



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ**

**ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ**

**ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ**

**ΥΠΟΛΟΓΙΣΤΩΝ**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Χρήση νευρωνικών δικτύων αιχμών**

**για εφαρμογές μηχανικής όρασης**

**ΤΣΕΤΣΩΝΗΣ ΓΕΩΡΓΙΟΣ**

**A.M. 19390236**

**Εισηγητής: ΑΝΤΩΝΙΟΣ ΜΠΟΓΡΗΣ**

**Μέλη Εξεταστικής Επιτροπής συμπεριλαμβανομένου και του Εισηγητή**

Η πτυχιακή/διπλωματική εργασία εξετάστηκε επιτυχώς από την κάτωθι  
Εξεταστική Επιτροπή:

<b>A/A</b>	<b>ΟΝΟΜΑ ΕΠΩΝΥΜΟ</b>	<b>ΒΑΘΜΙΑΔΑ/ΙΔΙΟΤΗΤΑ</b>	<b>ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ</b>
<b>1</b>	<b>ΑΝΤΩΝΙΟΣ ΜΠΟΓΡΗΣ</b>	<b>ΚΑΘΗΓΗΤΗΣ</b>	
<b>2</b>	<b>ΝΙΚΟΛΑΟΣ ΜΥΡΙΔΑΚΗΣ</b>	<b>ΑΝΑΠΛΗΡΩΤΗΣ ΚΑΘΗΓΗΤΗΣ</b>	
<b>3</b>	<b>ΠΑΝΑΓΙΩΤΗΣ ΚΑΡΚΑΖΗΣ</b>	<b>ΑΝΑΠΛΗΡΩΤΗΣ ΚΑΘΗΓΗΤΗΣ</b>	

**ΗΜΕΡΟΜΗΝΙΑ ΕΞΕΤΑΣΗΣ: 9/10/2024**

## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ

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

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

Ο Δηλών

Τσετσώνης Γεώργιος



## **ΕΥΧΑΡΙΣΤΙΕΣ**

Η παρούσα διπλωματική εργασία ολοκληρώθηκε μετά από επίμονες προσπάθειες, σε ένα ενδιαφέρον γνωστικό αντικείμενο. Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου κύριο Αντώνη Μπόγρη για την διδασκαλία, συνεργασία, θετική ενέργεια και καθοδήγησή του καθώς με βοήθησαν πάρα πολύ. Ακόμη θα ήθελα να ευχαριστήσω όλους τους καθηγητές του τμήματός μου Μηχανικών Πληροφορικής και Υπολογιστών για την πολύτιμη προσφορά τους στην διδασκαλία όλα αυτά τα χρόνια. Φυσικά δεν ξεχνώ το Πανεπιστήμιο Δυτικής Αττικής για την παροχή σίτισης, δομών και περιβάλλοντος. Τέλος, εκφράζω την ευγνωμοσύνη μου στην οικογένειά μου για την υποστήριξη όλα αυτά τα χρόνια δίνοντάς μου ώθηση να υπερβώ κάθε εμπόδιο.

## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία ασχολείται με τη μελέτη της χρήσης νευρωνικών δικτύων αιχμών για εφαρμογές μηχανικής όρασης. Παρουσιάζεται η έρευνα του απαραίτητου υλικού για τη θεωρητική, αλλά και την πρακτική μελέτη και θα αναλυθούν όλες οι απαραίτητες έννοιες για την πλήρη κατανόηση του αντικειμένου. Η παρούσα μελέτη παρέχει μια ολοκληρωμένη επισκόπηση της μηχανικής μάθησης και των νευρωνικών δικτύων, ξεκινώντας με μια εισαγωγή στη μηχανική μάθηση, τον ορισμό της, το ιστορικό πλαίσιο και τη σημασία της. Συζητά τη βαθιά μάθηση, τα συστατικά της, τα οφέλη, τις προκλήσεις και τις εφαρμογές σε περιβάλλοντα cloud. Στη συνέχεια, το κείμενο εμβαθύνει στα νευρωνικά δίκτυα, καλύπτοντας τους ορισμούς τους, την ιστορική εξέλιξη, τις βιολογικές συγκρίσεις, διάφορους τύπους (όπως CNN και RNN) και μεθόδους εκπαίδευσης. Επιπλέον, διερευνά την όραση μηχανών, συμπεριλαμβανομένων συνόλων δεδομένων όπως το MNIST και το CIFAR-10, και καταλήγει με πληροφορίες για τα Spiking Neural Networks (SNNs), την αρχιτεκτονική, τα πλεονεκτήματα και τις εφαρμογές τους. Το περιεχόμενο είναι δομημένο σε κεφάλαια, καθένα από τα οποία εξετάζει βασικές πτυχές αυτών των τεχνολογιών.

Χρήση νευρωνικών δικτύων αιχμών για εφαρμογές  
μηχανικής όρασης

## **ABSTRACT**

This thesis deals with the study of the use of spiking neural networks for machine vision applications. The research of the necessary material for both theoretical and practical study is presented and all the concepts necessary for a complete understanding of the subject will be analyzed. This paper provides a comprehensive overview of machine learning and neural networks, starting with an introduction to machine learning, its definition, historical context and importance. It discusses deep learning, its components, benefits, challenges and applications in cloud environments such as AWS. The text then delves into neural networks, covering their definitions, historical evolution, biological comparisons, various types (such as CNN and RNN) and training methods. In addition, it explores machine vision, including datasets such as MNIST and CIFAR-10, and concludes with information on Spiking Neural Networks (SNN), their architecture, advantages and applications. The content is structured in chapters, each of which addresses key aspects of these technologies.

## Περιεχόμενα

<b>Κεφάλαιο 1<sup>ο</sup> Μηχανική Μάθηση</b>	<b>13</b>
<b>1.1 Εισαγωγή στην μηχανική μάθηση</b>	<b>13</b>
<b>1.2 Ορισμός</b>	<b>14</b>
1.2.1 Εκμάθηση πρακτικών δεξιοτήτων μηχανικής μάθησης	15
1.2.2 Ταξινόμηση της Μηχανικής Μάθησης	16
<b>1.3 Ιστορική αναδρομή</b>	<b>18</b>
<b>1.4 Σημασία της μηχανικής μάθησης</b>	<b>21</b>
<b>1.5 Προβλήματα</b>	<b>24</b>
<b>1.6 Βαθιά μάθηση</b>	<b>24</b>
1.6.1 Η λειτουργία της βαθιάς μάθησης	27
1.6.2 Τα συστατικά ενός δικτύου βαθιάς μάθησης	27
1.6.3 Τι είναι η βαθιά μάθηση στο πλαίσιο της μηχανικής μάθησης	28
1.6.4 Τα οφέλη της βαθιάς μάθησης έναντι της μηχανικής μάθησης	29
1.6.5 Οι προκλήσεις της βαθιάς μάθησης	30
1.6.6 Τα οφέλη της βαθιάς εκμάθησης στο cloud	30
<b>1.7 Σύγχρονες εφαρμογές των τεχνητών νευρωνικών δικτύων</b>	<b>31</b>
<b>Κεφάλαιο 2<sup>ο</sup> Νευρωνικά δίκτυα</b>	<b>36</b>
<b>2.1 Εισαγωγή στα νευρωνικά δίκτυα</b>	<b>36</b>
<b>2.2 Ορισμός</b>	<b>41</b>
<b>2.3 Ιστορική αναδρομή</b>	<b>42</b>
2.3.1 Τα πρώτα πρότυπα των νευρωνικών δικτύων	43
<b>2.4 Βιολογικοί νευρώνες</b>	<b>45</b>
2.4.1 Σύγκριση βιολογικών και τεχνητών νευρωνικών δικτύων	47
<b>2.5 Τύποι νευρωνικών δικτύων</b>	<b>49</b>
2.5.1 Νευρωνικό δίκτυο τροφοδότησης προς τα εμπρός (Feedforward neural network, FNN)	49
2.5.2 Multilayer Perceptron (MLP)	50
2.5.3 Συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network, CNN)	51



2.5.4 Επαναλαμβανόμενο νευρωνικό δίκτυο(Recurrent Neural Network, RNN)	51
2.5.5 Μακροχρόνια Βραχυπρόθεσμη Μνήμη (Long Short-Term Memory, LSTM)	52
2.5.6 Δίκτυο Ακτινικής Συνάρτησης Βάσης (Radial Basies Function Networks, RBFN)	53
2.5.7 Αρθρωτό νευρωνικό δίκτυο (Modular Neural Newtwork, MNN)	53
<b>2.6 Εκπαίδευση των νευρωνικών δικτύων</b>	<b>54</b>
<b>2.7 Πλεονεκτήματα και Μειονεκτήματα των Νευρωνικών Δικτύων</b>	<b>55</b>
<b>2.8 Είδη Δικτύων και μέθοδοι εκπαίδευσης</b>	<b>56</b>
2.8.1 Ο αισθητήρας	56
2.8.2 Το πρόβλημα της αποκλειστικής διάζευξης	59
2.8.3 Γραμμική Διαχωριστικότητα	61
2.8.4 Ικανότητα αποθήκευσης	64
2.8.5 Η εκπαίδευση του αισθητήρα	64
2.8.6 Η διαδικασία εκπαίδευσης σύμφωνα με τον Κανόνα Δέλτα	65
2.8.7 Προβλήματα κατά την εκπαίδευση	69
<b>Κεφάλαιο 3<sup>ο</sup> Μηχανική Όραση</b>	<b>70</b>
<b>3.1 Εισαγωγή στη μηχανική όραση</b>	<b>70</b>
<b>3.2 Datasets μηχανικής όρασης</b>	<b>70</b>
3.2.1 MNIST	70
3.2.2 CIFAR-10	71
<b>3.2.3 ImageNet</b>	<b>72</b>
<b>3.3 Νευρωνικά Δίκτυα: AlexNet, LeNet</b>	<b>73</b>
<b>3.4 Accuracy and number of parameters</b>	<b>75</b>
<b>Κεφάλαιο 4<sup>ο</sup> SNN (Spiking Neural Networks-SNNs)</b>	<b>78</b>
<b>4.1 Αρχιτεκτονική και Λειτουργία</b>	<b>78</b>
<b>4.2 Πλεονεκτήματα και μειονεκτήματα</b>	<b>84</b>
<b>4.3 Μοντέλα SNNs</b>	<b>85</b>
<b>4.4 Πολυπλοκότητα</b>	<b>86</b>
<b>4.5 Μοντελοποίηση Νευρώνων</b>	<b>86</b>
<b>4.6 Εφαρμογές των SNNs</b>	<b>87</b>

<b>4.7 Επεξεργασία βάσει συμβάντων: SpiNNaker</b>	<b>88</b>
<b>4.8 Δομική πλαστικότητα για ταξινόμηση</b>	<b>91</b>
4.8.1 Τοπογραφικός χάρτης	92
4.8.2 Αρχιτεκτονική δικτύου	94
<b>4.9 Ταξινόμηση</b>	<b>98</b>
<b><i>Κεφάλαιο 5ο Συμπεράσματα</i></b>	<b><i>101</i></b>
<b><i>Βιβλιογραφία</i></b>	<b><i>102</i></b>

### **Πίνακας πινάκων**

Πίνακας 1-1: Εποπτευόμενη μάθηση παράδειγμα δεδομένων.....	17
Πίνακας 1-2: Μη εποπτευόμενη μάθηση.....	17
Πίνακας 2-1 Η συνάρτηση XOR .....	59
Πίνακας 4-1: Οι παράμετροι που χρησιμοποιούνται στις προσομοιώσεις που παρουσιάζονται στο παρόν τμήμα.....	100

### **Πίνακας σχημάτων**

<i>Σχήμα 1-1: Γράφημα από στοιχεία βάσης δεδομένων που αναφέρεται σε δάνεια.....</i>	<i>32</i>
<i>Σχήμα 2-1: Το μη-γραμμικό μοντέλο ενός τεχνητού νευρώνα.....</i>	<i>37</i>
<i>Σχήμα 2-2: Εμπρόσθιας-Τροφοδότησης δίκτυο με ένα επίπεδο νευρώνων.....</i>	<i>38</i>
<i>Σχήμα 2-3: Πλήρως συνδεδεμένο δίκτυο εμπρός-τροφοδότησης με ένα κρυφό επίπεδο και ένα επίπεδο εξόδου. ....</i>	<i>39</i>
<i>Σχήμα 2-4: Χαρακτηριστικά νευρωνικών δικτύων .....</i>	<i>40</i>
<i>Σχήμα 2-5: Αναδρομικό δίκτυο χωρίς ανατροφοδότηση και χωρίς κρυφούς νευρώνες .....</i>	<i>40</i>
<i>Σχήμα 2-6: (a) Μονοδιάστατο πλέγμα με 3 νευρώνες. (b) Δυσδιάστατο πλέγμα με 3 x 3 νευρώνες. ....</i>	<i>41</i>
<i>Σχήμα 2-7: Ο στοιχειώδης αισθητήρας.....</i>	<i>44</i>
<i>Σχήμα 2-8: Ο αισθητήρας με n νευρώνες. ....</i>	<i>45</i>
<i>Σχήμα 2-9: Επίπεδα νευρωνικού δικτύου .....</i>	<i>46</i>
<i>Σχήμα 2-10: Διάγραμμα της ταχύτητας με την οποία μπορούν να γίνουν οι αλλαγές ως προς τον ολικό αριθμό συνάψεων σε διάφορους οργανισμούς. Εδώ η ταχύτητα υπονοεί το πόσο γρήγορα μπορούν να γίνουν οι υπολογισμοί.....</i>	<i>49</i>
<i>Σχήμα 2-11: Τεχνητό νευρωνικό δίκτυο .....</i>	<i>50</i>
<i>Σχήμα 2-12: ο αισθητήρας με δυο εισόδους για το πρόβλημα XOR.....</i>	<i>59</i>

Σχήμα 2-13: Το πρόβλημα της συνάρτησης XOR σε αναπαράσταση στο επίπεδο $x-y$ .....	60
Σχήμα 2-14: Κυρτή περιοχή απόφασης που παράγεται από σύστημα δυο επιπέδων .....	62
Σχήμα 2-15: Δίκτυο τριών επιπέδων .....	63
Σχήμα 2-16: Αλγόριθμος εκπαίδευσης του δικτύου .....	66
Σχήμα 2-17: Είδη συναρτήσεων ενεργοποίησης .....	68
Σχήμα 4-1 .....	80
Σχήμα 4-2: Τρεις διαφορετικές μέθοδοι μετατροπής των δεδομένων σε spikes .....	81
Σχήμα 4-3: Κωδικοποίηση καθυστέρησης (latency coding) .....	82
Σχήμα 4-4: Το πρόβλημα των νεκρών νευρώνων και η λύση (Surrogate Gradient Descent) .	82
Σχήμα 4-5: 500 000-core SpiNNaker Human Brain Project platform.....	90
Σχήμα 4-6: Αναπαράσταση εικόνας πολλαπλών κλιμάκων Κώδικας PyNN .....	91
Σχήμα 4-7: Τοπογραφικοί χάρτες που υπάρχουν στον εγκέφαλο και εξηγεί πώς οι νευρώνες συνδέονται μεταξύ τους.....	92
Σχήμα 4-8: Αρχιτεκτονική δικτύου που χρησιμοποιείται για την εκπαίδευση.....	96
Σχήμα 4-9: Παράδειγμα εισόδων που παρουσιάζονται από κάθε στρώμα πηγής στο αντίστοιχο στρώμα στόχου πριν από τη μετατροπή σε αναπαράσταση με βάση το ρυθμό και την προσθήκη θορύβου. ....	97
Σχήμα 4-10: Επίδραση της συναπτικής επανασύνδεσης.....	99

## Κεφάλαιο 1<sup>ο</sup> Μηχανική Μάθηση

### 1.1 Εισαγωγή στην μηχανική μάθηση

Ο όρος μηχανική μάθηση επινοήθηκε το 1959 από τον Άρθουρ Σάμιουελ, έναν υπάλληλο της IBM και πρωτοπόρο στον τομέα των παιχνιδιών υπολογιστών και της τεχνητής νοημοσύνης (Helm et al., 2020). Το συνώνυμο αυτό εκπαιδευόμενοι υπολογιστές χρησιμοποιήθηκε επίσης σε αυτή τη χρονική περίοδο (ElNaga & Murphy, 2015).

Μολονότι το παλαιότερο μοντέλο μηχανικής μάθησης εισήχθη κατά τη δεκαετία του 1950, όταν ο Άρθουρ Σάμιουελ εφηύρε ένα πρόγραμμα που υπολόγιζε την πιθανότητα νίκης στο παιχνίδι της ντάμας για κάθε πλευρά, η ιστορία της μηχανικής μάθησης ξεκινά από δεκαετίες ανθρώπινης επιθυμίας και προσπάθειας μελέτης των ανθρώπινων γνωστικών διαδικασιών (Rebala et al., 2019).

Το 1949, ο Καναδός ψυχολόγος Donald Hebb δημοσίευσε το βιβλίο «The Organisations of Behavior», στο οποίο εισήγαγε μια θεωρητική νευρική δομή που σχηματίζεται από ορισμένες αλληλεπιδράσεις μεταξύ των νευρικών κυττάρων. Το μοντέλο του Hebb για τους νευρώνες που αλληλεπιδρούν μεταξύ τους έθεσε μια βάση για το πώς λειτουργούν η Τεχνητή Νοημοσύνη (TN) και οι αλγόριθμοι μηχανικής μάθησης κάτω από κόμβους ή τεχνητούς νευρώνες που χρησιμοποιούνται από υπολογιστές για την επικοινωνία δεδομένων (Rebala et al., 2019). Άλλοι ερευνητές που έχουν μελετήσει τα ανθρώπινα γνωστικά συστήματα συνέβαλαν επίσης στις σύγχρονες τεχνολογίες μηχανικής μάθησης, συμπεριλαμβανομένων των Walter Pitts και Warren McCulloch, οι οποίοι πρότειναν τα πρώιμα μαθηματικά μοντέλα νευρωνικών δικτύων για τον εντοπισμό των αλγορίθμων που αντικατοπτρίζουν τις διαδικασίες της ανθρώπινης σκέψης (Rebala et al., 2019).

Στις αρχές της δεκαετίας του 1960, μια πειραματική «μηχανή εκμάθησης» με μνήμη με διάτρητη ταινία, που ονομάστηκε Cybertron, είχε αναπτυχθεί από την εταιρεία Raytheon για την ανάλυση σημάτων σόναρ, ηλεκτροκαρδιογραφημάτων και μοτίβων ομιλίας χρησιμοποιώντας στοιχειώδη ενισχυτική μάθηση. Η μηχανή είχε «καταρτιστεί» επανειλημμένα από έναν άνθρωπο χειριστή/εκπαιδευτή ώστε να αναγνωρίζει μοτίβα και εξοπλίστηκε με ένα πλήκτρο «goof» ώστε να την αναγκάζει να αξιολογεί εκ νέου τις εσφαλμένες αποφάσεις (Kumar & Bhawna, 2024). Ένα αντιπροσωπευτικό βιβλίο για την έρευνα στη μηχανική μάθηση κατά τη διάρκεια της δεκαετίας του 1960 ήταν το βιβλίο του Nilsson για τις Μηχανές Μάθησης, που ασχολείται κυρίως με τη μηχανική μάθηση στην

ταξινόμηση προτύπων. Το ενδιαφέρον που σχετίζεται με την αναγνώριση προτύπων συνεχίστηκε έως τη δεκαετία του 1970, όπως περιγράφεται από τους Duda και Hart το 1973. Το 1981 δόθηκε μια αναφορά σχετικά με τη χρήση στρατηγικών διδασκαλίας, ούτως ώστε ένα τεχνητό νευρωνικό δίκτυο να μάθει να αναγνωρίζει 40 χαρακτήρες (26 γράμματα, 10 ψηφία και 4 ειδικά σύμβολα) από ένα τερματικό υπολογιστή (Kumar & Bhawna, 2024).

Ο Tom M. Mitchell παρείχε έναν ευρέως παρατιθέμενο και πλέον επίσημο ορισμό των αλγορίθμων που μελετήθηκαν στο πεδίο της μηχανικής μάθησης: «Ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από την εμπειρία  $E$  σε σχέση με κάποια κατηγορία εργασιών  $T$  και το μέτρο απόδοσης  $P$  εάν η απόδοσή του σε εργασίες στο  $T$ , ως μετρούνται από το  $P$ , βελτιώνονται με την εμπειρία  $E$ » (Cheng & Hackett, 2021). Αυτός ο ορισμός των εργασιών στις οποίες αφορά η μηχανική μάθηση προσφέρει έναν λειτουργικό ουσιαστικώς ορισμό αντί να ορίζει το πεδίο με γνωστικούς όρους. Αυτό ακολουθεί την πρόταση του Άλαν Τούρινγκ στην εργασία του «Computing Machinery and Intelligence», στην οποία το ερώτημα «Μπορούν οι μηχανές να σκεφτούν;» αντικαθίσταται με το ερώτημα «Μπορούν οι μηχανές να κάνουν αυτό που μπορούμε να κάνουμε εμείς (ως σκεπτόμενες οντότητες);» (Cheng & Hackett, 2021).

Η σύγχρονη μηχανική μάθηση έχει δύο στόχους: την ταξινόμηση των δεδομένων με βάση τα μοντέλα που έχουν αναπτυχθεί και την πραγματοποίηση προβλέψεων για μελλοντικά αποτελέσματα με βάση αυτά τα μοντέλα. Ένας υποθετικός αλγόριθμος που είναι ειδικός στην ταξινόμηση δεδομένων μπορεί να χρησιμοποιεί την προβολή σημείων σε υπολογιστή σε συνδυασμό με την εποπτευόμενη μάθηση, προκειμένου να τον εκπαιδεύσει να ταξινομήσει τα καρκινικά σημεία. Ένας αλγόριθμος μηχανικής μάθησης σχετικά με τις συναλλαγές μετοχών μπορεί να ενημερώσει τον επιχειρηματία για μελλοντικές πιθανές προβλέψεις (Mahesh, 2020).

## 1.2 Ορισμός

Η μηχανική μάθηση (Machine Learning, ML) είναι ένας τύπος Τεχνητής Νοημοσύνης (TN) που επιτρέπει στους υπολογιστές να μαθαίνουν χωρίς να χρειάζεται να είναι προγραμματισμένοι για τη συγκεκριμένη δράση. Ενέχει την τροφοδότηση δεδομένων σε αλγόριθμους που μπορούν στη συνέχεια να αναγνωρίσουν μοτίβα και να προβαίνουν σε προβλέψεις για νέα δεδομένα. Η μηχανική μάθηση χρησιμοποιείται σε μεγάλη ποικιλία εφαρμογών, όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και τα

συστήματα συστάσεων(Mahesh, 2020).

Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία σχετικά με κάποια κατηγορία εργασιών και το μέτρο απόδοσης, εάν η απόδοσή του στις εργασίες, ως μετράται από το μέτρο απόδοσης, βελτιώνεται με την εμπειρία (Arlaydin, 2021). Σχετικά παραδείγματα που θα βοηθούσαν στη κατανόηση του ορισμού της μηχανικής μάθησης αναφέρονται στη συνέχεια της ενότητας.

### 1.2.1 Εκμάθηση πρακτικών δεξιοτήτων μηχανικής μάθησης

Ανάπτυξη μιας πρακτικής εμπειρίας με τα εργαλεία της Python για μηχανική μάθηση, ακόμη κι αν δεν υπάρχει υπόβαθρο προγραμματισμού. Δοκιμή της ολοκληρωμένης διαδραστικής διαδρομής δεξιοτήτων «Zero to Hero» της Educative στην Python για τη μηχανική μάθηση (Zhou, 2022). Η εκμάθηση πρακτικών δεξιοτήτων στη Μηχανική Μάθηση (Machine Learning, ML) απαιτεί έναν συνδυασμό θεωρητικών γνώσεων, πρακτικών εφαρμογών, και πειραματισμού.

Η διαδικασία μπορεί να περιλαμβάνει συγκεκριμένα στάδια. Σε επίπεδο θεωρητικής κατάρτισης αναφέρεται στα ακόλουθα: α) Στη κατανόηση της γραμμικής άλγεβρας, των πιθανοτήτων και της στατιστικής η οποία ως διαδικασία είναι θεμελιώδης. Πρέπει να γνωρίζεις την έννοια των πινάκων, των ιδιοτιμών, των διανομών πιθανοτήτων και της στατιστικής ανάλυσης δεδομένων, β) Στη μελέτη βασικών αλγορίθμων, όπως η γραμμική παλινδρόμηση, τα δέντρα αποφάσεων, τα νευρωνικά δίκτυα, οι μέθοδοι συγκεντρωτικών μοντέλων (ensemble methods) και οι αλγόριθμοι μη επιβλεπόμενης μάθησης, όπως το clustering και η μείωση διαστάσεων.

Σε επίπεδο πρακτικής εφαρμογής εστιάζει σε εργαλεία προγραμματισμού Γλώσσες όπως η Python και βιβλιοθήκες όπως οι NumPy, Pandas, Scikit-learn, TensorFlow, και PyTorch είναι βασικά εργαλεία στη Μηχανική Μάθηση. Η πρακτική είναι πολύ σημαντική για την κατανόηση των αλγορίθμων. Προσπάθησε να δουλέψεις με σύνολα δεδομένων, είτε από πλατφόρμες όπως το Kaggle είτε με πραγματικά δεδομένα από διάφορους τομείς.

Ανάλογα με το πρόβλημα (ταξινόμηση, παλινδρόμηση, clustering), ο χρήστης επιλέγει τον κατάλληλο αλγόριθμο και τον τροποποιεί ώστε να ταιριάζει στις ανάγκες σου. Χρησιμοποιεί τεχνικές cross-validation για να αξιολογήσει την απόδοση του μοντέλου. Σε

επίπεδο επεξεργασίας των δεδομένων είναι απαραίτητο να αφαιρέσεις ή να διορθώσεις τα λάθος ή λείποντα δεδομένα. Μερικές φορές τα δεδομένα χρειάζονται κανονικοποίηση (normalization) ή τυποποίηση (standardization) για να είναι κατάλληλα για τον αλγόριθμο. Επίσης σημαντική είναι η εύρεση των κατάλληλων χαρακτηριστικών που θα τροφοδοτήσουν το μοντέλο, είτε μέσω της επιλογής χαρακτηριστικών (feature selection) είτε μέσω της δημιουργίας νέων χαρακτηριστικών. Ο χρήστης επίσης μπορεί να δοκιμάσει διαφορετικά μοντέλα και υπέρ παραμέτρους χρησιμοποιώντας μεθόδους όπως το Grid Search ή Random Search για να βελτιστοποιήσεις την απόδοση του μοντέλου σου. Μπορεί επίσης να κάνει χρήση μερικών μέσω αξιολόγησης όπως η ακρίβεια (accuracy), η απώλεια (loss), η precision/recall, η F1-score, ή το ROC-AUC, για να μετρήσεις την απόδοση του μοντέλου. Προκειμένου να βελτιωθεί το μοντέλο θα πρέπει να γίνει η ανάλυση των αποτελεσμάτων και βελτίωση του μοντέλου μέσω fine-tuning να γίνει ενσωμάτωση κάποιων τεχνικών όπως το regularization. Ο χρήστης εφαρμόζει τα μοντέλα μηχανικής μάθησης σε πραγματικά προβλήματα, δημιουργώντας συστήματα πρόβλεψης ή αυτοματισμούς. Η διαδικασία αυτή μπορεί να περιλαμβάνει τη χρήση ML σε περιβάλλοντα παραγωγής ή την ανάπτυξη εφαρμογών βασισμένων σε μοντέλα. Η ML εξελίσσεται γρήγορα, και είναι σημαντικό οι χρήστες να μένουν ενημερωμένοι για νέες τεχνικές και εργαλεία.

### 1.2.2 Ταξινόμηση της Μηχανικής Μάθησης

Οι υλοποιήσεις μηχανικής μάθησης ταξινομούνται σε τέσσερις μεγάλες κατηγορίες, αναλόγως της φύσης του «σήματος» ή της «απόκρισης» στη μάθηση που διατίθεται σε ένα σύστημα μάθησης που έχει ως εξής (Janiesch, Zsech & Heinrich, 2021):

- 1. Εποπτευόμενη μάθηση:** Η εποπτευόμενη μάθηση είναι η εργασία της μηχανικής μάθησης για την εκμάθηση μιας συνάρτησης που αντιστοιχίζει μια είσοδο σε μια έξοδο με βάση παραδείγματα ζευγών εισόδου-εξόδου. Τα δεδομένα που δίδονται επισημαίνονται. Τόσο τα προβλήματα ταξινόμησης όσο και τα προβλήματα παλινδρόμησης είναι εποπτευόμενα μαθησιακά προβλήματα. Λάβετε υπόψη τα ακόλουθα δεδομένα σχετικά με ασθενείς που εισέρχονται σε μια κλινική. Τα δεδομένα αποτελούνται από το φύλο και την ηλικία των ασθενών και κάθε ασθενής χαρακτηρίζεται ως «υγιής» ή «άρρωστος».



**Πίνακας 1-1: Εποπτευόμενη μάθηση παράδειγμα δεδομένων**

<b>Φύλο</b>	<b>Ηλικία</b>	<b>Ετικέτα</b>
M	48	άρρωστος
M	67	άρρωστος
F	53	υγιής
M	49	άρρωστος
F	32	υγιής
M	34	υγιής
M	21	υγιής

**2. Μη εποπτευόμενη μάθηση:** Η μη εποπτευόμενη μάθηση είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που χρησιμοποιείται για την εξαγωγή συμπερασμάτων από σύνολα δεδομένων που αποτελούνται από δεδομένα εισόδου χωρίς αποκρίσεις με ετικέτα. Σε αλγόριθμους μη εποπτευόμενης μάθησης, η ταξινόμηση ή η κατηγοριοποίηση δεν περιλαμβάνεται στις παρατηρήσεις. Παράδειγμα: Λάβετε υπόψη τα ακόλουθα δεδομένα σχετικά με ασθενείς που εισέρχονται σε μια κλινική. Τα δεδομένα αποτελούνται από το φύλο και την ηλικία των ασθενών.

**Πίνακας 1-2: Μη εποπτευόμενη μάθηση**

<b>Φύλο</b>	<b>Ηλικία</b>
M	48
M	67
F	53
M	49
F	34
M	21

Ως είδος μάθησης, μοιάζει με τις μεθόδους που χρησιμοποιούν οι άνθρωποι για να καταλάβουν ότι ορισμένα αντικείμενα ή γεγονότα ανήκουν στην ίδια κατηγορία, όπως στην παρατήρηση του βαθμού ομοιότητας μεταξύ των αντικειμένων. Ορισμένα συστήματα συστάσεων που βρίσκονται στον Ιστό με τη μορφή αυτοματισμού μάρκετινγκ βασίζονται σε αυτόν τον τύπο μάθησης.

### 1.3 Ιστορική αναδρομή

Η μηχανική μάθηση είναι ένα σημαντικό εργαλείο για τον στόχο της μόχλευσης τεχνολογιών γύρω από την τεχνητή νοημοσύνη. Λόγω των ικανοτήτων μάθησης και λήψης αποφάσεων, η μηχανική μάθηση αναφέρεται συχνά ως AI, αν και, στην πραγματικότητα, είναι μια υποδιαίρεση του AI. Μέχρι τα τέλη της δεκαετίας του 1970, ήταν μέρος της εξέλιξης του AI. Στη συνέχεια, διακλαδίστηκε για να εξελιχθεί από μόνο του. Η μηχανική μάθηση έχει γίνει ένα πολύ σημαντικό εργαλείο απόκρισης για το cloud computing και το ηλεκτρονικό εμπόριο και χρησιμοποιείται σε μια ποικιλία τεχνολογιών αιχμής. Ακολουθεί ένα σύντομο ιστορικό της μηχανικής μάθησης και ο ρόλος της στη διαχείριση δεδομένων (Fradkov, 2020).

Η μηχανική μάθηση είναι μια απαραίτητη πτυχή της σύγχρονης επιχείρησης και έρευνας για πολλούς οργανισμούς σήμερα. Χρησιμοποιεί αλγόριθμους και μοντέλα νευρωνικών δικτύων για να βοηθήσει τα συστήματα υπολογιστών να βελτιώσουν σταδιακά την απόδοσή τους. Οι αλγόριθμοι μηχανικής μάθησης δημιουργούν αυτόματα ένα μαθηματικό μοντέλο χρησιμοποιώντας δείγματα δεδομένων για τη λήψη αποφάσεων χωρίς να είναι ειδικά προγραμματισμένοι για τη λήψη αυτών των αποφάσεων (Fradkov, 2020).

Η μηχανική μάθηση βασίζεται, εν μέρει, σε ένα μοντέλο αλληλεπίδρασης των εγκεφαλικών κυττάρων. Το μοντέλο δημιουργήθηκε το 1949 από τον Donald Hebb σε ένα βιβλίο με τίτλο «The Organization of Behavior». Το βιβλίο παρουσιάζει τις θεωρίες του Hebb σχετικά με τη διέγερση των νευρώνων και την επικοινωνία μεταξύ των νευρώνων. Ο Hebb έγραψε: «Όταν ένα κύτταρο βοηθά επανειλημμένα να πυροδοτήσει ένα άλλο, ο άξονας του πρώτου κυττάρου αναπτύσσει συναπτικά πόμολα (ή τα μεγεθύνει αν υπάρχουν ήδη) σε επαφή με το σώμα του δεύτερου κυττάρου». Μεταφράζοντας τις έννοιες του Hebb σε τεχνητά νευρωνικά δίκτυα και τεχνητούς νευρώνες, το μοντέλο του μπορεί να περιγραφεί ως ένας τρόπος αλλαγής των σχέσεων μεταξύ τεχνητών νευρώνων (που αναφέρονται επίσης ως κόμβοι) και των αλλαγών σε μεμονωμένους νευρώνες. Η σχέση μεταξύ δύο νευρώνων/κόμβων

ενισχύεται εάν οι δύο νευρώνες/κόμβοι ενεργοποιηθούν ταυτόχρονα και εξασθενεί εάν ενεργοποιηθούν χωριστά (Foote, 2021).

Στη δεκαετία του 1950, ο Arthur Samuel ανέπτυξε ένα πρόγραμμα υπολογιστή με πούλια στην IBM, χρησιμοποιώντας alpha-beta pruning και μια συνάρτηση βαθμολόγησης βασισμένη στις θέσεις των κομματιών για να καθορίσει τις πιθανότητες κάθε πλευράς να κερδίσει. Το πρόγραμμα χρησιμοποίησε μια στρατηγική minimax, η οποία αργότερα εξελίχθηκε στον αλγόριθμο minimax. Ο Samuel εισήγαγε επίσης την εκμάθηση κατά τρόπο, όπου το πρόγραμμα κατέγραφε θέσεις και αξίες ανταμοιβής για βελτίωση. Επινόησε τον όρο «μηχανική μάθηση» το 1952 (Foote, 2021).

Το 1957, ο Frank Rosenblatt δημιούργησε το perceptron, μια μηχανή σχεδιασμένη για την αναγνώριση εικόνων που συνδύαζε μοντέλα αλληλεπίδρασης εγκεφαλικών κυττάρων και προσπάθειες μηχανικής μάθησης. Παρά την αρχική υπόσχεση, το perceptron δυσκολεύτηκε να αναγνωρίσει ορισμένα οπτικά μοτίβα, οδηγώντας σε καθυστερήσεις στην έρευνα νευρωνικών δικτύων. Ακόμα, ο αλγόριθμος του πλησιέστερου γείτονα (The Nearest Neighbor Algorithm), που εφευρέθηκε το 1967, σηματοδότησε την αρχή της βασικής αναγνώρισης προτύπων και χρησιμοποιήθηκε για τη χαρτογράφηση διαδρομής. Στη συνέχεια, η ανακάλυψη πολύ-επίπεδων στη δεκαετία του 1960 άνοιξε νέους δρόμους στην έρευνα των νευρωνικών δικτύων, οδηγώντας στην ανάπτυξη νευρωνικών δικτύων οπισθοδιάδοσης και τεχνητών νευρωνικών δικτύων με κρυφά επίπεδα για το χειρισμό πολύπλοκων εργασιών στη μηχανική μάθηση (Çelik, 2018).

Στα τέλη της δεκαετίας του 1970 και στις αρχές της δεκαετίας του 1980, η έρευνα για την τεχνητή νοημοσύνη στράφηκε προς λογικές προσεγγίσεις βασισμένες στη γνώση, οδηγώντας σε διάσπαση μεταξύ της τεχνητής νοημοσύνης και της μηχανικής μάθησης. Η μηχανική μάθηση, που χρησιμοποιήθηκε προηγουμένως για εκπαίδευση τεχνητής νοημοσύνης, αναδιοργανώθηκε σε ξεχωριστό πεδίο που εστιάζει στην πρακτική επίλυση προβλημάτων με χρήση θεωρίας πιθανοτήτων και στατιστικών.

Ο κλάδος άκμασε τη δεκαετία του 1990, οδηγούμενος από την ανάπτυξη του Διαδικτύου και την αφθονία των ψηφιακών δεδομένων. Αυτή η αλλαγή εστίασης ώθησε τη μηχανική μάθηση στην επιτυχία, δίνοντας έμφαση στα νευρωνικά δίκτυα και την παροχή υπηρεσιών σε σχέση με τις κληρονομημένες ερευνητικές μεθόδους AI.

