



ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Κόστος των neural networks σε μνήμη και ενέργεια, σε εφαρμογές μικροσκοπικής μάθησης.

Του ΦΟΙΤΗΤΗ
Κωνσταντίνου Γουρνάκη
Επιβλέπων Καθηγητής:
Κατσαρός Δημήτριος

Βόλος
Ιούνιος, 2024

Ευχαριστίες

Με την παρούσα διπλωματική εργασία ολοκληρώνονται οι προπτυχιακές σπουδές μου στο Τμήμα Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών του Πανεπιστημίου Θεσσαλίας.

Στο σημείο αυτό, θα ήθελα να ευχαριστήσω όσους στάθηκαν κοντά μου και με στήριξαν κατά τη διάρκεια της φοιτητικής μου ζωής αλλά και όλους όσους συνέβαλαν στην εκπόνηση της διπλωματικής μου εργασίας.

Λίστα Εικόνων

Εικόνα 2.5. Οι εικόνες μπορούν να χωριστούν σε τοπικά μοτίβα, όπως ακμές, υφές και ούτω καθεξής (F. Chollet, , 2021).....σελ 44

Εικόνα 2.5 β. Ο οπτικός κόσμος σχηματίζει μια χωρική ιεραρχία οπτικών ενοτήτων: στοιχειώδεις γραμμές ή υφές συνδυάζονται σε απλά αντικείμενα όπως μάτια ή αυτιά, τα οποία συνδυάζονται σε έννοιες υψηλού επιπέδου όπως η «γάτα».....σελ45

Εικόνα 3.2α Αλληλεπίδραση σήματος και αναλογία σήματος σε τεχνητό νευρώνα.....σελ56

Εικόνα 3.2β Αναλογία βιολογικού και νευρωνικού σήματος.....σελ57

Λίστα Σχημάτων

Σχήμα 1.2 Νευρώνας.....	σελ 13
Σχήμα 1.3 Τεχνικός Νευρώνας.....	σελ 15
Σχήμα 1.4α Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου.....	σελ 16
Σχήμα 1.4β Δίκτυο πρόσθιας τροφοδότησης πολλών επιπέδων.....	σελ 17
Σχήμα 1.4γ Αναδρομικό Νευρωνικό Δίκτυο (Recurrent Neural Network).....	σελ 18
Σχήμα 1.5 : Στοιχειώδης αισθητήρας.....	σελ 20
Σχήμα 1.6 Δίκτυο πολλών επιπέδων με δύο κρυφά επίπεδα.....	σελ 21
Σχήμα 2.1 Οι μικροί κύκλοι καταγράφουν την μεταβολή του συναπτικού βάρους σε πραγματικές βιολογικές παρατηρήσεις 60 ζευγών νευρώνων του ιππόκαμπου.....	σελ 28
Σχήμα 2.3 Γενικός τρόπος λειτουργίας των αλγορίθμων Μηχανικής Μάθησης....	σελ 35
Σχήμα 2.4 : Variational model.....	σελ 42
Σχήμα 2.5 γ Αρχιτεκτονική τυπικού Συνελικτικού Νευρωνικού Δικτύου.....	σελ 46
Σχήμα 4.5 Παράδειγμα LSTM νευρώνα.....	σελ 94
Σχήμα 5.4.α Ένα παράδειγμα εικόνας 28×28 pixel του χειρόγραφου ψηφίου «8» από τη βάση δεδομένων MNIST-10 (α). Μοτίβα μετασχηματισμού του πίνακα εικόνων: T-pattern-1 (b), T-pattern-2 (c), T-pattern-3 (d).....	σελ 101
Σχήμα 5.6.α Αρχιτεκτονική LogNet (α). Δίκτυα προώθησης δύο επιπέδων (β) και 1 επιπέδων(γ).....	σελ 103
Σχήμα 5.6.β: Το διάγραμμα διακλάδωσης της λογιστικής χαρτογράφησης (2)..	σελ 104
Σχήμα 6.1 Σύγκριση ακρίβειας ταξινόμησης (LogNet-784:100:10) και εκθέτη Lyapunov λ στην παράμετρο r	σελ 107

Λίστα Διαγραμμάτων

Διάγραμμα 3.1. Σχηματική αναπαράσταση διαδικασίας παραγωγής νανοδομών επιμερισμένη σε τρία βασικά στάδια, της κατασκευής, χαρακτηρισμού και εφαρμογής..... σελ 49

Διάγραμμα 4.2: Μεθοδολογία Υλοποίησης Συστήματος.....σελ 83

Περίληψη

Τα τελευταία χρόνια έχει υπάρξει μία έκρηξη ενδιαφέροντος για τα νευρωνικά δίκτυα καθώς εφαρμόζονται με μεγάλη επιτυχία σε ένα ασυνήθιστα μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, όπως τα χρηματοοικονομικά, η ιατρική, η επιστήμη μηχανικού, η γεωλογία, η φυσική, η ρομποτική, η επεξεργασία σήματος κτλ. Στην πραγματικότητα, τα νευρωνικά δίκτυα εισάγονται οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου. Η σαρωτική αυτή επιτυχία, μπορεί να αποδοθεί σε δύο βασικά στοιχεία: την ισχύ και την ευχρηστία.

Τα νευρωνικά δίκτυα είναι πολύ εξελιγμένες τεχνικές μη γραμμικής μοντελοποίησης, ικανές να μοντελοποιήσουν εξαιρετικά πολύπλοκες λειτουργίες. Η γραμμική μοντελοποίηση υπήρξε ευρέως διαδεδομένη για πολύ καιρό, δεδομένου ότι στα γραμμικά μοντέλα εφαρμόζονται πολύ γνωστές στρατηγικές βελτιστοποίησης. Στις συνήθειες, όμως, περιπτώσεις όπου η γραμμική προσέγγιση δεν ήταν έγκυρη, τα μοντέλα αυτά αποτύγχαναν αναλόγως. Τα νευρωνικά δίκτυα βέβαια, αν και επιτρέπουν τη μη γραμμικότητα μέσω χρήσης μη γραμμικών συναρτήσεων ενεργοποίησης, μεταθέτουν με τη σειρά τους το πρόβλημα στο ζήτημα της διάστασης (του πλήθους των διαφορετικών εισόδων και εξόδων), το οποίο αποτελεί αγκάθι στις προσπάθειες μοντελοποίησης μη γραμμικών συναρτήσεων με μεγάλο αριθμό μεταβλητών.

Τα νευρωνικά δίκτυα εκπαιδεύονται με παραδείγματα. Ο χρήστης συγκεντρώνει αντιπροσωπευτικά δεδομένα και στη συνέχεια, καθώς τα τροφοδοτεί συστηματικά στο δίκτυο μέσω των κατάλληλων αλγορίθμων εκπαίδευσης, το δίκτυο «αντιλαμβάνεται» αυτομάτως τη δομή των δεδομένων και η «γνώση» αυτή εκφράζεται ως κατάλληλες επιλογές συναπτικών βαρών. Επομένως το τελικό αποτέλεσμα της εκπαίδευσης με ένα συγκεκριμένο σύνολο παραδειγμάτων είναι ο προσδιορισμός των κατάλληλων βαρών του δικτύου. Ο χρήστης χρειάζεται να έχει κάποιες ουσιώδεις γνώσεις σχετικά με τον τρόπο επιλογής και προετοιμασίας των δεδομένων, τον τρόπο εκλογής του κατάλληλου νευρωνικού δικτύου και στο πως θα ερμηνευτούν τα αποτελέσματα. Παρά ταύτα, το επίπεδο των γνώσεων του χρήστη που απαιτούνται για μια επιτυχημένη εφαρμογή των νευρωνικών δικτύων, είναι πολύ χαμηλότερο συγκριτικά με κάποια περίπτωση που θα χρησιμοποιούνταν ορισμένες πιο παραδοσιακές, μη γραμμικές στατιστικές μέθοδοι.

Abstract

In recent years there has been an explosion of interest in neural networks as they are applied with great success in an unusually wide range of fields of science and technology, such as finance, medicine, engineering, geology, physics, robotics, signal processing etc. In fact, neural networks are introduced wherever there is a question of prediction, classification or control. This sweeping success can be attributed to two main elements: power and ease of use.

Neural networks are highly sophisticated nonlinear modeling techniques capable of modeling highly complex functions. Linear modeling has been widespread for a long time, since well-known optimization strategies are applied to linear models. In the usual cases, however, where the linear approximation was not valid, these models failed accordingly. Neural networks, of course, while allowing for nonlinearity through the use of non-linear activation functions, in turn shift the problem to the issue of dimensionality (the number of different inputs and outputs), which is a thorn in the side of modeling non-linear functions with large number of variables.

Neural networks are trained with examples. The user collects representative data and then, as he systematically feeds it to the network through the appropriate training algorithms, the network automatically "understands" the structure of the data, and this "knowledge" is expressed as appropriate choices of synaptic weights. Therefore the end result of training with a specific set of examples is to determine the appropriate weights of the network. The user needs to have some essential knowledge about how to select and prepare the data, how to choose the appropriate neural network and how to interpret the results. However, the level of user knowledge required for a successful application of neural networks is much lower than would be the case if some more traditional, non-linear statistical methods were used.

Λίστα Περιεχομένων

Ευχαριστίες.....	σελ 2
Λίστα Εικόνων.....	σελ 3
Λίστα Σχημάτων.....	σελ 4
Λίστα Διαγραμμάτων.....	σελ 5
Περίληψη.....	σελ 6
Abstract.....	σελ 7
Λίστα Περιεχομένων.....	σελ 8
ΘΕΩΡΗΤΙΚΟ ΜΕΡΟΣ.....	σελ 10
Κεφάλαιο 1.....	σελ 10
1.1 Η έννοια του τεχνητού νευρωνικού δικτύου.....	σελ 10
1.2 Η δομή του νευρώνα.....	σελ 12
1.3 Από τα βιολογικά στα τεχνητά νευρωνικά δίκτυα.....	σελ 14
1.4 Παραδείγματα νευρωνικών δικτύων.....	σελ 15
1.5 Ο αισθητήρας (Perceptron).....	σελ 19
1.6 Πολυεπίπεδοι Αισθητήρες (MultiLayer Perceptrons, MLPs).....	σελ 20
Κεφάλαιο 2.....	σελ 25
2.1 Στοιχεία της θεωρίας μάθησης-Κανόνες μάθησης.....	σελ 25
2.2 Αλγόριθμοι μάθησης.....	σελ 29
2.3 Μηχανική Μάθηση.....	σελ 31
2.3 Μηχανική Μάθηση.....	σελ 31
2.4 Κβαντική Μηχανική Μάθηση.....	σελ 39
2.5 Βαθιά Συνελικτική Μάθηση-Βαθύ Συνελικτικό Δίκτυο.....	σελ 43
Κεφάλαιο 3.....	σελ 47
3.1 Μικροσκοπική Μάθηση.....	σελ 47
3.2 Αρχές Μικροσκοπικής Μάθησης και Νευρωνικά Δίκτυα.....	σελ 53
3.3 Εφαρμογές Νευρωνικών Δικτύων.....	σελ 67
3.4 Εφαρμογές Μικροσκοπικής Μάθησης σε Νευρωνικά Δίκτυα.....	σελ 77
ΕΡΕΥΝΗΤΙΚΟ ΜΕΡΟΣ.....	σελ 81

Κεφάλαιο 4.....	σελ 81
4.1 Βασικές Αρχές και Επισκόπηση Βιβλιογραφίας.....	σελ 81
4.2 Τεχνικές για Αναγνώριση Ανθρώπινης Δραστηριότητας.....	σελ 82
-Αναγνώριση Εικόνας.....	σελ 82
4.3 Συνελικτικά Νευρωνικά Δίκτυα.....	σελ 90
4.4 Αναδρομικά Νευρωνικά Δίκτυα και Μακρά Δίκτυα Βραχείας Μνήμης.	σελ 92
4.5 Προσεγγίσεις με Νευρωνικά Δίκτυα.....	σελ 93
4.6 Τεχνικές Συμπίεσης Νευρωνικών Δικτύων.....	σελ 95
Κεφάλαιο 5.....	σελ 96
5.1 Πλαίσιο Υλοποίησης για Συλλογή Δεδομένων.....	σελ 96
- Case Study Αναγνώριση Εικόνας.....	σελ 96
5.2 Πλατφόρμα.....	σελ 99
5.3 Εφαρμογή.....	σελ 100
5.4 Σύνολο Δεδομένων.....	σελ 100
5.5 Προεπεξεργασία Δεδομένων.....	σελ 102
5.6 Μεθοδολογία Αξιολόγησης του Μοντέλου.....	σελ 102
5.7 Κώδικας Υλοποίησης Νευρωνικού Δικτύου(CNN) σε Γλώσσα Προγραμματισμού Python.....	σελ 104
Κεφάλαιο 6.....	σελ 106
6.1 Συζήτηση Έρευνας.....	σελ 106
6.2 Αποτελέσματα Ερευνητικού Μέρους.....	σελ 110
6.3 Συμπεράσματα -Μελλοντικές Προτάσεις.....	σελ 110
Βιβλιογραφία.....	σελ 113

ΘΕΩΡΗΤΙΚΟ ΜΕΡΟΣ

Κεφάλαιο 1

1.1 Η έννοια του τεχνητού νευρωνικού δικτύου.

Τα Τεχνητά Νευρωνικά Δίκτυα, αποτελούν απλοποιημένα μοντέλα του κεντρικού νευρικού συστήματος των ζώντων οργανισμών και ειδικότερα του ανθρώπου. Οι λειτουργίες τους, μιμούνται αυτή των βιολογικών νευρώνων του εγκεφάλου και τη δομή των βιολογικών Νευρικών Δικτύων. Επιχειρούν δηλαδή, να συνδυάσουν την λειτουργία του ανθρώπινου εγκεφάλου, με τον αυστηρά αφηρημένο μαθηματικό τρόπο σκέψης, ξεχωρίζοντας με αυτό τον τρόπο τα ΤΝΔ από την Βιολογία και την κλασσική λειτουργία των υπολογιστών. Έτσι, για παράδειγμα, ένα Νευρωνικό Δίκτυο είναι ικανό να μαθαίνει, να εκπαιδεύεται, να θυμάται ή να ξεχνά μία αριθμητική παράσταση κ.λ.π, πράξεις που μέχρι πρότινος αποδίδαμε μόνο στην ανθρώπινη σκέψη και ικανότητα. Επιπλέον, καθίστανται ικανά να χρησιμοποιούν πολύπλοκες συναρτήσεις και άλλα σύνθετα αντικείμενα της μαθηματικής Ανάλυσης. Ειδικότερα, αποτελούνται από διασυνδεδεμένα υπολογιστικά στοιχεία, τα οποία είναι ικανά να ανταποκρίνονται σε ερεθίσματα που δέχονται στην είσοδο τους και να μαθαίνουν να προσαρμόζονται στο περιβάλλον τους. Όπως γίνεται αντιληπτό, πηγή έμπνευσης στην έρευνα των ΤΝΔ, αποτελεί η Βιολογία και η Ιατρική. Οι ζωντανοί οργανισμοί, από τους πιο απλούς μέχρι τον πιο σύνθετο, τον άνθρωπο, εκτελούν διάφορες καθημερινές διεργασίες, όπως είναι η επαφή με τον εξωτερικό κόσμο, η μάθηση και η μνήμη. Υπεύθυνο για την εκτέλεση αυτών των εργασιών, είναι το Νευρικό Σύστημα, που όλοι οι έμβιοι οργανισμοί εκτός

από τα φυτά διαθέτουν. Το Νευρικό Σύστημα των οργανισμών, αποτελείται από πολλά Νευρωνικά Δίκτυα, που είναι εξειδικευμένα σε διάφορες εργασίες. Τα Νευρωνικά Δίκτυα αυτά, τα ονομάζουμε Βιολογικά Νευρωνικά Δίκτυα, καθώς είναι τα πρώτα δίκτυα που μελετήθηκαν και υπάρχουν στους ζώντες οργανισμούς. Πυρήνας του Νευρικού συστήματος των οργανισμών αποτελεί ο εγκέφαλος, ο οποίος επίσης αποτελείται από Νευρωνικά Δίκτυα. Κάθε Νευρωνικό Δίκτυο αποτελείται από ένα μεγάλο αριθμό μονάδων, που ονομάζονται Νευρώνες ή Νευρώνια (Neurons). Οι Νευρώνες αποτελούν το βασικό δομικό στοιχείο του εγκεφάλου. Καθίστανται δηλαδή, η πιο μικρή ανεξάρτητη μονάδα του Δικτύου, όπως το άτομο είναι η πιο μικρή μονάδα της ύλης. Οι Νευρώνες επεξεργάζονται πληροφορίες συνεχώς και ασταμάτητα, παίρνοντας και στέλνοντας ηλεκτρικά σήματα σε άλλους Νευρώνες. Κίνητρο για την έρευνα και τη μελέτη του Νευρώνα και του Νευρωνικού Δικτύου, αποτέλεσε η ελπίδα ανακάλυψης ενός νέου πρότυπου υπολογιστικού μοντέλου με δικτυακή δομή, όμοια με αυτή του εγκεφάλου. Με αφετηρία τον στόχο της ανακάλυψης αυτής, δημιουργήθηκε μια καινοτόμα υπολογιστική πλατφόρμα γνωστή ως Connectionist Model, κατάλληλη για την ανάπτυξη ευφρών αλγόριθμων και διαδικασιών επάνω στην νοημοσύνη, όπως η μάθηση και η απομνημόνευση. Μέσα από αυτό το μοντέλο, κατορθώνεται να συνδυαστούν διάφοροι κλάδοι επιστημών όπως η Ψυχολογία, η Νευρολογία, η Ανθρωπολογία κ.ά. πλάθοντας με αυτό τον τρόπο την Γνωσιακή Επιστήμη (Cognitive Science) και κατ'επέκταση το παραπάνω μοντέλο, το οποίο προσπαθεί να ενώσει τον ψυχικό κόσμο των έμβιων οργανισμών και την νοημοσύνη, σε έναν υπολογιστή με την χρήση των ΤΝΔ. Τα πιο διαδεδομένα Τεχνητά Νευρωνικά Δίκτυα, χρησιμοποιούν πολύ απλοποιημένα μοντέλα Νευρώνων, με συνέπεια να διατηρούν μόνο τα κύρια χαρακτηριστικά των μοντέλων που υπάρχουν στην Νευρολογία. Έτσι, καταλήγουμε στο συμπέρασμα, ότι τα Τεχνητά Νευρωνικά Μοντέλα έχουν ελάχιστη σχέση με τα

αντίστοιχα Βιολογικά Νευρωνικά Δίκτυα. Ωστόσο, στην κατανόηση της ευφυούς συμπεριφοράς των Βιολογικών Νευρωνικών Δικτύων, οι διαφορές αυτές στα χαρακτηριστικά, δεν έχουν ιδιαίτερη αξία. Παρόλα αυτά, ακόμα, και τα απλά μοντέλα είναι ικανά να δημιουργήσουν ενδιαφέροντα δίκτυα, με την προϋπόθεση ότι πληρούν δύο βασικά χαρακτηριστικά :

1. Οι Νευρώνες τους πρέπει να διαθέτουν ρυθμιζόμενες παραμέτρους, ώστε να γίνεται πιο εύκολη διαδικασία της μάθησης (Πλαστικότητα των Νευρώνων).
2. Το Δίκτυο είναι αναγκαίο να δομείται από πολλούς Νευρώνες, έτσι ώστε να είναι εφικτός ο παραλληλισμός της επεξεργασίας και η κατανομή της πληροφορίας. Ο εγκέφαλος αποτελεί σε όλα τα έμβια όντα το κύριο όργανο του Νευρικού Συστήματος, έτσι τα ΤΝΔ θα ήταν αδύνατο να μην έχουν δανειστεί στην δομή τους, χαρακτηριστικά του. Τα κύρια κοινά δομικά χαρακτηριστικά του εγκεφάλου με τα ΤΝΔ, είναι τα εξής :
 1. Η γνώση αποκτάται από το δίκτυο, μέσα από μια διαδικασία μάθησης, δηλαδή όπως ακριβώς ένα παιδί μαθαίνει με την επανάληψη των ίδιων εργασιών.
 2. Αποθήκη της γνώσης παρουσιάζονται οι δυνάμεις σύνδεσης των Νευρώνων, τα συναπτικά βάρη, μέσα από τα οποία κάθε νευρώνας, καταλαβαίνει κατά πόσο η εκάστοτε πληροφορία, τον αφορά ή όχι.

1.2 Η δομή του νευρώνα.

Η ανατομία του νευρώνα, δεν παρουσιάζει καμία διαφορά σε σχέση με τα υπόλοιπα κύτταρα του ανθρώπινου οργανισμού. Αποτελείται λοιπόν, από το σώμα, τον πυρήνα, τους δενδρίτες, τον άξονα και τις συνάψεις. Πιο συγκεκριμένα, το σώμα αποτελεί το κυρίως μέλος του νευρώνα, μέσα στο οποίο βρίσκεται ο πυρήνας του κυττάρου. Στον πυρήνα υπάρχουν όλες οι πληροφορίες, του γεννητικού υλικού του οργανισμού. Οι

δενδρίτες, είναι το σημείο εισόδου των πληροφοριών, όπου ο κάθε νευρώνας δέχεται από τους γειτονικούς του νευρώνες. Η ροή δεδομένων, εισέρχεται στον κάθε νευρώνα και μέσω των δενδριτών, με την μορφή ηλεκτρικών παλμών. Η εισερχόμενη στον εκάστοτε νευρώνα πληροφορία, εξέρχεται από αυτόν, μέσω ηλεκτρικών σημάτων, με την λειτουργία του σημείου εξόδου του νευρώνα, τον άξονα. Κλείνοντας την βασική δομή ενός νευρώνα, οι συνάψεις, είναι τα απειροελάχιστα κενά, στα οποία ενώνονται οι διακλαδώσεις του άξονα ενός νευρώνα, με τους δενδρίτες άλλων γειτονικών του. Η αμεσότητα, με την οποία μεταδίδεται η ηλεκτρική δραστηριότητα από έναν άξονα αποστολέα στους δενδρίτες-παραλήπτες, εξαρτάται από το πλάτος της σύναψης και από την πυκνότητα του ηλεκτροχημικού υλικού. Η ποσότητα του ηλεκτρικού παλμού που μεταφέρεται τελικά στους δενδρίτες του νευρώνα - παραλήπτη, ονομάζεται συναπτικό βάρος.



Σχήμα 1.2 Νευρώνας


Οι νευρώνες παρουσιάζουν, δύο πιθανές καταστάσεις. Κατά την λειτουργία, του ένας νευρώνας μπορεί να είναι ενεργός ή μη-ενεργός. Όταν λέμε ότι ένας νευρώνας είναι

ενεργός, εννοούμε ότι πυροδοτεί ένα ηλεκτρικό σήμα, μέσω του οποίου, μεταφέρονται τα δεδομένα που υπάρχουν στον νευρώνα, σε κάποιον γειτονικό του. Αντίστοιχα, όταν ένας νευρώνας παραμένει αδρανής, δηλαδή είναι μη-ενεργός, δεν παράγει ηλεκτρικό σήμα. Μέσω αυτής της ευαισθησίας του νευρώνα, να αντιδράει σε εξωτερικά ερεθίσματα (ηλεκτρομαγνητικά, χημικά, θερμικά κ.ά.), παράγονται οι ηλεκτρικοί παλμοί που μεταφέρουν τις πληροφορίες. Ο εκάστοτε νευρώνας, συλλέγει όλο το ηλεκτρικό φορτίο που παραλαμβάνει, από όλες τις συνάψεις του, στους δενδρίτες του. Όσο πιο ισχυρός είναι ο δεσμός, σε μία σύναψη δύο νευρώνων, τόσο πιο έντονα συμμετέχει το συγκεκριμένο παραγόμενο φορτίο εισόδου, στο συνολικό άθροισμα φορτίου. Ένας νευρώνας είναι ενεργός, δηλαδή παράγει ηλεκτρικούς παλμούς, εάν το συνολικό άθροισμα του φορτίου του, είναι μεγαλύτερο από ένα κατώφλι. Σε αντίθετη περίπτωση, ο νευρώνας καθίσταται αδρανής. Έτσι, αναφέρουμε ότι ο νευρώνας, είναι ένα δυαδικό στοιχείο.

1.3 Από τα βιολογικά στα τεχνητά νευρωνικά δίκτυα.

Ένας απλοποιημένος βιολογικός νευρώνας, λαμβάνει στους δενδρίτες του, σήματα εισόδου σε μορφή ηλεκτρικών παλμών, τα επεξεργάζεται και τέλος τα μεταφέρει μέσω του άξονα και των συνάψεων σε άλλους γειτονικούς νευρώνες, εάν βρίσκεται σε ενεργή κατάσταση. Στο αντίστοιχο μαθηματικό μοντέλο, ο νευρώνας λαμβάνει στους δενδρίτες του κάποια σήματα εισόδου $x_1, x_2, \dots, x_n$, τα οποία παίρνει από τον άξονα του προηγούμενου νευρώνα, πολλαπλασιαστικά και μέσω των συνάψεων (βάρη) w_i . Ο ρόλος των συναπτικών βαρών, είναι αντίστοιχος των συνάψεων του βιολογικού μοντέλου. Τα συναπτικά βάρη είναι εκπαιδεύσιμα και ελέγχουν την επιρροή, που ασκεί ένας νευρώνας σε έναν άλλο. Ανάλογα με τις τιμές των βαρών, θετικές ή αρνητικές, η λειτουργία ενός νευρώνα είναι διεγερτική ή ανασταλτική αντίστοιχα, όσον αφορά την

μεταφορά των δεδομένων, ή όχι. Το παρακάτω σχήμα, παρουσιάζει το μοντέλο του τεχνητού νευρώνα.



Σχήμα 1.3 Τεχνητός Νευρώνας


1.4 Παραδείγματα νευρωνικών δικτύων.

Ένα σύνολο νευρώνων, μαζί με τις συνάψεις τους, δομούν ένα βιολογικό νευρωνικό δίκτυο. Μέσα από έναν τόσο απλό ορισμό και με μια γρήγορη ματιά στα βιολογικά νευρωνικά δίκτυα, μπορεί κανείς να λάβει μία πρώτη εικόνα, από τον κόσμο των τεχνητών νευρωνικών δικτύων. Τα νευρωνικά δίκτυα, διαχωρίζονται με βάση τη λειτουργία τους, την μέθοδο εκπαίδευσης και την αρχιτεκτονική τους. Ο όρος αρχιτεκτονική ενός δικτύου, ορίζει με ακρίβεια τον τρόπο διάταξης των συνδέσεων των νευρώνων, όπως επίσης και τον αριθμό και τον τύπο τους. Σε ένα νευρωνικό δίκτυο, οι νευρώνες οργανώνονται σε μορφή επιπέδων και δομούνται με βάση τον αλγόριθμο μάθησης, που χρησιμοποιείται κατά την εκπαίδευση του εκάστοτε δικτύου. Τελικά, προκύπτουν οι παρακάτω κατηγορίες αρχιτεκτονικών δικτύων:

- i) Δίκτυα πρόσθιας τροφοδότησης ενός επιπέδου (feedforward): Τα δίκτυα αυτά, αποτελούν την πιο απλή μορφή που ένα δίκτυο μπορεί να πάρει. Η δομή τους, απαρτίζεται από ένα επίπεδο εισόδου, αποτελούμενο από πηγαίους κόμβους και από

ένα επίπεδο νευρώνων εξόδου. Το ηλεκτρικό σήμα, που εισέρχεται στο επίπεδο εισόδου, μεταφέρεται μονόδρομα και προς το επίπεδο νευρώνων εξόδου. Ο ρόλος των νευρώνων εισόδου του δικτύου, περιορίζεται στην μεταφορά του σήματος στο επίπεδο εξόδου, χωρίς να πραγματοποιούν κάποια επεξεργασία στην πληροφορία που διαδίδεται. Ο χαρακτηρισμός “ενός επιπέδου” προσανατολίζεται στο επίπεδο εξόδου, όπου και υλοποιείται ο υπολογισμός της τελικής τιμής, που το επίπεδο εξάγει. Η περιθωριοποίηση από τον χαρακτηρισμό αυτόν, του επιπέδου εισόδου, είναι πλήρως δικαιολογημένη, καθώς ο μοναδικός του ρόλος είναι η απλή μεταφορά του σήματος.


Στο παρακάτω σχήμα παρουσιάζεται ένα δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου:



Σχήμα 1.4α Δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου.

ii) Πολυεπίπεδα δίκτυα πρόσθιας τροφοδότησης: Η ιδέα των πολυεπίπεδων δικτύων, δομήθηκε σε απόλυτη συνάφεια με την αντίστοιχη του δικτύου ενός επιπέδου, που μελετήσαμε παραπάνω, πραγματοποιώντας μια προσθήκη σε αυτό. Πιο συγκεκριμένα, ένα πολυεπίπεδο δίκτυο, αποτελείται από τα επίπεδα εισόδου και εξόδου, με την ενσωμάτωση ενός ή περισσότερων κρυφών επιπέδων. Οι νευρώνες των κρυφών

επιπέδων, ονομάζονται κρυφοί. Σε κάθε επίπεδο, η είσοδος των νευρώνων, είναι τα σήματα εξόδου του προηγούμενου επιπέδου. Το σήμα, διαδίδεται μέσα στο δίκτυο, από το επίπεδο εισόδου και μέσω των κρυφών επιπέδων, προς το τελικό επίπεδο εξόδου. Όμοια με το δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου, η λειτουργία των επιπέδων εισόδου, περιορίζεται στην μεταφορά του σήματος στα επόμενα επίπεδα, χωρίς να πραγματοποιούν καμία επεξεργασία. Αντίθετα, οι κρυφοί νευρώνες και οι νευρώνες εξόδου, είναι οι υπολογιστικοί νευρώνες, που το μοντέλο ακολουθεί.




Σχήμα 1.4β Δίκτυο πρόσθιας τροφοδότησης πολλών επιπέδων.

iii) *Αναδρομικά Δίκτυα (Recurrent Neural Network):* Στην αρχιτεκτονική των παραδοσιακών νευρωνικών δικτύων, όπως παρουσιάστηκαν, γίνεται η υπόθεση, ότι όλες οι είσοδοι (και οι έξοδοι), είναι ανεξάρτητες μεταξύ τους. Με την ανάπτυξη των ΤΝΔ, παρατηρήθηκε ότι η υπόθεση αυτή, παρουσιάζει αρκετά κενά, στην λειτουργία των νευρωνικών δικτύων, όπως η αδυναμία μεταφοράς χαρακτηριστικών από το ένα επίπεδο νευρώνων στο άλλο. Για τον λόγο αυτό, χάνεται η αναγκαία για την πιο αποτελεσματική μάθηση, κληρονομικότητα. Έτσι, δημιουργήθηκε η ανάγκη εξέλιξης της αρχιτεκτονικής των νευρωνικών δικτύων, προκειμένου να γίνουν πιο αποδοτικά. Κλειδί

στην προσπάθεια αυτή των ερευνητών, αποτέλεσε η ιδέα της διαδοχικής πληροφορίας, δίνοντας το έναυσμα να δημιουργηθούν τα λεγόμενα αναδρομικά νευρωνικά δίκτυα. Ο όρος “αναδρομικά”, προέρχεται από την δυνατότητα που προσφέρει η αρχιτεκτονική τέτοιων δικτύων να εκτελούν την ίδια εργασία, για κάθε στοιχείο μίας αλληλουχίας, με το αποτέλεσμα να εξαρτάται από τους προηγούμενους υπολογισμούς. Δημιουργείται δηλαδή, η έννοια της ύπαρξης “μνήμης” πληροφοριών σε αυτού του τύπου τα δίκτυα.

Στο παρακάτω σχήμα, παρατίθεται ένα αναδρομικό νευρωνικό δίκτυο:



Σχήμα 1.4γ Αναδρομικό Νευρωνικό Δίκτυο (Recurrent Neural Network).

