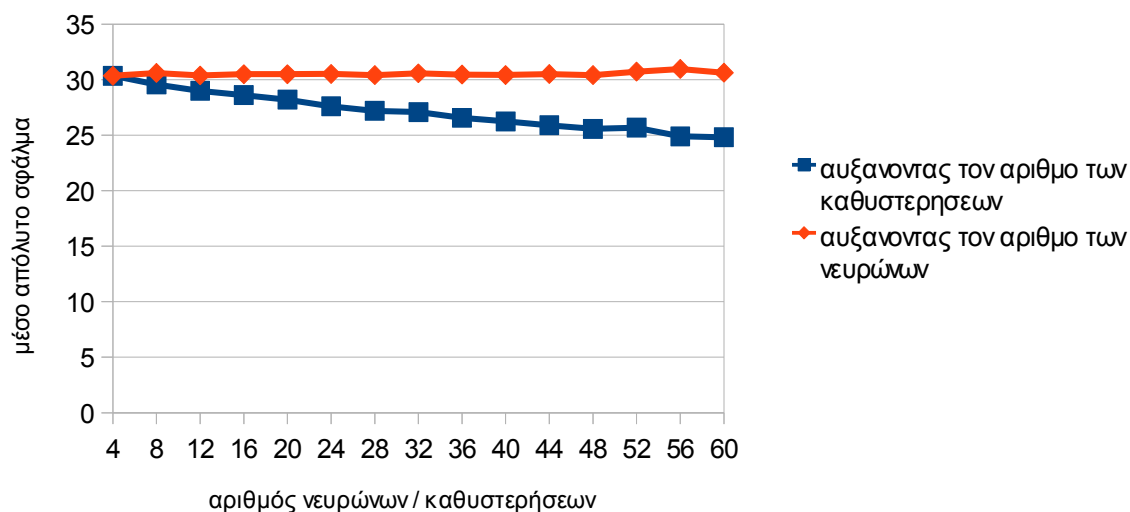
ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	24	28	32	36	40
4	27,6	27,2	27,09	26,57	26,25
8	27,58	27,3	26,79	26,47	26,24
12	28,05	27,14	26,97	26,51	26,41
16	27,75	27,22	27,02	26,41	26,26
20	27,89	27,19	26,92	26,56	26,3
24	27,74	27,4	27,02	35,82	26,34
28	27,95	27,56	26,95	26,98	26,81
32	27,65	27,69	26,76	26,86	26,29
36	28,05	27,27	27,18	26,89	26,33
40	28,23	27,93	27,01	26,6	26,45
44	27,86	27,37	27,4	26,73	26,66
48	28,2	27,55	27,2	27,24	26,64
52	28,01	27,51	27,03	27	26,59
56	28,17	27,71	27,08	29,59	26,66
60	27,9	27,5	27,43	27,24	26,58

Πίνακας 4.6: Μεσοκριτικό μέσο απόλυτο σφάλμα για 44-60 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	44	48	52	56	60
4	25,9	25,58	25,68	24,9	24,82
8	25,81	25,55	25,16	25,02	24,94
12	25,78	25,66	25,39	25,14	25,31
16	25,86	25,92	25,38	25,65	24,96
20	25,87	25,88	25,58	25,88	24,93
24	27,58	25,8	25,49	25,07	25,19
28	26,12	26,11	25,48	25,43	25,08
32	26,13	26,06	25,65	25,3	25,33
36	26,23	26,58	25,65	25,16	25,33
40	26,56	25,91	26,09	25,89	25,58
44	26,17	25,82	25,47	25,54	25,25
48	26,33	25,84	25,69	25,49	25,15
52	173,27	26,01	25,55	25,69	24,91
56	26,28	26,48	25,87	25,53	25,37
60	26,3	25,99	26,17	25,81	25,59

Όπως έγινε παραπάνω για το μέσο τετραγωνικό σφάλμα εκπαίδευσης, έτσι και εδώ θα παραθέσουμε ένα διάγραμμα με τη μεταβολή του μέσου απόλυτου σφάλματος για τυχαίο μεσοκριτικό διάστημα σε σχέση με την αύξηση του αριθμού των νευρώνων και των καθυστερήσεων.

Μεταβολή μέσου απόλυτου σφάλματος για μεσοκριτικά δεδομένα



Σχήμα 4.2: Μεταβολή μέσου απόλυτου σφάλματος πρόβλεψης για μεσοκριτικά δεδομένα.

Στη συνέχεια παρατίθεται το μέσο τετραγωνικό σφάλμα (mean squared normalized error) για το ίδιο μεσοκριτικό διάστημα.

Πίνακας 4.7: Μεσοκριτικό μέσο τετραγωνικό σφάλμα για 4-20 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	4	8	12	16	20
4	1849,36	1784,05	1682,3	1604,94	1583,85
8	1943,51	1775,45	1763,54	1706,17	1772,02
12	1845,32	1808,35	1684,24	1678,6	1601,29
16	2008,43	1735,25	1670,61	1615,57	1876,27
20	2039,2	2168,64	2036,39	1617,05	1545,32
24	2242,1	1781,33	1740,02	1614,04	1615,17
28	1918,05	2063,54	1717,84	1606,18	1668,63
32	2329,17	1962,52	1685,07	1663,12	1552,6
36	1953,85	2135,65	1828,79	1778,55	1617,56
40	1919,65	1739,71	1904,71	1629,93	2091,63
44	2007,61	2354,58	1829,43	1708,71	2924,25
48	1949,16	1745,16	1767,55	1679,36	1580,5
52	2500,62	1864,32	6440,5	2676,81	3157,54
56	2000,82	1915,61	1707,59	1644,34	2155,53
60	2118,05	4680,43	3176,81	1701,2	1752,17

Πίνακας 4.8: Μεσοκριτικό μέσο τετραγωνικό σφάλμα για 24-40 καθυστερήσεις

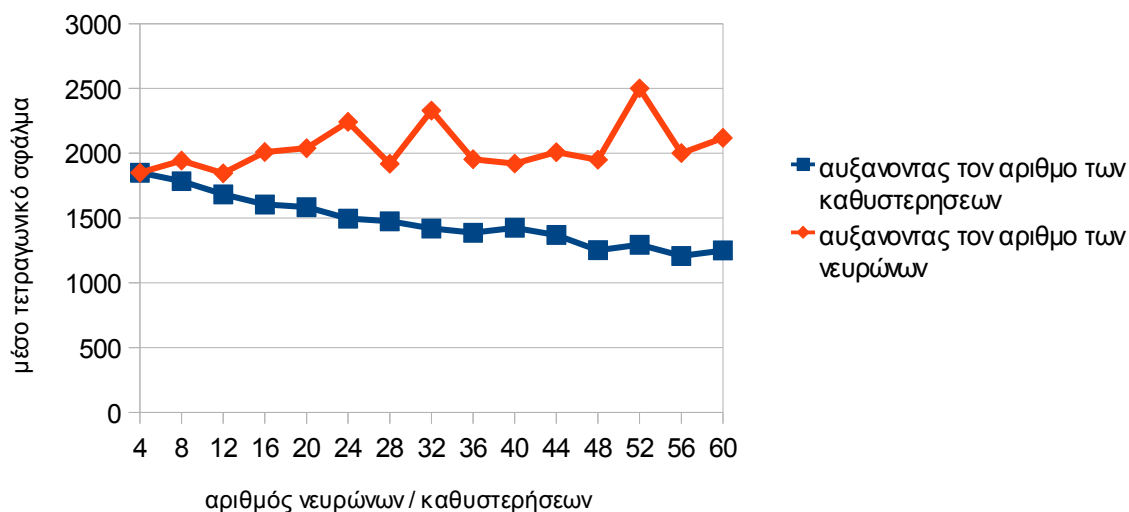
ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	24	28	32	36	40
4	1495,53	1474,73	1419,12	1386,01	1424,24
8	1479,01	1460,88	1433,61	1391,34	1385,99
12	1653,54	1429,8	1451,46	1370,82	1378,27
16	1542,24	1449,31	1611,65	1355,19	1371,31
20	1588,38	1461,82	1407,57	1397,96	1400,04
24	1521,19	1516,96	1413,78	9318,73	1399,09
28	1629,99	1494,6	1451,64	1500,82	1477,76
32	1508,02	1543,15	1385,53	1450,3	1389,13
36	2055,09	1488,51	1529,75	1513,07	1385,94
40	1769,81	1740,72	1507,28	1431,18	1422,92
44	1639,48	1470,58	1542,14	1412,57	1380,92
48	1563,65	1486,06	1552,92	1430,14	1472,25
52	1734,74	1716,98	1501,66	1606,88	1589,84
56	1605,87	1517,59	1498,3	1861,9	1500,81
60	1523,16	1619,08	1682,37	1510,43	1485,93

Πίνακας 4.9: Μεσοκρισικό μέσο τετραγωνικό σφάλμα για 44-60 καθυστερήσεις

ΑΡΙΘΜΟΣ ΝΕΥΡΩΝΩΝ	ΑΡΙΘΜΟΣ ΚΑΘΥΣΤΕΡΗΣΕΩΝ				
	44	48	52	56	60
4	1368,94	1251,35	1293,24	1206,69	1249,59
8	1310,24	1291,22	1244,49	1396,9	1211,52
12	1325,79	1301,58	1273,84	1271,08	1262,08
16	1330,34	1342,08	1282,39	25171,02	1195,12
20	1343,16	1651,54	1305,57	1336,17	1205,31
24	1582,21	1360,93	1280,75	1233,62	4106,62
28	1431,62	1341,06	1278,01	1287,47	1235,77
32	1402,63	1348,92	1321,29	1265,76	1283,45
36	1349,06	1471,48	1339,23	1225,96	1262,24
40	1559,38	1281	1347,45	1311,76	1301,77
44	1351,1	1311,15	1316,29	1409,64	1250,45
48	1343,21	1332,13	1292,06	1285,81	1240
52	36974,87	1306,79	1271,31	1387,94	1222,9
56	1369,55	1346,27	1296,89	1290,87	1310,1
60	1484,84	1337,61	1354,9	1410,9	1276,5

Παρακάτω φαίνεται το αντίστοιχο διάγραμμα μεταβολής του μέσου τετραγωνικού σφάλματος:

Μεταβολή μέσου τετραγωνικού σφάλματος για μεσοκρισικά δεδομένα



Σχήμα 4.3: Μεταβολή μέσου τετραγωνικού σφάλματος πρόβλεψης για μεσοκρισικά δεδομένα.

Από τα παραπάνω δεδομένα μπορούμε να παρατηρήσουμε δύο γενικές τάσεις. Η αύξηση του αριθμού των νευρώνων φαίνεται να βελτιώνει σε κάποιο βαθμό την απόδοση των δικτύων, ειδικά με βάση τα δεδομένα του δείγματος εκπαίδευσης. Ωστόσο παρατηρούμε ότι


στα αποτελέσματα της απόδοσης για την προσομοίωση τυχαίου μεσοκριστικού διαστήματος δεν υπάρχει κάποια αντίστοιχη βελτίωση και η απόδοση των δικτύων με βάση τους νευρώνες φαίνεται να μένει σχετικά σταθερή και ως προς τα δύο κριτήρια απόδοσης.

Με την αύξηση του αριθμού των καθυστερήσεων έχουμε βελτίωση της απόδοσης των δικτύων μας με βάση και τους 3 πίνακες στατιστικών που παραθέσαμε παραπάνω. Επίσης η βελτίωση στην απόδοση των δικτύων είναι πολύ μεγαλύτερη από ότι η βελτίωση που φαίνεται να προκαλεί η αύξηση του αριθμού των νευρώνων.

Με βάση τα παραπάνω, μπορούμε να πούμε ότι για την πρόβλεψη τιμών του ΗΕΓ, προτιμότερο θα ήταν να έχουμε ένα δίκτυο με πολλές καθυστερήσεις και όχι ιδιαίτερα πολλούς νευρώνες. Έτσι για να έχουμε το καλύτερο ισοζύγιο υπολογιστικής πολυπλοκότητας/απόδοσης, θα προτεινάμε τη χρήση ενός δικτύου 100 καθυστερήσεις και 16 νευρώνων. Φυσικά η παραπάνω παρατήρηση αναφέρεται σε δίκτυα με μέγεθος και χαρακτηριστικά αντίστοιχα με αυτά που χρησιμοποιήθηκαν στις παραπάνω προσομοιώσεις. Δεδομένου ότι τα αποτελέσματά αυτά προκύπτουν εμπειρικά δεν μπορούμε να ισχυριστούμε ότι για δίκτυα 1000 πχ νευρώνων και διαφοροποιημένης αρχιτεκτονικής η μεταβολή των μεγεθών του δικτύου θα επηρεάζει το δίκτυο με τον ίδιο τρόπο που επηρεάζει ένα δίκτυο μεγέθους 100 νευρώνων.

4.4 Πρόβλεψη ένα βήμα μπροστά στο χρόνο (one-step-ahead prediction)

Η προσπάθειά πρόβλεψης των τιμών του ΗΕΓ ξεκίνησε από την πρόβλεψη μίας μόνο τιμής χρησιμοποιώντας τα δεδομένα από τις προηγούμενες 100 τιμές. Για να επιτευχθεί αυτό χρησιμοποιήθηκε ένα δίκτυο με 16 νευρώνες και 100 καθυστερήσεις που εκπαιδεύτηκε με ένα δείγμα εκπαίδευσης μεγέθους 100.000 samples (390,625 sec). Οι προσομοιώσεις έγιναν και πάλι στα δεδομένα του καναλιού 1 (εστιακό κανάλι) του ασθενή 5. Συγκεκριμένα το δίκτυο εκπαιδεύτηκε με τα 100.000 πρώτα samples της μεσοκριστικής ΗΕΓ καταγραφής του ασθενή 5. Οι υπόλοιπες παράμετροι του δικτύου παρέμειναν ίδιες με αυτές που περιγράφονται παραπάνω.




Σχήμα 4.4: Το δίκτυο που χρησιμοποιήθηκε για τις προσομοιώσεις¹

¹ Τα στοιχεία του διαγράμματος αναλύονται στο παράρτημα


Μετά την εκπαίδευσή του, το νευρωνικό δίκτυο τροφοδοτήθηκε με όλο το καταγεγραμμένο ΗΕΓ του ασθενή 5, σε παράθυρα των 100 samples. Με αυτό τον τρόπο το δίκτυο προβλέπει για κάθε χρονική στιγμή την τιμή του ΗΕΓ του ασθενή βασιζόμενο στις προηγούμενες 100 χρονικές στιγμές (timestesp). Το προβλεφθέν σήμα αποθηκεύτηκε και συγκρίθηκε με το πραγματικό ΗΕΓ και καταγράφηκαν οι αποκλίσεις και οι προκύπτουσες μέσες τιμές του απόλυτου σφάλματος για διάφορες χρονικές περιόδους.

Συγκεκριμένα, η απόλυτη μέση τιμή του σφάλματος για το συνολικό καταγεγραμμένο ΗΕΓ του ασθενή 5 για το one step ahead prediction είναι 27,7197. Αξίζει επίσης να παρατηρήσουμε ότι η απόλυτη μέση τιμή του σφάλματος για τα αρχεία με μεσοκρισικά δεδομένα είναι 27,7564 και μέση τιμή του σφάλματος κατά τις πέντε επιληψίες του ασθενή είναι 72,1476. Η απόκλιση δηλαδή της πρόβλεψης είναι πολύ μεγαλύτερη όταν ο ασθενής παθαίνει επιληψία. Θα μπορούσαμε δηλαδή να πούμε ότι το επιληπτικό ΗΕΓ είναι λιγότερο προβλέψιμο από ότι το κανονικό. Παρακάτω φαίνεται η γραφική παράσταση του σφάλματος για μια περίοδο κατά την οποία παρατηρείται επιληψία στον ασθενή, η οποία ξεκινάει στο δείγμα 20.000.



Σχήμα 4.5: Σφάλματα πρόβλεψης κατά την έναρξη της κρίσης


Ένα μεγεθυμένο κομμάτι της παραπάνω γραφικής παράστασης που αντιστοιχεί στην έναρξη της επιληψίας μας βοηθά να δούμε την μεταβολή της τιμής των σφαλμάτων με μεγαλύτερη ευκρίνεια.



Σχήμα 4.6: Σφάλματα πρόβλεψης κατά την έναρξη της κρίσης μεγέθυνση


Παρατηρούμε ότι πράγματι η τιμή του σφάλματος είναι μεγαλύτερη κατά τη διάρκεια της επιληψίας. Παρατηρούμε επίσης ότι η τιμή του απόλυτου σφάλματος αυξάνεται ιδιαίτερα κοντά στην έναρξη της επιληψίας, και μάλιστα πριν καν αυτή αρχίσει να συμβαίνει. Συγκεκριμένα για την παραπάνω επιληπτική κρίση μπορούμε να πούμε ότι υπάρχει ευδιάκριτη αύξηση της τιμής του σφάλματος από το δείγμα 19.9920 των παραπάνω γραφικών παραστάσεων, δηλαδή 0,3125 sec (80 δείγματα) πριν το onset της επιληψίας. Το ίδιο συμβαίνει και για τις άλλες επιληπτικές κρίσεις του ασθενή.

Πέρα από την παράθεση της μέσης τιμής του σφάλματος, έχει νόημα να παραθέσουμε μερικές γραφικές με το προβλεπόμενο και το πραγματικό ΗΕΓ σήμα. Όπως φαίνεται και στις παρακάτω γραφικές παραστάσεις, το προβλεπόμενο σήμα μας δεν έχει πολύ μεγάλη απόκλιση από το πραγματικό, ειδικά για τις μεσοκρισικές περιόδους.



Σχήμα 4.7: Προβλεφθέν και πραγματικό σήμα

Παραθέτουμε και πάλι ένα μεγεθυμένο κομμάτι της παραπάνω γραφικής παράστασης.