Το Boosting ήταν μια κρίσιμη πρόοδος στη μηχανική μάθηση, με στόχο να

αναβαθμίσει τους αδύναμους μαθητές σε δυνατούς προσθέτοντας επαναληπτικά αδύναμους ταξινομητές σε έναν τελικό ισχυρό ταξινομητή. Ο AdaBoost ήταν ο πρώτος αλγόριθμος που δούλεψε με αδύναμους μαθητές, με νεότερες εκδόσεις όπως το xgbboost και το LogitBoost να έχουν επίσης σημαντική συμβολή. Επίσης, η αναγνώριση ομιλίας έχει δει μια στροφή προς τα μοντέλα LSTM (Long Short-Term Memory), επιτρέποντας τη μνήμη των προηγούμενων γεγονότων για καλύτερη απόδοση. Η αναγνώριση προσώπου έχει σημειώσει αξιοσημείωτη πρόοδο, με τους αλγόριθμους να ξεπερνούν τις ανθρώπινες ικανότητες στην αναγνώριση προσώπων, όπως φαίνεται στον αλγόριθμο DeepFace της Google και στα ευρήματα του Face Recognition Grand Challenge (Celik, 2018).

Επί του παρόντος, η μηχανική μάθηση είναι πλέον υπεύθυνη για μερικές από τις πιο σημαντικές εξελίξεις στην τεχνολογία. Χρησιμοποιείται για τη νέα βιομηχανία αυτό-οδηγούμενων οχημάτων και για την εξερεύνηση του γαλαξία καθώς βοηθά στον εντοπισμό έξω-πλανητών. Πρόσφατα, η μηχανική μάθηση ορίστηκε από το Πανεπιστήμιο του Στάνφορντ ως «η επιστήμη που κάνει τους υπολογιστές να ενεργούν χωρίς να είναι ρητά προγραμματισμένοι». Η μηχανική μάθηση έχει προκαλέσει μια νέα σειρά εννοιών και τεχνολογιών, όπως η εποπτευόμενη και η μη εποπτευόμενη μάθηση, οι νέοι αλγόριθμοι για ρομπότ, το Διαδίκτυο των πραγμάτων, τα εργαλεία ανάλυσης, τα chatbot και πολλά άλλα. Παρακάτω παρατίθενται επτά συνήθεις τρόποι με τους οποίους ο κόσμος των επιχειρήσεων χρησιμοποιεί αυτήν τη στιγμή τη μηχανική εκμάθηση (Foote, 2021):

- Ανάλυση δεδομένων πωλήσεων: Βελτιστοποίηση των δεδομένων
- Εξατομίκευση κινητού σε πραγματικό χρόνο: Προώθηση της εμπειρίας
- Ανίχνευση απάτης: Ανίχνευση αλλαγών προτύπων
- Συστάσεις προϊόντων: Εξατομίκευση πελατών
- Συστήματα Διαχείρισης Μάθησης: Προγράμματα λήψης αποφάσεων
- Dynamic Pricing: Ευέλικτη τιμολόγηση με βάση μια ανάγκη ή ζήτηση
- Επεξεργασία Φυσικής Γλώσσας: Μιλώντας με ανθρώπους

Τα μοντέλα μηχανικής μάθησης έχουν γίνει αρκετά προσαρμοστικά στη συνεχή μάθηση, γεγονός που τα καθιστά πιο ακριβή όσο περισσότερο λειτουργούν. Οι αλγόριθμοι ML σε συνδυασμό με νέες τεχνολογίες υπολογιστών προάγουν την επεκτασιμότητα και βελτιώνουν την απόδοση. Σε συνδυασμό με τις επιχειρηματικές αναλύσεις, η μηχανική μάθηση μπορεί να επιλύσει μια ποικιλία οργανωτικών περιπλοκών. Τα σύγχρονα μοντέλα ML μπορούν να χρησιμοποιηθούν για να κάνουν προβλέψεις που κυμαίνονται από εστίες

ασθενειών έως την άνοδο και την πτώση των αποθεμάτων (Mendonça et al., 2024).

Η Google πειραματίζεται με τη μηχανική μάθηση χρησιμοποιώντας μια προσέγγιση που ονομάζεται τελειοποίηση οδηγίων. Ο στόχος είναι η εκπαίδευση ενός μοντέλου ML για την επίλυση προβλημάτων επεξεργασίας φυσικής γλώσσας με γενικευμένο τρόπο. Η διαδικασία εκπαιδεύει το μοντέλο να επιλύει ένα ευρύ φάσμα προβλημάτων και όχι μόνο ένα είδος προβλήματος (Mendonça et al., 2024).

#### 1.4 Σημασία της μηχανικής μάθησης

Η ενισχυτική μάθηση είναι το πρόβλημα στο οποίο ένας παράγοντας ενεργεί στον κόσμο κατά τρόπο ώστε να μεγιστοποιήσει τις ανταμοιβές του. Ένας μαθητής δεν ενημερώνεται ως προς το ποιες ενέργειες πρέπει να κάνει όπως στις περισσότερες μορφές μηχανικής μάθησης, αλλά θα πρέπει να ανακαλύψει ποιες ενέργειες αποφέρουν τη μεγαλύτερη ανταμοιβή δια της δοκιμής αυτών. Για παράδειγμα, όταν ένα άτομο σκέφτεται μια διαδικασία όπου θέλει να διδάξει σε έναν σκύλο ένα νέο κόλπο, δεν μπορεί να του πει τι να κάνει ή τι να μην κάνει, αλλά μπορεί να ανταμείψει/τιμωρήσει το σκύλο εάν κάνει το σωστό ή λάθος. Όταν παρακολουθεί το άτομο το σκύλο, παρατηρεί τον τρόπο που το εν λόγω σκυλί είναι αρχικώς αδέξιο, αλλά βελτιώνεται σταθερά με την εξάσκηση (Sarker, 2021).

Όπου δίδεται ένα ημιτελές σήμα κατάρτισης: ένα σύνολο κατάρτισης με κάποιες (συχνά πολλές) από τις εξόδους-στόχους λείπουν. Υπάρχει μια ειδική περίπτωση αυτής της αρχής γνωστή ως μεταγωγή όπου ολόκληρο το σύνολο των περιπτώσεων προβλημάτων είναι γνωστό κατά το χρόνο εκμάθησης, εκτός από το ότι απουσιάζει ένα μέρος των στόχων. Η ημι-εποπτευόμενη μάθηση είναι μια προσέγγιση στη μηχανική μάθηση που συνδυάζει μικρά δεδομένα με ετικέτα με μεγάλο αριθμό δεδομένων χωρίς ετικέτα κατά τη διάρκεια της κατάρτισης. Η ημι-εποπτευόμενη μάθηση εμπίπτει μεταξύ της μη εποπτευόμενης μάθησης και της εποπτευόμενης μάθησης (Jiang, Gradus & Rosellini, 2020).

Μια άλλη κατηγοριοποίηση των εργασιών μηχανικής μάθησης προκύπτει όταν κάποιος λαμβάνει υπ' όψιν το επιθυμητό αποτέλεσμα ενός συστήματος μάθησης από μηχανή (Liu et al, 2021):

1. Ταξινόμηση: Όταν οι είσοδοι χωρίζονται σε δύο ή περισσότερες κατηγορίες, ο εκπαιδευόμενος πρέπει να παράγει ένα μοντέλο που εκχωρεί μη ορατές εισόδους σε μία ή

περισσότερες (ταξινόμηση πολλαπλών ετικετών) από αυτές τις κατηγορίες. Αυτό συνήθως αντιμετωπίζεται με έναν εποπτευόμενο τρόπο. Το φιλτράρισμα ανεπιθύμητων μηνυμάτων είναι ένα παράδειγμα ταξινόμησης, όπου οι εισοδοί είναι μηνύματα ηλεκτρονικού ταχυδρομείου (ή άλλα) και οι κατηγορίες είναι «ανεπιθύμητα» και «μη ανεπιθύμητα».

2. Παλινδρόμηση: Αυτό είναι επίσης ένα εποπτευόμενο πρόβλημα. Μια περίπτωση όπου οι έξοδοι είναι συνεχείς και όχι διακριτές.

3. Ομαδοποίηση: Όταν ένα σύνολο εισόδων πρόκειται να χωριστεί σε ομάδες. Σε αντίθεση με την ταξινόμηση, οι ομάδες δεν είναι γνωστές εκ των προτέρων, και συνήθως αυτό καθίσταται μια μη εποπτευόμενη εργασία. Η μηχανική μάθηση είναι συνυφασμένη με τον ιστό της καθημερινής μας ζωής. Ακολουθούν ορισμένα παραδείγματα που επεξηγούν τις διαφορετικές εφαρμογές της. Στις ενότητες που ακολουθούν γίνεται αναφορά σε παραδείγματα εποπτευόμενης και μη μάθησης. Τα παραδείγματα εποπτευόμενης μάθησης είναι τα ακόλουθα:

1. Φιλτράρισμα των εισερχομένων: Τα φίλτρα ανεπιθύμητης αλληλογραφίας χρησιμοποιούν τη μηχανική μάθηση για να αναλύουν τα μηνύματα ηλεκτρονικού ταχυδρομείου και να αναγνωρίζουν τα ανεπιθύμητα μηνύματα βάσει προηγούμενων μοτίβων. Μαθαίνουν από τα μηνύματα ηλεκτρονικού ταχυδρομείου που επισημαίνονται ως ανεπιθύμητα και ως μη ανεπιθύμητα, και γίνονται πιο ακριβή με την πάροδο του χρόνου.

2. Συστάσεις επόμενης αγοράς: Οι πλατφόρμες ηλεκτρονικού εμπορίου και οι υπηρεσίες ροής χρησιμοποιούν τη μηχανική εκμάθηση για να αναλύσουν το ιστορικό των αγορών των χρηστών και τις συνήθειες προβολής. Αυτό τους επιτρέπει να προτείνουν προϊόντα και να παρουσιάζουν ό,τι θεωρείται πιθανότερο να απολαύσουν οι χρήστες.

3. Έξυπνη απάντηση σε μηνύματα ηλεκτρονικού ταχυδρομείου: Η μηχανική μάθηση ενισχύει λειτουργίες όπως η «έξυπνη απάντηση» στο Gmail, προτείνοντας σύντομες απαντήσεις με βάση το περιεχόμενο του μηνύματος ηλεκτρονικού ταχυδρομείου (Tyagi & Chahal, 2020). Στον αντίποδα τα παραδείγματα μη εποπτευόμενης μάθησης είναι τα ακόλουθα:

1. Ομαδοποίηση πελατών: Η μηχανική μάθηση μπορεί να αναλύσει δεδομένα πελατών (ιστορικό αγορών, δημογραφικά στοιχεία) για να εντοπίσει τμήματα πελατών με παρόμοια χαρακτηριστικά. Αυτό βοηθά τις επιχειρήσεις να προσαρμόσουν τις εκστρατείες μάρκετινγκ και τις προσφορές προϊόντων.

2. Ανίχνευση ανωμαλιών: Τα χρηματοπιστωτικά ιδρύματα χρησιμοποιούν τη μηχανική μάθηση για να ανιχνεύσουν ασυνήθιστα μοτίβα δαπανών στην πιστωτική κάρτα των χρηστών, υποδεικνύοντας πιθανώς δόλια δραστηριότητα.

3. Ταξινόμηση εικόνων στις φωτογραφίες: Η αναγνώριση προσώπων σε φωτογραφίες σε πλατφόρμες των μέσων κοινωνικής δικτύωσης τροφοδοτείται από αλγόριθμους μηχανικής μάθησης που έχουν εκπαιδευτεί σε τεράστιες ποσότητες δεδομένων με ετικέτα (Helm et al., 2020). Πέρα από τις παραπάνω κατηγορίες πρόσθετα παραδείγματα είναι τα ακόλουθα:

1. Αυτό-οδηγούμενα αυτοκίνητα: Βασίζονται στην ενισχυτική μάθηση, έναν τύπο μηχανικής μάθησης όπου οι αλγόριθμοι μαθαίνουν μέσω δοκιμής και λάθους σε ένα προσομοιωμένο περιβάλλον.

2. Ιατρική διάγνωση: Οι αλγόριθμοι μηχανικής μάθησης μπορούν να αναλύσουν ιατρικές εικόνες (ακτινογραφίες, μαγνητική τομογραφία) για να εντοπίσουν ανωμαλίες και να βοηθήσουν τους ιατρούς στη διάγνωση (DeMauro, Sestino & Bacconi, 2022). Τα οφέλη και οι προκλήσεις της μηχανικής μάθησης αναφέρονται στα ακόλουθα. Η μηχανική μάθηση αποτελεί πλέον μια τεχνολογία μετασχηματισμού για διάφορους κλάδους. Μολονότι προσφέρει πολλά πλεονεκτήματα, είναι σημαντικό να επισημανθούν οι προκλήσεις που φέρει η αυξανόμενη χρήση της. Τα οφέλη της μηχανικής μάθησης έχουν ως εξής (Fujii et al., 2020):

1.Βελτιωμένη απόδοση και αυτοματισμός: Η μηχανική μάθηση αυτοματοποιεί τις επαναλαμβανόμενες εργασίες, αποδεσμεύοντας το ανθρώπινο δυναμικό για πιο σύνθετες εργασίες. Επίσης, ορθολογίζει τις διαδικασίες, οδηγώντας σε αυξημένη αποδοτικότητα και παραγωγικότητα.

2.Πληροφορίες βάσει δεδομένων: Η μηχανική μάθηση μπορεί να αναλύσει τεράστιες ποσότητες δεδομένων για να εντοπίσει μοτίβα και τάσεις που ενδεχομένως να μη μπορούν να διακρίνουν οι άνθρωποι. Αυτό επιτρέπει την καλύτερη λήψη αποφάσεων με βάση τα δεδομένα του πραγματικού κόσμου.

3.Βελτιωμένη εξατομίκευση: Η μηχανική μάθηση εξατομικεύει τις εμπειρίες των χρηστών σε διάφορες πλατφόρμες. Από συστήματα συστάσεων έως στοχευμένες διαφημίσεις, η μηχανική μάθηση προσαρμόζει το περιεχόμενο και τις υπηρεσίες στις μεμονωμένες προτιμήσεις.

4. Προηγμένος αυτοματισμός και ρομποτική: Η μηχανική μάθηση εξουσιοδοτεί τα

ρομπότ και τις μηχανές να εκτελούν σύνθετες εργασίες με μεγαλύτερη ακρίβεια και προσαρμοστικότητα. Αυτό το γεγονός φέρνει την επανάσταση σε τομείς όπως η μεταποίηση και η εφοδιαστική αλυσίδα.

## 1.5 Προβλήματα

Οι αλγόριθμοι της μηχανικής μάθησης είναι τόσο καλοί όσο και τα δεδομένα στα οποία έχουν εκπαιδευτεί. Τα μεροληπτικά δεδομένα μπορεί να οδηγήσουν σε αποτελέσματα που εισάγουν διακρίσεις, που απαιτούν προσεκτική επιλογή δεδομένων και παρακολούθηση αλγορίθμων. Καθώς η μηχανική μάθηση βασίζεται σε μεγάλο βαθμό σε δεδομένα, οι παραβιάσεις ασφαλείας μπορούν να εκθέσουν ευαίσθητες πληροφορίες. Επιπλέον, η χρήση των προσωπικών δεδομένων εγείρει ανησυχίες σχετικά με το απόρρητο και την ιδιωτικότητα και θα πρέπει να αντιμετωπιστούν (Kuhl et al., 2022).

Τα σύνθετα μοντέλα μηχανικής μάθησης μπορεί να είναι δύσκολο να κατανοηθούν, γεγονός που καθιστά δύσκολη την επεξήγηση των διαδικασιών λήψης αποφάσεων τους. Αυτή η έλλειψη διαφάνειας μπορεί να εγείρει ερωτήματα σχετικά με τη λογοδοσία και την εμπιστοσύνη.

Η αυτοματοποίηση μέσω της μηχανικής μάθησης μπορεί να οδηγήσει σε μετατόπιση θέσεων εργασίας σε ορισμένους τομείς. Η αντιμετώπιση της ανάγκης για επανεκπαίδευση και εκ νέου κατάρτιση του εργατικού δυναμικού είναι ζωτικής σημασίας. Συμπερασματικά, η μηχανική μάθηση είναι μια ισχυρή τεχνολογία που επιτρέπει στους υπολογιστές να μαθαίνουν χωρίς ρητό προγραμματισμό. Εξερευνώντας τις διαφορετικές μαθησιακές εργασίες και τις εφαρμογές τους, αποκτάται μια βαθύτερη κατανόηση του τρόπου που η μηχανική μάθηση διαμορφώνει τον κόσμο μας. Από το φιλτράρισμα των εισερχομένων έως τη διάγνωση νόσων, η μηχανική μάθηση έχει σημαντικό αντίκτυπο σε διάφορες πτυχές της ζωής μας (Joshi, 2020).

## 1.6 Βαθιά μάθηση

Η βαθιά μάθηση είναι μια μέθοδος στην τεχνητή νοημοσύνη (Artificial Intelligence, AI) που διδάσκει στους υπολογιστές να επεξεργάζονται δεδομένα με τρόπο που εμπνέεται από τον ανθρώπινο εγκέφαλο. Τα μοντέλα βαθιάς μάθησης μπορούν να αναγνωρίσουν πολύπλοκα μοτίβα σε εικόνες, κείμενο, ήχους και άλλα δεδομένα για να παράγουν ακριβείς ιδέες και



προβλέψεις. Δύναται να χρησιμοποιηθούν μέθοδοι βαθιάς εκμάθησης για την αυτοματοποίηση εργασιών που απαιτούν συνήθως ανθρώπινη νοημοσύνη, όπως η περιγραφή εικόνων ή η μεταγραφή ενός αρχείου ήχου σε κείμενο (Amazon, 2024) α)Ψηφιακοί βοηθοί, β)Τηλεχειριστήρια τηλεόρασης που ενεργοποιούνται με φωνή, γ)Ανίχνευση απάτης, δ)Αυτόματη αναγνώριση προσώπου.

Είναι επίσης ένα κρίσιμο συστατικό των αναδυόμενων τεχνολογιών, όπως τα αυτό-οδηγούμενα αυτοκίνητα, η εικονική πραγματικότητα και πολλά άλλα. Τα μοντέλα βαθιάς μάθησης είναι αρχεία υπολογιστή που οι επιστήμονες δεδομένων έχουν εκπαιδεύσει για να εκτελούν εργασίες χρησιμοποιώντας έναν αλγόριθμο ή ένα προκαθορισμένο σύνολο βημάτων. Οι επιχειρήσεις χρησιμοποιούν μοντέλα βαθιάς μάθησης για να αναλύσουν δεδομένα και να κάνουν προβλέψεις σε διάφορες εφαρμογές. Η βαθιά εκμάθηση έχει πολλές περιπτώσεις χρήσης στην αυτοκινητοβιομηχανία, την αεροδιαστημική, την κατασκευή, την ηλεκτρονική, την ιατρική έρευνα και άλλους τομείς. Αυτά είναι μερικά παραδείγματα βαθιάς μάθησης:

1. Τα αυτό-οδηγούμενα αυτοκίνητα χρησιμοποιούν μοντέλα βαθιάς εκμάθησης για να ανιχνεύουν αυτόματα οδικά σήματα και πεζούς.
2. Τα αμυντικά συστήματα χρησιμοποιούν βαθιά εκμάθηση για να επισημαίνουν αυτόματα περιοχές ενδιαφέροντος σε δορυφορικές εικόνες.
3. Η ανάλυση ιατρικής εικόνας χρησιμοποιεί βαθιά μάθηση για την αυτόματη ανίχνευση καρκινικών κυττάρων για ιατρική διάγνωση.
4. Τα εργοστάσια χρησιμοποιούν εφαρμογές βαθιάς μάθησης για να εντοπίζουν αυτόματα πότε άτομα ή αντικείμενα βρίσκονται σε μη ασφαλή απόσταση από μηχανές.

Μπορούν να ομαδοποιηθούν αυτές οι περιπτώσεις χρήσης βαθιάς μάθησης σε τέσσερις ευρείες κατηγορίες: όραση υπολογιστή, αναγνώριση ομιλίας, επεξεργασία φυσικής γλώσσας (Natural Language Processing, NLP) και μηχανές συστάσεων ως εξής (Amazon, 2024):

**Όραση υπολογιστή:** Η όραση υπολογιστή είναι η ικανότητα του υπολογιστή να εξάγει πληροφορίες από εικόνες και βίντεο. Οι υπολογιστές μπορούν να χρησιμοποιήσουν τεχνικές βαθιάς μάθησης για να κατανοήσουν εικόνες με τον ίδιο τρόπο που κάνουν οι άνθρωποι. Το Computer vision έχει πολλές εφαρμογές, όπως οι ακόλουθες:

1. Εποπτεία περιεχομένου για αυτόματη κατάργηση μη ασφαλούς ή ακατάλληλου περιεχομένου από αρχεία εικόνων και βίντεο
2. Αναγνώριση προσώπου για αναγνώριση προσώπων και αναγνώριση χαρακτηριστικών όπως ανοιχτά μάτια, γυαλιά και τρίχες προσώπου
3. Ταξινόμηση εικόνων για τον προσδιορισμό των λογότυπων επωνυμιών, των ρούχων, του εξοπλισμού ασφαλείας και άλλων λεπτομερειών εικόνας.

**Αναγνώριση ομιλίας:** Τα μοντέλα βαθιάς μάθησης μπορούν να αναλύσουν την ανθρώπινη ομιλία παρά τα διαφορετικά μοτίβα ομιλίας, τον τόνο, τη γλώσσα και την προφορά. Εικονικοί βοηθοί όπως το Amazon Alexa και το λογισμικό αυτόματης μεταγραφής χρησιμοποιούν την αναγνώριση ομιλίας για να κάνουν τις ακόλουθες εργασίες:

1. Βοηθά τους πράκτορες τηλεφωνικών κέντρων και ταξινομούν αυτόματα τις κλήσεις.
2. Μετατροπή κλινικών συνομιλιών σε τεκμηρίωση σε πραγματικό χρόνο.
3. Υποτιτλισμοί με ακρίβεια βίντεο και εγγραφές συσκέψεων για ευρύτερη προσέγγιση περιεχομένου.

**Επεξεργασία φυσικής γλώσσας:** Οι υπολογιστές χρησιμοποιούν αλγόριθμους βαθιάς εκμάθησης για τη συλλογή πληροφοριών και νοημάτων από δεδομένα κειμένου και έγγραφα. Αυτή η ικανότητα επεξεργασίας φυσικού κειμένου που δημιουργήθηκε από τον άνθρωπο έχει πολλές περιπτώσεις χρήσης, συμπεριλαμβανομένων αυτών των λειτουργιών:

1. Αυτοματοποιημένοι εικονικοί πράκτορες και chatbots
2. Αυτόματη σύνοψη εγγράφων ή ειδήσεων
3. Ανάλυση επιχειρηματικής ευφυΐας εγγράφων μεγάλης μορφής, όπως email και φόρμες
4. Ευρετηρίαση βασικών φράσεων που υποδηλώνουν συναίσθημα, όπως θετικά και αρνητικά σχόλια στα μέσα κοινωνικής δικτύωσης

**Μηχανές συστάσεων:** Οι εφαρμογές μπορούν να χρησιμοποιούν μεθόδους βαθιάς εκμάθησης για να παρακολουθούν τη δραστηριότητα των χρηστών και να αναπτύσσουν εξατομικευμένες προτάσεις. Μπορούν να αναλύσουν τη συμπεριφορά διαφόρων χρηστών και να τους βοηθήσουν να ανακαλύψουν νέα προϊόντα ή υπηρεσίες. Για παράδειγμα, Πολλές εταιρείες πολυμέσων και ψυχαγωγίας, όπως το Netflix, η Fox και η Peacock, χρησιμοποιούν τη βαθιά εκμάθηση για να παρέχουν εξατομικευμένες προτάσεις βίντεο (Amazon, 2024).

### 1.6.1 Η λειτουργία της βαθιάς μάθησης

Οι αλγόριθμοι βαθιάς μάθησης είναι νευρωνικά δίκτυα που διαμορφώνονται σύμφωνα με τον ανθρώπινο εγκέφαλο. Για παράδειγμα, ένας ανθρώπινος εγκέφαλος περιέχει εκατομμύρια διασυνδεδεμένους νευρώνες που συνεργάζονται για να μάθουν και να επεξεργάζονται πληροφορίες. Ομοίως, τα νευρωνικά δίκτυα βαθιάς μάθησης, ή τα τεχνητά νευρωνικά δίκτυα, αποτελούνται από πολλά στρώματα τεχνητών νευρώνων που συνεργάζονται μέσα στον υπολογιστή. Οι τεχνητοί νευρώνες είναι ενότητες λογισμικού που ονομάζονται κόμβοι, οι οποίοι χρησιμοποιούν μαθηματικούς υπολογισμούς για την επεξεργασία δεδομένων. Τα τεχνητά νευρωνικά δίκτυα είναι αλγόριθμοι βαθιάς μάθησης που χρησιμοποιούν αυτούς τους κόμβους για την επίλυση σύνθετων προβλημάτων (Amazon, 2024).

### 1.6.2 Τα συστατικά ενός δικτύου βαθιάς μάθησης

Τα συστατικά ενός βαθύ νευρωνικού δικτύου είναι τα ακόλουθα:

**Στρώμα εισόδου:** Ένα τεχνητό νευρωνικό δίκτυο έχει αρκετούς κόμβους που εισάγουν δεδομένα σε αυτό. Αυτοί οι κόμβοι αποτελούν το στρώμα εισόδου του συστήματος.

**Κρυφό στρώμα:** Το επίπεδο εισόδου επεξεργάζεται και μεταβιβάζει τα δεδομένα σε επίπεδα περαιτέρω στο νευρωνικό δίκτυο. Αυτά τα κρυφά επίπεδα επεξεργάζονται πληροφορίες σε διαφορετικά επίπεδα, προσαρμόζοντας τη συμπεριφορά τους καθώς λαμβάνουν νέες πληροφορίες. Τα δίκτυα Deep Learning έχουν εκατοντάδες κρυφά επίπεδα που μπορούν να χρησιμοποιήσουν για να αναλύσουν ένα πρόβλημα από πολλές διαφορετικές οπτικές γωνίες. Για παράδειγμα, αν σας έδιναν μια εικόνα ενός άγνωστου ζώου που έπρεπε να ταξινομήσετε, θα τη συγκρίνατε με ζώα που ήδη γνωρίζετε. Για παράδειγμα, θα κοιτάζατε το σχήμα των ματιών και των αυτιών του, το μέγεθός του, τον αριθμό των ποδιών και το σχέδιο της γούνας του. Θα προσπαθήσετε να προσδιορίσετε μοτίβα, όπως τα ακόλουθα:

1. Το ζώο έχει οπλές, επομένως μπορεί να είναι αγελάδα ή ελάφι.
2. Το ζώο έχει μάτια γάτας, επομένως θα μπορούσε να είναι κάποιο είδος άγριας γάτας.
3. Τα κρυφά στρώματα στα βαθιά νευρωνικά δίκτυα λειτουργούν με τον ίδιο τρόπο.

Εάν ένας αλγόριθμος βαθιάς μάθησης προσπαθεί να ταξινομήσει μια εικόνα ζώου,

κάθε ένα από τα κρυφά του στρώματα επεξεργάζεται ένα διαφορετικό χαρακτηριστικό του ζώου και προσπαθεί να το κατηγοριοποιήσει με ακρίβεια.

**Επίπεδο εξόδου:** Το επίπεδο εξόδου αποτελείται από τους κόμβους που εξάγουν τα δεδομένα. Τα μοντέλα βαθιάς μάθησης που δίνουν απαντήσεις "ναι" ή "όχι" έχουν μόνο δύο κόμβους στο επίπεδο εξόδου. Από την άλλη πλευρά, αυτά που δίνουν μεγαλύτερο εύρος απαντήσεων έχουν περισσότερους κόμβους (Amazon, 2024).

### 1.6.3 Τι είναι η βαθιά μάθηση στο πλαίσιο της μηχανικής μάθησης

Η βαθιά μάθηση είναι ένα υποσύνολο της μηχανικής μάθησης. Οι αλγόριθμοι βαθιάς μάθησης εμφανίστηκαν σε μια προσπάθεια να καταστήσουν τις παραδοσιακές τεχνικές μηχανικής μάθησης πιο αποτελεσματικές. Οι παραδοσιακές μέθοδοι μηχανικής εκμάθησης απαιτούν σημαντική ανθρώπινη προσπάθεια για την εκπαίδευση του λογισμικού. Για παράδειγμα, στην αναγνώριση εικόνας ζώων, πρέπει να γίνουν τα εξής:

- Επισήμανση με μη αυτόματο τρόπο εκατοντάδες χιλιάδες εικόνες ζώων.
- Κάνει τους αλγόριθμους μηχανικής μάθησης να επεξεργάζονται αυτές τις εικόνες.
- Δοκιμή αυτών των αλγόριθμων σε ένα σύνολο άγνωστων εικόνων.
- Προσδιορισμός γιατί ορισμένα αποτελέσματα είναι ανακριβή.
- Βελτίωση του συνόλου δεδομένων προσθέτοντας ετικέτες σε νέες εικόνες για να βελτιώσετε την ακρίβεια των αποτελεσμάτων.

Αυτή η διαδικασία ονομάζεται εποπτευόμενη μάθηση. Στην εποπτευόμενη μάθηση, η ακρίβεια των αποτελεσμάτων βελτιώνεται μόνο όταν έχετε ένα ευρύ και επαρκώς ποικίλο σύνολο δεδομένων. Για παράδειγμα, ο αλγόριθμος μπορεί να αναγνωρίσει με ακρίβεια τις μαύρες γάτες αλλά όχι τις λευκές γάτες, επειδή το σύνολο δεδομένων εκπαίδευσης είχε περισσότερες εικόνες μαύρων γατών. Σε αυτήν την περίπτωση, θα χρειαστεί να προσθέσετε ετικέτες σε περισσότερες εικόνες λευκών γατών και να εκπαιδεύσετε ξανά τα μοντέλα μηχανικής εκμάθησης (Amazon, 2024).

#### 1.6.4 Τα οφέλη της βαθιάς μάθησης έναντι της μηχανικής μάθησης

Ένα δίκτυο βαθιάς εκμάθησης έχει τα ακόλουθα πλεονεκτήματα σε σχέση με την παραδοσιακή μηχανική εκμάθηση (Amazon, 2024):

Αποτελεσματική επεξεργασία μη δομημένων δεδομένων: Οι μέθοδοι μηχανικής μάθησης βρίσκουν αδόμητα δεδομένα, όπως έγγραφα κειμένου, που είναι δύσκολο να επεξεργαστούν επειδή το σύνολο δεδομένων εκπαίδευσης μπορεί να έχει άπειρες παραλλαγές. Από την άλλη πλευρά, τα μοντέλα βαθιάς μάθησης μπορούν να κατανοήσουν μη δομημένα δεδομένα και να κάνουν γενικές παρατηρήσεις χωρίς χειροκίνητη εξαγωγή χαρακτηριστικών. Για παράδειγμα, ένα νευρωνικό δίκτυο μπορεί να αναγνωρίσει ότι αυτές οι δύο διαφορετικές προτάσεις εισόδου έχουν την ίδια σημασία:

- “Μπορείτε να μου πείτε πώς να κάνω την πληρωμή”;
- “Πώς μπορώ να μεταφέρω χρήματα”;

Κρυφές σχέσεις και ανακάλυψη μοτίβων: Μια εφαρμογή βαθιάς μάθησης μπορεί να αναλύσει μεγάλο όγκο δεδομένων πιο βαθιά και να αποκαλύψει νέες ιδέες για τις οποίες μπορεί να μην έχει εκπαιδευτεί. Για παράδειγμα, σκεφτείτε ένα μοντέλο βαθιάς μάθησης που είναι εκπαιδευμένο να αναλύει τις αγορές των καταναλωτών. Το μοντέλο έχει δεδομένα μόνο για τα είδη που έχετε ήδη αγοράσει. Ωστόσο, το τεχνητό νευρωνικό δίκτυο μπορεί να προτείνει νέα αντικείμενα που δεν έχετε αγοράσει συγκρίνοντας τα πρότυπα αγοράς σας με αυτά άλλων παρόμοιων πελατών.

Εκμάθηση χωρίς επίβλεψη: Τα μοντέλα βαθιάς μάθησης μπορούν να μάθουν και να βελτιωθούν με την πάροδο του χρόνου με βάση τη συμπεριφορά των χρηστών. Δεν απαιτούν μεγάλες παραλλαγές επισημασμένων συνόλων δεδομένων. Για παράδειγμα, σκεφτείτε ένα νευρωνικό δίκτυο που διορθώνει ή προτείνει αυτόματα λέξεις αναλύοντας τη συμπεριφορά σας στην πληκτρολόγηση. Ας υποθέσουμε ότι έχει εκπαιδευτεί στην αγγλική γλώσσα και μπορεί να ορθογραφήσει αγγλικές λέξεις. Ωστόσο, εάν πληκτρολογείτε συχνά μη αγγλικές λέξεις, όπως *danke*, το νευρωνικό δίκτυο μαθαίνει αυτόματα και διορθώνει αυτόματα και αυτές τις λέξεις.

Πτητική επεξεργασία δεδομένων: Τα πτητικά σύνολα δεδομένων έχουν μεγάλες παραλλαγές. Ένα παράδειγμα είναι τα ποσά εξόφλησης δανείων σε τράπεζα. Ένα νευρωνικό δίκτυο βαθιάς μάθησης μπορεί επίσης να κατηγοριοποιήσει και να ταξινομήσει αυτά τα δεδομένα, όπως αναλύοντας οικονομικές συναλλαγές και επισημαίνοντας ορισμένες από αυτές

για ανίχνευση απάτης(Amazon, 2024).

### **1.6.5 Οι προκλήσεις της βαθιάς μάθησης**

Καθώς η βαθιά μάθηση είναι μια σχετικά νέα τεχνολογία, ορισμένες προκλήσεις έρχονται με την πρακτική εφαρμογή της ως εξής (Amazon, 2024):

**Μεγάλες ποσότητες δεδομένων υψηλής ποιότητας:** Οι αλγόριθμοι βαθιάς μάθησης δίνουν καλύτερα αποτελέσματα όταν τους εκπαιδεύετε σε μεγάλες ποσότητες δεδομένων υψηλής ποιότητας. Οι ακραίες τιμές ή τα λάθη στο σύνολο δεδομένων εισόδου μπορούν να επηρεάσουν σημαντικά τη διαδικασία βαθιάς μάθησης. Για παράδειγμα, στο παράδειγμά μας με εικόνα ζώων, το μοντέλο βαθιάς μάθησης μπορεί να ταξινομήσει ένα αεροπλάνο ως χελώνα, εάν στο σύνολο δεδομένων εισήχθησαν κατά λάθος εικόνες χωρίς ζώα. Για να αποφύγετε τέτοιες ανακρίβειες, πρέπει να καθαρίσετε και να επεξεργαστείτε μεγάλες ποσότητες δεδομένων για να μπορέσετε να εκπαιδεύσετε μοντέλα βαθιάς μάθησης. Η προεπεξεργασία δεδομένων εισόδου απαιτεί μεγάλες ποσότητες χωρητικότητας αποθήκευσης δεδομένων.

**Μεγάλη επεξεργαστική ισχύς:** Οι αλγόριθμοι βαθιάς μάθησης είναι υπολογιστικής έντασης και απαιτούν υποδομή με επαρκή υπολογιστική ικανότητα για να λειτουργήσουν σωστά. Διαφορετικά, χρειάζονται πολύ χρόνο για να επεξεργαστούν τα αποτελέσματα.

### **1.6.6 Τα οφέλη της βαθιάς εκμάθησης στο cloud**

Η εκτέλεση αλγορίθμων βαθιάς μάθησης σε υποδομές cloud μπορεί να ξεπεράσει πολλές από αυτές τις προκλήσεις. Μπορείτε να χρησιμοποιήσετε τη βαθιά εκμάθηση στο cloud για να σχεδιάσετε, να αναπτύξετε και να εκπαιδεύσετε εφαρμογές βαθιάς εκμάθησης πιο γρήγορα (Amazon, 2024).

**Ταχύτητα:** Μπορείτε να εκπαιδεύσετε γρηγορότερα μοντέλα βαθιάς εκμάθησης χρησιμοποιώντας συμπλέγματα GPU και CPU για να εκτελέσετε τις πολύπλοκες μαθηματικές πράξεις που απαιτούν τα νευρωνικά σας δίκτυα. Στη συνέχεια, μπορείτε να αναπτύξετε αυτά τα μοντέλα για την επεξεργασία μεγάλων ποσοτήτων δεδομένων και την παραγωγή ολοένα και πιο συναφών αποτελεσμάτων.

Επεκτασιμότητα: Με το ευρύ φάσμα πόρων κατ' απαίτηση που διατίθενται μέσω του cloud, μπορείτε να έχετε πρόσβαση σε σχεδόν απεριόριστους πόρους υλικού για να αντιμετωπίσετε μοντέλα βαθιάς εκμάθησης οποιουδήποτε μεγέθους. Τα νευρωνικά σας δίκτυα μπορούν να επωφεληθούν από πολλούς επεξεργαστές για την απρόσκοπτη και αποτελεσματική διανομή φόρτου εργασίας σε διαφορετικούς τύπους και ποσότητες επεξεργαστών.