Στο παραπάνω διάγραμμα παρουσιάζεται, πως ένα αναδρομικό δίκτυο ξετυλίγεται σε μια πλήρη ανάλυση του δικτύου. Η χρήση της λέξης του “ξετυλίγματος”, αναφέρεται στην αντικατάσταση του δικτύου από την πλήρη αλληλουχία. Για παράδειγμα, εάν η ακολουθία είναι μία πρόταση 4 λέξεων, τότε το δίκτυο θα ξετυλίγονταν σε 4 επίπεδα, ένα επίπεδο $S(t)$ για κάθε λέξη. Η δομή του εκάστοτε επιπέδου, αποτελείται από τα εξής :


- a) $x(t)$ είναι η είσοδος του επιπέδου στο βήμα t . Παραδείγματος χάριν, το $x(1)$ θα μπορούσε να είναι ένα διάνυσμα, το οποίο να παριστάνει την δεύτερη λέξη μίας πρότασης.
- b) $s(t)$ είναι τα λεγόμενα κρυφά επίπεδα στο βήμα t . Τα επίπεδα αυτά, αποτελούν την “μνήμη” του δικτύου και τα αποτελέσματά τους, υπολογίζονται με βάση την τελική τιμή του προηγούμενου κρυφού επιπέδου $s(t-1)$ και της νέας εισόδου, στο

αντίστοιχο βήμα t . Δηλαδή : $s(t)=f(Ux(t)+Ws(t))$. Η συνάρτηση ενεργοποίησης f , συνήθως είναι μη-γραμμική, όπως η συνάρτηση της υπερβολικής εφαστομένης. $c)$ Ως $o(t)$, ορίζεται η έξοδος στο βήμα t που παράγει το συγκεκριμένο επίπεδο. Αξίζει να σημειωθεί, ότι στην πραγματικότητα, δεν καθίσταται δυνατόν να υπολογιστεί, από το προηγούμενο $s(t-1)$ οποιοδήποτε $s(t)$, αλλά αυτό υλοποιείται παρά μόνο για μερικά βήματα πίσω. Τέλος σημειώνεται, ότι η έξοδος κάθε νευρώνα του δικτύου τροφοδοτεί την είσοδο των άλλων νευρώνων του επιπέδου π.χ. του $s(t-2)$ και μερικές φορές ανατροφοδοτεί και την δική του είσοδο. Το φαινόμενο αυτό ονομάζεται αυτοανάδραση.

1.5 Ο αισθητήρας (Perceptron).

Ο αισθητήρας, είναι από τα πρώτα νευρωνικά δίκτυα που αναπτύχθηκαν, συμβάλλοντας τα μέγιστα στην ανάπτυξη του τομέα των νευρωνικών δικτύων, λόγω των πολλών επιτυχιών που είχε. Το μοντέλο του στοιχειώδη αισθητήρα (Elementary Perceptron), είναι το πιο απλό μοντέλο νευρωνικού δικτύου που σχεδιάστηκε ποτέ, καθώς αποτελείται μόνο από έναν νευρώνα. Προτάθηκε το 1958, από τον Rosenblatt και κατάφερε να εξελιχθεί, αποτελώντας την βάση για την δημιουργία πιο σύνθετων δικτύων, κυρίως λόγω της απλότητας, της χρησιμότητας και της αυτοδυναμίας, που ως μοντέλο είχε. Το δίκτυο Perceptron, μπορεί να δέχεται πολλές διαφορετικές εισόδους, αλλά παράγει μοναδική έξοδο. Στο σημείο αυτό, είναι κρίσιμο να αναφερθεί ότι ο νευρώνας του δικτύου, μπορεί να εξάγει πολλές εξόδους, οι οποίες όμως έχουν όλες την ίδια τιμή. Κάθε εισερχόμενο σήμα a_i , συνδέεται με τον κεντρικό νευρώνα, μέσω ενός βάρους w_i . Τα συνοπτικά βάρη, μας δείχνουν την επίδραση του εισερχόμενου σήματος, στον νευρώνα. Στο δίκτυο αυτό, οι τιμές εισόδου και τα αντίστοιχα βάρη από μόνα τους, δεν έχουν απολύτως καμία λειτουργική σημασία για το σύστημα. Η ποσότητα που συμβάλλει στην δημιουργία του εξερχόμενου σήματος, είναι το γινόμενο των σημάτων


εισόδου με τα αντίστοιχα συναπτικά τους βάρη $a_i w_i$. Έτσι, το δίκτυο υπολογίζει το άθροισμα των $a_i w_i$, για όλες.



Σχήμα 1.5 : Στοιχειώδης αισθητήρας

1.6 Πολυεπίπεδοι Αισθητήρες (MultiLayer Perceptrons, MLPs).

Το δίκτυο *Perceptron* των πολλών επιπέδων (*Multi-Layer Perceptron*), αναπτύχθηκε με βάση το μοντέλο *Perceptron* ενός νευρώνα. Σε αντίθεση με το στοιχειώδες μοντέλο *Perceptron*, που αποτελείται από έναν μοναδικό νευρώνα (1-επίπεδο), το δίκτυο *MLP* συντίθεται από ένα σύνολο αισθητήρων (πηγαίοι κόμβοι), που αποτελούν το επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα (*hidden-layers*) και ένα επίπεδο εξόδων. Τα κρυφά επίπεδα και το επίπεδο εξόδου, αποτελούν υπολογιστικοί κόμβοι, δηλαδή εκεί πραγματοποιούνται οι πράξεις για τον υπολογισμό της τελικής τιμής εξόδου, που το δίκτυο παράγει. Κύριο χαρακτηριστικό της δομής των δικτύων πολλών επιπέδων, είναι ότι οι νευρώνες οποιουδήποτε στρώματος l , τροφοδοτούν αποκλειστικά τους νευρώνες του επόμενου στρώματος $l+1$ και λαμβάνουν πληροφορίες, μόνο από τους νευρώνες του προηγούμενου στρώματος $l-1$. Η αρχιτεκτονική ενός δικτύου *MLP* τριών επιπέδων με δύο κρυφά επίπεδα, απεικονίζεται στο παρακάτω σχήμα 1.6.



Σχήμα 1.6 Δίκτυο πολλών επιπέδων με δύο κρυφά επίπεδα.

Η αρχιτεκτονική που απεικονίζεται παραπάνω, προέρχεται από την γνωστή μας αρχιτεκτονική των *feedforward networks* (βλ. αντίστοιχη ενότητα). Έτσι, κάθε νευρώνας οποιουδήποτε επιπέδου, είναι συνδεδεμένος με όλους τους νευρώνες του προηγούμενου επιπέδου του. Το δίκτυο αυτό, ονομάζεται πλήρως συνδεδεμένο. Επιπρόσθετα, το ηλεκτρικό σήμα μεταφέρεται μονόδρομα από αριστερά προς τα δεξιά και από επίπεδο σε επίπεδο, ξεκινώντας από το επίπεδο εισόδου, καταλήγοντας στο επίπεδο εξόδου και μέσω των κρυφών επιπέδων. Τα πολυεπίπεδα δίκτυα *Perceptron*, έχουν αρκετά πιο πολύπλοκη δομή και λειτουργία, από αυτή του μοντέλου του στοιχειώδους αισθητήρα. Μερικά από τα πιο κύρια χαρακτηριστικά των δικτύων *MLP*, είναι τα εξής: ▪ Το μοντέλο του κάθε νευρώνα του δικτύου, περιλαμβάνει μία μη γραμμική συνάρτηση ενεργοποίησης, που είναι παραγωγίσιμη σε όλο το πεδίο ορισμού της. Η πιο διαδεδομένη συνάρτηση, που πληρεί αυτές τις προϋποθέσεις είναι η γνωστή

μας Σιγμοειδής, με τύπο:

$$f(u) = \frac{1}{1 + e^{-u}} \quad (1.6.1)$$

- Το χαρακτηριστικό αυτό, αυτού του τύπου δικτύου, πηγάζει από το γεγονός ότι οι περισσότεροι κανόνες εκπαίδευσης, στηρίζονται σε μεθόδους βελτιστοποίησης που χρησιμοποιούν παραγώγους. Για τον λόγο αυτό, συναρτήσεις όπως η Βηματική, (έχει δυαδικές τιμές, δεν είναι παραγωγίσιμη και δεν είναι συνεχής, σε όλο το πεδίο ορισμού της), δεν επαρκούν για αυτού του τύπου τα δίκτυα. Επιπλέον, μέσω της μη γραμμικότητας η σχέση εισόδου-εξόδου ενός πολυεπίπεδου δικτύου, θα υποβιβάζοταν σε αυτή του απλού *Perceptron* ενός επιπέδου.
- Σ'ένα δίκτυο *MLP*, υπάρχουν ένα ή και περισσότερα επίπεδα, κρυφά για τους κόμβους των επιπέδων εισόδων και εξόδων, τα λεγόμενα κρυφά επίπεδα. Οι νευρώνες των κρυφών επιπέδων, ονομάζονται κρυφοί νευρώνες και προσφέρουν στο δίκτυο την δυνατότητα να μάθει πολύπλοκες εργασίες, εξάγοντας τα πιο σημαντικά χαρακτηριστικά, από τα διανύσματα εισόδου.
- Ένα αξιολογούμετο προσόν των δικτύων *MLP*, καθίσταται ο υψηλός βαθμός διασύνδεσης που επιδεικνύει, ανάλογα και με τα βάρη του δικτύου.
- Τα πολυεπίπεδα δίκτυα *Perceptron*, διαθέτουν δύο είδη σημάτων: Τα λειτουργικά σήματα (*function signals*) και σήματα σφάλματος (*error signals*). Το πρώτο είδος σημάτων, είναι σήματα εισόδου, τα οποία καταφτάνουν στην είσοδο του δικτύου. Στην συνέχεια, μεταφέρονται διαμέσου του δικτύου, με την γνωστή κατεύθυνση (αριστερά προς τα δεξιά) και εμφανίζονται τελικώς στο επίπεδο εξόδου ως έξοδοι, όπου και εκτελούν μία χρήσιμη λειτουργία στην έξοδο του δικτύου. Σε κάθε νευρώνα οποιουδήποτε επιπέδου του δικτύου, τα σήματα αυτά υπολογίζονται συναρτήσει των εισόδων του νευρώνα και των αντίστοιχων συνοπτικών βαρών. Το δεύτερο είδος, είναι τα σήματα σφάλματος, τα οποία δημιουργούνται σε έναν νευρώνα εξόδου του δικτύου

MLP και μεταφέρονται προς τα πίσω, δια μέσω του δικτύου, από επίπεδο σε επίπεδο. Ο ρόλος όλων των κρυφών νευρώνων και των νευρώνων εξόδου ενός πολυεπίπεδου μοντέλου *Perceptron*, καθίσταται ο υπολογισμός του λειτουργικού σήματος που παρουσιάζεται στην έξοδό τους. Επιπρόσθετα, οι νευρώνες αυτοί, βρίσκουν μία εκτίμηση του διανύσματος κλίσης που απαιτείται για την πίσω διάδοση, μέσω του δικτύου. Ένα ιδιαίτερα σημαντικό πλεονέκτημα των πολυεπίπεδων δικτύων *Perceptron*, είναι η ικανότητά τους να χρησιμοποιούν πιο περίπλοκες συναρτήσεις, όπου το μοντέλο του απλού αισθητήρα δεν μπορεί. Χαρακτηριστικό παράδειγμα της ιδιότητας αυτής, αποτελούν τα δίκτυα MLP, που ενσωματώνουν την σιγμοειδή συνάρτηση. Τα δίκτυα αυτά, έχουν την ικανότητα να προσεγγίζουν οποιαδήποτε συνεχή συνάρτηση όσο κοντά επιθυμούμε, με μόλις δύο επίπεδα και γι αυτό ονομάζονται καθολικοί προσεγγιστές (*universal approximators*). Πιο συγκεκριμένα, η δομή των καθολικών προσεγγιστών, είναι η εξής: Το νευρωνικό δίκτυο αυτό, αποτελείται από δύο επίπεδα και λαμβάνει n πρότυπα. Το πρώτο επίπεδο είναι κρυφό και δομείται από p μη-γραμμικούς νευρώνες, οι οποίοι χρησιμοποιούν την σιγμοειδή συνάρτηση ενεργοποίησης f . Έτσι, η έξοδος ενός i -οστού νευρώνα του πρώτου επιπέδου, προκύπτει από τον τύπο:

$$y_i = f\left(\sum_{j=1}^n w_{ij} \cdot x_j + \theta_i\right) \quad (1.6.2)$$

▪ Το χαρακτηριστικό αυτό, αυτού του τύπου δικτύου, πηγάζει από το γεγονός ότι οι περισσότεροι κανόνες εκπαίδευσης, στηρίζονται σε μεθόδους βελτιστοποίησης που χρησιμοποιούν παραγώγους. Για τον λόγο αυτό, συναρτήσεις όπως η Βηματική, (έχει δυαδικές τιμές, δεν είναι παραγωγίσιμη και δεν είναι συνεχής, σε όλο το πεδίο ορισμού της), δεν επαρκούν γι αυτού του τύπου τα δίκτυα. Επιπλέον, μέσω της μηγραμμικότητας η σχέση εισόδου-εξόδου ενός πολυεπίπεδου δικτύου, θα υποβιβάζοταν σε αυτή του απλού *Perceptron* ενός επιπέδου.

- Σ'ένα δίκτυο MLP, υπάρχουν ένα ή και περισσότερα επίπεδα, κρυφά για τους κόμβους των επιπέδων εισόδων και εξόδων, τα λεγόμενα κρυφά επίπεδα. Οι νευρώνες των κρυφών επιπέδων, ονομάζονται κρυφοί νευρώνες και προσφέρουν στο δίκτυο την δυνατότητα να μάθει πολύπλοκες εργασίες, εξαγοντας τα πιο σημαντικά χαρακτηριστικά, από τα διανύσματα εισόδου.

- Ένα αξιοσημείο προσόν των δικτύων MLP, καθίσταται ο υψηλός βαθμός διασύνδεσης που επιδεικνύει, ανάλογα και με τα βάρη του δικτύου.

- Τα πολυεπίπεδα δίκτυα Perceptron, διαθέτουν δύο είδη σημάτων: Τα λειτουργικά σήματα (*function signals*) και σήματα σφάλματος (*error signals*). Το πρώτο είδος σημάτων, είναι σήματα εισόδου, τα οποία καταφτάνουν στην είσοδο του δικτύου. Στην συνέχεια, μεταφέρονται διαμέσου του δικτύου, με την γνωστή κατεύθυνση (αριστερά προς τα δεξιά) και εμφανίζονται τελικώς στο επίπεδο εξόδου ως έξοδοι, όπου και εκτελούν μία χρήσιμη λειτουργία στην έξοδο του δικτύου. Σε κάθε νευρώνα οποιουδήποτε επιπέδου του δικτύου, τα σήματα αυτά υπολογίζονται συναρτήσεως των εισόδων του νευρώνα και των αντίστοιχων συνοπτικών βαρών. Το δεύτερο είδος, είναι τα σήματα σφάλματος, τα οποία δημιουργούνται σε έναν νευρώνα εξόδου του δικτύου MLP και μεταφέρονται προς τα πίσω, δια μέσου του δικτύου, από επίπεδο σε επίπεδο. Ο ρόλος όλων των κρυφών νευρώνων και των νευρώνων εξόδου ενός πολυεπίπεδου μοντέλου Perceptron, καθίσταται ο υπολογισμός του λειτουργικού σήματος που παρουσιάζεται στην έξοδό τους. Επιπρόσθετα, οι νευρώνες αυτοί, βρίσκουν μία εκτίμηση του διανύσματος κλίσης που απαιτείται για την πίσω διάδοση, μέσω του δικτύου. Ένα ιδιαίτερα σημαντικό πλεονέκτημα των πολυεπίπεδων δικτύων Perceptron, είναι η ικανότητά τους να χρησιμοποιούν πιο περίπλοκες συναρτήσεις, όπου το μοντέλο του απλού αισθητήρα δεν μπορεί. Χαρακτηριστικό παράδειγμα της ιδιότητας αυτής, αποτελούν τα δίκτυα MLP, που ενσωματώνουν την σιγμοειδή συνάρτηση. Τα δίκτυα

αυτά, έχουν την ικανότητα να προσεγγίζουν οποιαδήποτε συνεχή συνάρτηση όσο κοντά επιθυμούμε, με μόλις δύο επίπεδα και γι αυτό ονομάζονται καθολικοί προσεγγιστές (*universal approximators*).

Κεφάλαιο 2

2.1 Στοιχεία της θεωρίας μάθησης-Κανόνες μάθησης.

« Η Μάθηση είναι μια διαδικασία με την οποία προσαρμόζονται οι ελεύθεροι παράμετροι (δηλαδή τα βάρη και οι πολώσεις/τα κατώφλια) ενός Νευρωνικού Δικτύου μέσω μίας διαδικασίας συνεχούς διέγερσης από το περιβάλλον στο οποίο βρίσκεται το δίκτυο. Το είδος της μάθησης καθορίζεται από τον τρόπο με τον οποίο πραγματοποιούνται οι αλλαγές των παραμέτρων».

Ο ορισμός της διαδικασίας μάθησης υπονοεί την ακόλουθη σειρά βημάτων για το Νευρωνικό Δίκτυο:

1. «διεγείρεται» από το περιβάλλον.
2. υφίσταται αλλαγές ως συνέπεια αυτής της διέγερσης.
- 3.«απαντά» με έναν καινούργιο τρόπο στο περιβάλλον.


Η δυνατότητα των Νευρωνικών Δικτύων να «εργάζονται» και με παραδείγματα που δεν έχουν χρησιμοποιηθεί κατά τη φάση της εκπαίδευσης τους, δηλαδή να «γενικεύουν» τη γνώση που έχουν αποκτήσει. Χωρίς αυτήν την ικανότητα τα Νευρωνικά Δίκτυα θα μπορούσαν, απλώς, να επεξεργάζονται πληροφορία που είχαν μάθει και τίποτα παραπάνω και κατά συνέπεια η χρησιμότητά τους θα ήταν περιορισμένη.

Το κύριο χαρακτηριστικό γενικότερα των νευρωνικών δικτύων, είναι η εγγενής ικανότητα μάθησης. Ως μάθηση μπορεί να οριστεί η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα. Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, η οποία μπορεί να θεωρηθεί μία επαναληπτική διαδικασία σταδιακής

προσαρμογής των παραμέτρων του δικτύου, συνήθως των βαρών και της πόλωσής του, σε τιμές κατάλληλες ώστε να επιλύεται με επαρκή επιτυχία το προς εξέταση πρόβλημα. Αφού ένα δίκτυο εκπαιδευτεί, οι παράμετροί του συνήθως σταθεροποιούνται στις κατάλληλες τιμές και από εκεί κι έπειτα βρίσκεται στην βέλτιστη κατάσταση για να επιλύσει το εν λόγω πρόβλημα. Το ζητούμενο είναι το δίκτυο να χαρακτηρίζεται από μία ικανότητα γενίκευσης, να μπορεί δηλαδή να δίνει ορθές εξόδους για εισόδους καινοφανείς και διαφορετικές από αυτές με τις οποίες εκπαιδεύτηκε. Η δυναμική που παρουσιάζει ένα Νευρωνικό Δίκτυο Αιχμών ορίζεται από την συνδετικότητα του και από την δύναμη των συναπτικών του συνδέσεων. Η μάθηση σε ένα τέτοιο δίκτυο συνεπάγεται την προσαρμογή των συνάψεων του μέσω επαναλαμβανόμενων βελτιστοποιήσεων. Η επιλογή του κατάλληλου αλγορίθμου μάθησης για ένα πρόβλημα εξαρτάται από τρία θεμελιώδη χαρακτηριστικά του χρησιμοποιούμενου μοντέλου. Πρώτον, ορισμένοι αλγόριθμοι μπορούν να εφαρμοστούν μόνο σε συγκεκριμένες τοπολογίες δικτύων και νευρωνικά μοντέλα. Έτσι, το μοντέλο που θα επιλεγεί θα περιορίσει σημαντικά την επιλογή του αλγορίθμου μάθησης. Κατα δεύτερον, ένα επιπλέον ζήτημα που εγείρεται είναι το αν η εκπαίδευση ή η μάθηση ενός συστήματος θα πρέπει να υλοποιηθεί πάνω στο υλικό ή να γίνει η μεταφορά του ήδη εκπαιδευμένου δικτύου στο νευρομορφικό υλικό. Μία τρίτη απόφαση που πρέπει να παρθεί, είναι το αν το δίκτυο πρόκειται να εκπαιδευτεί με ή χωρίς επίβλεψη. Μια ποικιλία από σοβαρά προβλήματα επηρεάζουν σημαντικά τις διαδικασίες μάθησης στα ΝΔΑ, καθώς οι ρητές απαιτήσεις εξάρτησης των αποτελεσμάτων σε σχέση με μια προκαθορισμένη είσοδο, η διάταξη του λειτουργίας με βάση ακριβείς χωροχρονικές παραμέτρους, η ασύγχρονη επεξεργασία των πληροφοριών που απαιτεί συνήθως εξειδικευμένο λογισμικό ή και υλικό, καθώς και οι πρόσθετες δυσκολίες που εισάγουν οι πολύπλοκες αρχιτεκτονικές και τοπολογίες που χρησιμοποιούνται από τα δίκτυα αυτά, δεν επιτρέπουν συνήθως την

εφαρμογή μιας απλής μεθόδου μάθησης, όπως η οπισθοδιάδοση. Οι σημαντικότερες τεχνικές μάθησης που έχουν προταθεί και έχουν κατά καιρούς δοκιμαστεί σε εφαρμογές ΤΝΔΑ, παρουσιάζονται στη συνέχεια.

Βιολογικές παρατηρήσεις έχουν προσφέρει αποδείξεις ότι η μεταβολή της συναπτικής απόδοσης σχετίζεται άμεσα με τον χρονισμό των προσυναπτικών και μετασυναπτικών αιχμών στους νευρώνες. Αυτή η λειτουργική αλληλεπίδραση μεταξύ της χρονικά συνδυασμένης ενεργοποίησης διαφορετικών συναπτικών οδών στον νευρώνα συνιστά ουσιαστικά ένα είδος συνειρμού στο μοριακοκυτταρικό επίπεδο. Ο συνειρμός αυτός υφίσταται από το γεγονός ότι σε όλες αυτές τις περιπτώσεις συμβαίνει σύγχρονη, χρονικά συνδυασμένη, προσυναπτική και μετασυναπτική ενεργοποίηση. Ο ρόλος αυτής της συνειρμικής διεργασίας εκφράζεται πολύ χαρακτηριστικά μέσω της πειραματικής συνθήκης, κατά την οποία ενεργοποιούνται σύγχρονα ο προσυναπτικός και μετασυναπτικός νευρώνας. Η συναπτική πλαστικότητα που επάγεται μέσω αυτής της συνθήκης καλείται πλαστικότητα εξαρτώμενη από τον χρονισμό των αιχμών (*SpikeTiming Dependent Plasticity - STDP*), με τον βασικό της μηχανισμό να οπτικοποιείται στο Σχήμα 2.1



Σχήμα 2.1 Οι μικροί κύκλοι καταγράφουν την μεταβολή του συναπτικού βάρους σε πραγματικές βιολογικές παρατηρήσεις 60 ζευγών νευρώνων του ιππόκαμπου. Όπως βλέπουμε στην γραφική παράσταση, οι καμπύλες που αναπαριστούν την εκθετική μείωση του βάρους σε συνάρτηση με τον σχετικό χρονισμό των προσυναπτικών και μετασυναπτικών αιχμών, ταιριάζουν αρκετά καλά στα πραγματικά βιολογικά δεδομένα. Ο Αλγόριθμος Μάθησης Ενός Περάσματος ((One-pass learning) αποτελεί μια εξαιρετικά εύκολη και απλοποιημένη διαδικασία κατηγοριοποίησης, η οποία ολοκληρώνεται σε πολύ γρήγορο χρονικό διάστημα καθώς δεν απαιτεί ιδιαίτερους υπολογιστικούς πόρους και ενδείκνυται για γραμμικά προβλήματα ή ανάλυση δεδομένων που μπορεί να προέρχονται από μια κατανομή. Σε γενικές γραμμές η λειτουργία του αλγορίθμου περιγράφεται ως εξής:

- Πραγματοποιείται μια σειριακή εισαγωγή των δεδομένων-αντικειμένων στο σύστημα.
- Το πρώτο αντικείμενο γίνεται ο εκπρόσωπος της πρώτης κατηγορίας.
- Κάθε επόμενο αντικείμενο συγκρίνεται με όλους τους εκπροσώπους των υφιστάμενων κατηγοριών κατά το χρόνο επεξεργασίας του και κατατάσσεται σε κάποια κατηγορία με βάση κάποια κριτήρια.

- Όταν ένα αντικείμενο έχει εκχωρηθεί σε μια κατηγορία ο εκπρόσωπος για την εν λόγω κατηγορία επανυπολογίζεται.
- Αν ένα νέο αντικείμενο αποτύχει να καταταχθεί σε μια από τις ήδη υπάρχουσες κατηγορίες, γίνεται εκπρόσωπος μιας νέας κατηγορίας.

2.2 Αλγόριθμοί μάθησης.

Ο αριθμός των διαθέσιμων αλγορίθμων μηχανικής εκμάθησης είναι τόσο μεγάλος που δεν κάνει πολύ λογικό να παρουσιάζονται συγκεκριμένοι αλγόριθμοι. Αντίθετα, μια επισκόπηση του αλγορίθμου όπου η κατηγοριοποίηση βασίζεται στον τρόπο με τον αλγόριθμο αντιμετωπίζει το πρόβλημα και αναπαριστά δεδομένα. Πρέπει να σημειωθεί ότι ένας αλγόριθμος μπορεί να ανήκει σε περισσότερες από μία κατηγορίες και ότι δεν θα περιλαμβάνονται όλες οι προσδιοριζόμενες κατηγορίες σε αυτό.

Αλγόριθμοι που βασίζονται σε στατιστικά στοιχεία/

Αλγόριθμοι παλινδρόμησης: αλγόριθμοι αυτής της κατηγορίας επιδιώκουν να μοντελοποιήσουν τη σχέση μεταξύ εισροών και εκροών χρησιμοποιώντας στατιστικά εργαλεία όπως π.χ παλινδρόμηση (γραμμική/ βαθμιαία/ λογιστική).

Αλγόριθμοι Δέντρου Αποφάσεων: αυτός ο τύπος αλγορίθμων κατασκευάζει ένα μοντέλο απόφασης που προβλέπει την τιμή της μεταβλητής εξόδου με βάση τις πραγματικές τιμές/χαρακτηριστικά στις πολλαπλές εισόδους. Τα δεδομένα εισόδου οργανώνονται στους κλάδους του δέντρου και στην έξοδο. Οι τιμές αντιπροσωπεύονται από τα φύλλα. Η ταχύτητα και η ακρίβεια παρατηρούνται συχνά σε αυτό με κατηγορία μεθόδων, καθιστώντας τις έτσι μια δημοφιλή επιλογή.

Μπεϋζιανοί αλγόριθμοι: οι αλγόριθμοι αυτής της κατηγορίας εφαρμόζουν το θεώρημα του Bayes για να συμπεράνουν ότι οι πιθανότητες των τιμών αποτελούν την έξοδο. Τα δεδομένα χαρτογραφούνται συνήθως χρησιμοποιώντας ένα άμεσο ακυκλικό γράφημα.

Αλγόριθμοι μηχανικής μάθησης για μεγάλα δεδομένα στην οποία η παρουσία μιας ακμής που συνδέει δύο κόμβους αντιπροσωπεύει μια υπό όρους εξάρτησης.

Αλγόριθμοι ομαδοποίησης: αλγόριθμοι μηχανικής μάθησης που βασίζονται σε ομαδοποίηση, όπως η κατηγορία προβλημάτων με το ίδιο όνομα, στοχεύουν στην ομαδοποίηση των δεδομένων σε σύνολα με τα μέγιστα κοινά χαρακτηριστικά.

Αλγόριθμοι μάθησης βασισμένοι σε κανόνες: αντί να προσδιορίσετε ένα μοντέλο που θα κάνει μια ακριβή πρόβλεψη της εξόδου για μια δεδομένη είσοδο, οι αλγόριθμοι αυτής της κατηγορίας στοχεύουν σε μια ακριβή πρόβλεψη της εξόδου για μια δεδομένη είσοδο κατασκευάζοντας ένα σύνολο κανόνων που περιγράφουν ολόκληρη τη γνώση του συστήματος.

Η υποομάδα αυτής της κατηγορίας είναι αλγόριθμοι εκμάθησης κανόνων συσχέτισης.

Τεχνητά νευρωνικά δίκτυα: τα τεχνητά νευρωνικά δίκτυα είναι εμπνευσμένες από δομές δεδομένων από νευρώνες που βρίσκονται σε εγκεφάλους ανθρώπων και ζώων και αλγόριθμους που χρησιμοποιούν τέτοιες δομές και προσπαθούν να λύσουν προβλήματα όπως θα έκανε ένας ανθρώπινος εγκέφαλος. Σε ένα τεχνητό νευρωνικό δίκτυο οι συνδέσεις μεταξύ των νευρώνων λειτουργούν όπως οι συνάψεις του εγκεφάλου, δηλαδή λαμβάνουν και μεταδίδουν σήματα από/προς άλλους συνδεδεμένους νευρώνες. Η χρήση τέτοιων εργαλείων, είναι πολύπλοκη.

Οι σχέσεις μεταξύ των εισόδων και των εξόδων μπορούν να μοντελοποιηθούν, τα μοτίβα στα δεδομένα μπορούν να μοντελοποιηθούν ήδη ανακαλύφθηκαν και μπορούν να γίνουν άγνωστες κοινές κατανομές πιθανοτήτων μεταξύ των εισόδων που έχουν παρατηρηθεί.

Βαθιά μάθηση: οι μέθοδοι και οι αλγόριθμοι βαθιάς μάθησης αποτελούν εξέλιξη στα τεχνητά νευρωνικά δίκτυα, γίνονται εφικτά λόγω του μεγέθους των διαθέσιμων δεδομένων και της μειωμένης τιμής της επεξεργαστικής ισχύος. Σε τέτοιες μεθόδους, ο

αλγόριθμος εστιάζει στα δεδομένα εκμάθησης αναπαραστάσεις παρά ένα συγκεκριμένο έργο. Τα πιο πολύπλοκα νευρωνικά δίκτυα είναι κατασκευασμένα, με κάθε επίπεδο να προσφέρει ένα ελαφρώς πιο αφηρημένο και σύνθετο μοτίβο αναπαράστασης των δεδομένων.

Οι τεχνικές και οι αλγόριθμοι βαθιάς μάθησης αποτελούν ουσιαστικά έναν ξεχωριστό κλάδο και αποτελούν μέρους του θέματος της παρούσας πτυχιακής εργασίας. Αλγόριθμοι μηχανικής μάθησης για μεγάλα δεδομένα. Το κύριο χαρακτηριστικό που διακρίνει τις μεθόδους βαθιάς μάθησης από τις παραδοσιακές μεθόδους είναι οι μέθοδοι μηχανικής μάθησης είναι η εστίαση στις αναπαραστάσεις δεδομένων που είναι τώρα μαθησιακός στόχος παρά συγκεκριμένες εργασίες. Χρησιμοποιώντας πολλαπλά επίπεδα μη γραμμικής περίληψης

η επεξεργασία πληροφοριών, οι αλγόριθμοι βαθιάς μάθησης διευκολύνουν την εκμάθηση χαρακτηριστικών, με αναπαράσταση, ταξινόμηση και αναγνώριση προτύπων. Κάθε επεξεργασία ρυθμίζει το στρώμα εξαγωγής και χρησιμοποιεί την έξοδο από το προηγούμενο στρώμα ως είσοδο.

2.3 Μηχανική Μάθηση.

