



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

**ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ**

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ
ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ
ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ
ΔΙΚΤΥΑ**

**Παστουσέα Σοφία
Αριθμός Μητρώου: 16088**

**Επιβλέπων Καθηγητής
Ερρίκος Βεντούρας**

Αθήνα 11/10/2024

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Ερρίκος Βεντούρας

Καθηγητής

Παντελεήμων Ασβεστάς

Καθηγητής

Αικατερίνη Σκουρολιάκου

Καθηγήτρια

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η υπογράφουσα Παστουσέα Σοφία του Παναγιώτη, με αριθμό μητρώου 16088 φοιτήτρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

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

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

Ημερομηνία

11/10/2024

Η Δηλούσα

Παστουσέα Σοφία



ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Ευχαριστίες

Σε αυτό το σημείο θα ήθελα να εκφράσω τις ειλικρινείς μου ευχαριστίες στον επιβλέποντα καθηγητή μου, κύριο Βεντούρα Ερρίκο, για την καθοδήγηση, την υποστήριξη και τις σημαντικές συμβουλές του καθ' όλη τη διάρκεια της συγγραφής της διπλωματικής μου εργασίας. Η υπομονή του και οι γνώσεις του υπήρξαν πολύτιμες, συμβάλλοντας σημαντικά στη διαμόρφωση και ολοκλήρωση του παρόντος έργου.

Επίσης, θα ήθελα να ευχαριστήσω τους φίλους μου και την οικογένειά μου, για την θερμή υποστήριξή τους και την ενθάρρυνση που μου προσέφεραν.

Περίληψη

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η χρήση μεθόδων βαθιάς μάθησης για την αυτόματη ανίχνευση συγκεκριμένων κυματομορφών στο ηλεκτροεγκεφαλογράφημα (ΗΕΓ) ύπνου που ονομάζονται υπνικές άτρακτοι.

Οι άτρακτοι αποτελούν σημαντικούς βιοδείκτες για τη μελέτη του ύπνου και τη διάγνωση παθολογικών καταστάσεων. Η αναγνώριση προτύπων και αντικειμένων σε εικόνες είναι ιδιαίτερα ενεργό πεδίο έρευνας στην επιστήμη των υπολογιστών, χάρη στην ανάπτυξη της αναγνώρισης προτύπων, της μηχανικής μάθησης και της υποπερίπτωσής της, της βαθιάς μάθησης. Μέρος των τεχνικών βαθιάς μάθησης είναι η οικογένεια των συνελικτικών νευρωνικών δικτύων (Convolutional Neural Networks - CNN).

Στην παρούσα διπλωματική εργασία, διερευνάται η εφαρμογή του συνελικτικού νευρωνικού δικτύου GoogLeNet σε καταλλήλως επεξεργασμένα δεδομένα υπνικού ΗΕΓ. Το σύνολο δεδομένων χωρίστηκε σε τέσσερα διαφορετικά σύνολα εκμάθησης και δοκιμής και έγινε διερεύνηση για δύο αλγόριθμους βελτιστοποίησης για διάφορες παραμέτρους τους. Από τα αποτελέσματα φάνηκε ότι χρησιμοποιώντας τον αλγόριθμο SGDM για μικρό βήμα εκμάθησης πετυχαίνουμε παραμέτρους επίδοσης πάνω από 90%, σε δίκτυα που επιδεικνύουν και αξιόλογη σταθερότητα στην φάση της εκμάθησής τους.

Λέξεις κλειδιά: *Ηλεκτροεγκεφαλογραφία, άτρακτοι, συνελικτικά νευρωνικά δίκτυα*

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

ABSTRACT

The subject of the present Diploma Thesis is the use of deep learning methods to automatically detect specific waveforms in the sleep electroencephalogram (EEG) called sleep spindles.

Spindles are important biomarkers for the study of sleep and the diagnosis of pathological conditions. Pattern and object recognition in images is a particularly active area of research in computer science, thanks to the development of pattern recognition, machine learning, and its subcase, deep learning. Convolutional Neural Networks (CNN) belong to deep learning techniques.

In the present Thesis, the application of the pretrained GoogLeNet convolutional neural network, to properly processed sleep EEG data, is investigated. The dataset was divided into four different training and testing sets and two optimization algorithms were investigated varying their parameters. The results showed that using the SGDM algorithm for a small learning step we achieved performance parameters above 90%, in networks that also demonstrate remarkable stability in their learning phase.

Keywords: *Electroencephalography, spindles, convolutional neural networks*

Περιεχόμενα

Εισαγωγή.....	8
1.Εγκέφαλος και ύπνος	9
1.1 Η ανατομία του εγκεφάλου	9
1.1.1 Τα νευρικά κύτταρα	11
1.2 Ο ύπνος και τα στάδια του	13
1.2.1 Οι υπνικές άτρακτοι	14
1.2.2 Το ηλεκτροεγκεφαλογράφημα και η καταγραφή των ατράκτων	15
2.Η βαθιά μάθηση, τα συνελικτικά νευρωνικά δίκτυα (CNN) και το GoogLeNet.....	16
2.1 Η μηχανική μάθηση.....	16
2.2 Τεχνητά νευρωνικά δίκτυα.....	18
2.3 Βαθιά μάθηση (deep learning).....	21
2.3.1 Συνελικτικά νευρωνικά δίκτυα (Convolutional neural networks – CNN).....	22
2.3.2 Προεκπαιδευμένα δίκτυα βαθιάς μάθησης	27
2.3.3 Το προεκπαιδευμένο συνελικτικό νευρωνικό δίκτυο GoogLeNet.....	29
3.Δεδομένα και αποτελέσματα.....	33
3.1 Δεδομένα.....	33
3.1.2 Επεξεργασία δεδομένων	33
3.2 Παράμετροι εκπαίδευσης του συνελικτικού νευρωνικού δικτύου GoogLeNet.....	36
3.2.1 Αλγόριθμοι βελτιστοποίησης	37
3.2.2 Μέθοδος βελτιστοποίησης SGDM-(Stochastic Gradient Descent with Momentum).....	37
3.2.3 Μέθοδος βελτιστοποίησης ADAM - (Adaptive Moment Estimation).....	37
3.2.4 Σύγκριση των δύο μεθόδων	37
3.3 Αποτελέσματα εκπαίδευσης και δοκιμής	39
4.Συμπεράσματα	64
Βιβλιογραφία.....	66

Εισαγωγή

Η αναγνώριση προτύπων και αντικειμένων σε εικόνες έχει γίνει ένα από τα πιο ενεργά πεδία έρευνας στην επιστήμη των υπολογιστών, χάρη στην ανάπτυξη της αναγνώρισης προτύπων, της μηχανικής μάθησης και της υποπερίπτωσής της, της βαθιάς μάθησης. Μέρος των τεχνικών βαθιάς μάθησης είναι η οικογένεια των συνελικτικών νευρωνικών δικτύων (Convolutional Neural Networks - CNN). Στο πλαίσιο αυτό, η επεξεργασία και ανάλυση εικόνων ιατρικών δεδομένων προσφέρει σημαντικά οφέλη, ειδικά σε τομείς όπως η διάγνωση και η παρακολούθηση των διαταραχών ύπνου. Ένα από τα κεντρικά χαρακτηριστικά που εξετάζονται σε τέτοιες περιπτώσεις διαταραχών ύπνου είναι οι άτρακτοι του ύπνου (sleep spindles), οι οποίες αποτελούν σημαντικούς βιοδείκτες για τη μελέτη του ύπνου και τη διάγνωση παθολογικών καταστάσεων.

Στην παρούσα διπλωματική εργασία, διερευνάται η εφαρμογή του συνελικτικού νευρωνικού δικτύου GoogLeNet σε καταλλήλως επεξεργασμένα δεδομένα που έχουν αρχικά επεξεργαστεί και χρησιμοποιηθεί σε άλλες εφαρμογές, σε πρότερες διπλωματικές εργασίες [1]. Ο στόχος είναι μέσα από ένα προεκπαιδευμένο (δηλαδή εκπαιδευμένο ήδη με δεδομένα εκτός της τρέχουσας εφαρμογής) συνελικτικό νευρωνικό δίκτυο όπως το GoogLeNet να βελτιστοποιηθεί η ακρίβεια και η ταχύτητα ανίχνευσης αυτών των σημάτων, συμβάλλοντας στην αυτοματοποίηση και βελτίωση της ανάλυσης των δεδομένων ύπνου.

Στο πρώτο κεφάλαιο περιγράφεται συνοπτικά η λειτουργία του εγκεφάλου και κάποιες βασικές δομές αυτού. Στη συνέχεια παρατίθενται στοιχεία από την λειτουργία του ύπνου και των συγκεκριμένων υπό μελέτη σημάτων αυτής της εργασίας, δηλαδή των υπνικών ατράκτων (sleep spindles) όπως και της διαδικασίας εντοπισμού τους αφού καταγραφθούν μέσω του ηλεκτροεγκεφαλογραφήματος (ΗΕΓ).

Το δεύτερο κεφάλαιο εξετάζει τις βασικές αρχές της μηχανικής και βαθιάς μάθησης, των συνελικτικών νευρωνικών δικτύων και τέλος του GoogLeNet που είναι το δίκτυο που επιλέχθηκε για να πραγματοποιηθεί η εκπαίδευση.

Στο τρίτο κεφάλαιο παραθέτονται τα αποτελέσματα της εκπαίδευσης του συνελικτικού νευρωνικού δικτύου, όπως επίσης δίνεται το θεωρητικό υπόβαθρο για τις βασικές παραμέτρους που ρυθμίστηκαν σε αυτό. Τελικά, στο τέταρτο κεφάλαιο, γίνεται ο σχολιασμός των αποτελεσμάτων.

ΚΕΦΑΛΑΙΟ 1

Εγκέφαλος και ύπνος

1.1 Η ανατομία του εγκεφάλου

Ο εγκέφαλος είναι το πιο πολύπλοκο όργανο στο σώμα, που ρυθμίζει όλες τις γνωστικές και συναισθηματικές διεργασίες. Αποτελεί το βασικό όργανο του κεντρικού νευρικού συστήματος μαζί με τον νωτιαίο μυελό. Ρυθμίζει τη σκέψη, τη μνήμη, τη λήψη αποφάσεων, τις αισθήσεις, τη συναισθηματική κατάσταση και τις κινήσεις.

Η δομή του έχει ως εξής:

Τα εγκεφαλικά ημισφαίρια (αριστερό και δεξί) αποτελούνται από α) τον εγκεφαλικό φλοιό, μια στοιβάδα με πολλές αύλακες, β) τα βασικά γάγγλια, που συμμετέχουν στον έλεγχο της κίνησης και στη ρύθμιση των κινήσεων που είναι απαραίτητες για την ομαλή εκτέλεση δραστηριοτήτων, γ) τον ιππόκαμπο, ο οποίος είναι κρίσιμος για τη διαμόρφωση και ανάκληση μνήμης και, τέλος, δ) την αμυγδαλή που είναι υπεύθυνη για να ρυθμίζει «βασικά» συναισθήματα, ειδικά το φόβο και το άγχος. Στον φλοιό διακρίνονται τέσσερις «λοβοί», ο μετωπιαίος, ο βρεγματικός, ο κροταφικός και ο ινιακός.

Ο μεσεγκέφαλος ή μέσος εγκέφαλος: βρίσκεται κάτω από τα εγκεφαλικά ημισφαίρια. Παίζει σημαντικό ρόλο στη ρύθμιση των βασικών αισθητηριακών και κινητικών λειτουργιών, και εμπλέκεται στη ρύθμιση της όρασης, της ακοής, του ελέγχου της κίνησης, και της διατήρησης της εγρήγορσης.

Ο διεγκέφαλος ή διάμεσος εγκέφαλος: είναι μια περιοχή του εγκεφάλου που βρίσκεται ανάμεσα στα εγκεφαλικά ημισφαίρια και πάνω από τον μεσεγκέφαλο. Αποτελείται από δύο κύριες δομές:

α) Τον θάλαμο, ο οποίος είναι υπεύθυνος για την επεξεργασία αισθητηριακών σημάτων. Σχεδόν όλες οι πληροφορίες που προέρχονται από το εξωτερικό περιβάλλον (αφή, όραση, ακοή, γεύση) περνούν από τον θάλαμο, πριν μεταφερθούν στον εγκεφαλικό φλοιό για επεξεργασία.

β) Τον υποθάλαμο, στον οποίο ελέγχονται οι αυτόνομες, ενδοκρινικές και σπλαχνικές λειτουργίες, π.χ. η θερμοκρασία του σώματος, η πείνα, η δίψα και ο κύκλος ύπνου.


Η γέφυρα: Βρίσκεται κάτω από τον μεσεγκέφαλο και αποτελείται από μια μεγάλη μάζα νευρικών ινών και πυρήνων που συνδέουν τον εγκέφαλο με τον νωτιαίο μυελό και την παρεγκεφαλίδα. Λειτουργεί ως "γέφυρα" επικοινωνίας μεταξύ αυτών των περιοχών, ενώ συμμετέχει σε πολλές ζωτικές λειτουργίες, όπως ο έλεγχος της αναπνοής, η κίνηση, και η αισθητηριακή επεξεργασία.

Επίσης περιγράφουμε και τον μυελό, που δεν είναι μέρος του εγκεφάλου, αλλά αποτελεί κύριο τμήμα του κεντρικού νευρικού συστήματος.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ


Ο νωτιαίος μυελός: εκτείνεται από τον προμήκη μυελό του εγκεφάλου μέχρι την οσφυϊκή περιοχή της σπονδυλικής στήλης, περιβάλλεται από τους σπονδύλους, οι οποίοι τον προστατεύουν, χωρίζεται σε διάφορες περιοχές ανάλογα με το επίπεδο της σπονδυλικής στήλης, (την αυχενική περιοχή, την θωρακική περιοχή, την οσφυϊκή περιοχή, την ιερή περιοχή). Δέχεται και προωθεί αισθητικές πληροφορίες από το δέρμα, τις αρθρώσεις και τους μύες των άκρων και του κορμού και λειτουργεί ως κύριος δίαυλος μεταφοράς σημάτων μεταξύ του εγκεφάλου και του υπόλοιπου σώματος, ελέγχοντας την επικοινωνία και τον συντονισμό μεταξύ αισθητήριων και κινητικών λειτουργιών.

Ο προμήκης μυελός: είναι το χαμηλότερο μέρος του εγκεφαλικού στελέχους, (τα άλλα δύο μέρη, είναι ο μεσεγκέφαλος και η γέφυρα), που συνδέει τον εγκέφαλο με τον νωτιαίο μυελό. Αποτελεί μία από τις πιο κρίσιμες δομές του κεντρικού νευρικού συστήματος, καθώς ελέγχει βασικές ζωτικές λειτουργίες, όπως η αναπνοή, η καρδιακή λειτουργία και η αρτηριακή πίεση.[2]



Εικόνα 1.1: Λοβοί του εγκεφάλου. [3]

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 1.2: Δομή εγκεφάλου, στελέχους και νωτιαίου μυελού. [3]

1.1.1 Τα νευρικά κύτταρα

Στο νευρικό σύστημα υπάρχουν δύο κύρια είδη κυττάρων, τα νευρικά κύτταρα ή νευρώνες και τα νευρογλοιακά ή νευρογλοία.

Οι νευρώνες είναι τα κύρια λειτουργικά κύτταρα του νευρικού συστήματος και παίζουν καθοριστικό ρόλο στη μετάδοση και επεξεργασία πληροφοριών. Είναι εξειδικευμένα κύτταρα, σχεδιασμένα να λαμβάνουν, να επεξεργάζονται και να μεταδίδουν ηλεκτροχημικά σήματα, που επιτρέπουν την επικοινωνία μεταξύ διαφορετικών περιοχών του εγκεφάλου, του νωτιαίου μυελού και των υπόλοιπων συστημάτων του σώματος. Οι νευρώνες διαφέρουν από τα περισσότερα άλλα κύτταρα του σώματος λόγω της εξειδικευμένης μορφολογίας και των λειτουργιών τους.

Η δομή τους έχει ως εξής. Ένας τυπικός νευρώνας αποτελείται από τέσσερα κύρια μέρη:

Σώμα του κυττάρου: Το κέντρο επεξεργασίας του νευρώνα, όπου βρίσκεται ο πυρήνας και τα οργανίδια. Το κυτταρικό σώμα είναι υπεύθυνο για τη σύνθεση πρωτεϊνών και άλλων μορίων απαραίτητων για τη λειτουργία του κυττάρου.


ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Δενδρίτες: Αποτελούν τις απολήξεις του νευρώνα, οι οποίες είναι υπεύθυνες για τη λήψη σημάτων από άλλα νευρικά κύτταρα. Οι δενδρίτες διαθέτουν υποδοχείς που αναγνωρίζουν και επεξεργάζονται τα σήματα από τα εξωτερικά ερεθίσματα ή από άλλους νευρώνες.

Νευράξονας: Είναι η εκτεταμένη ίνα που μεταφέρει τα σήματα από το σώμα του κυττάρου προς άλλους νευρώνες, μύες ή αδένες. Στο τέλος του άξονα, οι συναπτικές απολήξεις μεταδίδουν τα σήματα μέσω της σύναψης σε άλλους νευρώνες. Στον νευράξονα άγονται ηλεκτρικά σήματα, τα δυναμικά ενέργειας με εύρος έως δεκάδες mV και διάρκεια της τάξης των λίγων ms.

Προσυναπτικά τελικά κομβία: είναι τα άκρα των νευρώνων από τα οποία απελευθερώνονται νευροδιαβιβαστές κατά τη μετάδοση των σημάτων από έναν νευρώνα σε έναν άλλο ή σε έναν «στόχο», δηλαδή άλλο είδους κυττάρου, όπως ένας μυς ή αδένας. Αποτελούν ένα κρίσιμο μέρος της συναπτικής διαβίβασης, που επιτρέπει την επικοινωνία μεταξύ των νευρικών κυττάρων.

Συνοψίζοντας τα παραπάνω και επικεντρώνοντας στην επικοινωνία μεταξύ κυττάρων, η επικοινωνία μεταξύ νευρώνων πραγματοποιείται μέσω των συναπτικών συνδέσεων. Στην άκρη του άξονα ενός νευρώνα βρίσκονται οι συναπτικές απολήξεις, οι οποίες απελευθερώνουν νευροδιαβιβαστές σε μια μικρή κενή περιοχή που ονομάζεται σύναψη. Οι νευροδιαβιβαστές αυτοί είναι χημικά μόρια που μεταφέρουν το σήμα από έναν νευρώνα στον επόμενο, προσδένοντας σε ειδικούς υποδοχείς στην επιφάνεια του δενδρίτη του άλλου νευρώνα. Η διαδικασία αυτή επιτρέπει την ταχεία μετάδοση πληροφοριών σε όλο το νευρικό σύστημα.[2]



Εικόνα1.3: Δομή του νευρώνα.[4]

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

1.2 Ο ύπνος και τα στάδια του

Ο ύπνος είναι μια βασική φυσιολογική διαδικασία που καταλαμβάνει περίπου το ένα τρίτο της ζωής ενός ανθρώπου και ακολουθεί κερκάδιο (δηλαδή περίπου 24ωρο, στους κύκλους μιας ημέρας) ρυθμό, γνωστό και ως «βιολογικό ρολόι» του σώματος και συγχρονίζεται κυρίως με τα περιβαλλοντικά ερεθίσματα, όπως το φως και το σκοτάδι. Κατά τη διάρκεια του ύπνου, πραγματοποιούνται ζωτικές λειτουργίες όπως η ανάκτηση ενέργειας, η επισκευή ιστών και η ενίσχυση της μνήμης.