### 1.7 Σύγχρονες εφαρμογές των τεχνητών νευρωνικών δικτύων

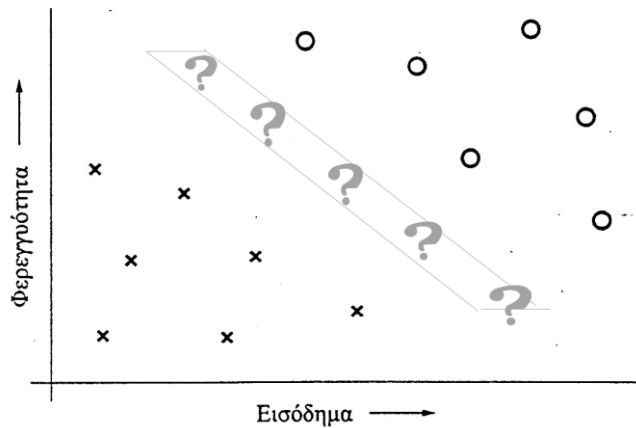
Σήμερα τα νευρωνικά δίκτυα παρουσιάζουν μεγάλο ενδιαφέρον επειδή μπορούν να τροποποιούν μεγάλες ποσότητες δεδομένων γρήγορα και αποτελεσματικά, και αυτό είναι ιδιαίτερα χρήσιμο σε εφαρμογές όπως η αναγνώριση εικόνων, όπου το νευρωνικό δίκτυο μπορεί να επεξεργαστεί εκατομμύρια εικόνες μέσα σε λίγα δευτερόλεπτα για να εντοπίσει σημαντικά μοτίβα και χαρακτηριστικά.

Έτσι, τα νευρωνικά δίκτυα ήδη χρησιμοποιούνται σε ένα ευρύ φάσμα εφαρμογών, από μηχανές αναζήτησης έως συστήματα ασφαλείας, ενώ καινούργιες εφαρμογές αναπτύσσονται, καθώς υπάρχουν πολλοί υποσχόμενοι τομείς στους οποίους τα νευρωνικά δίκτυα αναμένεται να έχουν μεγάλο αντίκτυπο στο μέλλον, Στη συνέχεια θα περιγράψουμε συνοπτικά ορισμένες από τις εφαρμογές αυτές, αλλά δεν είναι εφικτό να γίνει για όλες, επειδή είναι πραγματικά πολλές.

Η εφαρμογή των ΤΝΔ στον τραπεζικό τομέα έχει οδηγήσει σε καλύτερες επιδόσεις από τις παραδοσιακές στατιστικές μεθόδους τόσο στην ακρίβεια ταξινόμησης όσο και στην ακρίβεια πρόβλεψης. Αυτό μπορεί να είναι χρήσιμο για διαχειριστές χαρτοφυλακίου και άλλους χρηματοοικονομικούς επαγγελματίες που θέλουν να λάβουν τεκμηριωμένες αποφάσεις σχετικά με το πώς να επενδύσουν τα χρήματα των πελατών τους (Çelik, 2018).

Στις τραπεζικές εργασίες μια αρκετά απαιτητική απόφαση είναι να εκτιμηθεί ο παράγοντας της επικινδυνότητας σε μια αίτηση για στεγαστικό δάνειο. Από ένα σύνολο βασικών στοιχείων που περιλαμβάνει μια αίτηση, η τράπεζα επιδιώκει να γνωρίζει αν θα συμβεί το ενδεχόμενο ο πελάτης να μην μπορέσει να πληρώσει τις δόσεις του συμβολαίου. Όπως δείχνει το Σχήμα (1-1), τα στοιχεία αυτά που ασκούν επίδραση στις αποφάσεις αυτές είναι το εισόδημα και η αξιοπιστία του δανειολήπτη. Στην περιοχή των "ο" το ενδεχόμενο ο δανειολήπτης να αποπληρώσει το δάνειο είναι πολύ μεγάλη επειδή ο τελευταίος διαθέτει

μεγάλο εισόδημα και είναι αξιόχρεος, ενώ γίνεται ακριβώς το αντίθετο στην περιοχή των "x". Για τις δυο αυτές περιοχές, η απόφαση της τράπεζας είναι μάλλον εύκολη. Μεταξύ όμως των δυο εξεταζόμενων περιοχών παρεμβάλλει μια γκρίζα, δηλαδή ακαθόριστη περιοχή στην οποία η απόφαση καθίσταται πολύ δύσκολη.



Σχήμα 1-1: Γράφημα από στοιχεία βάσης δεδομένων που αναφέρεται σε δάνεια

Ένα πρόγραμμα νευρωνικού δικτύου που ονομάζεται 'Νέστορ' εκπαιδεύεται σε έναν μεγάλο αριθμό αιτήσεων από τις οποίες ορισμένες έγιναν αποδεκτές, ενώ άλλες απορρίφθηκαν από την τράπεζα με πρωτοβουλία των υπαλλήλων της.

Παραλληλίζοντας με τα αληθινά δεδομένα για μια νέα αίτηση δανείου που υλοποιείται εντός της τραπεζής, το σύστημα αναζητά να εντοπίσει στοιχεία προκειμένου να αποφασίσει τι ακριβώς θεωρείται παράγοντας μεγάλης επικινδυνότητας. Στο τέλος παίρνει την απόφαση να δώσει ή να μη δώσει το δάνειο, η οποία σημαίνει υψηλότερο ποσοστό επιτυχίας συγκριτικά με άλλες μεθόδους. Το πρόγραμμα 'Νέστορ' είναι εξαιρετικά αποδοτικό καθώς πραγματοποιεί τον αναμενόμενο στόχο στη γκρίζα περιοχή του σχήματος και ως εκ τούτου αξιοποιείται συστηματικά τα τελευταία χρόνια.

Μια ακόμη εφαρμογή είναι το νευρωνικό δίκτυο που εφαρμόστηκε σε ένα πραγματικό πρόβλημα, χρησιμοποιώντας ένα προσαρμοστικό φίλτρο που αφαιρεί την ηχώ από τις τηλεφωνικές γραμμές, ενώ ταυτόχρονα περιορίζει τα σφάλματα κατά τη μετάδοση. Όπως ειπώθηκε παραπάνω, πρόκειται για το γνωστό ADALINE που επινοήθηκε από τους Widrow και Smith, το οποίο εφαρμόζεται πολλές δεκαετίες τώρα με επιτυχία (Sarker, 2021).

Στη χημική ανάλυση πολλές φορές αξιοποιούνται ΤΝΔ εκεί όπου απαιτείται μια άμεση



απόφαση δίχως χρονοτριβή καθώς δεν υπάρχει διαθέσιμος χρόνος για περιττές αναλύσεις και καθυστερήσεις στο εργαστήριο. Ένα παράδειγμα είναι να υπάρχει η δυνατότητα να προβεί σε σύντομο έλεγχο στις αποσκευές επιβατών στα αεροδρόμια για το ενδεχόμενο να βρεθούν εκρηκτικές ύλες μέσα κλεισμένες σε αυτές.

Τα κυριότερα, ή τουλάχιστον τα πιο γνωστά, παραδείγματα πρακτικής χρήσης των νευρωνικών δικτύων είναι: (Awsamazon, 2023)

**Αναγνώριση εικόνας:** Τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks, CNNs) είναι ιδιαίτερα αποτελεσματικά στην αναγνώριση εικόνων. Χρησιμοποιούνται σε εφαρμογές όπως η ιατρική απεικόνιση, η αυτόνομη οδήγηση και η επιτήρηση.

**Επεξεργασία φυσικής γλώσσας (Natural Language Processing, NLP):** Τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks, RNNs) και τα μοντέλα μετασχηματισμού έχουν φέρει επανάσταση στην επεξεργασία φυσικής γλώσσας. Χρησιμοποιούνται σε μηχανικούς μεταφραστές, chatbots και ανάλυση συναισθήματος.

**Πρόβλεψη και ανάλυση δεδομένων:** Τα νευρωνικά δίκτυα χρησιμοποιούνται για την πρόβλεψη των τάσεων της αγοράς, τη χρηματοοικονομική ανάλυση και τη διαχείριση κινδύνων, χάρη στην ικανότητά τους να εντοπίζουν μοτίβα σε μεγάλους όγκους δεδομένων.

**Συστήματα συστάσεων:** Πλατφόρμες όπως το Netflix, το Amazon και το Spotify χρησιμοποιούν νευρωνικά δίκτυα για την ανάλυση της συμπεριφοράς των χρηστών και την παροχή εξατομικευμένων συστάσεων. Καθώς αυξάνεται η υπολογιστική ικανότητα, τα νευρωνικά δίκτυα εξελίσσονται και βελτιώνονται, καθιστώντας δυνατές δραστηριότητες ή εργασίες που ήταν προηγουμένως αδύνατο να αυτοματοποιηθούν με τη χρήση συμβατικών γλωσσών προγραμματισμού, ώστε να γίνουν μέρος της καθημερινότητάς μας.

Μια άλλη πολύ εξυπηρετική εφαρμογή των ΤΝΔ είναι εκείνη που είναι βοηθητική στην αναγνώριση εικόνων, κειμένων και γενικά προτύπων (pattern recognition), η οποία εμπεριέχει μια σειρά από δραστηριότητες και θεωρείται πολύ δημοφιλής. Ένα άλλο πρόγραμμα που εφαρμόζεται για την επεξεργασία κειμένου λέγεται "Omnipage". Το δημιούργησε και προώθησε η εταιρία Caere (που τώρα λέγεται Scansoft) το 1994 και εκτελείται σε ένα απλό PC. Το πρόγραμμα έχει την ικανότητα να διαβάζει τυπωμένα κείμενα με σαρωτή (scanner) και στη συνέχεια να τα μετατρέπει σε χαρακτήρες ASCII, κατά την οποία ο χρήστης μπορεί να τροποποιήσει το κάθε έγγραφο. Το πρόγραμμα είναι πολύ βολικό ακόμα

κι αν μερικά γράμματα είναι έως ένα βαθμό φθαρμένα όπως πχ συμβαίνει σε σελίδες fax.

Η εταιρία Nestor έχει παράλληλα προωθήσει ένα πρόγραμμα που αναγνωρίζει τη γραφή Κάντζι (ιαπωνική γραφή ιδεογραμμμάτων) όπου με αυτόν τον τρόπο μεταφράζει αυτόματα διάφορα κείμενα στα Αγγλικά. Η πρώτη έκδοση είχε τη δυνατότητα να αναγνωρίσει 2500 χαρακτήρες με επιτυχία 92%. Ένα μεγάλο ποσοστό Ιαπώνων αναγνωρίζουν σχεδόν 2000-3000 τέτοιους χαρακτήρες. Αυτό το πρόγραμμα αξιοποιεί μια γενικευμένη λογική που δύναται να χρησιμοποιηθεί και σε άλλες γλώσσες, όπως Κυριλλικά, Εβραϊκά κτλ. Σε αυτόν τον τύπο εφαρμογών δύναται να εισάγουμε και την υπηρεσία φωνητικής κλήσης που προσφέρουν οι εταιρίες κινητής τηλεφωνίας.

Ένα άλλο ενδιαφέρον ζήτημα είναι η μετατροπή κειμένου σε φωνή και το αντίστροφο. Το 'NETtalk' είναι ένα έγκυρο πρόγραμμα το οποίο εκπαιδεύεται να διαβάζει γραπτά κείμενα και στη συνέχεια να τα μετατρέπει σε φωνή. Στο πρώιμο στάδιο η απαγγελία ήταν δυσνόητη, στη συνέχεια ήταν νηπιακής μορφής και στο τέλος έφθασε σε 95% αναγνωρίσιμης και κατανοητής ομιλίας.

Υπάρχουν βέβαια πολλές ακόμη εφαρμογές των ΤΝΔ που δεν είναι πρακτικά εύκολο να αναφερθούν στην παρούσα εργασία. Όσες περιγράφηκαν είναι απλά παραδείγματα, ενώ αναπτύσσονται σταδιακά νέες. Στην πραγματικότητα απευθύνονται σε μια σειρά από κλάδους και επαγγέλματα. Ο αντίκτυπος της χρήσης ΤΝΔ είναι πολύ θετικός και έχει βοηθήσει αρκετούς κλάδους μέχρι σήμερα, ενώ εκτείνεται σε διάφορους τομείς, συμπεριλαμβανομένων των επιχειρήσεων (Tyagi & Chahal, 2020).

Ιατρική διάγνωση: Εκτός από την ιατρική απεικόνιση, τα νευρωνικά δίκτυα χρησιμοποιούνται για την ανάλυση γενετικών δεδομένων και την πρόβλεψη ασθενειών, τη βελτίωση των θεραπειών και την εξατομίκευση της ιατρικής.

Βιομηχανικός αυτοματισμός: Στη μεταποίηση και τη βιομηχανία, τα νευρωνικά δίκτυα χρησιμοποιούνται για τον έλεγχο της ποιότητας, την πρόβλεψη σφαλμάτων και τη βελτιστοποίηση διαδικασιών.

Η χρήση των ΤΝΔ έχει αποδειχθεί ισχυρό εργαλείο για την ενίσχυση της αποδοτικότητας των οργανισμών. Τα πεδία εφαρμογής της όπως τα χρηματοοικονομικά έχουν βοηθήσει σημαντικά στην επιλογή του καλύτερου προσωπικού σε αξιολογικά πόστα, στην αξιολόγηση επενδύσεων και την ανάλυση χαρτοφυλακίων.

Τέλος, τα ΤΝΔ στους τομείς του στρατού και της βιομηχανίας έχει σημειώσει σημαντικές προόδους καθώς συνέβαλαν στην αυτοματοποίηση ρομπότ και συστημάτων ελέγχου, την κωδικοποίηση σημάτων ραντάρ και την αναγνώριση και παρακολούθηση στόχων (Tyagi & Chahal, 2020).

## Κεφάλαιο 2° Νευρωνικά δίκτυα

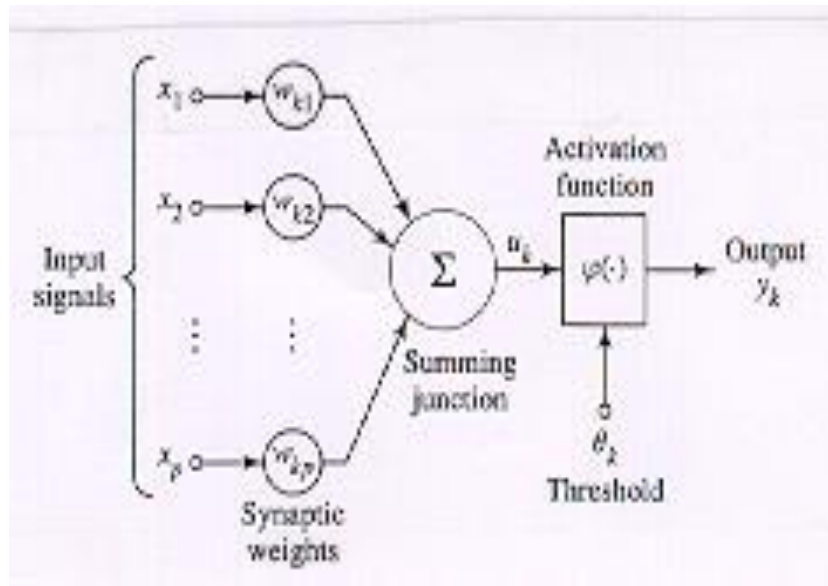
### 2.1 Εισαγωγή στα νευρωνικά δίκτυα

Τα νευρωνικά δίκτυα είναι υπολογιστικά μοντέλα που μιμούνται τις πολύπλοκες λειτουργίες του ανθρώπινου εγκεφάλου. Τα νευρωνικά δίκτυα αποτελούνται από διασυνδεδεμένους κόμβους ή νευρώνες που επεξεργάζονται και μαθαίνουν από δεδομένα, καθιστώντας δυνατές εργασίες όπως η αναγνώριση προτύπων και η λήψη αποφάσεων στη μηχανική μάθηση. Η ικανότητα των νευρωνικών δικτύων να αναγνωρίζουν μοτίβα, να επιλύουν περίπλοκους γρίφους και να προσαρμόζονται στο μεταβαλλόμενο περιβάλλον είναι απαραίτητη.

Η ικανότητά τους να μαθαίνουν από δεδομένα ενέχει εκτεταμένες επιδράσεις, που κυμαίνονται από την επανάσταση στην τεχνολογία όπως η επεξεργασία φυσικής γλώσσας και τα αυτο-οδηγούμενα αυτοκίνητα έως την αυτοματοποίηση των διαδικασιών λήψης αποφάσεων και την αύξηση της αποτελεσματικότητας σε πολλούς κλάδους. Η ανάπτυξη της τεχνητής νοημοσύνης εξαρτάται σε μεγάλο βαθμό από τα νευρωνικά δίκτυα, τα οποία επίσης καθοδηγούν την καινοτομία και επηρεάζουν την κατεύθυνση της τεχνολογίας.

Ένα νευρωνικό δίκτυο είναι ένας τύπος τεχνητής νοημοσύνης που προσπαθεί να μιμηθεί τον τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος. Αντί να χρησιμοποιεί ένα ψηφιακό μοντέλο, στο οποίο όλοι οι υπολογισμοί συνεπάγονται χειρισμό μηδενικών και μονάδων, ένα νευρωνικό δίκτυο λειτουργεί δημιουργώντας συνδέσεις μεταξύ στοιχείων επεξεργασίας και το ισοδύναμο υπολογιστή των νευρώνων. Η οργάνωση και τα βάρη των συνδέσεων καθορίζουν την έξοδο (Xie et al. 2022).

Τα νευρωνικά δίκτυα είναι ιδιαίτερα αποτελεσματικά στην πρόβλεψη γεγονότων όταν τα δίκτυα διαθέτουν μια μεγάλη βάση δεδομένων με προηγούμενα παραδείγματα για να βασιστούν. Στην πραγματικότητα, ένα νευρωνικό δίκτυο συνεπάγεται έναν μη ψηφιακό υπολογιστή, αλλά τα νευρωνικά δίκτυα μπορούν να διοχετεύουν πληροφορίες στο περιβάλλον ενώ τέλος οι υπολογιστικοί υπολογίζουν το ολικό άθροισμα των γινομένων των πληροφοριών (Haykin, 1999). Παρακάτω παραθέτουμε τη μορφή ενός τεχνητού νευρώνα.




Σχήμα 2-1: Το μη-γραμμικό μοντέλο ενός τεχνητού νευρώνα

Πηγή: Λυκοθανάσης & Γεωργόπουλος, 1999

Ένας νευρώνας είναι μια μονάδα επεξεργασίας, που είναι θεμελιώδης για την λειτουργία ενός νευρωνικού δικτύου (Λυκοθανάσης & Γεωργόπουλος, 1999). Το παραπάνω σχήμα έδειξε το μοντέλο ενός νευρώνα. Τα τρία βασικά στοιχεία αυτού του μοντέλου είναι: (Hagan et al., 1996) Ένα σύνολο από συνδετικούς κρίκους. Καθένα από αυτά χαρακτηρίζεται από μια δύναμη. Συγκεκριμένα, ένα σήμα  $x_j$  στην είσοδο της σύναψης  $j$  που συνδέεται στον νευρώνα  $k$ , πολλαπλασιάζεται με το συνοπτικό βάρος  $w_{kj}$ . Το βάρος  $w_{kj}$  είναι θετικό αν ωθείτε ο νευρώνας να αποκριθεί στη διέγερση και αρνητικό αν η σύναψη είναι απαγορευτική, αν δηλαδή ο νευρώνας αποτρέπεται να παράγει μια απόκριση. Έναν αθροιστή για την πρόσθεση των σημάτων εισόδου, τα οποία παίρνουν βάρος από την αντίστοιχη σύναψη.

Μια συνάρτηση ενεργοποίησης για τη μείωση του εύρους της εξόδου του νευρώνα. Ο τρόπος με τον οποίο οι νευρώνες ενός νευρωνικού δικτύου δομούνται, συνδέεται άμεσα με τον τρόπο εκμάθησης που χρησιμοποιείται για την εκπαίδευση. Σαν μπροστινή τροφοδότηση, αναφέρονται τα δίκτυα, στα οποία τα σήματα κατευθύνονται από την είσοδο στην έξοδο (Hagan et al., 1996).

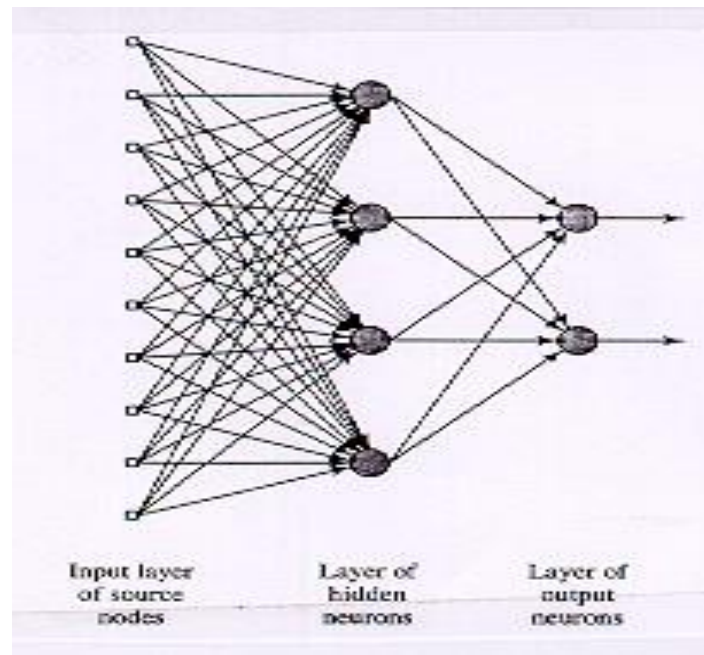
Ενός-επιπέδου Εμπρόσθιας-Τροφοδότησης Δίκτυα: Σε ένα τέτοιο δίκτυο, οι νευρώνες οργανώνονται σε διάφορα επίπεδα. Οι νευρώνες του πηγαίου επιπέδου αναφέρονται στους νευρώνες του επόμενου επιπέδου, αυτή η σχέση δεν λειτουργεί αντίστροφα (Σχήμα 2-2).



*Σχήμα 2-2: Νευρωνικό δίκτυο τροφοδότησης προς τα εμπρός με ένα επίπεδο νευρώνων*

*Πηγή: Λυκοθανάσης & Γεωργόπουλος, 1999*

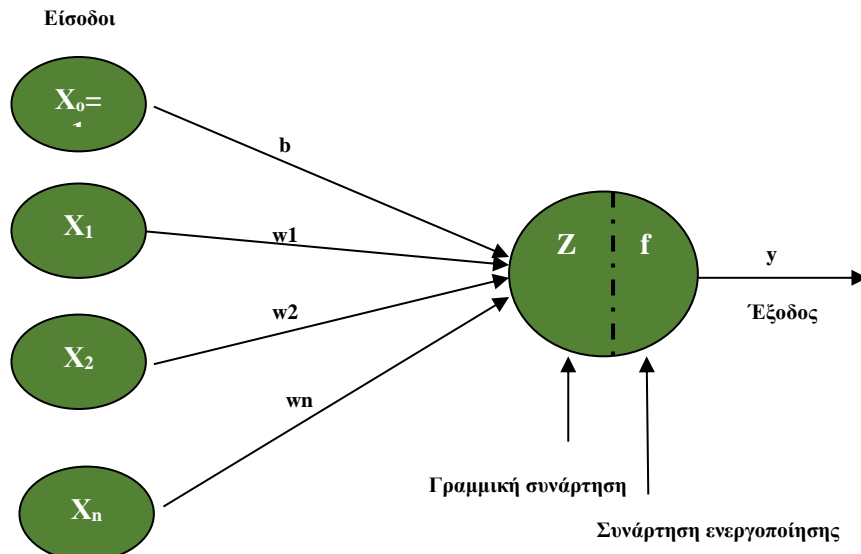
Πολλαπλών-Επιπέδων Εμπρόσθιας-Τροφοδότησης Δίκτυα: Εδώ παρουσιάζονται περισσότερα του ενός κρυφά επίπεδα, των οποίων οι κόμβοι ονομάζονται «κρυφοί νευρώνες». Οι νευρώνες σε κάθε επίπεδο έχουν σαν εισόδους τα σήματα εξόδου του προηγούμενου μόνο επιπέδου (Λυκοθανάσης & Γεωργόπουλος, 1999). Στο σχήμα 2-3 έχουμε ένα πλήρως συνδεδεμένο νευρωνικό δίκτυο, με την έννοια ότι κάθε κόμβος συνδέεται με όλους τους κόμβους του αμέσως επόμενου επιπέδου.



*Σχήμα 2-3: Πλήρως συνδεδεμένο νευρωνικό δίκτυο τροφοδότησης προς τα εμπρός με ένα κρυφό επίπεδο και ένα επίπεδο εξόδου.*

*Πηγή: Λυκοθανάσης & Γεωργόπουλος, 1999*

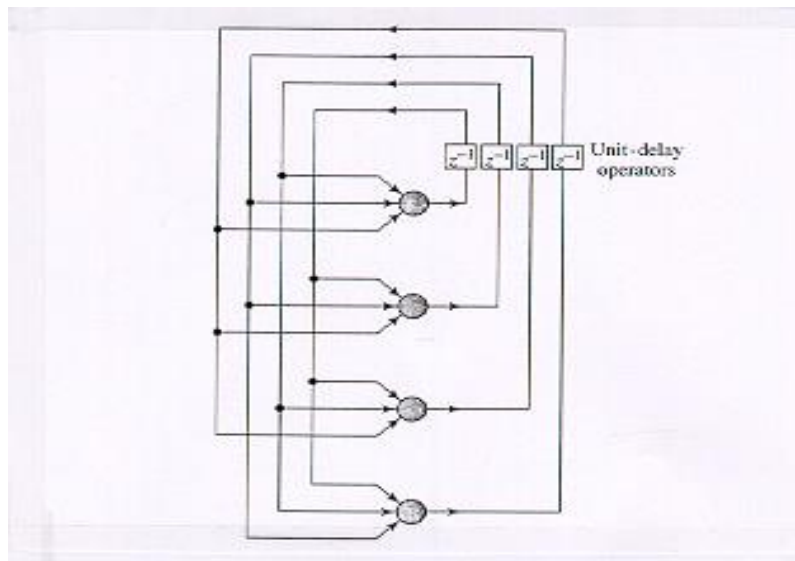
Ένα τέτοιο δίκτυο περιγράφεται με το συμβολισμό 10-4-2. Αυτός ο συμβολισμός σημαίνει ότι το νευρωνικό δίκτυο έχει δέκα εισόδους, ένα κρυφό επίπεδο με τέσσερις κόμβους ενώ το επίπεδο εξόδου έχει δύο κόμβους. Γενικά, ένα πολύ-επίπεδο δίκτυο εμπρός τροφοδότησης με  $p$  εισόδους,  $m$  κρυφά επίπεδα με  $h_j$ ,  $j=1, \dots, m$  κόμβους ανά επίπεδο και  $n$  κόμβους εξόδου, συμβολίζεται σαν:  $p-h_1, h_2, \dots, h_m-n$  (Haykin, 1994). Αντίθετα στο σχήμα 2-4 έχουμε ένα μερικώς συνδεδεμένο νευρωνικό δίκτυο.



Σχήμα 2-4: Χαρακτηριστικά νευρωνικών δικτύων

Πηγή: Viering & Loog (2022)

Αναδρομικά Δίκτυα: Η διαφορά με τα Δίκτυα επανατροφοδότησης είναι ότι έχει ένα τουλάχιστον βρόχο ανάδρασης. Στα παρακάτω σχήματα φαίνονται δύο αναδρομικά δίκτυα το πρώτο χωρίς και το δεύτερο με κρυφούς νευρώνες.




Σχήμα 2-5: Αναδρομικό δίκτυο χωρίς ανατροφοδότηση και χωρίς κρυφούς νευρώνες

Πηγή: Λυκοθανάσης & Γεωργόπουλος, 1999

Δικτυωτές Δομές: Ένα πλέγμα, αποτελείται από έναν πίνακα μιας, δύο ή μεγαλύτερης διάστασης από νευρώνες, με ένα αντίστοιχο σύνολο από πηγαίους κόμβους, που παρέχουν τα



σήματα εισόδου στον πίνακα, όπως φαίνεται στο Σχήμα 2-7 (artemis.cslab.ntua.gr/el\_thesis/artemis.ntua.ece/.../DT2003-0182.doc).



Σχήμα 2-6: (a) Μονοδιάστατο πλέγμα με 3 νευρώνες. (b) Δυσδιάστατο πλέγμα με 3 x 3 νευρώνες.

Πηγή: Λυκοθανάσης & Γεωργόπουλος, 1999

Τα νευρωνικά δίκτυα εξάγουν χαρακτηριστικά αναγνώρισης από δεδομένα, χωρίς εκ των προτέρων προγραμματισμένη κατανόηση. Τα στοιχεία δικτύου συμπεριλαμβάνουν νευρώνες, συνδέσεις, βάρη, πολικότητες, συναρτήσεις διάδοσης και έναν κανόνα εκμάθησης. Οι νευρώνες λαμβάνουν εισόδους, που διέπονται από κατώφλια και συναρτήσεις ενεργοποίησης. Οι συνδέσεις περιλαμβάνουν βάρη και πολικότητες που ρυθμίζουν τη μεταφορά πληροφοριών. Η εκμάθηση, η προσαρμογή των βαρών και των πολικότητων πραγματοποιείται σε τρία στάδια: υπολογισμός εισόδου, παραγωγή εξόδου και επαναληπτική βελτίωση που ενισχύει την ικανότητα του δικτύου σε διάφορες εργασίες. Αυτές περιλαμβάνουν: 1. Το νευρωνικό δίκτυο προσομοιώνεται από ένα νέο περιβάλλον, 2. Κατόπιν, οι ελεύθερες παράμετροι του νευρωνικού δικτύου αλλάζουν ως αποτέλεσμα αυτής της προσομοίωσης, 3. Στη συνέχεια, το νευρωνικό δίκτυο ανταποκρίνεται με έναν καινούργιο τρόπο στο περιβάλλον λόγω των αλλαγών στις ελεύθερες παραμέτρους του.

## 2.2 Ορισμός

Τα νευρωνικά δίκτυα χαρακτηρίζονται ως μια τεχνολογική επανάσταση που κυριολεκτικά αλλάζει τον τρόπο με τον οποίο οι άνθρωποι και οι οργανισμοί αλληλεπιδρούν με τα συστήματα αυτά, τα οποία είναι δημοφιλή σε διεθνές επίπεδο τις τελευταίες δεκαετίες.

Παράλληλα, υπάρχει μια μεγάλη μερίδα επιστημόνων που έχουν στρέψει το ενδιαφέρον τους στα νευρωνικά δίκτυα εντρυφώντας σε αυτά με απώτερο στόχο να οδηγηθούν

στο άμεσο μέλλον σε σπουδαίες ανακαλύψεις για την απλοποίηση των καθημερινών δραστηριοτήτων τους, καθώς υπάρχουν αξιοπρόσεκτες εφαρμογές ΝΔ που ήδη αξιοποιούνται σε διάφορους τομείς.

Στην ουσία τα νευρωνικά δίκτυα αποτέλεσαν μια έμπνευση από τους βιολογικούς οργανισμούς και μάλιστα από το νευρικό σύστημα του ανθρώπου. Ωστόσο η μελέτη και η αξιοποίησή τους έχει διευρυνθεί αρκετά. Στην πραγματικότητα έχει αναπτυχθεί ένας καινούργιος κλάδος επηρεαζόμενος από τη βιολογία. Σήμερα τα νευρωνικά δίκτυα χρησιμεύουν προκειμένου να λύσουν διάφορα πολύπλοκα προβλήματα με τη βοήθεια του ηλεκτρονικού υπολογιστή. Παρ' όλα αυτά, η φιλοσοφία τους διαφέρει σε κάποιο βαθμό από τον κλασικό τρόπο με τον οποίο λειτουργούν οι υπολογιστές.

Η λειτουργία τους στηρίζεται στην προσομοίωση της δομής και λειτουργίας του ανθρώπινου εγκεφάλου με τον εφαρμοσμένο μαθηματικό τρόπο σκέψης. Για τον λόγο αυτό στα νευρωνικά δίκτυα χρησιμοποιούνται ορισμένες εκφράσεις όπως 'ένα δίκτυο μαθαίνει και εκπαιδεύεται', 'θυμάται ή ξεχνά μια αριθμητική τιμή πράγματα που μέχρι τώρα τα αποδίδαμε μόνο στην ανθρώπινη σκέψη'. Άλλου είδους συστήματα μπορούν να αξιοποιούν δύσκολα και σύνθετα μαθηματικά εργαλεία, ιδιαίτερα από τη μαθηματική ανάλυση. Προτού προβούμε σε μεγαλύτερη ανάλυση των νευρωνικών δικτύων, θα περιγράψουμε τα βιολογικά νευρωνικά δίκτυα, προκειμένου να γίνει πιο κατανοητή η δομή τους και να γίνει γνωστό πώς γεννήθηκε αυτή η επιστήμη.

### 2.3 Ιστορική αναδρομή

Από τη δεκαετία του 1940, έχουν σημειωθεί μια σειρά από αξιοσημείωτες προόδους στον τομέα των νευρωνικών δικτύων (Gawlikowski et al., 2023):

- 1940-1950: Αρχικές έννοιες: Τα νευρωνικά δίκτυα ξεκίνησαν με την εισαγωγή του πρώτου μαθηματικού μοντέλου τεχνητών νευρώνων από τους McCulloch και Pitts. Αλλά οι υπολογιστικοί περιορισμοί δυσκόλεψαν την πρόοδο.
- 1960-1970: Αντιλήψεις: Αυτή η εποχή ορίζεται από το έργο του Rosenblatt για τις αντιλήψεις. Οι αντιλήψεις είναι δίκτυα ενός επιπέδου των οποίων η δυνατότητα εφαρμογής περιοριζόταν σε ζητήματα που μπορούσαν να επιλυθούν γραμμικώς ξεχωριστά.
- Δεκαετία του 1980: οπισθοδιάδοση και συνδυασμός: Η εκπαίδευση σε δίκτυο

πολλαπλών επιπέδων κατέστη δυνατή χάρη στην εφεύρεση της μεθόδου της πισθοδιάδοσης από τους Rumelhart, Hinton και Williams. Με την έμφαση που δίδει στη μάθηση μέσω διασυνδεδεμένων κόμβων, ο συνδυασμός απέκτησε απήχηση.

- Δεκαετία του 1990: Άνθηση και Χειμώνας: Με εφαρμογές στην αναγνώριση εικόνων, στην οικονομία και σε άλλους τομείς, τα νευρωνικά δίκτυα γνώρισαν άνθηση. Ωστόσο, η έρευνα στα νευρωνικά δίκτυα γνώρισε και έναν «χειμώνα» λόγω του υπερβολικού υπολογιστικού κόστους και των υπερβολικών προσδοκιών.
- 2000: Αναζωπύρωση και βαθιά Μάθηση: Μεγαλύτερα σύνολα δεδομένων, καινοτόμες δομές και βελτιωμένη ικανότητα επεξεργασίας ώθησαν την αναθέρμανση του ενδιαφέροντος. Η βαθιά μάθηση κατέδειξε μια εκπληκτική αποτελεσματικότητα σε πολλούς κλάδους, χρησιμοποιώντας πολλά επίπεδα.
- 2010-Σήμερα: Κυριαρχία της βαθιάς μάθησης: Τα συνελκτικά νευρωνικά δίκτυα (CNNs) και τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs), δύο αρχιτεκτονικές βαθιάς μάθησης, κυριαρχούσαν στη μηχανική μάθηση. Η δύναμή τους αποδείχθηκε με καινοτομίες στα παίγνια, την αναγνώριση εικόνων και την επεξεργασία φυσικής γλώσσας.


### 2.3.1 Τα πρώτα πρότυπα των νευρωνικών δικτύων

Το perceptron είναι το παλαιότερο νευρωνικό δίκτυο που δημιουργήθηκε από τον Frank Rosenblatt το 1958 μέσα από μια δημοσιευμένη μελέτη. Ένα νευρωνικό δίκτυο είναι ένα πρόγραμμα ή μοντέλο μηχανικής μάθησης που λαμβάνει αποφάσεις με παρόμοιο τρόπο με τον ανθρώπινο εγκέφαλο, χρησιμοποιώντας διαδικασίες που μιμούνται τον τρόπο με τον οποίο οι βιολογικοί νευρώνες συνεργάζονται για τον εντοπισμό φαινομένων, τη στάθμιση επιλογών και την εξαγωγή συμπερασμάτων.

Οι επιστήμονες πληροφορικής άρχισαν να προσπαθούν να κατασκευάσουν απλά νευρωνικά δίκτυα στις δεκαετίες του 1950 και 1960, αλλά η ιδέα τελικά έπεσε σε δυσμένεια. Το 1962 εμφανίστηκε το Perceptron, το οποίο είναι ένα αναγνωριστικό δυαδικών οπτικών μοτίβων και δυαδικής εξόδου. Προκάλεσε τον κανόνα εκμάθησης δέλτα, ο οποίος επέτρεπε τη χρήση συνεχών σημάτων εισόδου και εξόδου.