Η Μάθηση (Learning) είναι μία από τις θεμελιώδεις ιδιότητες της νοήμονος συμπεριφοράς του ανθρώπου. Παρά τις μελέτες και τις έρευνες επί χρόνια από τους επιστήμονες του πεδίου της Γνωστικής Ψυχολογίας και τους φιλοσόφους, η έννοια της μάθησης δεν έχει γίνει πλήρως κατανοητή. Πώς, λοιπόν, θα μπορούσαν οι επιστήμονες του χώρου της ΤΝ να δημιουργήσουν υπολογιστικά συστήματα ικανά να μάθουν, να επιτύχουν, δηλαδή, τη λεγόμενη Μηχανική Μάθηση (Machine Learning). Αυτή μπορεί να οριστεί ως: το φαινόμενο κατά το οποίο ένα σύστημα βελτιώνει την απόδοσή του κατά την εκτέλεση μιας συγκεκριμένης εργασίας, χωρίς να υπάρχει ανάγκη να

προγραμματίζεται εκ νέου. Βάσει του ορισμού αυτού, η Μηχανική Μάθηση έχει ως σκοπό τη δημιουργία μηχανών ικανών να μαθαίνουν, να βελτιώνουν, δηλαδή, την απόδοσή τους σε κάποιους τομείς μέσω της αξιοποίησης προηγούμενης γνώσης και εμπειρίας. Ένας σχετικός γενικός ορισμός Μηχανικής Μάθησης δίνεται από τον Mitchell (1997): «Ένα πρόγραμμα υπολογιστή λέμε ότι μαθαίνει από την εμπειρία E ως προς κάποια κλάση εργασιών T και μέτρο απόδοσης P , αν η απόδοσή του σε εργασίες από το T , όπως μετριέται από το P , βελτιώνεται μέσω της εμπειρίας E .» Στην Επαγωγική Μάθηση (Inductive Learning), με τη διαδικασία της επαγωγής (induction) ο άνθρωπος μαθαίνει κατανοώντας το περιβάλλον του μέσω παρατηρήσεων και δημιουργεί μια απλοποιημένη (αφαιρετική) εκδοχή του που ονομάζεται νοητικό μοντέλο (mental model). Επιπλέον, ο άνθρωπος έχει τη δυνατότητα να οργανώνει και να συσχετίζει τις εμπειρίες και τις παρατηρήσεις του δημιουργώντας νέες δομές που ονομάζονται νοητικά πρότυπα (mental patterns), με αξιοποίηση και του επαγωγικού και του απαγωγικού συλλογισμού. Στη δημιουργία νέων προτύπων από παλαιά βασίζονται οι τρόποι μάθησης που εξαρτώνται σε μεγαλύτερο ή μικρότερο βαθμό από την προϋπάρχουσα γνώση για ένα πρόβλημα, όπως είναι η μάθηση από επεξηγήσεις και η μάθηση από περιπτώσεις. Σε σχέση με την ανθρώπινη ικανότητα προς μάθηση, οι φιλόσοφοι θέτουν το ερώτημα: «Πώς μπορεί ένας επαγωγικός συλλογισμός που οδηγεί στη μάθηση να αξιολογηθεί ως προς την ορθότητά του;». Αντίστοιχα, οι ψυχολόγοι ρωτούν: «Πώς αποθηκεύει ο εγκέφαλος τα αποτελέσματα της διαδικασίας της μάθησης, δηλαδή τα νοητικά μοντέλα και τα πρότυπα;». Στο χώρο της ΤΝ απλώς ρωτούν: «Πώς μπορεί μία μηχανή να δημιουργήσει νέα μοντέλα και πρότυπα μάθησης από συγκεκριμένα παραδείγματα και πόσο αξιόπιστα είναι αυτά τα μοντέλα και πρότυπα στην πράξη;». Με βάση τα παραπάνω, μπορεί να δοθεί ο ακόλουθος εναλλακτικός ορισμός για τη Μηχανική Μάθηση: Μηχανική Μάθηση ονομάζεται η ικανότητα ενός

υπολογιστικού συστήματος να δημιουργεί μοντέλα ή πρότυπα από ένα σύνολο δεδομένων. Ως κλάδος της TN, η Μηχανική Μάθηση ασχολείται με τη μελέτη αλγορίθμων που βελτιώνουν τη συμπεριφορά τους σε κάποια εργασία που τους έχει ανατεθεί χρησιμοποιώντας την εμπειρία τους. Όσον αφορά τη σχεδίαση των συστημάτων Μηχανικής Μάθησης, για τα συστήματα που ανήκουν στη συμβολική TN, η δυνατότητα μάθησης προσδιορίζεται ως η ικανότητα πρόσκτησης επιπλέον γνώσης, που επιφέρει μεταβολές στην υπάρχουσα καταχωρημένη γνώση είτε αλλάζοντας χαρακτηριστικά της είτε με αυξομείωσή της. Στην περίπτωση των συστημάτων TN που ανήκουν στη Μη Συμβολική TN (όπως η περίπτωση των Τεχνητών Νευρωνικών Δικτύων), ως μάθηση προσδιορίζεται η δυνατότητα που διαθέτουν τα συστήματα στο να μετασχηματίζουν την εσωτερική τους δομή, παρά στο να μεταβάλλουν κατάλληλα τη γνώση που έχει καταχωρηθεί μέσα σε αυτά κατά το σχεδιασμό τους. Αν και απέχουμε πάρα πολύ από τη δημιουργία μηχανών που μαθαίνουν τόσο καλά όσο ο άνθρωπος, για συγκεκριμένες περιοχές μάθησης έχουν αναπτυχθεί αλγόριθμοι οι οποίοι έχουν επιτρέψει την εμφάνιση σύγχρονων εμπορικών εφαρμογών με σημαντική επιτυχία. Επιπλέον, τα αποτελέσματα από τις εφαρμογές της TN αρχίζουν ήδη να είναι ορατά και να δίνουν απαντήσεις σε αναπάντητα, έως τώρα, ερωτήματα των άλλων κλάδων που διερευνούν την ικανότητα του ανθρώπου να μαθαίνει. Ο τομέας της Μηχανικής Μάθησης αναπτύσσει, επίσης, επιτυχώς την Εξελικτική Μάθηση (Evolutionary Learning), η οποία μιμείται διαδικασίες φυσικής αναπαραγωγικής σε έμβια όντα. Χρησιμοποιείται κυρίως σε προβλήματα βελτιστοποίησης. Στην Εξελικτική Μάθηση κυριαρχούν οι γενετικοί αλγόριθμοι που θα παρουσιαστούν στο τέλος του κεφαλαίου. Εκτός της ίδιας της TN, μεταξύ των επιστημονικών κλάδων που επωφελούνται από τα επιτεύγματα στον τομέα της Μηχανικής Μάθησης συγκαταλέγονται οι: Εξόρυξη Δεδομένων, Πιθανότητες και Στατιστική, Θεωρία της Πληροφορίας, Αριθμητική

Βελτιστοποίηση, Θεωρία της Πολυπλοκότητας, Θεωρία Ελέγχου (προσαρμοστική), Ψυχολογία (εξελικτική, γνωστική), Νευροβιολογία και Γλωσσολογία.

Εν γένει, ο τομέας της Μηχανικής Μάθησης αναπτύσσει τρεις τρόπους μάθησης, ανάλογους με τους τρόπους με τους οποίους μαθαίνει ο άνθρωπος: επιβλεπόμενη μάθηση, μη επιβλεπόμενη μάθηση και ενισχυτική μάθηση. Πιο αναλυτικά: □

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


(*Classification*) ο Πρόγνωσης (*Prediction*) ο Διερμηνείας (*Interpretation*) □ Μη

Επιβλεπόμενη Μάθηση (*Unsupervised Learning*), όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων υπό μορφή παρατηρήσεων χωρίς να γνωρίζει τις επιθυμητές εξόδους. Χρησιμοποιείται σε προβλήματα: ο Ανάλυσης Συσχετισμών (*Association Analysis*) ο Ομαδοποίησης (*Clustering*) □ Ενισχυτική Μάθηση

(*Reinforcement Learning*), όπου ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών μέσα από άμεση αλληλεπίδραση με το περιβάλλον. Χρησιμοποιείται κυρίως σε προβλήματα Σχεδιασμού (*Planning*), όπως για παράδειγμα ο έλεγχος κίνησης ρομπότ και η βελτιστοποίηση εργασιών σε εργοστασιακούς χώρους. Για κάθε πρόβλημα προς επίλυση στο χώρο της Μηχανικής Μάθησης υπάρχει ένας κατάλληλος τρόπος μάθησης και για κάθε τρόπο μάθησης υπάρχει τουλάχιστον ένας κατάλληλος αλγόριθμος που μπορεί να χρησιμοποιηθεί. Όλοι οι αλγόριθμοι Μηχανικής Μάθησης διαχειρίζονται τη γνώση αναπαριστώντας την με κάποιον από τους τρόπους που έχουμε ήδη παρουσιάσει στο κεφάλαιο 2 για την αναπαράσταση της γνώσης ή με άλλους πιο μαθηματικοποιημένους τρόπους που θεωρούνται από τον συγκεκριμένο αλγόριθμο καταλληλότεροι να την εκφράσουν. Ορισμένοι αλγόριθμοι δέχονται ως είσοδο μόνο παρατηρήσεις και άλλοι

λαμβάνουν υπόψη τους λίγο ή περισσότερο την προϋπάρχουσα γνώση. Μια προσπάθεια κατάταξης των αλγορίθμων με κριτήριο τον τρόπο μάθησης βασισμένο περισσότερο ή λιγότερο στην υπάρχουσα γνώση δίνεται παρακάτω: Πλούσιοι σε χρήση γνώσης Μάθηση Βασισμένη σε Επεξηγήσεις (*Explanation-based Learning*) Μάθηση Βασισμένη σε Περιπτώσεις (*Case-based Learning*) Μάθηση από Επαγωγές μέσω στιγμιότυπων και παραδειγμάτων (*Inductive Learning*) Φτωχοί σε χρήση γνώσης Νευρωνικά Δίκτυα (*Neural Networks*).

Στο σχήμα 2.3 , αποτυπώνεται ο γενικός τρόπος λειτουργίας των αλγορίθμων Μηχανικής Μάθησης. Η βασικότερη φάση κάθε αλγόριθμου είναι η εκπαίδευση, όπου ο αλγόριθμος χρησιμοποιεί ως είσοδο ένα σύνολο δεδομένων εκπαίδευσης (*training set*) προς επίτευξη του σκοπού του, τη δημιουργία νέας γνώσης. Επιπλέον, μπορεί είτε να χρησιμοποιήσει λιγότερο ή περισσότερο την υπάρχουσα γνώση είτε να μην τη χρησιμοποιήσει καθόλου.



Σχήμα 2.3 Γενικός τρόπος λειτουργίας των αλγορίθμων Μηχανικής Μάθησης.

Την εκπαίδευση ακολουθεί η φάση της πιστοποίησης της παραγόμενης νέας γνώσης. Συνήθως, η πιστοποίηση πραγματοποιείται καταρχάς από τον ίδιο τον αλγόριθμο μέσω διαδικασιών ανάκλησης (*recall*) με τη βοήθεια δεδομένων ελέγχου (*test data*) και, στη συνέχεια, μέσω κριτικής που κάνει ο χρήστης βάσει των γνώσεων που διαθέτει για το πρόβλημα που επιχειρεί να λύσει ο αλγόριθμος. Τέλος, η νέα γνώση δίνεται προς χρήση σε εφαρμογές στις οποίες είναι απαραίτητη, για να λυθούν πραγματικά προβλήματα. Ένας από τους συνηθέστερους τρόπους Μηχανικής Μάθησης είναι μέσω επαγωγών οι οποίες παρέχουν δια του προτασιακού λογισμού ένα μηχανισμό εξαγωγής (όχι απαραίτητα σωστών) λογικών συμπερασμάτων από παραδείγματα. Οι αλγόριθμοι Επαγωγικής Μάθησης (*Inductive Learning algorithms*) είναι ένα είδος αλγορίθμων που αναπτύχθηκε στο πλαίσιο της ΤΝ και ιδιαίτερα στο χώρο της Μηχανικής Μάθησης. Σκοπός των αλγορίθμων αυτών είναι η κατάληξη σε αποφάσεις σχετικές με τις σχέσεις που κυριαρχούν μέσα σε ένα σύνολο παραδειγμάτων που έχουν συγκεντρωθεί από παρατηρήσεις. Οι αλγόριθμοι επιβλεπόμενης Επαγωγικής Μάθησης εφαρμόζονται κυρίως σε προβλήματα ταξινόμησης (*classification problems*) και σε προβλήματα παρεμβολής (*regression problems*). Δημιουργούνται μοντέλα πρόβλεψης διακριτών τάξεων κατά την κατηγοριοποίηση και αριθμητικών τιμών κατά την παρεμβολή. Για προβλήματα πρόβλεψης, χρησιμοποιείται κυρίως μια παραλλαγή τους, οι αλγόριθμοι ημι-επιβλεπόμενης Μηχανικής Μάθησης, οι οποίοι λειτουργούν με σύνολο εκπαίδευσης μέσα στο οποίο υπάρχουν παραδείγματα μη γνωστές εξόδους. Στην επιβλεπόμενη Επαγωγική Μάθηση (*supervised Inductive Learning*) το σύστημα πρέπει να “μάθει”, δηλαδή να κατασκευάσει ένα νέο μοντέλο υπό μορφή μιας συνάρτησης πρόγνωσης (*predictor function*), η οποία θα απεικονίζει δεδομένες εισόδους σε γνωστές, επιθυμητές εξόδους, με απώτερο στόχο τη γενίκευση της συνάρτησης αυτής και για εισόδους με άγνωστη έξοδο. Για τη συνάρτηση πρόγνωσης ισχύουν τα ακόλουθα: □

Κάθε είσοδος, δεδομένη ή μη, που μπορεί να δεχθεί η συνάρτηση χαρακτηρίζεται ως στιγμιότυπο (*instance*), δημιουργώντας έτσι ένα σύνολο στιγμιότυπων. Οι είσοδοι περιγράφονται με βάση τα γνωρίσματα (*attributes*) που διαθέτουν και έχουν χαρακτηριστεί ως σημαντικά από την αρχή της μελέτης του προβλήματος που καλείται να επιλύσει το σύστημα. Οι δεδομένες είσοδοι συγκεντρώνονται από παρατηρήσεις και αποτελούν το λεγόμενο σύνολο εκπαίδευσης (*training set*) που αποτελεί υποσύνολο του συνόλου στιγμιότυπων. Το υπόλοιπο μέρος του συνόλου στιγμιότυπων αποτελεί το σύνολο ελέγχου (*test set*) που θα χρησιμοποιηθεί κατά τη φάση πιστοποίησης. Η συνάρτηση που απεικονίζει μια είσοδο από το σύνολο εκπαίδευσης στη γνωστή της έξοδο καλείται συνάρτηση στόχου (*goal function*). □ Η τιμή που επιστρέφει η συνάρτηση στόχου για ένα στιγμιότυπο από το σύνολο στιγμιότυπων, δίνεται σε μια μεταβλητή που καλείται μεταβλητή στόχου (*goal variable*). □ Στην επιβλεπόμενη μάθηση, η συμπεριφορά της συνάρτησης στόχου βελτιώνεται μέσω διαδικασιών εκπαίδευσης με τη βοήθεια της συνάρτησης λάθους (*error function*) που εντοπίζει τη διαφορά της μεταβλητής στόχου από την επιθυμητή έξοδο. Εναλλακτική ορολογία που χρησιμοποιείται στο κεφάλαιο αυτό: Στιγμιότυπα (*instances*) ο Επίσης αναφέρονται ως παραδείγματα ή δείγματα (*examples*) Γνωρίσματα (*attributes*) ο Επίσης γνωστά ως χαρακτηριστικά (*features*), προσόντα (*qualifications*), μεταβλητές (*variables*), ανεξάρτητες μεταβλητές (*independent variables*), μεταβλητές εισόδου (*input variables*), συμεταβλητές (*covariates*) Μεταβλητή στόχου (*goal variable*) ο Επίσης γνωστή ως κατηγορήμα στόχου (*goal predicate*), εξαρτημένη μεταβλητή (*dependent variable*), τάξη κατηγοριοποίησης (*classification class*) Συνάρτηση λάθους (*error function*) ο Επίσης γνωστή ως αντικειμενική συνάρτηση (*objective function*), συνάρτηση απώλειας (*loss function*). Αν υποθέσουμε ότι: □ h η συνάρτηση πρόγνωσης που θέλουμε να “μάθουμε”, □ f η συνάρτηση στόχου, □ D το σύνολο εκπαίδευσης, □ x ένα στιγμιότυπο σε

μορφή ενός διανύσματος q των χαρακτηριστικών του. Τότε, καταρχάς, η έμμεση απεικόνιση του x προς το $f(x)$ μάς είναι άγνωστη. Διαθέσιμα είναι μόνο ζεύγη

$$D = \{(x, f(x))\} \quad (2.3.1)$$

εκπαίδευσης του τύπου

Αυτό που θέλουμε να μάθουμε είναι η συνάρτηση $h(x; q)$ που υλοποιεί μια γενικευμένη απεικόνιση από το x στο f . Αν $h(x; q)$ είναι “κοντά” στο $f(x)$ για όλα τα στιγμιότυπα x του συνόλου ελέγχου, συμπεραίνουμε ότι τα χαρακτηριστικά q είναι οι παράμετροι που πρέπει να λάβει υπόψη της η συνάρτηση πρόβλεψης $h(\cdot)$. Ένα παράδειγμα συνάρτησης πρόγνωσης δίνεται παρακάτω, όπου $q(x_1 \ x_2 \ x_3)$ το διάνυσμα των χαρακτηριστικών του

$$x: \quad h(x; q) = (x_1 \text{ or } x_2) \text{ and } (\text{not } x_3) \quad (2.3.2)$$

Μια εμπειρική συνάρτηση λάθους E θα μπορούσε να υπολογίζεται ως ακολούθως:

$$E(h) = \sum_x \text{distance}[h(x; q), f] \quad (2.3.3)$$

όπου distance είναι η συνάρτηση που υπολογίζει τη διαφορά της πρόγνωσης από την πραγματική τιμή που επιστρέφει η συνάρτηση στόχου f για ένα x από το σύνολο εκπαίδευσης. Η E επιστρέφει το άθροισμα όλων των διαφορών που αφορούν τα ζεύγη εκπαίδευσης μέσα στο D . Γνωστότεροι αλγόριθμοι Επιβλεπόμενης Επαγωγικής

Μάθησης είναι: ☐ Δένδρα Απόφασης (*Decision Trees*), ☐ Μάθηση βασισμένη σε Επεξηγήσεις (*Explanation-Based Learning*), ☐ Μάθηση βασισμένη σε Περιπτώσεις (*Case-Based Learning*), ☐ Μάθηση Νευρωνικών δικτύων (π.χ. για *Backpropagation Neural Networks*), ☐ Μάθηση Μέσω Στατιστικών Μεθόδων (π.χ. μάθηση κατά *Bayes*), ☐ Συλλογική Μάθηση από Ενδυνάμωση (*Boosting*) κ.ά.

2.4 Κβαντική Μηχανική Μάθηση

Υπάρχουν πολλοί τομείς στους οποίους η κβαντική μηχανική μάθηση αναμένεται (ή τουλάχιστον ευελπιστούμε) να δώσει τεράστια ώθηση, όπως πχ τα *logistics*, τα οικονομικά, η επιστήμη των Υλικών, η ιατρική και τέλος η ίδια η φυσική στο κομμάτι που ασχολείται με την κατανόηση του σύμπαντος. Τι εννοούμε όμως με τον όρο *Κβαντική μηχανική μάθηση*;

Είδη Κβαντικής Μηχανικής Μάθησης		Υπολογιστικό σύστημα	
		Κλασικός υπολογιστής	Κβαντικός υπολογιστής
Τύπος Δεδομένων	Κλασικά Δεδομένα	CC	CQ
	Κβαντικά δεδομένα	QC	QQ

Εδώ βλέπουμε ότι το πεδίο της κβαντικής μηχανικής μάθησης χωρίζεται γενικώς σε 4 υποπεδία, αναλόγως με το αν χρησιμοποιούμε κλασικά ή κβαντικά δεδομένα (δηλαδή αν τα δεδομένα είναι κλασική πληροφορία ή αποτελέσματα κβαντικού πειράματος) και το πως γίνεται η επεξεργασία των δεδομένων, αν χρησιμοποιείται κλασικός ή κβαντικός υπολογιστής. Στο πρώτο *block* έχουμε το κλασικό μοντέλο μηχανικής μάθησης. Έχουμε κλασικά δεδομένα (πχ εικόνες, ηχητική πληροφορία, κείμενο κλπ) και τα επεξεργαζόμαστε με κλασικό υπολογιστή. Μπορούμε όμως σε κλασικό υπολογιστή πάλι, να έχουμε κβαντικά δεδομένα, που όπως αναφέρθηκε είναι αποτελέσματα πειράματος κβαντικής φυσικής και προφανώς μπορούμε να έχουμε κβαντικά δεδομένα σε κβαντικό υπολογιστή, κάτι που διαισθητικά φαίνεται ως το πιο “σωστό” πρότυπο κβαντικής μηχανικής μάθησης.

Το μόνο μοντέλο κβαντικού υπολογιστή που έχουμε στη διάθεση μας αυτή την εποχή είναι ο κυκλωματικός κβαντικός υπολογιστής, επομένως όταν μιλάμε για κβαντικό προγραμματισμό εννοούμε κυκλώματα που εκτελούν κάποιους υπολογισμούς με συγκεκριμένη χρονική σειρά και κβαντική μάθηση είναι τα ίδια κυκλώματα αλλά έχοντας αυτή τη φορά κάποια παραμετροποίηση, οπότε στόχος είναι όπως και στην κλασική μάθηση να βρούμε το σύνολο των βέλτιστων παραμέτρων. Ακόμη, να αναφέρουμε πως είμαστε στην εποχή των NISQ συσκευών, που είναι ευάλωτοι σε σφάλματα, είναι σε ισχύ στα 50 qubits ή μέχρι μερικά εκατοντάδες qubits και τέλος δεν μπορούμε να εκμεταλλευτούμε πλήρως όλα τα θετικά της κβαντικής μηχανικής. Σε κάποιες περιπτώσεις μάλιστα, οι προσομοιωτές δίνουν καλύτερα αποτελέσματα από τον πραγματικό κβαντικό υπολογιστή. Στο μέλλον αναμένεται να έχουμε συσκευές faulttolerant, που θα μπορούν δηλαδή να συνεχίσουν να δουλεύουν ακόμα και όταν συμβαίνουν σφάλματα χωρίς να καταρρέει όλο το σύστημα. Τα κβαντικά μοντέλα χωρίζονται σε 2 μεγάλες κατηγορίες: τα αιτιοκρατικά (deterministic quantum models) και τα στοχαστικά (variational quantum models). Στο ντετερμινιστικό μοντέλο γνωρίζουμε από πριν το αποτέλεσμα με βεβαιότητα, ξέρουμε πχ ότι θα δράσουμε με μια πύλη X πάνω στο qubit $|q1\rangle$ και θα πάρουμε το αποτέλεσμα $|q2\rangle$. Τέτοιο παράδειγμα είναι ο αλγόριθμος Deutsch-Jozsa και ο αλγόριθμος του Deutsch που ήταν η έμπνευση για τον αλγόριθμο Deutsch-Jozsa (ο δεύτερος είναι η γενίκευση του πρώτου). Έστω συνάρτηση $f: \{0,1\} \rightarrow \{0,1\}$. Η συνάρτηση αυτή μπορεί να έχει τιμές μόνο το 0 και το 1 όπως είναι εμφανές. Αν οι 2 τιμές είναι ίσες, οι περιπτώσεις δηλαδή $f(0)=0=f(1)$ ή $f(0)=1=f(1)$, τότε λέμε πως η συνάρτηση είναι σταθερή, ενώ όταν $f(0)=1$ αλλά $f(1)=0$ ή $f(0)=0$ αλλά $f(1)=1$, τότε η συνάρτηση δεν είναι σταθερή. Ο αλγόριθμος του Deutsch μας δίνει τη δυνατότητα να βρίσκουμε πότε η συνάρτηση είναι σταθερή ή όχι, γνωρίζοντας μόνο τη μία από τις 2 τιμές! Ο αλγόριθμος των Deutsch και Jozsa

γενικεύει το αποτέλεσμα σε συνάρτηση $f: \{0,1\}^n \rightarrow \{0,1\}$ με περισσότερες εισόδους αλλά πάλι 2 τιμές. Η άλλη κατηγορία αλγορίθμων είναι οι στοχαστικοί (variational) αλγόριθμοι. Στα στοχαστικά κβαντικά μοντέλα, τα οποία κερδίζουν έδαφος στο χώρο της κβαντικής υπολογιστικής, της κβαντικής μηχανικής μάθησης και της κβαντικής χημείας τα τελευταία χρόνια, το αποτέλεσμα παύει να είναι προβλέψιμο εκ των προτέρων, αλλά θυμίζει περισσότερο κατανομή πιθανότητας κάποιων πιθανών λύσεων. Σε αντιστοιχία με προηγουμένως, θα λέγαμε πως αν έχουμε ένα qubit $|q1\rangle$ και δράσουμε με μια πύλη $P(\theta)$, όπου θ τυχαία παράμετρος από ένα σύνολο παραμέτρων $\Theta=(\theta_1, \dots, \theta_n)$ τότε το αποτέλεσμα δε θα είναι απλώς μια άλλη κβαντική κατάσταση $|q2\rangle$ αλλά ένα σύνολο από καταστάσεις $|q1\rangle, \dots, |qn\rangle$ όπου κάθε μια κατάσταση έχει πιθανότητα p_i να είναι αυτή η λύση. Τέτοιοι αλγόριθμοι είναι ο Variational Quantum Eigensolver (VQE) ο Variational Quantum Classifier, τα κβαντικά ανάλογα των μηχανών διανυσμάτων υποστήριξης (QSVM) και τα κβαντικά νευρωνικά δίκτυα (QNNs) Εδώ θα περιγράψουμε σύντομα το γενικό πρότυπο ενός αλγορίθμου κβαντικής μηχανικής μάθησης που ονομάζεται στοχαστικό μοντέλο. Ένα variational model είναι “απλώς” ένα κβαντικό κύκλωμα όπως αυτά που αναλύσαμε πιο πάνω, που περιέχει κάποιες παραμέτρους τις οποίες θέλουμε να βελτιστοποιήσουμε και άρα να εκπαιδεύσουμε το μοντέλο με βάση αυτές. Είναι το ανάλογο των βαρών (weights) στα κλασικά νευρωνικά δίκτυα. Και σχηματικά, έστω το παρακάτω κύκλωμα.



Σχήμα 2.4 : variational model


Έστω λοιπόν ότι έχουμε μερικά qubits και τα αρχικοποιούμε στην κατάσταση $|0\rangle$. Το πρώτο βήμα είναι να μετατρέψουμε τα κλασικά δεδομένα σε κβαντικές καταστάσεις σε έναν χώρο Hilbert και από εκεί να κάνουμε στην ουσία γραμμική άλγεβρα. Το πρώτο κομμάτι αυτό ονομάζεται κωδικοποίηση κλασικών δεδομένων σε κβαντικές καταστάσεις ή data encoding. Από εδώ και πέρα, τα ηνία τα αναλαμβάνει η κβαντική υπολογιστική. Έπειτα έχουμε το επόμενο βήμα που είναι να κάνουμε κάποιες πράξεις πάνω σε αυτά τα qubits για να αλλάξουμε την κατάσταση τους, με κάποιες κβαντικές πύλες ή γενικώς έναν ορθομοναδιαίο τελεστή. Οι πράξεις αυτές στην ουσία θα έχουν ως αποτέλεσμα το να περιστραφούν τα διανύσματα των κβαντικών καταστάσεων στο χώρο Hilbert, τα διανύσματα που είναι οι απεικονίσεις των δεδομένων μας. Οι κβαντικές πύλες που κάνουν αυτές τις πράξεις εξαρτώνται από κάποιες παραμέτρους θ από ένα σύνολο παραμέτρων $\Theta = (\theta_1, \dots, \theta_n)$. Οι περιστροφές (rotation) που θα γίνουν στο χώρο Hilbert είναι κατά γωνία θ_i . Επομένως μετά από πράξεις έχουμε φτάσει σε μια κατάσταση όπου τα δεδομένα έχουν μετασχηματιστεί από μια συνάρτηση f και εξαρτώνται από κάποιες παραμέτρους: $|f(x, \theta)\rangle$. Το επόμενο στάδιο είναι διαφορετικό σε σύγκριση με το κλασικό μοντέλο, είναι το στάδιο της μέτρησης/παρατήρησης (measurement). Στη κβαντική θεωρία όπως αναφέραμε, μπορεί ένα qubit να βρίσκεται

σε παραπάνω από μία καταστάσεις, οπότε όταν παρατηρούμε τα δεδομένα, βλέπουμε την κατάσταση που είχε μεγαλύτερη πιθανότητα να εμφανιστεί και ΟΛΕΣ οι άλλες καταστάσεις καταρρέουν καθώς καταρρέει η υπέρθεση (*superposition*). Το τελικό στάδιο λοιπόν είναι η κατάσταση y' που παρατηρήθηκε προηγουμένως, που πάντα θα διαφέρει έστω λίγο από την επιθυμητή κατάσταση y , και τα υπόλοιπα είναι ήδη γνωστά από την κλασική περίπτωση: υπολογίζεται αυτή η διαφορά $y-y'$, αλλάζουν οι παράμετροι θ και ξαναγίνεται ο υπολογισμός από την αρχή με τις νέες παραμέτρους, παρατηρούμε το αποτέλεσμα ξανά κλπ μέχρις ότου το σφάλμα να πέσει κάτω από κάποιο αποδεκτό όριο που έχουμε θέσει. Αυτό είναι γενικά το πλαίσιο που θα μπορούσε με κάποια τροποποίηση να ονομαστεί και *Κβαντικό Νευρωνικό Δίκτυο*, ίσως με παραπάνω στάδια πράξεων με κβαντικές πύλες, πχ αντί για $W(\theta)$ να έχουμε $W(\theta_1), W(\theta_2), \dots$ αν και πολλοί ερευνητές του χώρου διαφωνούν με τον όρο, κάνοντας λόγο για “*παραμετροποιημένα κβαντικά κυκλώματα*”. Δεν έχει βρεθεί κάποιο μοντέλο που θα μπορούσε να οριστεί ως *Κβαντικός Νευρώνας*, έχουμε μόνο γραμμικές πράξεις, δεν μπορούμε να έχουμε την ευελιξία των συναρτήσεων ενεργοποίησης όπως πχ η *ReLU*, δεν υπάρχει δυνατότητα χρήσης αλγορίθμου όπως ο *backpropagation* κλπ. Μπορούμε ίσως να ορίσουμε την έννοια των γραμμικών *QNNs*. Οπότε ο όρος *Κβαντικά Νευρωνικά δίκτυα* σε γενικές γραμμές προς το παρόν αναφέρεται σε κάποια μορφή των *Variational Models* και στην ουσία χρησιμοποιείται για λόγους *Marketing*.

2.5 Βαθιά Συνελικτική Μάθηση-Βαθύ Συνελικτικό Δίκτυο.

Η θεμελιώδης διαφορά μεταξύ ενός πυκνά συνδεδεμένου στρώματος (*densely connected layer*) και ενός στρώματος συνέλιξης (*convolutional layer*) είναι η εξής: Τα πυκνά στρώματα μαθαίνουν καθολικά μοτίβα στο χώρο των χαρακτηριστικών εισόδου τους (δηλαδή όλα τα εικονοστοιχεία), ενώ τα στρώματα συνέλιξης μαθαίνουν τοπικά

μοτίβα, στην περίπτωση εικόνων, μοτίβα που βρίσκονται σε μικρά δυσδιάστατα παράθυρα των εισόδων.




Εικόνα 2.5. Οι εικόνες μπορούν να χωριστούν σε τοπικά μοτίβα, όπως ακμές, υφές και ούτω καθεξής (F. Chollet, , 2021).

Αυτό το χαρακτηριστικό κλειδί δίνει τα συνελκτικά δίκτυα δύο ενδιαφέροντα χαρακτηριστικά:

- Τα πρότυπα που μαθαίνουν είναι αμετάβλητα στην μεταφορά (*translation invariant*). Αυτό σημαίνει ότι άπαξ και μάθει ένα μοτίβο σε οποιοδήποτε μέρος μιας εικόνας, θα μπορεί να το αναγνωρίσει οπουδήποτε. Αντίθετα ένα πυκνά συνδεδεμένο δίκτυο θα έπρεπε να το μάθει ξανά εάν εμφανιζόταν σε διαφορετική θέση. Κατά συνέπεια, τα συνελκτικά δίκτυα χρειάζονται λιγότερα δείγματα για να μάθουν γενικευμένες αναπαραστάσεις.