Σχήμα 4.8: Προβλεφθέν και πραγματικό σήμα μεγέθυνση

Τα αποτελέσματα της πρόβλεψης του επόμενου βήματος με βάση τα 100 προηγούμενα είναι αρκετά καλά. Όπως φαίνεται και από τα διαγράμματα και τις μέσες τιμές, η πρόβλεψη που γίνεται ακολουθεί σε αρκετά καλό βαθμό το πραγματικό σήμα. Με βάση όλα τα παραπάνω μπορούμε να καταλήξουμε ότι πράγματι υπάρχει κάποια εξάρτηση της κάθε τιμής του ΗΕΓ από τις προηγούμενες τιμές του ΗΕΓ, και μάλιστα από τις ακριβώς προηγούμενες τιμές του, δεδομένου ότι δεν φτάνουμε καν πάνω από 100 βήματα πιο πίσω.

Ωστόσο ο ορίζοντας πρόβλεψης μεγέθους μόνο ενός βήματος είναι πολύ μικρός για να μπορεί να μας φανεί πρακτικά χρήσιμος. Παρακάτω γίνεται η προσπάθεια επέκτασης της χρήσης των ΤΝΔ και για μεγαλύτερους χρονικούς ορίζοντες πρόβλεψης.

4.5 Πρόβλεψη για πολλαπλά βήματα (multistep prediction)

Στη συνέχεια η πρόβλεψη επεκτάθηκε και για παραπάνω από ένα βήματα μπροστά. Έτσι “κλείσαμε” το δίκτυο με ένα feedback loop (προσθέσαμε δηλαδή στο δίκτυο ανάδραση) και ανατροφοδοτήσαμε τις τιμές που προβλέπουμε (εξόδος του δικτύου μας) στην είσοδο του δικτύου. Με αυτό τον τρόπο το δίκτυο βασιζόμενο στις δικές του εξόδους (προβλεπόμενες τιμές) προβλέπει και τις παρακάτω μελλοντικές τιμές. Η αρχιτεκτονική του δικτύου είναι πλέον η παρακάτω:




Σχήμα 4.9: Closed loop net

Παρακάτω βλέπουμε πώς μεταβάλλεται η απόλυτη μέση τιμή του σφάλματος για μια τυχαία μεσοκρυσική περίοδο διάρκειας 4000 samples (15,625 sec). Έχει προβλεφθεί για κάθε timestep η τιμή του από 1 έως 500 timesteps πιο πριν και παρουσιάζεται η απόλυτη μέση τιμή των σφαλμάτων αυτών. Συγκεκριμένα για την i-step ahead πρόβλεψη το νευρωνικό τροφοδοτείται με παράθυρα 100 δειγμάτων από ένα διάστημα 4000 δειγμάτων και προβλέπει τις επόμενες i τιμές. Αποθηκεύτηκε η i-οστή τιμή της πρόβλεψης, η οποία αντιστοιχεί στην πρόβλεψη του δικτύου μας για εκείνο το δείγμα του ΗΕΓ i βήματα μπροστά. Συνεχίζοντας έτσι και τροφοδοτώντας το νευρωνικό με το ΗΕΓ σε παράθυρα, προβλέψαμε όλο το διάστημα των 4.000 δειγμάτων i-steps ahead και το συγκρίναμε με το πραγματικό ΗΕΓ.


Πίνακας 4.10: Μέσο απόλυτο σφάλμα πρόβλεψης για πολλαπλά βήματα

Αριθμός βημάτων που προβλέπουμε	Μέσο απόλυτο σφάλμα
1	23,27
2	29,48
3	38,13
4	46,65
5	55,2
6	64,2
7	74,42
8	84,9
9	95,09
10	104,59
11	114,17
13	132,48
15	150,02
17	165,59
19	179,84
21	192,92
31	235,56
41	249,59
51	246,39
61	244,07
71	238,01
81	213,15
91	191,58
101	197,8
151	199
201	203,09
251	201,57
301	204,52
351	201,56
401	202,11
451	202,04
501	201,89

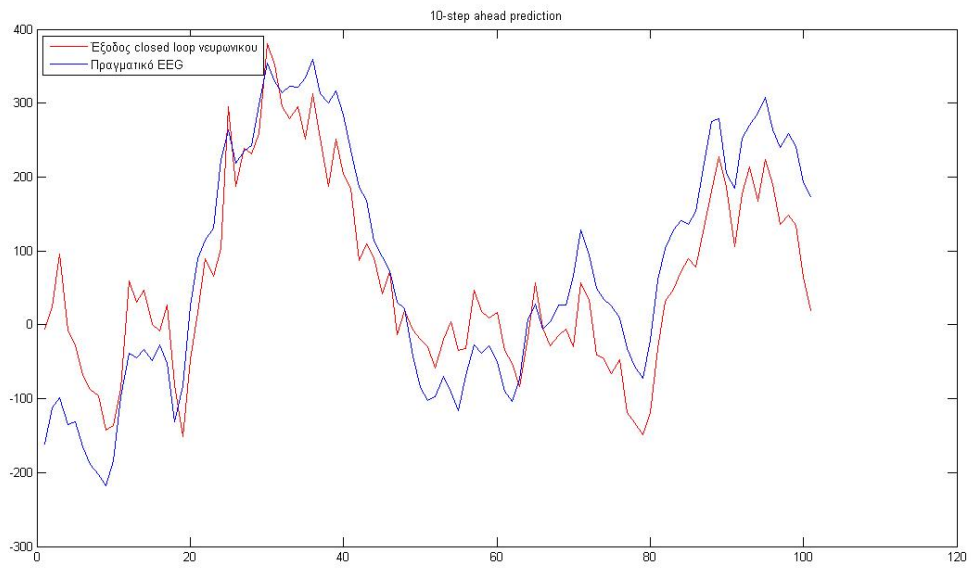
Στις παρακάτω γραφικές παραστάσεις φαίνεται το σήμα που προβλέπουμε σε σχέση με το πραγματικό σήμα για κάποιες από τις παραπάνω τιμές.




Σχήμα 4.10: Πρόβλεψη για ένα(1) βήμα




Σχήμα 4.11: Πρόβλεψη για δύο(2) βήματα



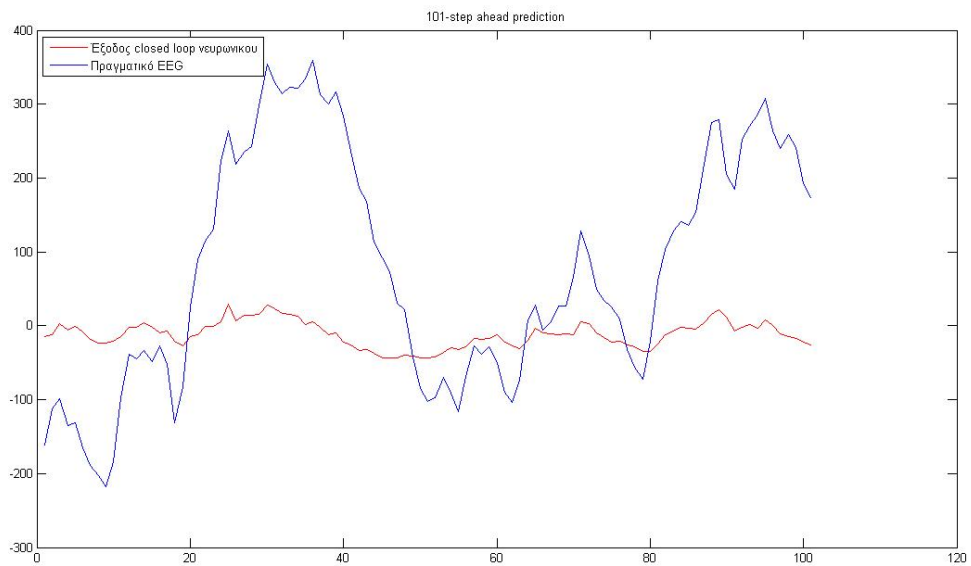
Σχήμα 4.12: Πρόβλεψη για δέκα(10) βήματα




Σχήμα 4.13: Πρόβλεψη για εικοσιένα(21) βήματα



Σχήμα 4.14: Πρόβλεψη για πενήντα ένα (51) βήματα




Σχήμα 4.15: Πρόβλεψη για εκατόν ένα (101) βήματα



Σχήμα 4.16: Πρόβλεψη για διακόσια ένα (201) βήματα

Όπως φαίνεται τόσο από τα παραπάνω σχήματα όσο και από τις γραφικές παραστάσεις, μετά τα 20 περίπου βήματα δεν μπορούμε να προβλέψουμε σε καθόλου καλό βαθμό την τιμή του ΗΕΓ. Επίσης βλέπουμε ότι μετά από έναν αριθμό βημάτων πρόβλεψης μπροστά, η έξοδος του νευρωνικού σταθεροποιείται γύρω από μία τιμή, η οποία μάλιστα είναι σταθερή για κάθε νευρωνικό. Για το συγκεκριμένο νευρωνικό η τιμή αυτή είναι το -14 περίπου. Αυτό μπορούμε να το δούμε πιο ξεκάθαρα από τη γραφική παράσταση της εξόδου μόνο του νευρωνικού, για μια είσοδο 100 δειγμάτων του νευρωνικού, όπου κάνουμε πρόβλεψη των επόμενων 500 βημάτων.



Σχήμα 4.17: Έξοδος νευρωνικού για πρόβλεψη 500 βημάτων

Από τα παραπάνω είναι εμφανές ότι η πρόβλεψη για πολλά βήματα μπροστά δεν έχει ικανοποιητικά αποτελέσματα. Δεν μπορούμε να προβλέψουμε με αποδεκτό σφάλμα ούτε καν τα επόμενα 0,1 sec. Ωστόσο τα αποτελέσματα για λίγα βήματα μπροστά επιβεβαιώνουν αυτό που είπαμε και παραπάνω, ότι δηλαδή εντοπίζουμε εξάρτηση των τιμών του ΗΕΓ από τις προηγούμενες τιμές του ΗΕΓ. Πιθανόν με τη χρησιμοποίηση κάποιου πολύ μεγαλύτερου νευρωνικού δικτύου, που θα είχε σαν αποτέλεσμα σημαντικά μικρότερο σφάλμα στο one-step ahead prediction, να μπορούσαμε να προβλέψουμε το ΗΕΓ για μερικά δευτερόλεπτα στο μέλλον.

4.6 Βιβλιογραφία

- [1] D. Bassi and O. Olivares, “Medium Term Electric Load Forecasting Using TLFN Neural Networks,” vol. I, no. 2, pp. 23–32, 2006.
- [2] Y. Sun, V. Babovic, and E. S. Chan, “Multi-step-ahead model error prediction using time-delay neural networks combined with chaos theory,” *Journal of Hydrology*, vol. 395, no. 1–2, pp. 109–116, Dec. 2010.
- [3] D. Shi, “Time-delay neural network for the prediction of carbonation tower’s temperature,” *IEEE Transactions on Instrumentation and Measurement*, vol. 52, no. 4, pp. 1125–1128, Aug. 2003.
- [4] G. Zhang and M. Y. Hu, “Neural Network Forecasting of the British Pound/US Dollar Exchange Rate.” 1997.
- [5] A. Alkan, E. Koklukaya, and A. Subasi, “Automatic seizure detection in EEG using logistic regression and artificial neural network.,” *Journal of neuroscience methods*, vol. 148, no. 2, pp. 167–76, Oct. 2005.
- [6] M. H. Beale, M. T. Hagan, and H. B. Demuth, “Neural Network Toolbox™ User’s Guide,” *Order A Journal On The Theory Of Ordered Sets And Its Applications*.
- [7] N. Guler, E. Ubeyli, and I. Guler, “Recurrent neural networks employing Lyapunov exponents for EEG signals classification,” *Expert Systems with Applications*, vol. 29, no. 3, pp. 506–514, Oct. 2005.
- [8] T. a. E. Ferreira, G. C. Vasconcelos, and P. J. L. Adeodato, “A New Intelligent System Methodology for Time Series Forecasting with Artificial Neural Networks,” *Neural Processing Letters*, vol. 28, no. 2, pp. 113–129, Sep. 2008.
- [9] T. Ozel and Y. Karpas, “Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks,” *International Journal of Machine Tools and Manufacture*, vol. 45, no. 4–5, pp. 467–479, Apr. 2005.
- [10] G. B. Sahoo, S. G. Schladow, and J. E. Reuter, “Forecasting stream water temperature using regression analysis, artificial neural network, and chaotic non-linear dynamic models,” *Journal of Hydrology*, vol. 378, no. 3–4, pp. 325–342, Nov. 2009.
- [11] C. Man-chung, W. Chi-cheong, and L. A. M. Chi-chung, “Financial Time Series Forecasting by Neural Network Using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization,” *Compute*.

Κεφάλαιο 5: Ανίχνευση επιληπτικών κρίσεων

5.1 Εισαγωγή

Όπως αναφέρθηκε και στο προηγούμενο κεφάλαιο, δεν παρατηρήθηκαν ικανοποιητικά αποτελέσματα στην προσπάθειά να προβλέψουμε τις τιμές του εγκεφαλογραφήματος αρκετά βήματα μπροστά ώστε να μπορεί να φανεί χρήσιμο για πρόβλεψη επιληπτικών κρίσεων. Παρόλαυτά, παρατηρήσαμε σημαντική αύξηση στη τιμή του σφάλματος της πρόβλεψης κατά τις επιληπτικές κρίσεις του ασθενή. Αποφασίσαμε λοιπόν να εξετάσουμε αν αυτό συμβαίνει συστηματικά και σε άλλους ασθενείς, κατά πόσο παρατηρείται και κατά τις μεσοκρυσικές περιόδους καθώς και σε ποια χρονική στιγμή σε σχέση με την έναρξη (onset) της κρίσης συμβαίνει αυτό. Αναπτύχθηκε έτσι ένας αλγόριθμος για να εξετάσουμε τη δυνατότητα χρήσης αυτού του χαρακτηριστικού των δικτύων για την ανίχνευση (detection), ή πρώιμη ανίχνευση (early detection) αν αυτό ήταν δυνατό, των επιληπτικών κρίσεων ενός ασθενή.

Ο αλγόριθμος χρησιμοποιεί μόνο ένα κανάλι του εγκεφαλογραφήματος για να κάνει την ανίχνευση των κρίσεων. Ο αλγόριθμος εφαρμόστηκε σε 6 ασθενείς στα 3 εστιακά (focal) κανάλια του καθενός ξεχωριστά, και αξιολογήθηκε με βάση την ευαισθησία ανίχνευσης και την ειδικότητα του για αυτούς τους ασθενείς, όπως γίνεται και στην αντίστοιχη βιβλιογραφία [1]. Επιλέξαμε να ασχοληθούμε μόνο με τα εστιακά (focal) κανάλια των ασθενών, καθώς μετά από πειραματισμούς με τα μη εστιακά (extra-focal) κανάλια δεν καταφέραμε να εντοπίσουμε στις τιμές των σφαλμάτων τους διαφοροποιήσεις ανάμεσα στις περιόδους των επιληπτικών κρίσεων και των μεσοκρυσικών περιόδων. Δεδομένου ότι επεξεργαζόμαστε εγκεφαλογράφημα βάθους το αποτέλεσμα αυτό συνάδει με αυτό που θα περιμέναμε.

5.2 Περιγραφή του αλγορίθμου για την ανίχνευση των επιληπτικών κρίσεων

Ο αλγόριθμος που αναπτύχθηκε κάνει την ανίχνευση των επιληπτικών κρίσεων σε έξι βήματα. Παρακάτω αναλύονται τα βήματα του αλγορίθμου και οι παράμετροί τους και σχολιάζεται η λειτουργία του κάθε βήματος.

5.2.1. Βήμα 1ο: Εκπαίδευση δικτύων

Για το πρώτο βήμα του αλγορίθμου εκπαιδεύτηκε ένα δίκτυο ανά κανάλι του ασθενή, ώστε αυτό να κάνει την καλύτερη δυνατή πρόβλεψη ΗΕΓ τιμών. Στη συνέχεια το δίκτυο τροφοδοτήθηκε με όλο το καταγεγραμμένο ΗΕΓ του ασθενή (σε παράθυρα σύμφωνα με τον αριθμό των καθυστερήσεων του). Με αυτό τον τρόπο προβλέφθηκε κάθε timestep του σήματος με βάση τα προηγούμενα D timesteps αυτού (όπου D ο αριθμός των

καθυστερήσεων του δικτύου). Προφανώς για κάθε αρχείο των δεδομένων η πρόβλεψη ξεκινάει από το sample D+1 , αφού για τα πρώτα D samples δεν υπάρχει αρκετή πρότερη πληροφορία για να προβλεφθούν. Δεδομένου όμως της μικρής τιμής του D(≤ 100) αυτό δεν δημιουργεί κάποιο ιδιαίτερο πρόβλημα στον αλγόριθμο.

5.2.2. Τα δίκτυα

Όπως περιγράψαμε και παραπάνω, από την εκπαίδευση πολλών δικτύων και την αξιολόγηση της επίδοσής τους για την πρόβλεψη των τιμών του ΗΕΓ προέκυψε εμπειρικά ότι η αύξηση του αριθμού των νευρώνων βελτιώνει την πρόβλεψη αλλά όχι όσο ραγδαία την βελτιώνει η αύξηση του αριθμού των χρονικών καθυστερήσεων του δικτύου. Προσπαθώντας λοιπόν να επιλέξουμε μια αρχιτεκτονική δικτύου που θα έκανε την καλύτερη δυνατή πρόβλεψη με αποδεκτό υπολογιστικό κόστος (δεδομένου και του μεγάλου όγκου δεδομένων που είχαμε επιλέξει να επεξεργαστούμε, αλλά και του γεγονότος ότι θα έπρεπε να εκπαιδεύσουμε 18 δίκτυα - 6 ασθενείς x 3 focal κανάλια ο καθένας), καταλήξαμε στη χρήση ενός δικτύου 16 νευρώνων με 100 καθυστερήσεις. Τα υπόλοιπα χαρακτηριστικά του δικτύου παρέμειναν ίδια με αυτά που περιγράφηκαν στο κεφάλαιο 4 και το μέγεθος του δείγματος εκπαίδευσης για τα δίκτυά μας επιλέχθηκε ίσο με 100.000 samples (390,625 sec δηλαδή 6,51 min) .