Η μελέτη του ύπνου και των διαταραχών του βασίζεται σε μεγάλο βαθμό στη νευροφυσιολογική παρακολούθηση μέσω ηλεκτροεγκεφαλογραφήματος (HEΓ), το οποίο παρέχει πληροφορίες για την εγκεφαλική δραστηριότητα.


Ο ύπνος χωρίζεται σε δύο κύριες φάσεις:

Ύπνος μη ταχείας κίνησης των ματιών (Non-Rapid Eye Movement - NREM): Ο NREM ύπνος χωρίζεται σε τέσσερα στάδια, με την εγκεφαλική δραστηριότητα να γίνεται προοδευτικά πιο συγχρονισμένη και βραδεία (συχνοτικά) καθώς ο ύπνος «βαθαίνει». Στο στάδιο 1 ο ύπνος είναι ελαφρύς, όπου τα άτομα μπορεί εύκολα να ξυπνήσουν. Χαρακτηρίζεται από αργές, ταλαντωτικές εγκεφαλικές δραστηριότητες και μείωση του μυϊκού τόνου. Στο στάδιο 2, το «βάθος» του ύπνου αυξάνεται και το HEΓ εμφανίζει χαρακτηριστικά μοτίβα, όπως είναι οι άτρακτοι (sleep spindles) και συμπλέγματα K. Τέλος, στα στάδια 3 και 4 επέρχεται ο «βαθύς» ύπνος, όπου κυριαρχούν τα κύματα δέλτα στο HEΓ. Αυτή η φάση είναι σημαντική για τη σωματική ανάρρωση και την ανάπτυξη.

Ύπνος ταχείας κίνησης των ματιών (Rapid Eye Movement - REM): Ο REM ύπνος χαρακτηρίζεται από έντονη εγκεφαλική δραστηριότητα, γρήγορες κινήσεις των ματιών, όνειρα, και προσωρινή ατονία των μυών (σχεδόν πλήρης παράλυση του σώματος). Κατά την διάρκεια του REM ο τύπος εκφόρτισης των περισσότερων νευρώνων μοιάζει με αυτόν κατά την διάρκεια της ενεργούς εγρήγορσης.

Η εναλλαγή αυτών των σταδίων σχηματίζει κύκλους που επαναλαμβάνονται καθ' όλη τη διάρκεια της νύχτας, με το κάθε κύκλο να διαρκεί περίπου 90 λεπτά. Σε ενήλικες ο περισσότερος χρόνος καταναλώνεται στο στάδιο 2 του Non-REM (50-60%) ενώ οι REM κύκλοι καταλαμβάνουν το 20-25% του συνολικού ύπνου, τα στάδια 3 και 4 κατέχουν το 15-20%, τέλος το στάδιο 1 του Non-REM κατέχει το 5%. [2]

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 1.4: Κυματομορφές σημάτων ύπνου [5].

1.2.1 Οι υπνικές άτρακτοι

Οι υπνικές άτρακτοι (sleep spindles) είναι χαρακτηριστικά μοτίβα εγκεφαλικής δραστηριότητας που εμφανίζονται κατά τη διάρκεια του ύπνου. Είναι βραχείας διάρκειας «εκρήξεις» συγχρονισμένων κυμάτων με συχνότητα 10-15Hz, που διαρκούν περίπου 0,5-2s. Αυτές οι εκφορτίσεις έχουν εντοπιστεί μέσω ηλεκτροεγκεφαλογραφήματος (HEΓ) και είναι ένα από τα βασικά χαρακτηριστικά που ορίζουν το στάδιο 2 του NREM ύπνου. Όταν εμφανίζονται σε μια ένδειξη του HEΓ, αυτό δείχνει ότι ένα άτομο έχει αποκοιμηθεί, δηλαδή έχει πάψει η ενσυνείδητη επαφή με το εξωτερικό περιβάλλον. Θεωρούνται σημαντικές για πολλές λειτουργίες που σχετίζονται με τον ύπνο, όπως η παγίωση της μνήμης και η ανάπτυξη του φλοιού.[6]

Το συχνοτικό περιεχόμενο των ατράκτων φαίνεται να είναι εντοπισμένο σε δύο υποπεριοχές συχνοτήτων αλλά και τοπογραφικά οργανωμένο, μεταξύ διαφορετικών περιοχών του εγκεφάλου. Συγκεκριμένα εντοπίζονται δυο κατηγορίες: Οι «γρήγορες» (υψηλής συχνότητας) άτρακτοι που εμφανίζονται σε συχνότητες πάνω από 13Hz και παρατηρούνται κυρίως στην κέντρο-βρεγματική περιοχή του εγκεφάλου, δηλαδή κοντά στο κέντρο και προς το πάνω μέρος του κεφαλιού και οι «αργές» άτρακτοι που έχουν συχνότητες κάτω από 13Hz και είναι πιο συχνές στην μετωπιαία περιοχή, δηλαδή στο μπροστινό μέρος του εγκεφάλου, κοντά στο μέτωπο.[7]

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 1.5: Διάγραμμα υπνικών ατράκτων και συμπλεγμάτων K.[8]

1.2.2 Το ηλεκτροεγκεφαλογράφημα και η καταγραφή των ατράκτων

Το ηλεκτροεγκεφαλογράφημα (ΗΕΓ) είναι μια διαγνωστική μέθοδος που χρησιμοποιείται για την καταγραφή της ηλεκτρικής δραστηριότητας του εγκεφάλου. Αυτή η μέθοδος βασίζεται στη μέτρηση των ηλεκτρικών σημάτων που παράγονται από τις νευρικές δραστηριότητες και παρέχει πληροφορίες σχετικά με τη λειτουργία του εγκεφάλου. Τοποθετούνται περίπου 20-30 ηλεκτρόδια στο τριχωτό της κεφαλής του ασθενούς που είναι συνδεδεμένα με το μηχανοηλεκτροεγκεφαλογράφο μέσω καλωδίων και η τοποθέτηση γίνεται συνήθως με βάση το σύστημα 10-20, που καθορίζει τη θέση των ηλεκτροδίων σε συγκεκριμένα σημεία του κεφαλιού, σύμφωνα με ανατομικά ορόσημα.

Οι υπνικές άτρακτοι μετριοούνται με τη χρήση του ηλεκτροεγκεφαλογράφηματος, που αποτελεί μέρος της πολυϋπνογραφίας, δηλαδή της μελέτης ύπνου που περιλαμβάνει καταγραφές και με άλλες μετρητικές διατάξεις επιπλέον του ΗΕΓ. Οι άτρακτοι εμφανίζονται ως ομαλά ημιτονοειδή κύματα και είναι σχετικά εύκολο να εντοπιστούν λόγω της αυξημένης συχνότητάς τους. Στην καταγραφή φαίνονται ως «εκρήξεις» δραστηριότητας μέσα σε λιγότερο πυκνά και λιγότερο συχνά κύματα. Αυξάνονται και μειώνονται σε πλάτος, δίνοντάς τους την χαρακτηριστική εμφάνισή τους που θυμίζει το αδράχτι του αργαλειού (για αυτό και η ονομασία τους ως άτρακτοι).[7][9][10].

ΚΕΦΑΛΑΙΟ 2

Η βαθιά μάθηση, τα συνελικτικά νευρωνικά δίκτυα (CNN) και το GoogLeNet

2.1 Η μηχανική μάθηση

Ο όρος μηχανική μάθηση αναφέρεται σε ένα σύνολο θεμάτων που ασχολούνται με τη δημιουργία και την αξιολόγηση αλγορίθμων που διευκολύνουν την αναγνώριση προτύπων, την ταξινόμηση και την πρόβλεψη, με βάση μοντέλα που προέρχονται από υπάρχοντα δεδομένα. Κατά την εξέταση της μηχανικής μάθησης, σε γενικές γραμμές, θα πρέπει να αναγνωριστούν δύο πτυχές της «μηχανοποίησης». Πρώτον, επιδιώκεται ότι οι εργασίες ταξινόμησης και πρόβλεψης μπορούν να πραγματοποιηθούν από μια κατάλληλα προγραμματισμένη υπολογιστική μηχανή. Δηλαδή, το προϊόν της μηχανικής μάθησης είναι ένας ταξινομητής που μπορεί να χρησιμοποιηθεί εφικτά στο διαθέσιμο υλικό. Δεύτερον, επιδιώκεται η δημιουργία του ταξινομητή να είναι η ίδια σε μεγάλο βαθμό μηχανοποιημένη και να μην περιλαμβάνει πολύ μεγάλη ανθρώπινη συμβολή. Ο βασικός στόχος είναι ότι η χρήση αυτόματων μεθόδων κατασκευής αλγορίθμων μπορεί να ελαχιστοποιήσει την πιθανότητα ανθρώπινες επεμβάσεις να επηρεάσουν την επιλογή και την απόδοση του αλγορίθμου. Τόσο η δημιουργία του αλγορίθμου όσο και η λειτουργία του για την ταξινόμηση αντικειμένων ή την πρόβλεψη γεγονότων πρέπει να βασίζονται σε συγκεκριμένα, παρατηρήσιμα δεδομένα.

Στον τομέα της μηχανικής μάθησης υπάρχουν οι παρακάτω βασικές κατηγορίες:

Επιβλεπόμενη (Supervised): Στην επιβλεπόμενη μάθηση, το μοντέλο εκπαιδεύεται σε ένα σύνολο δεδομένων με «ετικέτες», δηλαδή κάθε παράδειγμα εκπαίδευσης αντιστοιχίζεται με μια ετικέτα/κατηγορία/κλάση εξόδου. Ο στόχος είναι το μοντέλο να μάθει μια αντιστοίχιση από τις εισόδους στις εξόδους, ανά κατηγορία, και να κάνει προβλέψεις σε νέα, άγνωστα δεδομένα. Εκτός από την πρόβλεψη ενός κατηγορικού χαρακτηριστικού, όπως η ετικέτα κλάσης, σε κάθε εφαρμογή της μάθησης με επίβλεψη, θα ήταν χρήσιμο ο αλγόριθμος ταξινόμησης να επιστρέφει μια τιμή που υποδεικνύει «αμφιβολία», υποδεικνύοντας ότι δεν είναι σαφές σε ποια από τις πολλές πιθανές κλάσεις θα πρέπει να καταταχθεί το αντικείμενο, ή ότι το σήμα εισόδου είναι «ακραίο», υποδεικνύοντας ότι το αντικείμενο εισόδου είναι τόσο διαφορετικό από οποιοδήποτε αντικείμενο που έχει παρατηρηθεί προηγουμένως, ώστε η καταλληλότητα οποιασδήποτε απόφασης σχετικά με την ταξική ένταξη είναι αμφισβητήσιμη.

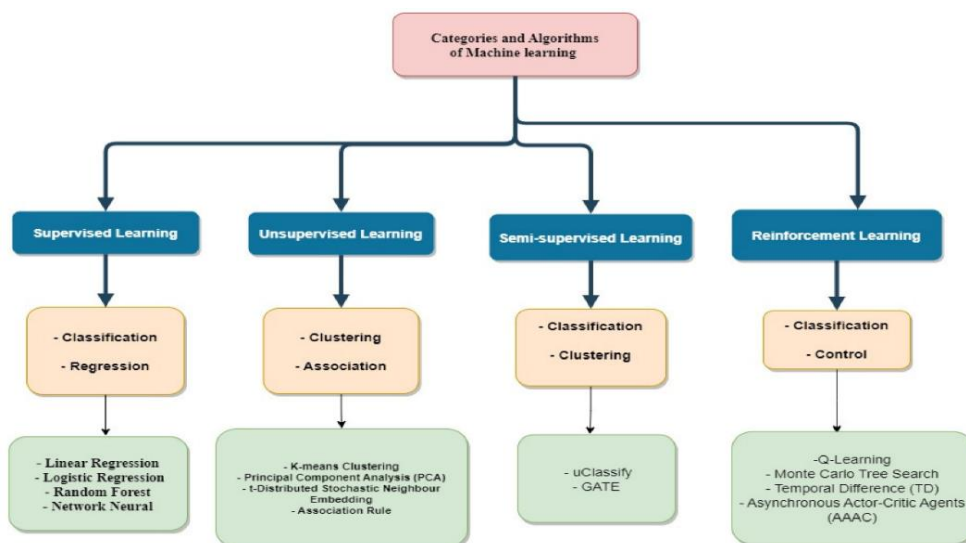
Μη επιβλεπόμενη (Unsupervised): Στη μάθηση χωρίς επίβλεψη δεν υπάρχουν προκαθορισμένες ετικέτες κλάσεων για τα υπό μελέτη αντικείμενα. Σε αυτή την περίπτωση, ο στόχος είναι η εξερεύνηση των δεδομένων και η ανακάλυψη ομοιοτήτων μεταξύ των αντικειμένων. Οι ομοιότητες χρησιμοποιούνται για τον ορισμό ομάδων αντικειμένων, οι οποίες αναφέρονται ως συστάδες (clusters). Με άλλα λόγια, η μάθηση χωρίς επίβλεψη αποσκοπεί στην αποκάλυψη φυσικών ομαδοποιήσεων στα δεδομένα. Έτσι, τα δύο παραδείγματα μπορούν απλοϊκά να

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

αντιπαραβληθούν ως εξής: στην επιβλεπόμενη μάθηση, τα δεδομένα συνοδεύονται από ετικέτες κλάσεων και μαθαίνουμε πώς να συσχετίζουμε τα δεδομένα με ετικέτες με κλάσεις- στη μάθηση χωρίς επίβλεψη, όλα τα δεδομένα είναι χωρίς ετικέτες και η διαδικασία μάθησης συνίσταται τόσο στον ορισμό των ετικετών όσο και στη συσχέτιση των αντικειμένων με αυτές [11].

Ημιεπιβλεπόμενη (Semi-supervised): Η μάθηση με «ημιεπίβλεψη» περιλαμβάνει χαρακτηριστικά τόσο της επιβλεπόμενης όσο και της μη επιβλεπόμενης μηχανικής μάθησης. Χρησιμοποιεί το συνδυασμό επισημασμένων και μη επισημασμένων συνόλων δεδομένων για την εκπαίδευση των αλγορίθμων της. Χρησιμοποιώντας και τους δύο τύπους συνόλων δεδομένων, η μάθηση με ημιεπίβλεψη κάποιες φορές ξεπερνά τα μειονεκτήματα των δύο αυτών κατηγοριών. Χρησιμοποιείται συχνά όταν η απόκτηση δεδομένων με ετικέτες είναι δαπανηρή ή χρονοβόρα [12].

Ενισχυμένη (Reinforced): Η μάθηση μέσω της αλληλεπίδρασης με το «περιβάλλον» του προβλήματος κατηγοριοποίησης ονομάζεται ενισχυτική μάθηση. Αντί να λαμβάνει σαφείς οδηγίες για το τι πρέπει να κάνει, ένα σύστημα ενισχυτικής μάθησης μαθαίνει μέσω των «δικών» του δραστηριοτήτων. Επιλέγει μια τρέχουσα «πορεία δράσης» με βάση προηγούμενες αλληλεπιδράσεις (εκμετάλλευση) και νέες επιλογές (εξερεύνηση). Έτσι, θα μπορούσε να χαρακτηριστεί ως μια διαδικασία μάθησης που βασίζεται στη δοκιμή και το σφάλμα. Το σύστημα ενισχυτικής μάθησης λαμβάνει ένα σήμα με τη μορφή μιας τιμής ανταμοιβής που δείχνει αν μια ενέργεια ήταν επιτυχής ή όχι. Ο στόχος είναι να μάθει μια στρατηγική (πολιτική) που μεγιστοποιεί τη σωρευτική ανταμοιβή με την πάροδο του χρόνου [13].



Εικόνα 2.1: Κατηγορίες μηχανικής μάθησης [13].

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.2 Τεχνητά νευρωνικά δίκτυα


Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) είναι μαθηματικές-αλγοριθμικές κατασκευές (συναρτήσεις εισόδου-εξόδου) που έχουν ως βασική δομική μονάδα τον τεχνητό νευρώνα, ένα μαθηματικό μοντέλο που σε κάποιες βασικές του λειτουργίες μοιάζει με τους ανθρώπινους νευρώνες του εγκεφάλου, κυρίως στον τρόπο που οι τεχνητοί νευρώνες επεξεργάζονται και μεταδίδουν πληροφορίες. Τα δεδομένα εισέρχονται στο δίκτυο και το διατρέχουν, υποβάλλονται σε επεξεργασία με τη χρήση διαδοχικών επιπέδων/στοιβάδων/στρώματων νευρώνων, μέχρι να φτάσουν στην έξοδο. Κάθε στρώμα περιέχει πολλαπλούς νευρώνες που επεξεργάζονται τα δεδομένα εισόδου που τους έρχονται από άλλα στρώματα. Τα νευρωνικά δίκτυα χρησιμοποιούνται ευρέως στην αναγνώριση προτύπων: ιατρικών δεδομένων, εικόνων, στην επεξεργασία φυσικής γλώσσας, στην αναγνώριση ομιλίας. Οι κυριότερες κατηγορίες ΤΝΔ είναι τα δίκτυα Perceptron, εμπροσθοτροφοδοτούμενα δίκτυα, δηλαδή δίκτυα που η πληροφορία προχωρά από αρχικό/κατώτερο στρώμα μόνο προς επόμενο/άνωτερο, στην πορεία προς την έξοδο (layered feed forward networks), αναδρομικά δίκτυα (recurrent networks) στα οποία η είσοδος σε ένα στρώμα μπορεί να προέρχεται είτε από «κατώτερο/προηγούμενο» στρώμα είτε από «άνωτερο/επόμενο στρώμα» και συνήθως ακολουθείται μια πορεία αρχικά «ορθόδρομη» (από την είσοδο στην έξοδο) και στην συνέχεια «αντίδρομη» (από την έξοδο προς την είσοδο). Ειδικές περιπτώσεις εμπροσθοτροφοδοτούμενων δικτύων είναι τα συνελικτικά νευρωνικά δίκτυα (Convolutional neural networks - CNN), ενώ αναδρομικών δικτύων τα δίκτυα τύπου gated recurrent unit (GRU) networks και long short-term memory (LSTM) networks [14].