- Μπορούν να μάθουν χωρικές ιεραρχίες μοτίβων. Πιο αναλυτικά, τα πρώτα συνελκτικά στρώματα μαθαίνουν μικρά τοπικά μοτίβα όπως άκρα, το δεύτερα στρώματα θα μάθουν μεγαλύτερα μοτίβα φτιαγμένα από τα χαρακτηριστικά των πρώτων στρωμάτων και ούτω καθεξής. Αυτό επιτρέπει στα συνελκτικά δίκτυα να μαθαίνουν αποτελεσματικά όλο και πιο περίπλοκες και αφηρημένες οπτικές έννοιες.



Εικόνα 2.5 β. Ο οπτικός κόσμος σχηματίζει μια χωρική ιεραρχία οπτικών εννοιών: στοιχειώδεις γραμμές ή υφές συνδυάζονται σε απλά αντικείμενα όπως μάτια ή αυτιά, τα οποία συνδυάζονται σε έννοιες υψηλού επιπέδου όπως η «γάτα».

Ένα είδος νευρωνικού δικτύου είναι τα Συνελκτικά Νευρωνικά Δίκτυα (*Convolutional Neural Network*) αποτελούμενα από πολλαπλά στρώματα με κύρια χρήση στην αναγνώριση εικόνας. Επιστήμονες και ερευνητές παρέτειναν την χρήση των CNN σε μονοδιάστατα δεδομένα. Μέχρι πρότινος, χρησιμοποιούντουσαν σε χωρικά δεδομένα, εικόνες με δύο και τρεις διαστάσεις, ωστόσο αυτή ήταν μόνο η αρχή καθώς εμφανίστηκαν τα θετικά αποτελέσματα σε χρονοσειρές, διεκδικώντας έτσι, δίκαια, το χαρακτηριστικό χρονικά δίκτυα. Οι είσοδοι ενός τέτοιου δικτύου περνάνε από στρώματα συνέλιξης και υποδειγματοληψίας. Στα πρώτα, όπως μαρτυρά το όνομα τους,

εφαρμόζεται η μαθηματική πράξη της συνέλιξης και στην συνέχεια, στα στρώματα υποδειγματοληψίας, μειώνεται η διάσταση της εισόδου. Η αλληλουχία των στρωμάτων αυτών υλοποιεί ουσιαστικά έναν μετασχηματισμό της εισόδου σε χάρτη χαρακτηριστικών. Στο τελικό στρώμα του δικτύου, ο χάρτης χαρακτηριστικών που θα έχει ήδη δημιουργηθεί εισάγεται ως είσοδος σε έναν ταξινομητή, στην προκειμένη περίπτωση της πτυχιακής, σε ένα στρώμα *Softmax* προκειμένου να κατηγοριοποιηθεί σε κλάσεις.



Σχήμα 2.5 γ Αρχιτεκτονική τυπικού Συνελικτικού Νευρωνικού Δικτύου.

Η αρχιτεκτονική των συνελικτικών δικτύων είναι απλή. Η είσοδος περνάει σε ένα συνελικτικό στρώμα όπου γίνεται χρήση συνελικτικών масκών, μάσκας (*mask*), ή φίλτρου (*filter*), για την ανίχνευση χαρακτηριστικών. Ένα φίλτρο είναι ένας μικρός σε διάσταση τανιστής ο οποίος σαρώνει τον τανιστή εισόδου και επιστρέφει την μέγιστη απόκριση εκεί που εμφανίζεται ένα τοπικό χαρακτηριστικό όμοιο με αυτό του φίλτρου. Η διαδικασία αυτή πραγματοποιείται με το εσωτερικό γινόμενο των τανιστών που επικαλύπτονται καθώς το φίλτρο σαρώνει μια συγκεκριμένη περιοχή της είσοδο με την έξοδο του να ονομάζεται τοπικό υποδεκτικό πεδίο (*local receptive field*). Ένα

συνελικτικό στρώμα (Convolution Layer) αποτελείται από ένα πλήθος (C), χαρτών χαρακτηριστικών, τα οποία είναι δισδιάστατα πλέγματα νευρώνων με διαστάσεις $N \times N$. Επομένως, με ένα συνελικτικό στρώμα να έχει $N \times N \times C$ νευρώνες, ο νευρώνας με θέση i, j στο k -οστό χάρτη χαρακτηριστικών υπολογίζει την συνάρτηση.

$$y_{ij}^k = f \left(\sum_{l=1}^{C'} \sum_{a=1}^m \sum_{b=1}^m w_{a,b,l}^k x_{i-a,j-b}^l + b^k \right) \quad (2.5.1)$$

Ειδικότερα, η παραπάνω συνάρτηση υπολογίζει το άθροισμα των νευρώνων όλων των χαρτών χαρακτηριστικών για τις τιμές $x_{i-a,j-b}^l$.

Κεφάλαιο 3

3.1 Μικροσκοπική Μάθηση.

Η εφαρμογή εργαλείων της τεχνητής νοημοσύνης στη νανοτεχνολογία είναι περιορισμένη και έχει επικεντρωθεί κυρίως στην ερμηνεία εικόνων μικροσκοπίας σάρωσης ακίδας, στην πρόβλεψη ιδιοτήτων νανοϋλικών, στον σχεδιασμό νανοσυστημάτων και στην επιλογή παραμέτρων σε προσομοιώσεις νανοδιεργασιών. Εντούτοις, τα εργαλεία λογισμικού που χρησιμοποιούνται από τις τεχνικές της

μηχανικής μάθησης (υποπεδίο της τεχνητής νοημοσύνης) θα μπορούσαν να προσθέσουν αξία στη σύνθετη διαδικασία κατασκευής, χαρακτηρισμού και χρήσης των νανοδομών επιτρέποντας πιο αποτελεσματικό χειρισμό των δεδομένων, μειωμένη πολυπλοκότητα και ορθότερη λήψη αποφάσεων. Πιο συγκεκριμένα, στην εργασία αυτή εστιάζουμε στο πρόβλημα του στοχευμένου χαρακτηρισμού της μορφολογίας νανοδομημένων επιφανειών με τραχύτητα. Με τον όρο στοχευμένο εννοούμε τον χαρακτηρισμό που προσδιορίζεται από την συγκεκριμένη εφαρμογή της νανοδομημένης επιφάνειας που θέλουμε να χαρακτηρίσουμε. Με άλλα λόγια, ο στόχος μας είναι να επιλεγούν για τον μορφολογικό χαρακτηρισμό τους οι παράμετροι εκείνοι που είναι κρισιμότεροι για την εφαρμογή που στοχεύει η κατασκευή τους. Για να γίνει κατανοητό το παραπάνω πρόβλημα, θα βοηθούσε να επιμερίσουμε σε τρία στάδια (σχήμα 4.1) όλη τη διαδικασία από την παραγωγή ενός προϊόντος που περιέχει νανοδομές (π.χ. νανοδομημένες επιφάνειες) μέχρι την τελική χρήση του: α) την κατασκευή, β) τον μετρολογικό χαρακτηρισμό και γ) την εφαρμογή και χρήση του. Η κατασκευή είναι υπεύθυνη για το σχεδιασμό και την παραγωγή της νανοδομημένης επιφάνειας. Σε αυτό το στάδιο, πρέπει να αποφασιστούν βασικοί παράγοντες σχετικά με τη κατασκευή των νανοδομών, όπως το είδος υλικού που πρέπει να χρησιμοποιηθεί όπως και με ποιες διεργασίες πρέπει να γίνει η επεξεργασία του ώστε να επιτευχθεί η σχεδιαζόμενη νανοδομή. Οι εμπλεκόμενες παράμετροι σε αυτό το στάδιο μπορεί είναι πολλές και συσχετισμένες με πολύπλοκο τρόπο. Αφού κατασκευαστεί η νανοεπιφάνεια, πρέπει να χαρακτηριστεί μορφολογικά (γεωμετρικά) και χημικά, δηλ. να μετρηθεί ένα άλλο σύνολο παραμέτρων για τον χαρακτηρισμό των δομών της (τοπογραφία, τραχύτητα κλπ.) αλλά και για τη χημική σύστασή της. Οι τεχνικές του μορφολογικού και χημικού χαρακτηρισμού μπορούν να περιλαμβάνουν τη χρήση SPM (μικροσκοπία σάρωσης με ακίδα) ή SEM (ηλεκτρονική μικροσκοπία σάρωσης) ή οπτικών μεθόδων ανάλυσης όπου ηλεκτρομαγνητική

ακτινοβολία συγκεκριμένου φάσματος αλληλοεπιδρά με τη νανοδομημένη επιφάνεια ή υλικό. Το τελευταίο στάδιο της διαδικασίας παραγωγής νανοδομών είναι η διασφάλιση της συγκεκριμένης επιδιωκόμενης λειτουργικότητας. Αυτό το στάδιο περιλαμβάνει παραμέτρους που σχετίζονται με τις επιθυμητές τελικές ιδιότητες της νανοδομής, όπως για παράδειγμα συγκεκριμένη υπερυδροφοβικότητα, αντίσταση, αντανάκλαση του φωτός, απόδοση των τσιπ κλπ. Ο χαρακτηρισμός και η ποσοτικοποίηση αυτών των ιδιοτήτων μπορεί να σχετίζεται με μια ποικιλία τεχνικών μέτρησης, που αξιολογούν πόσο επιτυχής ήταν ο αρχικός σχεδιασμός.



Διάγραμμα 3.1. Σχηματική αναπαράσταση διαδικασίας παραγωγής νανοδομών επιμερισμένη σε τρία βασικά στάδια, της κατασκευής, χαρακτηρισμού και εφαρμογής.

Ως Νανοτεχνολογία ορίζουμε τον σχεδιασμό, κατασκευή και λειτουργία διατάξεων και συστημάτων που περιέχουν νανοδομημένα υλικά, δηλ. υλικά με δομές που έχουν τουλάχιστον μία χαρακτηριστική διάσταση μικρότερη των 100nm. Ένα νανόμετρο (nm) αντιστοιχεί σε 10⁻⁹ μέτρα (m). Σε ατομική κλίμακα είναι περίπου δέκα φορές η διάμετρος του Ηλίου (He). Για να γίνει κατανοητή η κλίμακα αυτή, αρκεί να σημειώσουμε ότι η ανθρώπινη τρίχα έχει 60-80,000 nm πάχος. Δηλ. η νανοτεχνολογία χειρίζεται δομές που η διάστασή τους είναι περίπου το 1/1000 του πάχους της

ανθρώπινης τρίχας. Μια από τις πρώτες και πιο σημαντικές αναφορές στη νανοτεχνολογία έγινε το 1959 από τον διάσημο φυσικό *Richard Feynman* κατά τη διάρκεια της διάλεξής του στην ετήσια συνάντηση της Αμερικανικής Φυσικής Εταιρείας (*American Physical Society*) στο Ινστιτούτο Τεχνολογίας της Καλιφόρνιας (*Caltech*) . Στην ομιλία του ανέφερε το πρόβλημα χειρισμού και ελέγχου των πραγμάτων σε ατομική κλίμακα. Η κατασκευή συσκευών σε τέτοια κλίμακα θα μπορούσε να λύσει προβλήματα αποθήκευσης χώρου, ενέργειας και λειτουργικότητας. Μεταξύ άλλων ανέφερε επίσης «Όταν φτάσουμε σε αυτό το μικρόκοσμο – για παράδειγμα σε κυκλώματα επτά ατόμων - θα εμφανιστούν πολλά νέα φαινόμενα που θα αντιπροσωπεύουν εντελώς νέες ευκαιρίες για το σχεδιασμό συσκευών». Αυτή μάλιστα, ήταν και η αντίληψη της επιστημονικής κοινότητας όταν κατάφεραν να μελετήσουν διατάξεις τέτοιων μικροσυστημάτων. Τα υλικά σε μικρές διαστάσεις (νάνο-σωματίδια, λεπτά φιλμ κ.α.) μπορούν να έχουν έντονα διαφορετικές ιδιότητες συγκριτικά με τα ίδια υλικά σε αντίστοιχα μεγάλες διαστάσεις . Μέσω αυτής της ιδιαιτερότητας μπορούν να δημιουργηθούν πολλές μικροσυσκευές με μοναδικά χαρακτηριστικά. Για να συμβεί όμως αυτό πρέπει να κατανοήσουμε τον τρόπο και τις συνθήκες κατασκευής τους. Το πρώτο βήμα λοιπόν, για τη μελέτη της κατασκευής τους ξεκίνησε μετά το 1974 όπου οι επιστημονικές ανακαλύψεις και εργαστηριακές μέθοδοι πορεύτηκαν με εφευρέσεις όπως του διάσημου *Dr. Tuomo Suntola* και την ατομική εναπόθεση στρωμάτων (*ALD*). Έτσι ξεκίνησε να ανοίγει ο δρόμος για την νανοτεχνολογία και την αναγνώρισή της από τους επιστημονικούς φορείς. Στα τέλη της δεκαετίας του 1980 η νανοτεχνολογία αρχίζει να αναγνωρίζεται και ως διακριτό αντικείμενο μελέτης και από εταιρίες με αποτέλεσμα από το 2000 να αρχίσουν να αναπτύσσονται εμπορικά προϊόντα και να κυκλοφορούν στην αγορά. Σημαντικός παράγοντας αποτέλεσε η προσαρμογή των τεχνικών εργαστηρίου για βιομηχανική παραγωγή των προϊόντων και η χρήση φθηνών πρώτων

υλών όπως το Πυρίτιο (Si). Η νανοτεχνολογία ακόμα και σήμερα θεωρείται μια αναδυόμενη τεχνολογία, κυρίως λόγω της ποιοτικής κατασκευής νανοδιατάξεων που στοχεύουν στη δημιουργία νέων προϊόντων με τελείως καινούργια και μοναδικά χαρακτηριστικά. Το εύρος των εφαρμογών που μπορούν να καλύψουν αυτές οι συσκευές είναι τεράστιο. Επειδή η νανοτεχνολογία ορίζεται με όρους κλίμακας διαστάσεων, έχει εφαρμογές σε πολλά πεδία και μπορούμε να πούμε ότι διατρέχει οριζόντια πολλές περιοχές της επιστήμης και τεχνολογίας ανεξάρτητα με τη φύση των εμπλεκόμενων υλικών και διεργασιών. Οι καινοτομίες και λύσεις των προβλημάτων που έχει συνεισφέρει στην τεχνολογία και κοινωνία γενικότερα έχουν αναγνωρισθεί και γι' αυτό έχει επιλεγεί από την Ευρωπαϊκή Ένωση ως ένας τομέας έρευνας με προτεραιότητα στην εξασφάλιση κονδυλίων χρηματοδότησης. Η νανοτεχνολογία μπορεί να θεωρηθεί ότι περιέχει τρεις βασικούς τομείς που σήμερα δρουν σε συνεργασία ή και ανεξάρτητα:

Η νανοηλεκτρονική και η μικροηλεκτρονική αποτελούν δύο από τις κινητήριες δυνάμεις για την ανάπτυξη της νανοτεχνολογίας. Αυτές οι δύο έχουν οδηγήσει σε επενδύσεις όπως της ευρωπαϊκής ένωσης το 2013, όπου έθεσε ως στόχο το διπλασιασμό της παραγωγής ολοκληρωμένων συστημάτων σε περίπου 20% τη ολόκληρης παραγωγής της. Η πληροφορία πλέον καθημερινά μεταφέρεται και αναπαράγεται ψηφιακά με την ηλεκτρονική να αποτελεί κεντρικό πυρήνα της. Η σμίκρυνση διαστάσεων των ηλεκτρονικών συστημάτων έχει αυξήσει τις δυνατότητες χρήσης τους κατασκευάζοντας αμέτρητες συσκευές (γρήγορες, λειτουργικές, φθηνές αλλά παράλληλα μεγάλης αξίας) μέσω της βιομηχανικής καινοτομίας στο χώρο αυτό. Οι βιομηχανίες αυτές δημιουργούν στοιχεία ενεργητικών κυκλωμάτων (τρανζίστορ, διόδους, οπτοηλεκτρονικές διατάξεις) σε μικρό και νάνο κλίμακα και μέσω τον συνδυασμό τους είναι δυνατόν να σχεδιαστούν τα ψηφιακά συστήματα που χρησιμοποιεί ο κόσμος καθημερινά. Βασικό ρόλο σε αυτή τη διαδικασία αποτελεί η κατανόηση των διεργασιών παράλληλα με τις φυσικές,

μηχανικές και χημικές ιδιότητες των επιμέρους υλικών όπως μετάλλων, ημιαγωγών και ιδιαίτερα του πυριτίου. Πάνω από το 90% του φλοιού της Γης αποτελείται από πυριτικά ορυκτά, καθιστώντας το πυρίτιο το δεύτερο πιο πλούσιο σε στοιχείο στον ανώτερο γήινο φλοιό (περίπου 28% κατά μάζα) μετά το οξυγόνο. Συνεπώς η αφθονία σε συνδυασμό με την επιστημονική μελέτη και ικανότητας επεξεργασίας του (μεταβολή των ιδιοτήτων) προσφέρει μεγάλες δυνατότητες στη σύγχρονη ηλεκτρονική. Το πυρίτιο σε σχέση με τα γειτονικά στοιχεία στο περιοδικό πίνακα παρουσιάζει τις υψηλότερες θερμοκρασίες τήξης. Μάλιστα, το φυσικό του οξείδιο, SiO_2 είναι επίσης εύχρηστο και μπορεί να σχηματίσει φιλικές επαφές ζεύγους ημιαγωγών - διηλεκτρικών, σε σχέση με κάθε άλλο γνωστό υλικό. Το SiO_2 παράλληλα με τις νοθέουσες Si τύπου p και n αποτελούν τη βάση των ολοκληρωμένων κυκλωμάτων και γενικά των μικρο και νάνο συστημάτων. Δομικό στοιχείο που περιέχεται στα ολοκληρωμένα κυκλώματα είναι το τρανζίστορ. Η λειτουργία του τρανζίστορ ταυτίζεται με την ψηφιακή λογική αφού δρα ως ένας πολύ γρήγορος διακόπτης με το συνδυασμό τους δημιουργεί λογικά κυκλώματα. Στα τρανζίστορ περιέχεται μια σημαντική κατηγορία, τα τρανζίστορ εκπομπής πεδίου (Field Effect Transistors, FET) τα οποία χωρίζονται σε δύο άλλες υποκατηγορίες με σημαντικότερη εξ' αυτών τα τρανζίστορ μετάλλου-οξειδίου-ημιαγωγού (Metal-Oxide-Semiconductor FET-MOSFET). Τα MOSFET αποτελούνται από διαδοχικά λεπτά στρώματα μετάλλου, οξειδίου και ημιαγωγού. Για μέταλλο χρησιμοποιείται Αλουμίνιο (Al) είτε μια πολυκρυσταλλική μορφή πυριτίου (polysilicon). Οι ιδιότητες των MOSFET συνδέονται άμεσα με τις γεωμετρικές διαστάσεις του. Το μέγεθος μάλιστα των 34 χαρακτηριστικών εσωτερικών αποστάσεων χαρακτηρίζει τις διαφορετικές γενιές της τεχνολογίας των κυκλωμάτων του. Η απόδοση μιας ηλεκτρονικής συσκευής και συγκεκριμένα των τσίπ καθορίζεται από τον αριθμό των τρανζίστορ. Ο μεγάλος αριθμός των τρανζίστορ αντιστοιχεί σε πληθώρα λογικών πυλών ανά μονάδα χρόνου.

Για παράδειγμα η σημερινή απόδοση των ηλεκτρονικών υπολογιστών οφείλεται στην αύξηση των τρανζίστορ στα τσίπ παράλληλα με τη σμίκρυνση τους. Το 1965, μέλος των ιδρυτών της εταιρείας Intel προέβλεψε το ταχύ ρυθμό της τεχνολογικής καινοτομίας. Η πρόβλεψη τους, γνωστή και ως «Νόμος του Moore» αναφέρει ότι ο αριθμός των τρανζίστορ σε ένα ολοκληρωμένο κύκλωμα ή τσιπ θα διπλασιάζεται κάθε δύο χρόνια.

3.2 Αρχές Μικροσκοπικής Μάθησης και Νευρωνικά Δίκτυα.

Ως σήμα καλείται μια λειτουργία που μεταφέρει πληροφορίες σχετικά με ένα φαινόμενο και στην περίπτωση των βιοϊατρικών σημάτων, αυτό μπορεί να είναι ένα ηλεκτρικό βιοσήμα. Οποιαδήποτε ποσότητα που ποικίλλει στο χώρο ή στο χρόνο μπορεί να χρησιμοποιηθεί ως σήμα για την ανταλλαγή μηνυμάτων μεταξύ των παρατηρητών. Το ερώτημα που συχνά τίθεται είναι: «υπάρχει σύνδεση μεταξύ σημάτων και καταστάσεων και αν ναι, πώς μπορεί να αναγνωριστεί αυτόματα;» (Georgoulas, et al., 2005).

Τα βιοϊατρικά σήματα διαβιβάζουν βασικές πληροφορίες σχετικά με τη φύση και την κατάσταση του βιολογικού συστήματος που μελετάται. Η κατάλληλη επεξεργασία τους παρέχει σημαντικές φυσιολογικές και κλινικές πληροφορίες. Η επεξεργασία βιοσημάτων έχει ως αποτέλεσμα την αναγνώριση γεγονότων και εν συνεχεία τη χρήση μεθόδων μέσω μηχανικής μάθησης για την ταξινόμηση των γεγονότων. Για την επεξεργασία σήματος, πραγματοποιείται κοπή και διαίρεση των αρχικών δειγμάτων σε σταθερά τμήματα και υπολογίζονται τα βασικά χαρακτηριστικά τους. Αυτά μπορούν να χρησιμοποιηθούν είτε ως είσοδοι για την ανάλυση ομάδων για την εύρεση της καλύτερης διαίρεσης των τμημάτων σε συστάδες, είτε ως είσοδοι σε έναν εποπτευόμενο ταξινομητή. Οι συστάδες που προκύπτουν μπορούν να χρησιμοποιηθούν ως σύνολα εκπαίδευσης και δοκιμής για διάφορες μεθόδους μηχανικής εκμάθησης, αλλά και για τον εποπτευόμενο ταξινομητή, χωρίς το ενδιάμεσο στάδιο της ανάλυσης συστάδων. Η

ανάλυση αυτή βασίζεται στο σημαντικό χαρακτηριστικό των βιοϊατρικών σημάτων, τη χρονική τους διάσταση. (Giannakakis, et al., 2019).

Στις μέρες μας, αλγόριθμοι ML βρίσκονται στον πυρήνα ποικίλων τομέων της τεχνολογίας, της οικονομίας και της κοινωνίας. Ιατρική, βιοπληροφορική, χρηματιστήριο, ίντερνετ είναι μόλις λίγοι από τους τομείς στους οποίους επιστρατεύονται. Τεχνολογικοί κολοσσοί όπως Apple, Youtube, Microsoft, e-shops όπως Amazon και eBay, κοινωνικά δίκτυα όπως Facebook και Twitter εμπεριέχουν μοντέλα ML (Müller & Guido, 2016). Η παρουσία τους υπάρχει ακόμα και σε πιο ανεπαίσθητες εφαρμογές όπως οι προτάσεις για ταινίες, αγορές ρούχων ή παραγγελιών φαγητού, αναγνώριση προσώπων σε φωτογραφίες, κλπ. Εκτός βέβαια από τις εμπορικές εφαρμογές, η ML αποτελεί ισχυρό εργαλείο έρευνας επιστημονικών ζητημάτων, όπως η εύρεση εξωπλανητών, η διερεύνηση του γαλαξία, η αλληλούχιση του DNA, η καταπολέμηση ανίατων ασθενειών, κλπ. Οι πληροφορίες σχετικά με σωστές διαγνώσεις μπορούν να βρεθούν σε ιατρικά αρχεία σε εξειδικευμένα νοσοκομεία και τμήματα, και μπορούν να χρησιμοποιηθούν για την εκμάθηση ενός αλγορίθμου μηχανικής μάθησης. Οι περιπτώσεις που έχουν ήδη επιλυθεί μπορούν να αξιοποιηθούν για την ανάπτυξη ταξινομητών και τη διάγνωση ασθενών. Ο ταξινομητής μπορεί να χρησιμοποιηθεί για να βελτιώσει τη διαγνωστική ταχύτητα, ακρίβεια και αξιοπιστία των ιατρών κατά τη διάγνωση νέων ασθενών, ή για να εκπαιδεύσει μαθητές ή μη ειδικούς γιατρούς σε ένα ειδικό διαγνωστικό πρόβλημα. Αυτό είναι ένα παράδειγμα του πώς η μηχανική μάθηση μπορεί να βελτιώσει την ιατρική πρακτική και την αύξηση της αξιοπιστίας των διαγνώσεων (Kononenko, 2001).


Η μάθηση χωρίς επίβλεψη είναι σημαντική, διότι ο εγκέφαλος αντιμετωπίζει συχνά ανάγκη να αναπαράγει αναλυτικά και ακριβώς τον οπτικό κόσμο. Για παράδειγμα, τα φωτοϋποδοχεία στο μάτι παρέχουν όλες τις διαθέσιμες πληροφορίες για τα αντικείμενα

στον κόσμο, και ο εγκέφαλος πρέπει να τα επεξεργαστεί για να παραγάγει μια αναπαράσταση της εισόδου. Στη μάθηση χωρίς επίβλεψη, οι μέθοδοι πρέπει να δουλεύουν με τα παρατηρούμενα μοτίβα εισόδου, τα οποία είναι συχνά ανεξάρτητα δείγματα μιας άγνωστης κατανομής πιθανότητας $PI[x]$, και να χρησιμοποιούν την υπόθεση ότι ορισμένα μοτίβα είναι πιο σημαντικά από άλλα, βασιζόμενοι σε ρητές ή υπόρρητες *a priori* πληροφορίες. Ένα βασικό σημείο είναι η είσοδος (Dayan et al., 1995).


Δύο κατηγορίες μεθόδων έχουν προταθεί για μάθηση χωρίς επίβλεψη. Οι τεχνικές εκτίμησης πυκνότητας που δημιουργούν ρητά στατιστικά μοντέλα για το πώς οι υποκείμενες αιτίες θα μπορούσαν να δημιουργήσουν τα δεδομένα, καθώς και οι τεχνικές εξαγωγής χαρακτηριστικών που προσπαθούν να εξάγουν στατιστικές κανονικότητες (ή μερικές φορές ανωμαλίες) απευθείας από τις εισόδους (Dayan et al., 1995).

Η ανακάλυψη ότι τα βιολογικά συστήματα μάθησης αποτελούνται από εξαιρετικά περίπλοκους ιστούς διασυνδεδεμένων νευρώνων χρησίμευσε ως κύρια έμπνευση για την έρευνα των ΤΝΔ. Ως αποτέλεσμα, τα ΤΝΔ δημιουργούνται από ένα σύνολο απλών μονάδων που είναι στενά συνδεδεμένα μεταξύ τους και το καθένα παράγει μια ενιαία έξοδο πραγματικής αξίας αφού λάβει έναν αριθμό εισόδων πραγματικής αξίας (οι οποίες θα μπορούσαν να είναι οι έξοδοι άλλων μονάδων). (η οποία μπορεί να γίνει η είσοδος σε πολλές άλλες μονάδες). Ουσιαστικά, Τα ΤΝΔ είναι μια σειρά από συνδεδεμένα Στοιχεία Επεξεργασίας που διαμορφώνονται σύμφωνα με πραγματικούς νευρώνες και αναφέρονται ως τεχνητοί νευρώνες (Mitchell, 1997). Οι άξονες και οι δενδρίτες αναπαρίστανται από τις συνδέσεις των κόμβων, οι συνάψεις και το κατώφλι αντιπροσωπεύονται από τα βάρη σύνδεσης. Αυτή είναι μια ωμή αναλογία μεταξύ ενός τεχνητού νευρώνα και ενός βιολογικού νευρώνα (Jain et al., 1996). Είναι αλήθεια ότι

ενώ τα ΤΝΔ μπορεί να θεωρηθούν ως απλώς αλγόριθμοι που έχουν σχεδιαστεί για την επίλυση συγκεκριμένων προβλημάτων, η αναλογία τους με τον εγκέφαλο είναι ένας πολύ χρήσιμος τρόπος περιγραφής της κατασκευής και λειτουργίας τους. Παρακάτω, οι εικόνες 4.2α & 4.2β απεικονίζουν η βιολογικούς νευρώνες με διάφορα σήματα έντασης x και συναπτικής ισχύος w που τροφοδοτούνται σε έναν νευρώνα με κατώφλι b και το ισοδύναμο σύστημα τεχνητών νευρώνων. Τόσο το βιολογικό δίκτυο όσο και το ΤΝΔ μαθαίνουν προσαρμόζοντας σταδιακά τα μεγέθη των δυνάμεων των βαρών ή των συνάψεων (Basheer & Hajmeer, 2000)



Εικόνα 3.2α Αλληλεπίδραση σήματος και αναλογία σήματος σε τεχνητό νευρώνα.



Εικόνα 3.2β Αναλογία βιολογικού και νευρωνικού σήματος.

Οι νευρώνες ενός ΤΝΔ είναι οργανωμένοι σε επίπεδα (layers). Τα βασικά επίπεδα των ΤΝΔ είναι τα ακόλουθα:

- **Επίπεδο Εισόδου (Input Layer):** Αποτελεί το επίπεδο στο οποίο εφαρμόζονται τα εξωτερικά σήματα.
- **Ενδιάμεσο ή Κρυμμένο Επίπεδο (Hidden Layer):** Είναι το επίπεδο στο οποίο μεταφέρονται οι έξοδοι των νευρώνων εισόδου και δεν έχουν άμεση αλληλεπίδραση με το περιβάλλον.
- **Επίπεδο Εξόδου (Output Layer):** Είναι το επίπεδο που ενημερώνει το χρήστη για την έξοδο του ΤΝΔ. Κάθε νευρωνικό δίκτυο έχει μερικά κοινά στοιχεία:

- Εισαγωγή (Input): Είναι δεδομένα που εισάγονται στο μοντέλο για σκοπούς μάθησης και εκπαίδευσης.
- Βάρη (Weights): Βοηθούν στην οργάνωση των μεταβλητών με βάση τη σημασία και τον αντίκτυπο της συνεισφοράς τους.
- Συνάρτηση μεταφοράς (Transfer Function): Όταν οι εισροές συνδυάζονται σε ενιαία μεταβλητή εξόδου.
- Συνάρτηση ενεργοποίησης (Activation Function): Αποφασίζει εάν ένας συγκεκριμένος νευρώνας πρέπει να ενεργοποιηθεί ή όχι. Αυτή η απόφαση βασίζεται στο αν η είσοδος του νευρώνα θα είναι σημαντική για τη διαδικασία πρόβλεψης.
- Προκατάληψη (Bias): Μετατοπίζει την τιμή που δίνει η συνάρτηση ενεργοποίησης. Όταν κάθε νευρώνας ενός επιπέδου συνδέεται με όλους τους νευρώνες του επόμενου, τότε το ΤΝΔ καλείται πλήρως συνδεδεμένο (fully connected), ειδικά μερικώς συνδεδεμένο (partially connected). Η αρχιτεκτονική ενός ΤΝΔ καθορίζει τον αριθμό των επιπέδων, όπως και το πλήθος νευρώνων που απαρτίζουν κάθε ένα από τα επίπεδα. Τα ΤΝΔ μικρού μεγέθους ενέχουν τον κίνδυνο αποτυχίας σε σύνθετες καταστάσεις, ενώ τα μεγάλου μεγέθους απαιτούν μεγάλο αριθμό δεδομένων και πολύ υπολογιστικό χρόνο. Παράλληλα, το πλήθος των κρυφών επιπέδων συνάδει με την πολυπλοκότητα του εκάστοτε ζητήματος που μας ενδιαφέρει (Dornhege, 2007; Μουγιακάκου, 2003).



Εικόνα 4.2γ Ταξινόμηση Αρχιτεκτονικών Νευρωνικών Δικτύων.