Ωστόσο, ο στόχος των δικτύων στον αλγόριθμο μας δεν είναι η πρόβλεψη των τιμών του ΗΕΓ, αλλά η “παραγωγή” όσο το δυνατόν μεγαλύτερων σφαλμάτων για τις επιληπτικές κρίσεις σε σχέση με τα σφάλματα που παρατηρούνται για τις κανονικές μεσοκριστικές περιόδους. Έτσι, το γεγονός ότι ένα δίκτυο έχει καλή απόδοση στην πρόβλεψη των τιμών του ΗΕΓ δεν σημαίνει ότι θα αποδίδει και στον αλγόριθμό καλύτερα από ένα δίκτυο με χειρότερη απόδοση στην πρόβλεψη. Ιδανικά, θα έπρεπε να είχαμε βρει κάποιο τρόπο ώστε να εκπαιδεύουμε όλο τον αλγόριθμο μαζί, έτσι ώστε το δίκτυό μας να εκπαιδευτεί για την εργασία ακριβώς που το προορίζουμε. Ωστόσο η υλοποίηση ενός αλγορίθμου εκπαίδευσης για κάτι τέτοιο, με τη οπισθοδιάδοση του σφάλματος (backpropagation) για ολόκληρο τον αλγόριθμο ξεφεύγει από τα πλαίσια της παρούσας διπλωματικής. Εναλλακτικά , θα μπορούσαμε να δοκιμάσουμε διαφορετικού μεγέθους (και απόδοσης) δίκτυα για να διαλέξουμε εμπειρικά το βέλτιστο μέγεθος νευρώνων και καθυστερήσεων. Ωστόσο, ο υπολογιστικός χρόνος που θα απαιτούσε μια τέτοια εφαρμογή , έστω και για 10-15 δίκτυα είναι απαγορευτικός.

Για να υπάρχει ένα μέτρο σύγκρισης ανάμεσα στην απόδοση πρόβλεψης των δικτύων και την απόδοσή τους στον αλγόριθμό μας, επιλέξαμε πέρα από το δίκτυο με τους 16 νευρώνες και τις 100 καθυστερήσεις να τρέξουμε την ίδια προσομοίωση και με άλλο ένα δίκτυο με χειρότερο αναμενόμενο performance. Ωστόσο δεν ήταν στόχος μας να χρησιμοποιήσουμε ένα δίκτυο που να κάνει επίτηδες “κακή” πρόβλεψη τιμών. Κάτι τέτοιο πιθανώς θα σήμαινε ότι το δίκτυο δεν αξιοποιεί επαρκώς την πληροφορία που δέχεται ως είσοδο από τις παρελθούσες τιμές του ΗΕΓ, και άρα δεν θα ήταν χρήσιμο ούτε για τον αλγόριθμο. Αντίθετα, χρειαζόταν ως μέτρο σύγκρισης ένα δίκτυο που να έχει performance σαφώς χειρότερο από αυτό του δικτύου των 16 νευρώνων και 100 καθυστερήσεων αλλά όχι το χειρότερο δυνατό. Επιλέχθηκε ένα δίκτυο 16 νευρώνων και 32 καθυστερήσεις, μέγεθος που φαίνεται να καλύπτει τις παραπάνω προϋποθέσεις.

Οι υπόλοιπες παράμετροι της εκπαίδευσης (early stopping, αλγόριθμος εκπαίδευσης κλπ) παρέμειναν οι ίδιες με αυτές που αναφέρονται στο κεφάλαιο 4.

5.2.3. Βήμα 2ο: Εξαγωγή σφαλμάτων

Στη συνέχεια εξάγαμε το σφάλμα της πρόβλεψης των δικτύων, παίρνοντας την απόλυτη τιμή της διαφοράς της πραγματικής τιμής του ΗΕΓ με αυτή που είχε προβλεφθεί, και αποθηκεύσαμε τη χρονοσειρά των σφαλμάτων.


Επιλέχθηκε να χρησιμοποιηθεί σαν στατιστικό για τον αλγόριθμό το απόλυτο σφάλμα των προβλέψεων του δικτύου, όπου

$$\text{απόλυτο σφάλμα} = |\text{έξοδος δικτύου} - \text{επιθυμητή έξοδος}|$$

Αρχικά πρόθεσή μας ήταν να χρησιμοποιηθεί το σχετικό σφάλμα, όπου

$$\text{σχετικό σφάλμα} = \frac{|\text{έξοδος δικτύου} - \text{επιθυμητή έξοδος}|}{|\text{επιθυμητή έξοδος}|}$$

Υπήρξαν ωστόσο σημαντικά προβλήματα στη χρήση του σχετικού σφάλματος. Το βασικότερο από αυτά είναι ότι στα δείγματα που η πραγματική τιμή του ΗΕΓ ήταν αρκετά μικρότερη από 1, το σχετικό σφάλμα προκύπτει υπερβολικά μεγάλο. Πχ, η τιμή του ΗΕΓ για το 15ο sample στο παρακάτω γράφημα είναι -0,0008 με αποτέλεσμα το σχετικό σφάλμα σε αυτό το timestep να βγαίνει ίσο με 50.000, ενώ τα σχετικά σφάλματα πρόβλεψης των υπόλοιπων samples που φαίνονται στο γράφημα είναι τα περισσότερα πολύ μικρότερα του 1. Προφανώς αυτή η τιμή δεν αντικατοπτρίζει την πραγματική απόκλιση του αποτελέσματος της πρόβλεψης.



Σχήμα 5.1: Παράδειγμα πραγματικού και προβλεπόμενου ΗΕΓ

Για την ανίχνευση των κρίσεων λοιπόν χρησιμοποιήσαμε το απόλυτο σφάλμα πρόβλεψης του δικτύου μας και όχι το σχετικό σφάλμα για δύο λόγους:

1. Ο πρώτος είναι ότι σύμφωνα με τη βιβλιογραφία [2] η αύξηση του πλάτους του εγκεφαλικού σήματος είναι ένα από τα χαρακτηριστικά (features) που χρησιμοποιούνται για την ανίχνευση μιας επιληπτικής κρίσης, οπότε καλό θα ήταν να μην κόψουμε την πληροφορία αυτή από τα δεδομένα μας χρησιμοποιώντας το σχετικό σφάλμα.
2. Όπως αναφέρεται και παραπάνω, παρατηρούμε τεράστιες τιμές σχετικού σφάλματος σε αρκετά σημεία, με αποτέλεσμα η ανίχνευση να γίνεται πολύ πιο δύσκολη.

5.2.4. Βήμα 3ο: Άθροιση σφαλμάτων

Ωστόσο, η μεμονωμένη τιμή του απόλυτου σφάλματος ενός timestep δεν προσέφερε και πολύ μεγάλη πληροφορία σε σχέση με το κατά πόσο μια περίοδος είναι επιληπτική ή όχι. Αυτή η μεμονωμένη χρονικά πληροφορία μπορεί να αναφέρεται σε ένα σφάλμα του δικτύου που θα μπορούσε να είναι ακόμα και τυχαίο καθώς παρατηρούνται σημαντικές διακυμάνσεις της ακρίβειας πρόβλεψης. Θα ήταν άλλωστε και παράδοξο σε μια επιληπτική περίοδο να παρατηρούμε ότι ένα και μόνο δείγμα (1/256 sec δηλαδή) του ΗΕΓ είναι “απρόβλεπτο”, ενώ όλα τα υπόλοιπα γύρω του προβλέπονται φυσιολογικά. Θα πρέπει λοιπόν να παρατηρήσουμε συστηματική εμφάνιση μεγάλων αποκλίσεων ανίχνευσης για να θεωρήσουμε ότι ανιχνεύουμε επιληπτική περίοδο. Έτσι αποφασίσαμε να “άθροισουμε” τα σφάλματα ώστε να μην παρατηρούμε μεμονωμένες τιμές τους, αλλά περιοχές με μεγαλύτερο ή μικρότερο σφάλμα. Το σήμα του σφάλματος φιλτραρίστηκε με ένα φίλτρο κινούμενου μέσου (moving average) με μεταβλητό παράθυρο σε μια προσπάθεια να προκύψουν τιμές που να αντιπροσωπεύουν την μέση τιμή του σφάλματος σε μια χρονική περίοδο και όχι μεμονωμένα σφάλματα. Το παράθυρο αυτό είναι ένα από τα χαρακτηριστικά του αλγορίθμου το οποίο επηρεάζει το αποτέλεσμα της ανίχνευσης, και για αυτό χρειάστηκε να το μεταβάλλουμε. Συγκεκριμένα δοκιμάστηκαν παράθυρα μήκους 20, 300 και 700 samples (0,078 sec , 1,17 sec και 2,73 sec αντίστοιχα) και στα αποτελέσματα σχολιάζεται η επίδραση της τιμής του παραθύρου στην απόδοση του αλγορίθμου.

Η επιλογή των τριών αυτών παραθύρων έγινε με τη λογική ότι παράθυρα μήκους πάνω από 700 δείγματα θα χρησιμοποιούσαν πληροφορία από πολύ μελλοντικά δείγματα, ενώ παράθυρα μικρότερα από 20 δείγματα δεν θα άθροιζαν αρκετή πληροφορία ώστε να ξεπεράσουμε το μεμονωμένο χαρακτήρα της ανίχνευσης μεγάλου σφάλματος που μπορεί να μην οφείλεται σε κάτι συστηματικό που παρατηρείται στο σφάλμα και χαρακτηρίζει μια γενικότερη χρονική περίοδο όπως είναι μια επιληπτική περίοδος.

Το φιλτράρισμα στο Matlab έγινε με τη ρουτίνα

```
filtfilt(ones(1,windowSize)/windowSize,1,err);
```

όπου `windowSize` το μέγεθος του παραθύρου και `err` η χρονοσειρά των αποκλίσεων της πρόβλεψης των δικτύων μας.

5.2.5. Βήμα 4ο: Κατωφλίωση

Σε αυτό το βήμα καθορίζεται αν ένα timestep είναι επιληπτικό. Αυτό γίνεται με τη χρήση ενός κατωφλίου. Αν η τιμή του απόλυτου σφάλματος μετά το φιλτράρισμα με το moving average ξεπερνάει το δεδομένο κατώφλι, θεωρούμε ότι το συγκεκριμένο timestep είναι “επιληπτικό”.

5.2.6. Βήμα 5ο: Εφαρμογή χρονικού παραθύρου

Τέλος παρατηρήσαμε ότι η κύρια πηγή ΨΑ στα μεσοκρυσικά δεδομένα μας ήταν η ανίχνευση μεμονωμένων “επιληπτικών” δειγμάτων, η ακολουθιών από περιορισμένο αριθμό “επιληπτικών” δειγμάτων. Τελευταίο κριτήριο λοιπόν για την ανίχνευση μιας επιληπτικής κρίσης είναι η ύπαρξη τουλάχιστον 200 συνεχόμενων “επιληπτικών” σημείων. Είναι σαφές ότι αυξάνοντας το μέγεθος αυτού του παραθύρου προσπαθούμε να βελτιώσουμε την ειδικότητα του αλγορίθμου μας, χωρίς ωστόσο να χάνουμε από την ευαισθησία. Έτσι με την εισαγωγή αυτού του παραθύρου, “κόβουμε” κάποια ΨΑ, σε περιπτώσεις ιδιαίτερα που εμφανίζεται μια πολύ τοπική (χρονικά) ανωμαλία στο σφάλμα πρόβλεψης, αλλά φροντίζουμε το παράθυρό μας να μην είναι τέτοιο ώστε να χάνουμε κάποια επιληψία.

Η τιμή αυτή του παραθύρου (200 συνεχόμενα “επιληπτικά” σημεία) βγήκε μετά από παρατήρηση στο σήμα σφάλματος των ασθενών και δειγματοληπτική επισκόπηση της διάρκειας των κορυφών (spikes) που εμφανίζονται στο σήμα σφάλματος στα μεσοκρυσικά διαστήματα σε σχέση με τη διάρκεια των επιληψιών που εντοπίζουμε κατά τα επιληπτικά διαστήματα. Επιλέχθηκε έτσι εμπειρικά μια τιμή τέτοια ώστε να κόβει όσο το δυνατόν περισσότερες ΨΑ χωρίς να επηρεάζει καθόλου την ευαισθησία ανίχνευσης του αλγορίθμου. Περαιτέρω πειραματισμός με τη μεταβολή της τιμής αυτής έχει σαν αποτέλεσμα είτε την μείωση της ευαισθησίας είτε την μείωση των ΨΑ εις βάρος όμως της καθυστέρησης ανίχνευσης – είναι ένα tradeoff που μπορεί να προκύψει και μέσα από τη μεταβολή του παραθύρου ή της τιμής του κατωφλίου του αλγορίθμου.

Αξίζει εδώ να σχολιάσουμε την επιλογή μας να έχουμε δύο “παραθυροποιήσεις” στον αλγόριθμό μας (το παράθυρο του moving average filter και το χρονικό που περιγράφεται εδώ). Το παράθυρο των moving averages ουσιαστικά εξομαλύνει το σήμα των σφαλμάτων και μας διευκολύνει στη συνέχεια να κατατάξουμε το σήμα σε περιόδους με βάση την μέση τιμή του σφάλματος. Το χρονικό παράθυρο από την άλλη κατηγοριοποιεί τις περιόδους μόνο με βάση τη διάρκεια που οι τιμές υπερβαίνουν το κατώφλι, χωρίς να λαμβάνει υπόψη τις ακριβείς τιμές. Έτσι αν έχουμε ένα spike στο σφάλμα πρόβλεψης, πολύ μεγάλης τιμής αλλά μικρής διάρκειας, και προσπαθούμε να το εξομαλύνουμε μόνο με το moving average παράθυρο θα χρειαστεί να αυξήσουμε πάρα πολύ την τιμή του παραθύρου στο φίλτρο μας για να το κόψουμε. Αντίθετα με την χρονική “παραθυροποίηση” κάτι τέτοιο θα μπορούσαμε να το κόψουμε πάρα πολύ εύκολα βασιζόμενη μόνο στη διάρκειά του.

5.2.7. Βήμα 6ο: Εξαγωγή αποτελεσμάτων

Μετά από τα παραπάνω βήματα, καταγράφονται οι επιληψίες που έχουν ανιχνευθεί θεωρώντας σαν αρχή της επιληψίας την πρώτη τιμή για την οποία η τιμή του φιλτραρισμένου σφάλματος υπερβαίνει το κατώφλι και σαν τέλος της την τελευταία τιμή του σφάλματος που υπερβαίνει το κατώφλι.

Αξίζει εδώ να σημειωθεί ότι για τον εντοπισμό της έναρξης της κρίσης χρησιμοποιείται και πληροφορία που προέρχεται από χρονικά βήματα μετά από το δείγμα που εντοπίζουμε σαν έναρξη. Αυτό συμβαίνει εξαιτίας των παραθύρων που χρησιμοποιούνται. Έτσι αν τρέχαμε τον αλγόριθμο αυτό σε πραγματικό χρόνο δεν θα μπορούσαμε να ανιχνεύσουμε το onset των κρίσεων τόσο έγκαιρα. Ουσιαστικά σε on-line τρέξιμο του αλγορίθμου, η επιλογή του μεγέθους των δύο παραθύρων καθορίζει και την ελάχιστη τιμή της καθυστέρησης για την ανίχνευση που κάνουμε σε σχέση με την έναρξη της επιληπτικής κρίσης. Αυτό σημαίνει ότι αν χρησιμοποιηθεί ένα παράθυρο πχ 20 δειγμάτων για τον κινούμενο μέσο θα χρειαστεί για την κάθε χρονική στιγμή πληροφορία τόσο για 10 δείγματα πριν από αυτή, όσο και 10 δείγματα μετά. Άρα αν ανιχνεύεται έναρξη επιληψίας εκεί κατά το τρέξιμο το αλγορίθμου, στο online τρέξιμο θα παρατηρούσαμε την έναρξη 10 δείγματα πιο μετά. Ωστόσο με ένα παράθυρο μεγέθους 700, θα το παρατηρούσαμε 350 δείγματα πιο μετά. Βλέπουμε λοιπόν ότι η επιλογή τιμής για το παράθυρο της άθροισης επηρεάζει πέρα από τον αλγόριθμο όπως τον χρησιμοποιούμε σε μεγάλο βαθμό και την πιθανή online χρήση του.

Επιλέξαμε ωστόσο να μην λάβουμε υπόψη στα αποτελέσματα που παρουσιάζουμε την καθυστέρηση που θα προκαλούσε η χρήση των παραθύρων σε online εφαρμογή του αλγορίθμου. Επιλέξαμε να κάνουμε την ανίχνευση ουσιαστικά στα ήδη καταγεγραμμένα στοιχεία, δεδομένου ότι ούτως ή άλλως ο στόχος μας είναι περισσότερο το να εξετάσουμε το κατά πόσο τα επιληπτικά δεδομένα είναι πιο απρόβλεπτα από τα μη επιληπτικά και να αξιολογήσουμε το πώς αυτό θα μπορούσε να χρησιμοποιηθεί για την ανίχνευση, και λιγότερο το να υλοποιήσουμε ένα λειτουργικό on-line σύστημα ανίχνευσης επιληπτικών κρίσεων. Έτσι μας νοιάζει πιο πολύ το πότε αρχίζει το σήμα να γίνεται λιγότερο προβλέψιμο και δευτερευόντως το πώς ακριβώς θα υλοποιούσαμε ένα πρόγραμμα που θα εντόπιζε αυτή την αλλαγή στην προβλεψιμότητα του σήματος σε πραγματικό χρόνο.

Τέλος, στα αποτελέσματά ομαδοποιήθηκαν οι επιληψίες που εντοπίστηκαν για τις οποίες η έναρξη της μιας απείχε λιγότερο από 40 sec από το τέλος της προηγούμενης και θεωρήθηκαν ως μία επιληψία. Το ίδιο γίνεται και στη σχετική βιβλιογραφία [3][4].