Η δομή που έχει ένα ΤΝΔ έχει ως εξής:

- Τα ΤΝΔ αποτελούνται από στρώματα κόμβων.
- Το πρώτο στρώμα ενός ΤΝΔ ονομάζεται στρώμα εισόδου, ακολουθούν τα «κρυφά» στρώματα και τέλος το στρώμα εξόδου.
- Κάθε κόμβος εκτελεί κάποιου είδους υπολογισμό, ο οποίος μεταβιβάζεται σε άλλους κόμβους «βαθύτερα» στο ΤΝΔ [15].

Οι νευρώνες στα μοντέλα μηχανικής μάθησης είναι οι κόμβοι μέσω των οποίων ρέουν δεδομένα και υπολογισμοί, και λειτουργούν ως εξής. Λαμβάνουν ένα ή περισσότερα σήματα εισόδου. Αυτά τα σήματα εισόδου μπορεί να προέρχονται είτε από το σύνολο των δεδομένων εισόδου, είτε από νευρώνες που είναι τοποθετημένοι σε προηγούμενο επίπεδο του νευρωνικού δικτύου.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα:2.2: Δομή ενός ΤΝΔ [15].

Οι νευρώνες σε ένα μοντέλο μηχανικής μάθησης είναι σε θέση να έχουν συνάψεις που συνδέονται με περισσότερους από έναν νευρώνες στο προηγούμενο επίπεδο. Κάθε σύναψη έχει ένα σχετικό βάρος, το οποίο επηρεάζει τη σημασία του προηγούμενου νευρώνα στο συνολικό νευρωνικό δίκτυο.

Τα βάρη είναι ένα πολύ σημαντικό θέμα στον τομέα της μηχανικής μάθησης, επειδή η προσαρμογή των βαρών ενός μοντέλου είναι ο κύριος τρόπος μέσω του οποίου εκπαιδεύονται τα μοντέλα. Είναι οι τιμές που, όπως θα αναφέρουμε στην συνέχεια, σχετίζονται με τα φίλτρα που χρησιμοποιούνται στα επίπεδα συνελίξεων των CNNs. Όταν ένα φίλτρο ολισθαίνει πάνω στα δεδομένα εισόδου (όπως μια εικόνα), τα βάρη καθορίζουν τον τρόπο με τον οποίο το δίκτυο ανταποκρίνεται σε συγκεκριμένα μοτίβα ή χαρακτηριστικά στα δεδομένα. Τα βάρη προσαρμόζονται κατά τη διάρκεια της εκπαίδευσης για να βελτιωθεί η ακρίβεια του δικτύου.

Μόλις ένας νευρώνας λάβει τις εισόδους του από τους νευρώνες του προηγούμενου στρώματος του μοντέλου (ή και επόμενου αν έχουμε αναδρομικό δίκτυο), προσθέτει κάθε σήμα εισόδου του πολλαπλασιασμένο με το αντίστοιχο βάρος του και εισάγει τις τροποποιημένες έτσι εισόδους σε μια συνάρτηση ενεργοποίησης.

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**




Εικόνα 2.3: αναπαράσταση ενός τεχνητού νευρώνα [15].

Η συνάρτηση ενεργοποίησης υπολογίζει την τιμή εξόδου για τον νευρώνα. Αυτή η τιμή εξόδου μεταβιβάζεται στη συνέχεια στο επόμενο επίπεδο του νευρωνικού δικτύου μέσω μιας σύνδεσης. Οι συναρτήσεις ενεργοποίησης είναι μια βασική έννοια στη μηχανική μάθηση. Είναι αυτό που επιτρέπει στους νευρώνες ενός νευρωνικού δικτύου να επικοινωνούν μεταξύ τους μέσω των συνάψεών τους. Γενικά, οι συναρτήσεις ενεργοποίησης χρησιμοποιούνται επίσης για την αύξηση της μη γραμμικότητας των δεδομένων και για την ταξινόμηση της εξόδου ανάλογα με το μοντέλο και τα δεδομένα που χρησιμοποιούνται σε αυτό.


Υπάρχουν τέσσερις κύριοι τύποι συναρτήσεων ενεργοποίησης (παρακάτω δείχνουμε τυπικές γραφικές παραστάσεις των συναρτήσεων, χωρίς να έχουμε αριθμήσει τις σχετικές εικόνες) [15],[16]:

- Συναρτήσεις κατωφλιού (Threshold functions):




ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ


- Σιγμοειδείς συναρτήσεις (Sigmoid functions):



- Συναρτήσεις «ανόρθωσης» (Rectifier functions – Rectified Linear Units ReLUs):



- Συναρτήσεις υπερβολικής εφαπτομένης (Hyperbolic Tangent functions):



2.3 Βαθιά μάθηση (deep learning)

Τα τελευταία χρόνια, η «βαθιά» μάθηση (deep learning - DL), που είναι η τεχνική εκπαίδευσης των «βαθιών» (νευρωνικών) δικτύων, αποτελεί την πιο δημοφιλή υπολογιστική προσέγγιση στον τομέα της μηχανικής μάθησης, επιτυγχάνοντας εξαιρετικά αποτελέσματα σε μια ποικιλία σύνθετων γνωστικών καθηκόντων, που ταιριάζουν ή και ξεπερνούν τις ανθρώπινες επιδόσεις. Η τεχνολογία της βαθιάς μάθησης, η οποία προέκυψε από τα ΤΝΔ, έχει γίνει διαδεδομένη, διότι όταν εκπαιδεύονται σωστά, τα βαθιά νευρωνικά δίκτυα έχουν αποδειχθεί πολύ καλά σε ένα ευρύ φάσμα προβλημάτων ταξινόμησης και παλινδρόμησης, λόγω της ικανότητάς τους να μαθαίνουν από τα παρεχόμενα δεδομένα, καλύτερα από τα λεγόμενα πλέον και «ρηχά» δίκτυα. Πρόκειται για ένα μοντέλο δικτύου που αποτελείται από

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

νευρώνες με πολλαπλές παραμέτρους και, κυρίως, πολλά επίπεδα μεταξύ εισόδου και εξόδου.

Το κύριο χαρακτηριστικό είναι ότι ενώ τα «ρηχά» (shallow) νευρωνικά δίκτυα, όπως αυτά που εξετάσαμε στην προηγούμενη υποενότητα αποτελούνται από 3 επίπεδα (εισόδου-ενδιάμεσο ή «κρυφό»-εξόδου), ή κάποιες φορές από 2 ή το πολύ 3 ενδιάμεσα («κρυφά») στρώματα, στην βαθιά μάθηση ο αριθμός των ενδιάμεσων στρωμάτων μπορεί να γίνει πολύ μεγάλος και συνήθως έχουμε «ενότητες» (ενδιάμεσων) επιπέδων, όπου κάθε ενότητα αποτελείται από νευρώνες με περίπου ίδια δομή. Επίσης οι τύποι των συνδέσεων μεταξύ των νευρώνων, οι συναρτήσεις ενεργοποίησης, μπορεί να ποικίλουν από ενότητα επιπέδων σε άλλη ενότητα επιπέδων. Κατά συνέπεια, είναι γνωστά ως βαθιά νευρωνικά δίκτυα.

Η βαθιά μάθηση παρέχει αυτόνομη εκμάθηση των χαρακτηριστικών και ιεραρχική αναπαράστασή τους σε πολλαπλά επίπεδα. Σε αντίθεση με τις συμβατικές («ρηχές») προσεγγίσεις μηχανικής μάθησης, αυτή η ευρωστία είναι αποτέλεσμα της ισχυρής, λόγω των πολλών επιπέδων, διαδικασίας του DL. Ολόκληρη η πολλαπλών επιπέδων αρχιτεκτονική της βαθιάς μάθησης χρησιμοποιείται για την εξαγωγή και την τροποποίηση των χαρακτηριστικών. Τα πρώιμα στρώματα κάνουν στοιχειώδη επεξεργασία των εισερχόμενων δεδομένων ή μαθαίνουν απλά χαρακτηριστικά και η έξοδος αποστέλλεται στα ανώτερα στρώματα, τα οποία είναι υπεύθυνα για την εκμάθηση περίπλοκων χαρακτηριστικών. Ως εκ τούτου, η βαθιά μάθηση είναι κατάλληλη για το χειρισμό μεγαλύτερων συνόλων δεδομένων και μεγαλύτερης πολυπλοκότητας [13]. Έτσι ανακαλύπτονται περίπλοκες δομές σε μεγάλα σύνολα δεδομένων χρησιμοποιώντας τον αλγόριθμο οπισθοτροφοδότησης (backpropagation), που χρησιμοποιήθηκε αρχικά στα ρηχά TND, για να υποδείξει πώς μια μηχανή θα πρέπει να αλλάξει τις εσωτερικές της παραμέτρους που χρησιμοποιούνται για τον υπολογισμό της αναπαράστασης σε κάθε στρώμα από την αναπαράσταση που υπολογίστηκε στο προηγούμενο στρώμα. Τα δίκτυα βαθιάς συνελικτικής μάθησης, που αποτελούν μια κατηγορία εμπροσθοτροφοδοτούμενων βαθιών TND έχουν επιφέρει καινοτομίες στην επεξεργασία εικόνων, βίντεο, ομιλίας και ήχου, ενώ τα αναδρομικά δίκτυα έχουν χρησιμοποιηθεί σε δομές δεδομένων που εμπεριέχουν μια ακολουθία πληροφορίας, όπως το κείμενο και η ομιλία [17].

2.3.1 Συνελικτικά νευρωνικά δίκτυα (Convolutional neural networks – CNN)

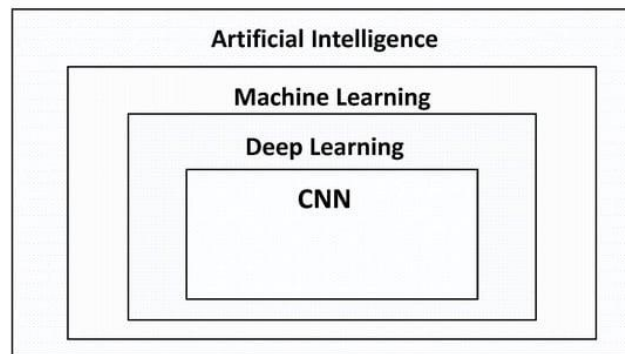
Ο Yann LeCun είναι περισσότερο γνωστός για την ανάπτυξη των νευρωνικών δικτύων συνελικτικού τύπου, που ονομάζονται συνελικτικά νευρωνικά δίκτυα (CNN), το οποίο είναι ειδικά σχεδιασμένα για την επεξεργασία δομημένων δεδομένων «πλέγματος», όπως οι εικόνες. Τα CNN είναι ένας τύπος δικτύων εμπροσθοτροφοδότησης, δηλαδή δικτύων που έχουμε ροή της πληροφορίας μόνο από ένα «κατώτερο» (πρότερο στη δομή) στρώμα σε «ανώτερα» (επόμενα στην δομή) στρώματα και έχουν γίνει το θεμέλιο της σύγχρονης όρασης υπολογιστών, επιτρέποντας επαναστατικές ανακαλύψεις σε εργασίες όπως η αναγνώριση εικόνων, η ανίχνευση αντικειμένων και η αναγνώριση προσώπου.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Η ονομασία «συνελικτικό» υποδηλώνει ότι το δίκτυο χρησιμοποιεί μια μαθηματική διαδικασία που ονομάζεται συνέλιξη (Convolution). Η συνέλιξη είναι ένα εξειδικευμένο είδος γραμμικής πράξης. Τα συνελικτικά νευρωνικά δίκτυα είναι νευρωνικά δίκτυα που χρησιμοποιούν συνέλιξη σε ένα τουλάχιστον από τα στρώματά τους, αντί του γενικού πολλαπλασιασμού πινάκων (ή ισοδύναμα, της απλής προώθησης των δεδομένων εισόδου μιας δισδιάστατης εικόνας σε ξεχωριστούς και μη αλληλεπιδρώντες μεταξύ τους νευρώνες ενός στρώματος εισόδου) [18].

Τα συνελικτικά δίκτυα ξεκίνησαν ως «ρηχά» δίκτυα (αν και σχετικώς ρηχά, διότι από τη δομή τους, όπως θα φανεί παρακάτω χρειάζονται, ακόμη και στις απλούστερες εκδοχές τους, λίγο περισσότερα από 3 στρώματα). Η πραγματική τους όμως διάδοση επιτεύχθηκε όταν έγινε δυνατή η χρήση πολλών περισσότερων επιπέδων, δηλαδή όταν έγιναν μέρος των τεχνικών/δικτύων βαθιάς μάθησης.

Ένα CNN μπορεί να θεωρηθεί ως ένας αλγόριθμος βαθιάς μάθησης που μπορεί να λάβει μια εικόνα εισόδου, να αποδώσει σημασία (μαθησιακά βάρη) σε διάφορες πτυχές/αντικείμενα της εικόνας και να είναι σε θέση να διακρίνει τη μία εικόνα από την άλλη.

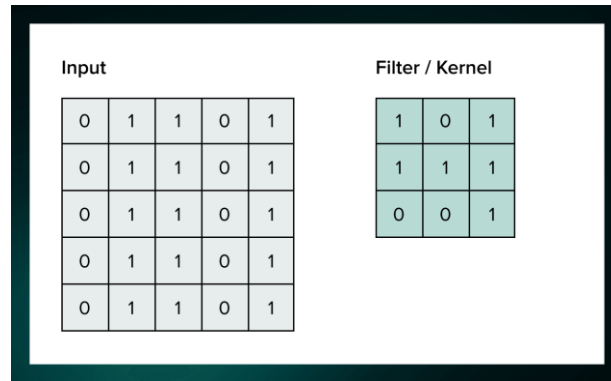


Εικόνα 2.4: Η σχέση μεταξύ AI, ML, DL, και CNN [19].

Συνέλιξη (convolution):

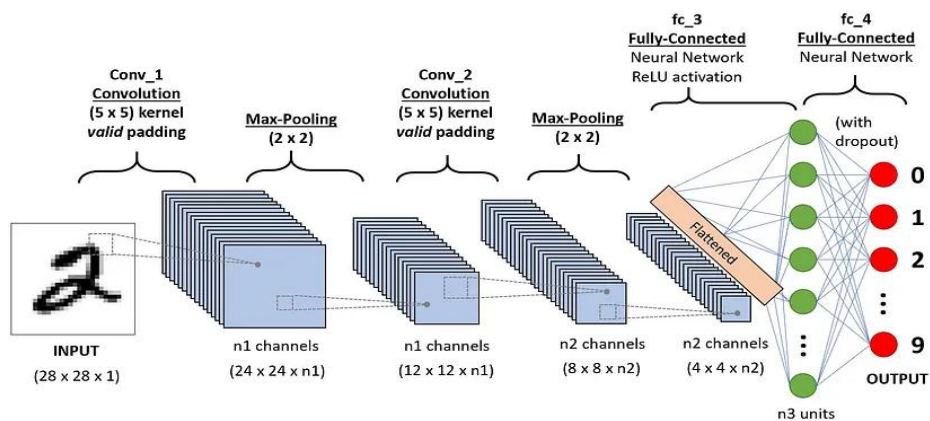
Η συνέλιξη είναι μια μαθηματική πράξη που επιτρέπει τη συγχώνευση δύο συνόλων πληροφοριών. Στην περίπτωση του CNN, η συνέλιξη εφαρμόζεται στα δεδομένα εισόδου για το φιλτράρισμα των πληροφοριών και την παραγωγή ενός χάρτη χαρακτηριστικών. Αυτό το φίλτρο ονομάζεται επίσης πυρήνας ή ανιχνευτής χαρακτηριστικών και οι διαστάσεις του μπορεί να είναι, για παράδειγμα, 3x3. Για την εκτέλεση της συνέλιξης, ο πυρήνας περνάει από την εικόνα εισόδου, κάνοντας πολλαπλασιασμό πινάκων στοιχείο προς στοιχείο.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 2.5: Το συνελικτικό φίλτρο και τα δεδομένα εισόδου [20].

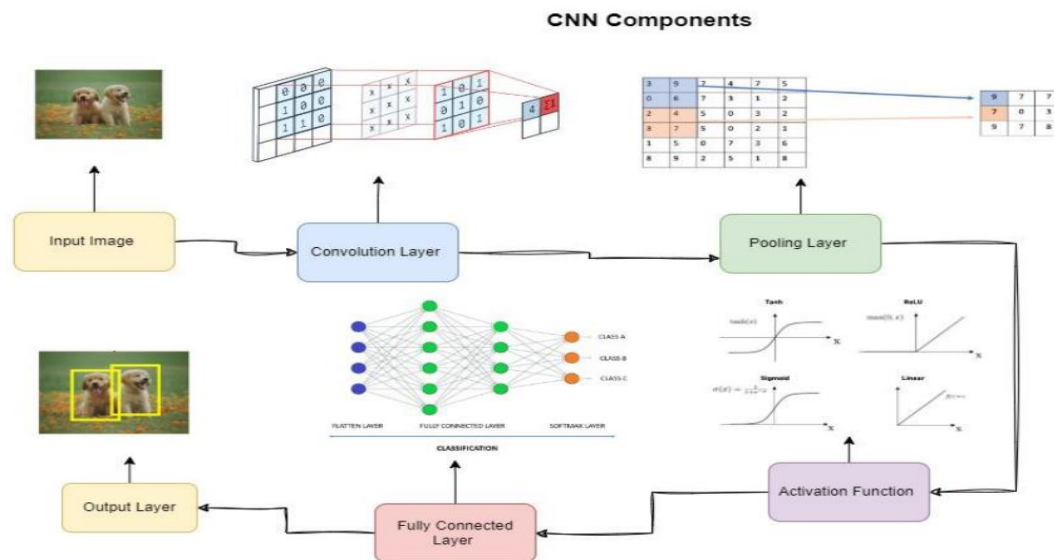
Η είσοδος για τα συνελικτικά νευρωνικά δίκτυα παρέχεται μέσω εικόνων. Τα συνελικτικά νευρωνικά δίκτυα χρησιμοποιούνται για την αυτόματη εκμάθηση μιας ιεραρχίας χαρακτηριστικών που μπορούν στη συνέχεια να χρησιμοποιηθούν για ταξινόμηση, σε αντίθεση με τη χειροκίνητη παραγωγή χαρακτηριστικών. Για να επιτευχθεί αυτό, κατασκευάζεται μια ιεραρχία χαρτών χαρακτηριστικών με επαναληπτική συνέλιξη της εικόνας εισόδου με φίλτρα που «μαθαίνονται», δηλαδή φίλτρα των οποίων οι τιμές τροποποιούνται στην διαδικασία της εκμάθησης, διαδικασία ανάλογη αυτής των ρηχών δικτύων, αλλά συνολικά πολύ πιο απαιτητικής, επειδή έχουμε έως και δεκάδες στρώματα. Λόγω της ιεραρχικής μεθόδου, τα υψηλότερα στρώματα μπορούν να μάθουν πιο περίπλοκα χαρακτηριστικά που είναι επίσης αμετάβλητα σε παραμόρφωση και μετατόπιση.