Οι συνελκτικές δομές επιτρέπουν στο CNN, έναν τύπο νευρωνικού δικτύου τροφοδοσίας, να εξάγει χαρακτηριστικά από δεδομένα εισόδου. Το CNN δεν χρειάζεται να εξάγει απευθείας χαρακτηριστικά, σε αντίθεση με τις συμβατικές τεχνικές εξαγωγής χαρακτηριστικών. Ο σχεδιασμός του CNN επηρεάστηκε από την οπτική αντίληψη. Οι τεχνητοί νευρώνες είναι ισοδύναμοι με τους πραγματικούς νευρώνες. Διαφορετικοί υποδοχείς που μπορούν να αντιδράσουν σε διάφορα χαρακτηριστικά

αντιπροσωπεύονται από πυρήνες CNN. Η συνάρτηση ότι μόνο ηλεκτρικά ερεθίσματα από νευρώνες που είναι ισχυρότεροι από ένα ορισμένο όριο μπορούν να μεταδοθούν στον ακόλουθο νευρώνα προσομοιώνεται με συναρτήσεις ενεργοποίησης. Οι άνθρωποι δημιούργησαν συναρτήσεις απώλειας και βελτιστοποιητές για να εκπαιδεύσουν ολόκληρο το σύστημα CNN για να μάθουν τι αναμένουμε (Li, et al., 2021).

1. Τοπικές Συνδέσεις: Περιορίζοντας τις συνδέσεις κάθε νευρώνα σε μερικούς επιλεγμένους νευρώνες από το προηγούμενο επίπεδο, μπορεί κανείς να μειώσει αποτελεσματικά τον αριθμό των παραμέτρων και να επιταχύνει τη σύγκλιση.

2. *Κοινή χρήση βάρους: Επιτρέποντας στους συνδέσμους να μοιράζονται τα ίδια βάρη, οι παράμετροι μπορούν να ελαχιστοποιηθούν περαιτέρω.*

3. *Υποδειγματοληψία (Downsampling) Μείωσης της Διάστασης: Για να μειώσει την ποσότητα των δεδομένων διατηρώντας παράλληλα σημαντικές πληροφορίες, ένα επίπεδο συγκέντρωσης χρησιμοποιεί την αρχή τοπικής συσχέτισης εικόνας για τη μείωση του δείγματος μιας εικόνας. Με την εξάλειψη των περιττών χαρακτηριστικών, μπορεί επίσης να μειώσει τον αριθμό των παραγόντων. Αυτά τα τρία ελκυστικά χαρακτηριστικά καθιστούν το CNN έναν από τους πιο αντιπροσωπευτικούς αλγόριθμους στον τομέα της βαθιάς μάθησης (Li, et al., 2021).*

Τα βασικά στοιχεία που απαρτίζουν ένα CNN είναι τα ακόλουθα (Ajit, Acharya & Samanta, 2020; Bernal et al., 2018).

- *Εισαγωγή (Δεδομένα Εκπαίδευσης): Το επίπεδο εισόδου αντιπροσωπεύεται σε 3 διαστάσεις, δηλαδή πλάτος, μήκος και ύψος. Στην εισαγωγή (δεδομένα εκπαίδευσης), οι εικόνες συνήθως αναπαρίστανται ως πίνακες μεγέθους πλάτος * ύψος * βάθος στα οποία το βάθος χρησιμοποιείται κυρίως για την αναπαράσταση έγχρωμων εικόνων σε μορφή RGB. Συνήθως, το επίπεδο εισόδου έχει άρτιο μέγεθος και μπορεί να διαιρεθεί πολλές φορές με τον αριθμό 2.*

- *Συνελικτικό Επίπεδο (Convolved Feature): Τα CNN μαθαίνουν τις σχέσεις μεταξύ των pixel των εικόνων εισόδου εξάγοντας αντιπροσωπευτικά χαρακτηριστικά χρησιμοποιώντας λειτουργίες συνέλιξης και συγκέντρωσης. Τα συνελικτικά επίπεδα (Convolved Features) σε ένα CNN ανιχνεύουν χαρακτηριστικά χρησιμοποιώντας πυρήνες εκμάθησης, τα οποία ποικίλλουν σε πολυπλοκότητα από το πρώτο επίπεδο που εξάγει απλά χαρακτηριστικά όπως άκρες, έως τα τελευταία επίπεδα που εξάγουν πιο περίπλοκα και υψηλού επιπέδου χαρακτηριστικά. Η λειτουργία συνέλιξης στα CNN έχει τρία κύρια πλεονεκτήματα: πρώτον, βοηθά στην αντιμετώπιση δεδομένων υψηλών*

διαστάσεων, όπως εικόνες 2D και δεδομένα 3D, όπως βίντεο και ογκομετρικές εικόνες, μέσω του μηχανισμού κατανομής βάρους. Δεύτερον, αξιολογεί την τοπική συνδεσιμότητα της τοπολογίας εισόδου χρησιμοποιώντας πυρήνες 2D ή 3D. Τέλος, επιτυγχάνει ελαφρώς αναλλοίωτη μετατόπιση με τη χρήση στρωμάτων συγκέντρωσης.

- *Επίπεδο μη γραμμικότητας (Non-linearity layer):* Ένα επίπεδο μη γραμμικότητας συνήθως ακολουθεί το επίπεδο συνέλιξης, με σκοπό να επιτύχει μη γραμμική απόκριση. Για την επίτευξη αυτού του στόχου, χρησιμοποιούνται ειδικές συναρτήσεις, γνωστές ως συναρτήσεις ενεργοποίησης. Οι συναρτήσεις αυτές εξασφαλίζουν μια αραιή αναπαράσταση του χώρου εισόδου, προκειμένου να προωθήσουν (i) μια σταθερή ανεξαρτησία από τα δεδομένα και (ii) μια αποδοτική υπολογιστική αναπαράσταση. Το πρώτο στοιχείο αφορά την ικανότητα των αραιών αναπαραστάσεων να αντέχουν μικρές μεταβολές καλύτερα από τις πυκνές αναπαραστάσεις. Στο παρελθόν, σιγμοειδείς και υπερβολικές εφραπτομενικές συναρτήσεις χρησιμοποιούνταν κυρίως για αυτόν τον σκοπό. Ωστόσο, καθώς η αναγνώριση εικόνας σε μεγάλη κλίμακα εξελίσσεται, προτείνονται διαρκώς νέες συναρτήσεις ενεργοποίησης. Συνεπώς, το επίπεδο μη γραμμικότητας παίζει κρίσιμο ρόλο στη διαδικασία επεξεργασίας των δεδομένων μέσα στο νευρωνικό δίκτυο. Χρησιμοποιώντας τις συναρτήσεις ενεργοποίησης, το επίπεδο αυτό διασφαλίζει ότι οι αναπαραστάσεις των δεδομένων παραμένουν αποτελεσματικές και ανθεκτικές σε μικρές αλλαγές. Κατηγοριοποιούμε τις συναρτήσεις ενεργοποίησης που χρησιμοποιούνται συνήθως σε τρεις ευρείες οικογένειες.

➤ *Διορθωμένες γραμμικές μονάδες (ReLU) και παραλλαγές:* Το επίπεδο ReLU χρησιμοποιείται για την εφαρμογή της συνάρτησης ενεργοποίησης κατά στοιχεία, η οποία μετατρέπει όλες τις αρνητικές τιμές σε μηδέν, επομένως μετατρέπει το όριο σε μηδέν. Δεν επηρεάζει τις παραμέτρους έντασης.

➤ *Maxout και παραλλαγές: Το Maxout προτάθηκε ιδιαίτερα για τη βελτιστοποίηση και του μοντέλου υπολογισμού του μέσου όρου της απόδοσης της εκπαίδευσης που εγκαταλείπει το σχολείο. Αυτή η συνάρτηση ενεργοποίησης είναι επίσης μια γενίκευση του ReLU.*

➤ *Εκθετικές γραμμικές μονάδες (ELU) και παραλλαγές: Οι εκθετικές γραμμικές μονάδες (ELU) αποτελούν μια εναλλακτική λύση στη χρήση των επεκτάσεων της ReLU. Η ELU χρησιμοποιεί την ταυτότητα για θετικές εισροές, ενώ παρέχει κορεσμένη έξοδο για αρνητικές εισόδους. Ο κορεσμός αυτός αναφέρεται ότι βοηθάει στην επιτάχυνση της μάθησης και στη βελτίωση της απόδοσης των βαθιών CNN. Η χρήση αυτής της συνάρτησης θα μπορούσε να οδηγήσει σε ακόμη καλύτερα αποτελέσματα κατά την εκπαίδευση των μοντέλων CNN.*

• *Επίπεδο συγκέντρωσης και υποδειγματοληψίας (Pooling and sub-sampling layer):*

Το επίπεδο συγκέντρωσης και υποδειγματοληψίας αποτελείται από τρία βήματα τα οποία ακολουθούνται στα συνελκτικά επίπεδα. Στο πρώτο βήμα εκτελούνται αρκετές συνελίξεις για τη δημιουργία των χαρτών χαρακτηριστικών, στο δεύτερο βήμα εφαρμόζονται οι μη γραμμικές συναρτήσεις ενεργοποίησης στους χάρτες χαρακτηριστικών, ενώ στο τρίτο βήμα η έξοδος του επιπέδου τροποποιείται μέσω της συγκέντρωσης. Η συνάρτηση συγκέντρωσης επιτρέπει την εξαγωγή μιας συνοπτικής στατιστικής για μη επικαλυπτόμενες γειτονιές, με στόχο τη μείωση του αριθμού των παραμέτρων στα επόμενα επίπεδα, τον έλεγχο της υπερβολικής προσαρμογής και την επίτευξη ελαφριάς μεταβλητότητας μετάφρασης. Οι πιο συνηθισμένες μέθοδοι συγκέντρωσης είναι η μέγιστη συγκέντρωση και η μέση συγκέντρωση, οι οποίες

προσφέρουν παρόμοιες λειτουργίες, αλλά η πρώτη χρησιμοποιεί το μέγιστο των ενεργοποιήσεων. Η συγκέντρωση πραγματοποιείται για να μειωθεί η διάσταση των δεδομένων και να επιταχυνθεί η διαδικασία εκπαίδευσης του μοντέλου, καθώς και να αποτραπεί η υπερπροσαρμογή. Οι μέθοδοι συγκέντρωσης συνήθως είναι μέθοδοι μηχανικής απομάκρυνσης πληροφορίας, καθώς μειώνουν την πληροφορία που παρέχεται από τα χαρακτηριστικά των εικόνων. Παρόλο που οι μέθοδοι συγκέντρωσης χρησιμοποιούνται ευρέως στην εκπαίδευση των CNN, υπάρχουν και άλλες πιο προηγμένες μέθοδοι συνελικτικών δικτύων, όπως οι συνελικτικοί νευρώνες με προσοχή (*attention-based convolutional neural networks*), που δίνουν καλύτερα αποτελέσματα στην αναγνώριση εικόνων και την επεξεργασία τους.

- Πλήρως συνδεδεμένο επίπεδο (*Fully connected layer*): Σε αντίθεση με το συνελικτικό επίπεδο, το επίπεδο Πλήρως Συνδεδεμένο επίπεδο (FC) έχει πλήρη σύνδεση με όλες τις μονάδες του προηγούμενου επιπέδου. Αυτό το επίπεδο αλλάζει τα χαρακτηριστικά δισδιάστατης δομής των προηγούμενων επιπέδων σε ένα προκαθορισμένο μονοδιάστατο διάνυσμα χαρακτηριστικών. Το επίπεδο FC έχει ως βασικό καθήκον την εξαγωγή πληροφοριών για το περιεχόμενο της εικόνας που εισέρχεται στο μοντέλο. Η διαδικασία συνήθως συνίσταται στην ισοπέδωση των χαρτών χαρακτηριστικών που προέρχονται από συνελικτικά επίπεδα, για να επιτευχθεί μια μονοδιάστατη αναπαράσταση διανύσματος χαρακτηριστικών και, στη συνέχεια, η εισαγωγή του στο επίπεδο FC. Η έξοδος αυτού του επιπέδου θα μπορούσε να είναι είτε οι ετικέτες κλάσης πρόβλεψης, είτε ένα ενδιάμεσο επίπεδο (διαδοχικά επίπεδα FC μπορούν να στοιβάζονται μαζί). Απαιτεί μεγάλο αριθμό παραμέτρων, καθώς κάθε κελί ενός χάρτη χαρακτηριστικών συνδέεται πλήρως με όλα τα στοιχεία του προηγούμενου επιπέδου. Ένα από τα μειονεκτήματά του είναι ότι παράγει μία μόνο έξοδο, αν χρησιμοποιηθεί ως στρώμα εξόδου, και δέχεται εισόδους σταθερού μεγέθους.

Αντίθετα, άλλα επίπεδα στρωμάτων αποτελούνται από πολλά βήματα, όπως η εκτέλεση συνελίξεων και η χρήση μη γραμμικών συναρτήσεων ενεργοποίησης, ενώ επιτρέπουν τη δυνατότητα επεξεργασίας εισόδων διαφορετικού μεγέθους και παραγωγής πολλαπλών εξόδων.

- *Συνάρτηση Απώλειας (Loss function):* Η Συνάρτηση Απώλειας είναι ένα σημαντικό στοιχείο των *Convolutional Neural Networks (CNN)* και χρησιμοποιείται για τη βελτίωση της μάθησης. Οι συναρτήσεις απώλειας που χρησιμοποιούνται στα CNN σχεδιάζονται έτσι ώστε να ενθαρρύνουν την ομοιότητα εντός των κλάσεων και τη διαχωριστική ικανότητα μεταξύ τους. Αυτό επιτυγχάνεται μέσω της εφαρμογής μαθησιακών βαρών σε κάθε επίπεδο του CNN, τα οποία βελτιώνουν τη διαδικασία μάθησης και επιτρέπουν στο μοντέλο να εξάγει διακριτικά χαρακτηριστικά από την εικόνα εισόδου. Ένα από τα κύρια ζητήματα κατά τη φάση της εκπαίδευσης είναι η δυσαναλογία μεταξύ των παρατηρήσεων της τάξης, καθώς ο ταξινομητής που προκύπτει μπορεί να είναι προκατειλημμένος προς την πλειοψηφική τάξη. Αυτό το πρόβλημα μπορεί να αντιμετωπιστεί στη φάση της εκπαίδευσης με τη συνάρτηση απώλειας, η οποία αποδίδει υψηλότερα συγκριτικά με άλλες μεθόδους. Εκτός των ανωτέρω, υπάρχουν και άλλες συνιστώσες που συνθέτουν το σύνολο ενός CNN (Ajit, Acharya & Samanta, 2020; Bernal et al., 2018):
- *Φίλτρο ή Πυρήνας (kernel):* Ονομάζεται επίσης ως ανιχνευτής χαρακτηριστικών. Η ανίχνευση χαρακτηριστικών χρησιμοποιεί συνήθως έναν μικρό πίνακα. Για παράδειγμα, στο ConvNet, το πρώτο επίπεδο έχει διάσταση
- *Δεκτικό Πεδίο (Receptive Field):* Περιοχή πίνακα εισόδου παρόμοια με το μέγεθος του φίλτρου.

- *Βάθος*: Ο αριθμός των φίλτρων.
- *Στήλη Βάθους*: Ονομάζεται επίσης ίνα, είναι μια ομάδα νευρώνων που δείχνουν προς το ίδιο δεκτικό πεδίο.
- *Ρυθμίσεις (Regularizations)*: Καθορισμός της απόδοσης των μεθόδων βαθιάς CNN σε διαφορετικούς τομείς, παρ' ότι γίνεται χρήση τεράστιου αριθμού παραμέτρων. Εάν δεν γίνεται εκπαίδευση σε ένα μεγάλο, με ετικέτα σύνολο δεδομένων εκπαίδευσης, θα πρέπει να χρησιμοποιείται η κατάλληλη τακτοποίηση για να μετριαστεί η υπερβολική προσαρμογή. Τέτοιες ρυθμίσεις είναι η L1, η L2 και η αύξηση δεδομένων.
- *Βελτιστοποίηση (Optimisation)*: Τα CNN βελτιστοποιούν τη συνάρτηση απώλειας αναζητώντας κατάλληλες τιμές παραμέτρων μοντέλου. Για την εκτέλεση της ενημέρωσης παραμέτρων, χρησιμοποιούνται ευρέως μέθοδοι *gradient descent* που βασίζονται στον αλγόριθμο *back-propagation*.
- *Αρχικοποίηση Βαρών (Weight Initialisation)*: Η αρχικοποίηση των βαρών σε ίδιες μικρές τιμές μπορεί να οδηγήσει σε ανεπιθύμητα αποτελέσματα κατά την ενημέρωσή τους κατά τη διάρκεια της αντίστροφης διάδοσης. Για αυτόν το λόγο, υπάρχουν μέθοδοι αρχικοποίησης βαρών που βοηθούν στη βελτιστοποίηση της αρχιτεκτονικής του μοντέλου. Οι μέθοδοι αυτές περιλαμβάνουν την τυχαία αρχικοποίηση, την αρχικοποίηση με μηδενικά, την αρχικοποίηση με βάρη από άλλα μοντέλα, και την αρχικοποίηση Xavier που λαμβάνει υπόψη τις διαστάσεις της εισόδου και της εξόδου στην επιλογή των αρχικών βαρών.
- *Κανονικοποίηση (Normalisation)*: Η κανονικοποίηση αποτελεί συνήθη πρακτική στην εκπαίδευση βαθιών CNN και εφαρμόζεται με τη χρήση συνόλων δεδομένων

εκπαίδευσης με βάση το μέσο όρο. Για να επιτευχθεί αυτό, εφαρμόζεται η τεχνική κανονικοποίησης αντίθεσης.

- *Διασκελισμός (Stride)*: Καθορίζει την ποσότητα του διασκελισμού της απόστασης που θα μετατοπίζεται μετά από κάθε συνέλιξη. Έχοντας μεγαλύτερο βηματισμό δίνεται μικρότερος όγκος εξόδου. Μια από τις τεχνικές που χρησιμοποιούνται στα CNN είναι ο διασκελισμός, όπου ένα φίλτρο μπορεί να μετατοπίζεται κατά ένα συγκεκριμένο αριθμό στηλών και σειρών μετά από κάθε εφαρμογή.
- *Γέμισμα Μηδενικών (Padding)*: Η τεχνική του γεμίσματος με μηδενικά χρησιμοποιείται για τη διατήρηση του μεγέθους του όγκου εισόδου και του όγκου εξόδου, αποτρέποντας την απώλεια πληροφοριών στο περίγραμμα της εικόνας και τη μείωση της διάστασης του όγκου. Η χρήση μικρότερων βημάτων κατά την εφαρμογή του διασκελισμού οδηγεί σε καλύτερα αποτελέσματα στην επεξεργασία της εικόνας.
- *Κοινή χρήση παραμέτρων*: Η κοινή χρήση παραμέτρων στα CNN αναζητά τα κοινά χαρακτηριστικά σε πολλές εικόνες, όπως είναι η περίπτωση των χρωμάτων ή των γωνιών, και χρησιμοποιεί τις ίδιες παραμέτρους για όλες τις εικόνες. Αυτό μπορεί να βοηθήσει στην επίτευξη καλύτερων αποτελεσμάτων και στη μείωση της πολυπλοκότητας του μοντέλου. Ωστόσο, είναι μια πρακτική που χρησιμοποιείται με μέτρο, καθώς μπορεί να οδηγήσει σε υπερπροσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης και να μειώσει τη γενικότητα του μοντέλου σε νέα δεδομένα. Για παράδειγμα, σε μια ανίχνευση προσώπου, δεν υπάρχει ανάγκη για τα χαρακτηριστικά του προσώπου εάν το πρόσωπο είναι τοποθετημένο στην ίδια θέση σε κάθε εικόνα.
- *Διαστολή (Dilation)*: Η διαστολή αποτελεί φίλτρα τα οποία περιλαμβάνουν κενούς χώρους στα κελιά τους. Αν έχουμε ένα φίλτρο μίας διάστασης με μέγεθος W και μια είσοδο X , τότε μπορούμε να εφαρμόσουμε τη διαστολή με διάφορες αποστάσεις. Για παράδειγμα, αν διαθέτουμε ένα φίλτρο μεγέθους 3 και εφαρμόσουμε διαστολή 0, τότε

το αποτέλεσμα θα είναι η πρόσθεση του γινομένου κάθε στοιχείου του φίλτρου με το αντίστοιχο στοιχείο της εισόδου. Αν εφαρμόσουμε διαστολή 1, τότε το αποτέλεσμα θα είναι η πρόσθεση του γινομένου κάθε στοιχείου του φίλτρου με το αντίστοιχο στοιχείο της εισόδου, όμως τα στοιχεία του φίλτρου θα είναι απομακρυσμένα μεταξύ τους κατά 1 στοιχείο.

3.3 Εφαρμογές Νευρωνικών Δικτύων.

Η ευρεία χρήση των CNN οφείλεται κυρίως στην εγγενή τους ικανότητα να συγχωνεύουν την εξαγωγή και την ταξινόμηση χαρακτηριστικών σε ένα ενιαίο προσαρμοστικό σώμα μάθησης. Για τους προαναφερθέντες λόγους, υπάρχουν αρκετοί τομείς εφαρμογών όπου τα CNN προτιμώνται πλέον έναντι άλλων τεχνικών:

- *Αυτόματη Αναγνώριση Ομιλίας (Kiranyaz et al., 2021)* Η αυτόματη αναγνώριση ομιλίας σε πραγματικό χρόνο (ASR) είναι ο απώτερος στόχος για πολλές δεκαετίες από τις αρχές του 20ου αιώνα. Στόχος της αυτόματης μεταγραφής ομιλίας σε (γραπτό) κείμενο είναι η ανάπτυξη μεθόδων που βασίζονται σε βαθιά NN για την Αυτόματη Αναγνώριση Ομιλίας (ASR). Φυσικά, αυτό είναι ένα δύσκολο έργο, καθώς ένα ανθρώπινο σήμα ομιλίας παρουσιάζει υψηλό επίπεδο παραλλαγών μεταξύ διαφορετικών ομιλητών και η εργασία γίνεται ακόμη πιο δύσκολη όταν υπάρχει ένα ορισμένο επίπεδο περιβαλλοντικού θορύβου ή όταν το στυλ ομιλίας ποικίλλει. Η γενική προσέγγιση είναι να χρησιμοποιηθούν φασματογράμματα ως εικόνες, με την χρήση βαθιών CNN, για τη διάκριση των φωνητικών μοτίβων. Τα κρυφά στρώματα των βαθιών CNN μπορούν να μετατρέψουν μεγαλύτερα περιβάλλοντα στην ομιλία, ώστε να αναγνωριστούν πιο αφηρημένα μοτίβα. Παράλληλα, η εκπαίδευση του πολυεπίπεδου μοντέλου ASR γίνεται μέσω του αλγορίθμου *backpropagation*, με σκοπό την ελαχιστοποίηση του σφάλματος σε κάθε στρώμα. Τα πρώτα επίπεδα των

CNN μπορούν να ανιχνεύουν απλά μοτίβα πιο κοντά στο επίπεδο εισόδου, ενώ τα τελευταία επίπεδα μπορούν να ανιχνεύσουν πιο σύνθετα μοτίβα που είναι ευρύτερα. Για να γίνει αυτό, χρησιμοποιούνται οι βασικές πληροφορίες που είναι διαθέσιμες εκ των προτέρων. Τα *deep CNN* μπορούν να εκμεταλλευτούν αποτελεσματικά τις πληροφορίες μεγαλύτερης εξάρτησης σε άξονες χρόνου και συχνότητας χρησιμοποιώντας μικρότερους πυρήνες σε συνδυασμό με περισσότερα επίπεδα.

- Παρακολούθηση ηλεκτροκαρδιογραφήματος σε πραγματικό χρόνο (Kiranyaz et al., 2021) Οι αρρυθμικοί καρδιακοί παλμοί αποτελούν μία από τις ενδείξεις καρδιαγγειακού προβλήματος, ενώ οι καρδιαγγειακές ασθένειες είναι μία από τις κύριες αιτίες θανάτων παγκοσμίως. Η ηλεκτροκαρδιογραφία (ΗΚΓ) είναι η κύρια μέθοδος παρακολούθησης και αξιολόγησης της καρδιακής υγείας από τους ιατρούς, καθώς ανιχνεύει την ηλεκτρική δραστηριότητα του καρδιακού μυ. Η οπτική ανάλυση και επιθεώρηση των σημάτων ΗΚΓ από Καρδιολόγους είναι χρονοβόρα, υποκειμενική και δυσκολεύει την έγκαιρη ανίχνευση πιθανής καρδιακής απειλής. Γι' αυτό, η αυτοματοποιημένη παρακολούθηση και ανάλυση της ΗΚΓ σε πραγματικό χρόνο με μια ακριβή και ισχυρή προσέγγιση μηχανικής μάθησης επιτρέπει την ανίχνευση των καρδιακών ανωμαλιών με μεγάλη ακρίβεια και αποτελεσματικότητα. Μετά την εκμάθηση του υγιούς ατόμου (πραγματικό) με κανονικούς παλμούς και πιθανούς (συντεθειμένους) μη φυσιολογικούς παλμούς, το προτεινόμενο σύστημα με CNN μπορεί στη συνέχεια να χρησιμοποιηθεί για την ανίχνευση τυχόν μη φυσιολογικών παλμών που μπορεί να εμφανιστούν κατά την παρακολούθηση. Η αυτοματοποιημένη ανάλυση των καρδιακών σημάτων απαιτεί μια ισχυρή, ακριβή και πραγματικού χρόνου προσέγγιση μηχανικής μάθησης. Σύμφωνα με την προτεινόμενη μέθοδο, η οποία δεν χρειάζεται τη χρήση πραγματικών μη φυσιολογικών παλμών στην προπόνηση, επιτυγχάνεται ένα επίπεδο ακρίβειας $Acc = 80,1\%$, με ποσοστό ψευδών συναγερμών $FAR = 0,43\%$. Ως

αποτέλεσμα, η πιθανότητα να χάσετε τον πρώτο μη φυσιολογικό ρυθμό είναι 0,199 και η πιθανότητα να χαθούν τρεις διαδοχικοί μη φυσιολογικοί παλμοί είναι περίπου 0,0079. Επομένως, η ανίχνευση ενός ή περισσότερων μη φυσιολογικών παλμών μεταξύ των τριών πρώτων εμφανίσεων είναι πολύ πιθανή, με πιθανότητα πάνω από 99,2%.

- *Βλάβες Ρουλεμάν (Kiranyaz et al., 2021).* Τα ρουλεμάν είναι αναπόσπαστα μέρη των περιστρεφόμενων μηχανών και αποτελούν το σύνδεσμο μεταξύ των εσωτερικών σταθερών στηρίξεων και των περιστρεφόμενων εξαρτημάτων. Η λειτουργία των ρουλεμάν επηρεάζει όχι μόνο την απόδοσή τους, αλλά και τη συνολική ακρίβεια, αξιοπιστία και διάρκεια ζωής των περιστρεφόμενων μηχανημάτων. Οι βλάβες των ρουλεμάν είναι κοινές και μπορούν να οδηγήσουν σε απώλεια απόδοσης και κίνδυνο ασφαλείας. Είναι σημαντικό να διατηρούνται σε καλή κατάσταση και να ελέγχονται τακτικά για τη διασφάλιση της αποτελεσματικής λειτουργίας τους. Η έγκαιρη ανίχνευση σφαλμάτων ρουλεμάν με αξιολόγηση της κατάστασης σε πραγματικό χρόνο μέσω ενσωματωμένων αισθητήρων, έχει τη δυνατότητα να επιτρέψει την αντικατάσταση των εξαρτημάτων ρουλεμάν, αντί για δαπανηρές αντικαταστάσεις ολόκληρης της ομάδας μηχανών. Ενώ υπήρχαν μέθοδοι που αποκαλύπτουν την ύπαρξη ελαττωμάτων στο εσωτερικό των ρουλεμάν, δεν ήταν ικανές να εντοπίσουν το ελάττωμα. Τα CNN έχουν δείξει ότι η παρακολούθηση σε πραγματικό χρόνο και η στιγμιαία ανίχνευση ανωμαλιών μπορεί να επιτευχθεί με επίπεδο ακρίβειας τελευταίας τεχνολογίας καθώς ανιχνεύουν ανωμαλίες σε πραγματικό χρόνο με ακρίβεια σχεδόν 100% χάρη στην αποσύνθεση της υποζώνης σε στρώσεις που εκτελείται στα κρυφά τους στρώματα CNN.
- *Μετατροπείς Ισχύος.* Μια πρόσφατη εφαρμογή CNN που έχει χρησιμοποιηθεί εκτενώς είναι η εφαρμογή της σε μετατροπείς πολλαπλών επιπέδων υψηλής ισχύος για την αποτελεσματική μετατροπή ισχύος. Παρόλο που υπάρχουν άλλες μέθοδοι για την ανίχνευση ανωμαλιών σε κυκλώματα μετατροπείς, πολλές από

αυτές περιέχουν περιορισμούς και μειονεκτήματα που μπορεί να εμποδίσουν την πρακτική χρήση τους.

Σε αυτή την εφαρμογή, συμπαγείς CNN χρησιμοποιούνται για να παρακολουθούν τις τάσεις του πυκνωτή κυψέλης και το διαφορικό ρεύμα για την ανίχνευση μιας ανωμαλίας ανοιχτού κυκλώματος σχεδόν αμέσως. Η ακρίβεια του συστήματος είναι πολύ υψηλή (περίπου 100%) στην ανίχνευση σφαλμάτων και αναγνώριση, ενώ παράλληλα εμφανίζει εξαιρετική αξιοπιστία και στιβαρότητα έναντι των διακυμάνσεων των παραμέτρων μετατροπών και του χρόνου σφάλματος. Επιπλέον, το σύστημα είναι χαμηλής υπολογιστικής πολυπλοκότητας, επιτρέποντας την παρακολούθηση σε πραγματικό χρόνο και χαμηλή χρονική καθυστέρηση για τον εντοπισμό και την αναγνώριση σφαλμάτων (λιγότερο από 0,1 δευτερόλεπτα).

Η εκ του μηδενός δημιουργία ενός μοντέλου CNN είναι πολλές φορές πέραν της τεχνογνωσίας πολλών ερευνητών. Για το λόγο αυτό, είναι θεμιτό να χρησιμοποιούνται υπάρχοντα πλαίσια ή βιβλιοθήκες βαθιάς μάθησης για γρήγορη υλοποίηση χωρίς εξειδίκευση στον τομέα. Υπάρχει μια μεγάλη ποικιλία διαθέσιμων βιβλιοθηκών βαθιάς μάθησης για σχεδιασμό και υλοποίηση μοντέλων CNN για διάφορες εφαρμογές. Επίσης, αυτές οι βιβλιοθήκες είναι συμβατές με δημοφιλείς γλώσσες προγραμματισμού όπως Python, R, MATLAB, Lua, Java και C++. Ωστόσο, οι βιβλιοθήκες Python έχουν γίνει πιο δημοφιλείς στην έρευνα. Πολλές από τις βιβλιοθήκες είναι χτισμένες στη βάση άλλων βιβλιοθηκών (Balwant, 2022).