Στην καταγραφή των αποτελεσμάτων, θεωρήθηκε ως σωστή ανίχνευση κάθε ανίχνευση κρίσης για την οποία το onset που ανιχνεύουμε βρίσκεται από 10 sec πριν την αρχή της καταγεγραμμένης επιληψίας του ασθενή έως το τέλος της επιληψίας. Κάθε άλλη ανίχνευση που κάνει ο αλγόριθμός καταγράφεται ως ψευδής ανίχνευση. Για κάθε επιληπτική κρίση μετράμε την καθυστέρηση ανίχνευσής της που είναι ίση με το onset που εντοπίζουμε μείον το πραγματικό onset της κρίσης. Όταν η τιμή της καθυστέρησης είναι αρνητική, σημαίνει ότι ανιχνεύουμε την κρίση πριν αυτή ξεκινήσει να συμβαίνει.

5.3 Εκτέλεση του αλγορίθμου και παράμετροι που μεταβάλλονται

Στο τρέξιμο του αλγορίθμου αυτό που ψάχνουμε ουσιαστικά να βρούμε είναι το βέλτιστο κατώφλι του βήματος 2 (κατωφλίωση) του αλγορίθμου μας για τον εντοπισμό των κρίσεων. Ωστόσο, μεταβάλλοντας το κατώφλι γίνεται σαφές ότι για το κατώφλι αυτό δεν υπάρχει μόνο μια αποδεκτή τιμή και ότι υπάρχουν διαφορετικές τιμές που μπορούμε να θεωρήσουμε αποδεκτές.

Ένα κριτήριο που χρησιμοποιούμε για το κατώφλι, τον καθορισμό του οποίου μπορούμε να κάνουμε αυτόματα και που μπορούμε να θεωρήσουμε κατά μια έννοια βέλτιστο, είναι το μέγιστο κατώφλι για το οποίο ανιχνεύουμε όλες τις επιληψίες. Όπως έχουμε εξηγήσει η αύξηση του κατωφλίου μειώνει τον αριθμό των ψευδών, αλλά και των αληθών ανιχνεύσεων. Έτσι, υπάρχει μια μέγιστη τιμή κατωφλίου για την οποία εντοπίζουμε όλες τις κρίσεις. Από αυτή την τιμή και πάνω χάνουμε 1 τουλάχιστον κρίση. Από αυτή την τιμή και κάτω κάνουμε περισσότερα ΨΑ. Έτσι, όσον αφορά την ευαισθησία και την ειδικότητα, η τιμή αυτή μας δίνει την βέλτιστη τιμή ειδικότητας για ευαισθησία=100%.

Υπάρχει ωστόσο ένα σημαντικό πρόβλημα με αυτό τον τρόπο καθορισμού του κατωφλίου. Αυτό είναι ότι με αυτό τον τρόπο δεν λαμβάνεται καθόλου υπόψιν η καθυστέρηση ανίχνευσης της επιληψίας. Έτσι εμφανίζονται περιπτώσεις για τις οποίες ένα κατώφλι μικρότερο από το μέγιστο δυνατό για την ανίχνευση όλων των επιληψιών δίνει παραπλήσια αποτελέσματα ως προς την ειδικότητα ανίχνευσης, κάνοντας αυτή την πρόβλεψη πολύ πιο έγκαιρα. Ένα τέτοιο παράδειγμα από τον ασθενή 9 αναλύεται παρακάτω:

Για παράθυρο 50 το μέγιστο κατώφλι για να ανιχνεύουμε όλες τις επιληψίες είναι 247. Για αυτό το κατώφλι ανιχνεύουμε όλες τις επιληψίες με μέση καθυστέρηση 4776,400 δείγματα, δηλαδή

$$\text{μέσος χρόνος καθυστέρησης} = 18,6578125 \text{ sec}$$

Κάναμε επίσης 15 ΨΑ, και καθώς για τον ασθενή 9 έχουμε 33.9342 ώρες ΗΕΓ άρα αυτό αντιστοιχεί σε

$$\text{αριθμός ψευδών ανιχνεύσεων ανά ώρα} = 0,442$$

Αν ωστόσο μειώσουμε το κατώφλι, εις βάρος του αριθμού των ψευδών ανιχνεύσεων, τότε η καθυστέρηση ανίχνευσης αλλάζει αρκετά. Έτσι για παράδειγμα, για κατώφλι 220 έχουμε


$$\text{μέσος χρόνος καθυστέρησης} = 3,075 \text{ sec}$$

και

$$\text{αριθμός ψευδών ανιχνεύσεων ανά ώρα} = 0,50$$

Πρέπει εδώ να σημειώσουμε ότι στον συγκεκριμένο ασθενή, η τόσο μεγάλη μεταβολή της καθυστέρησης ανίχνευσης οφείλεται στην 4η επιληψία, για την οποία η γραφική

παράσταση του σφάλματος φαίνεται στο παρακάτω διάγραμμα (για καλύτερη ευκρίνεια , έχουμε σχεδιάσει για running averages window = 700)



Σχήμα 5.2: Σφάλμα τέταρτης κρίσης ασθενή 9, για παράθυρο κινούμενων μέσων=700

Στο παραπάνω διάγραμμα η επιληψία αρχίζει στο δείγμα 10.123 και τελειώνει στο δείγμα 32.589. Όπως βλέπουμε το σφάλμα πράγματι αυξάνει πολύ στην αρχή ακριβώς της επιληπτικής κρίσης. Αν ,ωστόσο, το κατώφλι μας δεν είναι αρκετά χαμηλό ώστε να ανιχνεύσουμε την πρώτη κορυφή, δεν θα χάσουμε την κρίση, αλλά θα ανιχνεύσουμε την δεύτερη κορυφή, που συμβαίνει κοντά στο τέλος της επιληπτικής κρίσης. Αυτός είναι και ο λόγος που η μέση καθυστέρηση ανίχνευσης είναι τόσο μεγάλη στην πρώτη περίπτωση του κατωφλίου. Προφανώς αυτό παρατηρείται για τα περισσότερα μήκη παραθύρου.

Είναι σαφές ότι το δεύτερο κατώφλι με την καλή απόδοση στην καθυστέρηση ανίχνευσης είναι αυτό που θα διαλέγαμε σαν βέλτιστο. Όχι μόνο τα αποτελέσματα του είναι καλύτερα, αλλά μας δείχνει και με πιο αντιπροσωπευτικό τρόπο τη μεταβολή του σφάλματος της πρόβλεψης στον ασθενή μας, και άρα τις δυνατότητες του αλγορίθμου που εξετάζουμε.

Έτσι, στην παρουσίαση των αποτελεσμάτων που παραθέτουμε αρχικά τα αποτελέσματα για το μέγιστο επιτρεπτό κατώφλι για την ανίχνευση όλων των επιληψιών και στη συνέχεια εφόσον υπάρχουν καλύτερα αποτελέσματα για κάποιο άλλο κατώφλι παραθέτουμε και αυτά.

5.4 Απόδοση του αλγορίθμου

Η απόδοση του αλγορίθμου αξιολογείται με βάση 3 κριτήρια. Καταρχήν με βάση την ευαισθησία ανίχνευσης (sensitivity, δηλαδή το ποσοστό των κρίσεων τις οποίες εντοπίζουμε σε σχέση με αυτές που συμβαίνουν) και την ειδικότητα (selectivity, δηλαδή τον αριθμό των ανιχνεύσεων που γίνονται οι οποίες δεν αντιστοιχούν σε κρίσεις που συμβαίνουν στον ασθενή, τις ψευδείς δηλαδή ανιχνεύσεις). Σύμφωνα με τη συνήθη πρακτική, μετράμε την ειδικότητα σε ψευδείς ανιχνεύσεις ανά ώρα (false-positive errors per hour FPH)[9]

$$\text{ευαισθησία} = \frac{\text{Αριθμός κρίσεων που εντοπίζονται}}{\text{Αριθμός κρίσεων του ασθενή}}$$

$$\text{ειδικότητα} = \frac{\text{Αριθμός ψευδών ανιχνεύσεων}}{\text{Συνολική χρονική διάρκεια EEG του ασθενή}}$$


Τέλος μετράμε το πόσο καθυστερεί ο αλγόριθμος να εντοπίσει την κάθε κρίση, και για τον κάθε ασθενή παραθέτουμε την μέση τιμή των καθυστερήσεων ανίχνευσης για τις επιληπτικές του κρίσεις.

5.5 Αποτελέσματα

Παρακάτω φαίνονται τα αποτελέσματα ανά ασθενή όπως καταγράφηκαν κατά το τρέξιμο του αλγορίθμου. Ταυτόχρονα αναλύονται και κάποιες ιδιαιτερότητες του τρεξίματος για τον κάθε ασθενή.

5.5.1 Ασθενής 9

Ο ασθενής 9 έχει σύνθετες εστιακές (complex partial) και γενικευμένες τονικλονικές (generalized tonic-clonic) επιληπτικές κρίσεις και η καταγραφή έχει γίνει με ηλεκτρόδια πλέγματος (grid electrode) και ταινίας (strip electrode). Στις παρακάτω εικόνες φαίνεται η σχετική διάταξη καταγραφής EEG βάθους για τον ασθενή:



Σχήμα 5.3: Θέσεις ηλεκτροδίων ασθενή 9

Η διάρκεια της μεσοκριτικής καταγραφής είναι 86163 sec και έχει γίνει σε 2 διαστήματα. Για τον ασθενή 9 έχουν καταγραφεί 5 επιληπτικές κρίσεις.

Αρχικά ο αλγόριθμος εκτελέστηκε για το μέγιστο κατώφλι για το οποίο ανιχνεύονται όλες οι επιληπτικές κρίσεις, δηλαδή για όλες τις τιμές που αναφέρονται στους πίνακες η ευαισθησία είναι 100%. Για δίκτυα 16 νευρώνων και 32 καθυστερήσεων, οι ψευδείς ανιχνεύσεις που παρατηρήσαμε για το καθένα από τα τρία κανάλια του ασθενή και για 3 διαφορετικές τιμές παραθύρου των κινούμενων μέσων φαίνονται στον πίνακα 5.1 , η αντίστοιχη ειδικότητα στον πίνακα 5.3 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.5. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων ο αριθμός των ΨΑ παρατίθεται στον πίνακα 5.2 , η ειδικότητα στον πίνακα 5.4 και οι αντίστοιχες μέσες καθυστερήσεις στον πίνακα 5.6

Πίνακας 5.1: Αριθμός ΨΑ για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	15	12	21
300	21	26	31
700	20	19	26

Πίνακας 5.2: Αριθμός ΨΑ για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	26	23	34
300	22	32	59
700	19	21	51

Πίνακας 5.3: ΨΑ/h για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,442	0,354	0,619
300	0,619	0,766	0,914
700	0,589	0,560	0,766

Πίνακας 5.4: ΨΑ/h για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,766	0,678	1,002
300	0,648	0,943	1,739
700	0,560	0,619	1,503

Πίνακας 5.5: Μέση καθυστέρηση ανίχνευσης (sec) για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	18,98	19,09	19,01
300	19,6	15,89	18,98
700	18,62	18,51	18,79

Πίνακας 5.6: Μέση καθυστέρηση ανίχνευσης (sec) για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	17,51	18,81	17,94
300	24,11	18,32	17,91
700	18,56	18,32	18,33

Ωστόσο, όπως αναφέραμε και παραπάνω για τον ασθενή 9 υπάρχει ένα μικρότερο κατώφλι για το οποίο έχουμε πολύ καλύτερα αποτελέσματα για την καθυστέρηση της ανίχνευσης των κρίσεων. Τα αποτελέσματα για αυτό το καλύτερο κατώφλι φαίνονται στους παρακάτω πίνακες, τόσο για δίκτυα 32 όσο και για δίκτυα 100 καθυστερήσεων:

Πίνακας 5.7: ΨΑ για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	17	21	36
300	39	38	65
700	25	29	43

Πίνακας 5.8: ΨΑ για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	35	27	48
300	48	39	86
700	30	30	74

Πίνακας 5.9: ΨΑ ανά ώρα για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,501	0,619	1,061
300	1,149	1,120	1,915
700	0,737	0,855	1,267

Πίνακας 5.10: ΨΑ ανά ώρα για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	1,031	0,796	1,415
300	1,415	1,149	2,534
700	0,884	0,884	2,181

Πίνακας 5.11: Μέση καθυστέρηση (sec) για ασθενή 9 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	3,46	3,21	3,14
300	2,12	1,55	2,26
700	3,54	1,52	2,36

Πίνακας 5.12: Μέση καθυστέρηση (sec) για ασθενή 9 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	1,48	3,16	2,86
300	1,88	3,05	1,97
700	2	1,36	1,73

Γενικά, μπορούμε να πούμε ότι τα αποτελέσματα της ανίχνευσης, ειδικά για την δεύτερη περίπτωση είναι αρκετά ικανοποιητικά. Για τα περισσότερα παράθυρα των καναλιών 1 και 2, έχουμε ΨΑ/h μικρότερο του 1 και η καθυστέρηση ανίχνευσης για τις αντίστοιχες περιπτώσεις είναι 2-3 sec. Έχει επίσης ενδιαφέρον να παρατηρήσουμε, ότι άσχετα με το κανάλι και τις παραμέτρους φαίνεται να υπάρχει ένα σχετικά (αλλά όχι απόλυτα) σταθερό tradeoff μεταξύ μέσης καθυστέρησης ανίχνευσης και αριθμού συνολικών ΨΑ. Το κανάλι 1 φαίνεται να αποδίδει καλύτερα ως προς την ειδικότητα (ΨΑ/h), ενώ το κανάλι 2 φαίνεται να αποδίδει καλύτερα όσον αφορά την καθυστέρηση για τα δίκτυα με 32 καθυστερήσεις. Για

τα δίκτυα με 100 καθυστερήσεις φαίνεται να ισχύει το ανάποδο. Εδώ είναι ενδιαφέρον για να αξιολογήσουμε το πώς συνδέεται η απόδοση των δικτύων μας στην εργασία της πρόβλεψης με την απόδοσή τους στον αλγόριθμο της ανίχνευσης που έχουμε αναπτύξει και γιαυτό παραθέτουμε έναν πίνακα με την απόδοση (performance) των δικτύων που χρησιμοποιήθηκαν για τον ασθενή 9 στην πρόβλεψη μεσοκριστικών επιληπτικών τιμών.

Πίνακας 5.13: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 9.

	ΚΑΝΑΛΙ 1	ΚΑΝΑΛΙ 2	ΚΑΝΑΛΙ 3
16N 32K	6103,3	5025,6	3248,9
16N 100κ	4412,6	4132,8	2622,7

Παρατηρούμε πράγματι ότι η απόδοση ενός νευρωνικού δικτύου στην πρόβλεψη ΗΕΓ τιμών δεν είναι ανάλογη με την απόδοσή του στον αλγόριθμο ανίχνευσης που αναπτύχθηκε. Χαρακτηριστικά βλέπουμε ότι τα δίκτυα του καναλιού 3 έχουν την καλύτερη απόδοση πρόβλεψης και την χειρότερη για την ανίχνευση.

Τέλος νομίζω ότι είναι απαραίτητο να παραθέσουμε για ένα τουλάχιστον τρέξιμο του αλγορίθμου τις επιμέρους τιμές των καθυστερήσεων, για να δείξουμε κυρίως το πόσο μικρές τιμές παίρνουν αυτές για τις περισσότερες κρίσεις. Παραθέτουμε παρακάτω τις καθυστερήσεις ανίχνευσης για κάθε επιληψία ξεχωριστά για δίκτυο 32 καθυστερήσεων με παράθυρο μεγέθους 20 για το κανάλι 1 (όπου το κατώφλι δεν είναι το μέγιστο, αλλά το κατάλληλο για να επιτύχουμε βέλτιστη ειδικευση, δηλαδή αναφέρεται στο τρέξιμο με τις 17 ΨΑ).

Πίνακας 5.14: Καθυστερήσεις ανίχνευσης (sec) για τις κρίσεις του ασθενή 9, πρώτο κατώφλι.

	επιληψία				
	1	2	3	4	5
καθυστερήση ανίχνευσης (sec)	-0,156	-0,328	12,730	4,340	0,719

Παρατηρούμε ότι εντοπίζουμε 3 στις 5 επιληψίες με καθυστέρηση κάτω από 1 sec, και μάλιστα 2 από αυτές πριν καν ξεκινήσουν να συμβαίνουν. Παρόλαυτά, η συνολική μέση καθυστέρηση είναι 3,46 sec κυρίως λόγω της πολύ μεγάλης καθυστέρησης που παρουσιάζεται στον εντοπισμό της 3ης επιληψίας. Παρακάτω παραθέτουμε και τα αντίστοιχα στοιχεία για ένα τρέξιμο με καλύτερα αποτελέσματα ως προς την καθυστέρηση.


Πίνακας 5.15: Καθυστερήσεις ανίχνευσης (sec) για τις κρίσεις του ασθενή 9, δεύτερο κατώφλι.

	επιληψία				
	1	2	3	4	5
καθυστερήση ανίχνευσης (sec)	-0,426	-0,691	3,992	4,063	0,441


Πρόκειται συγκεκριμένα για το τρέξιμο με δίκτυο 100 καθυστερήσεις και παράθυρο 20 για το κανάλι 1 και με κατώφλι τέτοιο ώστε να έχουμε βέλτιστη μέση καθυστέρηση με

ευαισθησία 100%. Η τιμή της συνολικής μέσης καθυστέρησης είναι 1,48 δευτερόλεπτα και είναι η δεύτερη μικρότερη που έχουμε εντοπίσει. Σε σχέση με το προηγούμενο τρέξιμο που παραθέσαμε, παρατηρούμε ότι έχουμε μεγάλη βελτίωση στην ανίχνευση όλων των επιληψιών εκτός από την 5η και ότι ειδικά τις πρώτες 2 τις ανιχνεύουμε μισό δευτερόλεπτο περίπου πριν την έναρξή τους.