Εικόνα 2.6: Παράδειγμα δομής συνελικτικού νευρωνικού δικτύου [21].

Ένα CNN αποτελείται συνήθως από τέσσερις τύπους (οικογένειες/ομάδες) επιπέδων/στρωμάτων, συνελικτικά στρώματα, στρώματα ομαδοποίησης, πλήρως συνδεδεμένα στρώματα και στρώματα μονάδων ανόρθωσης.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 2.7: Παράδειγμα δομής συνελικτικού νευρωνικού δικτύου όπου απεικονίζονται οι κύριες κατηγορίες επιπέδων [22].

Ένα γενικό χαρακτηριστικό για κάθε CNN, όπως συμβαίνει και στα ρηγά ΤΝΔ, είναι ότι αποτελούνται από στρώματα κόμβων, τα οποία περιέχουν ένα στρώμα εισόδου, ένα ή περισσότερα κρυφά στρώματα και ένα στρώμα εξόδου. Κάθε κόμβος συνδέεται με έναν άλλο και έχει ένα σχετικό βάρος και κατώφλι. Εάν η έξοδος οποιουδήποτε μεμονωμένου κόμβου είναι πάνω από την καθορισμένη τιμή κατωφλίου, ο εν λόγω κόμβος ενεργοποιείται, στέλνοντας δεδομένα στο επόμενο στρώμα του δικτύου. Διαφορετικά, δεν διαβιβάζονται δεδομένα στο επόμενο επίπεδο του δικτύου.

Το συνελικτικό επίπεδο είναι το πρώτο επίπεδο ενός συνελικτικού δικτύου. Ενώ τα στρώματα συνέλιξης μπορεί να ακολουθούνται από πρόσθετα στρώματα συνέλιξης ή στρώματα συγκέντρωσης, το πλήρως συνδεδεμένο στρώμα (που αποτελείται από ένα ή περισσότερα υποστρώματα) είναι το τελευταίο στρώμα, πριν το στρώμα εξόδου. Με κάθε στρώμα, το CNN αυξάνει την πολυπλοκότητά του, αναγνωρίζοντας μεγαλύτερα τμήματα της εικόνας. Τα προηγούμενα στρώματα επικεντρώνονται σε απλά χαρακτηριστικά, όπως τα χρώματα και οι ακμές. Καθώς τα δεδομένα της εικόνας εξελίσσονται μέσω των στρωμάτων του CNN, αρχίζει να αναγνωρίζει μεγαλύτερα στοιχεία ή σχήματα του αντικειμένου, έως ότου τελικά αναγνωρίσει το προοριζόμενο αντικείμενο.

Στη συνέχεια θα αναλύσουμε την λειτουργία των διαφόρων οικογενειών στρωμάτων:

Συνελικτικό στρώμα (Convolutional layer)

Το στρώμα συνέλιξης είναι το βασικό δομικό στοιχείο ενός CNN, και σε αυτό πραγματοποιείται η πλειονότητα των υπολογισμών. Απαιτεί μερικά στοιχεία, τα οποία είναι τα δεδομένα εισόδου, ένα φίλτρο και ένα χάρτη χαρακτηριστικών. Εάν η είσοδος είναι μια έγχρωμη εικόνα, η οποία αποτελείται από έναν πίνακα εικονοστοιχείων σε 3D, αυτό σημαίνει ότι η είσοδος είναι τρισδιάστατη (ένα ύψος,

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

ένα πλάτος και ένα βάθος). Υπάρχει επίσης ένας ανιχνευτής χαρακτηριστικών, γνωστός και ως πυρήνας ή φίλτρο, ο οποίος θα κινείται στα δεκτικά πεδία της εικόνας, ελέγχοντας αν το χαρακτηριστικό είναι παρόν. Αυτή η διαδικασία είναι γνωστή ως συνέλιξη.

Ωστόσο, υπάρχουν τρεις υπερπαραμέτροι που επηρεάζουν το μέγεθος του όγκου της εξόδου, οι οποίες πρέπει να οριστούν πριν από την έναρξη της εκπαίδευσης του νευρωνικού δικτύου.

Σε αυτές περιλαμβάνονται:

- Ένα φίλτρο: είναι ένας δισδιάστατος πίνακας βαρών συνήθως 3x3, που χρησιμοποιείται για την εκτέλεση πράξεων συνέλιξης. Ολισθαίνει πάνω στην εικόνα εισόδου για την παραγωγή χαρτών χαρακτηριστικών. Κάθε φίλτρο είναι υπεύθυνο για την ανίχνευση συγκεκριμένων χαρακτηριστικών, όπως ακμές, υφές ή μοτίβα. Ο αριθμός των φίλτρων επηρεάζει το βάθος χαρακτηριστικών της εξόδου. Για παράδειγμα, τρία διαφορετικά φίλτρα θα αποδώσουν τρεις διαφορετικούς χάρτες χαρακτηριστικών.
- Το βήμα (stride): είναι η απόσταση, ή ο αριθμός των εικονοστοιχείων, που το φίλτρο κινείται πάνω στον πίνακα εισόδου. ορίζει τον αριθμό των pixel κατά τον οποίο το φίλτρο κινείται στην εικόνα. Stride 1 σημαίνει ότι το φίλτρο μετακινείται κατά ένα εικονοστοιχείο κάθε φορά, ενώ stride 2 μετακινεί το φίλτρο κατά δύο εικονοστοιχεία, μειώνοντας ουσιαστικά τις χωρικές διαστάσεις της εξόδου.
- Η συμπλήρωση: περιλαμβάνει την προσθήκη επιπλέον εικονοστοιχείων γύρω από τις άκρες της εικόνας εισόδου για να διασφαλιστεί ότι το φίλτρο μπορεί να επεξεργαστεί πλήρως τις άκρες της εικόνας.

Στρώμα συγκέντρωσης/ομαδοποίησης (Pooling layer)

Το στρώμα/επίπεδο συγκέντρωσης/ομαδοποίησης, γνωστή και ως υποδειγματοληψία, πραγματοποιεί μείωση της διαστατικότητας μέσω χωρικής υποδειγματοληψίας. Παρόμοια με το στρώμα συνέλιξης, η λειτουργία συγκέντρωσης σαρώνει με ένα φίλτρο ολόκληρη την είσοδο, αλλά η διαφορά είναι ότι αυτό το φίλτρο δεν έχει βάρη. Αντ' αυτού, το φίλτρο εφαρμόζει μια συνάρτηση συνάθροισης στις τιμές εντός του δεκτικού πεδίου, στέλνοντας στον πίνακα εξόδου μόνο μία τιμή. Υπάρχουν δύο κύριοι τύποι συγκέντρωσης:

- Μέγιστη συγκέντρωση (max pooling): Καθώς το φίλτρο κινείται στην είσοδο, επιλέγει το εικονοστοιχείο με τη μέγιστη τιμή για να το στείλει στον πίνακα εξόδου.
- Μέση συγκέντρωση (average pooling): Καθώς το φίλτρο κινείται στην είσοδο, υπολογίζει τη μέση τιμή εντός του δεκτικού πεδίου για να την στείλει στη συστοιχία εξόδου.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Ενώ χάνονται πολλές πληροφορίες στο επίπεδο συγκέντρωσης, έχει επίσης μια σειρά από πλεονεκτήματα για το CNN. Βοηθούν στη μείωση της πολυπλοκότητας, στη βελτίωση της αποδοτικότητας και στον περιορισμό του κινδύνου υπερπροσαρμογής.

Πλήρως συνδεδεμένο στρώμα (Fully-connected layer)

Μετά από ομάδες επιπέδων τύπου συνέλιξης και ομαδοποίησης, το δίκτυο περιλαμβάνει συνήθως πλήρως συνδεδεμένα επίπεδα, όπου κάθε νευρώνας συνδέεται με κάθε νευρώνα του προηγούμενου επιπέδου. Αυτά τα στρώματα ενσωματώνουν τα χαρακτηριστικά που εξάγονται από τα στρώματα συνέλιξης για να κάνουν μια τελική πρόβλεψη, όπως η ταξινόμηση μιας εικόνας και λειτουργούν όπως συνηθισμένα (ρηχά) ΤΝΔ. Αυτό το στρώμα εκτελεί το έργο της ταξινόμησης με βάση τα χαρακτηριστικά που εξάγονται μέσω των προηγούμενων στρωμάτων και των διαφόρων φίλτρων τους.

Όσον αφορά την συνάρτηση ενεργοποίησης των νευρώνων, τα συνελικτικά στρώματα και τα στρώματα ομαδοποίησης τείνουν να χρησιμοποιούν συναρτήσεις ReLu, ενώ τα στρώματα πλήρους σύνδεσης συνήθως αξιοποιούν μια συνάρτηση ενεργοποίησης softmax για την κατάλληλη ταξινόμηση των εισόδων, παράγοντας μια πιθανότητα από 0 έως 1 [22].

2.3.2 Προεκπαιδευμένα δίκτυα βαθιάς μάθησης

Τα προεκπαιδευμένα μοντέλα αποτελούν ένα βασικό κομμάτι της σύγχρονης βαθιάς μάθησης και κατ' επέκταση της ταξινόμησης εικόνων. Η εκπαίδευση τους πραγματοποιείται σε μεγάλα σύνολα δεδομένων (εκατομμύρια εικόνες) γενικής φύσης και επιτυγχάνουν εξαιρετικές επιδόσεις. Μαθαίνουν να αναγνωρίζουν διάφορα χαρακτηριστικά, από απλές ακμές έως σύνθετες υφές και αντικείμενα. Ένα προεκπαιδευμένο νευρωνικό δίκτυο ταξινόμησης εικόνων έχει ήδη μάθει να εξάγει ισχυρά και πλούσια πληροφοριακά χαρακτηριστικά από εικόνες και μπορεί να χρησιμοποιηθεί ως σημείο εκκίνησης για την εκμάθηση μιας νέας ομάδας/κατηγορίας εικόνων. Ύστερα, με τη λεπτομερή ρύθμιση κάποιων παραμέτρων τελικών στρωμάτων, επιτυγχάνεται η εκπαίδευση με τα όποια νέα δεδομένα έχει κάθε ερευνητής, ώστε να δημιουργηθούν τα νέα χαρακτηριστικά και να δοκιμαστούν ως προς τις επιδόσεις τους.

Η αρχιτεκτονική των προεκπαιδευμένων μοντέλων ποικίλλει, αλλά έχουν κοινά χαρακτηριστικά. Αποτελούνται από πολλαπλά στρώματα που εξάγουν προοδευτικά χαρακτηριστικά από τις εικόνες εισόδου. Τα αρχικά στρώματα εντοπίζουν χαρακτηριστικά χαμηλού επιπέδου, ενώ τα βαθύτερα στρώματα αναγνωρίζουν μοτίβα υψηλού επιπέδου.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Πλεονεκτήματα:

- Μειωμένος χρόνος εκπαίδευσης: Τα προεκπαιδευμένα μοντέλα μειώνουν σημαντικά τον χρόνο εκπαίδευσης, δεδομένου ότι έχουν ήδη εκπαιδευτεί σε μεγάλα σύνολα δεδομένων, απαιτούν μόνο λεπτομερή ρύθμιση για συγκεκριμένες εργασίες. Αυτή η αποδοτικότητα επιτρέπει στους προγραμματιστές να αναπτύξουν τα μοντέλα πιο γρήγορα.
- Βελτιωμένη ακρίβεια: Επειδή αυτά τα μοντέλα έχουν εκπαιδευτεί σε τεράστιες ποσότητες δεδομένων, μπορούν να γενικεύουν καλά, δηλαδή να επεκτείνουν τις «γνώσεις» τους σε νέα σύνολα δεδομένων. Ως αποτέλεσμα, συχνά επιτυγχάνουν μεγαλύτερη ακρίβεια σε διάφορες εργασίες σε σύγκριση με μοντέλα που εκπαιδεύονται από το μηδέν και μόνο με τα νέα δεδομένα. Αυτό οδηγεί σε πιο αξιόπιστα αποτελέσματα ταξινόμησης εικόνων.
- Αποδοτικότητα πόρων: Η χρήση προεκπαιδευμένων μοντέλων μειώνει την ανάγκη για μεγάλα σύνολα δεδομένων και υπολογιστική ισχύ. Η τελειοποίηση ενός προεκπαιδευμένου μοντέλου απαιτεί λιγότερους πόρους από την εκπαίδευση ενός νέου μοντέλου, καθιστώντας το πιο προσιτό σε περιπτώσεις όπου οι ερευνητές διαθέτουν περιορισμένους υπολογιστικούς πόρους [23],[24].

Τα συνηθέστερα προεκπαιδευμένα CNN είναι τα ακόλουθα:

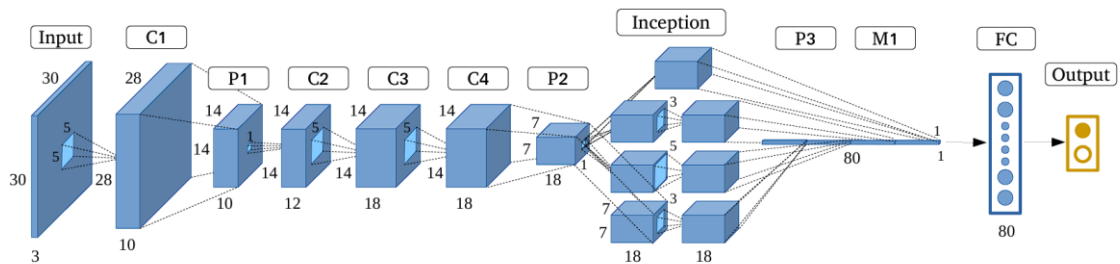
- AlexNet:
Το AlexNet, που αναπτύχθηκε από τον Alex Krizhevsky, είναι ένα από τα πρώτα μοντέλα βαθιάς μάθησης που διέδωσε τη χρήση των CNN στην ταξινόμηση εικόνων.
- VGGNet:
Τα μοντέλα VGG αναπτύχθηκαν από την ομάδα οπτικής γεωμετρίας του Πανεπιστημίου της Οξφόρδης και είναι γνωστά για την απλότητα και το βάθος τους.
- ResNet:
Το ResNet, που εισήχθη από την Microsoft Research, έχει πάνω από 152 στρώματα .
- Squeezenet:
Το Squeezenet είναι ένα αποδοτικό δίκτυο βαθιάς μάθησης που έχει σχεδιαστεί για να επιτυγχάνει εξαιρετικά καλή απόδοση στην ταξινόμηση εικόνων με πολύ μικρότερο μέγεθος μοντέλου, σε σχέση με άλλα, μεγαλύτερα, δίκτυα, όπως το AlexNet και το VGG [22],[25].
- GoogLeNet:
Το GoogLeNet είναι το προεκπαιδευμένο δίκτυο που χρησιμοποιήθηκε στην παρούσα διπλωματική και αναλύεται περαιτέρω στην συνέχεια.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.3.3 Το προεκπαιδευμένο συνελικτικό νευρωνικό δίκτυο GoogLeNet

Το GoogLeNet είναι μια αρχιτεκτονική συνελικτικού νευρωνικού δικτύου (CNN) που αναπτύχθηκε από την Google και παρουσιάστηκε το 2014. Αποτελεί σημαντική πρόοδο στη βαθιά μάθηση, ιδίως σε εργασίες αναγνώρισης εικόνας, και είναι γνωστό για τη εισαγωγή της αρχιτεκτονικής ‘inception module’.

Το GoogLeNet είναι πολύ βαθύτερο από τα προηγούμενα δίκτυα, με 22 επίπεδα σε σύγκριση με τα 8 επίπεδα του AlexNet. Παρά αυτό το αυξημένο βάθος, είναι πιο αποδοτικό όσον αφορά τους υπολογιστικούς πόρους [26].



Εικόνα 2.8: Η αρχιτεκτονική του GoogLeNet [27].

Δομή του GoogLeNet:

Η αρχιτεκτονική του GoogLeNet μπορεί να χωριστεί στα ακόλουθα στοιχεία:

- Επίπεδο εισόδου - Input Layer: Λαμβάνει την εικόνα εισόδου (224x224x3).
- Αρχικά στρώματα συνελικτικής ανάλυσης-Initial Convolutional Layers: Στρώματα που μειώνουν το χωρικό μέγεθος και εξάγουν βασικά χαρακτηριστικά μέσω της συνέλιξης.
- Inception Modules: Πολλαπλές ενότητες Inception στοιβαγμένες μεταξύ τους, επιτρέποντας στο δίκτυο να εξάγει χαρακτηριστικά σε διάφορα επίπεδα αφαίρεσης. Το Inception module είναι το θεμελιώδες δομικό στοιχείο του GoogLeNet. Επιτρέπει στο δίκτυο να λαμβάνει πληροφορίες σε διαφορετικές κλίμακες εκτελώντας παράλληλα πολλαπλές συνέλιξεις με διαφορετικά μεγέθη φίλτρων (1x1, 3x3, 5x5) και μια λειτουργία μέγιστης συγκέντρωσης (max-pooling). Οι εξοδοί αυτών των λειτουργιών στη συνέχεια συνενώνονται για να αποτελέσουν την είσοδο του επόμενου στρώματος. Αυτή η προσέγγιση επιτρέπει στο δίκτυο να ανιχνεύει τόσο τις λεπτές όσο και τις χονδροειδείς λεπτομέρειες σε μια εικόνα, οδηγώντας σε πιο ακριβείς προβλέψεις.
- Global Average Pooling: είναι η εναλλακτική λύση στα πλήρως συνδεδεμένα στρώματα, ιδίως κατά τη μετάβαση από τα συνελικτικά στρώματα στο στρώμα εξόδου. Αντί να χρησιμοποιεί ένα πυκνό στρώμα για να μειώσει τις χωρικές διαστάσεις των χαρτών χαρακτηριστικών, το GAP μειώνει κάθε χάρτη χαρακτηριστικών σε μία μόνο τιμή υπολογίζοντας τον μέσο όρο όλων

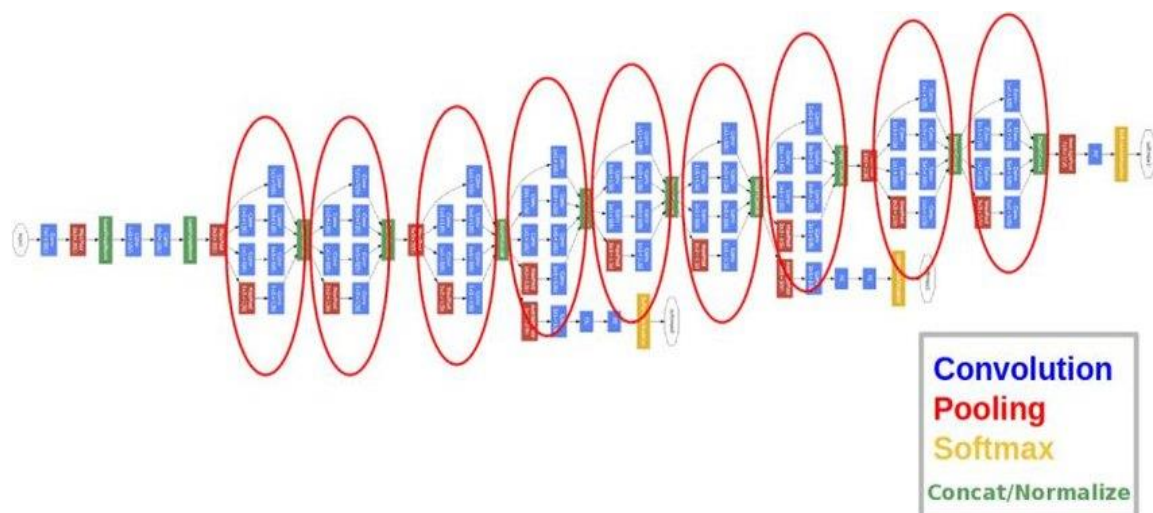
ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

των στοιχείων του. Αντί να χρησιμοποιεί πλήρως συνδεδεμένα στρώματα, τα οποία μπορεί να έχουν μεγάλο αριθμό παραμέτρων, το GoogLeNet χρησιμοποιεί τη συγκέντρωση του συνολικού μέσου όρου στο τέλος του δικτύου. Αυτό μειώνει περαιτέρω τον αριθμό των παραμέτρων και αποτρέπει την υπερπροσαρμογή (overfitting).