Οι Muhammad et al. (2018) παρουσιάζουν μια μελέτη για την ανίχνευση επιληπτικών κρίσεων σε ένα πλαίσιο πολυμέσων για κινητά, χρησιμοποιώντας 1-D και 2-D CNN για την εξαγωγή χαρακτηριστικών βαθιάς μάθησης από τα σήματα EEG. Στη μελέτη χρησιμοποιήθηκε το SVM για ταξινόμηση και έτσι πέτυχε ακρίβεια 99,02% σε

περιπτώσεις μεταξύ ασθενών χρησιμοποιώντας τη βάση δεδομένων CHB-MIT. Το προτεινόμενο σύστημα χρησιμοποίησε συνεισφορές διαφορετικών ζωνών και εξήγαγε χαρακτηριστικά ξεχωριστά, πετυχαίνοντας καλύτερη ακρίβεια σε σύγκριση με άλλα συστήματα στη βιβλιογραφία. Η χρονική σχέση στο σήμα ΗΕΓ καταγράφηκε από την 1D συνέλιξη, ενώ η χωρική σχέση κωδικοποιήθηκε από τις 2-D συνελίξεις. Αυτός ο χρονικο-χωρικός συνδυασμός έκανε το σύστημα ανθεκτικό στην ανίχνευση επιληπτικών κρίσεων. Μια ομάδα ερευνητών ανέπτυξε ένα ακόμα μοντέλο CNN για την ανίχνευση αιχμών στο ΗΕΓ πέντε επιληπτικών ασθενών (Johansen et al., 2016). Το μοντέλο χρησιμοποίησε τη συνάρτηση ενεργοποίησης Leaky ReLU και τα αποτελέσματα έδειξαν ότι το CNN ήταν ανώτερο σε απόδοση σε σύγκριση με τους μηχανικούς ταξινομητές. Στη συνέχεια, οι Antoniadou et al. (2016), χρησιμοποίησαν επίσης το CNN για την αυτόματη εξαγωγή χαρακτηριστικών στο πεδίο του χρόνου-συχνότητας στα ΗΕΓ επιληπτικών ασθενών και κατέληξαν σε ακρίβεια 87% στο δικό τους σύνολο δεδομένων. Παράλληλα οι Li et al. (2016), προτείνουν την accelerated proximal gradient μέθοδο για την αύξηση της αναλογίας προπόνησης. Απέφεραν ότι πέτυχαν ένα ιδανικό ποσοστό ακρίβειας για τη διάγνωση της επιληψίας και τη γρήγορη σύγκλιση του CNN. Ισχυρίστηκαν 99% ακρίβεια στα δεδομένα τους. Ταυτόχρονα, οι Supratak, Li & Guo (2014), χρησιμοποίησαν στοιβαγμένους αυτοκωδικοποιητές με λογιστικούς ταξινομητές για την ανίχνευση επιληπτικών κρίσεων σε συγκεκριμένο ασθενή στο σύνολο δεδομένων CHBMIT. Η μέθοδος έμαθε αυτόματα χαρακτηριστικά από ακατέργαστα μη επισημασμένα δεδομένα ΗΕΓ. Αναφέρθηκε μέση καθυστέρηση 3,36 δευτερολέπτων και χαμηλό ποσοστό ψευδούς ανίχνευσης. Επιπλέον, οι Qi et al. (2014) προτείνουν έναν ισχυρό αυτοκωδικοποιητή στοίβαξης για την εκμάθηση αποτελεσματικών

χαρακτηριστικών και μιας μέγιστης συνάρτησης αντιστοιχίας, η οποία χρησιμοποιήθηκε για τη μείωση των τεχνουργημάτων θορύβου. Η μέθοδος αξιολογήθηκε σε δεδομένα ΗΕΓ του τριχωτού της κεφαλής και ανέφερε 100% ευαισθησία και 99% ειδικότητα.

Στην έρευνα των Yan et al. (2016), χρησιμοποιήθηκε αυτόματος κωδικοποιητής και SVM για την ανίχνευση επιληπτικών κρίσεων στο σύνολο δεδομένων επιληψίας UBonn. Οι ερευνητές ισχυρίστηκαν ότι η ακρίβεια ήταν στο 98%. Επίσης, οι Gogna, Majumdar & Ward (2016), ανέπτυξαν μια κοινή λύση ανάλυσης και ανακατασκευής σήματος ΗΕΓ μέσω ενός ημι-εποπτευόμενου στοιβαγμένου αυτόματου κωδικοποιητή. Οι τεχνικές ανακατασκευής βασίζονται σε συμπιεσμένη αίσθηση, αλλά απαιτούν αρκετά μεγάλα σύνολα δεδομένων εκπαίδευσης. Τέλος, οι Thodoroff, Pineau & Lim (2016), μετέτρεψαν τα σήματα ΗΕΓ σε εικόνες προβάλλοντας τα ηλεκτρόδια του ασθενούς σε 2 διαστάσεις.

Οι Amin et al. (2020) προτείνουν στη μελέτη τους ένα μοντέλο σύντηξης CNN πολλαπλών επιπέδων για ταξινόμηση εικόνων κίνησης εγκεφάλου (Brain Motor Imagery). Η συγχώνευση χαρακτηριστικών πραγματοποιήθηκε με θεματικές αλλά και με διαθεματικές προσεγγίσεις. Τα αποτελέσματα δείχνουν ότι το CNN είναι καλύτερο από τα συμβατικά μοντέλα μηχανικής μάθησης όπως το FBCSP. Η προ-εκπαίδευση βοήθησε στη βελτίωση της ακρίβειας και στην αποτροπή της υπερβολικής προσαρμογής του μοντέλου. Η εκπαίδευση με αυτόματο κωδικοποιητή μεταξύ θεμάτων βοήθησε στην εύρεση διακριτικών χαρακτηριστικών για το ίδιο θέμα καθώς και για διαφορετικά θέματα. Επομένως, το μοντέλο σύντηξης μπόρεσε να βρει διαφορές σε διαφορετικές δοκιμές που ανήκουν στο ίδιο υποκείμενο και δοκιμές που ανήκουν σε διαφορετικά άτομα. Το μοντέλο σύντηξης προτάθηκε για να δείξει ότι με προσαρμοσμένη σύντηξη τα μοντέλα CNN μπορούν να επιτύχουν καλά αποτελέσματα και μπορούν να εξάγουν

χωρικά αμετάβλητα χαρακτηριστικά από δεδομένα εικόνων κίνησης και ως εκ τούτου μπορούν να εφαρμοστούν και για άλλους τύπους σημάτων HEG.

Τα τελευταία χρόνια έχουν διεξαχθεί διάφορες έρευνες σχετικά με τη χρήση τεχνικών τεχνητής νοημοσύνης για διάγνωση και ερμηνεία σχιζοφρένειας μέσω σημάτων HEG για την αντιμετώπιση αυτής της πρόκλησης. Αυτές οι μέθοδοι προτείνονται για να βοηθήσουν τους γιατρούς και τους νευρολόγους με μια γρήγορη και ακριβή διάγνωση της διαταραχής. Στη μελέτη των *Shoeibi et al. (2021)*, το σύνολο δεδομένων αποτελούνταν από δεδομένα HEG φυσιολογικών ατόμων και ασθενών με σχιζοφρένεια. Χρησιμοποιήθηκαν διάφορες μέθοδοι CNN με διαφορετικές συναρτήσεις ενεργοποίησης. Το μοντέλο που χρησιμοποιήθηκε παρουσίασε μεγαλύτερη ακρίβεια σε σύγκριση με τη συντριπτική πλειονότητα μεθόδων από άλλες μελέτες και θα μπορούσε να εφαρμοστεί σε ειδικές πλατφόρμες λογισμικού και υλικού για γρήγορη διάγνωση σχιζοφρένειας μέσω σημάτων HEG και να χρησιμοποιηθεί ως βοηθητική μέθοδος διάγνωσης σε νοσοκομεία. Ακόμα, άρθρο των *Khare et al. (2021)*, διερευνά την απόδοση διαφόρων μεθόδων χρονικής συχνότητας και μοντέλων που βασίζονται στο CNN. Το προτεινόμενο μοντέλο CNN με τέσσερα συνελκτικά επίπεδα όχι μόνο πέτυχε την υψηλότερη ακρίβεια μεταξύ άλλων δικτύων που βασίζονται στο CNN, αλλά είναι επίσης υπολογιστικά αποδοτικό και γρήγορο.

Ενδιαφέρον παρουσιάζει και η μελέτη αναγνώρισης συναισθημάτων μέσω HEG. Σε ένα άρθρο από τους *Keelawat et al. (2021)*, εξετάστηκαν οι επιπτώσεις του μεγέθους

παραθύρου και της ταξινόμησης των ηλεκτροδίων στην απόδοση του CNN για την αναγνώριση συναισθημάτων από τα σήματα HEG δώδεκα ατόμων. Τα αποτελέσματα έδειξαν ότι η αύξηση του μεγέθους παραθύρου βελτίωσε τη μέση ακρίβεια. Μεγαλύτερο μέγεθος παραθύρου μπορεί να μειώσει τη μεταβλητότητα μεταξύ των θεμάτων και, κατά συνέπεια, να βελτιώσει την απόδοση της ταξινόμησης συναισθημάτων. Επιπλέον, οι ερευνητές εξέτασαν διαφορετικές αρχιτεκτονικές του CNN και αξιοποίησαν τα μέσα αποτελέσματα. Όσον αφορά τη διάταξη των ηλεκτροδίων, οι αλγόριθμοι ταξινόμησης που δοκιμάστηκαν στη μελέτη φάνηκε να έχουν μόνο ασήμαντη επίδραση στην απόδοση. Επιπλέον, σε εργασία των Sheykhivand et al. (2020), παρουσιάζεται μια μέθοδος για την αναγνώριση συναισθημάτων χρησιμοποιώντας συγχώνευση των δικτύων CNN και LSTM. Όπως παρατηρήθηκε, η σύντηξη αυτών των δικτύων αυξάνει την ακρίβεια και τη σταθερότητα του προτεινόμενου αλγορίθμου με ακρίβεια 97,42% και 95,23% για 2 σταδίων και 3 σταδίων συναισθήματος για 12 ενεργά κανάλια. Κάτι τέτοιο είναι πολλά υποσχόμενο σε σύγκριση με τις προηγούμενες προσεγγίσεις αναγνώρισης συναισθημάτων που βασίζονται σε ταξινομήσεις MLP και DBM. Επιπρόσθετα, σε εργασία των Yang et al. (2019), παρουσιάζεται ένα δομημένο μοντέλο πολλαπλών στηλών για την αναγνώριση συναισθημάτων. Κάθε στοιχείο του μοντέλου είναι μια μονάδα αναγνώρισης συναισθημάτων που βασίζεται σε CNN με διάφορα επίπεδα μετατροπής, συγκέντρωσης και πλήρως συνδεδεμένων επιπέδων με είσοδο δεδομένα σήματος HEG. Το μοντέλο καταγράφει μεγαλύτερη ακρίβεια από τα υπάρχοντα μοντέλα. Επίσης, οι Hwang et al. (2019), προτείνουν τη δική τους πρακτική για την αναγνώριση συναισθημάτων με βάση το HEG χρησιμοποιώντας τη βαθιά μάθηση. Τα πειραματικά αποτελέσματα καταδεικνύουν ότι το δίκτυό τους ξεπερνά τις άλλες μεθόδους στο σύνολο δεδομένων SEED (το σύνολο δεδομένων SEED είναι καλά σχεδιασμένο για εργασία ταξινόμησης συναισθημάτων που βασίζεται στο HEG από

προσεγγίσεις μηχανικής μάθησης ή βαθιάς μάθησης), το οποίο περιλαμβάνει σήματα ΗΕΓ καναλιών τριών συναισθηματικών καταστάσεων (θετική, ουδέτερη, αρνητική) που καταγράφηκαν από 15 συμμετέχοντες.

Τα αποτελέσματα της προσέγγισης σε δύο διαφορετικές ημερομηνίες καταγραφής δείχνουν ακρίβεια της τάξης του 91,68% και 89,14%, με τυπική απόκλιση 8,46% και 8,94%, αντίστοιχα. Ειδικότερα, οι θετικές ετικέτες διακρίνονται σε μεγάλο βαθμό στο 96% από τις άλλες καταστάσεις. Η προτεινόμενη μέθοδος μπορεί να επεκταθεί στην αλληλεπίδραση ανθρώπου-μηχανής (HMI), εγκεφάλου-υπολογιστή (BCI) και ανθρώπου-υπολογιστή (HCI).

Σε έρευνα των Sandheer et al. (2019), πραγματοποιείται η ανάλυση απόδοσης CNN βαθιάς μάθησης στην ταξινόμηση των σημάτων ΗΕΓ από ασθενείς με κατάθλιψη και υγιείς. Το βαθύ CNN που εκπαιδεύτηκε χρησιμοποιώντας σήματα ΗΕΓ από 30 υγιή και 30 άτομα με κατάθλιψη οδήγησε στην ταξινόμηση της κατάθλιψης με την υψηλότερη ακρίβεια 99,31% από σήματα ΗΕΓ από το δεξί ημισφαίριο του εγκεφάλου και 96,3% από το αριστερό. Επίσης, η ικανότητα αξιολόγησης του βάθους της αναισθησίας έχει μελετηθεί και βελτιωθεί τα τελευταία χρόνια, ωστόσο σπάνια CNN με πολύ ισχυρές μαθησιακές ικανότητες έχουν εφαρμοστεί για την αξιολόγηση του βάθους της αναισθησίας. Οι Liu et al., (2019), πραγματοποιούν ποιοτική ανάλυση της αξιολόγησης των τριών επιπέδων αναισθησίας χρησιμοποιώντας CNN και μηχανική ελάχιστων χαρακτηριστικών. Αυτή η πρόταση δείχνει ότι έχει καλή σχέση με τα χαρακτηριστικά του

βάθους της αναισθησίας στα σήματα HEG, γεγονός που ανοίγει ευκαιρίες για ένα ασφαλέστερο διεγχειρητικό περιβάλλον μέσω της κατασκευής μιας απλής συσκευής πρόβλεψης βάθους αναισθησίας.

Με βάση έρευνα των *Plis et al. (2014)*, τα CNN έχουν υψηλές δυνατότητες σε εφαρμογές νευροαπεικόνισης. Ακόμη και τα «ρηχά» δίκτυα ενός μόνο επιπέδου αποδεικνύονται ανταγωνιστικά με το μοντέλο που χρησιμοποιείται συνήθως στο πεδίο, αφού παράγει χαρακτηριστικά με φυσιολογική σημασία που είναι (επιθυμητά) πολύ εστιακά και έχουν διασταυρούμενες συσχετίσεις χρονικής πορείας που τα συνδέουν σε σημαντικές λειτουργικές ομάδες. Ακόμα, διαπιστώνουν πως το βάθος του δικτύου βοηθά στην ταξινόμηση και αυξάνει το διαχωρισμό των ομάδων. Αυτό είναι εμφανές σε δύο σύνολα δεδομένων sMRI που συλλέγονται υπό διαφορετικές συνθήκες, σε πολλαπλές θέσεις το καθένα, από διαφορετικές ομάδες ασθενειών και έχουν υποστεί διαφορετική προεπεξεργασία. Επιπλέον, η μελέτη τους δείχνει ένα υψηλό δυναμικό των δικτύων για διερευνητική ανάλυση, αφού σε συνδυασμό με νέες μεθόδους χαρτογράφησης τα CNN μπορεί να αποκαλύψουν κρυφές σχέσεις στα δεδομένα. Ακόμα, οι *Li & Feng (2019)*, πραγματοποιούν αποτελεσματικά εξαγωγή χαρακτηριστικών και ταξινόμηση σημάτων HEG στην έρευνά τους με χρήση CNN. Τα αποτελέσματά τους αποκαλύπτουν ότι η μέθοδος απαιτεί σχετικά λίγους πόρους και έχει σχετικά υψηλή ακρίβεια, επομένως έχει ιδιαίτερη αξία για την επίλυση ανάλογων προβλημάτων. Ακόμα, τα αποτελέσματά των *Krizhevsky, Sutskever & Hinton (2017)* δείχνουν ότι ένα μεγάλο, βαθύ συνελικτικό νευρωνικό δίκτυο είναι ικανό να επιτύχει αποτελέσματα ρεκόρ σε ένα εξαιρετικά απαιτητικό σύνολο δεδομένων χρησιμοποιώντας καθαρά εποπτευόμενη μάθηση. Είναι αξιοσημείωτο ότι η απόδοση του δικτύου υποβαθμίζεται

εάν αφαιρεθεί ένα μόνο συνελικτικό επίπεδο. Παράλληλα οι Bashivan et al. (2016), προτείνουν μια νέα μεθοδολογία εκμάθησης αναπαραστάσεων από πολυκαναλικές χρονοσειρές ΗΕΓ με βαθιά νευρωνικά δίκτυα. Η προτεινόμενη προσέγγιση καταδεικνύει σημαντικές βελτιώσεις στην ακρίβεια ταξινόμησης σε σχέση με τα τελευταία τεχνολογίας αποτελέσματα και μπορεί να εφαρμοστεί σε δεδομένα ΗΕΓ που αποκτήθηκαν με διαφορετικό υλικό (π.χ. με διαφορετικό αριθμό ηλεκτροδίων). Οι μόνες πληροφορίες που απαιτούνται για την ολοκλήρωση αυτού του μετασχηματισμού είναι οι χωρικές συντεταγμένες των ηλεκτροδίων για κάθε εγκατάσταση. Τέλος οι Cecotti & Graeser (2009), παρουσίασαν ένα νέο μοντέλο που βασίζεται σε ένα CNN το οποίο ενσωματώνει ανάμεσα σε 2 κρυφά επίπεδα τον μετασχηματισμό Fourier, ο οποίος αλλάζει τη σημασιολογική του επιπέδου από την ανάλυση του πεδίου χρόνου στην ανάλυση του τομέα συχνότητας. Αυτή η μέθοδος επιτρέπει επίσης την αυτόματη δημιουργία καναλιών και τη λειτουργία γραμμικών φίλτρων χρόνου στο χρήστη και τις διακριτικές τους δυνάμεις για την ταξινόμηση του σήματος. Το προτεινόμενο κριτήριο απόρριψης είναι επιτυχές και επιτρέπει υψηλή αξιοπιστία. Το μοντέλο έχει επικυρωθεί για την ταξινόμηση του σήματος ΗΕΓ σε ένα σύστημα BCI με βάση τις αποκρίσεις SSVEP.

3.4 Εφαρμογές Μικροσκοπικής Μάθησης σε Νευρωνικά Δίκτυα.

Οι προσομοιώσεις των παραδειγμάτων βιολογικών υπολογιστών που εφαρμόζονται από τα TND έχουν πολύ καλά αποτελέσματα για πολλά είδη προβλημάτων. αυτά είναι • Η κατηγορία των NP προβλημάτων τα οποία περιλαμβάνουν προβλήματα δρομολόγησης, αναζήτησης κτλπ

- Η κατηγορία προβλημάτων αναγνώρισης π.χ αναγνώριση φωνής, εικόνας
- Η κατηγορία ελέγχου των οποίων τα δεδομένα είναι ελλιπή και ασαφή

- Όλα αυτά τα προβλήματα χαρακτηρίζονται από πολυδιάστατο χώρο, πολυπλοκότητα και άγνωστες συσχετίσεις μεταξύ των μεταβλητών. Επιπλέον, όπως φαίνεται παρακάτω, τα TND παρέχουν κυρίως λύσεις σε προβλήματα που σχετίζονται με ανθρώπινους παράγοντες, όπως η αναγνώριση φωνής και εικόνας. Συγκεκριμένα, οι περιοχές όπου τα νευρωνικά δίκτυα παρέχουν ικανοποιητικές λύσεις είναι οι εξής:
- Επεξεργασία εικόνας και μηχανική όραση π.χ ταίριασμα εικόνας,
- Επεξεργασία σήματος π.χ ανάλυση σεισμικού σήματος
- Αναγνώριση προτύπων π.χ εξαγωγή χαρακτηριστικών με βάση βιομετρικά χαρακτηριστικά,
- Οικονομία π.χ ανάλυση αγοράς μετοχών , εκτίμηση φερεγγυότητας δανειζόμενου πελάτη
- τεχνητή νοημοσύνη π.χ υλοποίηση έμπειρων συστημάτων
- Πρόβλεψη χρονοσειρών
- Επικοινωνία ανθρώπου υπολογιστή.

Δεδομένου ότι το νευρωνικό δίκτυο είναι ένα αντικείμενο που δεν έχει διερευνηθεί διεξοδικά ως υπολογιστικό μοντέλο επειδή είναι σχετικά νέο, πρέπει να τονίσουμε τα πλεονεκτήματα και τα μειονεκτήματα σε σύγκριση με τις παραδοσιακές υπολογιστικές μεθόδους. Οι προσδοκίες σε αυτόν τον τομέα είναι υψηλές. Σε γενικές γραμμές, οι πολυεθνικές εταιρείες είναι κατάλληλες για την επίλυση συγκεκριμένων τύπων προβλημάτων, ειδικά εκπαιδευτικών προβλημάτων που επιλύονται μέσω τυπικής συνάφειας. Η ιδέα ότι οι πολυεθνικές εταιρείες μπορούν να λύσουν όλα τα εκπαιδευτικά προβλήματα δεν είναι ρεαλιστική. Αφενός, τα κύρια πλεονεκτήματά τους είναι τα εξής: “ Έμφυτος προγραμματισμός • Ανοχή σε βλάβες λόγω του παραλληλισμού • Σχεδιασμένα να είναι προσαρμοζόμενα • Δεν υπάρχει η ανάγκη για χαρακτηρισμό του προβλήματος πέρα από το σύνολο των προτύπων εκπαίδευσης Τα αρνητικά τους είναι όμως τα εξής: •

Δεν υπάρχουν σαφείς κανόνες για την ανάπτυξη ΤΝΔ για οποιαδήποτε εφαρμογή • Δεν υπάρχει γενικός τρόπος για την ερμηνεία της εσωτερικής λειτουργίας του δικτύου • Η εκπαίδευση μπορεί να είναι αδύνατη ή πολύ δύσκολη • Η ικανότητα γενίκευσης είναι δύσκολα προβλέψιμη.

Ο νευρομορφικός υπολογισμός χρησιμοποιεί ένα σύστημα ολοκλήρωσης πολύ μεγάλης κλίμακας (VLSI) που περιέχει ηλεκτρονικά αναλογικά κυκλώματα για την προσομοίωση της νευροβιολογικής αρχιτεκτονικής που υπάρχει στο νευρικό σύστημα. Ένας νευρομορφικός υπολογιστής/τσιπ είναι κάθε συσκευή που χρησιμοποιεί φυσικούς τεχνητούς νευρώνες (από πυρίτιο) για υπολογισμούς. Πρόσφατα, ο όρος νευρομορφολογία έχει χρησιμοποιηθεί για να περιγράψει αναλογικά, ψηφιακά, μικτά αναλογικά/ψηφιακά VLSI και τυπικά συστήματα λογισμικού (για αντίληψη ή πολυαισθητηριακή ολοκλήρωση) του νευρικού συστήματος. Η εφαρμογή του νευρομορφικού υπολογισμού σε επίπεδο υλικού μπορεί να επιτευχθεί μέσω μεμρίστορ που βασίζονται σε οξείδια, σπιντρονική μνήμη, διακόπτες κατωφλίου και τρανζίστορ. Μια βασική πτυχή της νευρομορφικής μηχανικής είναι να κατανοήσουμε πώς τα σχήματα μεμονωμένων νευρώνων, κυκλωμάτων, εφαρμογών και συνολικής αρχιτεκτονικής δημιουργούν τους απαιτούμενους υπολογισμούς, επηρεάζουν τον τρόπο έκφρασης των πληροφοριών, επηρεάζουν την ευρωστία της βλάβης, ενσωματώνουν τη μάθηση και την τοπική ανάπτυξη και προσαρμόζονται σε αλλαγές (Πλαστικότητα) και προωθούν την εξελικτική αλλαγή.

Ο νευρομορφικός υπολογισμός εμπνέεται από την κατανόησή μας για τη δομή και τη λειτουργία του εγκεφάλου και τη μετατροπή της κατανόησής μας για τις λειτουργίες του εγκεφάλου σε γνώση σε συστήματα υπολογιστών. Σε γενικές γραμμές, αυτή η μέθοδος εστιάζει κυρίως στην αναπαραγωγή των παρόμοιων ιδιοτήτων του βιολογικού υπολογισμού και του ρόλου των νευρώνων στις γνωστικές λειτουργίες. Οι βιολογικές

διεργασίες των νευρώνων και των συνάψεων τους είναι εξαιρετικά περίπλοκες, επομένως είναι δύσκολο να προσομοιωθούν τεχνητά. Ένα βασικό χαρακτηριστικό του βιολογικού εγκεφάλου είναι ότι όλη η επεξεργασία στους νευρώνες χρησιμοποιεί αναλογικά χημικά σήματα. Αυτό καθιστά δύσκολη την αναπαραγωγή του εγκεφάλου σε έναν υπολογιστή, επειδή η τρέχουσα γενιά υπολογιστών είναι εντελώς ψηφιακή. Ωστόσο, τα χαρακτηριστικά αυτών των τμημάτων μπορούν να ληφθούν μέσω μαθηματικών συναρτήσεων, οι οποίες συλλαμβάνουν στενά την ουσία της λειτουργίας των νευρώνων. Ο στόχος της νευρομορφικής επιστήμης των υπολογιστών δεν είναι η τέλεια μίμηση του εγκεφάλου και όλων των λειτουργιών του, αλλά η εξαγωγή γνωστών πληροφοριών σχετικά με τη δομή και τη λειτουργία του για χρήση σε πραγματικά συστήματα υπολογιστών. Κανένα νευρομορφικό σύστημα δεν θα ισχυριστεί ή θα προσπαθήσει να αναπαραγάγει κάθε στοιχείο νευρώνων και συνάψεων, αλλά όλοι επιμένουν ότι οι υπολογισμοί κατανέμονται σε μεγάλο βαθμό σε μια σειρά μικρών υπολογιστικών στοιχείων παρόμοια με τους νευρώνες. Αν και αυτό το συναίσθημα είναι τυπικό, οι ερευνητές επιδιώκουν αυτόν τον στόχο με διαφορετικούς τρόπους.

ΕΡΕΥΝΗΤΙΚΟ ΜΕΡΟΣ

Κεφάλαιο 4

4.1 Βασικές Αρχές και Επισκόπηση Βιβλιογραφίας.

Οι αλγόριθμοι Μηχανικής Μάθησης αποτελούν συχνά το συνδετικό κρίκο ανάμεσα στα χαρακτηριστικά που εξάγονται με τη βοήθεια της Όρασης Υπολογιστών και στον προσδιορισμό της υπό προσδιορισμό της ιδιότητας της φυσικής σκηνής που εξετάζεται. Η συνέργεια Όρασης Υπολογιστών και Μηχανικής Μάθησης αποτελεί μία διεπιστημονική περιοχή η οποία αλληλεπιδρά ενεργά με άλλους επιστημονικούς κλάδους όπως η Τεχνητή Νοημοσύνη, η Ρομποτική, τα Εφαρμοσμένα Μαθηματικά και η Νευροβιολογία. Επιπρόσθετα, αξίζει να σημειωθεί η ισχυρή εξάρτηση των συστημάτων Όρασης Υπολογιστών και Μηχανικής Μάθησης από την ύπαρξη αισθητήρων και καταγραφικών συσκευών που επιτρέπουν τη ζεύξη του αναλογικού με τον ψηφιακό κόσμο και πολλές φορές προσφέρουν πλούσιες μορφές οπτικής πληροφορίας. Ένα παράδειγμα αισθητήρα που έχει διευρύνει σημαντικά τις δυνατότητες των συστημάτων αναγνώρισης ανθρωπίνων δράσεων και χειρονομιών είναι ο αισθητήρας βάθους (π.χ Microsoft Kinect). Αντίστοιχα, ένα παράδειγμα καταγραφικής συσκευής που προσφέρει πλούσια οπτική πληροφορία σχετικά με το εσωτερικό του ανθρώπινου σώματος είναι η μαγνητική τομογραφία (MRI), η οποία μπορεί να αξιοποιηθεί από "έξυπνα" συστήματα βιοιατρικών εφαρμογών που συνδυάζουν τεχνικές τόσο της Όρασης Υπολογιστών όσο και της Μηχανικής Μάθησης. Άλλες ενδιαφέρουσες περιπτώσεις συνέργειας μεταξύ των δύο επιστημονικών περιοχών είναι:


- *Ανάκτηση πληροφορίας (content extraction), ανάλυση του περιεχομένου και κατηγοριοποίηση εικόνων και βίντεο του διαδικτύου με σκοπό τη δημιουργία βάσεων δεδομένων και την εύκολη αναζήτηση και ανάκλησή τους βάσει του περιεχομένου.*
- *Υλοποίηση συστημάτων υποβοηθούμενης διαβίωσης (assisted leaving technology) με σκοπό τη διευκόλυνση ατόμων που αντιμετωπίζουν κινητικές δυσκολίες ή κάποια ασθένεια*
- *Παρακολούθηση συναισθηματικής κατάστασης μέσω της καταγραφής και ανάλυσης της έκφρασης του προσώπου ή/και της στάσης του σώματος ενός ατόμου.*
- *Γρήγορη αλληλεπίδραση οχήματος-οδηγού μέσω χειρονομιών με σκοπό να μην αποσπάται η προσοχή του οδηγού.*

4.2 Τεχνικές για Αναγνώριση Ανθρώπινης Δραστηριότητας- Αναγνώριση Εικόνας.

Η Python είναι μια δημοφιλής γλώσσα προγραμματισμού που χρησιμοποιείται για την ανάλυση δεδομένων, τη μηχανική μάθηση και τους επιστημονικούς υπολογισμούς. Έχει γίνει μια από τις πιο ευρέως χρησιμοποιούμενες γλώσσες προγραμματισμού για την επιστήμη των δεδομένων λόγω της ευελιξίας, της ευκολίας χρήσης και των εκτεταμένων βιβλιοθηκών της. Το Jupyter είναι ένα διαδικτυακό διαδραστικό περιβάλλον ανάπτυξης που παρέχει μια πλατφόρμα για την ανάλυση δεδομένων, τον επιστημονικό υπολογισμό και τη μηχανική μάθηση σε Python. Επιτρέπει στους χρήστες να δημιουργούν, να επεξεργάζονται και να εκτελούν κώδικα σε ένα διαδραστικό περιβάλλον. Επιπλέον, παρέχει μια ποικιλία εργαλείων για την οπτικοποίηση δεδομένων, το οποίο βοηθάει στην κατανόησή τους.

Προκειμένου να σχεδιαστεί και να υλοποιηθεί ένα σύστημα αναγνώρισης δραστηριότητας με βαθιά μάθηση, καθώς και να εφαρμοστεί σε μία πλακέτα, όπως αυτή

του *Arduino*, θα πρέπει να πραγματοποιηθούν συγκεκριμένες διαδικασίες. Το πρώτο βήμα είναι η επιλογή της συσκευής που θα χρησιμοποιηθεί, καθώς και του σημείου στο σώμα για την τοποθέτηση της. Μόλις επιλεγεί το σημείο για τη συσκευή, το επόμενο βήμα είναι η συλλογή των δεδομένων στα οποία θα εκπαιδευτεί το μοντέλο βαθιάς μάθησης. Αφού συλλεχθούν τα δεδομένα, πρέπει να υποστούν προεπεξεργασία για να προετοιμαστούν για την εκπαίδευση του μοντέλου. Το επόμενο βήμα είναι η εκπαίδευση ενός μοντέλου βαθιάς μάθησης στα προεπεξεργασμένα δεδομένα. Στη συνέχεια, το μοντέλο πρέπει να αξιολογηθεί στο σύνολο δοκιμών για να μετρηθεί η απόδοσή του. Τέλος, για την ανάπτυξη του μοντέλου βαθιάς μάθησης στο *Arduino*, το μοντέλο πρέπει να μετατραπεί σε μορφή που να μπορεί να εκτελεστεί στον μικροελεγκτή. Το μετατρεπόμενο μοντέλο μπορεί στη συνέχεια να μεταφορτωθεί στο *Arduino* και να ενσωματωθεί με τους αισθητήρες.



Διάγραμμα 4.2 : Μεθοδολογία Υλοποίησης Συστήματος.

Η επιλογή της συσκευής αποτέλεσε σημαντικό ρόλο στην υλοποίηση της πτυχιακής. Η πλακέτα *Arduino Nano 33 BLE Sense*, οι ενσωματωμένοι αισθητήρες, αλλά και η συνδεσιμότητα *Bluetooth*, βοήθησαν στην πραγματοποίηση της ιδέας. Επίσης, το μικρό μέγεθος της πλακέτας κατέγραψε Το περπάτημα (*walking*), το τρέξιμο (*running*), η

στιγμή που στεκόμαστε όρθιοι (standing), αλλά και καθιστοί (sitting). Οι δραστηριότητες αυτές περιλαμβάνουν κυρίως κινήσεις του κάτω μέρους του σώματος. Έπειτα από πολλαπλές δοκιμές για την συλλογή των δεδομένων από διάφορα σημεία του σώματος, εξακριβώθηκε πως τα καλύτερα αποτελέσματα ήρθαν όταν οι αισθητήρες της συσκευής ήταν σε κάποιο σημείο κάτω από την μέση. Επομένως, η συσκευή αποφασίστηκε να τοποθετηθεί ψηλά στο πόδι.

Για τη συλλογή δεδομένων με τη χρήση των αισθητήρων IMU στο Arduino Nano 33 BLE Sense, η πλακέτα έπρεπε πρώτα να προγραμματιστεί για να διαβάζει τις τιμές του επιταχυνσιομέτρου και του γυροσκοπίου, ώστε να τις αποθηκεύει σε κάποιο αρχείο.