Έχει επίσης νόημα να παραθέσουμε και τα διαγράμματα των σφαλμάτων ενός δικτύου κατά τις επιληπτικές κρίσεις του ασθενή. Συγκεκριμένα επιλέξαμε να απεικονίσουμε τα σφάλματα του δικτύου 16 νευρώνων και 32 καθυστερήσεων, που φαίνεται να έχει και την καλύτερη απόδοση. Επίσης για να είναι εμφανής η συνολική μεταβολή του σφάλματος του δικτύου, επιλέξαμε να εφαρμόσουμε και φίλτρο κινούμενου μέσου με παράθυρο 300 δειγμάτων.




Σχήμα 5.4 Η πρώτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 29.871.




Σχήμα 5.5: Η δεύτερη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 88504.



Σχήμα 5.6: Η τρίτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.363.



Σχήμα 5.7: Η τέταρτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 10.000 και τελειώνει στο 42.466.

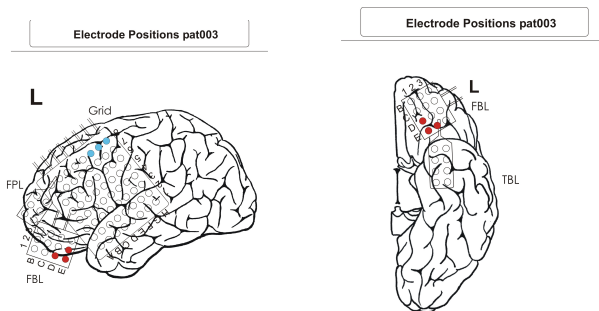


Σχήμα 5.8: Η πέμπτη κρίση του ασθενή 9, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 43.320.

Όπως μπορούμε πολύ εύκολα να παρατηρήσουμε, σε όλες τις επιληπτικές κρίσεις παρατηρείται μεγάλη και απότομη αύξηση του σφάλματος της πρόβλεψης που ταυτίζεται σχεδόν με την έναρξη της επιληπτικής κρίσης. Το σφάλμα δεν παραμένει σταθερά υψηλό καθ όλη τη διάρκεια της κρίσης, ωστόσο αυτό δεν επηρεάζει την ανίχνευση των κρίσεων, που σχετίζεται με την ανίχνευση της έναρξης της κρίσης, χωρίς να μας απασχολεί η διάρκειά της.

5.5.2 Ασθενής 3

Ο ασθενής 3 έχει σύνθετες εστιακές (complex partial) και απλές εστιακές (simple partial) επιληπτικές κρίσεις και η καταγραφή έχει γίνει με ηλεκτρόδια πλέγματος (grid electrode) και ταινίας (strip electrode). Στις παρακάτω εικόνες φαίνεται η σχετική διάταξη καταγραφής ΕΕΓ βάρους για τον ασθενή:



Σχήμα 5.9: Θέσεις ηλεκτροδίων ασθενή 3

Η διάρκεια της μεσοκρισικής καταγραφής είναι 86400 sec και έχει γίνει σε 1 διάστημα. Για τον ασθενή 3 έχουν καταγραφεί 5 επιληπτικές κρίσεις.

Ξεκινάμε από τα αποτελέσματα για το μέγιστο κατώφλι για το οποίο εντοπίζουμε όλες τις επιληψίες. Η ειδικότητα για δίκτυα 16 νευρώνων και 32 καθυστερήσεων φαίνεται στον πίνακα 5.16 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.18. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων η ειδικότητα παρατίθεται στον πίνακα 5.17 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.19.

Πίνακας 5.16: ΨΑ ανά ώρα για ασθενή 3 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	10,128	8,823	10,190
300	0,217	0,621	2,175
700	0,186	0,249	0,652

Πίνακας 5.17 : ΨΑ ανά ώρα για ασθενή 3 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,186	0,652	8,792
300	1,212	0,249	2,579
700	0,932	0,186	0,652

Πίνακας 5.18: Μέση καθυστέρηση (sec) για ασθενή 3 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	8,574	17,215	28,905
300	39,245	40,285	40,831
700	38,643	40,121	41,549

Πίνακας 5.19: Μέση καθυστέρηση (sec) για ασθενή 3 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	41,368	39,777	38,023
300	37,877	40,205	39,611
700	37,345	39,480	39,856


Το βασικό πρόβλημα που παρατηρούμε σε αυτό τον ασθενή είναι η πολύ κακή τιμή της καθυστέρησης ανίχνευσης των κρίσεων, την οποία μάλιστα δεν μπορούμε να διορθώσουμε αλλάζοντας την τιμή του κατωφλίου. Γιαντό και δεν παραθέτονται τιμές για άλλα κατώφλια εκτός από το παραπάνω.

Ένα πρώτο πράγμα που παρατηρούμε είναι πως τα δίκτυα με τις 32 καθυστερήσεις αποδίδουν σαφώς καλύτερα από αυτά με τις 100 καθυστερήσεις. Όπως βλέπουμε στον πίνακα 5.20 όπου παρατίθεται η απόδοση (mse) των δικτύων που χρησιμοποιήθηκαν στον ασθενή 3, πάλι το μέσο τετραγωνικό σφάλμα των δικτύων στην πρόβλεψη μεσοκρυσικών δεδομένων που φαίνεται στον παραπάνω πίνακα δεν συνάδει με την απόδοσή τους στον αλγόριθμό ανίχνευσης.


Πίνακας 5.20: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 3.

	ΚΑΝΑΛΙ 1	ΚΑΝΑΛΙ 2	ΚΑΝΑΛΙ 3
16N 32K	5376,3	2582,1	3401,4
16N 100K	3559,1	2218,1	3326,2


Παραθέτουμε παρακάτω τα απόλυτα σφάλματα πρόβλεψης των δικτύων κατά τις επιληπτικές κρίσεις του ασθενή. Πρόκειται για το δίκτυο μεγέθους 16 νευρώνων και 100 καθυστερήσεων που έχει εκπαιδευτεί και εφαρμοστεί στο κανάλι 1 του ασθενή. Έχει γίνει φιλτράρισμα των σφαλμάτων με φίλτρο κινούμενου μέσου με παράθυρο 300 δειγμάτων.




Σχήμα 5.10: Η πρώτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 47.808.




Σχήμα 5.11: Η δεύτερη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 50.400.



Σχήμα 5.12: Η τρίτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 49.843.



Σχήμα 5.13 Η τέταρτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 44.156.



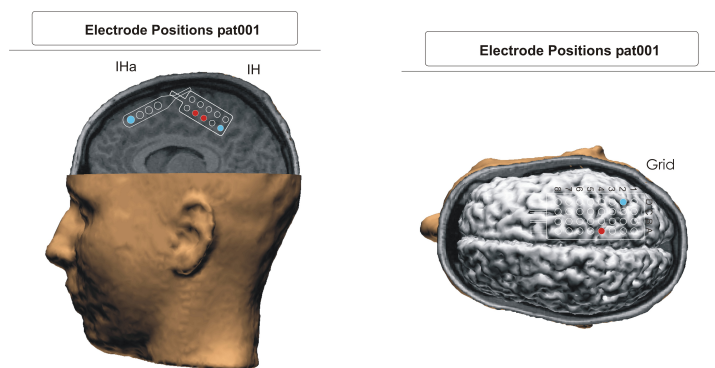
Σχήμα 5.14: Η πέμπτη κρίση του ασθενή 3, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 26.398.

Παρατηρούμε ότι σε όλες τις επιληπτικές κρίσεις, η αύξηση της τιμής του σφάλματος έπεται κατά πολύ της έναρξης της επιληπτικής κρίσης. Αν και παράλληλα με την αρχή της κρίσης μπορούμε ακόμα και εδώ να παρατηρήσουμε μια αύξηση του σφάλματος, αυτή δεν είναι αρκετά μεγάλη ώστε να μπορούμε να τη χρησιμοποιήσουμε για να διαχωρίσουμε την επιληπτική περίοδο από τις μη επιληπτικές. Αυτό αποτυπώνεται και στην εκτέλεση του αλγορίθμου μας, όπου αυτό που ουσιαστικά ανιχνεύουμε είναι την αιχμή (spike) που βλέπουμε στα διαγράμματα, και σε αυτό οφείλονται και οι μεγάλες τιμές καθυστέρησης στα αποτελέσματά μας.

Όπως θα αναμέναμε και από τα παραπάνω διαγράμματα, σε όλες τις επιληψίες η καθυστέρηση ανίχνευσής είναι αρκετά μεγάλη και δεν υπάρχει ούτε μια κρίση που να εντοπίζεται εγκαίρως.

5.5.3 Ασθενής 1

Ο ασθενής 1 έχει σύνθετες εστιακές (complex partial) και απλές εστιακές (simple partial) επιληπτικές κρίσεις και η καταγραφή έχει γίνει με ηλεκτρόδια πλέγματος (grid electrode) και ταινίας (strip electrode). Στις παρακάτω εικόνες φαίνεται η σχετική διάταξη καταγραφής ΗΕΓ βάθους για τον ασθενή:



Σχήμα 5.15: Θέσεις ηλεκτροδίων ασθενή 1

Η διάρκεια της μεσοκρισικής καταγραφής είναι 86400 sec και έχει γίνει σε 1 διάστημα. Για τον ασθενή 1 έχουν καταγραφεί 4 επιληπτικές κρίσεις.

Ξεκινάμε από τα αποτελέσματα για το μέγιστο κατώφλι για το οποίο εντοπίζουμε όλες τις επιληψίες. Η ειδικότητα για δίκτυα 16 νευρώνων και 32 καθυστερήσεων φαίνεται στον πίνακα 5.21 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.23. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων η ειδικότητα παρατίθεται στον πίνακα 5.22 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.24.

Όσον αφορά την ειδικότητα έχουμε:

Πίνακας 5.21: ΨΑ ανά ώρα για ασθενή 1 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,097	3,194	2,936
300	0,226	2,903	3,774
700	0,226	1,903	2,678

Πίνακας 5.22: ΨΑ ανά ώρα για ασθενή 1 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,226	3,936	2,387
300	0,355	2,516	3,097
700	0,323	1,807	2,710

Πίνακας 5.23: Μέση καθυστέρηση (sec) για ασθενή 1 και δίκτυα 32 καθυστερήσεων.


Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	4,488281	-0,2724609	5,696289
300	3,290039	-0,5205078	5,855469
700	2,90625	-0,7695313	5,388672

Πίνακας 5.24: Μέση καθυστέρηση (sec) για ασθενή 1 και δίκτυα 100 καθυστερήσεων.


Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	4,222656	-0,6210938	6,134766
300	3,019531	-0,7978516	3,668945
700	2,674805	-1,118164	4,56543

Όπου εδώ αξίζει να παρατηρήσουμε όχι μόνο την καλή συνολική επίδοση του καναλιού 1 , αλλά και το γεγονός ότι το κανάλι 2 έχει αρνητική καθυστέρηση ανίχνευσης, το οποίο είναι μια πολύ ενδιαφέρουσα παρατήρηση, γιατί παρά την πολύ κακή ειδικότητα, μας δείχνει ότι παρατηρείται μεταβολή του σφάλματος από πολύ νωρίς.


Παραθέτουμε παρακάτω τα απόλυτα σφάλματα πρόβλεψης των δικτύων κατά τις επιληπτικές κρίσεις του ασθενή. Πρόκειται για το δίκτυο μεγέθους 16 νευρώνων και 100 καθυστερήσεων που έχει εκπαιδευτεί και εφαρμοστεί στο κανάλι 2 ασθενή. Έχει γίνει φιλτράρισμα των σφαλμάτων με φίλτρο κινούμενου μέσου με παράθυρο 300 δειγμάτων.




Σχήμα 5.16: Η πρώτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 24.990.



Σχήμα 5.17: Η δεύτερη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 24.743.




Σχήμα 5.18: Η τρίτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.845.



Σχήμα 5.19: Η τέταρτη κρίση του ασθενή 1, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.882.

5.5.4. Ασθενής 19

Ο ασθενής 19 έχει σύνθετες εστιακές (complex partial) και απλές εστιακές (simple partial) και γενικευμένες τονικλονικές (generalized tonic-clonic) επιληπτικές κρίσεις και η καταγραφή έχει γίνει με ηλεκτρόδια ταινίας (strip electrode). Στην παρακάτω εικόνα φαίνεται η σχετική διάταξη καταγραφής EEG βάθους για τον ασθενή:



Σχήμα 5.20: Θέσεις ηλεκτροδίων ασθενή 19

Η διάρκεια της μεσοκρισικής καταγραφής είναι 87780 sec και έχει γίνει σε 3 διαστήματα. Για τον ασθενή 19 έχουν καταγραφεί 4 επιληπτικές κρίσεις.

Παραθέτουμε αρχικά τα αποτελέσματα για το μέγιστο κατώφλι για το οποίο εντοπίζουμε όλες τις επιληψίες (ευαισθησία=100%). Η ειδικότητα για δίκτυα 16 νευρώνων και 32 καθυστερήσεων φαίνεται στον πίνακα 5.25 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.27. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων η ειδικότητα παρατίθεται στον πίνακα 5.26 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.28.

Πίνακας 5.25: ΨΑ ανά ώρα για ασθενή 19 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	1,2	5,97	NaN
300	3,32	5,62	4,79
700	4,28	1,2	4,09

Πίνακας 5.26: ΨΑ ανά ώρα για ασθενή 19 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	2,11	5,88	9,6
300	3,77	3,02	0,51
700	3,69	0,72	0,75

Πίνακας 5.27: Μέση καθυστέρηση (sec) για ασθενή 19 και δίκτυα 32 καθυστερήσεων

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	2,56	2,57	NaN
300	3	2,55	3,85
700	1,97	1,77	1,34

Πίνακας 5.28: Μέση καθυστέρηση (sec) για ασθενή 19 και δίκτυα 100 καθυστερήσεων

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	1,78	2,4	-0,32
300	2,82	2,37	6,07
700	1,98	1,68	3,73

Για παράθυρο 20 στο κανάλι 3 για δίκτυο 32 καθυστερήσεων δεν μπορούμε να καταλήξουμε σε κατώφλι που να ανιχνεύει όλες τις επιληψίες του ασθενή, γιατί και δεν παραθέτουμε αποτελέσματα.


Οι τιμές για την μέση καθυστέρηση είναι αρκετά ικανοποιητικές. Η ειδικότητα ωστόσο δεν είναι καλή. Δύο συνδυασμοί καναλιού και παραθύρου για τους οποίους παρατηρούμε τα βέλτιστα αποτελέσματα είναι το κανάλι 1 για παράθυρο 20 με δίκτυο 32d ($\Psi A/h=1,2$ και μέση καθυστέρηση= 2,56 sec) και το κανάλι 2 για δίκτυο 100d και παράθυρο 700 ($\Psi A/h=0,72$ και μέση καθυστέρηση=1,68 sec). Τα συγκεκριμένα δύο παραδείγματα είναι ικανοποιητικά.

Στον πίνακα 5.29 φαίνονται οι αποδόσεις (mse performances) για όλα τα δίκτυα που χρησιμοποιήθηκαν στον αλγόριθμο.


Πίνακας 5.29: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 19

	ΚΑΝΑΛΙ 1	ΚΑΝΑΛΙ 2	ΚΑΝΑΛΙ 3
16N 32K	1091,4	1792,4	1270,2
16N 100K	792,85	1303,9	939,14


Επίσης παραθέτουμε και τα αναλυτικά διαγράμματα για το σφάλμα των δικτύων κατά τις επιληπτικές κρίσεις. Πρόκειται για το δίκτυο μεγέθους 16 νευρώνων και 100 καθυστερήσεων που έχει εκπαιδευτεί και εφαρμοστεί στο κανάλι 1 ασθενή. Έχει γίνει φιλτράρισμα των σφαλμάτων με φίλτρο κινούμενου μέσου με παράθυρο 300 δειγμάτων.




Σχήμα 5.21: Η πρώτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 5.000 και τελειώνει στο 10.931.



Σχήμα 5.22: Η δεύτερη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 21.914.



Σχήμα 5.23: Η τρίτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 22.785.




Σχήμα 5.24: Η τέταρτη κρίση του ασθενή 19, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 22.214.

5.5.5. Ασθενής 16

Ο ασθενής 16 έχει σύνθετες εστιακές (complex partial) και απλές εστιακές (simple partial) και γενικευμένες τονικλονικές (generalized tonic-clonic) επιληπτικές κρίσεις και η

καταγραφή έχει γίνει με βελονοειδές (depth electrode) και ηλεκτρόδιο ταινίας (strip electrode). Στις παρακάτω εικόνες φαίνεται η σχετική διάταξη καταγραφής ΕΕΓ βάθους για τον ασθενή:



Σχήμα 5.25: Θέσεις ηλεκτροδίων του ασθενή 16

Η διάρκεια της μεσοκρισικής καταγραφής είναι 86400 sec και έχει γίνει σε 2 διαστήματα. Για τον ασθενή 16 έχουν καταγραφεί 5 επιληπτικές κρίσεις.

Όπως και παραπάνω ξεκινάμε παραθέτοντας τα αποτελέσματα για τα οποία μόλις εντοπίζουμε και τις 5 επιληπτικές κρίσεις του ασθενή (ευαισθησία=100%). Η ειδικότητα για δίκτυα 16 νευρώνων και 32 καθυστερήσεων φαίνεται στον πίνακα 5.30 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.32. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων η ειδικότητα παρατίθεται στον πίνακα 5.31 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.33.

Πίνακας 5.30: ΨΑ ανά ώρα για ασθενή 16 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,56	0,64	1,82
300	2,69	2,8	5,02
700	1,68	1,4	3,25

Πίνακας 5.31: ΨΑ ανά ώρα για ασθενή 16 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,64	0,59	4,71
300	3,05	1,26	7,29
700	1,68	0,78	5,52

Πίνακας 5.32: Μέση καθυστέρηση (sec) για ασθενή 16 και δίκτυα 32 καθυστερήσεων.


Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	47,9	31,18	49,67
300	47,85	12,51	37,98
700	47,57	14,02	47,61

Πίνακας 5.33: Μέση καθυστέρηση ασθενή 16 για (sec) και δίκτυα 100 καθυστερήσεων.


Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	47,38	33,93	50,06
300	46,86	16,57	26,93
700	46,83	15,98	47,55

Παρατηρούμε ότι ο αριθμός των ΨΑ είναι αρκετά ικανοποιητικός, ειδικά για παράθυρο 20 για τα κανάλια 1 και 2. Μάλιστα αυτό συμβαίνει τόσο για δίκτυα 32 καθυστερήσεων όσο και για δίκτυα 100 καθυστερήσεων. Ωστόσο η καθυστέρηση ανίχνευσης των κρίσεων είναι πάρα πολύ μεγάλη. Όπως και στον ασθενή 3, όπου έχουμε επίσης πολύ υψηλές τιμές μέσης καθυστέρησης ανίχνευσης, έτσι και εδώ δεν μπορούμε να επιτύχουμε ικανοποιητική καθυστέρηση ό,τι κατώφλι και αν θέσουμε.


Όπως και στους προηγούμενους ασθενείς, παραθέτουμε τα διαγράμματα με το σφάλμα για παράθυρο κινούμενων μέσων ίσο με 300 για το δίκτυο μεγέθους 16 νευρώνων και 32 καθυστερήσεων που έχει εκπαιδευτεί και εφαρμοστεί στο κανάλι 2 του ασθενή. Σημειώνουμε εδώ ότι η μέση καθυστέρηση για το συγκεκριμένο συνδυασμό καναλιού και παραθύρου είναι 12,51 sec και είναι η μικρότερη που έχουμε πετύχει. Για τα άλλα κανάλια η μεταβολή του σφάλματος κατά τις επιληπτικές κρίσεις είναι ακόμα πιο δυσδιάκριτη.




Σχήμα 5.26: Η πρώτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 63.676.




Σχήμα 5.27: Η δεύτερη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 43.992.



Σχήμα 5.28: Η τρίτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 44.667.



Σχήμα 5.29: Η τέταρτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 42.254



Σχήμα 5.30: Η πέμπτη κρίση του ασθενή 16, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 60.345

Μπορούμε και σε αυτό τον ασθενή να παρατηρήσουμε ότι υπάρχει σημαντική αύξηση της τιμής του σφάλματος πρόβλεψης κατά την έναρξη της επιληπτικής κρίσης. Ωστόσο η αύξηση αυτή είτε δεν είναι αρκετά υψηλή για να την εντοπίσουμε (όπως στην κρίση 1 ή στην κρίση 3 όπου η αύξηση της τιμής του σφάλματος ξεκινάει μαζί με την επιληπτική κρίση αλλά το σφάλμα αυξάνεται με πολύ αργό ρυθμό για να εντοπίσουμε την κρίση), είτε δεν είναι αρκετά σταθερή, εμφανίζοντας μεγάλες διαβαθμίσεις. Ουσιαστικά εδώ ο μη έγκαιρος εντοπισμός των κρίσεων οφείλεται στο χρονικό παράθυρο του αλγορίθμου μας.

Όλες οι κρίσεις αργούν να ανιχνευτούν, αν και όχι εξίσου. Όμως για συνολικές μέσες τιμές που κινούνται γύρω στα 40 sec στους παραπάνω πίνακες, δεν ανιχνεύουμε επιληψία με καθυστέρηση μικρότερη των 10 sec. Έτσι, δεν μπορούμε να πούμε ότι η μεγάλη μέση τιμή της καθυστέρησης οφείλεται σε συγκεκριμένες μόνο κρίσεις του ασθενή.

Στον πίνακα 5.34 παρατίθεται η απόδοση των δικτύων ως προς την πρόβλεψη ΗΕΓ τιμών.


Πίνακας 5.34: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 16

	ΚΑΝΑΛΙ 1	ΚΑΝΑΛΙ 2	ΚΑΝΑΛΙ 3
16N 32K	992,45	636,83	2022,6
16N 100K	578,8	412,04	1053,6

Αξίζει και εδώ να παρατηρήσουμε ότι παρόλο που τα δίκτυα έχουν αρκετά διαφορετικά performances, η απόδοσή τους στον αλγόριθμο είναι παρόμοια.

5.5.6. Ασθενής 5

Ο ασθενής 5 έχει σύνθετες εστιακές (complex partial) και απλές εστιακές (simple partial) και γενικευμένες τονικλονικές (generalized tonic-clonic) επιληπτικές κρίσεις και η καταγραφή έχει γίνει με ηλεκτρόδια πλέγματος (grid electrode) και τανίας (strip electrode). Στις παρακάτω εικόνες φαίνεται η σχετική διάταξη καταγραφής ΗΕΓ βάρους για τον ασθενή:



Σχήμα 5.31: Θέσεις ηλεκτροδίων του ασθενή 5

Η διάρκεια της μεσοκρισικής καταγραφής είναι 86400 sec και έχει γίνει σε 3 διαστήματα. Για τον ασθενή 16 έχουν καταγραφεί 5 επιληπτικές κρίσεις.

Παραθέτουμε και εδώ τα αποτελέσματα για το μέγιστο δυνατό κατώφλι για το οποίο ανιχνεύουμε και τις 5 επιληπτικές κρίσεις του ασθενή. Η ειδικότητα για δίκτυα 16 νευρώνων και 32 καθυστερήσεων φαίνεται στον πίνακα 5.35 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.37. Για δίκτυα 16 νευρώνων και 100 καθυστερήσεων η ειδικότητα παρατίθεται στον πίνακα 5.36 και η αντίστοιχη μέση καθυστέρηση ανίχνευσης στον πίνακα 5.38.

Πίνακας 5.35: ΨΑ ανά ώρα για ασθενή 5 και δίκτυα 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,06	0,32	0,18
300	0,21	0,62	0,32
700	0,15	0,47	0,30

Πίνακας 5.36: ΨΑ ανά ώρα για ασθενή 5 και δίκτυα 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,32	0,41	0,44
300	1,86	0,53	0,65
700	0,24	0,47	0,47

Πίνακας 5.37: Μέση καθυστέρηση (sec) για ασθενή 5 και δίκτυο 32 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 32 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	0,84	1,62	2,98
300	1,83	1,67	21,05
700	2,59	1,58	1,72

Πίνακας 5.38: Μέση καθυστέρηση (sec) για ασθενή 5 και δίκτυο 100 καθυστερήσεων.

Δίκτυο 16 νευρώνων και 100 καθυστερήσεων			
Παράθυρο	Κανάλι		
	1	2	3
20	4,99	21,99	4,09
300	21,99	22,41	22,06
700	24,09	21,93	23,56

Είναι εμφανές ότι για τον ασθενή 5 έχουμε τα καλύτερα αποτελέσματα εφαρμογής του αλγορίθμου. Ειδικά για δίκτυο 32 καθυστερήσεων, για παράθυρο=20 στο κανάλι 1 τα αποτελέσματα είναι εντυπωσιακά. (ειδικότητα=0,06 και μέση καθυστέρηση=0,84 sec). Σημειώνεται εδώ ότι ο ασθενής 5 είναι ο ασθενής με τον οποίο ξεκινήσαμε την προσπάθεια πρόβλεψης ΗΕΓ τιμών με τη χρήση νευρωνικών δικτύων καθώς και την εφαρμογή του αλγορίθμου μας για την ανίχνευση των κρίσεων.


Μπορούμε επίσης να παρατηρήσουμε ότι το δίκτυο με τις 32 καθυστερήσεις αποδίδει τρομερά καλύτερα από αυτό με τις 100 καθυστερήσεις.

Στον πίνακα 5.39 φαίνονται οι τιμές του performance με κριτήριο το mse για κάθε δίκτυο που χρησιμοποιήθηκε.


Πίνακας 5.39: Μέσο τετραγωνικό σφάλμα πρόβλεψης δικτύων για τον ασθενή 5

	ΚΑΝΑΛΙ 1	ΚΑΝΑΛΙ 2	ΚΑΝΑΛΙ 3
16N 32K	1965,7	1792,6	980,07
16N 100K	1631,7	1344,4	710,35


Επίσης παρακάτω φαίνονται γραφικές παραστάσεις από τα σφάλματα κατά τις επιληπτικές κρίσεις του ασθενή. Πρόκειται για το δίκτυο μεγέθους 16 νευρώνων και 32 καθυστερήσεων που έχει εκπαιδευτεί και εφαρμοστεί στο κανάλι 1 του ασθενή. Έχει γίνει φιλτράρισμα των σφαλμάτων με φίλτρο κινούμενων μέσων με παράθυρο 300 δειγμάτων.




Σχήμα 5.32: Η πρώτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.834




Σχήμα 5.33: Η δεύτερη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 27.133



Σχήμα 5.34: Η τρίτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.704



Σχήμα 5.35: Η τέταρτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 23.910



Σχήμα 5.36: Η πέμπτη κρίση του ασθενή 5, που ξεκινά στο δείγμα 20.000 και τελειώνει στο 58.868.

5.5.7. Συγκεντρωτικά αποτελέσματα

Στους παρακάτω πίνακες φαίνονται συγκεντρωτικά τα καλύτερα αποτελέσματα για τον κάθε ασθενή όσον αφορά την μέση καθυστέρηση ανίχνευσης αλλά και την ειδικότητα. Παρατίθενται επίσης και οι τιμές των μεταβλητών τρεξίματος του αλγορίθμου για τις οποίες είχαμε τα συγκεκριμένα αποτελέσματα. Αξίζει να σημειωθεί ότι επειδή η βελτίωση της τιμής της ειδικότητας γίνεται εις βάρος της τιμής της μέσης καθυστέρησης, κανένα σχεδόν από τα παρακάτω αποτελέσματα δεν μπορεί να θεωρηθεί συνολικά βέλτιστο. Καθώς ωστόσο δεν υπάρχει κάποιο κριτήριο απόδοσης που να συνδυάζει την τιμή της ειδικότητας με αυτή της μέσης καθυστέρησης, ο αναγνώστης που επιθυμεί να δει τα αποτελέσματα όπου και τα δύο κριτήρια έχουν καλές τιμές ταυτόχρονα παραπέμπεται στα αποτελέσματα που παρατίθενται για τον κάθε ασθενή ξεχωριστά στις προηγούμενες παραγράφους.

Πίνακας 5.40: Συγκεντρωτικές τιμές με τα καλύτερα αποτελέσματα του κάθε ασθενή με βάση τη μέση καθυστέρηση ανίχνευσης.

Καλύτερες τιμές με βάση την μέση καθυστέρηση ανίχνευσης κρίσεων					
	Κανάλι	Παράθυρο	Αριθμός καθυστερήσεων δικτύου	ΨΑ/ώρα	Μέση καθυστέρηση ανίχνευσης (sec)
Ασθενής 9	2	700	100	0,884	1,36
Ασθενής 3	1	20	32	10,128	8,57
Ασθενής 1	2	700	100	1,807	-1,12
Ασθενής 19	3	20	100	9,6	-0,32
Ασθενής 16	2	300	32	2,8	12,51
Ασθενής 5	1	20	32	0,06	0,84

Πίνακας 5.41: Συγκεντρωτικές τιμές με τα καλύτερα αποτελέσματα του κάθε ασθενή με βάση την ειδικότητα ανίχνευσης.

Καλύτερες τιμές με βάση την ειδικότητα ανίχνευσης					
	Κανάλι	Παράθυρο	Αριθμός καθυστερήσεων δικτύου	ΨΑ/ώρα	Μέση καθυστέρηση ανίχνευσης (sec)
Ασθενής 9	2	20	32	0,354	19,09
Ασθενής 3	1	700	32	0,186	38,64
Ασθενής 1	1	20	32	0,097	4,49
Ασθενής 19	3	300	100	0,51	6,07
Ασθενής 16	1	20	32	0,56	47,9
Ασθενής 5	1	20	32	0,06	0,84

5.6 Βιβλιογραφία

- [1] T. Maiwald, M. Winterhalder, R. Aschenbrennerscheibe, H. Voss, a Schulzebonhage, and J. Timmer, “Comparison of three nonlinear seizure prediction methods by means of the seizure prediction characteristic,” *Physica D: Nonlinear Phenomena*, vol. 194, no. 3–4, pp. 357–368, Jul. 2004.
- [2] S. Grewal and J. Gotman, “An automatic warning system for epileptic seizures recorded on intracerebral EEGs.,” *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, vol. 116, no. 10, pp. 2460–72, Oct. 2005.
- [3] A. B. Gardner, H. Hall, and A. M. Krieger, “One-Class Novelty Detection for Seizure Analysis from Intracranial EEG,” *Journal of Machine Learning Research*, vol. 7, pp. 1025 – 1044, 2006.
- [4] W. R. Webber, R. P. Lesser, R. T. Richardson, and K. Wilson, “An approach to seizure detection using an artificial neural network (ANN).,” *Electroencephalography and clinical neurophysiology*, vol. 98, no. 4, pp. 250–72, Apr. 1996.

Κεφάλαιο 6: Συμπεράσματα και συζήτηση

6.1 Συμπεράσματα ως προς την πρόβλεψη ΗΕΓ τιμών

Το πρώτο συμπέρασμα που μπορούμε να παραθέσουμε σε σχέση με τους πειραματισμούς για την πρόβλεψη ΗΕΓ τιμών είναι ότι πράγματι καταφέραμε να προβλέψουμε τα μεσοκρισικά ΗΕΓ δεδομένα ένα βήμα μπροστά με τη χρήση νευρωνικών δικτύων και βασιζόμενοι μόνο σε παρελθούσες τιμές του ίδιου ΗΕΓ με ανεκτή ακρίβεια. Παρόλο που ο χρονικός ορίζοντας της πρόβλεψης αυτής είναι υπερβολικά μικρός και την καθιστά ουσιαστικά άχρηστη για κάθε πιθανή κλινική εφαρμογή, ακόμα και αυτό το αποτέλεσμα μας δίνει την ένδειξη της χρονικής συσχέτισης των τιμών του ΗΕΓ με τις προηγούμενες του τιμές. Πιθανόν ένα πολύ πιο ισχυρό δίκτυο να μπορούσε να προβλέψει τις μελλοντικές τιμές του ΗΕΓ με κάποιο κάπως μεγαλύτερο ορίζοντα πρόβλεψης. Ωστόσο, το δεύτερο συμπέρασμα στο οποίο φτάνει αναγκαστικά κάποιος, με βάση τα αποτελέσματα των πειραματισμών της παρούσας εργασίας, είναι ότι η πρόβλεψη των ΗΕΓ τιμών πάνω από μερικά βήματα στο μέλλον δεν είναι εφικτή με τη χρήση μόνο των νευρωνικών δικτύων της τάξης μεγέθους που χρησιμοποιήθηκαν (λιγότερο από 60 νευρώνες και λιγότερο από 100 καθυστερήσεις δηλαδή). Έτσι δεν τίθεται και κανένα θέμα απευθείας χρησιμοποίησης της πρόβλεψης αυτής σε κάποια κλινική εφαρμογή σχετική με την πρόβλεψη επιληπτικών κρίσεων, όπως ήταν αρχικά ο στόχος της διπλωματικής. Τέλος, αξίζει να σημειωθεί η παρατήρηση που προέκυψε από τους πειραματισμούς του 4ου κεφαλαίου, ότι τα επιληπτικά δεδομένα είναι σημαντικά πιο απρόβλεπτα από τα μεσοκρισικά δεδομένα των ασθενών. Κάτι τέτοιο επιβεβαιώνεται στη συνέχεια και με τους πειραματισμούς του κεφαλαίου 5 και θα μπορούσε πιθανόν να φανεί χρήσιμο και σε μελλοντικές εργασίες.

6.2 Συμπεράσματα εφαρμογής του αλγορίθμου ανίχνευσης επιληπτικών κρίσεων

Εξετάζοντας τα αποτελέσματα της εφαρμογής του αλγορίθμου για την ανίχνευση επιληπτικών κρίσεων στους έξι ασθενείς όπως αυτή έγινε στο προηγούμενο κεφάλαιο μπορούμε να καταλήξουμε σε κάποια συμπεράσματα. Καταρχήν, θα μπορούσαμε να πούμε ότι η μέση απόδοση του αλγορίθμου ήταν ικανοποιητική, αναφερόμενοι στις περιπτώσεις για τις οποίες είχε γίνει η βέλτιστη επιλογή παραμέτρων (μέγεθος παραθύρου, αριθμός καθυστερήσεων). Αξίζει επίσης να σημειώσουμε ότι στους ασθενείς για τους οποίους είχαμε βέλτιστη απόδοση, τα αποτελέσματα ήταν πάρα πολύ καλά συγκρινόμενα και με αποτελέσματα τις σχετικής βιβλιογραφίας (όπου βέβαια αναφέρονται μέσες και όχι βέλτιστες τιμές και οι δοκιμές αφορούν πολύ μεγαλύτερο αριθμό ασθενών). Είναι επίσης σημαντικό να σημειώσουμε ότι σε αρκετές κρίσεις των παραπάνω ασθενών παρατηρούμε ανίχνευση πριν την έναρξη (εγκεφαλογραφικό onset) της κρίσης. Αυτό, πέρα από τη κλινική του χρησιμότητα, μας κάνει να πιστένουμε ότι έχει αρχίσει να συμβαίνει κάποια αλλαγή στην εγκεφαλική λειτουργία πριν το κλινικό onset της κρίσης, ακόμα και αν αυτό είναι για

κάποια μόλις δέκατα του δευτερολέπτου πιο νωρίς.