- Επίπεδο εξόδου - Output Layer: Ένα πλήρως συνδεδεμένο στρώμα ακολουθούμενο από μια συνάρτηση softmax που παράγει την τελική έξοδο ταξινόμησης.

type	patch size/ stride	output size	depth	#1×1	#3×3 reduce	#3×3	#5×5 reduce	#5×5	pool proj	params	ops
convolution	7×7/2	112×112×64	1							2.7K	34M
max pool	3×3/2	56×56×64	0								
convolution	3×3/1	56×56×192	2		64	192				112K	360M
max pool	3×3/2	28×28×192	0								
inception (3a)		28×28×256	2	64	96	128	16	32	32	159K	128M
inception (3b)		28×28×480	2	128	128	192	32	96	64	380K	304M
max pool	3×3/2	14×14×480	0								
inception (4a)		14×14×512	2	192	96	208	16	48	64	364K	73M
inception (4b)		14×14×512	2	160	112	224	24	64	64	437K	88M
inception (4c)		14×14×512	2	128	128	256	24	64	64	463K	100M
inception (4d)		14×14×528	2	112	144	288	32	64	64	580K	119M
inception (4e)		14×14×832	2	256	160	320	32	128	128	840K	170M
max pool	3×3/2	7×7×832	0								
inception (5a)		7×7×832	2	256	160	320	32	128	128	1072K	54M
inception (5b)		7×7×1024	2	384	192	384	48	128	128	1388K	71M
avg pool	7×7/1	1×1×1024	0								
dropout (40%)		1×1×1024	0								
linear		1×1×1000	1							1000K	1M
softmax		1×1×1000	0								

Εικόνα 2.9: Αναπαράσταση των παραμέτρων της αρχιτεκτονικής του GoogLeNet. [26].



Εικόνα 2.10: Τα στρώματα του GoogLeNet [28].

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Στη συνέχεια παραθέτουμε με περισσότερη λεπτομέρεια τα βασικά χαρακτηριστικά του inception layer:

- Πολυεπίπεδη εξαγωγή χαρακτηριστικών (Multi-Level Feature Extraction): Η βασική ιδέα της ενότητας inception είναι ότι αποτελείται από πολλαπλές πράξεις συγκέντρωσης και συνέλιξης με διαφορετικά μεγέθη (3×3 , 5×5) παράλληλα, αντί να χρησιμοποιείται μόνο ένα φίλτρο ενός μεγέθους.

- Παράλληλα συνελικτικά δίκτυα (Parallel Convolutional Layers): Το Inception εκτελεί παράλληλα διάφορες συνέλιξεις χρησιμοποιώντας φίλτρα διαφορετικών μεγεθών: 1×1 , 3×3 και 5×5 . Κάθε ένα από αυτά τα φίλτρα συλλαμβάνει χαρακτηριστικά σε διαφορετικές κλίμακες:

Συνελίξεις 1×1 : Χρησιμοποιούνται κυρίως για τη μείωση των διαστάσεων, μειώνοντας τον αριθμό των καναλιών εισόδου για τη μείωση του υπολογιστικού κόστους. Εισάγουν επίσης μη γραμμικότητα, η οποία βοηθά στην εκμάθηση πιο σύνθετων μοτίβων.

Συνελίξεις 3×3 και 5×5 : Αυτά τα φίλτρα συλλαμβάνουν χωρικές πληροφορίες σε διαφορετικές κλίμακες. Τα φίλτρα 3×3 συλλαμβάνουν μοτίβα μεσαίου μεγέθους, ενώ τα φίλτρα 5×5 συλλαμβάνουν μεγαλύτερα μοτίβα.

- Μέγιστη συγκέντρωση (Max pooling):

Εκτός από τα συνελικτικά στρώματα, η ενότητα Inception περιλαμβάνει μια λειτουργία μέγιστης συγκέντρωσης (max pooling). Η max pooling μειώνει τις χωρικές διαστάσεις, διατηρώντας παράλληλα σημαντικά χαρακτηριστικά, ιδίως εκείνα που σχετίζονται με τις ακμές και τις υφές. Η λειτουργία αυτή εκτελείται επίσης παράλληλα με τις συνέλιξεις.

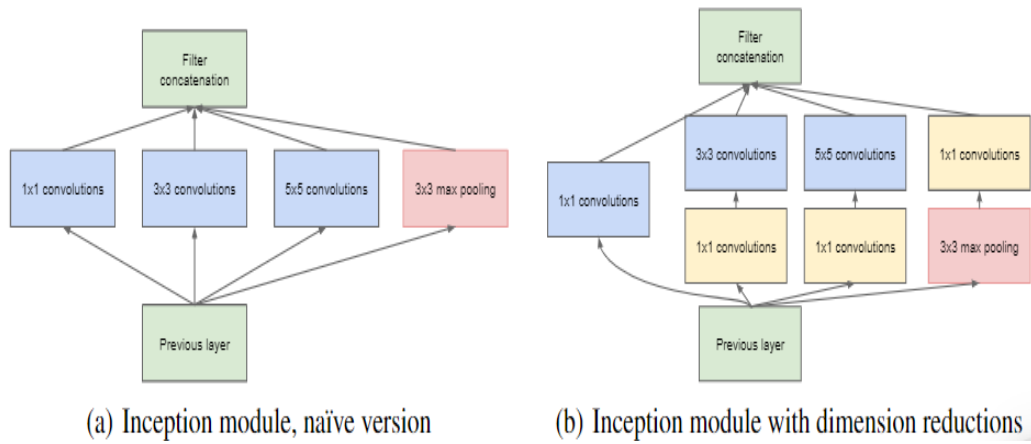
- Συγκεντρώσεις (Concentrations):

Αφού εκτελεστούν οι παράλληλες πράξεις (συνελίξεις 1×1 , 3×3 , 5×5 και max pooling), οι έξοδοί τους συνενώνονται κατά μήκος της διάστασης του καναλιού. Αυτό επιτρέπει στο δίκτυο να συνδυάζει χαρακτηριστικά που εξάγονται σε διαφορετικές κλίμακες, δημιουργώντας μια πλουσιότερη και πιο κατατοπιστική αναπαράσταση χαρακτηριστικών.

- Μείωση διαστάσεων (Dimension Reduction):

Οι 1×1 συνέλιξεις παίζουν καθοριστικό ρόλο στη μείωση του αριθμού των παραμέτρων και του υπολογιστικού κόστους. Εφαρμόζοντας αυτές τις συνέλιξεις πριν από τις συνέλιξεις 3×3 και 5×5 , το δίκτυο μειώνει τον αριθμό των καναλιών εισόδου, γεγονός που καθιστά τον συνολικό υπολογισμό πιο αποδοτικό. [Αυτές οι συνέλιξεις χρησιμοποιούνται για τη μείωση του αριθμού των παραμέτρων (βάρη) της αρχιτεκτονικής. Με τη μείωση των παραμέτρων αυξάνουμε επίσης το βάθος της αρχιτεκτονικής [29].

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 2.11: Η αρχιτεκτονική της inception module α) χωρίς μείωση διαστάσεων, β) με μείωση [29].

ΚΕΦΑΛΑΙΟ 3

Δεδομένα και αποτελέσματα

3.1 Δεδομένα


Τα δεδομένα πάνω στα οποία βασίστηκε η παρούσα διπλωματική εργασία είναι 8 ηλεκτροεγκεφαλογραφήματα διάρκειας 30 λεπτών και αντλήθηκαν από τη βάση δεδομένων *Dream Database* του Πανεπιστημίου MONS (TCTS Laboratory) των Stéphanie Devuyst και Thierry Dutoit και του Ελεύθερου Πανεπιστημίου των Βρυξελλών (Charleroi Sleep Laboratory) της Myriam Kerkhofs, υπό τους όρους Αναφορά-Μη Εμπορική-Παρόμοια Διανομή 3.0 μη εισαγόμενη άδεια (Attribution-NonCommercial-NoDerivs 3.0 Unported (CC BY-NC-ND 3.0) License). Γιατροί με ειδικευση πάνω στο συγκεκριμένο πεδίο εντόπισαν στα υπό μελέτη ΗΕΓ ατράκτους ή άλλες κυματομορφές ύπνου. Η βάση είναι διαθέσιμη στον παρακάτω σύνδεσμο:

<https://zenodo.org/records/2650142>

3.1.2 Επεξεργασία δεδομένων

Έπειτα από την επεξεργασία των συγκεκριμένων 8 ΗΕΓ από προηγούμενη διπλωματική εργασία του Τμήματος Μηχανικών Βιοϊατρικής, του φοιτητή Σαρακηνού Σταύρου [1], προέκυψαν 126 τμήματα ΗΕΓ, διάρκειας 1s με συχνότητα δειγματοληψίας 200 Hz άρα και ο αριθμός των δειγμάτων/τιμών του κάθε τμήματος είναι 200 τιμές δυναμικού (στην κλίμακα των μV).

Με την χρήση του περιβάλλοντος Matlab αυτά τα 126 τμήματα μετατράπηκαν από μήτρες τιμών σε γραφήματα-εικόνες που κάθε ένα από αυτά απεικόνιζε άτρακτο ή μη άτρακτο, με άξονα X τον αριθμό των δειγμάτων και άξονα Y με εύρος από $-25 \mu\text{V}$ ως $25 \mu\text{V}$. Το εύρος αυτό ορίστηκε ώστε να περιλαμβάνει τις ακρότατες (μέγιστες θετικές/ελάχιστες αρνητικές) τιμές δυναμικού που εμφανίζονται στα δεδομένα των 126 τμημάτων. Έστερα τα συγκεκριμένα γραφήματα υπέστησαν περαιτέρω επεξεργασία όπως την περικοπή του περιττού περιγράμματος και υποβάθρου που δημιουργούσε το matlab, ώστε να είναι κατάλληλα για χρήση στην εκπαίδευση του δικτύου που χρησιμοποιήθηκε.



Εικόνα 3.1: Αριστερά: αρχικό γράφημα ατράκτου. Δεξιά: γράφημα ατράκτου με περικοπή υποβάθρου.

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

Τα γραφήματα αυτά χωρίστηκαν στα παρακάτω σύνολα/σέτ εικόνων για την εκπαίδευση και τον συνακόλουθο έλεγχο επίδοσης του συνελικτικού νευρωνικού δικτύου GoogLeNet.

Πίνακας 3.1: Σύνολα/σέτ εκπαίδευσης/δοκιμής

Σέτ εικόνων	Κατηγορία σήματος	Αριθμός εικόνων (για την φάση της εκπαίδευσης)	Αριθμός εικόνων (για την φάση της δοκιμής)
1ο Σέτ	Spindle-(άτρακτος)	58	5
	No Spindle-(μη άτρακτος)	58	5
2ο Σέτ	Spindle-(άτρακτος)	40	23
	No Spindle-(μη άτρακτος)	40	23
3ο Σέτ	Spindle-(άτρακτος)	30	33
	No Spindle-(μη άτρακτος)	30	33
4ο Σέτ	Spindle-(άτρακτος)	20	43
	No Spindle-(μη άτρακτος)	20	43

Όπως μπορεί να παρατηρηθεί ξεκινάμε από σύνολο εκπαίδευσης με σχετικά μεγάλο αριθμό παραδειγμάτων για εκπαίδευση (58+58), αλλά μικρό αριθμό δειγμάτων για έλεγχο επίδοσης μετά την εκπαίδευση (5+5), τελειώνοντας σε σύνολο με μικρό αριθμό παραδειγμάτων για εκπαίδευση (20+20), αλλά μεγάλο αριθμό δειγμάτων για έλεγχο επίδοσης μετά την εκπαίδευση (43+43). Θεωρητικά αναμένουμε το 1^ο σέτ να εκπαιδευθεί καλύτερα (δηλαδή να έχει καλύτερες μετρικές επίδοσης στο τέλος της εκπαίδευσης), αλλά η εξαγωγή συμπερασμάτων για τις πραγματικές (μελλοντικές) επιδόσεις του σε άγνωστα δεδομένα είναι επισφαλής λόγω του εξαιρετικά μικρού αριθμού δειγμάτων ανά κατηγορία (5) που διαθέτουμε για να ελέγξουμε τις επιδόσεις του (φάση δοκιμής). Αντίστροφα, στο τελευταίο, 4^ο, σέτ, έχουμε μικρό σχετικά αριθμό δειγμάτων για την εκπαίδευση, αλλά μεγαλύτερο αριθμό δειγμάτων για την φάση δοκιμής. Θεωρητικά, το δίκτυο δυσχεραίνεται να εκπαιδευθεί (ίσως οι επιδόσεις στο τέλος της φάσης εκπαίδευσης να μην είναι τόσο καλές όσο στα προηγούμενα σύνολα), αλλά μπορούμε να έχουμε περισσότερη εμπιστοσύνη στην αξιοπιστία των επιδόσεων που θα μετρήσουμε στην φάση της δοκιμής (λόγω του μεγαλύτερου αριθμού δειγμάτων που χρησιμοποιούμε στη φάση της δοκιμής).

Πριν προχωρήσουμε, θα δώσουμε τους ορισμούς των μετρικών (παραμέτρων) επίδοσης της λειτουργίας του δικτύου, που θα υπολογίσουμε στο τέλος της φάσης δοκιμής, δηλαδή όταν θα έχουν ελεγχθεί όλα τα δείγματα του συνόλου που έχουμε για τη φάση της δοκιμής. Οι μετρικές ορίζονται με βάση τον λεγόμενο πίνακα «σύγχυσης» (confusion matrix), για τον οποίο θα χρησιμοποιήσουμε στην παρούσα εργασία τον όρο πίνακα αληθείας, μια που δείχνει την αληθινή κατάσταση επιδόσεων που εξάγουμε από τις δοκιμές μας

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

Ο πίνακας αληθείας (σύγχυσης) ορίζεται ως εξής:

	PREDICTED POSITIVE (PP) ΠΡΟΒΛΕΠΟΜΕΝΟ ΘΕΤΙΚΟ (PP=TP+FP)	PREDICTED NEGATIVE (PN) ΠΡΟΒΛΕΠΟΜΕΝΟ ΑΡΝΗΤΙΚΟ (PN=FN+TN)
Κατηγορία – Class 1 (P=TP+FN)	TRUE POSITIVE (TP) - ΑΛΗΘΩΣ ΘΕΤΙΚΟ	FALSE NEGATIVE (FN) - ΨΕΥΔΩΣ ΑΡΝΗΤΙΚΟ
Κατηγορία – Class 2 (N=FP+TN)	FALSE POSITIVE (FP) - ΨΕΥΔΩΣ ΘΕΤΙΚΟ	TRUE NEGATIVE (TN) - ΑΛΗΘΩΣ ΑΡΝΗΤΙΚΟ

Στην περίπτωση μας η κατηγορία/τάξη/κλάση 1 θα είναι τα τμήματα ΗΕΓ που περιέχουν άτρακτο και κλάση 2 τα τμήματα ΗΕΓ που δεν περιέχουν άτρακτο.

Οι παράμετροι (μετρικές) επίδοσης υπολογίζονται ως εξής με βάση τον πίνακα αληθείας:

- ACCURACY (ACC) = $(TP+TN)/(P+N)$. Συνηθέστερος ελληνικός όρος: ακρίβεια.
- SENSITIVITY (SEN) = TP/P . Συνηθέστερος ελληνικός όρος: ευαισθησία.
- SPECIFICITY (SPE) = TN/N . Συνηθέστερος ελληνικός όρος: ειδικότητα.
- PRECISION (PRE) = $TP/PP = TP/(TP+FP)$. Για τον όρο αυτό υπάρχει αμφισημία στην ελληνική ορολογία, μια που γλωσσικά ταυτίζεται με την ακρίβεια. Ακριβέστερα μπορεί να αποδοθεί αναλυτικά ως ποσοστό αληθώς θετικών προς το σύνολο των θετικών ενδείξεων του συστήματος, ή συντομότερα, ποσοστό αληθώς θετικών.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.2 Παράμετροι εκπαίδευσης του συνελικτικού νευρωνικού δικτύου GoogLeNet

Σε περιβάλλον matlab το δίκτυο GoogLeNet εκπαιδεύτηκε με τις εικόνες που παράχθηκαν από τα 126 τμήματα των ΗΕΓ, σύμφωνα με τα σύνολα που δείχνονται στο Πίνακα 3.1.

Οι πρώτες ρυθμίσεις που πραγματοποιήθηκαν πριν εκκινήσουμε την εκπαίδευση, είναι στις επιλογές εκπαίδευσης. Το ποσοστό εκπαίδευσης/επικύρωσης σε κάθε σύνολο εκπαίδευσης τέθηκε στο 30%, έπειτα περνώντας στη δομή του GoogLeNet αντικαταστάθηκαν δύο στρώματα, το classification layer με output size=2 και το fully connected.