Το 1969, ο Minsky και ο Papert επέκριναν σοβαρά το Perceptron, το οποίο, δεδομένης της γραμμικής φύσης του, είχε πολλούς περιορισμούς, προκαλώντας μια πτώση στην έρευνα

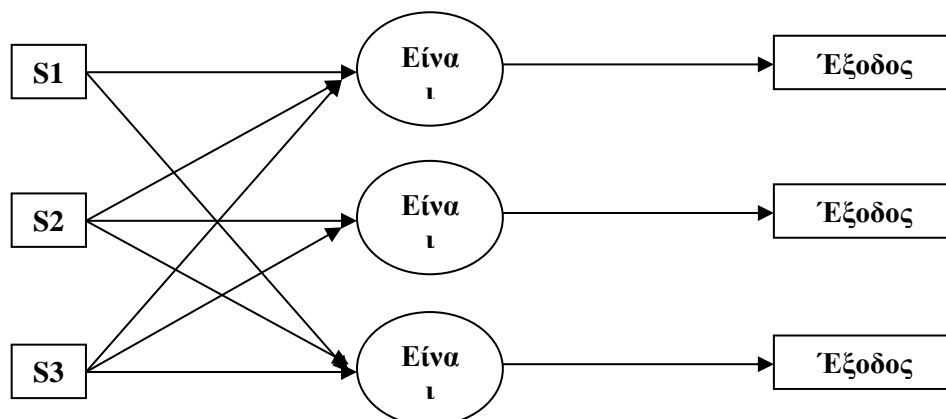
και μια γκριζα περίοδο για τα νευρωνικά δίκτυα. Στη δεκαετία του 1980, η έννοια επανήλθε στην επιφάνεια και μέχρι τη δεκαετία του 1990 τα νευρωνικά δίκτυα χρησιμοποιούνταν ευρέως στην έρευνα για την τεχνητή νοημοσύνη. Ο πιο απλός τύπος είναι γνωστός με την ονομασία στοιχειώδης αισθητήρας (elementary perceptron), Σχήμα(2-8), καθώς διαθέτει έναν νευρώνα. Πρόκειται για ένα σύστημα που έχει τη δυνατότητα να εκτελέσει κάποιες αναγκαίες διεργασίες.



Σχήμα 2-7: Ο στοιχειώδης αισθητήρας

Πηγή: Gawlikowski et al., 2023

Τα νευρωνικά δίκτυα αποτελούνται από ένα σύνολο κόμβων. Οι κόμβοι κατανέμονται σε τουλάχιστον τρία στρώματα. Τα τρία στρώματα είναι: ένα στρώμα εισόδου, ένα "κρυφό στρώμα εξόδου" και ένα στρώμα εξόδου Σχήμα (2-9). Ανεξάρτητα από το σε ποιο επίπεδο είναι μέρος, κάθε κόμβος εκτελεί κάποιο είδος εργασίας ή λειτουργίας επεξεργασίας σε οποιαδήποτε είσοδο λαμβάνει από τον προηγούμενο κόμβο (ή το επίπεδο εισόδου). Ουσιαστικά, κάθε κόμβος περιέχει έναν μαθηματικό τύπο, με κάθε μεταβλητή εντός του τύπου να σταθμίζεται διαφορετικά. Εάν το αποτέλεσμα της εφαρμογής αυτού του μαθηματικού τύπου στην είσοδο υπερβαίνει ένα ορισμένο όριο, ο κόμβος περνά τα δεδομένα στο επόμενο επίπεδο του νευρωνικού δικτύου. Εάν η έξοδος είναι κάτω από το όριο, δεν διαβιβάζονται δεδομένα στο επόμενο επίπεδο.



Σχήμα 2-8: Ο αισθητήρας με  $n$  νευρώνες.

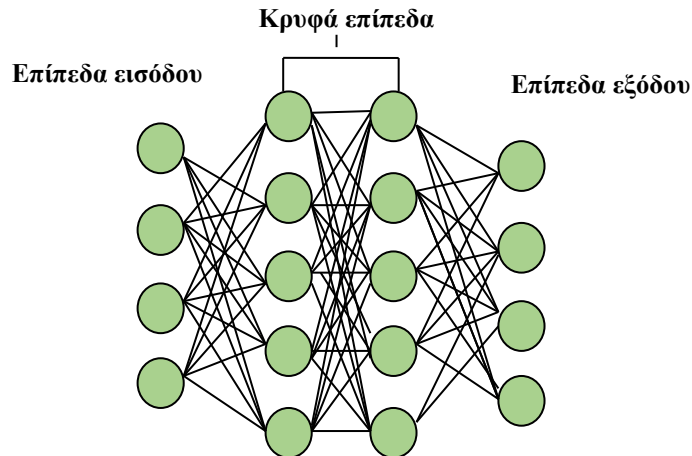
Πηγή: Gawlikowski et al., 2023

## 2.4 Βιολογικοί νευρώνες

Τα βιολογικά νευρωνικά δίκτυα των ζώντων οργανισμών αποτέλεσαν πηγή έμπνευσης για την επιστήμη των νευρωνικών δικτύων, επομένως βοηθάει να φανεί ξεχωριστά η δομή του κυττάρου του νευρώνα, η συνδεσμολογία του, η λειτουργία του και πώς μια συλλογή τέτοιων μονάδων απαρτίζει ένα νευρωνικό δίκτυο. Κάποιος μπορεί να παρατηρήσει με έκπληξη ότι μερικά χαρακτηριστικά είναι τα ίδια όπως και στους υπολογιστές, π.χ. το ηλεκτρικό σήμα μεταδίδεται με δυαδικό τρόπο ενώ θα περίμενε κανείς ότι ως ηλεκτρικό μέγεθος θα είχε συνεχείς τιμές. Είναι αρκετά τα χαρακτηριστικά για τα οποία πιστεύεται ότι μπορούν να αντληθούν ιδέες ακόμα και για την κατασκευή νέων υπολογιστών. Θα περιγραφούν με λεπτομέρειες όλα τα παραπάνω ώστε να μπορούν να οριστούν οι ομοιότητες και οι διαφορές που έχουν οι δυο αυτές κατηγορίες δικτύων και μέσω της σύγκρισης να κατανοηθούν καλύτερα τα τεχνητά νευρωνικά δίκτυα.

Σκεφτείτε ένα νευρωνικό δίκτυο για ταξινόμηση των email. Το επίπεδο εισόδου λαμβάνει λειτουργίες όπως περιεχόμενο email, πληροφορίες αποστολέα και θέμα. Αυτές οι εισοδοι, πολλαπλασιαζόμενες με προσαρμοσμένα βάρη, περνούν μέσα από κρυφά επίπεδα. Το δίκτυο, μέσω της εκπαίδευσης, μαθαίνει να αναγνωρίζει μοτίβα που υποδεικνύουν εάν ένα email είναι ανεπιθύμητο ή όχι. Το επίπεδο εξόδου, με λειτουργία δυαδικής ενεργοποίησης, προβλέπει εάν το email είναι ανεπιθύμητο (1) ή όχι (0). Καθώς το δίκτυο βελτιώνει επαναληπτικά τα βάρη του μέσω της οπίσθιας διάδοσης, καθίσταται έμπειρο στη διάκριση μεταξύ ανεπιθύμητων και επιθυμητών email, επιδεικνύοντας την πρακτικότητα των νευρωνικών δικτύων σε πραγματικές εφαρμογές όπως το φιλτράρισμα των email.

Τα νευρωνικά δίκτυα είναι πολύπλοκα συστήματα που μιμούνται ορισμένα χαρακτηριστικά της λειτουργίας του ανθρώπινου εγκεφάλου. Αποτελούνται από ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και ένα επίπεδο εξόδου που αποτελείται από επίπεδα τεχνητών νευρώνων που είναι συνδεδεμένοι. Τα δύο στάδια της βασικής διαδικασίας ονομάζονται οπισθοδιάδοση και εμπρόσθια διάδοση (Han et al., 2021).



Σχήμα 2-9: Επίπεδα νευρωνικού δικτύου

Πηγή: Han et al., 2021

### Εμπρόσθια διάδοση

- Επίπεδο εισόδου: Κάθε χαρακτηριστικό στο επίπεδο εισόδου αντιπροσωπεύεται από έναν κόμβο στο δίκτυο, ο οποίος λαμβάνει δεδομένα εισόδου.
- Βάρη και συνδέσεις: Το βάρος κάθε νευρωνικής σύνδεσης υποδεικνύει πόσο ισχυρή είναι η σύνδεση. Κατά τη διάρκεια της εκπαίδευσης, αυτά τα βάρη αλλάζουν.
- Κρυφά επίπεδα: Κάθε νευρώνας κρυφού επιπέδου επεξεργάζεται τις εισόδους πολλαπλασιάζοντάς τις με βάρη, αθροίζοντάς τις και στη συνέχεια τις μεταδίδει μέσω μιας συνάρτησης ενεργοποίησης. Με αυτόν τον τρόπο, εισάγεται η μη γραμμικότητα, επιτρέποντας στο δίκτυο να αναγνωρίζει περίπλοκα μοτίβα.
- Έξοδος: Το τελικό αποτέλεσμα παράγεται επαναλαμβάνοντας τη διαδικασία έως την επίτευξη του επιπέδου εξόδου.

### **Οπισθοδιάδοση**

- Υπολογισμός απώλειας: Η έξοδος του δικτύου αξιολογείται με βάση τις πραγματικές τιμές στόχου και χρησιμοποιείται μια συνάρτηση απώλειας για τον υπολογισμό της διαφοράς. Για ένα πρόβλημα παλινδρόμησης, το μέσο τετραγωνικό σφάλμα (MSE) χρησιμοποιείται συνήθως ως συνάρτηση κόστους.

### **Συνάρτηση απώλειας:**

- Βαθμίδα καθόδου: Στη συνέχεια χρησιμοποιείται η βαθμίδα καθόδου από το δίκτυο για τη μείωση της απώλειας. Για να μειωθεί η ανακρίβεια, τα βάρη αλλάζουν με βάση το παράγωγο της απώλειας σε σχέση με κάθε βάρος.
- Προσαρμογή βαρών: Τα βάρη προσαρμόζονται σε κάθε σύνδεση με εφαρμογή αυτής της επαναληπτικής διαδικασίας ή της οπισθοδιάδοσης σε όλο το δίκτυο.
- Εκπαίδευση: Κατά τη διάρκεια της εκπαίδευσης με διαφορετικά δείγματα δεδομένων, ολόκληρη η διαδικασία της εμπρόσθια διάδοσης, του υπολογισμού των απωλειών και της οπίσθια διάδοσης πραγματοποιείται γίνεται επαναληπτικά, επιτρέποντας στο δίκτυο να προσαρμόζεται και να μαθαίνει μοτίβα από τα δεδομένα.
- Συναρτήσεις ενεργοποίησης: Η μη γραμμικότητα του μοντέλου εισάγεται από συναρτήσεις ενεργοποίησης όπως η διορθωμένη γραμμική μονάδα (Rectified Linear Unit, ReLU) ή το σιγμοειδές. Η απόφασή τους για το αν θα «ενεργοποιηθεί» ένας νευρώνας βασίζεται σε ολόκληρη τη σταθμισμένη είσοδο.

### **2.4.1 Σύγκριση βιολογικών και τεχνητών νευρωνικών δικτύων**

Είναι γεγονός πως τα βιολογικά ΝΔ υπερέχουν των τεχνητών καθώς αποτελούν πολύπλοκα συστήματα επειδή έχουν την ικανότητα να ελέγχουν τις νοητικές και κινητικές διεργασίες και το σύνολο των νευρώνων και συνδέσεων. Ως βαθμό μεγέθους είναι πολύ μεγαλύτεροι από εκείνους που δύναται να υλοποιήσει τις αναγκαίες λειτουργίες ένας ηλεκτρονικός υπολογιστής. Το ΤΝΔ στηρίζεται στη μίμηση της ανθρώπινης σκέψης αντί να μοντελοποιεί τον τρόπο με τον οποίο επιτυγχάνεται από τον ανθρώπινο εγκέφαλο. Ένας νευρωνικός υπολογιστής χρησιμοποιεί μια εναλλακτική μέθοδο στην οποία η βιολογική δομή

και ο μηχανισμός επεξεργασίας πληροφοριών του ανθρώπινου εγκεφάλου μοντελοποιούνται απευθείας.

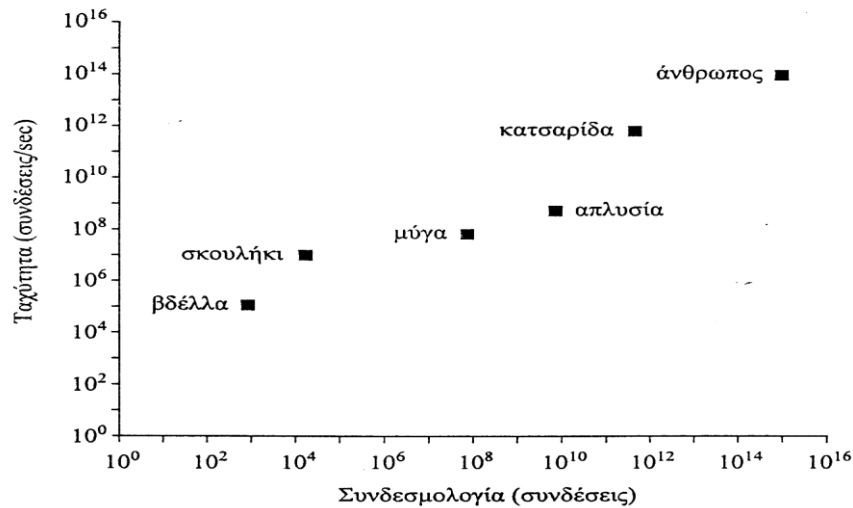
Η βασική δομή ενός ΤΝΔ περιλαμβάνει δενδρίτες μέσω των οποίων δέχεται ερεθίσματα, έναν πυρήνα όπου επεξεργάζεται αυτά τα ερεθίσματα και άξονες μέσω των οποίων μεταδίδει την απάντηση.

Εμπνευσμένα από την οργάνωση των βιολογικών νευρώνων και τη λειτουργία του ανθρώπινου εγκεφάλου, τα νευρωνικά δίκτυα είναι μοντέλα αλγορίθμων που ενσωματώνουν την περιοχή των Φυσικών Υπολογιστών. Η περιοχή αυτή βασίζεται στην παρατήρηση φυσικών φαινομένων με στόχο τη δημιουργία Τεχνητής Νοημοσύνης.

Ως προς την ταχύτητα τα τεχνητά νευρωνικά δίκτυα επικεντρώνονται κυρίως στην αναλυτική πτυχή, γίνονται πολύ πιο γρήγορα στην επεξεργασία πληροφοριών από τον εγκέφαλο.

Στο Σχήμα (2-11) παρατηρούνται ορισμένοι οργανισμοί, ως προς τον συνολικό αριθμό των συνάψεων των νευρώνων, άξονας  $x$ , ως προς την ταχύτητα με την οποία μπορούν να μεταβληθούν, άξονας  $y$ . Τα ΤΝΔ έχουν μόλις υπερβεί το σκουλήκι, επιχειρούν να φτάσουν τη μύγα, αλλά υπερτερούν κατά πολύ του ανθρώπινου εγκεφάλου. Με βάση την αρχή των επιπέδων αντίληψης, η μάθηση σε ένα νευρωνικό δίκτυο είναι μια επαναληπτική διαδικασία που περιλαμβάνει την επανειλημμένη παρουσίαση δεδομένων εκπαίδευσης στο δίκτυο. Υπενθυμίζοντας ότι τα τεχνητά νευρωνικά δίκτυα είναι ένα σύνολο μαθηματικών αλγορίθμων που μπορούν να μάθουν με βάση τα χαρακτηριστικά, τον εντοπισμό προτύπων σε μια ομάδα δεδομένων και την ταξινόμηση αυτών των γεγονότων. Τέλος, οι νευρώνες στον ανθρώπινο εγκέφαλο μπορούν να επικοινωνούν μεταξύ τους μέσω δενδριτών και αξόνων, φτάνοντας σε εκατοντάδες εκατομμύρια συνδέσεις οι οποίες επιτρέπουν τη μάθηση, την αναγνώριση προτύπων, μεταξύ άλλων κλπ.





*Σχήμα 2-10: Διάγραμμα της ταχύτητας με την οποία μπορούν να γίνουν οι αλλαγές ως προς τον ολικό αριθμό συνάψεων σε διάφορους οργανισμούς. Εδώ η ταχύτητα υπονοεί το πόσο γρήγορα μπορούν να γίνουν οι υπολογισμοί.*

*Πηγή: Liu et al., 2020*


## 2.5 Τύποι νευρωνικών δικτύων

### 2.5.1 Νευρωνικό δίκτυο τροφοδότησης προς τα εμπρός (Feedforward neural network, FNN)

Ένα FNN είναι μια απλή αρχιτεκτονική τεχνητού νευρωνικού δικτύου στην οποία τα δεδομένα μετακινούνται από είσοδο σε έξοδο προς μία μόνο κατεύθυνση. Διαθέτει επίπεδα εισόδου, κρυφά και εξόδου και οι βρόχοι ανάδρασης απουσιάζουν. Η απλή αρχιτεκτονική του το καθιστά κατάλληλο για μια σειρά εφαρμογών, όπως η παλινδρόμηση και η αναγνώριση προτύπων. Αυτό το νευρωνικό δίκτυο είναι μια από τις απλούστερες μορφές τεχνητού νευρωνικού δικτύου, όπου τα δεδομένα ή η είσοδος πορεύονται προς μία κατεύθυνση. Τα δεδομένα διέρχονται από τους κόμβους εισόδου και εξέρχονται από τους κόμβους εξόδου. Αυτό το νευρωνικό δίκτυο μπορεί να έχει ή να μην έχει τα κρυφά επίπεδα. Διαφορετικά, διαθέτει ένα κύμα εμπρόσθιας διάδοσης και καθόλου οπισθοδιάδοση χρησιμοποιώντας συνήθως μια συνάρτηση ενεργοποίησης της ταξινόμησης.

Παρακάτω παρουσιάζεται ένα εμπρόσθιο τροφοδοτούμενο δίκτυο ενός επιπέδου. Εν

προκειμένου, το άθροισμα των γινομένων των εισροών και των βαρών υπολογίζεται και τροφοδοτείται στην έξοδο. Η έξοδος λαμβάνεται υπόψη εάν είναι πάνω από μια ορισμένη τιμή, π.χ. κατώφλι (συνήθως 0) και ο νευρώνας πυροδοτείται με μια ενεργοποιημένη έξοδο (συνήθως 1) και εάν δεν πυροδοτηθεί, εκπέμπεται η απενεργοποιημένη τιμή (συνήθως -1) (Liu et al., 2020).



Σχήμα 2-11: Τεχνητό νευρωνικό δίκτυο

Πηγή: Liu et al., 2020

Η εφαρμογή των εμπροσθιοτροφοδοτούμενων νευρωνικών δικτύων απαντάται στην όραση υπολογιστών και την αναγνώριση ομιλίας όπου η ταξινόμηση των κατηγοριών-στόχων είναι περίπλοκη. Αυτά τα είδη νευρωνικών δικτύων ανταποκρίνονται σε θορυβώδη δεδομένα και είναι εύκολο να διατηρηθούν.

## 2.5.2 Multilayer Perceptron (MLP)

Το MLP είναι ένας τύπος εμπρόσθιου τροφοδοτούμενου νευρωνικού δικτύου με τρία ή περισσότερα επίπεδα, συμπεριλαμβανομένου ενός επιπέδου εισόδου, ενός ή περισσότερων κρυφών επιπέδων και ενός επιπέδου εξόδου. Χρησιμοποιεί μη γραμμικές συναρτήσεις ενεργοποίησης. Το MLP και η NLP δεν θα πρέπει επ' ουδενί να θεωρούνται ταυτόσημες έννοιες καθώς η δεύτερη αναφέρεται στην επεξεργασία φυσικής γλώσσας. Το MLP αποτελεί ένα τεχνητό νευρωνικό δίκτυο που χρησιμοποιείται για την εποπτευόμενη μάθηση το οποίο περιλαμβάνει πολλαπλά στρώματα διασυνδεδεμένων νευρώνων στα οποία οι έξοδοι των νευρώνων σε ένα στρώμα γίνονται εισοδοί στο επόμενο, το οποίο θεωρείται αξιοπρόσεκτο εξαιτίας της ικανότητας διάκρισης δεδομένων που δεν είναι γραμμικώς διαχωρισμένα (Cybenko, 1989).

Τα σύγχρονα δίκτυα ανατροφοδότησης σταδιακά μαθαίνουν μέσω της μεθόδου της οπισθοδιάδοσης (Rumelhart et al., 1986) και καλούνται απλώς νευρωνικά δίκτυα «vanilla» (Hastie et al., 2017). Τα MLP αναπτύχθηκαν επιχειρώντας να επιτευχθεί μια καλύτερη επεξεργασία των

μονοστρωματικών perceptron, τα οποία είχαν την ιδιότητα να αντιλαμβάνονται μόνο γραμμικώς διαχωρίσιμα δεδομένα. Ένα perceptron κλασικά αξιοποιούσε μια συνάρτηση βήματος Heaviside ως μη γραμμική συνάρτηση ενεργοποίησής του. Παρ' όλα αυτά, ο αλγόριθμος οπισθοδιάδοσης επιβάλλει τα νέα MLP να χρησιμοποιούν συναρτήσεις διαρκούς ενεργοποίησης όπως σιγμοειδείς ή ReLU (Bertoin et al., 2021).

### **2.5.3 Συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network, CNN)**

Το συνελκτικό νευρωνικό δίκτυο (CNN) είναι ένα εξειδικευμένο τεχνητό νευρωνικό δίκτυο σχεδιασμένο για επεξεργασία εικόνας. Χρησιμοποιεί επίπεδα συνέλιξης για αυτόματη εκμάθηση ιεραρχικών χαρακτηριστικών από εικόνες εισόδου, επιτρέποντας την αποτελεσματική αναγνώριση και ταξινόμηση εικόνων. Τα CNN έχουν φέρει την επανάσταση στην όραση των υπολογιστών και είναι καθοριστικής σημασίας σε εργασίες όπως η ανίχνευση αντικειμένων και η ανάλυση εικόνας. Τα συνελκτικά νευρωνικά δίκτυα είναι παρόμοια με τα FNNs, όπου οι νευρώνες έχουν βάρη και πολικότητες επί των οποίων μπορούν να καταρτιστούν. Η εφαρμογή του λαμβάνει χώρα στην επεξεργασία σήματος και εικόνας που αναλαμβάνει το Open CV στον τομέα της υπολογιστικής όρασης. Το ConvNet εφαρμόζεται σε τεχνικές όπως η επεξεργασία σήματος και οι τεχνικές ταξινόμησης εικόνων. Οι τεχνικές υπολογιστικής όρασης κυριαρχούνται από τα συνελκτικά νευρωνικά δίκτυα λόγω της ακρίβειάς τους στην ταξινόμηση εικόνων. Εφαρμόζεται η τεχνική ανάλυσης και αναγνώρισης εικόνων, όπου τα χαρακτηριστικά της γεωργίας και του καιρού εξάγονται από δορυφόρους ανοιχτού κώδικα όπως ο LSAT για την πρόβλεψη της μελλοντικής ανάπτυξης και των αποδόσεων μιας συγκεκριμένης περιοχής γης (Liu & Marin, 2021).

### **2.5.4 Επαναλαμβανόμενο νευρωνικό δίκτυο(Recurrent Neural Network, RNN)**

Ένας τύπος τεχνητού νευρωνικού δικτύου που προορίζεται για διαδοχική επεξεργασία δεδομένων ονομάζεται επαναλαμβανόμενο νευρωνικό δίκτυο (RNN). Είναι κατάλληλο για εφαρμογές όπου οι εξαρτήσεις από το συγκείμενο είναι κρίσιμες, όπως η πρόβλεψη χρονοσειρών και η επεξεργασία φυσικής γλώσσας, καθώς χρησιμοποιεί βρόχους ανάδρασης, οι οποίοι επιτρέπουν στις πληροφορίες να επιβιώσουν μέσα στο δίκτυο.

Το επαναλαμβανόμενο νευρωνικό δίκτυο λειτουργεί με βάση την αρχή της

αποθήκευσης της εξόδου ενός επιπέδου και της τροφοδότησης αυτού πίσω στην είσοδο προκειμένου για τη διευκόλυνση της πρόβλεψης της έκβασης του επιπέδου. Εν προκειμένω, το πρώτο επίπεδο σχηματίζεται παρόμοια με το FNN με το γινόμενο του αθροίσματος των βαρών και των χαρακτηριστικών. Η διαδικασία του επαναλαμβανόμενου νευρωνικού δικτύου ξεκινά μόλις υπολογιστεί, αυτό σημαίνει ότι από το ένα χρονικό βήμα στο επόμενο κάθε νευρώνας θα θυμάται κάποιες πληροφορίες που είχε στο προηγούμενο χρονικό βήμα. Αυτό καθιστά κάθε νευρώνα να λειτουργεί σαν κύτταρο μνήμης κατά την εκτέλεση υπολογισμών. Σε αυτή τη διαδικασία, πρέπει το νευρωνικό δίκτυο να εργαστεί στην εμπροσθοδιάδοση και να θυμηθεί ποιες πληροφορίες χρειάζεται για μελλοντική χρήση. Εν προκειμένω, εάν η πρόβλεψη είναι λανθασμένη, χρησιμοποιείται ο ρυθμός εκμάθησης ή η διόρθωση σφαλμάτων για να προβούν σε μικρές αλλαγές, κατά τρόπο ώστε σταδιακώς να λειτουργήσει προς την κατεύθυνση της σωστής πρόβλεψης κατά την οπισθοδιάδοση.

### **2.5.5 Μακροχρόνια Βραχυπρόθεσμη Μνήμη (Long Short-Term Memory, LSTM)**

Η LSTM είναι ένας τύπος RNN που έχει σχεδιαστεί για να ξεπερνά το πρόβλημα της εξαφάνισης της βαθμίδας στην εκπαίδευση του RNN. Χρησιμοποιεί κελιά μνήμης και πύλες για επιλεκτική ανάγνωση, εγγραφή και διαγραφή πληροφοριών. Τα Δίκτυα Μακροχρόνιας Βραχυπρόθεσμης Μνήμης (Long Short-term Memory - LSTM) αποτελούν μια σημαντική τεχνολογία νευρωνικών δικτύων στο κομμάτι της βαθιάς μάθησης. Σε αντίθεση με τα πιο πολλά FNNs, τα ανατροφοδοτούμενα ΝΔ εμπεριέχουν συνδέσμους ανατροφοδότησης που τους δίνει τη δυνατότητα να μελετούν και να αναλύουν δεδομένα ως σειρές (συχνά χρονοσειρές όπως δεδομένα ήχου ή βίντεο). Τα LSTM είναι βασική παράμετρος σε εφαρμογές όπως η αυτόματη ανάγνωση χειρογράφων (Graves et al., 2008) η αναγνώριση ομιλίας (Sak, 2014) καθώς και η ανίχνευση ανωμαλιών σε δικτυακές επικοινωνίες.

Το πεδίο της Μακράς Βραχύχρονης Μνήμης σχεδιάστηκε ως λύση στο πρόβλημα εξαφάνισης κλίσεων όπου συχνά παρατηρείται στα κλασικά ανατροφοδοτούμενα νευρωνικά. Η βασική της μονάδα περιλαμβάνεται από ένα κελί και πύλες εισόδου, εξόδου και λήθης. Το κελί συγκρατεί δεδομένα από παλαιότερες θέσεις χρόνου ενώ οι τρεις πύλες διαχειρίζονται την κίνηση της πληροφορίας εντός και εκτός του κελιού. Με αυτόν τον τρόπο το δίκτυο δύναται να μοντελοποιήσει τις πτυχές χρονοσειρών με ένα βαθμό καθυστέρησης αόριστης διάρκειας ανάμεσα σε βασικά γεγονότα. Αυτού του είδους χαμηλή ευαισθησία στην χρονική απόσταση

πληροφοριών χαρακτηρίζεται και το κυριότερο θετικό στοιχείο των Δικτύων Μακράς Βραχύχρονης Μνήμης σε σύγκριση με τα κλασικά ανατροφοδοτούμενα, τα κρυφά Μακροβιανά μοντέλα και άλλες τεχνικές μάθησης σειρών.

### **2.5.6 Δίκτυο Ακτινικής Συνάρτησης Βάσης (Radial Basies Function Networks, RBFN)**

Οι ακτινικές συναρτήσεις βάσης θεωρούν την απόσταση ενός σημείου ως προς το κέντρο. Οι συναρτήσεις RBF έχουν δύο επίπεδα, πρώτα όπου τα χαρακτηριστικά συνδυάζονται με τη συνάρτηση ακτινικής βάσης στο εσωτερικό επίπεδο και στη συνέχεια λαμβάνεται υπόψη η έξοδος αυτών των χαρακτηριστικών κατά τον υπολογισμό της ίδιας εξόδου στο επόμενο χρονικό βήμα που είναι βασικά μια μνήμη. Ακολουθεί ένα διάγραμμα που αναπαριστά την απόσταση που υπολογίζεται από το κέντρο σε ένα σημείο του επιπέδου παρόμοιο με μια ακτίνα του κύκλου.

Εν προκειμένω, χρησιμοποιείται το μέτρο της απόστασης που χρησιμοποιείται στην Ευκλείδεια γεωμετρία, αλλά μπορούν επίσης να χρησιμοποιηθούν και άλλα μέτρα απόστασης. Το μοντέλο εξαρτάται από τη μέγιστη εμβέλεια ή την ακτίνα του κύκλου κατά την ταξινόμηση των σημείων σε διαφορετικές κατηγορίες. Εάν το σημείο βρίσκεται εντός ή πέριξ της ακτίνας, η πιθανότητα το νέο σημείο να ταξινομηθεί σε αυτήν την κατηγορία είναι υψηλή. Μπορεί να υπάρξει μια μετάβαση κατά την αλλαγή από τη μια περιοχή στην άλλη και αυτό να ελέγχεται από τη λειτουργία beta. Αυτό το νευρωνικό δίκτυο έχει εφαρμοστεί σε συστήματα αποκατάστασης ισχύος. Τα συστήματα ισχύος έχουν αυξηθεί σε μέγεθος και πολυπλοκότητα. Και οι δύο παράγοντες αυξάνουν τον κίνδυνο μεγάλων διακοπών ισχύος. Μετά από μια διακοπή της ισχύος, η παροχή ισχύος πρέπει να αποκατασταθεί όσο το δυνατόν πιο γρήγορα και αξιόπιστα (Murphy, 2022).

### **2.5.7 Αρθρωτό νευρωνικό δίκτυο (Modular Neural Newtwork, MNN)**

Τα αρθρωτά νευρωνικά δίκτυα έχουν μια συλλογή διαφορετικών δικτύων που λειτουργούν ανεξάρτητα και συμβάλλουν στην έξοδο. Κάθε νευρωνικό δίκτυο έχει ένα σύνολο εισόδων που είναι μοναδικές σε σύγκριση με άλλα δίκτυα που κατασκευάζουν και εκτελούν υπο-εργασίες. Αυτά τα δίκτυα δεν αλληλεπιδρούν ούτε σηματοδοτούν το ένα το άλλο κατά

την ολοκλήρωση των εργασιών. Το πλεονέκτημα ενός αρθρωτού νευρωνικού δικτύου είναι ότι αναλύει μια μεγάλη υπολογιστική διεργασία σε μικρότερα στοιχεία μειώνοντας την πολυπλοκότητα. Αυτή η ανάλυση θα βοηθήσει στη μείωση του αριθμού των συνδέσεων και θα αναιρέσει την αλληλεπίδραση αυτών των δικτύων μεταξύ τους, γεγονός που με τη σειρά του θα αυξήσει την ταχύτητα του υπολογισμού. Ωστόσο, ο χρόνος επεξεργασίας θα εξαρτηθεί από τον αριθμό των νευρώνων και τη συμμετοχή τους στον υπολογισμό των αποτελεσμάτων (Yang & Wang, 2020).

## 2.6 Εκπαίδευση των νευρωνικών δικτύων

Στην εποπτευόμενη μάθηση, το νευρωνικό δίκτυο καθοδηγείται από έναν εκπαιδευτή που έχει πρόσβαση και στα δύο ζεύγη εισόδου-εξόδου. Το δίκτυο δημιουργεί εξόδους με βάση τις εισόδους χωρίς να λαμβάνει υπόψη το περιβάλλον. Συγκρίνοντας αυτές τις εξόδους με τις γνωστές από τον εκπαιδευτή επιθυμητές εξόδους, δημιουργείται ένα σήμα σφάλματος. Προκειμένου να μειωθούν τα σφάλματα, οι παράμετροι του δικτύου αλλάζουν επανειλημμένως και σταματούν όταν η απόδοση φτάνει σε ένα αποδεκτό επίπεδο.

Οι ισοδύναμες μεταβλητές εξόδου απουσιάζουν στη μη εποπτευόμενη μάθηση. Ο κύριος στόχος της είναι η κατανόηση της υποκείμενης δομής των εισερχόμενων δεδομένων (X). Δεν υπάρχει εκπαιδευτής για να προσφέρει συμβουλές. Η μοντελοποίηση προτύπων δεδομένων και σχέσεων είναι το επιδιωκόμενο αποτέλεσμα. Λέξεις όπως η παλινδρόμηση και η ταξινόμηση σχετίζονται με την εποπτευόμενη μάθηση, ενώ η μη εποπτευόμενη μάθηση σχετίζεται με την ομαδοποίηση και τη συσχέτιση.

Μέσω της αλληλεπίδρασης με το περιβάλλον και της ανατροφοδότησης με τη μορφή ανταμοιβών ή ποινών, το δίκτυο αποκτά γνώση. Η εύρεση μιας πολιτικής ή στρατηγικής που βελτιστοποιεί τις σωρευτικές ανταμοιβές με την πάροδο του χρόνου είναι ο στόχος για το δίκτυο. Αυτό το είδος χρησιμοποιείται συχνά σε εφαρμογές παιγνίων και λήψης αποφάσεων (Eshraghian et al., 2023).

## 2.7 Πλεονεκτήματα και Μειονεκτήματα των Νευρωνικών Δικτύων

Τα νευρωνικά δίκτυα χρησιμοποιούνται ευρέως σε πολλές διαφορετικές εφαρμογές λόγω των πολλών πλεονεκτημάτων τους (Mijwel, 2021):

- Προσαρμοστικότητα: Τα νευρωνικά δίκτυα είναι χρήσιμα για δραστηριότητες όπου η σύνδεση μεταξύ εισόδων και εξόδων είναι πολύπλοκη ή δεν είναι καλώς καθορισμένη, επειδή μπορούν να προσαρμοστούν σε νέες καταστάσεις και να μάθουν από δεδομένα.
- Αναγνώριση προτύπων: Η επάρκειά τους στην αναγνώριση προτύπων τα καθιστά αποτελεσματικά σε εργασίες όπως η αναγνώριση ήχου και εικόνας, η επεξεργασία φυσικής γλώσσας και άλλα περίπλοκα μοτίβα δεδομένων.
- Παράλληλη επεξεργασία: Επειδή τα νευρωνικά δίκτυα είναι εκ φύσεως ικανά για παράλληλη επεξεργασία, μπορούν να επεξεργαστούν πολλές εργασίες ταυτόχρονα, γεγονός που επιταχύνει και βελτιώνει την αποτελεσματικότητα των υπολογισμών.
- Μη γραμμικότητα: Τα νευρωνικά δίκτυα είναι σε θέση να μοντελοποιούν και να κατανοούν περίπλοκες σχέσεις σε δεδομένα χάρη στις μη γραμμικές συναρτήσεις ενεργοποίησης που βρίσκονται στους νευρώνες, το οποίο ξεπερνά τα μειονεκτήματα των γραμμικών μοντέλων.

Από τα νευρωνικά δίκτυα, αν και ισχυρά, δεν απουσιάζουν τα μειονεκτήματα και δυσκολίες (Mijwel, 2021):

- Υπολογιστική ένταση: Η εκπαίδευση στα μεγάλα νευρωνικά δίκτυα μπορεί να είναι μια επίπονη και υπολογιστικώς απαιτητική διαδικασία που απαιτεί μεγάλη υπολογιστική ισχύ.
- Φύση μαύρου κουτιού: Ως μοντέλα «μαύρου κουτιού», τα νευρωνικά δίκτυα δημιουργούν προβλήματα σε σημαντικές εφαρμογές, καθώς είναι δύσκολο να κατανοήσουμε τον τρόπο που λαμβάνουν τις αποφάσεις.
- Υπερβολική προσαρμογή: Η υπερβολική προσαρμογή είναι ένα φαινόμενο κατά το οποίο τα νευρωνικά δίκτυα δεσμεύουν εκπαιδευτικό υλικό στη μνήμη αντί να αναγνωρίζουν μοτίβα στα δεδομένα. Αν και οι προσεγγίσεις κανονικοποίησης βοηθούν στον μετριασμό αυτού, το πρόβλημα εξακολουθεί να υπάρχει.
- Ανάγκη για μεγάλα σύνολα δεδομένων: Για την αποτελεσματική εκπαίδευση, τα νευρωνικά δίκτυα χρειάζονται συχνά μεγάλα σύνολα δεδομένων με ετικέτα, ειδικά

η απόδοσή τους ενδεχομένως να πάσχε από ελλιπή ή στρεβλά δεδομένα.