Πρέπει ωστόσο να αναφέρουμε ότι σε πολλές περιπτώσεις ασθενών ο αλγόριθμος δεν κατάφερε να έχει ικανοποιητικά αποτελέσματα. Χαρακτηριστικά παραδείγματα είναι οι ασθενείς 3 και 16 για τους οποίους προκύπτουν πολύ μεγάλες τιμές καθυστέρησης ανίχνευσης. Επίσης, με βάση τα αποτελέσματα των προσομοιώσεων που τρέξαμε στους έξι ασθενείς, δεν καταφέραμε να εντοπίσουμε κάποια συγκεκριμένα χαρακτηριστικά ασθενών για τα οποία ο αλγόριθμος να αποδίδει καλύτερα (πχ να είχαμε καλύτερα αποτελέσματα για απλές εστιακές κρίσεις από ότι για σύνθετες εστιακές, ή η απόδοση στην ανίχνευση επιληψίας κροταφικού λοβού να ήταν καλύτερη)

Συνολικά και με βάση όλα τα αποτελέσματα του κεφαλαίου 5 μπορούμε να πούμε ότι επιβεβαιώσαμε ότι παρατηρείται μια σημαντική αλλαγή στην “προβλεψιμότητα” των τιμών του ΗΕΓ κατά τις επιληπτικές κρίσεις. Η αλλαγή αυτή, αν και διαφέρει από ασθενή σε ασθενή στο πόσο ξεχωρίζει από το υπόλοιπο ΗΕΓ του και στο πόσο νωρίς σε σχέση με την έναρξη της κρίσης συμβαίνει, παρατηρείται σε όλες τις κρίσεις των ασθενών που εξετάσαμε.

6.3 Συζήτηση και προτάσεις για μελλοντική έρευνα

Υπάρχουν αρκετά κομμάτια της παρούσας δουλειάς που έχουν μείνει ανοιχτά και προσφέρονται για μελλοντική έρευνα. Το πιο σημαντικό φαίνεται να είναι ότι για να αξιολογηθεί η ικανότητα εφαρμογής του αλγορίθμου στην πράξη χρειάζεται με κάποιον τρόπο να συνδεθεί η εκπαίδευση των δικτύων με την εργασία της ανίχνευσης. Στην παρούσα διπλωματική, τα νευρωνικά δίκτυα εκπαιδεύτηκαν για την εργασία της πρόβλεψης τιμών, και στη συνέχεια τα δίκτυα που προέβλεπαν καλύτερα τις μελλοντικές τιμές του μεσοκριστικού ΗΕΓ χρησιμοποιήθηκαν για τον αλγόριθμο της ανίχνευσης. Ωστόσο, όπως είδαμε, το ότι ένα δίκτυο προβλέπει καλύτερα ΗΕΓ τιμές από ένα άλλο δεν μας εξασφαλίζει και το ότι το δίκτυο αυτό θα παρουσιάζει μεγαλύτερο σφάλμα στις επιληπτικές περιόδους από ότι στις υπόλοιπες, που είναι στην πραγματικότητα το χαρακτηριστικό που θα θέλαμε να έχει το δίκτυο για τον αλγόριθμο της ανίχνευσης. Θα πρέπει λοιπόν για την πιθανή χρήση του χαρακτηριστικού της μικρότερης προβλεψιμότητας του επιληπτικού ΗΕΓ να βρεθεί κάποιος τρόπος εκπαίδευσης του νευρωνικού δικτύου με κριτήριο την απόδοση του στο παραπάνω χαρακτηριστικό και όχι την απόδοση του στην πρόβλεψη τιμών.

Επίσης, θα ήταν καλό να εφαρμοστεί ο αλγόριθμος αυτός σε μια βάση δεδομένων με περισσότερους ασθενείς ώστε να έχουμε πιο αξιόπιστα αποτελέσματα σε σχέση με την απόδοση του. Θα ήταν αρκετά ενδιαφέρουσα η εφαρμογή του αλγορίθμου σε δεδομένα ΗΕΓ επιφανείας, δεδομένου της διαφορετικής αποτύπωσης της εγκεφαλικής λειτουργίας που παρέχει το ΗΕΓ επιφανείας, καθώς και της μεγαλύτερης ευκολίας απόκτησης του, πράγμα που θα ήταν πολύ χρήσιμο για ενδεχόμενη κλινική εφαρμογή. Για να αξιολογήσουμε περαιτέρω τα αποτελέσματά μας θα πρέπει εξεταστεί η φύση των ψευδών ανιχνεύσεων που έχουν προκύψει – αν πρόκειται δηλαδή για artifacts της καταγραφής, παράσιτα συγκεκριμένης προέλευσης κλπ ή αν για παράδειγμα οι ψευδείς ανιχνεύσεις συμβαίνουν κατά τη διάρκεια του ύπνου.


Τέλος, πιθανή βελτίωση της απόδοσης της πρόβλεψης ΗΕΓ τιμών (κεφάλαιο 4) αλλά και της ανίχνευσης που κάναμε θα μπορούσε να προκύψει μέσα από πειραματισμό με διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων. Θα φαινόταν λογικό μια αρχιτεκτονική που θα ενσωμάτωνε εκθετικά φθίνουσα μνήμη να έχει καλή απόδοση σε σχέση με την πρόβλεψη τιμών, καθώς είναι αναμενόμενο μια τιμή του ΗΕΓ να εξαρτάται πιο πολύ από τις πέντε πχ προηγούμενες τιμές από ότι από πέντε τιμές που βρίσκονται 100 δείγματα πίσω.

ΠΑΡΑΡΤΗΜΑ: ΕΡΓΑΛΕΙΑ ΚΑΙ ΚΩΔΙΚΑΣ ΜΑΤLAB


Για όλες τις προσομοιώσεις τις παρούσας διπλωματικής χρησιμοποιήθηκε το περιβάλλον προγραμματισμού Matlab®, και συγκεκριμένα το Neural Network Toolbox. Στο παρόν παράρτημα αναφέρονται επιγραμματικά κάποια από τα εργαλεία του Toolbox που χρησιμοποιήθηκαν, αναλύονται τα σχήματα των δικτύων που έγιναν με το Matlab και παρατίθενται και σχολιάζονται ενδεικτικά κομμάτια του κώδικα που χρησιμοποιήθηκε.

Π1. Σχεδιαγράμματα Δικτύων

Τα διαγράμματα των δικτύων που χρησιμοποιήθηκαν έγιναν μετά την δημιουργία των δικτύων με τη χρήση της εντολής `view(net)`. Παρακάτω βλέπουμε το διάγραμμα του δικτύου της παραγράφου 4.4 που βρίσκεται στη σελίδα 56.




Στοιχεία διαγράμματος




Εξήγηση

Το τετραγώνκι αυτό συμβολίζει το διάνυσμα εισόδου $y(t)$, που στο συγκεκριμένο δίκτυο είναι το ίδιο το σήμα εξόδου αφού προβλέπουμε μελλοντικές τιμές της ίδιας χρονοσειράς. Η μονάδα κάτω του μας πληροφορεί ότι το διάνυσμα εισόδου είναι μονοδιάστατο.




Οι γραμμές με τα βέλη δείχνουν την πορεία του σήματος. Στο σχήμα αριστερά βλέπουμε το κρυφό επίπεδο του δικτύου. Μέσα στον κύκλο φαίνεται ο αριθμός των χρονικών καθυστερήσεων του δικτύου, που στη συγκεκριμένη περίπτωση είναι 100. Το w και το b συμβολίζουν τα συναπτικά βάρη και την πόλωση αντίστοιχα, ενώ το 16 είναι ο αριθμός των νευρώνων του κρυφού επιπέδου.

Όπως φαίνεται από το σχήμα η συνάρτηση ενεργοποίησης είναι σιγμοειδής.



Εδώ βλέπουμε το επίπεδο εξόδου του δικτύου. Ομοίως με παραπάνω, έχουμε ένα νευρώνα εξόδου και η συνάρτηση ενεργοποίησης είναι απλή γραμμική. Το επίπεδο αυτό οδηγεί στην έξοδο του δικτύου.



Τέλος βλέπουμε την έξοδο του δικτύου, η οποία είναι προφανώς και αυτή ένα μονοδιάστατο διάνυσμα, όπως φαίνεται και από τον αριθμό 1 που υπάρχει από κάτω της.

Στα σχήματα που υπάρχουν βέλη που οδηγούν από το επίπεδο εξόδου πίσω στην είσοδο του δικτύου, αυτό σημαίνει ότι τα δίκτυα αυτά είναι ανατροφοδοτούμενα, αφού τα βέλη δείχνουν την πορεία του σήματος της πρόσθιας τροφοδότησης του δικτύου.

Π2. Κώδικας και Εντολές του Matlab

Π2.1 Φόρτωση και Προεπεξεργασία Δεδομένων

Το πρώτο πράγμα που χρειάστηκε να γίνει πριν από όλες τις εργασίες που περιγράφονται παρακάτω ήταν η φόρτωση των δεδομένων της βάσης του Freiburg που χρειάζονταν κάθε φορά από τα αρχεία ASCII που βρίσκονταν στο περιβάλλον εργασίας του Matlab. Παρακάτω παρουσιάζεται ο κώδικας που φορτώνει τα δεδομένα του ασθενή 1 από το ascii αρχείο 010403ba_0095.asc

```
dedomena='010403ba_0095';
ch_num=6;

%%
%arxika fortwnoume ola ta dedomena tou EEG sto dataf
dataf=[];

for k=1:ch_num
    name=[ dedomena ' ' int2str(k) '.asc'];
    allo=['x' dedomena ' ' int2str(k) '=importdata(name);'];
    eval([allo]);
```

```

end

for k=1:ch_num
    allo=['s = x' dedomena '_' int2str(k)'];
    eval([allo]);
    dataf=[dataf s];
end

```

Όπως φαίνεται από τον παραπάνω κώδικα, τα δεδομένα και για τα 6 κανάλια του ΗΕΓ είναι αποθηκευμένα στη μεταβλητή dataf. Μετά τη φόρτωση των δεδομένων ακολουθεί προεπεξεργασία τους με τον παρακάτω κώδικα:

```

fs=256; %to sampling rate twm eeg mas einai sta 256Hz

%%
%Notch filtering
wo = 50/(fs/2); % Notch around 50Hz
bw = wo/20; % Q factor
[b,a] = iirnotch(wo,bw);
for i=1:ch_num %fiiltraroume to ka8e kanali xehwrista
    s=dataf(:,i);
    s=filtfilt(b,a,s);
    dataf(:,i)=s; %kai to apo8hkeuoume pali pisw
end

%%

% 3. Re-referencing
k=ones(size(dataf,2),1);
m=mean(dataf); % Find mean value within electrodes for each value in time
M=(k*m); % Create a matrix with as many lines as number of points in time and as many columns
as number of electrodes.
%Each line of the matrix contains identical values=the mean value within electrodes for that point in
time
dataf=dataf-M;

%%
%Bandpass filtering

Wn=[0.5 120];
[b,a] = butter(4,2*Wn/fs);
for i=1:ch_num %filtraroume to ka8e kanali xehwrista
    s=dataf(:,i);
    s=filtfilt(b,a,s); %zero phase shift
    dataf(:,i)=s; %kai to apo8hkeuoume pali pisw
end

```

Αξίζει εδώ να σημειωθεί η χρήση της εντολής filtfilt η οποία κάνει φιλτράρισμα χωρίς να μεταβάλλει τη φάση των συχνοτήτων του σήματος.

Π2.2 Εκπαίδευση Δικτύων

Έχοντας φορτώσει και προεπεξεργαστεί τα δεδομένα, το επόμενο στάδιο είναι να τα τροφοδοτήσουμε στο δίκτυο. Παρακάτω φαίνεται ο επαναληπτικός κώδικας που χρησιμοποιήθηκε για την εκπαίδευση των δικτύων στην παράγραφο 4.3 για την εύρεση του βέλτιστου αριθμού νευρώνων και καθυστερήσεων. Στο dataf υπάρχουν από πριν τα κατάλληλα δεδομένα του ασθενή 5.

```
for NEURONS=4:4:60
for DELAYS=4:4:60

%%
%DHMIOURGIA TΟΥ NET
L=NEURONS;
D=DELAYS;

targetSeries = tonndata(tr_data,false,false);

% Create a Nonlinear Autoregressive Network
feedbackDelays = 1:D;
hiddenLayerSize = L;
net = narnet(feedbackDelays,hiddenLayerSize);

%gia veltisto memory usage
net.verbosity.cacheDelayedInputs=1;
net.verbosity.flattenTime=1;
net.verbosity.memoryReduction=20;

net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};

[inputs,inputStates,layerStates,targets] = preparets(net,{}, {},targetSeries);

net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'time'; % Divide up every value
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Algorithmos Ekpaideushs
net.trainFcn = 'trainlm'; % Levenberg-Marquardt

net.performFcn = 'mse'; % Mean squared error

% Ekpaideysh tou diktyou
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)
```

```
name=['net_' int2str(NEURONS) 'N_' int2str(DELAYS) 'D'];
```

```
save(name,'net','performance')
```

```
end
```

```
end
```

Αξίζει εδώ να σχολιάσουμε την εντολή `net = narnet(feedbackDelays,hiddenLayerSize)` που χρησιμοποιήθηκε για τη δημιουργία του δικτύου με δεδομένο αριθμό χρονικών καθυστερήσεων (`feedbackDelays`) και κρυφών νευρώνων (`hiddenLayerSize`) . Η εντολή αυτή δημιουργεί ένα μη γραμμικό αυτοπαλινδρομικό μοντέλο, `template` πάνω στο οποίο βασιζόμαστε για να δημιουργήσουμε τα δίκτυα που χρησιμοποιούνται στην εργασία. Στην συνέχεια ακολουθούν εντολές που επηρεάζουν τις απαιτήσεις εκτέλεσης του κώδικα από άποψη υπολογιστικών πόρων. Συγκεκριμένα οι εντολές `net. efficiency.cacheDelayedInputs=1` και `net. efficiency.flattenTime=1` `net. efficiency.memoryReduction=20` αυξάνουν τις απαιτήσεις σε υπολογιστικό χρόνο μειώνοντας ταυτόχρονα τις απαιτήσεις σε μνήμη. Αυτό γίνεται επαναυπολογίζοντας τιμές πινάκων που θα μπορούσαν να είχαν αποθηκευτεί και σπάζοντας τις πράξεις μεταξύ μεγάλων πινάκων σε υποπίνακες. Επίσης καθορίζεται ο τρόπος με τον οποίο θα χωριστεί το δείγμα εκπαίδευσης, τόσο ως προς την πολιτική που θα ακολουθηθεί τυχαία στην περίπτωση του κώδικα που χρησιμοποιήθηκε (`net.divideFcn = 'dividerand'`), όσο και ως προς το μέγεθος του κάθε συνόλου (επικύρωσης, ελέγχου, εκπαίδευσης). Το Matlab μας δίνει ακόμα τη δυνατότητα να καθορίσουμε τον αλγόριθμο εκπαίδευσης (στη συγκεκριμένη περίπτωση είναι ο αλγόριθμος `backpropagation` με τη βελτιστοποίηση `Levenberg-Marquadt` όπως καθορίζεται από την εντολή `net.trainFcn = 'trainlm'`) καθώς και το μέτρο της απόδοσης (μέσο τετραγωνικό σφάλμα `net.performFcn = 'mse'`) που θα χρησιμοποιηθούν. Έτσι μπορούμε να κάνουμε την εκπαίδευση του δικτύου με αυτές τις παραμέτρους χρησιμοποιώντας μια μόνο εντολή: `[net,tr] = train(net,inputs,targets,inputStates,layerStates)`. Στη μεταβλητή `tr` θα κρατηθούν τα δεδομένα και το αρχείο της εκπαίδευσης.

Στη συνέχεια ο παραπάνω κώδικας αποθηκεύει τα δίκτυα μαζί με την απόδοσή τους όπως αυτή μετρήθηκε στο δείγμα εκπαίδευσης.