Τέλος φτάνοντας στις επιλογές εκπαίδευσης το δίκτυο εκπαιδεύτηκε για κάθε σετ εικόνων με τις εξής επιλογές (Πίνακας 3.2): Ο αλγόριθμος βελτιστοποίησης (solver) που αναλύεται στην συνέχεια, η συχνότητα επικύρωσης (validation frequency) δηλαδή, πόσο συχνά πραγματοποιείται η επαλήθευση του μοντέλου κατά τη διάρκεια της εκπαίδευσης, ο αριθμός εποχών (max epoch), δηλαδή ο αριθμό των φορών που το μοντέλο περνάει ολόκληρο το training set (εκπαιδευτικό σύνολο) κατά τη διάρκεια της εκπαίδευσης και τέλος ο ρυθμός μάθησης (learning rate) ελέγχει το πόσο μεγάλο θα είναι το βήμα προσαρμογής των παραμέτρων (όπως τα βάρη) του μοντέλου σε κάθε ενημέρωση κατά την εκπαίδευση.

Πίνακας 3.2: Παράμετροι της διαδικασίας εκπαίδευσης του δικτύου.

αλγόριθμος βελτιστοποίησης	συχνότητα επικύρωσης	αριθμός εποχών	ρυθμός μάθησης
SGDM	5	100	0.0001
			0.001
			0.01
ADAM			0.0001
			0.001
			0.01

Οι ρυθμίσεις των παραπάνω χαρακτηριστικών εξαρτώνται από την εκάστοτε μέθοδο που θα χρησιμοποιηθεί. Όπως φαίνεται και στον Πίνακα 3.2, χρησιμοποιήσαμε εναλλακτικά δύο αλγορίθμους βελτιστοποίησης, τον SGDM-(Stochastic Gradient Descent with Momentum) και τον ADAM-(Adaptive Moment Estimation) [31], οι οποίοι αναλύονται στην συνέχεια.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.2.1 Αλγόριθμοι βελτιστοποίησης

Οι μέθοδοι βελτιστοποίησης εφαρμόζονται στα νευρωνικά δίκτυα με σκοπό να αλλάξουν τα χαρακτηριστικά τους, όπως τα βάρη και τον ρυθμό μάθησης, ώστε να ελαχιστοποιούν τη συνάρτηση απωλειών, μια συνάρτηση με την οποία μετρούμε την επίδοση της εκμάθησης και να έχουν όσο το δυνατόν ακριβέστερα αποτελέσματα με το μικρότερο δυνατό σφάλμα κατά τη διαδικασία εκπαίδευσης. Η συνάρτηση απώλειας ορίζεται ως τη διαφορά μεταξύ της προβλεπόμενης από το νευρωνικό δίκτυο εξόδου και της πραγματικής εξόδου.

3.2.2 Μέθοδος βελτιστοποίησης SGDM-(Stochastic Gradient Descent with Momentum)

Η Stochastic Gradient Descent with Momentum, είναι μία βελτιωμένη εκδοχή του αρχικού αλγορίθμου Stochastic Gradient Descent (SGD). Εισάγει την έννοια της ορμής (momentum), η οποία συμβάλλει στην επιτάχυνση/μεγιστοποίηση της κλίσης προς τη σχετική κατεύθυνση όπου αναμένεται η μείωση του σφάλματος ταξινόμησης και αποσβένει τις ταλαντώσεις. Αυτό έχει ως αποτέλεσμα την ταχύτερη σύγκλιση, ιδίως παρουσία θορυβωδών ή ανομοιογενών κλίσεων. Η ορμή είναι μια τεχνική που βοηθά στην εξομάλυνση των ενημερώσεων στη διαδικασία καθόδου κλίσης. Αντί να ενημερώνει τις παραμέτρους με βάση αποκλειστικά την τρέχουσα κλίση, η ορμή ενσωματώνει πληροφορίες από προηγούμενες κλίσεις. Η ιδέα είναι να διατηρείται ένας τρέχων μέσος όρος των κλίσεων, ο οποίος αποτρέπει τον αλγόριθμο από το να αλλάζει κατεύθυνση πολύ απότομα, βοηθώντας τον να πλοηγείται ταχύτερα σε επίπεδες περιοχές και μειώνοντας τις ταλαντώσεις όταν η κλίση κυμαίνεται προς διαφορετικές κατευθύνσεις. Ο ορισμός της στοχαστικής βελτιστοποίησης εμπεριέχει τη έννοια της τυχαιότητας, όπου δεν υπάρχει μια ενιαία λύση στο εκάστοτε πρόβλημα.

3.2.3 Μέθοδος βελτιστοποίησης ADAM - (Adaptive Moment Estimation)

Ο Adam είναι ένας προσαρμοστικός αλγόριθμος βελτιστοποίησης που χρησιμοποιείται στη βαθιά μάθηση για την προσαρμογή των βαρών των νευρωνικών δικτύων κατά τη διάρκεια της εκπαίδευσης, συνδυάζοντας τα πλεονεκτήματα της SGDM και δύο ακόμη μεθόδων. Προσαρμόζει τον ρυθμό μάθησης (την ταχύτητα με την οποία το μοντέλο ενημερώνει τα βάρη του) για κάθε παράμετρο ξεχωριστά. Αυτό είναι σημαντικό επειδή διαφορετικά μέρη του νευρωνικού δικτύου μπορεί να απαιτούν διαφορετικές ταχύτητες μάθησης.

3.2.4 Σύγκριση των δύο μεθόδων

Για την ταξινόμηση εικόνων χρησιμοποιώντας την αρχιτεκτονική GoogLeNet, τόσο ο βελτιστοποιητής ADAM όσο και ο SGDM χρησιμοποιούνται συχνά. Ωστόσο, η καλύτερη επιλογή εξαρτάται από διάφορους παράγοντες, όπως το μέγεθος του συνόλου δεδομένων, η ρύθμιση του ρυθμού εκμάθησης και η δυναμική της εκπαίδευσης. Παρακάτω παραθέτουμε τα κύρια πλεονεκτήματα των δύο μεθόδων.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

ADAM:

- Ταχύτερη σύγκλιση: Ο ADAM συνήθως συγκλίνει πιο γρήγορα στα αρχικά στάδια της εκπαίδευσης, γεγονός που μπορεί να είναι κρίσιμο όταν έχεις περιορισμένο αριθμό παραδειγμάτων για εκπαίδευση.
- Καλή διαχείριση μικρών συνόλων δεδομένων: Λόγω του προσαρμοστικού ρυθμού εκμάθησης, ο ADAM μπορεί να λειτουργήσει καλά σε μικρά σύνολα δεδομένων.
- Μειωμένος κίνδυνος υπερπροσαρμογής (overfitting): Αν και η ταχεία σύγκλιση μπορεί να είναι πλεονέκτημα, σε μικρά σύνολα δεδομένων υπάρχει ο κίνδυνος υπερπροσαρμογής, όπου το μοντέλο ταιριάζει υπερβολικά στα δεδομένα εκπαίδευσης και δεν γενικεύει καλά. Ο ADAM μπορεί να μειώσει τον κίνδυνο αυτόν.

SGDM:

- Βραδύτερη αρχική σύγκλιση: Ο SGDM συνήθως απαιτεί περισσότερο χρόνο για να συγκλίνει στην αρχή της εκπαίδευσης, ειδικά αν τα δεδομένα είναι περιορισμένα. Η αργή αυτή αρχή μπορεί να είναι μειονέκτημα σε μικρά σύνολα δεδομένων.
- Ρύθμιση του ρυθμού εκμάθησης: Ο SGDM απαιτεί προσεκτική ρύθμιση του ρυθμού εκμάθησης. Σε μικρά σύνολα δεδομένων, αν ο ρυθμός εκμάθησης είναι πολύ υψηλός, μπορεί να μην συγκλίνει καθόλου ή να παρουσιάσει αστάθεια. Αντίθετα, αν είναι πολύ χαμηλός, η εκπαίδευση μπορεί να είναι αργή και ανεπαρκής.
- Γενίκευση: Παρά τη βραδύτερη σύγκλιση, ο SGDM με σωστή ρύθμιση και κατάλληλη μείωση του ρυθμού εκμάθησης μπορεί να προσφέρει καλύτερη γενίκευση, αποφεύγοντας την υπερπροσαρμογή [36],[37].

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.3 Αποτελέσματα εκπαίδευσης και δοκιμής

Στη συνέχεια παραθέτουμε τα αποτελέσματα των φάσεων εκπαίδευσης και δοκιμής με την εξής διάταξη. Ανά σύνολο/σετ εικόνων (θυμίζουμε ότι έχουμε 4 σετ εικόνων, βλ. Πίνακα 3.1) δίνουμε αρχικά ένα πίνακα («πίνακας ακρίβειας επικύρωσης»), όπου αναγράφουμε για κάθε δίκτυο που δημιουργήσαμε ποιον βελτιστοποιητή χρησιμοποιήσαμε (2 βελτιστοποιητές) και ποιο ρυθμό μάθησης (βήμα εκμάθησης) χρησιμοποιήσαμε. Χρησιμοποιήσαμε 3 τιμές για το βήμα εκμάθησης, 0.0001, 0.001, 0.01. Στη βιβλιογραφία αυτές περίπου αντιστοιχούν σε μικρό, μέτριο και μεγάλο βήμα. Έτσι για κάθε σετ εικόνων είχαμε 6 δίκτυα. Στον πίνακα, για κάθε δίκτυο δίνουμε την ακρίβεια που υπολογίστηκε στο τελευταίο βήμα της διαδικασίας επικύρωσης, δηλαδή στο τέλος της εκμάθησης (ακρίβεια επικύρωσης) και τον χρόνο που απαιτήθηκε.

Στη συνέχεια δίνουμε για κάθε ένα από τα 6 δίκτυα το γράφημα της διαδικασίας εκπαίδευσης και μετά τον σχετικό πίνακα αληθείας.

Ξεκινούμε με τον πίνακα ακρίβειας επικύρωσης του 1^{ου} σετ.


Επιδόσεις 1^{ου} συνόλου/σετ δεδομένων

Πίνακας 3.3: Ακρίβεια επικύρωσης στη διαδικασία εκμάθησης - 1^ο σετ εικόνων.

ΔΙΚΤΥΑ- NETWORKS	SOLVER- ΒΕΛΤΙΣΤΟΠΟΙΗΤΗΣ	LEARNING RATE-ΒΗΜΑ ΕΚΜΑΘΗΣΗΣ	VALIDATION ACURACY- ΑΚΡΙΒΕΙΑ ΕΠΙΚΥΡΩΣΗΣ	TIME- ΧΡΟΝΟΣ (MIN)
1 ^ο ΔΙΚΤΥΟ	SGDM	0.0001	94.2%	41
2 ^ο ΔΙΚΤΥΟ	SGDM	0.001	94.1%	40
3 ^ο ΔΙΚΤΥΟ	SGDM	0.01	82.3%	39
4 ^ο ΔΙΚΤΥΟ	ADAM	0.0001	97.1%	42
5 ^ο ΔΙΚΤΥΟ	ADAM	0.001	91.2%	47
6 ^ο ΔΙΚΤΥΟ	ADAM	0.01	50%	41

Στις επόμενες σελίδες συνεχίζουμε παραθέτοντας το γράφημα της διαδικασίας εκπαίδευσης και μετά τον σχετικό πίνακα αληθείας καθενός από τα 6 δίκτυα. Στη συνέχεια, και μόνο για την παρακάτω πρώτη παράθεση, δίνουμε τον πίνακα αληθείας και τις μετρικές, με τους σχετικούς ορισμούς τους:

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 3.2: Γράφημα της διαδικασίας εκπαίδευσης του 1^{ου} δικτύου του 1^{ου} σετ με learning rate:0.0001 solver:SGDM.

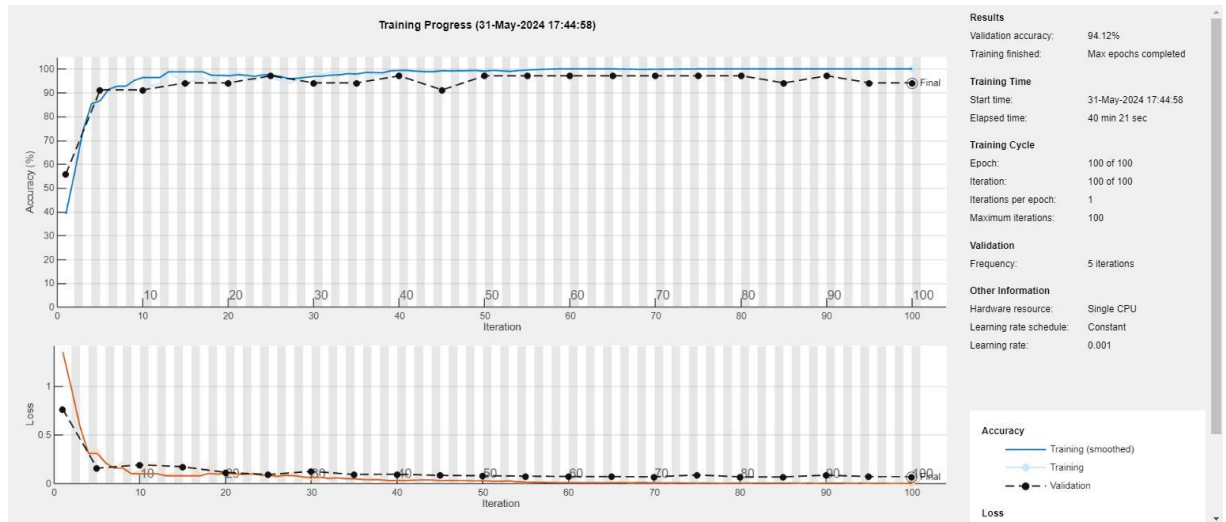
Πίνακας 3.4: πίνακας αληθείας για το 1^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι).

	PREDICTED POSITIVE (PP) ΠΡΟΒΛΕΠΟΜΕΝΟ ΘΕΤΙΚΟ	PREDICTED NEGATIVE (PN) ΠΡΟΒΛΕΠΟΜΕΝΟ ΑΡΝΗΤΙΚΟ
Κατηγορία – Class 1: SPINDLES (S)- ΑΤΡΑΚΤΟΙ	TRUE POSITIVE (TP) - ΑΛΗΘΩΣ ΘΕΤΙΚΟ 5	FALSE NEGATIVE (FN) - ΨΕΥΔΩΣ ΑΡΝΗΤΙΚΟ 0
Κατηγορία – Class 2: NO SPINDLES (NS)- ΜΗ ΑΤΡΑΚΤΟΙ	FALSE POSITIVE (FP) - ΨΕΥΔΩΣ ΘΕΤΙΚΟ 1	TRUE NEGATIVE (TN) - ΑΛΗΘΩΣ ΑΡΝΗΤΙΚΟ 4

- ACCURACY (ACC) $= (TP+TN)/(P+N) = 9/10 = 0.9$
- SENSITIVITY (SEN) $= TP/P = 5/5 = 1$
- SPECIFICITY (SPE) $= TN/N = 4/5 = 0.8$
- PRECISION (PRE) $= TP/PP = TP/(TP+FP) = 5/6 = 0.83$

Οι παραπάνω μετρικές επίδοσης μπορούν να εκφραστούν και σε ποσοστό επί τις %. Οπότε στην παραπάνω περίπτωση θα ήταν ACC=90%, SEN=100%, SPE=80%, PRE=100%. Στα επόμενα θα παραμείνουμε σε απλούς αριθμούς (ως δύο δεκαδικά)

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.3: Γράφημα της διαδικασίας εκπαίδευσης του 2^{ου} δικτύου του 1^{ου} σετ με learning rate:0.001 solver:SGDM.

Πίνακας 3.5: πίνακας αληθείας για το 2^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι). Οι μετρικές επίδοσης έχουν ως εξής: ACC=1, SEN=1, SPE=1, PRE=1.

	PP	PN
S	TP: 5	TN: 0
NS	FP: 0	TN: 5

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.4: Γράφημα της διαδικασίας εκπαίδευσης του 3^{ου} δικτύου του 1^{ου} σετ με learning rate:0.01 solver:SGDM

Πίνακας 3.6: πίνακας αληθείας για το 3^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι). ACC= 0.9, SEN=1, SPE=0.8, PRE=0.83.

	PP	PN
S	5	0
NS	1	4

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.5: Γράφημα της διαδικασίας εκπαίδευσης του 4^{ου} δικτύου του 1^{ου} σετ με learning rate:0.0001 solver:ADAM.

Πίνακας 3.7: πίνακας αληθείας για το 4^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι). ACC=1, SEN=1, SPE=1, PRE=1.

	PP	PN
S	5	0
NS	0	5

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

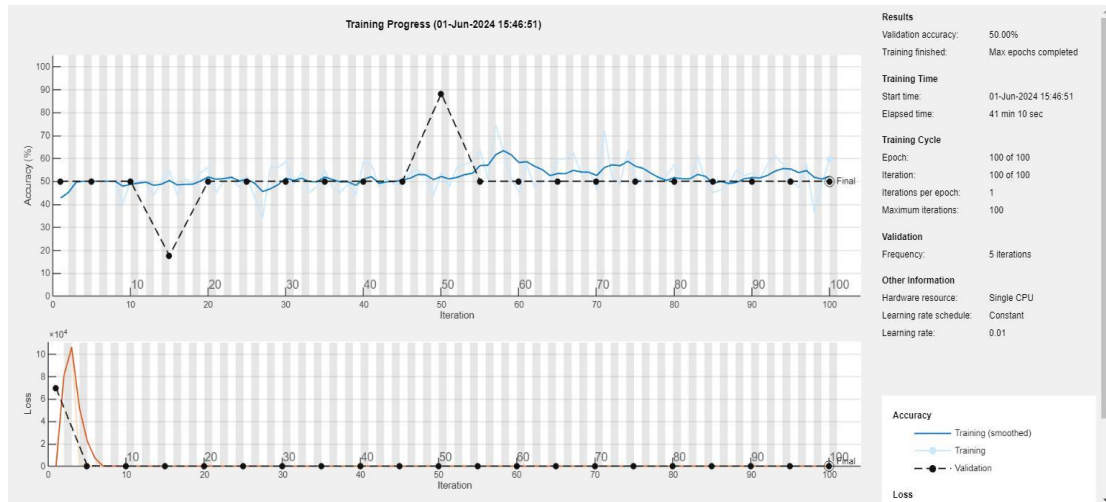


Εικόνα 3.6: Γράφημα της διαδικασίας εκπαίδευσης του 5^{ου} δικτύου του 1^{ου} σετ με learning rate:0.001 solver:ADAM.

Πίνακας 3.8: πίνακας αληθείας για το 5^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι). ACC=0.9, SEN=0.8, SPE=1, PRE=1.

	PP	PN
S	4	1
NS	0	5

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 3.7: Γράφημα της διαδικασίας εκπαίδευσης του 6^{ου} δικτύου του 1^{ου} σετ με learning rate:0.01 solver:ADAM.

Πίνακας 3.9: πίνακας αληθείας για το 6^ο δίκτυο του 1^{ου} σετ το οποίο εκπαιδεύτηκε σε 58 εικόνες σε κάθε κλάση και χρησιμοποίησε 10 για τεστ εικόνες (5 εικόνες άτρακτοι και 5 μη άτρακτοι). ACC=0.5, SEN=0, SPE=1, PRE=0.