## 2.8 Είδη Δικτύων και μέθοδοι εκπαίδευσης

Οι εκπαιδευτικές πρωτοβουλίες σχετικά με τα SNN είναι απαραίτητες για την προαγωγή του πεδίου και την εκπαίδευση της επόμενης γενιάς ερευνητών και μηχανικών:

- **Ανάπτυξη Προγραμμάτων Σπουδών:** Τα πανεπιστήμια αρχίζουν να περιλαμβάνουν SNN στα προγράμματα σπουδών τους, προσφέροντας μαθήματα που καλύπτουν τόσο θεωρητικές πτυχές όσο και πρακτικές εφαρμογές. Αυτά τα μαθήματα συνδυάζουν συχνά διαλέξεις με πρακτικές εργασίες που χρησιμοποιούν προσομοιωτές SNN ή νευρομορφικό υλικό.
- **Εργαστήρια και σεμινάρια:** Τα εργαστήρια και τα μαθήματα σε συνέδρια όπως τα συνέδρια NeurIPS και IEEE γίνονται πιο κοινά, παρέχοντας εντατική εκπαίδευση σε SNN, καλύπτοντας θέματα όπως η μοντελοποίηση νευρώνων, οι αλγόριθμοι εκμάθησης και οι εφαρμογές.
- **Πλατφόρμες ανοιχτού κώδικα:** Η ανάπτυξη εργαλείων και πλατφορμών ανοιχτού κώδικα, όπως το NEST και το Brian, έχει διευκολύνει τους φοιτητές και τους ερευνητές να πειραματιστούν με το SNN. Αυτές οι πλατφόρμες παρέχουν περιβάλλοντα για την προσομοίωση νευρώνων και δικτύων που ενισχύουν τον πειραματισμό και τη μάθηση (Çelik, 2018).
- **Παράδειγμα πειράματος:** Ένα εκπαιδευτικό έργο περιλάμβανε φοιτητές που χρησιμοποιούσαν τον προσομοιωτή NEST για να μοντελοποιήσουν ένα μικρό SNN που θα μπορούσε να μάθει να αναγνωρίζει απλά μοτίβα σε αιχμές εισόδου. Το έργο βοήθησε τους φοιτητές να κατανοήσουν την πολυπλοκότητα της εκπαίδευσης SNN και παρείχε πρακτική εμπειρία με τις προκλήσεις των μοντέλων νευρώνων.

### 2.8.1 Ο αισθητήρας

Το πρώτο στρώμα ή στρώμα εισόδου έχει κόμβους εισόδου που στέλνουν δεδομένα σε ένα δεύτερο στρώμα. Αυτοί οι κόμβοι είναι παθητικοί και απλώς μεταδίδουν τις πληροφορίες στο επόμενο στρώμα. Ο αριθμός των κόμβων σε αυτό το στρώμα αντιστοιχεί



στην ποσότητα των δεδομένων που εισάγονται. Οι κόμβοι στο δεύτερο ή κρυφό στρώμα φιλτράρουν τα σχετικά μοτίβα από τα άσχετα αναγνωρίζοντας τις σημαντικές πληροφορίες. Αυτοί οι κόμβοι είναι ενεργοί, πράγμα που σημαίνει ότι συνδυάζουν τα δεδομένα που προέρχονται από το προηγούμενο στρώμα. Κάθε είσοδος που λαμβάνεται πολλαπλασιάζεται με ένα βάρος και τα προκύπτοντα βάρη προστίθενται και οριοθετούνται με μια συνάρτηση (σιγμοειδή ή λογιστική) για τη βελτίωση της αποτελεσματικότητας. Αυτοί οι κόμβοι αντιπροσωπεύουν συνήθως το 10% αυτών του πρώτου στρώματος. Στο τρίτο στρώμα, που ονομάζεται επίσης στρώμα εξόδου, επαναλαμβάνεται η διαδικασία του δεύτερου στρώματος και τα δεδομένα συνδυάζονται και πάλι και τροποποιούνται στους ενεργούς κόμβους για να παραχθούν οι τιμές εξόδου (Δεμερτζής, 2020).

Κάθε εισερχόμενο σήμα  $s_i$  σχετίζεται με τον κεντρικό νευρώνα με ένα βάρος  $w_i$ . Να επισημάνουμε ότι το βάρος  $w$  μας φανερώνει το εύρος της αλληλεπίδρασης μεταξύ των δυο νευρώνων που συνδέει. Ωστόσο, ως προς τον ένα νευρώνα, δύναται να ειπωθεί ότι το  $w$  είναι η επίπτωση του εισερχόμενου σήματος με τον εν λόγω νευρώνα. Αυτό που ενδιαφέρει δεν είναι η τιμή του βάρους  $w$  από μόνη της ούτε η τιμή του σήματος  $s$ , αλλά είναι το γινόμενο  $s_i w_i$ , επειδή εκείνο είναι που εισέρχεται ξαφνικά στο νευρώνα ως τιμή του εισερχόμενου σήματος. Ο αισθητήρας στη συνέχεια υπολογίζεται τα αυτά για όλους τους  $n$  όρους (όπου  $n$  είναι ο αριθμός των εισόδων) και θεωρείται λοιπόν ότι λαμβάνει ένα συνολικό σήμα με τιμή:

$$S = \sum_{i=1}^n s_i w_i \quad \text{Σχέση (2.1)}$$

Ας εξετάσουμε τώρα την περίπτωση όπου ο νευρώνας διαθέτει και ένα εσωτερικό βάρος που τον διακρίνει. Θα πρέπει να το έχουμε κατά νου στην εξίσωση (2.1). Το εσωτερικό αυτό βάρος καλείται ‘προδιάθεση’ ή ‘παράγων προδιάθεσης’ του νευρώνα  $b$  (bias). Είναι ένα στοιχείο που δεν συνδέεται με τα άλλα βάρη αλλά λειτουργεί με τον ίδιο τρόπο. Μια βασική παρατήρηση είναι ότι το  $b$  πολλαπλασιάζεται σταθερά με τη μονάδα όταν πρόκειται να ληφθεί υπόψη για το εξερχόμενο σήμα. Έτσι, λοιπόν η εξίσωση (2.2) στην πιο γενική της μορφή, γίνεται:

$$S = b + \sum_{i=1}^n s_i w_i \quad \text{Σχέση (2.2)}$$

Ο όρος  $b$  δύναται να μην αποδίδει καμία φυσική σημασία και δεν απηχεί πάντα στο εσωτερικό του νευρώνα. Ορισμένες φορές εικάζεται ότι υπολογίζεται επιπλέον ένα εξωτερικό ερέθισμα, το οποίο εισάγεται στο υπόλοιπο άθροισμα για να δώσει το σωστό  $S$ . Ο τρόπος λύσης κάθε προβλήματος είναι διαφορετικός, ενώ το αποτέλεσμα δεν μεταβάλλεται

σημαντικά είτε χρησιμοποιήσουμε την εξίσωση (2.1), (χωρίς το b) είτε την εξίσωση (2.2), (με το b). Γενικός κανόνας για το ποια είναι η πιο ενδεδειγμένη δεν υπάρχει.

Μόλις υπολογιστεί η τελική τιμή του εισερχόμενου σήματος, υλοποιείται τη συνάρτηση κατωφλίου Heaviside, γνωρίζοντας εκ των προτέρων τη συγκεκριμένη τιμή του κατωφλίου  $\theta$ . ακολουθεί σύγκριση του  $\theta$  με το άθροισμα  $S$ . Αν  $S > \theta$ , ο αισθητήρας ενεργοποιείται και θεωρείται ότι πυροδοτεί. Αν  $S < \theta$  τότε το άθροισμα  $S$  μηδενίζεται και ο αισθητήρας διατηρείται αδρανής. Αυτό συνοψίζεται ως:

$$\text{Αν } S > \theta \text{ τότε η τιμή της εξόδου} = 1 \quad \text{Σχέση (2.3)}$$

$$\text{Αν } S < \theta \text{ τότε η τιμή της εξόδου} = 0 \quad \text{Σχέση (2.4)}$$

Συνεπώς, προκύπτουν τρεις παράμετροι που ασκούν επίδραση στην ενεργητικότητα του αισθητήρα: τα βάρη των συνδέσεων, οι τιμές των εισόδων και η τιμή κατωφλίου. Θεωρείται ότι αυτό που αντιλαμβάνεται το σύστημά μας αποθηκεύεται στα βάρη των συνδέσεων, τα οποία μετατρέπονται διαρκώς κατά τη διάρκεια που το σύστημα 'μαθαίνει' κάποια πληροφορία (Δεμερτζής, 2020).

Σύμφωνα με το πρότυπο του στοιχειώδους αισθητήρα, μπορούμε να διευρύνουμε αναπτύσσοντας πιο εξελιγμένα πρότυπα που περιλαμβάνουν περισσότερους από ένα νευρώνες. Οι νευρώνες είναι οι θεμελιώδεις μονάδες των προσομοιωμένων νευρωνικών δικτύων. Λαμβάνουν σήματα εισόδου, τα επεξεργάζονται χρησιμοποιώντας λειτουργίες ενεργοποίησης και παράγουν σήματα εξόδου. Αυτοί οι τεχνητοί νευρώνες διασυνδέονται σε στρώματα για να σχηματίσουν ένα δίκτυο. Το πρώτο επίπεδο, το επίπεδο εισόδου, λαμβάνει τα αρχικά δεδομένα, ενώ το τελευταίο επίπεδο, γνωστό ως επίπεδο εξόδου, παράγει το τελικό αποτέλεσμα. Λαμβάνοντας εισόδους από το προηγούμενο στρώμα και παραδίδοντας τις εξόδους στο επόμενο στρώμα, κάθε νευρώνας επιτρέπει τη ροή πληροφοριών σε όλο το δίκτυο. Το δίκτυο μπορεί να έχει ένα ή περισσότερα κρυφά επίπεδα, όπου γίνονται οι υπολογισμοί. Όταν αντιμετωπίζουν ένα αίτημα ή πρόβλημα που πρέπει να λυθεί, οι νευρώνες εκτελούν μαθηματικούς υπολογισμούς για να ελέγξουν εάν οι πληροφορίες που λαμβάνονται είναι επαρκείς για να ενεργοποιήσουν τον επόμενο νευρώνα. Με άλλα λόγια, οι νευρώνες διαβάζουν όλα τα δεδομένα και ανακαλύπτουν πού υπάρχουν οι ισχυρότερες σχέσεις. Σε ένα στοιχειώδες δίκτυο, τα εισερχόμενα δεδομένα προστίθενται και, εάν το άθροισμα υπερβαίνει μια ορισμένη τιμή κατωφλίου, ο νευρώνας "ενεργοποιείται" ενεργοποιώντας τους νευρώνες με τους οποίους συνδέεται (Δεμερτζής, 2020).


## 2.8.2 Το πρόβλημα της αποκλειστικής διάζευξης

Ένα σημαντικό πρόβλημα που επιλύει ο αισθητήρας είναι εκείνο της εκμάθησης της συνάρτησης XOR (exclusive or), δηλαδή της συνάρτησης της αποκλειστικής διάζευξης. Σκοπός αυτής της ανάρτησης είναι να ερμηνεύσουμε και να μάθουμε λίγα περισσότερα για τον τρόπο λειτουργίας των νευρωνικών δικτύων. Για να πετύχουμε αυτόν τον στόχο θα δημιουργήσουμε πρώτα ένα βασικό μοντέλο, θα το εκπαιδεύσουμε και τέλος θα κρυφοκοιτάξουμε τη δομή του και θα επαληθεύσουμε μαθηματικά τον τρόπο λειτουργίας του.

Πρώτα απ' όλα πρέπει να φανεί πώς λειτουργεί ο λογικός τελεστής XOR. Αυτή η πράξη επιστρέφει ένα 1 στην έξοδο μόνο αν οι είσοδοι έχουν διαφορετικές τιμές, με τον παρακάτω πίνακα θα γίνει σαφές πώς λειτουργεί. Αν και οι δυο είσοδοι είναι ίδιες τότε η έξοδος είναι 0, ενώ αν είναι διαφορετικές, η έξοδος είναι 1. Οι όροι αυτοί παρουσιάζονται συνοπτικά στον πίνακα (2-1) που ονομάζεται και 'πίνακας αλήθειας' της συνάρτησης.

**Πίνακας 2-1 Η συνάρτηση XOR**

Είσοδος 1	Είσοδος 2	Έξοδος
0	0	0
0	1	1
1	0	1
1	1	0




**Σχήμα 2-12: ο αισθητήρας με δυο εισόδους για το πρόβλημα XOR**

Πηγή: Liu et al., 2020

Μια διαφορετική εκδοχή του στοιχειώδους αισθητήρα με δυο εισόδους και μια έξοδο απεικονίζεται στο Σχήμα (2-13). Στο διάγραμμα του Σχήματος (2-14), περιλαμβάνονται όλοι οι δυνατοί συνδυασμοί που μπορούν να υπάρξουν στο επίπεδο x-y, από τη χρήση αυτού του είδους ΝΔ, όπου οι δυο άξονες θεωρούνται οι δυο εισοδοί  $s_1$  και  $s_2$ . Στο δίκτυο του Σχήματος (2-13) κάθε φορά που εισέρχονται οι εισοδοί  $s_1, s_2$  επιδέχονται τη σύγκριση μεταξύ του  $S$  και του  $\theta$ . Θέλουμε, λόγω χάριν, το δίκτυο να δίνει έξοδο 0 όταν  $S < 0.5$  και να δίνει έξοδο 1 όταν  $S > 0.5$ . Απ'ότι δείχνει όμως, δεν προκύπτει κανένας συνδυασμός τιμών των  $w_1, w_2$  που να παράγει τις σχέσεις που υπάρχουν στον πίνακα (2-1). Η αλγεβρική εξίσωση γίνεται (Sarker, 2021):

$$s_1 w_1 + s_2 w_2 = 0.5 \quad \text{Σχέση (2.5)}$$

και περιγράφει το δίκτυό μας με μια σχέση γραμμική ως προς  $s_1$  και  $s_2$ . Αυτό φανερώνει ότι όλες οι τιμές των  $s_1, s_2$  που την ικανοποιούν, βρίσκονται πάνω σε ευθεία του επιπέδου x-y, όπως αυτή του Σχήματος (2-14).



Σχήμα 2-13: Το πρόβλημα της συνάρτησης XOR σε αναπαράσταση στο επίπεδο x-y

Πηγή: Le & Wang, 2013

Για να είναι  $S > \theta$ , θα πρέπει τα  $s_1, s_2$  βρίσκονται στο δεξί ημιεπίπεδο οπότε και η έξοδος να είναι 1, αλλιώς αν τα  $s_1, s_2$  υπάρχουν στο αριστερό ημιεπίπεδο, τότε  $S < \theta$  και η έξοδος είναι 0. Οι τιμές των  $w_1, w_2, \theta$  προσδιορίζουν τη θέση και την κλίση της ευθείας. Αυτό που επιζητείται όμως είναι τα σημεία  $(0,0)$  και  $(1,1)$  να είναι στην ίδια πλευρά, καθώς και τα  $(0,1)$  και  $(1,0)$  στην άλλη. Μόνο τότε το δίκτυο θα δίνει τη σωστή απάντηση. Διαπιστώνουμε ότι δεν υπάρχει δυνατός τρόπος να δημιουργήσουμε μια τέτοια ευθεία κι έτσι συμπεραίνουμε ότι το δίκτυο του

Σχήματος (4-2) είναι μη εφικτό να λύσει το πρόβλημα XOR, ανεξάρτητα από τις τιμές των  $w_1, w_2, \theta$ .

### 2.8.3 Γραμμική Διαχωρισιμότητα

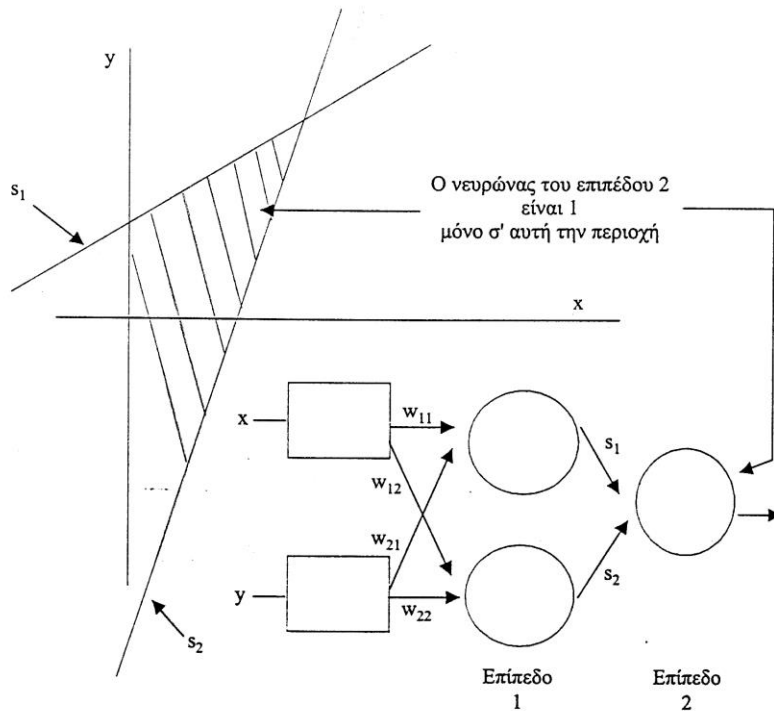
Η γραμμική διαχωριστικότητα αναφέρεται σε σημεία δεδομένων σε προβλήματα δυαδικής ταξινόμησης που μπορούν να διαχωριστούν χρησιμοποιώντας γραμμικό όριο. Εάν τα σημεία δεδομένων μπορούν να διαχωριστούν χρησιμοποιώντας μια γραμμή, μια γραμμική συνάρτηση ή ένα επίπεδο υπερεπίπεδο θεωρείται γραμμικά διαχωρίσιμο. Η γραμμική διαχωριστικότητα είναι μια σημαντική έννοια στα νευρωνικά δίκτυα.

Η γραμμική διαχωρισιμότητα περιορίζει τα δίκτυα ενός επιπέδου σε προβλήματα ταξινόμησης στα οποία μπορούν να διαχωριστούν γεωμετρικά σύνολα σημείων (που αντιστοιχούν σε τιμές εισόδου). Για την περίπτωση δύο εισόδων μας, το διαχωριστικό είναι μια ευθεία γραμμή. Στην περίπτωση τριών εισόδων, ο διαχωρισμός πραγματοποιείται με ένα επίπεδο που κόβει τον τρισδιάστατο χώρο. Για τέσσερις ή περισσότερες εισόδους, η οπτικοποίηση δεν είναι δυνατή και πρέπει να φανταστεί κανείς διανοητικά έναν  $n$ -διάστατο χώρο που κόβεται από ένα «υπερπλάνο», ένα γεωμετρικό αντικείμενο που διασχίζει έναν χώρο τεσσάρων ή περισσότερων διαστάσεων (Rebala et al., 2019).

Μέχρι το τέλος της δεκαετίας του 1960, το πρόβλημα της γραμμικής διαχωρισιμότητας ήταν καλά κατανοητό. Επιπλέον, ήταν γνωστό ότι αυτός ο σοβαρός περιορισμός της δυνατότητας αναπαράστασης από δίκτυα ενός επιπέδου θα μπορούσε να ξεπεραστεί με την προσθήκη πρόσθετων επιπέδων. Για παράδειγμα, τα δίκτυα δύο επιπέδων μπορούν να ληφθούν με τη διαδοχή δύο δικτύων μονής στρώσης. Είναι σε θέση να εκτελούν πιο γενικές ταξινομήσεις διαχωρίζοντας εκείνα τα σημεία που περιέχονται σε κυρτές οριοθετημένες ή απεριόριστες περιοχές. Μια περιοχή ονομάζεται κυρτή εάν για οποιαδήποτε δύο σημεία της το τμήμα που τα συνδέει βρίσκεται εξ ολοκλήρου στην περιοχή. Μια περιοχή ονομάζεται οριοθετημένη αν μπορεί να περικλείεται σε κύκλο. Μια απεριόριστη περιοχή δεν μπορεί να περικλείεται σε κύκλο (για παράδειγμα, μια περιοχή μεταξύ δύο παράλληλων ευθειών) (Gawlikowski et al., 2023).

Έστω ένα νευρωνικό δίκτυο με δυο επίπεδα και με δυο εισόδους που έρχονται στους δυο νευρώνες του πρώτου επιπέδου, όπως στο Σχήμα (2-15), οι οποίοι συνδέονται με έναν του δεύτερου επιπέδου. Έστω  $\theta = 0.65$  για το νευρώνα του δεύτερου και ότι τα βάρη είναι όλα ίσα

προς 0.5. Στην περίπτωση αυτή, αν η έξοδος των δυο νευρώνων του πρώτου επιπέδου είναι 1, τότε  $S_1=S_2=0.5*1+0.5*1=1>\theta$  επομένως και η έξοδος του νευρώνα του δεύτερου επιπέδου θα είναι 1.



Σχήμα 2-14: Κυρτή περιοχή απόφασης που παράγεται από σύστημα δυο επιπέδων

Πηγή: Norgaard et al., 2000


Στο Σχήμα (2-15) θεωρείται ότι κάθε νευρώνας του πρώτου επιπέδου χωρίζει σε μέρη το x-y επίπεδο έτσι ώστε ο πρώτος από τους δυο νευρώνες να προσφέρει έξοδο 1 για εισόδους κάτω από την ευθεία  $e_1$  κι ο άλλος νευρώνας να προσφέρει έξοδο 1 για εισόδους πάνω από την ευθεία  $e_2$ . Ύστερα από αυτό γίνεται αντιληπτό ότι η έξοδος του συστήματος θα είναι 1 για εισόδους της γραμμοσκιασμένης περιοχής. Κατ' αναλογία, αν είχαμε αξιοποιήσει τρεις νευρώνες στο επίπεδο εισόδου, θα διαθέταμε τρεις τεμνόμενες ευθείες, οι οποίες δίνουν περιοχή σε τριγωνικό σχήμα. Για περισσότερους νευρώνες αναπτύσσεται πολύγωνο με αντίστοιχο πλήθος πλευρών. Όλα τα πολύγωνα αυτά είναι κυρτά για τον λόγο ότι δημιουργούνται από τις περιοχές της λογικής σύζευξης, επομένως είναι αποδεκτά πεδία λύσεων (Gawlikowski et al., 2023).

Η εισαγωγή του νευρώνα του δεύτερου επιπέδου παρέχει την ευκαιρία να μπορεί το δίκτυο να αναπαραστήσει κι άλλες συναρτήσεις εκτός από τη λογική διάζευξη. Αυτό σαφώς

θεωρεί ως δεδομένο τα  $w$  και τα  $\theta$  να επιλεγούν σωστά. Επιπλέον, θα πρέπει έστω ένας από τους νευρώνες του πρώτου επιπέδου να έχει έξοδο 1. Υπάρχουν 16 δυαδικές συναρτήσεις δυο παραμέτρων. Εφόσον επιλεγούν σωστά τα  $\theta$  και  $w$ , ένα δίκτυο με δυο επίπεδα έχει τεκμηριωθεί ότι μπορεί να αναπαραστήσει τις 14 από αυτές, δηλαδή όλες εκτός από τις X-OR και X-NOR, που είναι οι γραμμικά μη διαχωρίσιμες.

Για να διευκρινιστεί η απαίτηση κυρτότητας, εξετάζουμε ένα απλό δίκτυο δύο επιπέδων με δύο εισόδους συνδεδεμένους σε δύο νευρώνες στο πρώτο στρώμα συνδεδεμένους σε έναν μόνο νευρώνα στο στρώμα. Κάθε νευρώνας στρώματος 1 χωρίζει το επίπεδο  $x$ - $y$  σε δύο ημιεπίπεδα, το ένα παρέχει μια ενιαία έξοδο για εισόδους κάτω από την επάνω γραμμή και το άλλο για εισόδους πάνω από την κάτω γραμμή (Gawlikowski et al., 2023).

Οι κινήσεις δεν χρειάζεται να είναι δυαδικές. Το διάνυσμα συνεχών εισόδων μπορεί να είναι ένα αυθαίρετο σημείο στο επίπεδο  $x$ - $y$ . Στην περίπτωση αυτή, έχουμε να κάνουμε με την ικανότητα του δικτύου να διαχωρίζει το επίπεδο σε συνεχείς περιοχές και όχι με το διαχωρισμό διακριτών συνόλων σημείων. Για όλες αυτές τις συναρτήσεις, ωστόσο, η γραμμική διαχωρισσιμότητα δείχνει ότι η έξοδος του νευρώνα του δεύτερου στρώματος είναι ίση με ένα μόνο στο τμήμα του επιπέδου  $x$ - $y$  που περιορίζεται από την πολυγωνική περιοχή. Επομένως, για να διαχωριστούν τα επίπεδα  $P$  και  $Q$ , είναι απαραίτητο όλα τα  $P$  να βρίσκονται μέσα σε μια κυρτή πολυγωνική περιοχή που δεν περιέχει σημεία  $Q$  (ή το αντίστροφο).



Σχήμα 2-15: Δίκτυο τριών επιπέδων

Πηγή: Norgaard et al., 2000

Στο Σχήμα (2-16) υπάρχει ένα δίκτυο με τρία επίπεδα του οποίου οι δυνατότητες

επηρεάζονται από τον αριθμό των νευρώνων και από τα βάρη  $w$ . Εδώ δεν προκύπτουν περιορισμοί κυρτότητας. Μια ομάδα κυρτών πολυγώνων σημαίνει την είσοδο στο τρίτο επίπεδο, ενώ ο λογικός συνδυασμός τους δεν είναι ανάγκη να είναι κυρτός. Όσο αυξάνουμε το πλήθος των νευρώνων, ο αριθμός των πλευρών των πολυγώνων αντιδρά με τον ίδιο τρόπο.

Αν και οι δυνατότητες των πολυεπίπεδων δικτύων είναι γνωστές εδώ και πολύ καιρό, για πολλά χρόνια δεν υπήρχε θεωρητικά ορθός αλγόριθμος για τη ρύθμιση των βαρών τους. Στα επόμενα κεφάλαια θα μελετήσουμε λεπτομερώς τους αλγόριθμους εκμάθησης πολλαπλών επιπέδων, αλλά προς το παρόν αρκεί να κατανοήσουμε το πρόβλημα και να ξέρουμε ότι η έρευνα οδήγησε σε ένα συγκεκριμένο αποτέλεσμα.

#### 2.8.4 Ικανότητα αποθήκευσης

Τα νευρωνικά δίκτυα εκπαιδεύονται σε μεγάλο αριθμό ζευγών ερωτήσεων-απαντήσεων. Ως αποτέλεσμα, απομνημονεύουν δεδομένα, τα συγκρίνουν, βρίσκουν μοτίβα και στη συνέχεια λαμβάνουν αποφάσεις με βάση αυτά. Όλα όσα έχει μάθει το μοντέλο κατά την εκπαίδευση αποθηκεύονται στις παραμέτρους του δικτύου του και παραμένουν αμετάβλητα μετά την εκπαίδευση. Όσον αφορά τους τύπους μνήμης, τα σύγχρονα νευρωνικά δίκτυα που γνωρίζουν από κείμενα (δηλ. τα μεγάλα γλωσσικά μοντέλα, LLM) διαθέτουν διάφορους τύπους, όπως ακριβώς και οι άνθρωποι.

Οι ερευνητές εργάζονται συνεχώς για την αύξηση της μνήμης RAM, ώστε το μοντέλο να γνωρίζει όσο το δυνατόν καλύτερα το πλαίσιο και να ανταποκρίνεται πιο λογικά στα αιτήματα των χρηστών. Είναι σημαντικό να συνειδητοποιήσουμε ότι τα μεγάλα γλωσσικά μοντέλα είναι σε θέση να επιλύουν νέα προβλήματα με βάση επιδείξεις ή οδηγίες χωρίς την παραδοσιακή μάθηση που απαιτεί την ενημέρωση των παραμέτρων του δικτύου (η λεγόμενη μάθηση εντός πλαισίου). Αυτό σημαίνει ότι όσο μεγαλύτερη είναι η χωρητικότητα της μνήμης, τόσο καλύτερα και αποτελεσματικότερα το μοντέλο μπορεί να επιλύει νέα και πιο σύνθετα καθήκοντα (Joshi, 2020).

#### 2.8.5 Η εκπαίδευση του αισθητήρα

Ως πρώτη προσέγγιση, η εκπαίδευση ενός νευρωνικού δικτύου είναι ένας από τους πρώτους παράγοντες που πρέπει να ληφθούν υπόψη κατά την εφαρμογή αυτού του τύπου



επεξεργασίας. Στην πραγματικότητα, μπορεί να ειπωθεί ότι η μάθηση ενός νευρωνικού δικτύου μοιάζει με εκείνη των ανθρώπων, η οποία είναι η μάθηση βάσει παραδειγμάτων. Όπως και οι άνθρωποι, τα νευρωνικά δίκτυα αναλύουν αντικείμενα, προβλέπουν τι αντιπροσωπεύουν και διορθώνονται αν κάνουν λάθος. Μετά από αυτή τη διόρθωση, διαφοροποιούν τις γνώσεις τους ώστε να μην κάνουν το ίδιο λάθος.

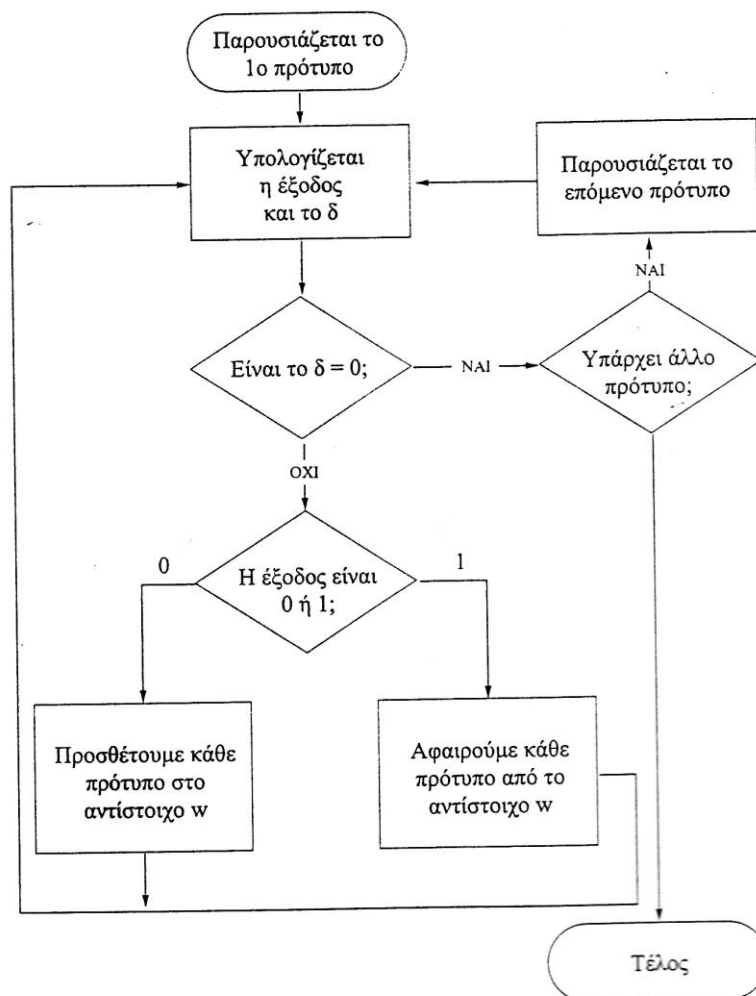
Επομένως, η εκπαίδευση ενός νευρωνικού δικτύου βασίζεται σε τέσσερα βασικά βήματα: εμπρόσθιο πέρασμα, σύγκριση με την βασική αλήθεια (GT), υπολογισμός του συνολικού σφάλματος και οπισθοδρομικό πέρασμα ή οπισθοδιάδοση.

Για να μεταβάλλουν τα νευρωνικά δίκτυα τη γνώση τους ώστε να είναι όσο το δυνατόν πιο κοντά στην απόλυτη αλήθεια το κάνουν με έναν απλό τρόπο: ελαχιστοποιώντας το σφάλμα που προκύπτει. Ωστόσο, η πιο συχνά χρησιμοποιούμενη μέθοδος για την ελαχιστοποίηση μιας συνάρτησης είναι η κατάβαση κλίσης. Η εκπαίδευση ενός νευρωνικού δικτύου συνίσταται στην προσαρμογή των βαρών εισόδου όλων των νευρώνων που αποτελούν μέρος του νευρωνικού δικτύου, έτσι ώστε οι αποκρίσεις του επιπέδου εξόδου να είναι όσο το δυνατόν πιο κοντά στα δεδομένα που γνωρίζουμε (Foote, 2021).

Οι αλγόριθμοι εκπαίδευσης ενός νευρωνικού δικτύου οδηγούν σε μια διαδικασία μάθησης που επιτρέπει στο δίκτυο να αναπτύσσει αντιδράσεις και καθήκοντα. Αυτό γίνεται μέσω μιας διαδικασίας μάθησης με επίβλεψη, η οποία παρέχει στον αλγόριθμο ένα σύνολο δεδομένων με ετικέτες. Χάρη σε αυτό, το δίκτυο μπορεί να επεξεργαστεί τα δεδομένα εισόδου και να εντοπίσει μοτίβα και να επεξεργαστεί απαντήσεις με βάση αυτά. Η οπισθοδιάδοση είναι μια ουσιαστική διαδικασία στα τεχνητά νευρωνικά δίκτυα. Χρησιμοποιεί δεδομένα εκπαίδευσης για να προσαρμόσει τα βάρη των νευρώνων ανάλογα με την απόδοσή τους, βελτιώνοντας έτσι την ακρίβεια του δικτύου. Η μέθοδος αυτή είναι γνωστή ως οπισθοδιάδοση.

### **2.8.6 Η διαδικασία εκπαίδευσης σύμφωνα με τον Κανόνα Δέλτα**

Η μέθοδος του κανόνα Δέλτα εμπεριέχει ένα σημαντικό αριθμό κύκλων. Ένας κύκλος αποτελεί μια συνεκτική διαδοχή από την απεικόνιση των τιμών των προτύπων στην είσοδο μέχρι την έξοδο και τη διόρθωση των τιμών  $w$ . Όταν ακολουθηθεί ο εν λόγω αλγόριθμος, ύστερα από πληθώρα κύκλων το  $N\Delta$  θα εκπαιδευτεί και θα είναι σε θέση να βλέπει και να ταυτοποιεί νέα πρότυπα απαντώντας ορθά. Στο σχήμα που ακολουθεί παρατηρείται τη διεργασία της εκπαίδευσης  $N\Delta$  με απλό τρόπο.



Σχήμα 2-16: Αλγόριθμος εκπαίδευσης του δικτύου

Πηγή: Cui et al., 2017

Με βάση τον κανόνα Δέλτα, προσδιορίζουμε ως παράμετρο  $\delta$  τη διαφορά εξόδου και στόχου, δηλαδή

$$\delta = t - o \quad \text{Σχέση (2.6)}$$

όπου 't' είναι ο στόχος (από τη λέξη target) και 'o' η έξοδος (από τη λέξη output). Η εξίσωση (2.6) μας εξυπηρετεί στον υπολογισμό του  $\delta$ , ενώ αν  $\delta=0$ , οπότε και το σφάλμα είναι 0, η έξοδος είναι ορθή και δεν χρειάζεται διόρθωση (αυτό πρακτικά δίνει την απάντηση 'ναι' στο διάγραμμα ροής). Σε κάθε άλλη τιμή του  $\delta$  θα γίνει διόρθωση (η απάντηση 'όχι'). Ακολούθως τίθεται το ερώτημα αν η έξοδος είναι 0 ή 1. Αν είναι 0 τότε η περίπτωση αντιστοιχεί σε

$\delta > 0$ , επομένως εισάγουμε την τιμή κάθε εισόδου στο αντίστοιχο  $w$ . Αν είναι 1 τότε έχουμε  $\delta < 0$  και αφαιρείται την τιμή κάθε εισόδου από το  $w$ . Υπολογίζουμε τώρα την ποσότητα  $\Delta$ :

$$\Delta_i = \eta \delta x_i \quad \text{Σχέση (2.7)}$$

Όπου  $x_i$  είναι η τιμή του σήματος εισόδου και  $\eta$  είναι μια σταθερά που δίνει το ρυθμό εκπαίδευσης. Ακολουθώντας:

$$w_i(n+1) = w_i(n) + \Delta_i \quad \text{Σχέση (2.8)}$$

όπου  $w_i(n)$  είναι η τιμή του βάρους πριν τη διόρθωση στο βήμα  $n$ ,  $w_i(n+1)$  είναι η τιμή του βάρους ύστερα από τη διόρθωση στο βήμα  $n+1$  και  $\Delta$  το ποσό της διόρθωσης. Ο κανόνας αυτός αλλάζει ένα βάρος  $w_i$  μόνο αν το σήμα  $x_i = 1$ , αλλά δεν το αλλάζει αν  $x_i = 0$  διότι τότε  $\Delta_i = 0$ . Παράλληλα, θα πρέπει  $\delta \neq 0$ , για να γίνει οποιαδήποτε μεταβολή. Η τιμή του  $\eta$  είναι γενικά  $0 < \eta < 1$ . Ο χρόνος εκπαίδευσης είναι μεγάλος αν το  $\eta$  είναι μικρό, ενώ είναι μικρός όταν το  $\eta$  είναι μεγαλύτερο.