Αυτό επιτεύχθηκε χρησιμοποιώντας το Arduino IDE. Εκεί, δημιουργήθηκε ένα σκίτσο (sketch) Arduino που, με την βοήθεια της ενσωματωμένης βιβλιοθήκης αισθητήρων ολοκλήρωσε την διασύνδεση με τους αισθητήρες και τη συλλογή των δεδομένων. Το σκίτσο ρυθμίστηκε, μέσω κώδικα ώστε να παίρνει δείγματα από τους αισθητήρες σε συγκεκριμένη συχνότητα ή να ενεργοποιείται από συγκεκριμένο εύρος κίνησης, έχοντας προκαθορισμένη ευαισθησία στους αισθητήρες.

```

#include <Arduino_LSM9DS1.h> //necessary library for IMU

const float accelerationThreshold = 1.4; //threshold of significant motion
const int numSamples = 1000; //samples gathered per 10 seconds

int samplesRead = numSamples; //a value for each sample

void setup() {
  Serial.begin(9600); //start serial monitor
  while (!Serial); //start the process when serial monitor is open

  if (!IMU.begin()) { // print a message if IMU fails to start
    Serial.println("Failed to initialize IMU!");
    while (1);
  }
}

void loop() {
  float aX, aY, aZ, gX, gY, gZ; //variables for 3-axis accelerometer
  char action[] = "standing"; // and 3-axis gyroscope

  // wait for significant motion
  while (samplesRead == numSamples) {
    if (IMU.accelerationAvailable()) {
      // read the acceleration data
      IMU.readAcceleration(aX, aY, aZ);

      // sum up the absolutes
      float aSum = fabs(aX) + fabs(aY) + fabs(aZ);

      // check if it's above the threshold
      if (aSum >= accelerationThreshold) {
        // reset the sample read count
        samplesRead = 0;
        break;
      }
    }
  }
}

```

```

// check if the all the required samples have been read since
// the last time the significant motion was detected
while (samplesRead < numSamples) {
    // check if both new acceleration and gyroscope data is
    // available
    if (IMU.accelerationAvailable() && IMU.gyroscopeAvailable()) {
        // read the acceleration and gyroscope data
        IMU.readAcceleration(aX, aY, aZ);
        IMU.readGyroscope(gX, gY, gZ);

        samplesRead++;

        // print the data in CSV format
        Serial.print(aX, 3);
        Serial.print(',');
        Serial.print(aY, 3);
        Serial.print(',');
        Serial.print(aZ, 3);
        Serial.print(',');
        Serial.print(gX, 3);
        Serial.print(',');
        Serial.print(gY, 3);
        Serial.print(',');
        Serial.print(gZ, 3);
        Serial.print(',');
        Serial.print("standing");
        Serial.println();

        if (samplesRead == numSamples) {
            // add an empty line if it's the last sample
            Serial.println();
        }
    }
}
}
1

```

Η προστασία των μοντέλων μηχανικής μάθησης είναι ένας σημαντικός τομέας έρευνας και ανάπτυξης και έχουν πραγματοποιηθεί πολλές μελέτες προκειμένου να εντοπιστούν οι ευπάθειες τους. Η διαδικασία περιλαμβάνει την ανάλυση της συμπεριφοράς των μοντέλων και των αποφάσεων τους ώστε να ανιχνευθούν τα προβλήματα. Οι επιθέσεις που πραγματοποιούνται στα μοντέλα μηχανικής μάθησης έχουν στόχο την απόκτηση πρόσβασης στα δεδομένα ή τον επηρεασμό των αποφάσεων ώστε να οδηγηθούν σε λανθασμένες προβλέψεις. Οι επιθέσεις διακρίνονται σε κατηγορίες ανάλογα με τους στόχους που θέλουν να επιτύχουν και τα χαρακτηριστικά τους. Μια διάκριση των επιθέσεων είναι ανάλογα με την γνώση που έχει ο επιτιθέμενος για την αρχιτεκτονική του μοντέλου ή τις παραμέτρους. Στην περίπτωση των *white box* επιθέσεων ο επιτιθέμενος έχει πλήρη γνώση της δομής του μοντέλου ενώ στις *black box* επιθέσεις γνωρίζει μόνο την είσοδο και την έξοδο του μοντέλου.

Στην κατηγορία των *score based attacks* εντάσσεται η ZOO σύμφωνα με (Chen et al., 2017) στόχος είναι η δημιουργία *adversarial examples* χωρίς να απαιτείται η γνώση των παραμέτρων του μοντέλου (*black box*). Ο επιτιθέμενος έχει πρόσβαση μόνο στα δεδομένα εισόδου και την αντίστοιχη έξοδο. Ο στόχος είναι η ανάκτηση της βεβαιότητας του μοντέλου σχετικά με την κατηγοριοποίηση ενός δεδομένου. Τα πειράματα εφαρμόστηκαν σε ένα μοντέλο *Deep Neural Network (DNN)* σε τρία σύνολα δεδομένων *MNIST*, *CIFAR10* (200 δείγματα για την *untargeted* επίθεση) και *ImageNet* (150 δείγματα για την *untargeted* επίθεση) και απέδειξαν ότι είναι τόσο αποτελεσματική όσο και η *white box* επίθεση των Carlini και Wagner και υπερτερεί με τις *black box* επιθέσεις που βασίζονται σε υποκατάστατα μοντέλα. Στην κατηγορία των *decision based* εντάσσεται η *Boundary attack* όπου σύμφωνα με (Brendel et al., 2017) η πληροφορία που είναι απαραίτητη στον επιτιθέμενο είναι η πρόσβαση μόνο στην τελική απόφαση του μοντέλου γεγονός που την καθιστά εφαρμόσιμη στον πραγματικό κόσμο.

Στόχος της επίθεσης είναι να βρεθεί ένα δεδομένο εισόδου που ανήκει στο όριο απόφασης του μοντέλου, αλλά βρίσκεται κοντά στην κατηγορία που επιθυμεί ο επιτιθέμενος. Η επίθεση ξεκινάει εφαρμόζοντας μια μεγάλη διαταραχή στο δείγμα εισόδου που παραποιεί την απόφαση του μοντέλου και στην συνέχεια προσπαθεί να μειώσει στο ελάχιστο την διαταραχή. Η επίθεση απαιτεί πολλαπλές δοκιμές, καθώς προσαρμόζει διαρκώς την είσοδο και προσπαθεί να βρει τις μικρότερες δυνατές αλλαγές στα χαρακτηριστικά της εισόδου ώστε να οδηγηθεί το μοντέλο σε λανθασμένη ταξινόμηση. Το πείραμα εφαρμόστηκε σε νευρωνικά δίκτυα σε τρία σύνολα δεδομένων MNIST, CIFAR10 (1000 δείγματα για την *untargeted* επίθεση) και ImageNet (250 δείγματα για την *untargeted* επίθεση). Για την αξιολόγηση της επίθεσης χρησιμοποιήθηκε η μέση τιμή των L2 αποστάσεων μεταξύ των δειγμάτων. Η σύγκριση των αποτελεσμάτων πραγματοποιήθηκε με *white box* επιθέσεις (Fast-Gradient Sign Method (FGSM), DeepFool και Carlini & Wagner) όπου παρουσιάζει ανταγωνιστική απόδοση, δεδομένου του ότι έχουν πλήρη πρόσβαση στις παραμέτρους του μοντέλου. Για να αντισταθμίσει την έλλειψη πληροφοριών η Boundary attack χρειάζεται περισσότερες επαναλήψεις για να συγκλίνει σε μια διαταραχή.

Τα δεδομένα τα οποία χρησιμοποιήθηκαν για την υλοποίηση του πειράματος αποτελούν δημοφιλή σύνολα δεδομένων για την εκπαίδευση και την αξιολόγηση μοντέλων μηχανικής μάθησης και χρησιμοποιήθηκαν από τους ερευνητές των συγκεκριμένων επιθέσεων. Συγκεκριμένα, πρόκειται για τα MNIST και Cifar10 datasets. Αναλυτικότερα: MNIST Dataset (Modified National Institute of Standards and Technology database): χρησιμοποιείται συχνά για τον εκσυγχρονισμό και τον έλεγχο αλγορίθμων αναγνώρισης ψηφίων. Αποτελείται από εικόνες με χειρόγραφα αριθμητικά ψηφία και χρησιμοποιείται ευρέως για την εκπαίδευση των μοντέλων της μηχανικής μάθησης. Συγκεκριμένα, περιέχει 60,000 εικόνες για εκπαίδευση και 10,000 για δοκιμή

με διαστάσεις 28x28 και είναι ισότιμα χωρισμένες σε 10 κλάσεις. Κάθε εικόνα σχετίζεται με μια ετικέτα που αντιπροσωπεύει το αντίστοιχο αριθμητικό ψηφίο από το 0 έως το 9. Στο module `art.utils.load_dataset` της βιβλιοθήκης ART δηλώνουμε ως σύνολο δεδομένων το MNIST, το οποίο χωρίζεται σε δεδομένα εκπαίδευσης και δοκιμής. Ορίζεται ως (x_train, y_train) , (x_test, y_test) , `min`, `max`, και ο τύπος δεδομένων που επιστρέφει είναι πλειάδα (`Art.Uutils, n.d.`), όπου: `x_train`: ένας πίνακας που περιέχει τα δεδομένα εκπαίδευσης `y_train`: ένας πίνακας που περιέχει τις αντίστοιχες ετικέτες `x_test`: ένας πίνακας που περιέχει τα δεδομένα δοκιμής `y_test`: ένας πίνακας που περιέχει τις αντίστοιχες ετικέτες `min`: η ελάχιστη τιμή που μπορεί να πάρει ένα χαρακτηριστικό στις εικόνες, το οποίο είναι μηδέν καθώς τα χαρακτηριστικά είναι αποχρώσεις γκρι στο διάστημα `max`: η μέγιστη τιμή που μπορεί να πάρει ένα χαρακτηριστικό στις εικόνες, το οποίο είναι 255 καθώς τα χαρακτηριστικά είναι αποχρώσεις γκρι στο διάστημα.

4.3 Συνελικτικά Νευρωνικά Δίκτυα.

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks ή CNN), περιγράφηκαν για πρώτη φορά από τον LeCun . Είναι μία ειδική κατηγορία νευρωνικών δικτύων τα οποία είναι κατάλληλα για την επεξεργασία πληροφορίας που μπορεί να αναπαρασταθεί σε μορφή πλέγματος. Στην περίπτωση των εικόνων, το πλέγμα είναι δισδιάστατο και κάθε στοιχείο του είναι η ένταση ενός pixel. Γενικεύοντας την ιδέα αυτή στην περίπτωση της ακολουθίας εικόνων (ή καρέ, frame), δηλαδή ενός βίντεο το πλέγμα είναι τρισδιάστατο και κάθε στοιχείο του είναι η ένταση ενός pixel σε μία συγκεκριμένη χρονική στιγμή. Παρότι τα Συνελικτικά Νευρωνικά Δίκτυα έχουν εφαρμοστεί με επιτυχία -όπως η αναγνώριση ομιλίας- σε προβλήματα όπου η είσοδος αναπαρίσταται από ένα μονοδιάστατο πλέγμα, στην παρούσα ενότητα θα περιοριστούμε στην περιγραφή τους στο πλαίσιο προβλημάτων αναγνώρισης εικόνας και βίντεο. Όπως δηλώνει και η ονομασία τους τα Συνελικτικά Νευρωνικά Δίκτυα, βασίζονται στη μαθηματική διαδικασία της συνέλιξης (convolution). Η γενική δομή ενός Συνελικτικού Δικτύου είναι παρόμοια με αυτή ενός MLP, υπό την έννοια ότι αποτελείται από σειριακά συνδεδεμένα επίπεδα και συνεπώς η εξίσωση περιγράφει και σε αυτή την περίπτωση τη συνολική λειτουργία του μοντέλου. Σε αντίθεση με ένα MLP ένα CNN, αντί για πλήρως συνδεδεμένους νευρώνες χρησιμοποιεί σε κάθε Συνελικτικό Στρώμα έναν αριθμό διαφορετικών φίλτρων με τα οποία συνελίσσεται η είσοδος και παράγεται ένα χάρτης ενεργοποίησης (activation map). Στην περίπτωση που το δίκτυο χρησιμοποιεί δισδιάστατη συνέλιξη και η είσοδος είναι εικόνα, τα φίλτρα είναι ένας τρισδιάστατος τανυστής με διαστάσεις ίσες με: (Χωρικό πλάτος, Χωρικό μήκος, Αριθμός Καναλιών). Όταν χρησιμοποιείται τρισδιάστατη συνέλιξη και η είσοδος είναι ένα βίντεο τα φίλτρα είναι τετραδιάστατα με διαστάσεις ίσες με: (Χωρικό πλάτος, Χωρικό μήκος, Χρονική Διάρκεια ή Αριθμός Καρέ, Αριθμός Καναλιών). Αντίστοιχα, ο

χάρτης ενεργοποίησης που προκύπτει από την συνέλιξη με κάθε φίλτρο είναι δισδιάστατος στην περίπτωση των εικόνων και τρισδιάστατος στην περίπτωση των βίντεο. Τα βάρη του κάθε φίλτρου αποτελούν τις υπό μάθηση παραμέτρους του μοντέλου. Μέχρι αυτό το σημείο, η δράση του συνελκτικού στρώματος στην είσοδο είναι μόνο γραμμική καθώς η συνέλιξη αποτελεί γραμμικό τελεστή. Στη συνέχεια, όπως και στην περίπτωση των MLP, σε κάθε τιμή του χάρτη ενεργοποίησης εφαρμόζεται μία μη γραμμική συνάρτηση ενεργοποίησης και έτσι προκύπτει η τελική έξοδος του στρώματος. Εκτός των στρωμάτων συνέλιξης, είναι κοινή πρακτική, να χρησιμοποιούνται μέσα σε ένα CNN και στρώματα συσσώρευσης (*max pooling layers*) με τελεστή συσσώρευσης τη συνάρτηση τοπικού μεγίστου που εφαρμόζεται σε μη επικαλυπτόμενες περιοχές του κάθε χάρτη ενεργοποίησης. Η χρήση της συνέλιξης στα Συνελκτικά Δίκτυα προσφέρει κάποιες χρήσιμες ιδιότητες οι οποίες έχουν περιγραφεί στις αναφορές. Πριν περιγράψουμε τον φορμαλισμό και τις μεθόδους εκπαίδευσης, κρίθηκε χρήσιμο να περιγραφούν οι ιδιότητες των Συνελκτικών μοντέλων που τα καθιστούν ελκυστικά στις εφαρμογές Όρασης Υπολογιστών και Μηχανικής Μάθησης και οι οποίες είναι:

- Αραιή ή Τοπική Συνδεσιμότητα (*Sparse or Local Connectivity*).
- Κοινή Χρήση Παραμέτρων (*Parameter Sharing*.)
- Συμεταβλητότητα στις μετατοπίσεις (*Equivariance to translation*).

4.4 Αναδρομικά Νευρωνικά Δίκτυα και Μακρά Δίκτυα Βραχείας Μνήμης.

Τα αναδρομικά νευρωνικά δίκτυα είναι μία ειδική κατηγορία νευρωνικών δικτύων που επεξεργάζονται αποτελεσματικά κάθε είδους ακολουθιακά δεδομένα. Παραδείγματα, αποτελούν η φωνή, η γραφή, η οπτική πληροφορία που προκύπτει από μία κίνηση ή μία δράση ή ακόμα και τα *pixel* μίας εικόνας αν τα διατρέξουμε με κάποιο δομημένο τρόπο. Ένα αναδρομικό δίκτυο μετασχηματίζει κάθε νέα είσοδο με τρόπο που εξαρτάται τόσο από την ίδια την είσοδο όσο και από τις προηγούμενες εισόδους που έχει δεχτεί. Φορμαλιστικά αυτή η βασική αρχή περιγράφεται ως εξής: Αν x_t είναι η είσοδος την χρονική στιγμή t , $f(\cdot)$ η συνάρτηση που περιγράφει την επίδραση του αναδρομικού δικτύου πάνω στην είσοδο και h_t η έξοδος του, τότε:

$$h_t = f(x_t, h_{t-1}) = f(x_t, f(x_{t-1}, h_{t-2})) = \dots = f(x_t, f(x_{t-1}, \dots, (f(x_1, h_0)) \dots))$$

(4.4.1)

Είναι φανερό πως υπάρχει στενή σχέση ανάμεσα στα γραφικά μοντέλα (*graphical models*) και τα αναδρομικά δίκτυα. Αυτή η σύνδεση ανάμεσα στις δύο κατηγορίες μοντέλων μπορεί να φανεί καλύτερα αν, όπως στο αναδρομικό δίκτυο "ξεδιπλωθεί", σχεδιάζοντας "εικονικές" υπολογιστικές μονάδες για να αναπαρασταθούν οι αναδρομικές εκτελέσεις της συνάρτησης f πάνω στις εισόδους $x_t, x_{t+1}, \dots, x_T$. Σημειώνεται πως η έξοδος h_t συχνά αναφέρεται και ως κατάσταση του δικτύου. Στις παραπάνω εξισώσεις δεν εισήχθη για λόγους απλότητας η ύπαρξη ενός συνόλου παραμέτρων θ ή βαρών που όπως και στις άλλες περιπτώσεις νευρωνικών μοντέλων καθορίζουν την επίδραση του μοντέλου πάνω στην είσοδο τους. Οι παράμετροι αυτοί, και για τα αναδρομικά νευρωνικά δίκτυα είναι υπό μάθηση.

4.5 Προσεγγίσεις με Νευρωνικά Δίκτυα.

Για την παρουσίαση των νευρώνων *LSTM*, αρχικά θα περιγραφεί ο φορμαλισμός που τους διέπει και στη συνέχεια θα δοθεί μία σύντομη ποιοτική ερμηνεία της λειτουργίας τους. Θεωρούμε ότι η κατάσταση ενός νευρώνα *LSTM* τη χρονική στιγμή t είναι μια συλλογή από διανύσματα του χώρου R^d . Συγκεκριμένα έχουμε:


- Τη θύρα εισόδου (*input gate*) i_t
- Τη θύρα λησμόνησης (*forget gate*) f_t
- Ένα κύτταρο μνήμης (*memory cell*) c_t
- Τη θύρα εξόδου (*output gate*) o_t
- Τη κατάσταση ή κρυφή κατάσταση (*hidden state*) h_t .

Δεδομένου ότι οι μη γραμμικές συναρτήσεις ενεργοποίησης που χρησιμοποιούνται είναι η σιγμοειδής συνάρτηση $\sigma(\cdot)$ και η υπερβολική εφαπτομένη $\tanh(\cdot)$, οι εξισώσεις κατάστασης που χαρακτηρίζουν έναν νευρώνα *LSTM* είναι οι εξής:

$$\begin{aligned}i_t &= \sigma(W^i x_t + U^i h_{t-1} + b^i) \\f_t &= \sigma(W^f x_t + U^f h_{t-1} + b^f) \\o_t &= \sigma(W^o x_t + U^o h_{t-1} + b^o) \\u_t &= \tanh(W^u x_t + U^u h_{t-1} + b^u) \\c_t &= i_t \odot u_t + f_t \odot c_{t-1} \\h_t &= o_t \odot \tanh(c_t)\end{aligned}$$

όπου x_t η είσοδος τη χρονική στιγμή t , b ένα διάνυσμα πόλωσης και $\odot$ το γινόμενο Hadamard. Διαισθητικά μπορούμε να ερμηνεύσουμε τη λειτουργία του μοντέλου ως εξής: πως η θύρα λησμόνησης ελέγχει το κατά πόσο οι παρελθούσες καταστάσεις πρέπει να ληφθούν υπόψη κατά το επόμενο βήμα, η θύρα εισόδου ελέγχει το ποια διανύσματα του νευρώνα θα μεταβληθούν και σε ποιο βαθμό,

- Η θύρα λησμόνησης ελέγχει το κατά πόσο πρέπει το περιεχόμενο του κυττάρου μνήμης c_t να ξεχαστεί κατά τη μετάβαση στο επόμενο βήμα λειτουργίας.
- Η θύρα εξόδου ελέγχει την έκθεση της εσωτερικής μνήμης στα υπόλοιπα μέρη του νευρώνα.
- Η θύρα εισόδου ελέγχει το ποια διανύσματα του νευρώνα θα μεταβληθούν και σε ποιο βαθμό.
- Η κρυφή κατάσταση αναπαριστά μία περιορισμένη και ελεγχόμενη εξωτερίκευση της αποθηκευμένης στο κύτταρο πληροφορίας η οποία εξαρτάται και από την νέα είσοδο x_t και όλες τις προηγούμενες λειτουργίες.



Σχήμα 4.5 Παράδειγμα LSTM νευρώνα.

4.6 Τεχνικές Συμπίεσης Νευρωνικών Δικτύων.

Η κβαντοποίηση είναι μια προσέγγιση για τη συμπίεση DNN. Η κβαντοποίηση χρησιμοποιεί λιγότερα bit για να αναπαραστήσει τους αριθμούς. Αυτό προκαλεί απόκλιση από τις αρχικές τιμές και έχει αντίκτυπο στην ακρίβεια του μοντέλου. Η κβαντοποίηση συνήθως επιτυγχάνεται με δύο τρόπους. Ο πρώτος είναι η μετατροπή των αριθμών κινητής υποδιαστολής σε αριθμούς σταθερής υποδιαστολής. Η θέση της υποδιαστολής καθορίζεται έτσι ώστε να υπάρχει το λιγότερο δυνατό σφάλμα από τις αρχικές τιμές. Ο δεύτερος είναι η ομαδοποίηση των βαρών βάσει κάποιου κριτηρίου. Κάθε ομάδα έχει μια αντιπροσωπευτική τιμή και έτσι τα βάρη καταλήγουν να είναι λιγότερα. Τα ΣΝΔ χρησιμοποιούν ένα έξυπνο τέχνασμα για να μειώνουν τον όγκο των δεδομένων εκπαίδευσης που απαιτείται για τον εντοπισμό αντικειμένων σε διαφορετικές συνθήκες. Βασικά, το τέχνασμα συνίσταται στη χρήση των ίδιων βαρών εισόδου για πολλούς νευρώνες – ούτως ώστε όλοι οι εν λόγω νευρώνες να ενεργοποιούνται από το ίδιο πρότυπο – αλλά με διαφορετικά εικονοστοιχεία εισόδου. Για παράδειγμα, μπορούμε να έχουμε ένα σύνολο νευρώνων που ενεργοποιούνται από το μυτερό αυτί μιας γάτας. Όταν η είσοδος είναι η φωτογραφία μιας γάτας, ενεργοποιούνται δύο νευρώνες, ένας για το αριστερό αυτί και ένας άλλος για το δεξί. Επίσης, μπορούμε να επιτρέψουμε τη λήψη των εικονοστοιχείων εισόδου του νευρώνα από μικρότερη ή μεγαλύτερη περιοχή, ούτως ώστε διαφορετικοί νευρώνες να ενεργοποιούνται από το αυτί που θα εμφανίζεται σε διαφορετικές κλίμακες (μεγέθη) και, ως εκ τούτου, να μπορούμε να εντοπίσουμε τα αυτιά μιας μικρής γάτας, ακόμη και αν στα δεδομένα εκπαίδευσης περιλαμβάνονταν εικόνες μόνο μεγάλων γατών. Υπάρχουν και οι τεχνικές οι οποίες βασίζονται στην ελάττωση του μεγέθους του νευρωνικού μοντέλου, δηλαδή στην ελάττωση του αριθμού των βαρών, όπως αυτές που περιγράφονται στις εργασίες Chouliaras et al. (2021), Fragkou et al. (2023).

Κεφάλαιο 5

5.1 Πλαίσιο Υλοποίησης για Συλλογή Δεδομένων. Case Study Αναγνώριση

Εικόνας.

Αυτή η μελέτη παρουσιάζει ένα νευρωνικό δίκτυο που χρησιμοποιεί φίλτρα που βασίζονται σε λογιστική χαρτογράφηση (LogNNet). Το LogNNet έχει μια δομή δικτύου τροφοδοσίας, αλλά διαθέτει τις ιδιότητες των νευρωνικών δικτύων δεξαμενής. Ο πίνακας βάρους εισόδου, που ορίζεται από μια επαναλαμβανόμενη λογιστική αντιστοίχιση, σχηματίζει τους πυρήνες που μετατρέπουν τον χώρο εισόδου στον χώρο χαρακτηριστικών υψηλότερης διάστασης. Η πιο αποτελεσματική αναγνώριση ενός χειρόγραφου ψηφίου από το MNIST-10 συμβαίνει κάτω από τη χαοτική συμπεριφορά του λογιστικού χάρτη. Αλήφθηκε η συσχέτιση της ακρίβειας ταξινόμησης με την τιμή του εκθέτη Lyapunov. Ένα πλεονέκτημα της εφαρμογής LogNNet σε συσκευές IoT είναι η σημαντική εξοικονόμηση στη μνήμη που χρησιμοποιείται. Ταυτόχρονα, το LogNNet διαθέτει έναν απλό αλγόριθμο και δείκτες απόδοσης συγκρίσιμους με αυτούς των καλύτερων αλγορίθμων αποδοτικών πόρων που είναι διαθέσιμοι αυτή τη στιγμή. Η αρχιτεκτονική δικτύου που παρουσιάζεται χρησιμοποιεί μια συστοιχία βαρών με συνολικό μέγεθος μνήμης από 1 έως 29 kB και επιτυγχάνει ακρίβεια ταξινόμησης 80,3–96,3%. Η μνήμη αποθηκεύεται λόγω του επεξεργαστή, ο οποίος υπολογίζει διαδοχικά τους απαιτούμενους συντελεστές βάρους κατά τη λειτουργία του δικτύου χρησιμοποιώντας την αναλυτική εξίσωση της λογιστικής χαρτογράφησης. Το προτεινόμενο νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί σε υλοποιήσεις τεχνητής νοημοσύνης που βασίζονται σε περιορισμένες συσκευές με περιορισμένη μνήμη, οι οποίες αποτελούν αναπόσπαστα μπλοκ για τη δημιουργία νοημοσύνης περιβάλλοντος σε σύγχρονα περιβάλλοντα IoT. Από ερευνητική άποψη, το LogNNet μπορεί να συμβάλει

στην κατανόηση των θεμελιωδών ζητημάτων της επιρροής του χάους στη συμπεριφορά των νευρωνικών δικτύων τύπου δεξαμενής.

Λέξεις-κλειδιά: λογιστικός χάρτης; περιορισμένες συσκευές? IoT; νευρικό σύστημα; Υπολογισμός δεξαμενής. χειρόγραφο αναγνώριση ψηφίων. νοημοσύνη περιβάλλοντος? Lyapunov εκθέτης; χάος

Στην εποχή των νευρωνικών δικτύων και του Διαδικτύου των Πραγμάτων (IoT), η αναζήτηση νέων αρχιτεκτονικών νευρωνικών δικτύων ικανών να λειτουργούν σε συσκευές με μικρές ποσότητες μνήμης (10s kB RAM) γίνεται επείγουσα ατζέντα [1,2,3] .

Οι περιορισμένες συσκευές διαθέτουν σημαντικά λιγότερη επεξεργαστική ισχύ και μνήμη από ένα συνηθισμένο smartphone ή σύγχρονο φορητό υπολογιστή και συνήθως δεν διαθέτουν διεπαφή χρήστη . Οι περιορισμένες συσκευές αποτελούν τη βάση για τη νοημοσύνη περιβάλλοντος (AmI) σε περιβάλλοντα IoT και μπορούν να χωριστούν σε τρεις κατηγορίες με βάση τα μεγέθη κώδικα και μνήμης: class 0 (λιγότερο από 100 KB Flash και μικρότερη από 1 KB RAM), κατηγορία 1 (≈ 100 KB Flash και ≈ 10 KB RAM) και κατηγορίας 2 (≈ 250 KB Flash και ≈ 50 KB RAM) . Τα έξυπνα αντικείμενα, τα οποία είναι χτισμένα σε περιορισμένες συσκευές, διαθέτουν περιορισμένους πόρους συστήματος και αυτοί οι περιορισμοί απαγορεύουν την εφαρμογή μηχανισμών ασφαλείας που είναι κοινοί στο περιβάλλον του Διαδικτύου. Οι σύνθετοι κρυπτογραφικοί μηχανισμοί απαιτούν σημαντικό χρόνο και υψηλούς ενεργειακούς πόρους, και επιπλέον, η αποθήκευση μεγάλου αριθμού κλειδιών για ασφαλή μετάβαση δεδομένων δεν είναι δυνατή στις περιορισμένες συσκευές. Το ζήτημα της αποθήκευσης παρουσιάζει σημαντικές προκλήσεις για την ενοποίηση της αλυσίδας μπλοκ και της τεχνητής νοημοσύνης (AI) με το IoT και απαιτεί νέες προσεγγίσεις και ερευνητικές προσπάθειες για την επίλυση αυτού του περιορισμού. Οι ευφυείς συσκευές IoT θα πρέπει να μπορούν να επεξεργάζονται τις εισερχόμενες πληροφορίες χωρίς να τις στέλνουν στο

cloud. Τα έξυπνα αντικείμενα εξοπλισμένα με τις δικές τους δυνατότητες τεχνητής νοημοσύνης ξοδεύουν σημαντικά λιγότερο χρόνο στην ανάλυση των εισερχόμενων δεδομένων και στην ανάπτυξη μιας τελικής λύσης, δημιουργώντας νέες δυνατότητες, για παράδειγμα, στην ανάπτυξη του AmI στην ιατρική βιομηχανία , προβλέποντας τη συμπεριφορά των μηχανισμών , τοπική σημασιολογική επεξεργασία δεδομένων βίντεο και «έξυπνες» υπηρεσίες στον ηλεκτρονικό τουρισμό . Αυτή η προσέγγιση διευκολύνει την ανάπτυξη των εννοιών των έξυπνων χώρων και του υπολογισμού ομίχλης, όταν οι συσκευές ανιχνεύονται μεταξύ τους, για παράδειγμα, χρησιμοποιώντας ασύρματες τεχνολογίες . ανακατανομή υπολογιστικών εργασιών. και βελτιστοποιήστε την κατανομή των απαντήσεων . Ως εκ τούτου, η ενοποίηση του AI και του IoT δημιουργεί νέα κοινωνικά, οικονομικά και τεχνολογικά οφέλη.

Τα νευρωνικά δίκτυα δημιουργούν τα θεμέλια για την τεχνητή νοημοσύνη. Οι γνωστοί τύποι νευρωνικών δικτύων είναι τα νευρωνικά δίκτυα τροφοδοσίας, τα συνελκτικά νευρωνικά δίκτυα και τα επαναλαμβανόμενα νευρωνικά δίκτυα . Εκτός από τα νευρωνικά δίκτυα, οι δημοφιλείς μέθοδοι ταξινόμησης και αποτελεσματικής πρόβλεψης περιλαμβάνουν αλγόριθμους βασισμένους σε δέντρα και τον αλγόριθμο κλησιέστερων γειτόνων (kNN). Το πρόβλημα της εφαρμογής συμπαγών και αποτελεσματικών αλγορίθμων για τη λειτουργία νευρωνικών δικτύων σε περιορισμένες συσκευές είναι ο κύριος περιοριστικός παράγοντας στην ανάπτυξη της ενοποίησης της τεχνητής νοημοσύνης και του IoT. Η εκπαίδευση των νευρωνικών δικτύων είναι η διαδικασία της βέλτιστης επιλογής των συντελεστών βάρους των συζεύξεων νευρώνων και των παραμέτρων φίλτρου που καταλαμβάνουν σημαντική ποσότητα μνήμης. Υπογραμμίζει τη σημασία της ανάπτυξης των μεθόδων για τη μείωση της μνήμης που καταναλώνεται από ένα νευρωνικό δίκτυο.

5.2 Πλατφόρμα.