	PP	PN
S	0	5
NS	0	5

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Επιδόσεις 2^{ου} συνόλου/σετ δεδομένων

Πίνακας 3.10: Ακρίβεια επικύρωσης στη διαδικασία εκμάθησης - 2^ο σετ εικόνων.

NETWORKS	SOLVER	LEARNING RATE	VALIDATION ACURACY	TIME (MIN)
1ο ΔΙΤΚΥΟ	SGDM	0.0001	95.8%	27
2 ^ο ΔΙΚΤΥΟ	SGDM	0.001	100%	29
3 ^ο ΔΙΚΤΥΟ	SGDM	0.01	95.8%	31
4 ^ο ΔΙΚΤΥΟ	ADAM	0.0001	100%	28
5 ^ο ΔΙΚΤΥΟ	ADAM	0.001	95.8%	32
6 ^ο ΔΙΚΤΥΟ	ADAM	0.01	100 %	28




Εικόνα 3.8: Γράφημα της διαδικασίας εκπαίδευσης του 1^{ου} δικτύου του 2^{ου} σετ με learning rate:0.0001 solver:SGDM.

Πίνακας 3.11: πίνακας αληθείας για το 1^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.95, SEN=1, SPE=0.91, PRE=0.92.

	PP	PN
S	23	0
NS	2	21

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

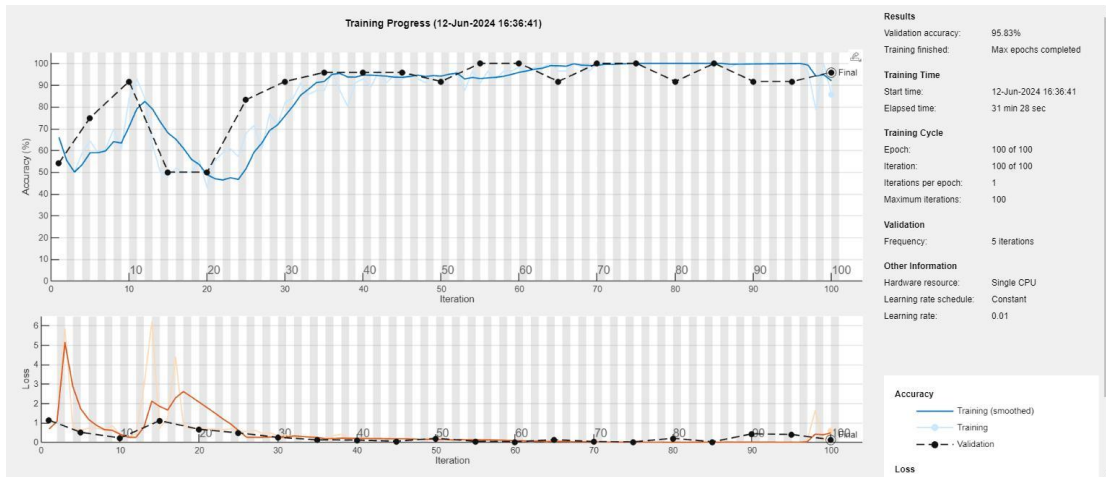


Εικόνα 3.9: Γράφημα της διαδικασίας εκπαίδευσης του 2^{ου} δικτύου του 2^{ου} σετ με learning rate:0.001 solver:SGDM.

Πίνακας 3.12: πίνακας αληθείας για το 2^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.93, SEN=1, SPE=0.87, PRE=0.88

	PP	PN
S	23	0
NS	3	20

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.10: Γράφημα της διαδικασίας εκπαίδευσης του 3^{ου} δικτύου του 2^{ου} σετ με learning rate:0.01 solver:SGDM.

Πίνακας 3.13: πίνακας αληθείας για το 3^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.91, SEN=0.82, SPE=1, PRE=1.

	PP	PN
S	19	4
NS	0	23

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.11: Γράφημα της διαδικασίας εκπαίδευσης του 4^{ου} δικτύου του 2^{ου} σετ με learning rate:0.0001 solver:ADAM.

Πίνακας 3.14: πίνακας αληθείας για το 4^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.93, SEN=1, SPE=0.86, PRE=0.88.

	PP	PN
S	23	0
NS	3	20

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.12: Γράφημα της διαδικασίας εκπαίδευσης του 5^{ου} δικτύου του 2^{ου} σετ με learning rate:0.001 solver:ADAM.

Πίνακας 3.15: πίνακας αληθείας για το 5^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.93, SEN=0.95, SPE=0.91, PRE=0.91.

	PP	PN
S	22	1
NS	2	21

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 3.13: Γράφημα της διαδικασίας εκπαίδευσης του 6^{ου} δικτύου του 2^{ου} σετ με learning rate:0.01 solver:ADAM.

Πίνακας 3.16: πίνακας αληθείας για το 6^ο δίκτυο του 2^{ου} σετ το οποίο εκπαιδεύτηκε σε 40 εικόνες σε κάθε κλάση και χρησιμοποίησε 46 για τεστ εικόνες (23 εικόνες άτρακτοι και 23 μη άτρακτοι). ACC=0.91, SEN=0.82, SPE=1, PRE=1.


	PP	PN
S	19	4
NS	0	23

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Επιδόσεις 3^{ου} συνόλου/σετ δεδομένων

Πίνακας 3.17: Ακρίβεια επικύρωσης στη διαδικασία εκμάθησης - 3^ο σετ εικόνων.

NETWORKS	SOLVER	LEARNING RATE	VALIDATION ACURACY	TIME (MIN)
1ο ΔΙΤΚΥΟ	SGDM	0.0001	100%	21
2 ^ο ΔΙΚΤΥΟ	SGDM	0.001	94.4%	21
3 ^ο ΔΙΚΤΥΟ	SGDM	0.01	94.4%	27
4 ^ο ΔΙΚΤΥΟ	ADAM	0.0001	88.9%	21
5 ^ο ΔΙΚΤΥΟ	ADAM	0.001	94.4%	25
6 ^ο ΔΙΚΤΥΟ	ADAM	0.01	50%	20




Εικόνα 3.14: Γράφημα της διαδικασίας εκπαίδευσης του 1^{ου} δικτύου του 3^{ου} σετ με learning rate:0.0001 solver:SGDM

Πίνακας 3.18: πίνακας αληθείας για το 1^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.93, SEN=0.93, SPE=0.93 PRE=0.93.

	PP	PN
S	31	2
NS	2	31

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

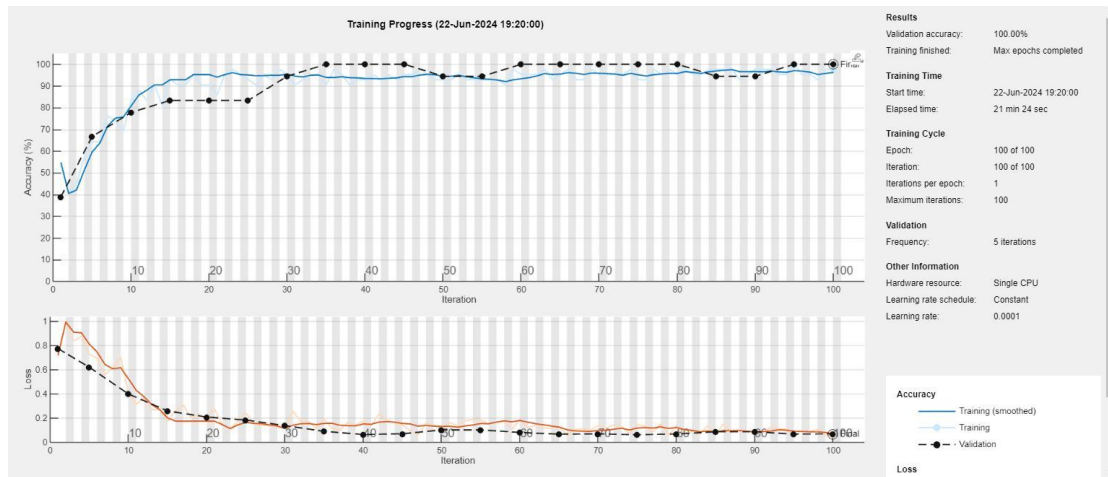


Εικόνα 3.15: Γράφημα της διαδικασίας εκπαίδευσης του 2^{ου} δικτύου του 3^{ου} σετ με learning rate:0.001 solver:SGDM.

Πίνακας 3.19: πίνακας αληθείας για το 2^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.94, SEN=0.96 SPE=0.9, PRE=0.91

	PP	PN
S	32	1
NS	3	30

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

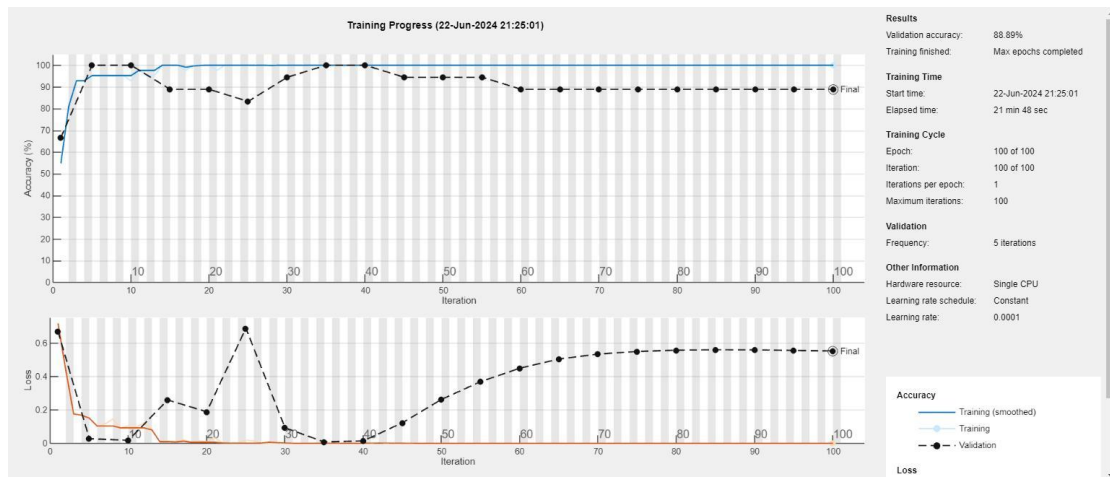


Εικόνα 3.16: Γράφημα της διαδικασίας εκπαίδευσης του 3^{ου} δικτύου του 3^{ου} σετ με learning rate:0.01 solver:SGDM.

Πίνακας 3.20: πίνακας αληθείας για το 3^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.93, SEN=0.93, SPE=0.93, PRE=0.93.

	PP	PN
S	31	2
NS	2	31

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.17: Γράφημα της διαδικασίας εκπαίδευσης του 4^{ου} δικτύου του 3^{ου} σετ με learning rate:0.0001 solver:ADAM.

Πίνακας 3.21: πίνακας αληθείας για το 4^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.92 SEN=0.93 SPE=0.9 PRE=0.91.

	PP	PN
S	31	2
NS	3	30

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.18: Γράφημα της διαδικασίας εκπαίδευσης του 5^{ου} δικτύου του 3^{ου} σετ με learning rate:0.001 solver:ADAM.

Πίνακας 3.22: πίνακας αληθείας για το 5^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.92 SEN=0.93 SPE=0.9 PRE=0.91.

	PP	PN
S	31	2
NS	3	30

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 3.19: Γράφημα της διαδικασίας εκπαίδευσης του 6^{ου} δικτύου του 3^{ου} σετ με learning rate:0.01 solver:ADAM.

Πίνακας 3.23: πίνακας αληθείας για το 6^ο δίκτυο του 3^{ου} σετ το οποίο εκπαιδεύτηκε σε 30 εικόνες σε κάθε κλάση και χρησιμοποίησε 66 για τεστ εικόνες (33 εικόνες άτρακτοι και 33 μη άτρακτοι). ACC=0.5, SEN=1, SPE=0, PRE=0.5.


	PP	PN
S	33	0
NS	33	0

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Επιδόσεις 4^{ου} συνόλου/σετ δεδομένων

Πίνακας 3.24: 4^ο σετ εικόνων (βλέπε πίνακα 3.1).

NETWORKS	SOLVER	LEARNING RATE	VALIDATION ACURACY	TIME (MIN)
1 ^ο ΔΙΚΤΥΟ	SGDM	0.0001	100%	13
2 ^ο ΔΙΚΤΥΟ	SGDM	0.001	100%	13
3 ^ο ΔΙΚΤΥΟ	SGDM	0.01	83.3%	13
4 ^ο ΔΙΚΤΥΟ	ADAM	0.0001	100%	13
5 ^ο ΔΙΚΤΥΟ	ADAM	0.001	91.5%	15
6 ^ο ΔΙΚΤΥΟ	ADAM	0.01	75%	15




Εικόνα 3.20: Γράφημα της διαδικασίας εκπαίδευσης του 1^{ου} δικτύου του 4^{ου} σετ με learning rate:0.0001 solver:SGDM.

Πίνακας 3.25: πίνακας αληθείας για το 1^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.94, SEN=0.98, SPE=0.9, PRE=0.91.

	PP	PN
S	42	1
NS	4	39

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.21: Γράφημα της διαδικασίας εκπαίδευσης του 2^{ου} δικτύου του 4^{ου} σετ με learning rate:0.001 solver:SGDM.

Πίνακας 3.26: πίνακας αληθείας για το 2^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.94, SEN=0.98, SPE=0.9, PRE=0.91.

	PP	PN
S	42	1
NS	4	39

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

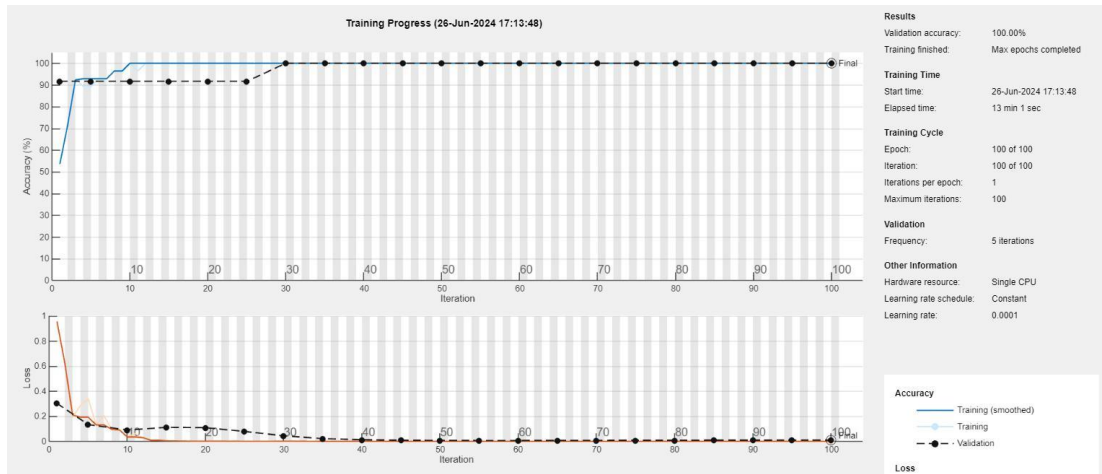


Εικόνα 3.22: Γράφημα της διαδικασίας εκπαίδευσης του 3^{ου} δικτύου του 4 σετ με learning rate:0.01 solver:SGDM.

Πίνακας 3.27: πίνακας αληθείας για το 3^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.8, SEN=0.65, SPE=0.97, PRE=0.96.

	PP	PN
S	28	15
NS	1	42

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

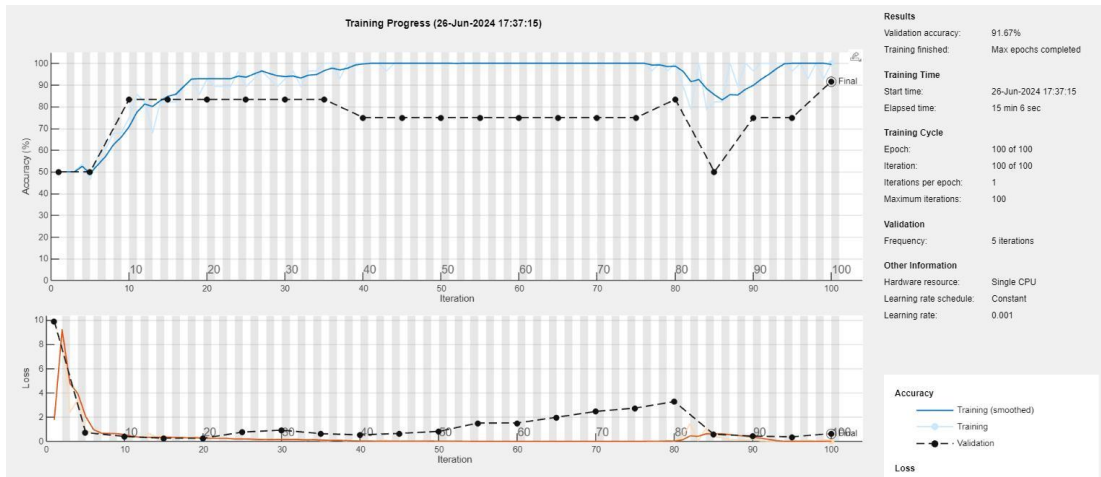


Εικόνα 3.23: Γράφημα της διαδικασίας εκπαίδευσης του 4^{ου} δικτύου του 4^{ου} σετ με learning rate:0.0001 solver:ADAM.

Πίνακας 3.28: πίνακας αληθείας για το 4^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.93, SEN=0.95 SPE=0.9, PRE=0.91

	PP	PN
S	41	2
NS	4	39

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ




Εικόνα 3.24: Γράφημα της διαδικασίας εκπαίδευσης του 5^{ου} δικτύου του 4^{ου} σετ με learning rate:0.001 solver:ADAM.

Πίνακας 3.29: πίνακας αληθείας για το 5^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.88, SEN=0.98 SPE=0.79 PRE=0.82.

	PP	PN
S	42	1
NS	9	34

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



Εικόνα 3.25: Γράφημα της διαδικασίας εκπαίδευσης του 6^{ου} δικτύου του 4^{ου} σετ με learning rate:0.01 solver:ADAM.

Πίνακας 3.30: πίνακας αληθείας για το 6^ο δίκτυο του 4^{ου} σετ το οποίο εκπαιδεύτηκε σε 20 εικόνες σε κάθε κλάση και χρησιμοποίησε 86 για τεστ εικόνες (43 εικόνες άτρακτοι και 43 μη άτρακτοι). ACC=0.83, SEN=0.67, SPE=1, PRE=1.