Η μέθοδος του κανόνα Δέλτα που παρουσιάζεται ανήκει σε μια ευρεία κατηγορία αλγορίθμων μάθησης, επειδή τόσο τα διανύσματα εισόδου όσο και οι απαιτούμενες τιμές των διανυσμάτων εξόδου είναι γνωστά. Φυσικά, τίθεται το ερώτημα αν ο αλγόριθμος μάθησης ενός perceptron οδηγεί πάντα στο επιθυμητό αποτέλεσμα. Η απάντηση σε αυτό το ερώτημα δίνεται από το θεώρημα σύγκλισης του perceptron: Εάν υπάρχει ένα σύνολο τιμών βαρών που παρέχουν την απαιτούμενη αναγνώριση προτύπων, τότε τελικά ο αλγόριθμος μάθησης οδηγεί είτε σε αυτό το σύνολο είτε σε ένα άλλο σύνολο, έτσι ώστε να επιτευχθεί η απαιτούμενη αναγνώριση προτύπων

Το κυριότερο αρνητικό που παρουσιάζει ο κανόνας Δέλτα είναι ότι οι μεταβολές των βαρών είναι εφικτές μόνο σε συγκεκριμένο επίπεδο όπου υπήρχε εξαρχής πριν από την έξοδο. Συνεπώς, μπορεί να επιτευχθεί μόνο σε δίκτυα όπως ο αισθητήρας. Ακολουθεί αριθμητικό παράδειγμα:

Έστω αισθητήρας της μορφής του σχήματος (2-13), με  $w_1 = 0.3$  και  $w_2 = 0.1$  τυχαίες αρχικές τιμές των βαρών,  $\theta = 0.5$  τιμή κατωφλίου και ρυθμό εκπαίδευσης  $\eta = 0.4$ . Εισάγουμε σήμα  $s = [3 \ -2]$  για το οποίο γνωρίζουμε ότι επιθυμητή έξοδος είναι το  $t = 0$ .

- Βήμα 1<sup>ο</sup> : Υπολογίζουμε το συνολικό σήμα που εισέρχεται στο νευρώνα, το οποίο δίνεται από τη σχέση  $S = s_1 w_1 + s_2 w_2 = 3 \cdot 0.3 - 2 \cdot 0.1 = 0.7$ .
- Βήμα 2<sup>ο</sup> : Πράγματι, ισχύει  $S > \theta$  επομένως η έξοδος  $o = 1$ , θεωρώντας ότι ο νευρώνας


επεξεργάζεται το σήμα με συνάρτηση μεταφοράς τη Heaviside.

- Βήμα 3° : Άρα  $\delta = t - o = 0 - 1 = -1$ .
- Βήμα 4° : Υπολογίζουμε την ποσότητα  $\Delta_i = \eta \delta_i$ , επομένως  $\Delta_1 = 0.4(-1)0.3 = -0.12$  και  $\Delta_2 = 0.4(-1)(-2) = 0.8$ .
- Βήμα 5° : Τα νέα βάρη προκύπτουν από τη σχέση (5.8), άρα  $w_1' = 0.3 - 0.12 = 0.18$  και  $w_2' = 0.1 + 0.8 = 0.9$ .

Σε αυτή τη φάση έχει υλοποιηθεί ένας πλήρης κύκλος υιοθέτησης του κανόνα Δέλτα. Ακολουθούν ακόμη πιο πολλοί προκειμένου να εκπαιδευτεί το δίκτυο, δηλαδή να περιοριστεί το σφάλμα  $\delta$ .

Έτσι, η εισαγωγή της σιγμοειδούς συνάρτησης ενεργοποίησης αντί της βηματικής συνάρτησης και η εμφάνιση ενός νέου αλγορίθμου μάθησης - του γενικευμένου κανόνα δέλτα - διεύρυναν το πεδίο εφαρμογής, ενώ υπάρχουν άλλες (Σχήμα 2-18) οι οποίες έχουν φανεί εξυπηρετικές σε άλλα είδη ΤΝΔ (Fujii et al., 2020).

Ως εκ τούτου, η γραμμική (linear) θεωρείται ιδεώδης καθώς με βάση τον κανόνα δέλτα, αναπτύχθηκε το ADALINE και άρχισε αμέσως να χρησιμοποιείται για εργασίες πρόβλεψης και προσαρμοστικού ελέγχου, το οποίο χαρακτηρίζεται κρίσιμο εργαλείο για τη μέθοδο οπισθοδιάδοσης όπως θα φανεί στην επόμενη παράγραφο.



Σχήμα 2-17: Είδη συναρτήσεων ενεργοποίησης

Πηγή: Cui et al., 2017

### 2.8.7 Προβλήματα κατά την εκπαίδευση

Αν και η εργασία των τεχνητών νευρωνικών δικτύων έχει αρκετά θετικά, υπάρχουν και ορισμένα προβλήματα. Για παράδειγμα, το πρόβλημα του κορεσμού του δικτύου: όσο μεγαλύτερες είναι οι τιμές των σημάτων, τόσο πιο κοντά στο μηδέν βρίσκονται οι κλίσεις της συνάρτησης ενεργοποίησης, γεγονός που εμποδίζει την επιλογή των καλύτερων συντελεστών. Επιπλέον, οι περισσότερες επιλογές σχεδιασμού για τα τεχνητά νευρωνικά δίκτυα είναι ευρετικές, πράγμα που σημαίνει ότι δεν δίνουν τις μόνες σωστές λύσεις. Απαιτείται επίσης πολύς χρόνος και προσπάθεια για τον πολυκυκλικό συντονισμό των στοιχείων του μοντέλου και των συνδέσεών τους και την επακόλουθη κατασκευή του ίδιου του μοντέλου (Helm et al., 2020).

Ενδέχεται να υπάρξουν προβλήματα στην προετοιμασία ενός δείγματος για εκπαίδευση λόγω της ανεπάρκειας του διαθέσιμου υλικού. Η εκπαίδευση του ΤΝΔ μπορεί να οδηγήσει σε αδιέξοδο και η ίδια η διαδικασία θα διαρκέσει πολύ χρόνο.

Επίσης η συμπεριφορά ενός προ-εκπαιδευμένου νευρωνικού δικτύου είναι μερικές φορές απρόβλεπτη και η χρήση εμπορικών προϊόντων που υλοποιούν τα ΤΝΔ μπορεί να είναι δύσκολη λόγω του υψηλού κόστους τους. Ένα άλλο πρόβλημα του νευρωνικού δικτύου είναι ότι είναι ένας προσεγγιστής, κατά τη δημιουργία του οποίου δεν υπολογίζει τη συνάρτησή-στόχο, αλλά επιλέγει συναρτήσεις που αθροίζονται και έτσι δίνουν το αποτέλεσμα με τη μορφή ενός συνόλου τιμών παρόμοιων με το αρχικό. Κατά συνέπεια, τα δεδομένα εξόδου του ANN, στην πραγματικότητα, θα έχουν πάντα ένα σφάλμα, η τιμή του οποίου δεν είναι γνωστή εκ των προτέρων, αλλά υπάρχει η δυνατότητα να μειωθεί σε ένα λογικό επίπεδο κατά τη διάρκεια της εκπαίδευσης. Το κυριότερο όμως πρόβλημα της εκπαίδευσης ενός τεχνητού νευρωνικού δικτύου, τελικά, είναι ότι αυτό «απομνημονεύει» τις απαντήσεις, ενώ ένας άνθρωπος αναγνωρίζει μοτίβα (Helm et al., 2020).

## Κεφάλαιο 3<sup>ο</sup> Μηχανική Όραση

### 3.1 Εισαγωγή στη μηχανική όραση

Η μηχανική όραση (CV) είναι ένα πεδίο τεχνητής νοημοσύνης που επιτρέπει στις μηχανές να ερμηνεύουν και να λαμβάνουν αποφάσεις με βάση οπτικά δεδομένα από τον πραγματικό κόσμο. Αυτό περιλαμβάνει εργασίες όπως η αναγνώριση αντικειμένων, η ταξινόμηση εικόνων και η κατανόηση σκηνής. Η παραδοσιακή όραση υπολογιστή βασίζεται σε μεγάλο βαθμό στα συνελκτικά νευρωνικά δίκτυα (CNN) λόγω της ικανότητάς τους να μαθαίνουν χωρικές ιεραρχίες στις εικόνες. Ωστόσο, τα νευρωνικά δίκτυα αιχμών (SNN) αναδεικνύονται ως μια πολλά υποσχόμενη εναλλακτική λύση, προσφέροντας οφέλη όπως η ενεργειακή απόδοση και η ικανότητα επεξεργασίας χρονικών οπτικών πληροφοριών.

**Νευρωνικά δίκτυα αιχμών (Spiking Neural Networks, SNN) στη μηχανική όραση:** Τα SNN εισάγουν ένα νέο παράδειγμα στην όραση υπολογιστή μιμούμενοι το ανθρώπινο οπτικό σύστημα, το οποίο λειτουργεί μέσω αιχμών (διακριτών ηλεκτρικών παλμών) και όχι συνεχών σημάτων. Η φύση των SNN που βασίζεται σε συμβάντα τους επιτρέπει να επεξεργάζονται οπτικά δεδομένα με τρόπο που είναι πιο κοντά στον τρόπο λειτουργίας των βιολογικών συστημάτων, ιδιαίτερα σε σενάρια όπου ο χρόνος διαδραματίζει καθοριστικό ρόλο, όπως σε δυναμικά οπτικά περιβάλλοντα.

**Παράδειγμα πειράματος:** Ερευνητές έχουν αποδείξει τη χρήση SNN σε αισθητήρες δυναμικής όρασης (DVS), οι οποίοι καταγράφουν αλλαγές σε μια σκηνή και όχι στατικές εικόνες, επιτρέποντας την αποτελεσματική επεξεργασία της κίνησης και τα χρονικά μοτίβα που αποτελούν πρόκληση για τα παραδοσιακά CNN (Han et al., 2021).

### 3.2 Datasets μηχανικής όρασης

#### 3.2.1 MNIST

Το σύνολο δεδομένων MNIST είναι ένα από τα πλέον γνωστά σημεία αναφοράς στην όραση υπολογιστών, που αποτελείται από χειρόγραφα ψηφία. Έχει χρησιμοποιηθεί εκτενώς για την αξιολόγηση της απόδοσης τόσο των παραδοσιακών νευρωνικών δικτύων όσο και των SNN:

- **Μετατροπή σε αιχμές:** Στα SNN, οι εικόνες MNIST συχνά μετατρέπονται σε σειρές αιχμών χρησιμοποιώντας τεχνικές όπως η κωδικοποίηση ρυθμού, όπου η ένταση των εικονοστοιχείων αντιστοιχίζεται στη συχνότητα των αιχμών. Εναλλακτικώς, μπορεί να χρησιμοποιηθεί χρονική κωδικοποίηση, όπου ο χρονισμός των αιχμών αντιπροσωπεύει τις τιμές των εικονοστοιχείων.
- **Απόδοση SNN στο MNIST:** Παρά την απλότητα του συνόλου δεδομένων MNIST, η εκπαίδευση των SNN για την επίτευξη υψηλής ακρίβειας απαιτεί προσεκτική ρύθμιση των παραμέτρων του δικτύου και των κανόνων εκμάθησης. Τα CNN αιχμών ήταν ιδιαίτερα επιτυχημένα, επιτυγχάνοντας σχεδόν υπερσύγχρονες επιδόσεις, ενώ αποδεικνύουν την ενεργειακή απόδοση των SNN (Xie et al., 2022).
- **Παράδειγμα πειράματος:** Ένα πείραμα κατέδειξε ότι ένα SNN που εκπαιδεύτηκε στο MNIST χρησιμοποιώντας πλαστικότητα εξαρτώμενης από τον χρόνο αιχμής (STDP) πέτυχε ακρίβεια 98%, κοντά σε αυτή των παραδοσιακών CNN, αλλά με μειωμένη κατανάλωση ενέργειας, απεικονίζοντας τις δυνατότητες των SNN για αποτελεσματική οπτική επεξεργασία.

### 3.2.2 CIFAR-10

Το CIFAR-10 είναι ένα περισσότερο απαιτητικό σύνολο δεδομένων από το MNIST, που αποτελείται από έγχρωμες εικόνες σε 10 διαφορετικές κατηγορίες. Χρησιμεύει ως σημείο αναφοράς για την αξιολόγηση της επεκτασιμότητας και της απόδοσης των SNN σε πιο σύνθετες εργασίες όρασης:

- **Προκλήσεις με το CIFAR-10:** Η αυξημένη πολυπλοκότητα των εικόνων CIFAR-10, συμπεριλαμβανομένης της ανάγκης επεξεργασίας έγχρωμων πληροφοριών και λεπτομερέστερων χωρικών δομών, καθιστά δυσκολότερη τη μετατροπή τους σε αναπαραστάσεις αιχμών και τη διατήρηση υψηλής ακρίβειας ταξινόμησης.
- **Προσεγγίσεις SNN:** Προηγμένες τεχνικές, όπως υβριδικά μοντέλα που συνδυάζουν SNN με παραδοσιακές προσεγγίσεις βαθιάς μάθησης ή χρησιμοποιώντας CNN αιχμών με προσεκτικά σχεδιασμένα σχήματα κωδικοποίησης, έχουν διερευνηθεί για τη βελτίωση της απόδοσης στο CIFAR-10.
- **Παράδειγμα πειράματος:** Σε μια πρόσφατη μελέτη, οι ερευνητές χρησιμοποίησαν

ένα βαθύ CNN αιχμών για να ταξινομήσουν εικόνες από το σύνολο δεδομένων CIFAR-10. Χρησιμοποιώντας κωδικοποίηση ρυθμού και εξειδικευμένες τεχνικές εκπαίδευσης, πέτυχαν ανταγωνιστική ακρίβεια, ενώ μείωσαν σημαντικά την κατανάλωση ενέργειας σε σύγκριση με τα παραδοσιακά CNN (Yang et al., 2020).

### 3.2.3 ImageNet

Η ImageNet είναι μια εκτενή βάση δεδομένων εικόνων που έχει χρησιμοποιηθεί ευρέως στην έρευνα της τεχνητής νοημοσύνης και της μηχανικής μάθησης, ειδικότερα για την εκπαίδευση και αξιολόγηση αλγορίθμων αναγνώρισης εικόνας. Δημιουργήθηκε το 2009 από ερευνητές του Πανεπιστημίου Πρίνστον και περιλαμβάνει εκατομμύρια ετικετοποιημένες εικόνες που καλύπτουν χιλιάδες κατηγορίες αντικειμένων. Τα σημαντικά στοιχεία του ImageNet είναι τα ακόλουθα: α) Δομή της Βάσης Δεδομένων (Deng et al., 2009): Η ImageNet οργανώνεται σε 20.000+ κατηγορίες, που είναι γνωστές ως "synsets", και καλύπτει ποικιλία θεμάτων όπως ζώα, φυτά, αντικείμενα κ.α. Κάθε κατηγορία περιέχει χιλιάδες εικόνες, β) Χρήση στη Μηχανική Μάθηση: Η ImageNet έχει γίνει το πρότυπο για την εκπαίδευση αλγορίθμων αναγνώρισης εικόνας. Το 2012, ένα νευρωνικό δίκτυο που εκπαιδεύτηκε με δεδομένα από την ImageNet κέρδισε τον διαγωνισμό ImageNet Large Scale Visual Recognition Challenge (ILSVRC), σημειώνοντας δραματική μείωση του ποσοστού σφαλμάτων στην αναγνώριση εικόνας (Russakovsky et al., 2015), γ) Επίδραση στην Τεχνητή Νοημοσύνη: Η επιτυχία των αλγορίθμων που εκπαιδεύτηκαν με την ImageNet έχει επιταχύνει την ανάπτυξη καινοτόμων τεχνολογιών στην αναγνώριση εικόνας και έχει ενισχύσει τη χρήση της τεχνητής νοημοσύνης σε τομείς όπως η αυτοκινητοβιομηχανία, η υγειονομική περίθαλψη και η ρομποτική, δ) Προβληματισμοί: Παρά τα οφέλη της, η ImageNet έχει επίσης προκαλέσει κριτική σχετικά με ζητήματα όπως η μεροληψία στις ετικέτες εικόνας και η αναπαράσταση των δεδομένων, καθώς μπορεί να αντικατοπτρίζει πολιτισμικές προκαταλήψεις. Η ImageNet παραμένει ένα από τα πιο σημαντικά εργαλεία για την ανάπτυξη και αξιολόγηση αλγορίθμων μηχανικής μάθησης και είναι κρίσιμη για την προώθηση της έρευνας στον τομέα της τεχνητής νοημοσύνης (Krizhevsky et al., 2012).



### 3.3 Νευρωνικά Δίκτυα: AlexNet, LeNet

Τα νευρωνικά δίκτυα είναι μια από τις πιο σημαντικές τεχνολογίες στον τομέα της τεχνητής νοημοσύνης και της μηχανικής μάθησης. Μεταξύ των πιο γνωστών αρχιτεκτονικών νευρωνικών δικτύων είναι τα LeNet και AlexNet, τα οποία έχουν διαδραματίσει καθοριστικό ρόλο στην εξέλιξη της αναγνώρισης εικόνας (LeCun, et al., 1998).

Το LeNet-5 είναι ένα από τα πρώτα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks - CNNs), που αναπτύχθηκε από τον Yann LeCun το 1998 για την αναγνώριση χειρόγραφων ψηφίων (π.χ. το σύστημα MNIST). Αυτή η αρχιτεκτονική αποτελείται από επαναλαμβανόμενα επίπεδα συνελκτικών και υποδειγματικών (pooling) στρωμάτων και έχει ως στόχο την εξαγωγή χαρακτηριστικών και τη μείωση της διαστάσεων των δεδομένων με τέτοιο τρόπο ώστε να διατηρείται η πληροφορία που είναι απαραίτητη για την κατηγοριοποίηση.

Το LeNet-5, που αναπτύχθηκε από τον Yann LeCun το 1998, είναι ένα από τα πρώτα συνελκτικά νευρωνικά δίκτυα, και η δομή του έχει διαμορφώσει σε μεγάλο βαθμό τη σύγχρονη έρευνα στα νευρωνικά δίκτυα και την αναγνώριση εικόνας. Το LeNet-5 αναπτύχθηκε αρχικά για την αναγνώριση χειρόγραφων ψηφίων, κυρίως με βάση το σύνολο δεδομένων MNIST. Ακολουθούν λεπτομερώς τα κύρια χαρακτηριστικά και η αρχιτεκτονική του (Krizhevsky et al., 2012). Το LeNet-5 εισάγει τη χρήση συνελκτικών επιπέδων, τα οποία είναι υπεύθυνα για την εξαγωγή χαρακτηριστικών από τις εισερχόμενες εικόνες. Αυτή η διαδικασία πραγματοποιείται μέσω εφαρμογής φίλτρων (kernels) που "συνελίσσονται" με την εικόνα για την ανίχνευση τοπικών χαρακτηριστικών, όπως ακμές ή υφές. Η βασική ιδέα πίσω από τη συγχώνευση είναι ότι βοηθά στην αναγνώριση τοπικών χαρακτηριστικών της εικόνας, όπως τα σχήματα και τα μοτίβα, χωρίς να χρειάζεται να επεξεργάζεται το δίκτυο ολόκληρη την εικόνα κάθε φορά (Simonyan & Zisserman, 2014).

Τα υποδειγματικά επίπεδα χρησιμοποιούνται για τη μείωση της διάστασης της εικόνας, διατηρώντας τις σημαντικές πληροφορίες, αλλά μειώνοντας τον αριθμό των παραμέτρων που χρειάζεται να μάθει το δίκτυο. Στην περίπτωση του LeNet-5, χρησιμοποιείται συνήθως η μέθοδος υποδειγματοληψίας μέγιστης τιμής (maxpooling). Η μείωση της ανάλυσης με αυτό τον τρόπο βοηθά στη γενίκευση και αποτρέπει την υπερπροσαρμογή (overfitting), επιτρέποντας στο δίκτυο να συγκεντρωθεί στις σημαντικές πληροφορίες της εικόνας (LeCun, et al., 1998). Μετά τα συνελκτικά και υποδειγματικά επίπεδα, το δίκτυο περιλαμβάνει πλήρως

συνδεδεμένα επίπεδα, τα οποία λειτουργούν όπως τα παραδοσιακά νευρωνικά δίκτυα και εκτελούν την τελική κατηγοριοποίηση. Κάθε νευρώνας σε αυτά τα επίπεδα είναι συνδεδεμένος με όλους τους νευρώνες του προηγούμενου επιπέδου, επιτρέποντας στο δίκτυο να συνδυάσει τα χαρακτηριστικά που έχουν εξαχθεί στα προηγούμενα στάδια και να καταλήξει στην τελική πρόβλεψη. Στο LeNet-5, υπάρχουν δύο πλήρως συνδεδεμένα επίπεδα, τα οποία συμβάλλουν στη βελτίωση της ακρίβειας στην κατηγοριοποίηση των ψηφίων. Το LeNet-5 χρησιμοποιεί την συνάρτηση ενεργοποίησης sigmoid ή hyperbolic tangent (tanh), η οποία ενεργοποιεί τους νευρώνες με βάση τις εισερχόμενες τιμές. Σε νεότερα μοντέλα, η συνάρτηση ReLU (Rectified Linear Unit) χρησιμοποιείται πιο συχνά, καθώς επιταχύνει τη διαδικασία μάθησης (Albawi et al., 2017).

Το LeNet-5 σχεδιάστηκε για μικρές εικόνες, όπως αυτές που χρησιμοποιούνται στο σύνολο δεδομένων MNIST (28x28 pixels), και έτσι είναι πολύ απλούστερο από σύγχρονα μοντέλα. Αποτελείται από μόλις 60.000 παραμέτρους, σε αντίθεση με τα σύγχρονα δίκτυα, τα οποία μπορεί να έχουν εκατομμύρια ή δισεκατομμύρια παραμέτρους. Όπως τα περισσότερα νευρωνικά δίκτυα, το LeNet-5 εκπαιδεύεται χρησιμοποιώντας εποπτευόμενη μάθηση, όπου το δίκτυο μαθαίνει να συνδέει εικόνες εισόδου με ετικέτες εξόδου (π.χ. τα ψηφία στο MNIST). Η εκπαίδευση πραγματοποιείται με τη χρήση της backpropagation, μιας διαδικασίας που ρυθμίζει τα βάρη των συνδέσεων μεταξύ των νευρώνων ώστε να μειωθεί το σφάλμα.

Η αρχιτεκτονική του LeNet-5 περιλαμβάνει 7 επίπεδα, που περιλαμβάνουν συνελκτικά και υποδειγματικά επίπεδα, πλήρως συνδεδεμένα επίπεδα, καθώς και επίπεδα εισόδου και εξόδου (Albawi et al., 2017):

- α) Επίπεδο Εισόδου: Εικόνα εισόδου 32x32 pixels (συνήθως από το σύνολο MNIST),
- β) Συνελκτικό Επίπεδο 1 (C1): Εφαρμογή 6 φίλτρων συγχώνευσης (με μέγεθος 5x5) που εξάγουν χαρακτηριστικά και παράγουν 6 featuremaps (28x28),
- γ) Υποδειγματικό Επίπεδο 1 (S2): Εφαρμογή της μεθόδου μέγιστης υποδειγματοληψίας (maxpooling), που μειώνει το μέγεθος των featuremaps σε 14x14 pixels,
- δ) Συνελκτικό Επίπεδο 2 (C3): Εφαρμογή 16 φίλτρων συγχώνευσης (με μέγεθος 5x5) στα 14x14 featuremaps του προηγούμενου επιπέδου,
- ε) Υποδειγματικό Επίπεδο 2 (S4): Μείωση των featuremaps σε 5x5 με τη χρήση υποδειγματοληψίας,

ζ) Πλήρως Συνδεδεμένο Επίπεδο (C5): Αυτό το επίπεδο είναι πλήρως συνδεδεμένο με το προηγούμενο επίπεδο και περιέχει 120 νευρώνες,

η) Τελικό Πλήρως Συνδεδεμένο Επίπεδο (F6): Πλήρως συνδεδεμένο επίπεδο με 84 νευρώνες, που οδηγεί στην έξοδο (10 νευρώνες για 10 κατηγορίες ψηφίων).

Το LeNet-5 ήταν θεμελιώδες για την ανάπτυξη των συνελκτικών νευρωνικών δικτύων, τα οποία έχουν αποδειχθεί εξαιρετικά ισχυρά στην ανάλυση εικόνων. Παρά την απλότητά του σε σύγκριση με σύγχρονα μοντέλα, η αρχιτεκτονική του έχει εμπνεύσει πολλές εξελίξεις στον τομέα της βαθιάς μάθησης και της υπολογιστικής όρασης. Το AlexNet είναι ένα πιο εξελιγμένο νευρωνικό δίκτυο, το οποίο ανέπτυξε ο Alex Krizhevsky το 2012. Η AlexNet έφερε επανάσταση στον τομέα της μηχανικής μάθησης, καθώς ήταν το πρώτο δίκτυο που κέρδισε τον διαγωνισμό ImageNet Large Scale Visual Recognition Challenge το 2012 με μεγάλη διαφορά, σημειώνοντας πολύ χαμηλό ποσοστό σφάλματος. Τα χαρακτηριστικά του AlexNet είναι τα ακόλουθα: α) Πολυεπίπεδη αρχιτεκτονική με εκατομμύρια παραμέτρους, β) Χρησιμοποιεί τεχνικές όπως η αποκοπή (dropout) για την αποφυγή της υπερεκπαίδευσης (overfitting), γ) Εκπαιδεύτηκε χρησιμοποιώντας GPUs για ταχύτερη επεξεργασία και αποτελεσματικότερη απόδοση, δ) Έφερε τη χρήση βαθύτερων συνελκτικών επιπέδων και μεγάλων βάσεων δεδομένων, όπως η ImageNet, για εκπαίδευση.

Το LeNet ήταν μια πρώιμη και απλή προσέγγιση που άνοιξε το δρόμο για την ανάπτυξη των συνελκτικών νευρωνικών δικτύων. Το AlexNet, από την άλλη, ήταν το πρώτο δίκτυο που επέδειξε τη δύναμη των CNNs για την ανάλυση πολύπλοκων και μεγάλων συνόλων δεδομένων, όπως η ImageNet, και έφερε την εποχή της "Βαθιάς Μάθησης" (Deep Learning) στο προσκήνιο. Η επιτυχία αυτών των δικτύων ενέπνευσε την ανάπτυξη ακόμη πιο βαθιών δικτύων, όπως το VGG, το ResNet και άλλες σύγχρονες αρχιτεκτονικές, που αποτελούν βασικά εργαλεία για εφαρμογές όπως η αναγνώριση προσώπου, η επεξεργασία φυσικής γλώσσας και η αυτόνομη οδήγηση.

### 3.4 Accuracy and number of parameters

Το LeNet-5 είναι ένα σχετικά μικρό συνελκτικό νευρωνικό δίκτυο σε σύγκριση με πιο σύγχρονες αρχιτεκτονικές, και ως εκ τούτου έχει πολύ λιγότερες παραμέτρους και χαμηλότερη υπολογιστική πολυπλοκότητα. Η ακρίβεια και ο αριθμός των παραμέτρων του σχετίζονται άμεσα με το μέγεθος του δικτύου, τον αριθμό των επιπέδων, και τη δομή του. Το

LeNet-5, όταν εκπαιδεύεται και αξιολογείται στο σύνολο δεδομένων MNIST (χειρόγραφα ψηφία), μπορεί να επιτύχει ακρίβεια περίπου 99% στην ταξινόμηση. Το MNIST είναι ένα σχετικά εύκολο σύνολο δεδομένων, και η αρχιτεκτονική του LeNet είναι αρκετή για να φτάσει πολύ υψηλή ακρίβεια σε αυτό το σύνολο. Αντίθετα, σε πιο περίπλοκα σύνολα δεδομένων με μεγαλύτερη ποικιλομορφία εικόνων, όπως το CIFAR-10, το LeNet-5 αποδίδει χειρότερα, καθώς είναι σχεδιασμένο για μικρότερα και πιο απλά σύνολα δεδομένων. Η ακρίβεια στο CIFAR-10, για παράδειγμα, είναι γύρω στο 75%-80%, πολύ χαμηλότερη από αυτή που μπορούν να επιτύχουν πιο σύγχρονα δίκτυα όπως το AlexNet ή το VGG. Το LeNet-5 είναι ένα δίκτυο με σχετικά χαμηλό αριθμό παραμέτρων. Ο συνολικός αριθμός των παραμέτρων του LeNet-5 είναι περίπου 60,000. Για σύγκριση: α) Το AlexNet έχει περίπου 60 εκατομμύρια παραμέτρους, β) Το VGG-16 έχει περίπου 138 εκατομμύρια παραμέτρους. Αυτός ο μικρός αριθμός παραμέτρων είναι αποτέλεσμα της απλότητας της αρχιτεκτονικής του LeNet-5, η οποία περιλαμβάνει λίγα συνελκτικά και πλήρως συνδεδεμένα επίπεδα σε σύγκριση με τα σύγχρονα βαθιά νευρωνικά δίκτυα.

Η ανάλυση των παραμέτρων ανά επίπεδο. Η ανάλυση των παραμέτρων ανά επίπεδο:

α) Συνελκτικό Επίπεδο C1: Εφαρμόζει 6 φίλτρα μεγέθους 5x5. Κάθε φίλτρο έχει 25 παραμέτρους (5x5 βάρη), μαζί με 1 παράμετρο μετατόπισης (bias), άρα συνολικά 26 παραμέτρους ανά φίλτρο. 6 φίλτρα συνολικά:  $6 * 26 = 156$  παραμέτρους, β) Συνελκτικό Επίπεδο C3: Εφαρμόζει 16 φίλτρα μεγέθους 5x5 στα 6 featuremaps του C1. Αυτό σημαίνει ότι κάθε φίλτρο πρέπει να συνδεθεί με τα 6 εισερχόμενα featuremaps, άρα κάθε φίλτρο έχει  $5x5x6 = 150$  παραμέτρους. Προσθέτοντας 1 bias, έχουμε 151 παραμέτρους ανά φίλτρο. 16 φίλτρα συνολικά:  $16 * 151 = 2,416$  παραμέτρους, γ) Πλήρως Συνδεδεμένο Επίπεδο C5: Αυτό το επίπεδο περιέχει 120 νευρώνες και είναι πλήρως συνδεδεμένο με τα 400 χαρακτηριστικά εισόδου από το προηγούμενο επίπεδο (16 featuremaps μεγέθους 5x5). Κάθε νευρώνας έχει 400 συνδέσεις (βάρη) και 1 bias, άρα 401 παραμέτρους ανά νευρώνα. 120 νευρώνες συνολικά:  $120 * 401 = 48,120$  παραμέτρους, δ) Πλήρως Συνδεδεμένο Επίπεδο F6: Έχει 84 νευρώνες και είναι πλήρως συνδεδεμένο με τους 120 νευρώνες του προηγούμενου επιπέδου. Κάθε νευρώνας έχει 120 συνδέσεις (βάρη) και 1 bias, άρα 121 παραμέτρους ανά νευρώνα. 84 νευρώνες συνολικά:  $84 * 121 = 10,164$  παραμέτρους, ε) Αυτό το επίπεδο περιλαμβάνει 10 νευρώνες (για τις 10 κατηγορίες του MNIST) και είναι πλήρως συνδεδεμένο με τους 84 νευρώνες του προηγούμενου επιπέδου. Κάθε νευρώνας έχει 84 συνδέσεις και 1 bias, άρα 85 παραμέτρους ανά νευρώνα. 10 νευρώνες συνολικά:  $10 * 85 = 850$  παραμέτρους. Επομένως, συνολικά

έχουμε: C1: 156 παραμέτρους, C3: 2,416 παραμέτρους, C5: 48,120 παραμέτρους, F6: 10,164 παραμέτρους, Output: 850 παραμέτρους. Σύνολο:  $156 + 2,416 + 48,120 + 10,164 + 850 = 61,706$  παραμέτρους. Το LeNet-5 είναι ένα αρκετά μικρό δίκτυο σε σύγκριση με σύγχρονες αρχιτεκτονικές, με συνολικά περίπου 61,706 παραμέτρους και επιτυγχάνει εξαιρετική ακρίβεια (περίπου 99% στο MNIST), αλλά η αποδοτικότητά του περιορίζεται σε πιο περίπλοκα σύνολα δεδομένων, όπως το CIFAR-10.

## Κεφάλαιο 4<sup>ο</sup> SNN (Spiking Neural Networks-SNNs)

### 4.1 Αρχιτεκτονική και Λειτουργία

Τα νευρωνικά δίκτυα αιχμών (SNN) είναι ένας τύπος τεχνητού νευρωνικού δικτύου που μιμείται τη συμπεριφορά των βιολογικών νευρώνων πλησιέστερα από τα παραδοσιακά τεχνητά νευρωνικά δίκτυα (ANN). Σε αντίθεση με τα συμβατικά ANN που βασίζονται σε λειτουργίες συνεχούς ενεργοποίησης, τα SNN χρησιμοποιούν αιχμές (διακριτά συμβάντα στον χρόνο) για τη μετάδοση πληροφοριών μεταξύ των νευρώνων. Αυτή η φύση που βασίζεται σε συμβάντα καθιστά τα SNN εγγενώς διαφορετικά στον τρόπο με τον οποίο επεξεργάζονται δεδομένα (Δεμερτζής, 2020).

#### Βασικά συστατικά στοιχεία των SNN:

- **Νευρώνες:** Στα SNN, οι νευρώνες ενσωματώνουν σήματα εισόδου έως ότου επιτευχθεί ένα συγκεκριμένο όριο. Μόλις ξεπεραστεί το όριο, ο νευρώνας «πυροδοτεί» μια αιχμή, η οποία στη συνέχεια μεταδίδεται στους συνδεδεμένους νευρώνες. Μετά την πυροδότηση, ο νευρώνας υφίσταται τυπικά μια ανθεκτική περίοδο κατά την οποία δεν μπορεί να πυροδοτηθεί ξανά.
- **Συνάψεις:** Είναι οι συνδέσεις μεταξύ των νευρώνων μέσω των οποίων μεταδίδονται οι αιχμές. Οι συνάψεις έχουν βάρη που καθορίζουν την ισχύ της σύνδεσης. Στα SNN, η συναπτική πλαστικότητα (η ικανότητα αλλαγής της ισχύος των συναπτικών συνδέσεων) είναι ζωτικής σημασίας, που συχνά διέπεται από μηχανισμούς όπως η πλαστικότητα που εξαρτάται από τον χρόνο αιχμής (STDP).
- **Δυναμική του χρόνου:** Ο χρόνος διαδραματίζει κρίσιμο ρόλο στα SNN. Ο ακριβής χρονισμός των αιχμών, καθώς και τα διαστήματα μεταξύ τους, μπορούν να μεταφέρουν πληροφορίες, σε αντίθεση με τα παραδοσιακά ANN, όπου οι πληροφορίες κωδικοποιούνται στο εύρος των ενεργοποιήσεων νευρώνων.

#### Μηχανισμός Λειτουργίας:

- **Κωδικοποίηση:** Οι πληροφορίες κωδικοποιούνται στον χρονισμό των αιχμών. Μπορούν να χρησιμοποιηθούν διαφορετικά σχήματα κωδικοποίησης, όπως κωδικοποίηση ρυθμού (συχνότητα αιχμής), χρονική κωδικοποίηση (ακριβής χρονισμός αιχμής) ή κωδικοποίηση πληθυσμού (μοτίβα αιχμών σε πολλούς νευρώνες).

- **Ενσωμάτωση:** Οι νευρώνες λαμβάνουν αιχμές εισόδου, οι οποίες συσσωρεύονται στο δυναμικό της μεμβράνης. Αυτή η ολοκλήρωση συνεχίζεται έως ότου το δυναμικό φτάσει στην τιμή κατωφλίου, προκαλώντας την αιχμή του νευρώνα.
- **Διάδοση:** Η αιχμή μεταδίδεται στους νευρώνες μέσω συνάψεων, επηρεάζοντας τα δυναμικά της μεμβράνης τους με βάση το συναπτικό βάρος.
- **Παράδειγμα πειράματος:** Μια κοινή πειραματική εγκατάσταση περιλαμβάνει τη χρήση μιας μηχανής ρευστής κατάστασης (LSM), ενός τύπου SNN, για την επεξεργασία χρονικών δεδομένων. Για παράδειγμα, τα LSM έχουν χρησιμοποιηθεί για την ταξινόμηση των εκφωνημένων ψηφίων κωδικοποιώντας ακουστικά σήματα ως σειρές αιχμών και μαθαίνοντας να αναγνωρίζουν τα χρονικά μοτίβα των αιχμών που αντιστοιχούν σε διαφορετικά ψηφία (Naga & Murphy, 2015).