Π2.3 Αλγόριθμος Ανίχνευσης Επιληπτικών κρίσεων

Ο κώδικας που χρησιμοποιήθηκε για το τρέξιμο του αλγορίθμου ανίχνευσης επιληπτικών κρίσεων στους έξι ασθενείς είναι αρκετά παρόμοιος , με μόνο πράγμα που αλλάζει από ασθενή σε ασθενή να είναι τα ονόματα των αρχείων των δεδομένων του και κάποιοι παράμετροι όπως ο αριθμός των επιληπτικών κρίσεων που παρατηρούνται καθώς και η χρονική στιγμή έναρξης και λήξης τους. Για κάθε ασθενή ο κώδικας αρχικά εκπαίδευει ένα δίκτυο για κάθε κανάλι του ΗΕΓ και το αποθηκεύει. Ο συγκεκριμένος κώδικας που παρατίθεται παρακάτω αναφέρεται στον ασθενή 9 για δίκτυα 16 νευρώνων και 32 καθυστερήσεων.

```
for CHANNEL=1:3
```

```

tr_data=datanf(1:(MEGETHOS-1),CHANNEL);

NEURONS=16;
DELAYS=32;

%%
%DHMIOURGIA TOU NET

L=NEURONS;
D=DELAYS;

training tic %8a krathsoume se mia metavlhth to xrono pou xreiasthke to ka8e dyktio gia
targetSeries = tonndata(tr_data,false,false);

% Create a Nonlinear Autoregressive Network
feedbackDelays = 1:D;
hiddenLayerSize = L;
net = narnet(feedbackDelays,hiddenLayerSize);

%gia veltisto memory usage
net.afficiency.cacheDelayedInputs=0;
net.afficiency.flattenTime=0;
net.afficiency.memoryReduction=1;

net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};

[inputs,inputStates,layerStates,targets] = preparets(net,{}, {},targetSeries);

net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'time'; % Divide up every value
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

net.trainFcn = 'trainlm'; % Levenberg-Marquardt

net.performFcn = 'mse'; % Mean squared error

[net,tr] = train(net,inputs,targets,inputStates,layerStates);

outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

name=['pat09_net_' int2str(NEURONS) 'N_' int2str(DELAYS) 'D_' int2str(CHANNEL)
'CH'];

t=toc/60; %kratame to xrono pou xreiasthke se minutes

save(name,'net','performance','t')

```

end

Στη συνέχεια χρησιμοποιώντας το αντίστοιχο δίκτυο προβλέπουμε ένα βήμα μπροστά και αποθηκεύουμε το σήμα σφάλματος (μεταβλητή err) ώστε στο επόμενο βήμα να το χρησιμοποιήσουμε για την ανίχνευση των κρίσεων. Αξίζει να σημειωθεί ότι ο συγκεκριμένος κώδικας αποθηκεύει εκτός από το σήμα σφάλματος τόσο το πραγματικό ΗΕΓ όσο και το προβλεπόμενο, πράγμα που έγινε για να υπάρχει η δυνατότητα χρήσης και κάποιου διαφορετικού μετρικού της απόκλισης πρόβλεψης πέρα από την απόλυτη τιμή του σφάλματος που αποθηκεύεται στο err.

for CHANNEL=1:3

```
name=['pat09_net_16N_100D_' int2str(CHANNEL) 'CH'];  
load(name)
```

for m=15:36

```
dedomena=['010906ea_01' int2str(m)]  
dataf=fortwma(dedomena);
```

```
eeg_data=dataf(:,CHANNEL);  
[err inputs outputs]=la8h_inout(eeg_data,net);  
name=[int2str(CHANNEL) 'CH_' dedomena 'err'];  
save(name,'err')
```

```
name=['inout' int2str(CHANNEL) 'CH_' dedomena];  
save(name,'inputs','outputs')
```

end

for m=39:42

```
dedomena=['010906ea_01' int2str(m)]  
dataf=fortwma(dedomena);
```

```
eeg_data=dataf(:,CHANNEL);  
err=la8h_inout(eeg_data,net);  
name=[int2str(CHANNEL) 'CH_' dedomena 'err'];  
save(name,'err')
```

```
name=['inout' int2str(CHANNEL) 'CH_' dedomena];  
save(name,'inputs','outputs')
```

end

```
iktal={'010906ea_0026','010906ea_0036','010906ea_0038','010906ea_0050','010906ea_0071'};
```

for l=1:size(iktal,2)

```
dedomena=iktal{l}  
dataf=fortwma(dedomena);
```

```

eeg_data=datas(:,CHANNEL);
err=la8h_inout(eeg_data,net);
name=[int2str(CHANNEL) 'CH_ikta_' dedomena 'err'];
save(name,'err')

name=['inout' int2str(CHANNEL) 'CH_' dedomena];
save(name,'inputs','outputs')

end

gyrw={'010906ea_0025','010906ea_0035','010906ea_0037','010906ea_0049','010906ea_0070'};

for l=1:size(gyrw,2)

    dedomena=gyrw{l}
    dataf=fortwma(dedomena);

    eeg_data=datas(:,CHANNEL);
    err=la8h_inout(eeg_data,net);
    name=[int2str(CHANNEL) 'CH_ikta_' dedomena 'err'];
    save(name,'err')

    name=['inout' int2str(CHANNEL) 'CH_' dedomena];
    save(name,'inputs','outputs')

end

clear('net')

end

```

Ο κώδικας του function la8h_inout που χρησιμοποιείται παραπάνω για την εξαγωγή του απόλυτου σφάλματος είναι:

```

function [err, inputs,outputs]= la8h_inout (eeg_data,net)

targetSeries= tonndata(eeg_data,false,false);
[inputs,inputStates,layerStates,targets] = preparets(net,{}, {},targetSeries);
outputs = net(inputs,inputStates,layerStates);
errors= gsubtract(targets,outputs);

err=abs(cell2mat(errors));

end

```

Επόμενο βήμα του αλγορίθμου είναι ο υπολογισμός του κατωφλίου της ανίχνευσης. Αυτό σε κάποιες περιπτώσεις έγινε μετά από εμπειρικές δοκιμές. Ωστόσο, για την εύρεση του κατωφλίου για το οποίο έχουμε ευαισθησία ανίχνευσης 100% και βέλτιστη ειδικότητα η τιμή του κατωφλίου βρέθηκε με αυτόματο τρόπο. Αυτό έγινε ξεκινώντας με δύο ακραίες

τιμές του κατωφλίου, μια `threshold_low` μηδενική τιμή (για την οποία προφανώς ανιχνεύονται όλες οι κρίσεις) και μια πολύ μεγάλη `threshold_high`, για την οποία σίγουρα δεν ανιχνεύονται όλες οι κρίσεις. Στη συνέχεια παίρνοντας τη μέση τιμή των δύο άκρων, ελέγχεται το κατά πόσο με αυτή την τιμή ανιχνεύονται όλες οι κρίσεις. Αν ανιχνεύονται, θέτουμε `threshold_low` την τιμή του μέσου όρου, εναλλακτικά θέτουμε `threshold_high` την τιμή του μέσου όρου και επαναλαμβάνουμε το παραπάνω. Ο αλγόριθμος τερματίζει όταν οι δύο ακραίες τιμές απέχουν λιγότερο από μονάδα, όταν δηλαδή βρούμε το μέγιστο κατώφλι για το οποίο ανιχνεύουμε όλες τις κρίσεις με ακρίβεια μονάδας. Κρατάμε τα αποτελέσματα για όλα τα κανάλια σε ένα αρχείο `txt`.

```

number=0;

for windowSize= [20, 300]

CHANNEL=1;

threshold_low=0;

threshold_high=600;

num_seizures=0; %edw kratame tw n ari8mo tw n seizures pou anixneuoume gia epalh8eush

mean_delay=0; %edw 8a apo8hkeusoume th mesh timh tou delay apo to onset tis krisis gia ta swsta
detection

syn8hkh=true;

onoma='dokimi.txt';

fid=fopen(onoma,'a');

while(syn8hkh)

    threshold=(threshold_low+(threshold_high-threshold_low)/2)

    dedomena='010906ea_0026';

    name=['32d_' int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
    load(name) %pou mas afhnei me mia metavlthth err sto workspace

    epilepsia=katwfliwsh(err>windowSize,threshold);
    [number, positive1, detection_delay]=detection_iktal(epilepsia,number,40292,50163);

    mean_delay=mean_delay+detection_delay;

    dedomena='010906ea_0036';

    name=['32d_' int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
    load(name)

    epilepsia=katwfliwsh(err>windowSize,threshold);
    [number, positive2, detection_delay]=detection_iktal(epilepsia,number,472934,541438);
    mean_delay=mean_delay+detection_delay;

```

```

dedomena='010906ea_0038';

name=['32d_' int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
load(name)

epilipsia=katwfliwsh(err,windowSize,threshold);
[number, positive3, detection_delay]=detection_iktal(epilipsia,number,141193,162556);

mean_delay=mean_delay+detection_delay;

```

```

dedomena='010906ea_0050';

name=['32d_' int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
load(name)

epilipsia=katwfliwsh(err,windowSize,threshold);
[number, positive4, detection_delay]=detection_iktal(epilipsia,number,10123,32589);

mean_delay=mean_delay+detection_delay;

```

```

dedomena='010906ea_0071';

name=['32d_' int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
load(name)

epilipsia=katwfliwsh(err,windowSize,threshold);
[number, positive5, detection_delay]=detection_iktal(epilipsia,number,350035,373355);
mean_delay=mean_delay+detection_delay;

```

```

%=====
%KAI TELOS 8A EXAGOUME TA OUTPUTS KAI 8A METAVALLOUME TO THRESHOLD

```

```

ari8mos_epilipsiwn=positive1+positive2+positive3+positive4+positive5;
mean_delay=mean_delay/ari8mos_epilipsiwn;
ola=(positive1&&positive2&&positive3&&positive4&&positive5)

```

```

if(ola)

```

```

    threshold_low=threshold;           %an exoume epityxia anevazoume to katwfli
    last_successful=threshold;         %kai kratame to twrino san katw orio
else

```

```

    threshold_high=threshold;         %alliws katevazoume to threshold
end                                     %kai kratame to twrino san panw orio

```

```

syn8hkh=~(threshold_high-threshold_low<1);

```

```

end

```

```

last_successful=floor(last_successful);

```

```
fprintf(fid, 'Kanali %d me window %d exei oriako threshold iso me %d \n\n',  
CHANNEL,windowSize,last_successful);
```

```
fclose(fid);
```

```
end
```

Τέλος, έχοντας πλέον υπολογίσει το κατώφλι προχωράμε στην ανίχνευση των κρίσεων με βάση τον παρακάτω κώδικα:

```
threshold=last_successful;
```

```
miss_count=0; %se auth th mevlhth 8a ktahsoume ton ari8mo twn false positive detections  
num_seizures=0; %edw kratame twn ari8mo twn seizures pou anixneuoume gia epalh8eush  
mean_delay=0; %edw 8a apo8hkeusoume th mesh timh tou delay apo to onset tis krisis gia ta  
swsta detection
```

```
number=0;
```

```
%%
```

```
%=====
```

```
===
```

```
for m=0:3
```

```
    dedomena=['010823ab_001' int2str(m)]
```

```
    name=[int2str(CHANNEL) 'CH_' dedomena 'err'];
```

```
    load(name) %pou mas afhnei me mia metavlhth err sto workspace
```

```
    epilipsia=katwfliwsh(err,windowSize,threshold);
```

```
    number=detection(epilipsia,number)
```

```
end
```

```
for k=10:29
```

```
    dedomena=['010827aa_00' int2str(k)]
```

```
    name=[int2str(CHANNEL) 'CH_' dedomena 'err'];
```

```
    load(name)
```

```
    epilipsia=katwfliwsh(err,windowSize,threshold);
```

```
    number=detection(epilipsia,number)
```

```
end
```

```
gyrw={'010823ab_0007', '010823ab_0009', '010823ab_0026', '010823ab_0040',
```



```

'010823ab_0042', '010823ab_0047', '010823ab_0082',};

for l=1:7

    dedomena=gyrw{l}

    name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err'];
    load(name)

    epilipsia=katwfliwsh(err>windowSize,threshold);

    number=detection(epilipsia,number)

end

%%
%PAME TWRA STA IKTAL DEDOMENA
%=====

mean_delay=0;

dedomena='010823ab_0008';

    name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
    load(name) %pou mas afhnei me mia metavltht err sto workspace

    epilipsia=katwfliwsh(err>windowSize,threshold);
    [number, positive1, detection_delay]=detection_iktal(epilipsia,number,332546,376222);
    detection_delay
    mean_delay=mean_delay+detection_delay;
    number

dedomena='010823ab_0027';

    name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
    load(name)

    epilipsia=katwfliwsh(err>windowSize,threshold);
    [number, positive2, detection_delay]=detection_iktal(epilipsia,number,404066,428058);
    detection_delay
    mean_delay=mean_delay+detection_delay;
    number

dedomena='010823ab_0041';

    name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
    load(name)

    epilipsia=katwfliwsh(err>windowSize,threshold);
    [number, positive3, detection_delay]=detection_iktal(epilipsia,number,219083,243750);
    detection_delay
    mean_delay=mean_delay+detection_delay;
    number

dedomena='010823ab_0048';

```

```

name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
load(name)

epilipsia=katwfliwsh(err>windowSize,threshold);
[number, positive4, detection_delay]=detection_iktal(epilipsia,number,384233,406487);
detection_delay
mean_delay=mean_delay+detection_delay;
number

dedomena='010823ab_0083';

name=[int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
load(name)

epilipsia=katwfliwsh(err>windowSize,threshold);
[number, positive5, detection_delay]=detection_iktal(epilipsia,number,71998,112343)
detection_delay
mean_delay=mean_delay+detection_delay;
number

ari8mos_epilipsiwn=positive1+positive2+positive3+positive4+positive5;
mean_delay=mean_delay/ari8mos_epilipsiwn;
ola=(positive1&&positive2&&positive3&&positive4&&positive5);
fprintf(fid,'MISSES= %d DETECTION OLWN TWN KRISEWN= %d KAI MEAN DELAY TIME=
%d \n \n', number, ola,mean_delay);

fprintf(fid,'FALSE POSITIVE RATE = %d per hour KAI MEAN DELAY TIME= %d sec \n ',
number/ 35.6875, mean_delay/256);

end

end

fclose(fid);

```

Στα παραπάνω κομμάτια κώδικα χρησιμοποιούνται οι συναρτήσεις:

katwfliwsh

```

function [epilipsia]= katwfliwsh (err>windowSize,threshold)

mesoi=filter(ones(1>windowSize)/windowSize,1,err);

epilipsia= zeros(1,size(mesoi,2));

for k=1:size(mesoi,2)

    elaxisto=threshold <mesoi(k);

    if (elaxisto)

```

```
    epilipsia(k)=1;
end
```

```
end
```

```
end
```

Που εκτελεί το βήμα της κατωφλίωσης του σήματος σφάλματος για χαρακτηρισμό ενός χρονικού δείγματος ως επιληπτικό ή μη.

detection

```
function [number] = detection(epilipsia,number)
```

```
telos_prohgoumenou=-10241;
```

```
flag=0;
k=1;
n=size(epilipsia);
```

```
while (k < n(2))
```

```
    if (flag==0)
        if (epilipsia(k)==1)
            flag=1;
            arxh=k;
        end
    end
```

```
    else
```

```
        if (epilipsia(k)==0)
            if (k-arxh >200)
```

```
                fprintf('EPIILIPSIA POU ARXIZEI STO %d KAI TELEIWNEI STO %d DIARKEIAS %d \n \n',
arxh, k, k-arxh);
```

```
                if(arxh-telos_prohgoumenou>10240)
```

```
                    number=number+1;
```

```
                end
```

```
                telos_prohgoumenou=k;
```

```
            end
            flag=0;
```

```
        end
    end
```

```
    k=k+1;
```

```
end
```

Που κάνει ανίχνευση κρίσεων σε αρχεία μεσοκριστικών δεδομένων, δεδομένα δηλαδή για τα

ποία ξέρουμε ότι αν ανιχνεύουμε κρίση πρόκειται για ψευδή ανίχνευση.

detection_iktal

```
function [number,positive,detection_delay] = detection_iktal(epilipsia,number,onset,telos)

detection_delay=0;
flag=0;
k=1;
n=size(epilipsia);
positive=0;

telos_prohgoumenou=-10241; %to arxikopoioume etsi wste akoma kai sto 0 na arxizei h prwth
                           epilipsia na vgainei h apostash apo thn prohgoumenh
                           %tetoia wste na mhn exoume
                           %provlhma me to detection

while (k < n(2))

    if (flag==0)           % an den exoume entopisei mexri twra 8etiko shmeio
        if (epilipsia(k)==1) %kai entopisoume twra gia prwth fora
            flag=1;        %kratame to shmeio kai arxizoume na metrame gia to an h diarkeia 8a
                           xepersaei to 300

            arxh=k;
        end
    else
        if (epilipsia(k)==0) %otan stamathsei h epilhptikh akolou8ia pou entopizoume
            if (k-arxh >200) %metrame an exei pragmati xeperasei san diarkeia to 200
                           %opote ola auta ta kanoume AN EINAI PRAGMATI EPILHPSIA

                if((arxh>(onset-2560))&&(arxh<telos)) %an einai swsto detection krishs
                    if(positive==0) %kai einai to prwto detection pou kanoume sthn periodo ths krishs
                        positive=1;
                        detection_delay=arxh-onset; %kratame to detection delay pou kaname
                    end
                else
                    %allws einai missdetection

                    if(arxh-telos_prohgoumenou>10240) %kai an apexei panw apo 40 s apo to
                                                           prohgoumeno

                        number=number+1; %to metrame ws neo missdetection

                    end
                end
            end

            telos_prohgoumenou=k;

        end
        %ara teleiwnontas to detection mporw na ta pernw se
        %pinakes me to onoma twn dedomenwn

        flag=0;

    end

end
```

```
end
```

```
k=k+1;
```

```
end
```

Που κάνει ανίχνευση σε αρχεία που περιέχουν επιληπτικές κρίσεις. Πέρα από το να βεβαιώσει την επιτυχημένη ανίχνευση της κρίσης, το συγκεκριμένο function επιστρέφει την καθυστέρηση ανίχνευσης καθώς και τις ΨΑ που έγιναν για το αρχείο αυτό – όλες δηλαδή τις ανιχνεύσεις που γίνονται 10 sec πριν την έναρξη της κρίσης ή αμέσως μετά το πέρας της.

Π2.4 Γραφικές Παραστάσεις

Τέλος, παρατίθεται ο κώδικας που χρησιμοποιήθηκε για να γίνουν οι γραφικές παραστάσεις των σφαλμάτων κατά τις επιληψίες του ασθενή 1, όπως αυτές παρουσιάζονται στο κεφάλαιο 5.

```
CHANNEL=2;  
windowSize=300
```

```
dedomena='010403ba_0007';
```

```
name=[ int2str(CHANNEL) 'CH_iktal_' dedomena 'err']  
load(name)
```

```
mesoi=filtfilt(ones(1,windowSize)/windowSize,1,err(71100:116090));  
%me diasthma 20.000 samples prin kai 20.000 meta
```

```
figure  
plot(mesoi)
```

```
dedomena='010403ba_0008';
```

```
name=[ int2str(CHANNEL) 'CH_iktal_' dedomena 'err']  
load(name)
```

```
mesoi=filtfilt(ones(1,windowSize)/windowSize,1,err(53382:98125));  
%me diasthma 20.000 samples prin kai 20.000 meta
```

```
figure  
plot(mesoi)
```

```
dedomena='010403ba_0013';
```

```
name=[ int2str(CHANNEL) 'CH_iktal_' dedomena 'err']  
load(name)
```

```
mesoi=filtfilt(ones(1,windowSize)/windowSize,1,err(62010:103855));  
%me diasthma 20.000 samples prin kai 20.000 meta
```

```
figure
plot(mesoi)

dedomena='010403ba_0015';

name=[ int2str(CHANNEL) 'CH_iktal_' dedomena 'err']
load(name)

mesoi=filtfilt(ones(1,windowSize)/windowSize,1,err(329009:370891));
%me diasthma 20.000 samples prin kai 20.000 meta
figure
plot(mesoi)
```