Οι εξέχοντες αλγόριθμοι που βασίζονται σε δέντρα περιλαμβάνουν τους αλγόριθμους GBDT και Bonsai από τη Microsoft, οι οποίοι επιτρέπουν την αποτελεσματική χρήση της μνήμης και εκτελούνται σε περιορισμένες συσκευές με μνήμη RAM 2–16 kB. Ένας αλγόριθμος που ονομάζεται ProtoNN, βασισμένος στη μέθοδο kNN, λειτουργεί σε συσκευές με μνήμη RAM 16 kB. Επί του παρόντος, είναι διαθέσιμοι αποτελεσματικοί αλγόριθμοι ανακατανομής μνήμης σε συνελκτικά νευρωνικά δίκτυα (CNN) και δεν υπερβαίνουν τα 2 kB καταναλωμένης μνήμης RAM και κατέδειξαν εντυπωσιακά αποτελέσματα ακρίβειας ταξινόμησης $\approx 99,15\%$ στη βάση δεδομένων MNIST-10. Ωστόσο, η πολυπλοκότητα των αλγορίθμων οδηγεί στο μεγάλο μέγεθος του ίδιου του προγράμματος. Αλγόριθμοι που βασίζονται στην επαναλαμβανόμενη αρχιτεκτονική δικτύου, όπως το Spectral-RNN και το FastGRNN [18], επιτυγχάνουν $\approx 98\%$ ακρίβεια ταξινόμησης στο MNIST-10 με μέγεθος μοντέλου ≈ 6 kB.

Μια εναλλακτική προσέγγιση για τη μείωση του αριθμού των εκπαιδευμένων βαρών βασίζεται στον υπολογισμό φυσικής δεξαμενής (RC). Το RC χρησιμοποιεί πολύπλοκα φυσικά δυναμικά συστήματα (συζευγμένους ταλαντωτές, συστοιχίες crossbar memristor, οπτο-ηλεκτρονικό βρόχο ανάδρασης) ή επαναλαμβανόμενα νευρωνικά δίκτυα (δίκτυα κατάστασης ηχούς (ESN) και υγρό μηχανές κατάστασης (LSM)), ως δεξαμενές με πλούσια δυναμική και ισχυρές υπολογιστικές δυνατότητες. Οι σύνδεσμοι στη δεξαμενή δεν είναι εκπαιδευμένοι, αλλά καθορίζονται με ειδικό τρόπο. Η δεξαμενή μεταφράζει τα δεδομένα εισόδου σε μεγαλύτερη διάσταση του χώρου (κόλπο πυρήνα) και το νευρωνικό δίκτυο εξόδου, μετά την εκπαίδευση, μπορεί να ταξινομήσει το αποτέλεσμα με μεγαλύτερη ακρίβεια. Η αναζήτηση απλών αλγορίθμων για την προσομοίωση πολύπλοκων δυναμικών δεξαμενών είναι ένα σημαντικό ερευνητικό έργο.

Η παρούσα μελέτη παρουσιάζει μια νέα αρχιτεκτονική για ένα νευρωνικό δίκτυο, όπου η πολύπλοκη δυναμική προσομοιώνεται με την εφαρμογή λογιστικής χαρτογράφησης στα βάρη πολλαπλών επιπέδων ενός δικτύου τροφοδοσίας. Προηγουμένως, η λογιστική χαρτογράφηση χρησιμοποιήθηκε στα νευρωνικά δίκτυα ως συνάρτηση ενεργοποίησης και ως αντικείμενο μοντέλου. Η εφαρμογή της λογιστικής χαρτογράφησης μειώνει σημαντικά την ποσότητα της μνήμης που χρησιμοποιείται από το δίκτυο χωρίς να χάσει τη λειτουργικότητα. Η μελέτη ισχύει για την αναγνώριση χειρόγραφων ψηφίων από τη βάση δεδομένων MNIST-10.


5.3 Εφαρμογή.

Το LogNet συγκρίνεται με άλλους γνωστούς αλγόριθμους και δίνονται προτάσεις για τη βελτίωση της λειτουργικότητας και τη μείωση της ποσότητας της μνήμης που καταλαμβάνεται. Συμπερασματικά, τα αποτελέσματα της μελέτης δείχνουν ότι το προτεινόμενο νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί για την εφαρμογή τεχνητής νοημοσύνης με βάση περιορισμένες συσκευές με περιορισμένη μνήμη, οι οποίες αποτελούν αναπόσπαστα μπλοκ για τη δημιουργία AmI και σύγχρονων περιβαλλόντων IoT.

5.4 Σύνολο Δεδομένων .

Η βάση δεδομένων χειρόγραφων ψηφίων MNIST-10 (διαθέσιμη στη σελίδα του Yan LeCun στο Διαδίκτυο) χρησιμοποιήθηκε για τη μελέτη. Η βάση δεδομένων αποτελείται από 70.000 εικόνες χειρόγραφων ψηφίων από το «0» έως το «9». Κάθε εικόνα έχει μέγεθος 28×28 pixel (βλ. Εικόνα 5.4.α). Η βάση δεδομένων χωρίζεται σε δύο σύνολα. Το πρώτο σύνολο αποτελείται από 60.000 εικόνες που προορίζονται για την εκπαίδευση του δικτύου και το δεύτερο σύνολο 10.000 εικόνων χρησιμοποιείται για τον έλεγχο του δικτύου και τον υπολογισμό της ακρίβειας ταξινόμησης. Η εικόνα παρουσιάζεται σε κλίμακα του γκρι με την ένταση κάθε pixel στην περιοχή από 0 έως 255.

Πριν από την εισαγωγή του δικτύου, μια δισδιάστατη εικόνα μετατράπηκε σε μονοδιάστατο πίνακα $Y[i]$, όπου $i = 1-784$, χρησιμοποιώντας ειδικά μοτίβα μετασχηματισμού. Οι κύριοι τύποι μοτίβων T που χρησιμοποιούνται παρουσιάζονται στο Σχήμα 1β-δ. Επιπλέον, τα μοτίβα T μπορούν να χρησιμοποιηθούν για την αντίστροφη μετατροπή από έναν μονοδιάστατο πίνακα σε έναν δισδιάστατο πίνακα.



Σχήμα 5.4.α Ένα παράδειγμα εικόνας 28×28 pixel του χειρόγραφου ψηφίου

«8» από τη βάση δεδομένων MNIST-10 (a). Μοτίβα μετασχηματισμού του πίνακα εικόνων: $T\text{-pattern-1}$ (b), $T\text{-pattern-2}$ (c), $T\text{-pattern-3}$ (d).

5.5 Προεπεξεργασία Δεδομένων.


Το T-pattern-1 εκτελεί την εισαγωγή στήλη προς στήλη της εικόνας. Το T-pattern-2 μετατρέπει την εικόνα σε σπειροειδή (δεξιόστροφη) μορφή. και T-pattern-3 είναι ένας συνδυασμός εισαγωγής γραμμή προς γραμμή του κεντρικού τμήματος της εικόνας, με την προσθήκη περιγραμμάτων σε σπειροειδή (δεξιόστροφη) μορφή.

Μετά τον μετασχηματισμό του μοτίβου T , οι τιμές του πίνακα Y κανονικοποιούνται διαιρώντας κάθε στοιχείο του πίνακα με το 255 και προστίθεται ένα στοιχείο πόλωσης $Y[0] = 1$.

5.6 Μεθοδολογία Αξιολόγησης του Μοντέλου.

Η αρχιτεκτονική δικτύου που χρησιμοποιείται στην παρούσα μελέτη παρουσιάζεται στο Σχήμα 5.6α. και μοιάζει ελαφρά με εκείνη που παρουσιάζεται στην εργασία των Fragkou et al. (2022). Η επεξεργασία δεδομένων πραγματοποιήθηκε παρόμοια με το δίκτυο προώθησης, σύμφωνα με τις εξισώσεις

$$Sh=fh(Y*W1), Sout=fout(Sh*W2) \quad (5.6.1)$$




Σχήμα 5.6.α Αρχιτεκτονική LogNet (α). Δίκτυα προώθησης δύο επιπέδων (β) και 1 επιπέδων (γ).

Τα βάρη W_1 στη δεξαμενή ορίστηκαν αναδρομικά, με βάση την λογιστική χαρτογράφηση. Η ταξινόμηση των χειρόγραφων ψηφίων στην περιοχή «0–9» προχώρησε σύμφωνα με τη μεγαλύτερη τιμή του στοιχείου του επιπέδου εξόδου $S_{out}[n]$, όπου $n = 0-9$. Η εκγύμναση των βαρών W_2 έγινε με τη μέθοδο οπισθοδιάδοσης σφάλματος με ρυθμό εκμάθησης 0,3. Οι αρχικές τιμές των βαρών W_2 ορίστηκαν τυχαία στο εύρος μεταξύ -0,5 και 0,5.

Τα βάρη W_1 δεν εκπαιδεύονται και μόνο τα βάρη W_2 του ταξινομητή εξόδου εκπαιδεύονται. Αυτή η προσέγγιση μοιάζει με τη λειτουργία ενός δικτύου επαναλαμβανόμενων δεξαμενών, με τη διαφορά ότι ο επαναλαμβανόμενος μετασχηματισμός δεν εφαρμόζεται στα δεδομένα εισόδου, αλλά στα στοιχεία του πίνακα W_1 .

Η λογιστική χαρτογράφηση είναι ευρέως γνωστή ως το απλούστερο μοντέλο που καταδεικνύει τη μετάβαση στη χαοτική συμπεριφορά μέσω μιας ακολουθίας

διακλαδώσεων διπλασιασμού περιόδου (σενάριο Feigenbaum). Ο καταρράκτης των διακλαδώσεων διπλασιασμού περιόδου στην λογιστική χαρτογράφηση μπορεί να απεικονιστεί χρησιμοποιώντας ένα διάγραμμα παραμέτρων φάσης, το οποίο ονομάζεται διάγραμμα διακλάδωσης μιας παραμέτρου.



Σχήμα 5.6.β: Το διάγραμμα διακλάδωσης της λογιστικής χαρτογράφησης (2).

5.7 Κώδικας Υλοποίησης Νευρωνικού Δικτύου(CNN) σε Γλώσσα

Προγραμματισμού Python.

```
import numpy as np
```

```
# Ορίζουμε την αρχιτεκτονική του νευρωνικού δικτύου
```

```
class NeuralNetwork:
```

```

def __init__(self, sizes):

    self.sizes = sizes

    self.num_layers = len(sizes)

    self.weights = [np.random.randn(y, x) for x, y in zip(sizes[:-1], sizes[1:])]

def forward(self, a):

    for w in self.weights:

        a = sigmoid(np.dot(w, a))

    return a

# Συνάρτηση ενεργοποίησης (σιγμοειδής)

def sigmoid(z):

    return 1.0 / (1.0 + np.exp(-z))

# Δημιουργούμε ένα νευρωνικό δίκτυο με 784 εισόδους, 30 κρυφά νευρώνια και 10
εξόδους

network = NeuralNetwork(sizes=[784, 30, 10])

# Εκπαιδεύουμε το νευρωνικό δίκτυο με τα δεδομένα MNIST

# Εκτελούμε το νευρωνικό δίκτυο σε ένα δείγμα

input_data = np.random.randn(784, 1)

output = network.forward(input_data)

print("Αποτέλεσμα νευρωνικού δικτύου:", output)

```

Κεφάλαιο 6

6.1 Συζήτηση Έρευνας.

Η λογιστική χαρτογράφηση μπορεί να παρουσιαστεί σε διάφορες μορφές εφαρμόζοντας αντικατάσταση μεταβλητής. Οι πιο συνηθισμένες μορφές είναι οι εξής:


$$x_{p+1} = a \cdot x_p \cdot (1 - x_p)$$

$$x_{p+1} = 1 - r \cdot x_p^2$$

$$x_{p+1} = x_p^2 + c$$

όπου τα a , r , c είναι σταθερές. Στην παρούσα μελέτη, χρησιμοποιείται η αναπαράσταση της λογιστικής χαρτογράφησης που εκφράζεται με την Εξίσωση (2). Ωστόσο, μπορεί να εφαρμοστεί οποιαδήποτε μορφή από το σετ (5).

Το σχήμα της εξάρτησης της ακρίβειας ταξινόμησης από την παράμετρο r μοιάζει με την εξάρτηση του εκθέτη Lyapunov λ από το r και υποδεικνύει τη σημασία της χαοτικής συμπεριφοράς της λογιστικής χαρτογράφησης στη διαδικασία αναγνώρισης. Ο εκθέτης Lyapunov λ αντιπροσωπεύει έναν αποτελεσματικό τρόπο αξιολόγησης της «χαοτικής» και καθορίζει το μέτρο της απόκλισης της τροχιάς - δηλαδή, τη φύση της αλλαγής της τροχιάς ανάλογα με την αλλαγή στην αρχική κατάσταση. Το θετικό $\lambda > 0$ αντιστοιχεί σε χαοτική συμπεριφορά με αποκλίνουσες τροχιές, ενώ το $\lambda < 0$ αντιστοιχεί σε συγκλίνουσες τροχιές και χωρίς χάος. Η σύγκριση της εξάρτησης του εκθέτη Lyapunov για την λογιστική χαρτογράφηση (2) και την ακρίβεια ταξινόμησης του δικτύου LogNNet-784: 100:10 από την παράμετρο r παρουσιάζεται στο Σχήμα 6.1. Οι εμφανιζόμενες εξαρτήσεις υπολογίζονται για το ίδιο σύνολο τιμές r .



Σχήμα 6.1 Σύγκριση ακρίβειας ταξινόμησης (LogNet-784:100:10) και εκθέτη Lyapunov λ στην παράμετρο r . Τα κατακόρυφα πράσινα σημάδια με επισημασμένες τιμές r αντιστοιχούν στα τοπικά μέγιστα των τιμών της ακρίβειας ταξινόμησης, τα κόκκινα σημάδια αντιστοιχούν στα τοπικά ελάχιστα. Ένα από τα τοπικά ελάχιστα των τιμών του εκθέτη Lyapunov σημειώνεται με μαύρο σημάδι. Η γραμμή 1 είναι μια γραμμή κατά προσέγγιση για τις τιμές ακρίβειας ταξινόμησης. Η γραμμή 2 είναι μια κατά προσέγγιση γραμμή για τις τιμές λ .

Μπορεί να παρατηρηθεί η αυξητική τάση αλλαγής της ακρίβειας ταξινόμησης στο r (θετική κλίση της γραμμής 1), με μέγιστες τιμές στην περιοχή $r = 1,4-2$. Αυτό συσχετίζεται με τη θετική κλίση της αλλαγής λ στο r (Γραμμή 2), όπου οι θετικές τιμές του λ επικρατούν στο $r > 1,4$. Επομένως, μια αύξηση στη χαοτική ικανότητα της λογιστικής χαρτογράφησης οδηγεί σε αύξηση της ακρίβειας ταξινόμησης και οι υψηλότερες τιμές ακρίβειας ταξινόμησης παρατηρήθηκαν στο $r > 1,4$.

Αν και υπάρχει συσχέτιση μεταξύ της ακρίβειας ταξινόμησης και του εκθέτη Lyapunov, δεν είναι αυστηρή. Για παράδειγμα, τα τοπικά ελάχιστα λ στο $r = 1,48, 1,63, 1,765$ αντιστοιχούν στα τοπικά ελάχιστα ακρίβειας ταξινόμησης (κόκκινα σημάδια στο Σχήμα

7). Ωστόσο, υπάρχει ένας αριθμός ελάχιστων λ , για παράδειγμα, για $r = 1,575$, για τα οποία η ακρίβεια ταξινόμησης παραμένει υψηλή (μαύρο σημάδι στο Σχήμα 7). Το ευρύτερο ελάχιστο λ στην περιοχή του $r = 1,765$ αντιστοιχεί επίσης στο ευρύτερο ελάχιστο της ακρίβειας ταξινόμησης. Τα τοπικά μέγιστα ακρίβειας ταξινόμησης, για παράδειγμα, για $r = 1,65, 1,805, 1,885$, συσχετίζονται με ακόμη πιο αδύναμο $\lambda(r)$. Ωστόσο, σε ορισμένες περιπτώσεις, για παράδειγμα, για $r = 1,65, 1,805$, τα τοπικά μέγιστα ακρίβειας ταξινόμησης προκύπτουν στα όρια του ισχυρού χάους και της διατεταγμένης συμπεριφοράς της λογιστικής χαρτογράφησης. Ο σημαντικός ρόλος της χαοτικής δυναμικής της δεξαμενής επισημάνθηκε στις μελέτες για τα ESN (ρύθμιση της φασματικής ακτίνας) και τα LSM (ρυθμίζοντας την ιδιότητα διαχωρισμού) [30]. Μια λεπτομερής μελέτη των επιρροών των παραμέτρων χάους της λογιστικής χαρτογράφησης στην ακρίβεια ταξινόμησης του νευρωνικού δικτύου LogNNet μπορεί να αποτελέσει θέμα για μελλοντική έρευνα.

Ο σημαντικός ρόλος της χαοτικής δυναμικής στην παρουσιαζόμενη αρχιτεκτονική δικτύου απαιτεί μια υλοποίηση υλικού της δεξαμενής δικτύου, χρησιμοποιώντας, για παράδειγμα, αναλογικά κυκλώματα χαοτικών ταλαντωτών [46,47]. Με αυτόν τον τρόπο, ο επεξεργαστής συσκευών IoT απελευθερώνεται από πολύπλοκους υπολογισμούς καταστάσεων δεξαμενής. Αυτή η προσέγγιση είναι ένα πολλά υποσχόμενο θέμα για μελλοντικές μελέτες.

Το σχήμα των φίλτρων που παρουσιάζονται στο Σχήμα 6.1 εξαρτάται από τις παραμέτρους των Εξισώσεων (2) και (4) και από τον αριθμό των νευρώνων του κρυφού στρώματος p . Σε μελλοντικές μελέτες, οι ιδιότητες ταξινόμησης του δικτύου μπορούν να βελτιωθούν, για παράδειγμα, με ανάμειξη σειρών (στήλων) φίλτρων με διαφορετικές τιμές p , με εφαρμογή διαφορετικής παραμέτρου r ή με εφαρμογή συνδυασμού εξισώσεων λογιστικής χαρτογράφησης σε διαφορετικά μέρη το φίλτρο.

Τέτοιοι μετασχηματισμοί θα μπορούσαν να οδηγήσουν στην ανακάλυψη καταλληλότερων διαμορφώσεων φίλτρων για κάθε συγκεκριμένο πρόβλημα ταξινόμησης.

Το κύριο πρακτικό πλεονέκτημα των δικτύων LogNet είναι ότι ο αλγόριθμος υλοποίησής τους, που βασίζεται στην λογιστική χαρτογράφηση, μπορεί να εξοικονομήσει σημαντικά πόρους μνήμης μεταφέροντας το υπολογιστικό φορτίο στον επεξεργαστή, ο οποίος υπολογίζει τους συντελεστές του πίνακα W χρησιμοποιώντας τις Εξισώσεις (1)–(4). Σε όλους τους αλγόριθμους, η έξοδος του δικτύου έχει την ίδια τιμή. Η κύρια διαφορά έγκειται στην ποσότητα της μνήμης που καταναλώνεται και στην ταχύτητα των αλγορίθμων. Η ποσότητα της μνήμης που καταναλώνεται από το LogNet-784:25:10 μπορεί να μειωθεί από 4 kB σε 1 kB χρησιμοποιώντας τον Αλγόριθμο 1. Ταυτόχρονα, η ακρίβεια ταξινόμησης $\approx 80\%$ αντιστοιχεί στην ακρίβεια ταξινόμησης των δικτύων δεξαμενών ESN (βλ. Πίνακα 1), αλλά η μνήμη MeW που χρησιμοποιείται από το LogNet-784:25:10 είναι σχεδόν 160 φορές μικρότερη. Σε σύγκριση με τα συνελκτικά (LeNet-1, CNN 2 kB) και τα επαναλαμβανόμενα δίκτυα (FastGRNN, Spectral-RNN), το πλεονέκτημα δεν είναι τόσο προφανές. Ωστόσο, οι δυνατότητες του LogNet δεν έχουν αποκαλυφθεί πλήρως και απαιτεί μια ολοκληρωμένη μελέτη. Επιπλέον, τα συνελκτικά δίκτυα απαιτούν πολύπλοκο κώδικα προγράμματος, ενώ το LogNet είναι ένα σχετικά απλό δίκτυο για εφαρμογή σε ενσωματωμένα συστήματα, όπως το Arduino ή το Raspberry Pi και άλλες περιορισμένες συσκευές. Αν και το LogNet παρέχει σχεδόν τις ίδιες τιμές ακρίβειας ταξινόμησης και μνήμης που χρησιμοποιούνται με τους αλγόριθμους Bonsai και ProtoNN, η αρχή των αλγορίθμων είναι θεμελιωδώς διαφορετική.

6.2 Αποτελέσματα Ερευνητικού Μέρους.

Η μελέτη παρουσιάζει το νευρωνικό δίκτυο LogNet, το οποίο χρησιμοποιεί φίλτρα που βασίζονται σε λογιστική χαρτογράφηση για να επιτύχει δείκτες υψηλής ακρίβειας για την ταξινόμηση των χειρόγραφων ψηφίων από τη βάση δεδομένων MNIST-10. Το δίκτυο χρησιμοποιεί λιγότερη μνήμη για συστοιχίες βάρους από πολλές γνωστές διαμορφώσεις δικτύου. Οι μελλοντικές ερευνητικές κατευθύνσεις ενδέχεται να αναζητήσουν άλλες χαοτικές χαρτογραφήσεις και αρχικές συνθήκες, για πιο αποτελεσματική λειτουργία του LogNet. Από ερευνητική άποψη, το LogNet είναι ενδιαφέρον για τη μελέτη των θεμελιωδών ζητημάτων της επίδρασης του χάους στη συμπεριφορά των νευρωνικών δικτύων δεξαμενών. Το προτεινόμενο νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί για την εφαρμογή τεχνητής νοημοσύνης που βασίζεται σε περιορισμένες συσκευές με περιορισμένο μέγεθος μνήμης, οι οποίες αποτελούν αναπόσπαστα μπλοκ για τη δημιουργία AmI και σύγχρονων περιβαλλόντων IoT.

6.3 Συμπεράσματα -Μελλοντικές Προτάσεις.

Τα νευρωνικά δίκτυα είναι εφαρμόσιμα σχεδόν σε κάθε κατάσταση στην οποία ισχύει μια σχέση μεταξύ μεταβλητών πρόβλεψης (ανεξάρτητες, εισροές) και προβλεπόμενες μεταβλητές (εξαρτημένες, εκροές), ακόμα και όταν αυτή η σχέση είναι πολύ περίπλοκη για να αποδοθεί με τους συνηθισμένους όρους της «συσχέτισης» ή των «διαφόρων ομάδων». Ενδεικτικά αντιπροσωπευτικά παραδείγματα προβλημάτων στα οποία η ανάλυση των νευρωνικών δικτύων έχει εφαρμοστεί με επιτυχία είναι τα εξής:

- *Ιατρική διάγνωση: Ένα ευρύ φάσμα ιατρικά συσχετιζόμενων ενδείξεων, όπως ο συνδυασμός της καρδιακής συχνότητας, τα επίπεδα των διαφόρων ουσιών στο αίμα,*

ο ρυθμός της αναπνοής μπορούν να παρακολουθηθούν. Η εκδήλωση μιας συγκεκριμένης ιατρικής κατάστασης, γίνεται να συσχετιστεί με ένα πολύπλοκο συνδυασμό μεταβολών σε ένα υποσύνολο μεταβλητών που παρακολουθούνται. Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την αναγνώριση αυτού του προτύπου πρόβλεψης, ώστε να χορηγηθεί η κατάλληλη θεραπεία.

- *Χρηματιστηριακές προβλέψεις:* Οι διακυμάνσεις των τιμών των μετοχών και των χρηματιστηριακών δεικτών είναι ακόμα ένα παράδειγμα ενός πολύπλοκου, πολυδιάστατου, αλλά και σε ορισμένες περιπτώσεις εν μέρει *ντετερμινιστικού* φαινομένου. Τα νευρωνικά δίκτυα χρησιμοποιούνται από πολλούς τεχνικούς αναλυτές, ώστε να κάνουν προβλέψεις σχετικά με τις τιμές των μετοχών, βασιζόμενοι σε ένα μεγάλο αριθμό παραγόντων, όπως δηλαδή, τις προηγούμενες επιδόσεις άλλων αποθεμάτων και διαφόρων οικονομικών δεικτών.
- *Πιστωτική ανάθεση:* Μια ποικιλία από κομμάτια πληροφοριών, τα οποία είναι συνήθως γνωστά για ένα απαιτούμενο δάνειο. Για παράδειγμα, η ηλικία του αιτούντος, η εκπαίδευση, το επάγγελμα και πολλά άλλα στοιχεία που μπορεί να είναι διαθέσιμα. Μετά την εκπαίδευση ενός νευρωνικού δικτύου σε ιστορικά δεδομένα η ανάλυση μπορεί να εκτοπίσει τα πιο κατάλληλα και σχετικά χαρακτηριστικά και να τα χρησιμοποιήσει για την ταξινόμηση των αιτούντων ως χαμηλού ή υψηλού κινδύνου.
- *Παρακολούθηση της κατάστασης των μηχανημάτων:* Τα νευρωνικά δίκτυα μπορούν να συμβάλλουν στη μείωση του κόστους με την εξασφάλιση της πρόσθετης εμπειρογνωμοσύνης για τον προγραμματισμό προληπτικής συντήρησης των μηχανημάτων. Ένα νευρωνικό δίκτυο, λοιπόν, μπορεί να εκπαιδευτεί με τέτοιο τρόπο, ώστε να διακρίνει από τους ήχους τους οποίους παράγει μια μηχανή είτε αν εκτελεί

κανονικά τις λειτουργίες της, είτε βρίσκεται στα πρόθυρα εμφάνισης οποιασδήποτε δυσλειτουργίας. Μετά από αυτήν την περίοδο εκπαιδευτικής κατάρτισης, η εμπειρία του ίδιου δικτύου είναι δυνατό να χρησιμοποιηθεί με σκοπό την προειδοποίηση ενός τεχνικού για κάποια επικείμενη βλάβη προτού συμβεί και ενδεχομένως προκαλέσει πολυδάπανες και τεχνικού για κάποια επικείμενη βλάβη προτού συμβεί και ενδεχομένως προκαλέσει πολυδάπανες και απρόβλεπτες χρονικές καθυστερήσεις.

- *Συστήματα διαχείρισης κινητήρα: Τα νευρωνικά δίκτυα έχουν χρησιμοποιηθεί για την ανάλυση των εισροών που δέχονται οι αισθητήρες ενός κινητήρα. Το νευρωνικό δίκτυο ελέγχει μια ποικιλία παραμέτρων με τις οποίες λειτουργεί ο κινητήρας, προκειμένου να επιτευχθεί ένας συγκεκριμένος στόχος. Για παράδειγμα, το δίκτυο αυτό επιχειρεί την ελαχιστοποίηση της κατανάλωσης των καυσίμων.*

Βιβλιογραφία

- State L. & Vlamos P., (2000), "The POMDP modeling in the Analysis of Genetic Algorithms", The Annals of Bucharest University XLIX*
- State L., Cocianu C. & Vlamos P. ,(2005), "Neural Network for Principal Component Analysis with Applications in Image Compression", Journal of Systemics, Cybernetics and Informatics*
- State L., Cocianu C., Vlamos P. & Miroiu M.,(2002), "A specialized Neural Network for implementing the HMM approach in Learning the Bayesian Procedure", 4th International Workshop on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC 02).*
- M. Jethanandani, A. Sharma, T. Perumal, and J.R. Chang. "Multi-label classification based ensemble learning for human activity recognition in smart home." Internet of Things, 2020*
- A.-J. Majumder, and J.A. Izaguirre. "A smart IoT security system for smart-home using motion detection and facial recognition." IEEE Annual Computers, Software, and Applications Conference, 2020*
- A. Lentzas, and D. Vrakas. Non-intrusive human activity recognition and abnormal behavior detection on elderly people: A review. Artificial Intelligence Review, 2021*
- A.J. Perez, and S. Zeadally. Recent advances in wearable sensing technologies. Sensors, 2019 <https://www.fitbit.com/global/eu/products/trackers/inspire3>.*
- A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, P. MartinezGonzalez, and J. Garcia-Rodriguez. "A survey on deep learning techniques for image and video semantic segmentation." Applied Soft Computing, 2018*
- M. Davide, G. Campobello, G. Gugliandolo, A. Celesti, M. Villari, and N. Donato.*

- "Comparison of Noise Reduction Techniques for Dysarthric Speech Recognition."*
IEEE International Symposium on Medical Measurements and Applications, 2022 36
 37
- M.W. Akram, M. Salman, M. Farrukh Bashir, S. Muhammad, S. Salman, T. R. Gadekallu, and A.R. Javed. "A novel deep auto-encoder based linguistics clustering model for social text." *Transactions on Asian and Low-Resource Language Information Processing, 2022*
- L. Shan, M. Zhang, L. Deng, and G. Gong. *A Dynamic Multi-Precision Fixed-Point Data Quantization Strategy for Convolutional Neural Network. Communications in Computer and Information Science, 2016* <https://www.renesas.com/us/en>.
<https://howthingsfly.si.edu/flight-dynamics/roll-pitch-and-yaw>
- J. Yu, X. Zheng, and S. Wang.. "A deep autoencoder feature learning method for process pattern recognition." *Journal of Process Control, 2019*
- D. Nidhi, S.N. Singh, S.K. Challa, V.B. Semwal, and M. L. S. Kumar. "A Survey on Human Activity Recognition Using Deep Learning Techniques and Wearable Sensor Data." *Machine Learning, Image Processing, Network Security and Data Sciences, 2023*
- S. Bai, J.Z. Kolter, and V. Koltun. *An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv preprint arXiv:1803.01271, 2018*
- J.H. Luo, H. Zhang, H.Y. Zhou, C.W. Xie, J. Wu, and W. Lin. *Thinet: pruning cnn filters for a thinner net. IEEE transactions on pattern analysis and machine intelligence, 2018*

S. Dargan, M. Kumar, M.R. Ayyagari and G. Kumar. A survey of deep learning and its applications: a new paradigm to machine learning. Archives of Computational Methods in Engineering, 2020

P. Ongsulee, "Artificial intelligence, machine learning and deep learning. International Conference on ICT and Knowledge Engineering, 2017.

Tom M.Mitchell, Machine Learning, McGraw-Hill Series in Computer Science (1997)

Ian J.Goodfellow-Yasuo Bengio-Aaron Courville, Deep Learning, MIT press book

Αργυράκης Πάνος, Νευρωνικά Δίκτυα και Εφαρμογές, Ελληνικό Ανοικτό Πανεπιστήμιο (2001).

Andreas Chouliaras, Evangelia Fragkou, Dimitrios Katsaros, Feed Forward Neural Network Sparsification with Dynamic Pruning, Proceedings of the Panhellenic Conference on Informatics (PCI), pp. 12-17, 2021

Evangelia Fragkou, Marianna Koulouki, Dimitrios Katsaros, Model Reduction of Feed Forward Neural Networks for Resource-Constrained Devices, Applied Intelligence, vol. 53, pp. 14102-14127, 2023

Evangelia Fragkou, Vasileios Lygnos, Dimitrios Katsaros, Transfer Learning for Convolutional Neural Networks in Tiny Deep Learning Environments, Proceedings of the Panhellenic Conference on Informatics (PCI), pp. 145-150, 2022

Kevin P.Merphy, Machine Learning : A Probabilistic Prospective, The MIT press Cambridge (2012) 5) Kishan Mehrotra-Chilukuri K.Mohan-Sanjay Ranka, Elements of Artificial Neural Networks, A Bradford Book-The MIT press Cambridge (1997)

Christopher M. Bishop, Neural Networks for Pattern Recognition, Oxford University Press (1995)

Θεοδόση-Κοκκίνου Λάουρα, Τεχνητά Νευρωνικά Δίκτυα και Εφαρμογές στα Συστήματα Αυτόματου Ελέγχου, Διπλωματική Εργασία, Πανεπιστήμιο Πατρών (2013)

Μελέτη Χ. Παναγιώτη, Τεχνικές Βαθιάς Μάθησης και Εφαρμογές στην Ανίχνευση

Προσώπων σε Εικόνες, Διπλωματική Εργασία, ΕΜΠ (2015)

Model Extremely Complex Function, Neural Networks

Maas Andrew, Hannun Awni, Ng Andrew, Rectifier Nonlinearities Improve Neural

Network Acoustic Models, Stanford University, (2013)

James L.McClelland & Axel Cleeremans Connectionist Models, Oxford University

Press (2009)

Pomerleau, Dean A. "Alvinn: An autonomous land vehicle in a neural network." In

Advances in neural information processing systems, pp. 305-313.

F. Chollet, Deep Learning with Python, Second Edition, Manning, 2021.