### **Εφαρμογές:**

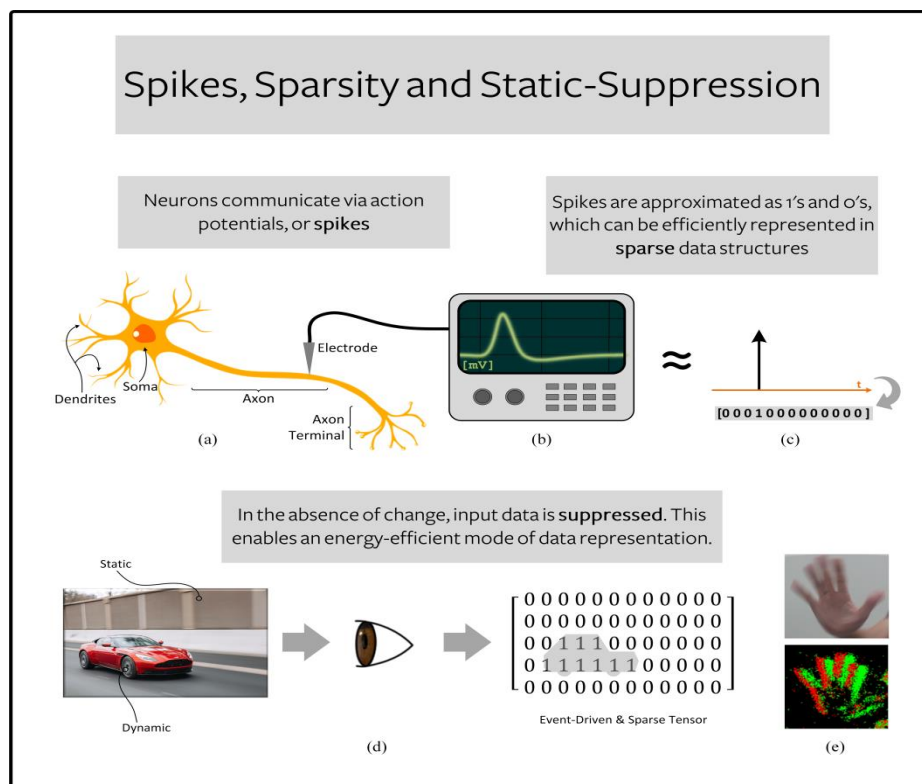
Τα SNN εφαρμόζονται ολοένα και περισσότερο σε διάφορες εργασίες υπολογιστικής όρασης, αξιοποιώντας τις μοναδικές τους ιδιότητες για την αντιμετώπιση συγκεκριμένων προκλήσεων στο πεδίο:

- **Αναγνώριση αντικειμένων:** Τα SNN μπορούν να χρησιμοποιηθούν για την αναγνώριση αντικειμένων σε εικόνες και ροές βίντεο, ιδιαίτερα σε καταστάσεις όπου η επεξεργασία σε πραγματικό χρόνο και η χαμηλή κατανάλωση ενέργειας είναι κρίσιμα στοιχεία. Η ικανότητά τους να χειρίζονται χωροχρονικά δεδομένα τα καθιστά κατάλληλα για την αναγνώριση αντικειμένων σε κίνηση.
- **Όραση βάσει συμβάντων:** Τα SNN υπερέχουν σε συστήματα όρασης που βασίζονται σε συμβάντα, όπως οι νευρομορφικές κάμερες που ανιχνεύουν αλλαγές στο περιβάλλον τη στιγμή της εμφάνισης αντί να καταγράφουν εικόνες καρέ-καρέ. Αυτό είναι ιδιαίτερα χρήσιμο σε εφαρμογές όπως σε αυτόνομα οχήματα και σε ρομποτικά συστήματα, όπου απαιτούνται γρήγοροι χρόνοι αντίδρασης.
- **Αναγνώριση χειρονομιών:** Τα SNN μπορούν να επεξεργάζονται χρονικά μοτίβα σε οπτικά δεδομένα, καθιστώντας τα ιδανικά για την αναγνώριση χειρονομιών με βάση την κίνηση των χεριών ή των μερών του σώματος με την πάροδο του χρόνου.
- **Επιτήρηση:** Στα συστήματα ασφαλείας, τα SNN μπορούν να χρησιμοποιηθούν για την συνεχή επιτήρηση περιβαλλόντων, τον εντοπισμό και την παρακολούθηση

κινούμενων αντικειμένων ή ύποπτων δραστηριοτήτων με υψηλή ενεργειακή απόδοση (Liu et al., 2020).

- **Παράδειγμα πειράματος:** Μια μελέτη κατέδειξε τη χρήση των SNN σε ένα σύστημα επιτήρησης σε πραγματικό χρόνο, όπου το δίκτυο ήταν σε θέση να ανιχνεύει και να ταξινομεί αποτελεσματικά τις δραστηριότητες σε μια παρακολουθούμενη περιοχή χρησιμοποιώντας δεδομένα από μια κάμερα βάσει συμβάντων, ξεπερνώντας τα παραδοσιακά συστήματα όρασης τόσο σε ταχύτητα όσο και σε ενέργεια. κατανάλωση.

Το SNN Torch επικεντρώνεται στη χρήση Spiking Neural Networks (SNNs), τα οποία προσομοιώνουν τη λειτουργία του εγκεφάλου, χρησιμοποιώντας ηλεκτρικούς παλμούς (spikes) για την επεξεργασία των δεδομένων. Αυτή η προσέγγιση μιμείται τη βιολογική λειτουργία των νευρώνων και παρουσιάζει πολλά πλεονεκτήματα σε σχέση με τα παραδοσιακά τεχνητά νευρωνικά δίκτυα, όπως αποδοτικότητα σε ενέργεια και ταχύτητα επεξεργασίας.

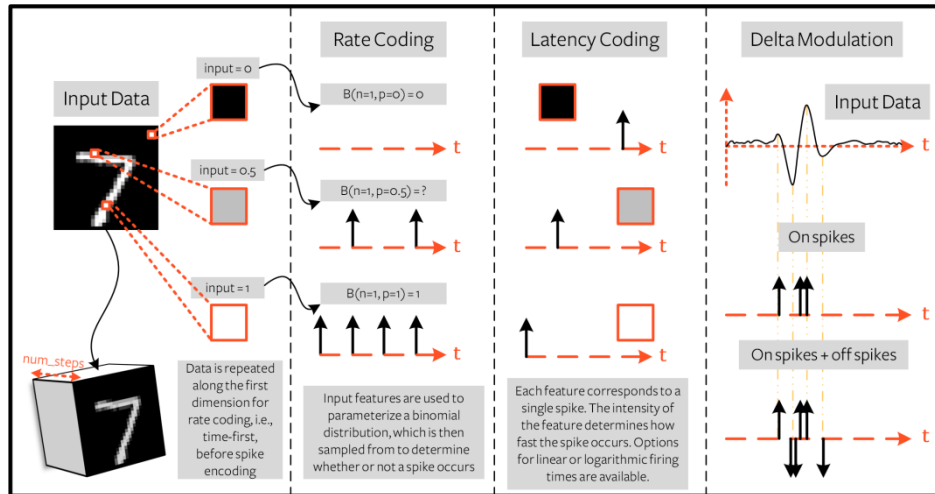


Σχήμα 4-1

Πηγή: Jason K. Eshraghian, 2023



Κατά τη χρήση της βιβλιοθήκης SNNtorch αρχικά, παρουσιάζεται η διαδικασία εγκατάστασης της βιβλιοθήκης και προετοιμασίας των δεδομένων, με τη χρήση του γνωστού MNIST dataset. Στη συνέχεια, εξηγούνται τρεις διαφορετικές μέθοδοι μετατροπής των δεδομένων σε spikes.



Σχήμα 4-2: Τρεις διαφορετικές μέθοδοι μετατροπής των δεδομένων σε spikes

Πηγή: Jason K. Eshraghian, 2023

1. Rate Coding: Κωδικοποίηση της συχνότητας με την οποία εμφανίζονται spikes, όπου κάθε τιμή του δεδομένου χρησιμοποιείται ως πιθανότητα εμφάνισης ενός spike.
2. Latency Coding: Κωδικοποίηση βασισμένη στον χρόνο καθυστέρησης ενός spike, όπου φωτεινά pixel στέλνουν spikes νωρίτερα από τα πιο σκοτεινά.
3. Delta Modulation: Μια μέθοδος που κωδικοποιεί μόνο τις μεταβολές στο σήμα, με βάση τις διαφορές των τιμών των δεδομένων.

Με παρόμοιο τρόπο, το spikegen.rate μπορεί να χρησιμοποιηθεί για τη δημιουργία ενός δείγματος δεδομένων με κωδικοποίηση ταχύτητας. Καθώς κάθε δείγμα του MNIST είναι απλώς μια εικόνα, μπορούμε να χρησιμοποιήσουμε το num\_steps για να το επαναλάβουμε σε βάθος χρόνου.

```
from sntorch import spikegen

# Iterate through minibatches

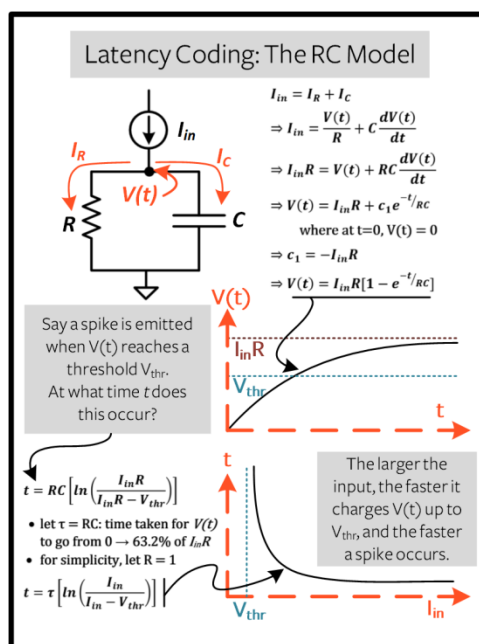
data = iter(train_loader)

data_it, targets_it = next(data)
```

## # Spiking Data

```
spike_data = spikegen.rate(data_it, num_steps=num_steps)
```

Η κωδικοποίηση καθυστέρησης (latency coding) προσπαθεί να αποτυπώσει πληροφορίες μέσα από τον χρόνο πυροδότησης ενός νευρώνα, δηλαδή το πότε ακριβώς παράγει ένα spike. Σε αντίθεση με άλλες μεθόδους όπως η κωδικοποίηση ρυθμού (rate coding), όπου μετράμε πόσο συχνά παράγονται spikes, εδώ μας ενδιαφέρει πόσο νωρίς ή αργά θα παραχθεί το spike. Πιο συγκεκριμένα: α) Μεγάλη τιμή εισόδου (όπως ένα φωτεινό pixel) σημαίνει ότι θα παραχθεί γρήγορα ένα spike, β) Μικρή τιμή εισόδου (όπως ένα σκοτεινό pixel) σημαίνει ότι το spike θα παραχθεί με καθυστέρηση.



Σχήμα 4-3: Κωδικοποίηση καθυστέρησης (latency coding)

Πηγή: Jason K. Eshraghian

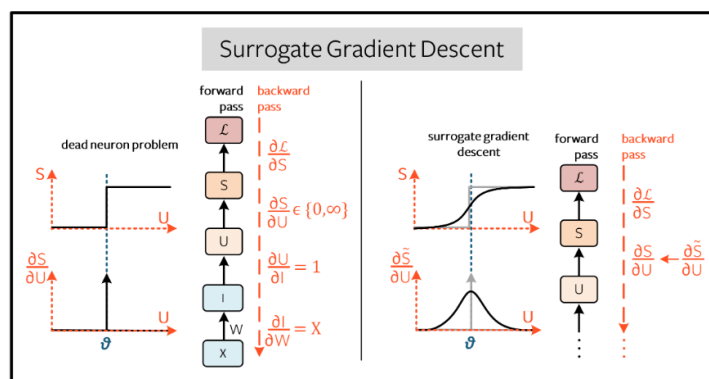
(2023)

Η διαδικασία αυτή βασίζεται στην ιδέα ότι ο χρόνος που απαιτείται για να δημιουργηθεί ένα spike εξαρτάται από το μέγεθος της εισόδου. Για να το καταλάβουμε καλύτερα, σκέψου έναν πυκνωτή σε ένα κύκλωμα. Όσο μεγαλύτερο είναι το ρεύμα που περνάει από τον πυκνωτή, τόσο πιο γρήγορα φορτίζεται και, όταν φτάσει σε ένα συγκεκριμένο επίπεδο (που ονομάζεται τάση ενεργοποίησης), παράγει το spike. Αν το ρεύμα είναι μικρότερο, τότε θα χρειαστεί περισσότερος χρόνος για να φτάσει αυτό το επίπεδο, με

αποτέλεσμα να καθυστερήσει η παραγωγή του spike. Πιο συγκεκριμένα ένα μεγάλο σήμα (φωτεινό pixel) θα προκαλέσει ένα γρήγορο spike ενώ ένα μικρό σήμα (σκοτεινό pixel) θα προκαλέσει ένα καθυστερημένο spike. Αυτή η λογική επιτρέπει να αποθηκεύουμε πληροφορίες με βάση το πότε παράγονται τα spikes, αντί για το πόσο συχνά, και μπορεί να μειώσει την κατανάλωση ενέργειας γιατί κάθε νευρώνας πυροδοτείται μόνο μία φορά σε κάθε χρονική περίοδο (Liu et al., 2020).

Το SNNTool είναι ένα ισχυρό εργαλείο για την εκπαίδευση Spiking Neural Networks και προσφέρει ευέλικτες μεθόδους κωδικοποίησης δεδομένων. Μέσω του tutorial, οι χρήστες έχουν την ευκαιρία να κατανοήσουν καλύτερα πώς μπορούν να μετατρέψουν δεδομένα σε μορφή spikes και να τα χρησιμοποιήσουν για την εκπαίδευση νευρωνικών δικτύων. Οι τρεις βασικές τεχνικές που παρουσιάστηκαν είναι το ratecoding, το latency coding και το delta modulation, κάθε μία από τις οποίες προσφέρει διαφορετικά πλεονεκτήματα ανάλογα με τη φύση των δεδομένων (Eshraghian et al., 2023).

**Surrogate Gradient:** Καθώς τα εργαλεία της PyTorch αδυνατούν να υπολογίσουν την αναλυτική παράγωγο του γραφήματος του νευρώνα αιχμής, έρχεται το Surrogate Gradient να δώσει την λύση με μία surrogate συνάρτηση που είναι παραγωγίμη και προσεγγίζει τη συμπεριφορά της βηματικής συνάρτησης. Κάποιες από αυτές τις συναρτήσεις είναι οι sigmoid, fast sigmoid, ATan. Επομένως, είναι μια απαραίτητη τεχνική για την εκπαίδευση των SNN καθώς προσφέρει την λύση στην δυσκολία που προκύπτει λόγω της μη παραγωγίμης φύσης της βηματικής συνάρτησης. Στο σχήμα που ακολουθεί πώς με αυτή την τεχνική μπορούμε να κάνουμε backpropagation σε δίκτυα SNN, παρόλο της μη διαφορίσιμης παράγωγο. (Jason K. Eshraghian et al., 2023)



Σχήμα 4-4: Το πρόβλημα των νεκρών νευρώνων και η λύση (Surrogate Gradient Descent)

Πηγή: Jason K. Eshraghian (2023)

## 4.2 Πλεονεκτήματα και μειονεκτήματα

### Πλεονεκτήματα των SNN:

- **Βιολογική αξιοπιστία:** Τα SNN μιμούνται περισσότερο τη λειτουργία του ανθρώπινου εγκεφάλου, προσφέροντας πληροφορίες για την κατανόηση των βιολογικών νευρωνικών διεργασιών.
- **Ενεργειακή απόδοση:** Επειδή οι νευρώνες στα SNN πυροδοτούν μόνο όταν είναι απαραίτητο (αραιή πυροδότηση), μπορούν να είναι πιο ενεργειακά αποδοτικά από τα παραδοσιακά ANN, ειδικά όταν εφαρμόζονται σε νευρομορφικό υλικό.
- **Χρονική Δυναμική:** Τα SNN μπορούν να επεξεργάζονται και να μαθαίνουν από τα χρονικά δεδομένα πιο αποτελεσματικά λόγω της ικανότητάς τους να κωδικοποιούν πληροφορίες για τον χρονισμό των αιχμών.
- **Επεξεργασία βάσει συμβάντων:** Τα SNN είναι κατάλληλα για την επεξεργασία δεδομένων που βασίζονται σε συμβάντα, όπως δεδομένα από αισθητήρες στη ρομποτική ή νευρομορφικά συστήματα όρασης.

### Μειονεκτήματα των SNN:

- **Πολυπλοκότητα εκπαίδευσης:** Η εκπαίδευση των SNN είναι πιο δύσκολη λόγω της διακριτής και χρονικής φύσης των αιχμών. Η οπισθοδιάδοση, που χρησιμοποιείται συνήθως στα ANN, δεν είναι άμεσα εφαρμόσιμη.
- **Περιορισμένα εργαλεία και πλαίσια:** Υπάρχουν λιγότερα καθιερωμένα εργαλεία και πλαίσια για την ανάπτυξη SNN σε σύγκριση με τα παραδοσιακά ANN, αν και αυτός είναι ένας τομέας συνεχούς έρευνας.
- **Υπολογιστική πολυπλοκότητα:** Η προσομοίωση των SNN μπορεί να είναι υπολογιστικώς εντατική, ειδικά κατά τη μοντελοποίηση μεγάλων δικτύων με ρεαλιστική δυναμική νευρώνων και συνάψεων (Mijwel, 2021).
- **Παράδειγμα πειράματος:** Μια μελέτη συνέκρινε την κατανάλωση ενέργειας ενός

SNN έναντι ενός παραδοσιακού ANN σε μια απλή εργασία ταξινόμησης εικόνων. Το SNN, που υλοποιήθηκε σε ένα νευρομορφικό τσιπ, καταναλώνει σημαντικά λιγότερη ενέργεια διατηρώντας συγκρίσιμη ακρίβεια, υπογραμμίζοντας τις δυνατότητες για ενεργειακά αποδοτικούς υπολογιστές.

### 4.3 Μοντέλα SNNs

Έχουν αναπτυχθεί πολλά μοντέλα ώστε να αντιπροσωπεύσουν τη συμπεριφορά αιχμών των νευρώνων σε SNN, το καθένα με διαφορετικά επίπεδα πολυπλοκότητας και βιολογικού ρεαλισμού (Liu & Marin, 2021):

- **Μοντέλο Leaky Integrate-and-Fire (LIF):** Ένα από τα απλούστερα και πιο συχνά χρησιμοποιούμενα μοντέλα, ο νευρώνας LIF ενσωματώνει τις εισερχόμενες αιχμές και το δυναμικό διαρροών με την πάροδο του χρόνου. Όταν το δυναμικό φτάσει σε μια τιμή κατωφλίου, ο νευρώνας πυροδοτεί μια αιχμή και επανέρχεται.
- **Μοντέλο Izhikevich:** Αυτό το μοντέλο εξισορροπεί τον βιολογικό ρεαλισμό με την υπολογιστική αποτελεσματικότητα. Μπορεί να αναπαράγει ένα ευρύ φάσμα μοτίβων πυροδότησης νευρώνων που παρατηρούνται στον εγκέφαλο προσαρμόζοντας μερικές παραμέτρους.
- **Μοντέλο Hodgkin-Huxley:** Αυτό είναι ένα εξαιρετικά λεπτομερές και βιολογικά ακριβές μοντέλο της δυναμικής των νευρώνων. Περιγράφει τον τρόπο που τα δυναμικά δράσης στους νευρώνες ξεκινούν και διαδίδονται μέσω των διαύλων ιόντων της κυτταρικής μεμβράνης. Λόγω της πολυπλοκότητάς του, χρησιμοποιείται συνήθως σε προσομοιώσεις όπου η βιολογική ακρίβεια είναι πρωταρχικής σημασίας.
- **Μοντέλο απόκρισης Spike (SRM):** Αυτό το μοντέλο γενικεύει το μοντέλο LIF και εστιάζει στην απόκριση ενός νευρώνα στις εισερχόμενες αιχμές, λαμβάνοντας υπόψη τόσο τις διεγερτικές όσο και τις ανασταλτικές επιρροές (Liu & Marin, 2021).
- **Παράδειγμα πειράματος:** Σε μια υπολογιστική μελέτη νευροεπιστήμης, οι ερευνητές χρησιμοποίησαν το μοντέλο Izhikevich για να προσομοιώσουν ένα δίκτυο νευρώνων που θα μπορούσε να αναπαράγει τα μοτίβα πυροδότησης που παρατηρούνται στους φλοιικούς νευρώνες κατά τη διάρκεια εργασιών αισθητηριακής επεξεργασίας. Η μελέτη κατέδειξε τον τρόπο που διαφορετικά μοντέλα νευρώνων θα μπορούσαν να

επηρεάσουν την ικανότητα του δικτύου να επεξεργάζεται πολύπλοκα ερεθίσματα.

#### 4.4 Πολυπλοκότητα

Η πολυπλοκότητα των SNN μπορεί να αναλυθεί με όρους υπολογιστικής πολυπλοκότητας και βιολογικού ρεαλισμού (Sak, 2014):

- **Υπολογιστική πολυπλοκότητα:** Η προσομοίωση SNN μπορεί να είναι υπολογιστικώς ακριβή λόγω της ανάγκης παρακολούθησης και ενημέρωσης της κατάστασης κάθε νευρώνα και συνάψεως ως απόκριση στις εισερχόμενες αιχμές. Η επιλογή του μοντέλου νευρώνων επηρεάζει σημαντικά το υπολογιστικό φορτίο. Για παράδειγμα, το μοντέλο Hodgkin-Huxley είναι πολύ πιο απαιτητικό υπολογιστικά από το μοντέλο LIF.
- **Βιολογικός ρεαλισμός έναντι απλότητας:** Υπάρχει μια αντιστάθμιση μεταξύ της βιολογικής ακρίβειας των μοντέλων νευρώνων και των υπολογιστικών πόρων που απαιτούνται. Πιο λεπτομερή μοντέλα όπως το Hodgkin-Huxley προσφέρουν μεγαλύτερη βιολογική πιστότητα, αλλά είναι λιγότερο εφικτά για προσομοιώσεις μεγάλης κλίμακας. Πιο απλά μοντέλα όπως το LIF ή το Izhikevich παρέχουν μια καλή ισορροπία για προσομοιώσεις μεγάλων δικτύων.
- **Παράδειγμα πειράματος:** Ένα πείραμα περιελάμβανε προσομοίωση ενός δικτύου 100.000 νευρώνων χρησιμοποιώντας αμφότερα τα μοντέλα LIF και Hodgkin-Huxley για την εκτέλεση μιας εργασίας οπτικής αναγνώρισης. Η προσομοίωση Hodgkin-Huxley απαιτούσε σημαντικά περισσότερους υπολογιστικούς πόρους και χρόνο, αλλά πρόσφερε πληροφορίες για τον τρόπο που η συγκεκριμένη δυναμική των διαύλων ιόντων επηρέασε τη συμπεριφορά του δικτύου.

#### 4.5 Μοντελοποίηση Νευρώνων

Η μοντελοποίηση νευρώνων στα SNN περιλαμβάνει τον καθορισμό του τρόπου με τον οποίο οι νευρώνες επεξεργάζονται αιχμές εισόδου και παράγουν αιχμές εξόδου. Η επιλογή του μοντέλου επηρεάζει την ικανότητα του δικτύου να αναπαράγει ορισμένους τύπους νευρωνικής συμπεριφοράς (Sak, 2014):

- **Δυναμική του δυναμικού μεμβράνης:** Περιγράφει τον τρόπο που το δυναμικό της

μεμβράνης του νευρώνα εξελίσσεται με την πάροδο του χρόνου ως απόκριση στις εισερχόμενες αιχμές. Το μοντέλο LIF, για παράδειγμα, το αντιπροσωπεύει ως μια απλή διαφορική εξίσωση με όρο διαρροής.

- **Μηχανισμός κατωφλίου:** Καθορίζει το πότε πυροδοτείται ένας νευρώνας. Σε πολλά μοντέλα, ένας νευρώνας πυροδοτείται όταν το δυναμικό της μεμβράνης του διασχίζει μια σταθερή τιμή κατωφλίου. Ορισμένα μοντέλα επιτρέπουν προσαρμοστικά όρια που αλλάζουν με βάση την πρόσφατη δραστηριότητα.
- **Συμπεριφορά μετά την αιχμή:** Μετά την πυροδότηση, ένας νευρώνας μπορεί να εισέλθει σε μια ανθεκτική περίοδο όπου δεν μπορεί να πυροδοτηθεί ξανά. Ορισμένα μοντέλα περιλαμβάνουν επίσης δυναμική μετά την αιχμή, όπως η μετα-υπερπόλωση, η οποία μειώνει προσωρινά το δυναμικό της μεμβράνης κάτω από το επίπεδο ηρεμίας.
- **Παράδειγμα πειράματος:** Μια ομάδα ερευνητών χρησιμοποίησε το μοντέλο LIF για να προσομοιώσει ένα μικρό κύκλωμα φλοιού που εμπλέκεται στη λήψη αποφάσεων. Προσαρμόζοντας τις παραμέτρους διαρροής και τιμής κατωφλίου, μπόρεσαν να αναπαράγουν την παρατηρούμενη συμπεριφορά λήψης αποφάσεων στα ζώα, αποδεικνύοντας τη σημασία της μοντελοποίησης νευρώνων στην καταγραφή νευρικών φαινομένων του πραγματικού κόσμου.

#### 4.6 Εφαρμογές των SNNs

Τα SNN έχουν πολλές εφαρμογές σε διάφορους τομείς, χάρη στην ικανότητά τους να επεξεργάζονται αποτελεσματικά χρονικά και χωροχρονικά δεδομένα:

- **Νευρομορφική Μηχανική:** Τα SNN είναι ένα βασικό συστατικό σε νευρομορφικά τσιπ που έχουν σχεδιαστεί για να μιμούνται την αρχιτεκτονική και τη λειτουργία του εγκεφάλου, επιτρέποντας τους ενεργειακά αποδοτικούς υπολογιστές. Αυτά τα τσιπ χρησιμοποιούνται σε συσκευές χαμηλής κατανάλωσης για εργασίες όπως η αναγνώριση εικόνας και η επεξεργασία αισθητηριακών δεδομένων.
- **Ρομποτική:** Τα SNN χρησιμοποιούνται στη ρομποτική για τη λήψη αποφάσεων σε πραγματικό χρόνο και την αισθητηριακή επεξεργασία. Για παράδειγμα, ένας ρομποτικός βραχίονας μπορεί να χρησιμοποιήσει ένα SNN για να ερμηνεύει τα οπτικά

δεδομένα και να προσαρμόζει τις κινήσεις του σε πραγματικό χρόνο.

- **Διεπαφές εγκεφάλου-μηχανής (ΔΜΣ):** Τα SNN μπορούν να χρησιμοποιηθούν για την αποκωδικοποίηση νευρικών σημάτων από τον εγκέφαλο, επιτρέποντας τον άμεσο έλεγχο των προσθετικών άκρων ή των υπολογιστών ερμηνεύοντας τον χρονοισμό των αιχμών από νευρωνικές εγγραφές.
- **Γνωστική Υπολογιστική:** Τα SNN διερευνούνται για γνωστικές εργασίες όπως η αναγνώριση προτύπων, η μάθηση και ο σχηματισμός μνήμης, προσφέροντας μια προσέγγιση που μοιάζει περισσότερο με τον εγκέφαλο σε σύγκριση με τα παραδοσιακά ANN.
- **Ιατρική διάγνωση:** Τα SNN μπορούν να αναλύσουν δεδομένα χρονοσειρών, όπως σήματα ΗΕΓ, για να ανιχνεύσουν ανωμαλίες όπως επιληπτικές κρίσεις ή άλλες νευρολογικές καταστάσεις (Çelik, 2018)
- **Παράδειγμα πειράματος:** Σε μια εφαρμογή για τη νευρομορφική όραση, αναπτύχθηκε ένα σύστημα βασισμένο σε SNN για την ταξινόμηση αντικειμένων σε ένα δυναμικό οπτικό περιβάλλον. Το σύστημα επεξεργάστηκε ασύγχρονα οπτικά δεδομένα (αιχμές) από έναν δυναμικό αισθητήρα όρασης και πέτυχε υψηλή ακρίβεια ενώ κατανάλωνε ένα κλάσμα της ενέργειας σε σύγκριση με τα συμβατικά συστήματα επεξεργασίας όρασης.

#### 4.7 Επεξεργασία βάσει συμβάντων: SpiNNaker

Η παρούσα ενότητα αναφέρεται σε δίκτυα οπτικής επεξεργασίας που βασίζονται σε γεγονότα, τα οποία είναι κατάλληλα για να λειτουργούν (και έχουν λειτουργήσει) σε μια νευρομορφική πλατφόρμα. Ένα παράδειγμα ενός μεγάλου νευρομορφικού συστήματος είναι το SpiNNaker (Spiking Neural Network Architecture). Το SpiNNaker βασίζεται σε ένα προσαρμοσμένο chip πολλαπλών πυρήνων, με τα μοντέλα νευρώνων και συνάψεων να υλοποιούνται μέσω λογισμικού, σε αντίθεση με άλλα νευρομορφικά συστήματα όπου αυτά τα μοντέλα υλοποιούνται χρησιμοποιώντας αναλογικά ή ψηφιακά κυκλώματα (Izhikevich, 2006).

Η προσέγγιση με το λογισμικό έχει τα δικά της πλεονεκτήματα και μειονεκτήματα: το σημαντικότερο πλεονέκτημα είναι η ευελιξία, καθώς μπορούν εύκολα να προστεθούν νέα



μοντέλα και κανόνες μάθησης στις βιβλιοθήκες του λογισμικού. Ωστόσο, το μειονέκτημα αυτής της προσέγγισης είναι ότι το λογισμικό συνεπάγεται ένα ενεργειακό κόστος περίπου μιας τάξης μεγέθους. Αυτό κάνει το SpiNNaker κατάλληλο για χρήση ως πλατφόρμα έρευνας και ανάπτυξης, ενώ οι αλγόριθμοι που βασίζονται σε υλικό είναι πιο αποδοτικοί για πλατφόρμες παράδοσης εφαρμογών (Furber et al., 2012).

Η νευρομορφική πλευρά του SpiNNaker φαίνεται στον τρόπο με τον οποίο οι επεξεργαστές είναι συνδεδεμένοι. Τα βιολογικά νευρωνικά δίκτυα παρουσιάζουν πολύ υψηλούς βαθμούς συνδεσιμότητας, με τους νευρώνες να έχουν συχνά χιλιάδες εισόδους, και σε κάποιες περιπτώσεις ακόμη και ένα τέταρτο του εκατομμυρίου. Εδώ το SpiNNaker δανείζεται την τεχνική της νευρομορφικής αναπαράστασης συμβάντων διευθύνσεων (Address Event Representation - AER), όπου κάθε νευρώνας λαμβάνει μια μοναδική αριθμητική «διεύθυνση», αλλά αντί να χρησιμοποιεί το AER σε ένα σύστημα αναμετάδοσης, το χαρτογραφεί σε ένα σύστημα μεταγωγής πακέτων, βελτιώνοντας έτσι την επεκτασιμότητα του συστήματος (Brown et al., 2017).

Το υλικό του SpiNNaker έχει παραδοθεί σε διάφορες κλίμακες, από τη μικρή πλακέτα 4 κόμβων (72 πυρήνων) που μπορεί να μοντελοποιήσει δίκτυα ισοδύναμα με τον εγκέφαλο ενός σαλιγκαριού, μέχρι την πλακέτα 48 κόμβων (864 πυρήνων) που μπορεί να μοντελοποιήσει μεγαλύτερα δίκτυα (Sivilotti, 1991).

Η κλιμάκωση του SpiNNaker, η οποία μπορεί να φτάσει από επίπεδο μικρού εντόμου έως και σε μια μηχανή με 500.000 πυρήνες, που αποτελεί τη βάση της πλατφόρμας SpiNNaker, η οποία διατίθεται ανοικτά υπό την αιγίδα του Ευρωπαϊκού Προγράμματος Ανθρωπίνου Εγκεφάλου (Human Brain Project) (Βλέπε Σχήμα 4-4).



***Σχήμα 4-5: 500 000-core SpiNNaker Human Brain Project platform***

***Πηγή: Hopkins et al., 2018***

Κάθε πυρήνας επεξεργαστή μπορεί να χρησιμοποιηθεί για να μοντελοποιήσει μερικές εκατοντάδες νευρώνες που εκπέμπουν σήματα (spiking neurons) και περίπου ένα εκατομμύριο συνάψεις που σχηματίζουν τις εισόδους σε αυτούς τους νευρώνες (Furber et al., 2012). Το SpiNNaker διαθέτει λογισμικό υποστήριξης που χαρτογραφεί ένα νευρωνικό δίκτυο που εκπέμπει σήματα, γραμμένο σε PyNN, πάνω στη μηχανή (Βλέπε Εικόνα 4-5).

```
1 input_list = ConnectionList(input_kernel, ...)
2 lateral_list ... elConnectionList(lateral_kernel, ...)
3
4 evs = EVSObject(...)
5 bipolar_cells = pynn.Population(...)
6 inter_cells = pynn.Population(...)
7 ganglion_cells = pynn.Population(...)
8
9 pynn.Projection(evs, bipolar_cells, pynn.FromListConnector(input_list),
10                 receptor_type='excitatory')
11 pynn.Projection(bipolar_cells, inter_cells,
12                 pynn.OneToOneConnector(), pynn.StaticSynapse(...),
13                 receptor_type='excitatory')
14 pynn.Projection(bipolar_cells, ganglion_cells,
15                 pynn.OneToOneConnector(), pynn.StaticSynapse(...),
16                 receptor_type='excitatory')
17 pynn.Projection(inter_cells, ganglion_cells,
18                 pynn.FromListConnector(lateral_list),
19                 receptor_type='inhibitory')
```

*Σχήμα 4-6: Αναπαράσταση εικόνας πολλαπλών κλιμάκων Κώδικας PyNN*

*Πηγή: Hopkins et al., 2018*

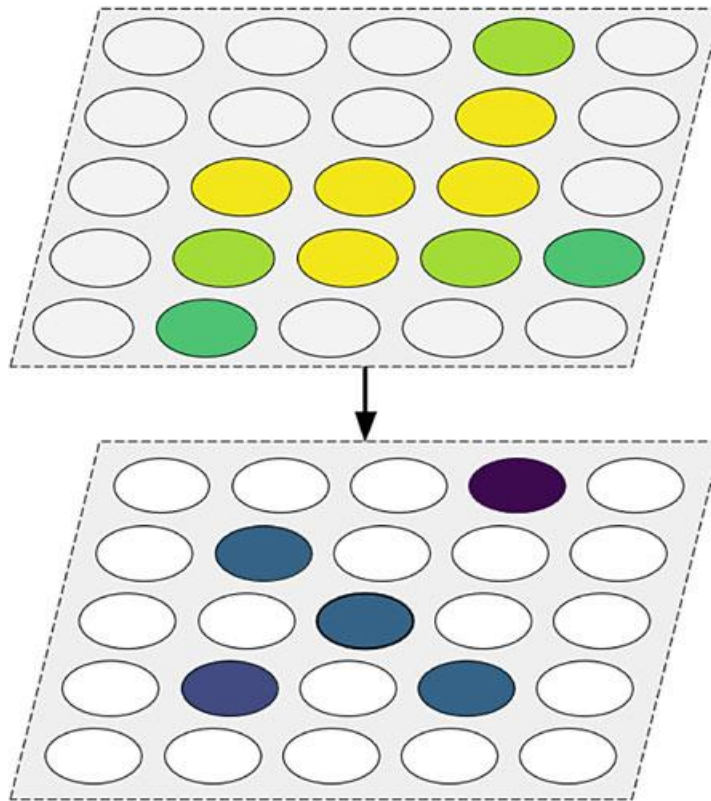
Μια απλοποιημένη περιγραφή του PyNN για το πολυκλιμακικό δίκτυο επεξεργασίας εικόνων που περιγράφηκε προηγουμένως παρουσιάζεται για να δείξει το στυλ της περιγραφής.

#### 4.8 Δομική πλαστικότητα για ταξινόμηση

Με μια ροή οπτικών δεδομένων βασισμένη σε γεγονότα, γίνεται προεπεξεργασία που βασίζεται σε ένα μοντέλο αμφιβληστροειδούς, και μια κατάλληλη νευρομορφική πλατφόρμα όπως το SpiNNaker. Επίσης δίνετε να γίνει επιπλέον επεξεργασία για να επιτευχθούν αποτελέσματα όπως η αναγνώριση και η ταξινόμηση αντικειμένων. Στη συνέχεια θα γίνει αναφορά σε ευρύτερα μέσα που προάγουν τη ταξινόμηση βάση των απαιτήσεων που ανάγονται στη συγκεκριμένη διαδικασία.

#### 4.8.1 Τοπογραφικός χάρτης

Στην παρούσα ενότητα γίνεται αρχικά αναφορά στη χρήση των τοπογραφικών χαρτών στον εγκέφαλο. Οι συγκεκριμένοι διατηρούν τις δισδιάστατες τοπολογικές σχέσεις στις προβολές από μια περιοχή του εγκεφάλου σε μια άλλη. Αυτοί οι τοπογραφικοί χάρτες αποτελούνται από στρώματα νευρώνων των οποίων η αντίδραση σε εισερχόμενα ερεθίσματα αλλάζει ανάλογα με την περιοχή. Ένα από τα κύρια χαρακτηριστικά αυτής της οργάνωσης είναι η διατήρηση της δραστηριότητας των γειτονικών νευρώνων από το αρχικό στρώμα στο στρώμα-στόχο, κάτι που προσφέρει πλεονεκτήματα όσον αφορά τη συνδεσιμότητα και την επεξεργασία της πληροφορίας (Βλέπε Σχήμα 4-6) (King, 2004).