	PP	PN
S	29	14
NS	0	43

Κεφάλαιο 4 - Συμπεράσματα

Από την εκπαίδευση του δικτύου Googlenet σε περιβάλλον Matlab, με δεδομένα τα 126 γραφήματα-εικόνες ατράκτων και μη ατράκτων, τα οποία χωρίστηκαν σε αυτά τα 4 σετ εκπαίδευσης προέκυψαν τα παραπάνω αποτελέσματα. Παρακάτω θα αναφερθούμε σε συμπεράσματα που εξάγονται από την μελέτη των αποτελεσμάτων.

Ξεκινούμε από τον χρόνο που χρειάζεται για να εκπαιδευθεί το δίκτυο. Η εκπαίδευση έγινε σε ένα τρέχοντα προσωπικό υπολογιστή, χωρίς ιδιαίτερα απαιτητικά χαρακτηριστικά. Για αυτό οι χρόνοι εκπαίδευσης είναι της τάξης των αρκετών λεπτών της ώρας. Όπως αναμενόταν, περνώντας από το 1^ο στο 4^ο σετ, δηλαδή όσο μειωνόταν ο αριθμός των δειγμάτων του συνόλου εκμάθησης (από 58 σε 40, 30, 20), τόσο μειωνόταν ο απαιτούμενος χρόνος: από 39-47min για το 1^ο σετ, σε 27-32min για το 2^ο, σε 20-27min για το 3^ο και 13-15min για το 4^ο σετ.

Η βασική παράμετρος για τις επιδόσεις ενός δικτύου στη φάση δοκιμής είναι η ακρίβεια. Στη συνέχεια μπορούν να εξεταστούν οι υπόλοιπες τρεις παράμετροι. Όμως δεν αρκεί μόνο η ακρίβεια. Χρειάζεται να ελέγξουμε στην φάση εκπαίδευσης, πόσο ευσταθής ήταν η λειτουργία του αλγορίθμου εκμάθησης. Και από αυτή την εξέταση εξάγονται πολύ χρήσιμα συμπεράσματα. Καταρχήν επιδιώκουμε να υπάρχει μια σχετικά μονότονα αυξητική καμπύλη της ακρίβειας επικύρωσης, η οποία γρήγορα (δηλαδή όσο δυνατόν νωρίτερα στους κύκλους των εποχών) να συγκλίνει στην τελική τιμή που λαμβάνουμε για τις 100 εποχές. Ο αριθμός των 100 εποχών είναι αυθαίρετος, αλλά υποβάλλεται από απαιτήσεις μικρού χρόνου εκμάθησης. Η ευσταθής αυτή σύγκλιση χρειάζεται, ώστε να έχουμε εμπιστοσύνη στο ότι, όταν ενδεχομένως θα εμπλουτίσουμε το σύνολο εκμάθησης με νέα δεδομένα, το δίκτυο δεν θα βρίσκεται, στις 100 εποχές που έχουμε λάβει ως σημείο τερματισμού της εκπαίδευσης σε σημείο όπου τα βάρη του είναι ακόμη ασταθώς μεταβαλλόμενα. Επιπλέον, ακόμα και χωρίς νέα εκπαίδευση, με το ήδη εκπαιδευμένο δίκτυο, αν τα βάρη στις 100 εποχές (ή ακόμη και αρκετά νωρίτερα) δεν είχαν σταθεροποιηθεί, υπάρχει ο φόβος η λειτουργία του δικτύου ως κατηγοριοποιητή να δίνει εσφαλμένα αποτελέσματα, ακόμη χειρότερα από αυτά που υποδεικνύει ο πίνακας αληθείας που έχουμε υπολογίσει.

Με βάση τα παραπάνω και παρατηρώντας τις καμπύλες εκπαίδευσης βλέπουμε ότι για βήμα εκμάθησης 0.01 σε όλες τις περιπτώσεις, πλην μίας, έχουμε αστάθεια στη σύγκλιση, επιπλέον του ότι ειδικά για τον ADAM, είχαμε και δύο περιπτώσεις όπου είχαμε πλήρη αποτυχία (ακρίβεια 50%). Άρα, όπως υποδεικνύεται από γενικότερες μελέτες, μεγάλο βήμα εκμάθησης οδηγεί πιθανότατα σε αστάθεια ή και πλήρη αποτυχία.

Περιοριζόμενοι σε βήμα εκμάθησης 0.001 ή 0.0001, παρατηρούμε ότι γενικά τα δίκτυα πετυχαίνουν αξιοσημείωτη επιτυχία, έχοντας ακρίβεια από 0.88 (88%) (4^ο σετ, βήμα 0.001, εκπαίδευση με ADAM) έως και 1 (100%) για το 1^ο σετ για βήμα 0.001 και εκπαίδευση με SGDM και βήμα 0.0001 και εκπαίδευση με ADAM.

Αλλά και αν περιοριστούμε σε βήμα εκμάθησης 0.001 ή 0.0001, βλέπουμε ότι ακόμη και αν οι επιδόσεις στη φάση δοκιμής είναι παρόμοιες για δίκτυα που εκπαιδεύτηκαν

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

με SGDM ή ADAM και ικανοποιητικές, όπως αναφέραμε παραπάνω, η εκπαίδευση με SGDM είναι συνήθως ευσταθέστερη σε σχέση με αυτή της ADAM, για το ίδιο (0.0001 ή 0.001) βήμα εκμάθησης. Αυτό φαίνεται χαρακτηριστικά συγκρίνοντας τις καμπύλες εκμάθησης για βήμα=0.001 σε όλα τα σετ, αλλά και για 0.001 για το 3^ο σετ. Αυτό μας υποδεικνύει ότι πρέπει να στρέψουμε την προσοχή μας προς τα δίκτυα που εκπαιδεύτηκαν με SGDM.

Συνεχίζοντας λοιπόν, παρατηρούμε ότι η βέλτιστη επίδοση (όλες οι παράμετροι ίσες με 1) επετεύχθη για το 1^ο σετ για βήμα 0.001.

Με τα παραπάνω ως οδηγούς, εστιάζοντας πλέον σε δίκτυα που εκπαιδεύτηκαν με SGDM με βήμα εκμάθησης 0.0001 ή 0.001, βλέπουμε ότι έχουμε ακρίβειες από 0.9 ως και 1, χωρίς να μπορούμε, στο επίπεδο της ακρίβειας να ξεχωρίσουμε τα βήματα εκμάθησης 0.0001 ή 0.001. Μπορούμε όμως να κάνουμε την εξής παρατήρηση: στο 1^ο σετ η δοκιμή έγινε σε εξαιρετικά περιορισμένο αριθμό δειγμάτων, μόλις 5 από κάθε μία από τις δύο κατηγορίες. Ο λόγος που έγινε αρχικά η επιλογή αυτή ήταν για να ανταπεξέλθουμε στο ενδεχόμενο, το δίκτυο για να εκπαιδευτεί να χρειαζόταν μεγάλο αριθμό δειγμάτων και έτσι με το 1^ο σετ του παρείχαμε το μέγιστο δυνατό αριθμό δειγμάτων για εκπαίδευση. Είναι όμως προφανές, ότι αφού το δίκτυο, τουλάχιστον με SGDM και βήμα 0.0001 ή 0.001 έχει καλές επιδόσεις και για τα άλλα σετ, καλό είναι να αγνοήσουμε εντέλει τις επιδόσεις για το 1^ο σετ, ακόμη και αν σε αυτό, με βήμα 0.001 πετύχαμε το «τέλειο» (όλες οι παράμετροι ίσες με 1).

Εστιάζοντας λοιπόν ακόμη περισσότερο, μόνο για τα σύνολα/σετ 2^ο ως και 4^ο βλέπουμε ότι το σύνολο των παραμέτρων (τώρα πλέον, σε αυτό το επίπεδο λεπτομέρειας ασχολούμαστε με όλες τις παραμέτρους) κυμαίνεται από 0.87 έως 1. Περιπτώσεις όπου το σύνολο των 4 παραμέτρων ήταν πάνω από 0.9 είχαμε για βήμα 0.0001 για το 2^ο σετ με τιμές παραμέτρων ACC=0.95, SEN=1, SPE=0.91, PRE=0.92 και για το 3^ο σετ με τιμές παραμέτρων ACC=0.93, SEN=0.93, SPE=0.93 PRE=0.93.

Συνεπώς, προκύπτει από τα παραπάνω, ότι τα δύο δίκτυα που εντοπίσαμε και αναφέραμε στην προηγούμενη παράγραφο είναι τα βέλτιστα για να χρησιμοποιηθούν για αυτοματοποιημένη ανίχνευση ατράκτων σε νέα («άγνωστα») τμήματα ΗΕΓ. Αν επιδιωχθεί με νέα (ταξινομημένα) δεδομένα να εκπαιδευθεί νέο δίκτυο αυτό είναι καλύτερο να γίνει με αλγόριθμο εκπαίδευσης SGDM και με βήμα εκμάθησης 0.0001.

Όσον αφορά περιορισμούς της παρούσας εργασίας, αυτοί αφορούν κυρίως το μικρό σχετικά δείγμα εικόνων που είχαμε (63 από κάθε κατηγορία), αλλά κυρίως ότι οι άτρακτοι στις περισσότερες καταγραφές που επιλέξαμε από τη βάση δεδομένων είχαν πολύ «καθαρή» μορφολογία, δηλαδή ήταν εύκολο, με φιλτράρισμα να εξαχθούν καμπύλες ατράκτων αρκετά ισχυρές, σε σχέση με ΗΕΓ όπου δεν υπήρχε άτρακτος. Σε καταστάσεις που το σύστημα κληθεί να ταξινομήσει δεδομένα ΗΕΓ (πάντα φιλτραρισμένα στη ζώνη των ατράκτων) από όλη τη διάρκεια του ύπνου, αναμένουμε χειροτέρευση των επιδόσεων. Η λύση σε αυτό είναι εκπαίδευση με ποικιλία ατράκτων και τμημάτων ΗΕΓ χωρίς άτρακτο, για τμήματα ΗΕΓ που, ακόμη και με το φιλτράρισμα, παρουσιάζουν «μη αρμονική» μορφολογία.

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Βιβλιογραφία

- [1] Σαρακηνός Σταύρος, (2022), *Αυτόματη ανίχνευση ατράκτων του ύπνου με τεχνικές βαθιάς μάθησης*, προπτυχιακή διπλωματική, Αθήνα: Πανεπιστήμιο Δυτικής Αττικής.
<https://polynoe.lib.uniwa.gr/xmlui/handle/11400/2893>
- [2] Kandel, E. R., Schwatz, J. H., Jessell, T. M., (2016), "*Βασικές Αρχές Νευροεπιστημών*", Εκδ. Π.Χ.Πασχαλίδης.
- [3] Μητράκας Π. Λάμπρος, *ANATOMIA II* <https://slideplayer.gr/slide/16141717/>
- [4]<https://el.wikipedia.org/wiki/%CE%9D%CE%B5%CF%85%CF%81%CF%8E%CE%BD%CE%B1%CF%82>
- [5] <https://www.quora.com/Can-you-have-spindles-in-REM-sleep>
- [6] Thomas Andrillon, Yuval Nir, Richard J. Staba, Fabio Ferrarelli, Chiara Cirelli, Giulio Tononi, and Itzhak Fried, (2011), *Sleep Spindles in Humans: Insights from Intracranial EEG and Unit Recordings*. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3270580/>
- [7] Jay Summer, Anis Rehman, (2023), *Sleep Spindles*. <https://www.sleepfoundation.org/how-sleep-works/sleep-spindles>
- [8] What are sleep spindles? (2018). <https://brainstuff.org/blog/what-are-sleep-spindles>
- [9] Electroencephalogram (EEG), Johns Hopkins medicine. <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/electroencephalogram-eeeg>
- [10] Ηλεκτροεγκεφαλογράφημα.
<https://el.wikipedia.org/wiki/%CE%97%CE%BB%CE%B5%CE%BA%CF%84%CF%81%CE%BF%CE%B5%CE%B3%CE%BA%CE%B5%CF%86%CE%B1%CE%BB%CE%BF%CE%B3%CF%81%CE%AC%CF%86%CE%B7%CE%BC%CE%B1>
- [11] Adi L Tarca, Vincent J Carey, Xue-wen Chen, Roberto Romero, Sorin Drăghici, (2007), *Machine Learning and Its Applications to Biology*.
<https://journals.plos.org/ploscompbiol/article?id=10.1371/journal.pcbi.0030116>
- [12] Vijay Kanade, (2022), *What Is Machine Learning? Definition, Types, Applications, and Trends*.
<https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-ml/>
- [13] Mohammad Mustafa Taye, (2023), *Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions*. <https://www.mdpi.com/2073-431X/12/5/91>
- [14] Jakub Kufel, Katarzyna Bargieł-Łączek, Szymon Kocot, Maciej Koźlik, Wiktoria Bartnikowska, Michał Janik, Łukasz Czogalik, Piotr Dudek, Mikołaj Magiera, Anna Lis, Iga Paszkiewicz, Zbigniew Nawrat, Maciej Cebula, Katarzyna Gruszczynska, (2023), *What Is Machine Learning, Artificial Neural Networks and Deep Learning?—Examples of Practical Applications in Medicine*. <https://www.mdpi.com/2075-4418/13/15/2582>

**ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΙΝΟΥ ΜΕ
ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ**

- [15] Nick McCullum, (2020), *Deep Learning Neural Networks Explained in Plain English*. <https://www.freecodecamp.org/news/deep-learning-neural-networks-explained-in-plain-english/>
- [16] Sai Gowtham Babu, (2020), *Different types of Activation Functions in a Artificial Neural Network*. <https://medium.com/different-types-of-activation-functions-in-a/different-types-of-activation-functions-in-a-artificial-neural-network-4b0cc518da0f>
- [17] Yann Lecun, Yoshua Bengio, Geoffrey Hinton, (2023), *Deep learning*. <https://hal.science/hal-04206682/document>
- [18] Ian Goodfellow, Yoshua Bengio, Aaron Courville, (2016), «*Deep Learning*», MIT Press. <https://www.deeplearningbook.org/contents/convnets.html>
- [19] Moez Krichen, (2023), *Convolutional Neural Networks: A Survey*. <https://www.mdpi.com/2073-431X/12/8/151>
- [20] Yulia Gavrilova, (2021), *Convolutional Neural Networks for Beginners*. <https://serokell.io/blog/introduction-to-convolutional-neural-networks>
- [21] Sumit Saha, (2018), *A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way*. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [22] Mohammad Mustafa Taye, (2023), *Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions*. <https://www.mdpi.com/2079-3197/11/3/52>
- [23] Top Pre-Trained Models for Image Classification, (2024). <https://www.geeksforgeeks.org/top-pre-trained-models-for-image-classification/>
- [24] Pretrained Deep Neural Networks. https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html#responsive_offcanvas
- [25] What are convolutional neural networks? <https://www.ibm.com/topics/convolutional-neural-networks>
- [26] Christian Szegedy , Wei Liu , Yangqing Jia , Pierre Sermanet, Scott Reed, Dragomir Anguelov , Dumitru Erhan , Vincent Vanhoucke , Andrew Rabinovich, (2015), *Going Deeper with Convolutions*. https://www.cv-foundation.org/openaccess/content_cvpr_2015/papers/Szegedy_Going_Deeper_With_2015_CVPR_paper.pdf
- [27] Zhiling Guo, Qi Chen, Guangming Wu, Yongwei Xu, Ryosuke Shibasaki and Xiaowei Shao, (2017), *Village Building Identification Based on Ensemble Convolutional Neural Networks*. https://www.researchgate.net/publication/320723863_Village_Building_Identification_Based_on_Ensemble_Convolutional_Neural_Networks

ΑΝΙΧΝΕΥΣΗ ΑΤΡΑΚΤΩΝ ΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ ΥΠΝΟΥ ΜΕ ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

- [28] Nur Ateqah Binti Mat Kasim , Nur Hidayah Binti Abd Rahman , Zaidah Ibrahim, Nur Nabilah Abu Mangshor, (2018), *Celebrity Face Recognition using Deep Learning*. file:///C:/Users/sofia/Downloads/Celebrity_Face_Recognition_using_Deep_Learning.pdf
- [29] Understanding GoogLeNet Model – CNN Architecture, (2021). <https://www.geeksforgeeks.org/understanding-googlenet-model-cnn-architecture/>
- [30] Gaudenz Boesch, (2024), *GoogLeNet Explained: The Inception Model that Won ImageNet*. <https://viso.ai/deep-learning/googlenet-explained-the-inception-model-that-won-imagenet/>
- [31] Sanket Doshi, (2019), *Various Optimization Algorithms For Training Neural Network*. <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6>
- [32] What is Adam Optimizer?, (2024). <https://www.geeksforgeeks.org/adam-optimizer/>
- [33] Adam Optimizer for Stochastic Gradient Descent, (2024). <https://www.shiksha.com/online-courses/articles/adam-optimizer-for-stochastic-gradient-descent/>
- [34] Diederik P. Kingma, Jimmy Ba, (2014), *Adam: A Method for Stochastic Optimization*. <https://paperswithcode.com/method/adam>
- [35] Rahul Agarwal, (2023), *Complete Guide to the Adam Optimization Algorithm*. <https://builtin.com/machine-learning/adam-optimization>
- [36] Sieun Park, (2021), *A 2021 Guide to improving CNNs-Optimizers: Adam vs SGDM*. <https://medium.com/geekculture/a-2021-guide-to-improving-cnns-optimizers-adam-vs-sgd-495848ac6008>
- [37] Aman Gupta, Rohan Ramanath, Jun Shi, S. Sathiya Keerthi, (2021), *Adam vs. SGDM: Closing the generalization gap on image classification*. <https://www.opt-ml.org/papers/2021/paper53.pdf>

Ειδική αναφορά για την βάση δεδομένων από την οποία αντλήσαμε τα δεδομένα (επανάληψη του κειμένου που υπάρχει στο Κεφάλαιο 3):

Τα δεδομένα πάνω στα οποία βασίστηκε η παρούσα διπλωματική εργασία είναι 8 ηλεκτροεγκεφαλογραφήματα διάρκειας 30 λεπτών και αντλήθηκαν από τη βάση δεδομένων *Dream Database* του Πανεπιστημίου MONS (TCTS Laboratory) των Stéphanie Devuyst και Thierry Dutoit και του Ελεύθερου Πανεπιστημίου των Βρυξελλών (Charleroi Sleep Laboratory) της Myriam Kerkhofs, υπό τους όρους Αναφορά-Μη Εμπορική-Παρόμοια Διανομή 3.0 μη εισαγόμενη άδεια (Attribution-NonCommercial-NoDerivs 3.0 Unported (CC BY-NC-ND 3.0) License). Γιατροί με ειδικευση πάνω στο συγκεκριμένο πεδίο εντόπισαν στα υπό μελέτη ΗΕΓ ατράκτους ή άλλες κυματομορφές ύπνου. Η βάση είναι διαθέσιμη στον παρακάτω σύνδεσμο:

<https://zenodo.org/records/2650142>