**Σχήμα 4-7:** Τοπογραφικοί χάρτες που υπάρχουν στον εγκέφαλο και εξηγεί πώς οι νευρώνες συνδέονται μεταξύ τους.

*Πηγή: Hopkins et al., 2018*

Το Σχήμα 4-6 αναφέρεται στους τοπογραφικούς χάρτες που υπάρχουν στον εγκέφαλο και εξηγεί πώς οι νευρώνες συνδέονται μεταξύ τους. Ο νευρώνας (2) στο τοποθετημένο στρώμα έχει ένα δεκτικό πεδίο που σχηματίζεται από συνδέσεις που προέρχονται από το πηγαίο στρώμα (feed-forward) καθώς και από συνδέσεις που υπάρχουν εντός του

τοποθετημένου στρώματος (πλαγίως). Οι συνδέσεις αυτές είναι κεντραρισμένες γύρω από τον πιο κοντινό γεωμετρικά νευρώνα, δηλαδή τον νευρώνα (1) στην περίπτωση των συνδέσεων που προέρχονται από το πηγαίο στρώμα. Οι συνδέσεις από πιο απομακρυσμένους νευρώνες είναι πιθανό να είναι πιο αδύναμες, γεγονός που υποδεικνύεται με πιο σκούρο χρώμα. Αυτή η οργάνωση των συνδέσεων επιτρέπει στους νευρώνες να επεξεργάζονται πληροφορίες με βάση τη γειτνίαση και τη σχετική θέση των άλλων νευρώνων, διευκολύνοντας έτσι την επεξεργασία των οπτικών ή άλλων αισθητηριακών δεδομένων.

Η χρήση τοπογραφικών χαρτών επιτρέπει βελτιστοποίηση της σύνδεσης μεταξύ των νευρώνων, καθώς οι νευρώνες τείνουν να έχουν περιορισμένα δεκτικά πεδία και ενδιαφέρονται για χωρικά συγκεντρωμένες περιοχές. Για παράδειγμα, οι νευρώνες που είναι επιλεκτικοί ως προς τον προσανατολισμό, όπως αυτοί που βρίσκονται στον πρωτογενή οπτικό φλοιό, λαμβάνουν πληροφορίες από μικρές περιοχές του συνολικού οπτικού πεδίου, εξασφαλίζοντας ότι συνδέονται μόνο με τους άμεσους γείτονές τους και αλληλεπιδρούν ελάχιστα με πιο απομακρυσμένους νευρώνες (King, 2004).

Επιπλέον, όταν οι νευρώνες σχηματίζουν πολλαπλούς ευθυγραμμισμένους χάρτες που λαμβάνουν πληροφορίες από διαφορετικές αισθητηριακές πηγές, παρουσιάζουν διευκόλυνση πολλαπλών αισθητηρίων. Η απόκρισή τους είναι υπεργραμμική όταν λαμβάνουν ταυτόχρονα ερεθίσματα από την ίδια περιοχή του χώρου από διαφορετικές αισθητηριακές πηγές. Αυτό παρατηρείται στον ανώτερο δίδυμο του εγκεφάλου, μια δομή που ενσωματώνει σήματα από πολλές αισθήσεις και κατευθύνει προσαρμοστικές κινητικές αποκρίσεις (Thivierge & Marcus, 2007).

Οι τοπογραφικές προβολές είναι διαδεδομένες στον φλοιό των θηλαστικών, και η ανάπτυξή τους έχει μελετηθεί μέσω προσομοιώσεων, τόσο με όσο και χωρίς νευρώνες που εκπέμπουν σήματα (spiking neurons), συμπεριλαμβανομένης της συνοπτικής πλαστικότητας και της επανασύνδεσης συνάψεων. Ένα τέτοιο μοντέλο έχει δημιουργηθεί και στο σύστημα SpiNNaker, με στόχο την ανάπτυξη μιας αρχιτεκτονικής ικανής να ταξινομεί χειρόγραφους αριθμούς μέσω εποπτευόμενης μάθησης (Kohonen, 1982).

Το προτεινόμενο μοντέλο περιλαμβάνει τη συνεργασία δύο τύπων μηχανισμών: ανεξάρτητους από τη δραστηριότητα και εξαρτώμενους από τη δραστηριότητα (Von der Malsburg, 1973). Οι ανεξάρτητοι μηχανισμοί αντιπροσωπεύονται από τον κανόνα σχηματισμού συνάψεων, ο οποίος βασίζεται στην απόσταση μεταξύ πιθανών συνεργαζόμενων

νευρώνων προκειμένου να δημιουργηθεί μια νέα σύναψη οι νευρώνες που είναι χωρικά συγκεντρωμένοι τείνουν να σχηματίζουν περισσότερες συνδέσεις σε σύγκριση με εκείνους που είναι χωρικά απομακρυσμένοι (Song & Abbott, 2001).

Οι εξαρτώμενοι μηχανισμοί αποτελούνται από δύο υπομηχανισμούς: τη Συναπτική Πλαστικότητα με Εξαρτώμενη από το Χρόνο (STDP) και έναν κανόνα αφαίρεσης για τον μηχανισμό επανασύνδεσης συνάψεων. Η STDP, χρησιμοποιώντας τοπικές πληροφορίες εκτόξευσης, τροποποιεί τα βάρη των συνάψεων που συνδέουν τους νευρώνες, ενώ ο κανόνας αφαίρεσης προτιμά να αφαιρεί εκείνες τις συνάψεις που είναι "καταθλιπτικές"—δηλαδή, οι συνάψεις που μεταφέρουν "χρήσιμα" μοτίβα ή υποσύνολα μοτίβων στους νευρώνες θα ενισχυθούν, καθιστώντας τες πιο σταθερές μακροπρόθεσμα. Αντίθετα, οι συνάψεις που συνήθως μεταδίδουν θόρυβο θα σιγήσουν και είναι πιο πιθανό να αποκοπούν. Όλοι οι παραπάνω μηχανισμοί λειτουργούν συνεχώς, σε σταθερό ρυθμό, σε έναν πληθυσμό νευρώνων. Το μοντέλο που χρησιμοποιούμε διαφέρει από αυτό που προτάθηκε από τους Bamford et al. (2010) σε αρκετές σημαντικές πτυχές: α) Προσομοιώνεται σε πραγματικό χρόνο στο νευρομορφικό υλικό SpiNNaker, β) Παρέχεται πιο ρεαλιστική είσοδος (ψηφία MNIST) σε μεγαλύτερες χωρικές κλίμακες σε κάθε στοχοποιημένο στρώμα, γ) Οι συνδέσεις είναι γενικά στατικές (τα βάρη δεν τροποποιούνται από την STDP), δ) Οι πλαγίες συνδέσεις (στόχος-στόχος) είναι ανασταλτικές, αντί για διεγερτικές, ε) Η προσομοίωση μηχανισμών για διαφορετικούς σκοπούς: οι Bamford et al. (2010) πρότειναν το μοντέλο ως μηχανισμό για τη βελτίωση του τοπογραφικού χάρτη.

#### 4.8.2 Αρχιτεκτονική δικτύου

Στο πλαίσιο των νευρωνικών δικτύων με εκρήξεις σήματος, η μάθηση συνήθως σχετίζεται με τη μακροπρόθεσμη αύξηση ή μείωση της αποτελεσματικότητας των συνάψεων. Μια τέτοια αύξηση μπορεί να συμβεί επειδή μια σύναψη ανίχνευσε μια προ-συναπτική δράση που ακολούθηθηκε γρήγορα από μια μετα-συναπτική δράση. Αντίθετα, μια μετα-συναπτική δράση που ακολουθείται από μια προ-συναπτική δράση θεωρείται αντίθετης αιτιότητας και η σύναψη που επεξεργάζεται αυτά τα γεγονότα μειώνει την αποτελεσματικότητά της. Η Συναπτική Πλαστικότητα με Εξαρτώμενη από το Χρόνο (STDP) είναι ο μηχανισμός που χρησιμοποιείται συνήθως για να προκαλέσει μακροπρόθεσμη ενίσχυση ή καταστολή.

Ωστόσο, ένα δίκτυο μπορεί να μάθει ακόμα και χωρίς αλλαγή στην αποτελεσματικότητα ή το βάρος μιας σύναψης. Χρησιμοποιώντας δομική πλαστικότητα στο σύστημα SpriNNaker, ένα δίκτυο μπορεί να λύσει την αποστολή της ταξινόμησης χειρόγραφων αριθμών είτε χρησιμοποιώντας μόνο στατικές συνάψεις είτε χρησιμοποιώντας την STDP για να ρυθμίσει την ανακατανομή των συνάψεων. Το μοντέλο ανακατανομής των συνάψεων περιλαμβάνει δύο πιθανότητες κανόνες ανακατανομής: έναν για τον σχηματισμό συνάψεων και έναν για την αφαίρεση αυτών. Ο σχηματισμός είναι μια διαδικασία ανεξάρτητη από τη δραστηριότητα και εξαρτάται από την απόσταση μεταξύ των υποψήφιων νευρώνων. Μια νέα σύναψη σχηματίζεται με το μέγιστο βάρος  $g_{maxg}_{\{max\}g_{max}}$  αν πληρούνται οι κατάλληλες συνθήκες.

$$r < p_{form} e^{-8^2 / 2\sigma_{form}^2} \quad (\text{Σχέση 4.1})$$


όπου  $r$  είναι ένας τυχαίος αριθμός που λαμβάνεται από μια ομοιόμορφη κατανομή στο διάστημα  $[0,1)[0, 1)[0,1)$ ,  $p_{form}$  είναι η μέγιστη πιθανότητα σχηματισμού,  $d$  είναι η απόσταση μεταξύ των δύο κυττάρων και  $s_{form}2s^2$  είναι η διακύμανση του δεκτικού πεδίου. Το αποτέλεσμα είναι μια κανονική κατανομή των σχηματισμένων συνάψεων γύρω από τον ιδανικό στόχο, δηλαδή γύρω από τον νευρώνα-στόχο όπου  $\delta=0$ . Η αφαίρεση συνάψεων πραγματοποιείται είτε με σταθερή πιθανότητα  $p_{elim-potp}$  όταν τα βάρη είναι στατικά, είτε με την επιλογή μεταξύ  $p_{elim-potp}$  και  $p_{elim-depp}$  όταν εφαρμόζεται σε συνδυασμό με τη Συναπτική Πλαστικότητα με Εξαρτώμενη από το Χρόνο (STDP). Έτσι, μια σύναψη αφαιρείται αν πληρούνται οι αντίστοιχες συνθήκες.

$$r < p_{elim} \quad \text{where } p_{elim} = \begin{cases} p_{elim-dep} \text{ for } w_{syn} < \theta_g \\ p_{elim-pot} \text{ for } w_{syn} \geq \theta_g \end{cases} \quad (\text{Σχέση 4.2})$$

Όταν εφαρμόζεται η Συναπτική Πλαστικότητα με Εξαρτώμενη από το Χρόνο (STDP), οι συνάψεις που ενισχύονται ή καταστέλλονται μπορούν να υποστούν ανακατανομή με βάση δύο πιθανότητες αφαίρεσης: μία για τις καταθλιπτικές συνάψεις ( $p_{elim-depp}$  και μία για τις ενισχυμένες συνάψεις ( $p_{elim-potp}$ ). Το βάρος της σύναψης ( $w_{syn}$ ) συγκρίνεται με ένα κατώφλι ( $\theta_g$ ), που είναι το μισό του μέγιστου βάρους ( $g_{maxg}$ ), για να αποφασιστεί αν θα αφαιρεθεί.

Στη διαδικασία εποπτευόμενης μάθησης (supervised learning) σε νευρωνικά δίκτυα, τα δεδομένα επισημαίνονται και προβάλλονται από ένα αρχικό στρώμα (source layer) σε ένα αντίστοιχο στοχοθετημένο στρώμα (target layer). Το στρώμα νευρώνων που παρέχει

παραδείγματα μιας κλάσης συνδέεται αποκλειστικά με έναν πληθυσμό που μαθαίνει να αναγνωρίζει τα μέλη αυτής της κλάσης. Η αρχική συνδεσιμότητα μεταξύ κάθε ζεύγους source-target είναι 1%. Το **Σχήμα 4-7** παρουσιάζει την αρχιτεκτονική του δικτύου κατά τη διάρκεια της διαδικασίας εκπαίδευσης, όπου κάθε πηγή ενός ζεύγους source-target προβάλλει ένα ψηφίο για 200 ms, για συνολικά 300 δευτερόλεπτα.

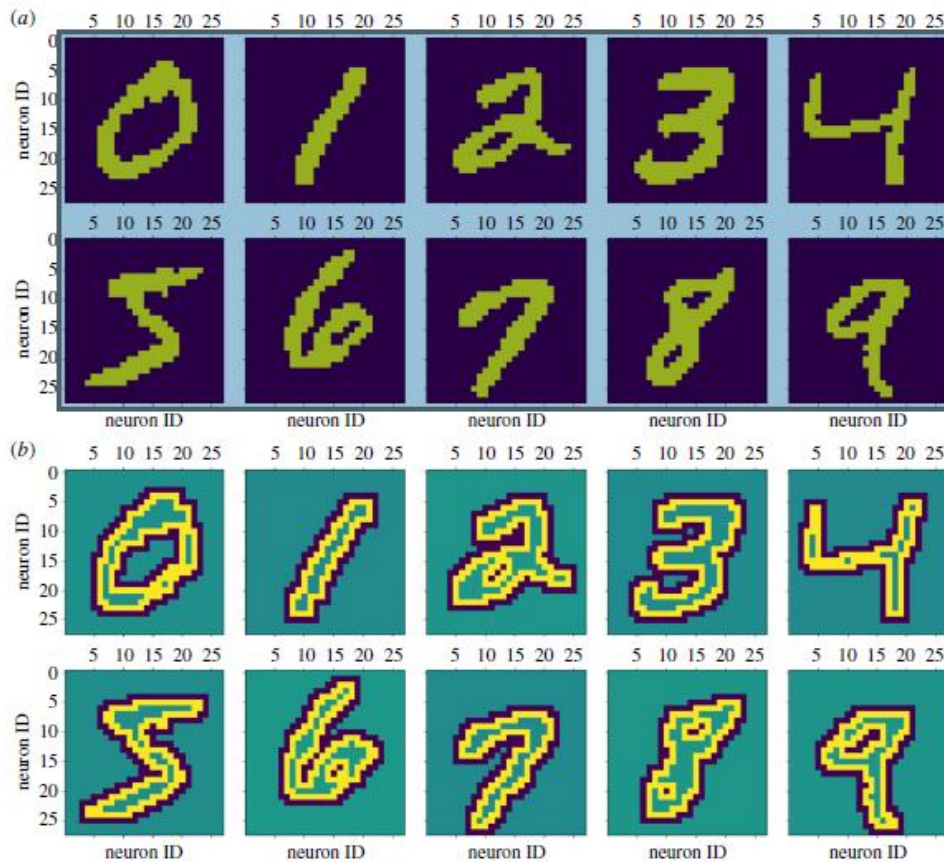


*Σχήμα 4-8: Αρχιτεκτονική δικτύου που χρησιμοποιείται για την εκπαίδευση*

*Πηγή: Hopkins et al., 2018*

Το Σχήμα 4-8 δείχνει παραδείγματα των εισερχόμενων ψηφίων πριν προστεθεί θόρυβος υποβάθρου. Τα παραδείγματα απεικονίζουν την επεξεργασία των ψηφίων μέσω διέλευσης από φίλτρο, το οποίο μιμείται την απόκριση των γαγγλιακών κυττάρων του αμφιβληστροειδούς. Στο (α) μέρος του σχήματος ψηφίου πριν από την εφαρμογή του φίλτρου κέντρου-περιοχής, ενώ στο (β) μέρος φαίνονται οι πληροφορίες ακμών που μεταδίδονται ως εικονοστοιχεία «ON» (θετική μεταβολή στη φωτεινότητα, ανοιχτότερο χρώμα) και «OFF» (αρνητική μεταβολή στη φωτεινότητα, πιο σκούρο χρώμα). Το δίκτυο δοκιμάστηκε και με τους δύο τύπους εισόδου.





Σχήμα 4-9: Παράδειγμα εισόδων που παρουσιάζονται από κάθε στρώμα πηγής στο αντίστοιχο στρώμα στόχου πριν από τη μετατροπή σε αναπαράσταση με βάση το ρυθμό και την προσθήκη θορύβου.

Πηγή: Hopkins et al., 2018

Το μοντέλο αυτό λειτουργεί ως παράδειγμα εποπτευόμενης μάθησης, όπου τα δεδομένα επισημαίνονται με την προβολή τους από ένα αρχικό στρώμα σε ένα οροθετημένο στρώμα. Ένα στρώμα νευρώνων που παρέχει παραδείγματα μιας κλάσης συνδέεται αποκλειστικά με έναν πληθυσμό που μαθαίνει να αναγνωρίζει μέλη αυτής της κλάσης.

Κατά τη διάρκεια της εκπαίδευσης, κάθε αρχικό ψηφίο περνά από μια διαδικασία φιλτραρίσματος χρησιμοποιώντας έναν πυρήνα σύγκρισης κέντρου-περιφέρειας  $3 \times 3$ , μιμούμενος την απόκριση των γαγγλιακών κυττάρων του αμφιβληστροειδούς με την υψηλότερη ανάλυση. Η μετάδοση των δεδομένων γίνεται μέσω νευρώνων που παράγουν σήματα τύπου Poisson, με κάθε πίξελ της εικόνας να αντιστοιχεί σε δύο νευρώνες Poisson (έναν για το κανάλι ενεργοποίησης και έναν για το κανάλι απενεργοποίησης).


Οι συνδέσεις εντός του στοχευμένου στρώματος είναι κυρίως ανασταλτικές, περιορίζοντας τη δραστηριότητα των νευρώνων για να αποτραπεί η υπερβολική εκτόξευση σημάτων. Το δίκτυο προσομοιώνεται χρησιμοποιώντας τη γλώσσα περιγραφής δικτύων PyNN και εφαρμόζεται σε πραγματικό χρόνο στο υλικό SpiNNaker, το οποίο έχει επεκταθεί για να υποστηρίζει την ανακατανομή συνάψεων.

Οι παράμετροι που χρησιμοποιούνται στις προσομοιώσεις, όπως ο ρυθμός ανακατανομής, το μέγεθος κάθε νευρωνικού στρώματος και οι πιθανότητες σχηματισμού και αφαίρεσης συνάψεων, επηρεάζουν τη λειτουργία του μηχανισμού ανακατανομής συνάψεων. Οι νευρώνες Poisson μεταδίδουν τα ψηφία στα στοχευμένα στρώματα με μέσο ρυθμό εκτόξευσης 5 Hz, ενώ κάθε ψηφίο προβάλλεται για 200 ms.

#### 4.9 Ταξινόμηση

Το Σχήμα 4-9 δείχνει ότι είναι δυνατόν να προσδιοριστεί οπτικά τι έχει μάθει κάθε στρώμα-στόχος- τα χρονικά μέσα ψηφία από κάθε κλάση ενσωματώνονται στη συνδεσιμότητα του δικτύου. Μετά την εκπαίδευση, μια μέση αναπαράσταση κάθε κατηγορίας ψηφίων εισόδου μπορεί να ανακατασκευαστεί από τα μεμονωμένα μοτίβα αναδίπλωσης του πληθυσμού πηγής όταν παρουσιάζονται με φιλτραρισμένες ( $\alpha$ ) και μη φιλτραρισμένες ( $\beta$ ) εισόδους. Στην περίπτωση της φιλτραρισμένης εισόδου, η εικόνα κατασκευάζεται από την άθροιση της ανακατασκευασμένης συνδεσιμότητας από τις στρώματα πηγής «ON» και «OFF». Τα φωτεινότερα χρώματα αντιστοιχούν σε περισσότερες συνδέσεις που προέρχονται από το συγκεκριμένο εικονοστοιχείο. Το σχήμα δείχνει μόνο την επίδραση της συναπτικής επανασύνδεσης- τα βάρη δεν περιλαμβάνονται. Στη συνέχεια, είναι δυνατός ο έλεγχος της ποιότητας της ταξινόμησης. Για το σκοπό αυτό, χρησιμοποιείται ένα μόνο στρώμα πηγής, ή ένα μόνο ζεύγος στρωμάτων πηγής στην περίπτωση των φιλτραρισμένων ψηφίων: το ένα αντιπροσωπεύει τα γεγονότα «ON», το άλλο τα γεγονότα «OFF». Η συνδεσιμότητα που έχει μάθει προηγουμένως χρησιμοποιείται για τη σύνδεση όλων των στρωμάτων-στόχων με το στρώμα-πηγή, και όλη η πλαστικότητα απενεργοποιείται. Το στρώμα πηγής εμφανίζει τώρα τυχαία παραδείγματα τάξης, το καθένα για 200ms. Η απόφαση ταξινόμησης λαμβάνεται off-line, με βάση το ποιο στρώμα-στόχος έχει τον υψηλότερο μέσο ρυθμό πυροδότησης εντός της περιόδου των 200 ms. Αυτό δεν είναι ένα state-of-the-art MNIST δίκτυο ταξινόμησης

(επιτυγχάνει μια μέτρια ακρίβεια 78% και ένα RMSE 2,01 με μη φιλτραρισμένες εισόδους, η απόδοση πέφτει όταν χρησιμοποιούνται φιλτραρισμένες εισόδους: ακρίβεια 71% και RMSE 2,38), καθώς κάθε κλάση ψηφίων εισόδου αναπαρίσταται μόνο ως μέσος όρος για την εν λόγω κλάση, αλλά χρησιμεύει εδώ για να δείξει ότι η συναπτική επανασύνδεση μπορεί να επιτρέψει σε ένα δίκτυο να μάθει, χωρίς επίβλεψη, τα στατιστικά στοιχεία των εισόδων του.



Σχήμα 4-10: Επίδραση της συναπτικής επανασύνδεσης.

Πηγή: Hopkins et al., 2018

**Πίνακας 4-1: Οι παράμετροι που χρησιμοποιούνται στις προσομοιώσεις που παρουσιάζονται στο παρόν τμήμα**

Συρμάτωση	Στοιχεία εισόδου	Μεμβράνη	STDP <sup>a</sup>
$N_{\text{layer}} = 28 \times 28$	$f_{\text{mean}} = 5\text{Hz}$	$v_{\text{rest}} = -70 \text{ mV}$	$A_+ = 0.1$
$S_{\text{max}} = 96$	$t_{\text{stim}} = 200 \text{ ms}$	$e_{\text{ext}} = 0 \text{ mV}$	$B=1.2$
$\sigma_{\text{form-ff}} = 2.5$	-	$v_{\text{thr}} = 54 \text{ mV}$	$\tau_+ = 20 \text{ ms}$
$\sigma_{\text{form-lat}} = 2$	-	$g_{\text{max}} = 0.1 \text{ nS}$	$\tau_- = 20 \text{ ms}$
$P_{\text{form-ff}} = 0.16$	-	$\tau_m = 20 \text{ ms}$	-
$P_{\text{form-lat}} = 1$	-	$\tau_{\text{ex}} = 5 \text{ ms}$	-
$P_{\text{elim-dep}} = 0.0245$	-	-	-
$P_{\text{elim-pot}} = 1.36 \times 10^{-3}$	-	-	-
$f_{\text{rew}} = 10 \text{ kHz}$	-	-	-

<sup>a</sup>Οι παράμετροι STDP χρησιμοποιούνται μόνο όταν η συναπτική πλαστικότητα χρησιμοποιείται σε συνδυασμό με την επανασύνδεση.

Επιπλέον, με την τρέχουσα διαμόρφωση του δικτύου και των εισόδων, η ποιότητα της ταξινόμησης εξαρτάται σε κρίσιμο βαθμό από τον μηχανισμό δειγματοληψίας που χρησιμοποιείται για τον σχηματισμό νέων συνάψεων. Η τυχαία επανασύνδεση, σε αντίθεση με τον προτιμησιακό σχηματισμό συνδέσεων με νευρώνες που έχουν πυροδοτηθεί πρόσφατα, θα μπορούσε να επιτύχει ακριβή ταξινόμηση μόνο αν λειτουργούσε σε συνδυασμό με το STDP ή με κάποιον άλλο μηχανισμό που αποτρέπει το κλάδεμα χρήσιμων συνάψεων.

## Κεφάλαιο 5<sup>ο</sup> Συμπεράσματα

Τα νευρωνικά δίκτυα αιχμών (SNN) αντιπροσωπεύουν ένα ισχυρό παράδειγμα που γεφυρώνει το χάσμα μεταξύ της βιολογικής νευρωνικής επεξεργασίας και της τεχνητής νοημοσύνης. Μέσα από την εξερεύνηση της αρχιτεκτονικής, της μοντελοποίησης και της εφαρμογής τους, είναι προφανές ότι τα SNN προσφέρουν μοναδικά πλεονεκτήματα, όπως η ενεργειακή απόδοση και η χρονική επεξεργασία πληροφοριών, τα οποία είναι ιδιαίτερα ωφέλιμα για τους νευρομορφικούς υπολογιστές.

Η σύγκριση των SNN με τα παραδοσιακά μοντέλα βαθιάς μάθησης υπογραμμίζει τόσο τις δυνατότητες όσο και τους υφιστάμενους περιορισμούς τους. Ενώ τα SNN παρέχουν ένα περισσότερο βιολογικώς εύλογο πλαίσιο, η πολυπλοκότητα της εκπαίδευσής τους και η ανάγκη για εξειδικευμένο υλικό, όπως τα νευρομορφικά τσιπ, εξακολουθούν να αποτελούν σημαντικές προκλήσεις. Ωστόσο, οι συνεχείς εξελίξεις, όπως η υποκατάστατη μάθηση με διαβάθμιση και οι εξειδικευμένες βιβλιοθήκες όπως η SNN\_Torch, καθιστούν τα SNN πιο προσιτά και αποτελεσματικά.

Εργαλεία όπως το SNN\_Torch υπήρξαν σημαντικά στην προαγωγή της έρευνας στα SNN παρέχοντας ένα ισχυρό πλαίσιο που ενσωματώνεται άψογα με το PyTorch, επιτρέποντας στους ερευνητές να υλοποιούν και να πειραματίζονται με SNN αποτελεσματικότερα. Η ενσωμάτωση παραδοσιακών συνόλων δεδομένων, όπως το MNIST και το CIFAR-10, σε πλαίσια SNN έχει επιδείξει πολλά υποσχόμενα αποτελέσματα, αποδεικνύοντας ότι τα SNN μπορούν να επιτύχουν ανταγωνιστική απόδοση σε τυπικές εργασίες μηχανικής μάθησης.

Συμπερασματικά, ενώ τα SNN βρίσκονται ακόμη σε ένα σχετικώς εκκολαπτόμενο στάδιο σε σύγκριση με τη συμβατική βαθιά μάθηση, οι δυνατότητές τους για εφαρμογές σε ενεργειακά αποδοτικά συστήματα υπολογιστών και επεξεργασίας σε πραγματικό χρόνο είναι τεράστιες. Το μέλλον των SNN έγκειται στην υπέρβαση των σημερινών περιορισμών μέσω περαιτέρω έρευνας, ανάπτυξης περισσότερο αποτελεσματικών αλγορίθμων εκπαίδευσης και της προόδου στο νευρομορφικό υλικό. Καθώς το πεδίο εξελίσσεται, τα SNN είναι πιθανό να διαδραματίσουν έναν κρίσιμο ρόλο στην επόμενη γενιά συστημάτων τεχνητής νοημοσύνης.

## Βιβλιογραφία

- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017) Understanding of a convolutional neural network, In 2017 International Conference on Engineering and Technology (ICET).IEEE.1-6
- Alpaydin, E. (2021). *Machine learning*. MIT press.
- Amazon. (2024). *What is deep learning?*. [online] ανάκτηση από: <https://aws.amazon.com/what-is/deep-learning/> [πρόσβαση 6-9-2024]
- Bamford, S. A., Murray, A. F., & Willshaw, D. J. (2010). Synaptic rewiring for topographic mapping and receptive field development. *Neural Networks*, 23(4), 517-527.
- Bertoin, D., Bolte, J., Gerchinovitz, S., & Pauwels, E. (2021). Numerical influence of ReLU'(0) on backpropagation. *Advances in Neural Information Processing Systems*, 34, 468-479.
- Brown, A. D., Chad, J. E., Kamarudin, R., Dugan, K. J., & Furber, S. B. (2017). SpiNNaker: event-based simulation—quantitative behavior. *IEEE transactions on multi-scale computing systems*, 4(3), 450-462.
- Çelik, Ö. (2018). A research on machine learning methods and its applications. *Journal of Educational Technology and Online Learning*, 1(3), 25-40.
- Cheng, M. M., & Hackett, R. D. (2021). A critical review of algorithms in HRM: Definition, theory, and practice. *Human Resource Management Review*, 31(1), 100698.
- Cui, R., Yang, C., Li, Y., & Sharma, S. (2017). Adaptive neural network control of AUVs with control input nonlinearities using reinforcement learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(6), 1019-1029.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303-314.
- De Mauro, A., Sestino, A., & Bacconi, A. (2022). Machine learning and artificial intelligence use in marketing: a general taxonomy. *Italian Journal of Marketing*, 2022(4), 439-457.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009) ImageNet: A large-scale hierarchical image database, In 2009 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 248-255

- El Naqa, I., & Murphy, M. J. (2015). *What is machine learning?* (pp. 3-11). Springer International Publishing.
- Eshraghian, J. K. (2021). *snnTorch: Spiking neural networks in PyTorch*. Available from <https://snntorch.readthedocs.io/en/latest/> [Accessed 2-9-2024]
- Eshraghian, J. K., Ward, M., Neftci, E. O., Wang, X., Lenz, G., Dwivedi, G., ... & Lu, W. D. (2023). Training spiking neural networks using lessons from deep learning. *Proceedings of the IEEE*.
- Foote, K. (2021). A Brief History of Machine Learning. Ανάκτηση από: <https://www.dataversity.net/a-brief-history-of-machine-learning/> [Πρόσβαση 06-08-2024]
- Fradkov, A. L. (2020). Early history of machine learning. *IFAC-PapersOnLine*, 53(2), 1385-1390.
- Fujii, G., Hamada, K., Ishikawa, F., Masuda, S., Matsuya, M., Myojin, T., ... & Ujita, Y. (2020). Guidelines for quality assurance of machine learning-based artificial intelligence. *International journal of software engineering and knowledge engineering*, 30(11n12), 1589-1606.
- Furber, S. B., Lester, D. R., Plana, L. A., Garside, J. D., Painkras, E., Temple, S., & Brown, A. D. (2012). Overview of the SpiNNaker system architecture. *IEEE transactions on computers*, 62(12), 2454-2467.
- Gawlikowski, J., Tassi, C. R. N., Ali, M., Lee, J., Humt, M., Feng, J., ... & Zhu, X. X. (2023). A survey of uncertainty in deep neural networks. *Artificial Intelligence Review*, 56(Suppl 1), 1513-1589.
- Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., & Schmidhuber, J. (2008). A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence*, 31(5), 855-868.
- Han, Y., Huang, G., Song, S., Yang, L., Wang, H., & Wang, Y. (2021). Dynamic neural networks: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(11), 7436-7456.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The elements of statistical learning: data*

mining, inference, and prediction.

- Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., ... & Ramkumar, P. N. (2020). Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskel et al medicine*, 13, 69-76.
- Hopkins, M., Pineda-García, G., Bogdan, P. A., & Furber, S. B. (2018). Spiking neural networks for computer vision. *Interface Focus*, 8(4), 20180007.
- Izhikevich, E. M. (2006). Polychronization: computation with spikes. *Neural computation*, 18(2), 245-282.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Jason K. Eshraghian, Max Ward, Emre Neftci, Xinxin Wang, Gregor Lenz, Girish Dwivedi, Mohammed Bennamoun, Doo Seok Jeong, and Wei D. Lu. "Training Spiking Neural Networks Using Lessons From Deep Learning". Proceedings of the IEEE, 111(9) September 2023.
- Jiang, T., Gradus, J. L., & Rosellini, A. J. (2020). Supervised machine learning: a brief primer. *Behavior therapy*, 51(5), 675-687.
- Joshi, A. V. (2020). Machine learning and artificial intelligence.
- King, A. J. (2004). The superior colliculus. *Current Biology*, 14(9), R335-R338.
- Köhler, G. (2020). *MNIST Handwritten Digit Recognition in PyTorch* Next journal, Available from <https://nextjournal.com/gkoehler/pytorch-mnist> [Accessed 2-9-2024]
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59-69.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012) ImageNet classification with deep convolution neural networks, *Advances in Neural Information Processing Systems*, 25, 1097-1105
- Kühl, N., Schemmer, M., Goutier, M., & Satzger, G. (2022). Artificial intelligence and machine learning. *Electronic Markets*, 32(4), 2235-2244.
- Kumar, M., & Bhawna. (2024). Introduction to Machine Learning. In *IoT and ML for*



- Information Management: A Smart Healthcare Perspective* (pp. 51-94). Singapore: Springer Nature Singapore.
- Le, X., & Wang, J. (2013). Robust pole assignment for synthesizing feedback control systems using recurrent neural networks. *IEEE transactions on neural networks and learning systems*, 25(2), 383-393.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998) Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.
- Liu, B., Ding, M., Shaham, S., Rahayu, W., Farokhi, F., & Lin, Z. (2021). When machine learning meets privacy: A survey and outlook. *ACM Computing Surveys (CSUR)*, 54(2), 1-36.
- Liu, Y., & Marin, O. (2021, September). Special function neural network (SFNN) models. In *2021 IEEE International Conference on Cluster Computing (CLUSTER)* (pp. 680-685). IEEE.
- Liu, Y., Liu, S., Wang, Y., Lombardi, F., & Han, J. (2020). A survey of stochastic computing neural networks for machine learning applications. *IEEE Transactions on Neural Networks and Learning Systems*, 32(7), 2809-2824.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9(1), 381-386.
- Mendonça, M. O., Netto, S. L., Diniz, P. S., & Theodoridis, S. (2024). Machine learning: Review and trends. *Signal Processing and Machine Learning Theory*, 869-959.
- Mijwel, M. M. (2021). Artificial neural networks advantages and disadvantages. *Mesopotamian Journal of Big Data*, 2021, 29-31.
- Murphy, K. P. (2022). *Probabilistic machine learning: an introduction*. MIT press.
- Norgaard, M., Ravn, O., Poulsen, N. K., & Hansen, L. K. (2000). *Neural networks for modelling and control of dynamic systems: a practitioner's handbook* (p. 246). London: Springer.
- Rebala, G., Ravi, A., Churiwala, S., Rebala, G., Ravi, A., & Churiwala, S. (2019). Machine learning definition and basics. *An introduction to machine learning*, 1-17.
- Rong, H., Duan, Y., & Zhang, G. (2022). A bibliometric analysis of membrane computing

- (1998–2019). *Journal of Membrane Computing*, 4(2), 177-207.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning internal representations by error propagation, parallel distributed processing, explorations in the microstructure of cognition, ed. de rumelhart and j. mcclelland. vol. 1. 1986. *Biometrika*, 71(599-607), 6.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015) ImageNet large scale visual recognition challenge, *International Journal of Computer Vision*, 115(3), 211-252
- Sak, H. (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling. *INTERSPEECH*.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 160.
- Simonyan, K., & Zisserman, A. (2014) Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sivilotti, M. A. (1991). *Wiring considerations in analog VLSI systems, with application to field-programmable networks*. California Institute of Technology.
- Song, S., & Abbott, L. F. (2001). Cortical development and remapping through spike timing-dependent plasticity. *Neuron*, 32(2), 339-350.
- Thivierge, J. P., & Marcus, G. F. (2007). The topographic brain: from neural connectivity to cognition. *Trends in neurosciences*, 30(6), 251-259.
- Tyagi, A. K., & Chahal, P. (2020). Artificial intelligence and machine learning algorithms. In *Challenges and applications for implementing machine learning in computer vision* (pp. 188-219). IGI Global.
- Viering, T., & Loog, M. (2022). The shape of learning curves: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(6), 7799-7819.
- Von der Malsburg, C. (1973). Self-organization of orientation sensitive cells in the striate cortex. *Kybernetik*, 14(2), 85-100.
- Xie, Y., Takikawa, T., Saito, S., Litany, O., Yan, S., Khan, N., ... & Sridhar, S. (2022, May). Neural fields in visual computing and beyond. In *Computer Graphics Forum* (Vol. 41,

No. 2, pp. 641-676).

Yamazaki, K., Vo-Ho, V. K., Bulsara, D., & Le, N. (2022). Spiking neural networks and their applications: A review. *Brain Sciences*, 12(7), 863.

Yang, G. R., & Wang, X. J. (2020). Artificial neural networks for neuroscientists: a primer. *Neuron*, 107(6), 1048-1070.

Zhou, Z. H. (2022). Open-environment machine learning. *National Science Review*, 9(8), nwac123.

Δεμερτζής, Κ. (2020) *Νευρωνικά Δίκτυα*, Διεθνές Πανεπιστήμιο Ελλάδος.

Λυκοθανάσης, Σ., & Γεωργόπουλος, Ε. (1999). Νευρωνικά δίκτυα και γενετικοί αλγόριθμοι. Πανεπιστήμιο Πατρών. Ανακτήθηκε από:  
[https://eclass.upatras.gr/modules/document/file.php/CEID1044/%CE%94%CE%B9%CE%B4%CE%B1%CE%BA%CF%84%CE%B9%CE%BA%CE%AD%CF%82%20%CE%A3%CE%B7%CE%BC%CE%B5%CE%B9%CF%8E%CF%83%CE%B5%CE%B9%CF%82/odl\\_nnga\\_2.pdf](https://eclass.upatras.gr/modules/document/file.php/CEID1044/%CE%94%CE%B9%CE%B4%CE%B1%CE%BA%CF%84%CE%B9%CE%BA%CE%AD%CF%82%20%CE%A3%CE%B7%CE%BC%CE%B5%CE%B9%CF%8E%CF%83%CE%B5%CE%B9%CF%82/odl_nnga_2.pdf)