

ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

ΕΠΙΣΤΗΜΗ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑ ΤΗΣ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

«Ειδίκευση: Δικτύων Επικοινωνιών και Κατανεμημένων Συστημάτων»



ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Πυροδοτούμενα νευρωνικά δίκτυα και εφαρμογές τους

Γιαννακόπουλος Βασίλειος
Α.Μ. 20010

Εισηγητής: Δρ Αντώνιος Μπόγρης, Καθηγητής

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Πυροδοτούμενα νευρωνικά δίκτυα και εφαρμογές τους

**Γιαννακόπουλος Βασίλειος
Α.Μ. 20010**

Εισηγητής:

Καθηγητής κ. Αντώνιος Μπόγρης,

Εξεταστική Επιτροπή:

**Επίκουρος καθηγητής κ.Μυριδάκης Νικόλαος
Καθηγητής κ. Πάρις Μαστοροκώστας**

Ημερομηνία εξέτασης:21/12/21

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Γιαννακόπουλος Βασίλειος του Αποστολου , με αριθμό μητρώου mcse20010 φοιτητής του Προγράμματος Μεταπτυχιακών Σπουδών Επιστήμη και Τεχνολογία της Πληροφορικής και των Υπολογιστών με ειδίκευση δικτύων υπολογιστών και κατανεμημένων συστημάτων του Τμήματος Μηχανικών πληροφορικής και υπολογιστών της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω ότι:

«Είμαι συγγραφέας αυτής της μεταπτυχιακής εργασίας και ότι 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».

Επιθυμώ την απαγόρευση πρόσβασης στο πλήρες κείμενο της εργασίας μου μέχρι και έπειτα από αίτηση μου στη Βιβλιοθήκη και έγκριση του επιβλέποντα καθηγητή.

Ο Δηλών

ΕΥΧΑΡΙΣΤΙΕΣ

Καταρχήν θα ήθελα να ευχαριστήσω τον σύμβουλο καθηγητή κ. Αντώνιο Μπόγρη για την ευκαιρία που μου έδωσε να ασχοληθώ με ένα τόσο ενδιαφέρον θέμα, καθώς και να τον ευχαριστήσω για τον χρόνο και την καθοδήγηση που μου έδωσε. Επιπλέον, είμαι πολύ ευγνώμων στους καθηγητές του τμήματός μας, οι οποίοι μου παρείχαν το απαραίτητο υλικό για τα μαθήματα και μας μετέδωσαν απόψεις σχετικές με τα σύγχρονα τεχνικά δεδομένα επιδημίας. Τέλος, θέλω να ευχαριστήσω , γονείς και φίλους για την υπομονή και την υποστήριξή τους κατά τη διάρκεια των μεταπτυχιακών μου σπουδών.

ΠΕΡΙΛΗΨΗ

. Πρόσφατα επιστημονικά δεδομένα από την επιστήμη της νευρολογίας μας έχουν δείξει ότι οι νευρώνες κωδικοποιούν πληροφορία μέσω του χρονισμού των ηλεκτρικών πυροδοτήσεων που προκαλούνται και όχι από την συχνότητα που πυροδοτούνται. Έτσι μας δίνεται η αφορμή για την διερεύνηση αυτής της προσέγγισης όσο αφορά τα νευρωνικά δίκτυα στο κομμάτι της πληροφορικής. Αρχικά γίνεται μια εισαγωγή όσο αναφορά την μηχανική μάθηση, τους τρόπους εκπαίδευσης και τα προβλήματα που επιλύουν. Στην συνέχεια γίνεται μια προσέγγιση στα νευρομορφική υπολογιστική, ως παρακλάδι της μηχανικής μάθησης με αναφορές στις υλοποιήσεις από πλευράς hardware(memristors, photonics) , με τελικό προορισμό τα spiking neural networks(Πυροδοτούμενα νευρωνικά δίκτυα) στα οποία θα αναφερθούν μοντέλα αυτών, μέθοδοι training(εκπαίδευσης) καθώς και μερικά χαρακτηριστικά που πρέπει να τα διέπουν (plasticity).Τέλος γίνεται αναφορά σε εφαρμογές αυτών στην καθημερινότητα(αναγνώριση εικόνας, ρομποτική) και σε μελλοντικά βήματα όσο αναφορά την περαιτέρω ανάπτυξή τους.

ABSTRACT

Recent scientific data from the science of neurology have shown us that neurons encode information through the timing of the electrical triggers caused rather than by the frequency they are triggered. This gives us the opportunity to explore this approach as far as neural networks in the field of information technology are concerned. Initially, an introduction is made as far as reference is made to machine learning, the ways of training and the problems they solve. Then there is an approach to neuromorphic computing, as an offshoot of machine learning with references to implementations in terms of hardware (memristors, photonics), with final destination to spiking neural networks (Spiking neural networks) that will be mentioned, methods of training (supervised, reward modulated, reinforced) as well as some characteristics that should govern them (plasticity). To sum up we propose applications for SNN at visual Computing and robotics and some future steps as far as their further development.

Keywords

Spiking neural networks, Liquid State machine, Machine Learning, Visual Computing, Robotics, Memristor, spintronics, Photonics, Plasticity, Neurons, Visual place recognition,

Κατάλογος εικόνων

Figure 1 Συσχέτιση ML, AI, NN.....	12
Figure 2 Νευρωνικά με ανατροφοδότηση και χωρίς	14
Figure 3 Το perceptron του Frank Rosenblatt	15
Figure 4 Perceptron για τη λύση των πυλών AND και OR αλλά όχι της XOR.....	16
Figure 6 Συνελικτικό επίπεδο με ένα χάρτη χαρακτηριστικών.	18
Figure 7 Συνελικτικό επίπεδο με N χάρτες χαρακτηριστικών.	19
Figure 8 Συγκέντρωση μέσης και μέγιστης τιμής	20
Figure 9 Αρχιτεκτονική δικτύου AlexNet.	21
Figure 10 "Ξεδίπλωμα" της δομής του RNN.....	22
Figure 11 : LSTM αρχιτεκτονική.	23
Figure 12 GRU αρχιτεκτονική.....	25
Figure 13 Σχηματική σύγκριση των αρχιτεκτονικών RNN	26
Figure 14 Δομή RNN.....	26
Figure 15 Διαδρομή σύγκλισης των GND αλγορίθμων	28
Figure 16 Αριστερά η διαδρομή χωρίς momentum και δεξιά με momentum.....	29
Figure 17 Διαφορά μεταξύ απλού και Nesterov momentum	29
Figure 18 Σύγκριση μεταξύ των αλγορίθμων βελτιστοποίησης με το MNIST	30
Figure 19 Σύγκριση μεταξύ των αλγορίθμων βελτιστοποίησης σε ένα CNN	31
Figure 20 Multilayer Perceptron	31
Figure 21 Multilayer Perceptron.....	32
Figure 22 Backpropagation στο επίπεδο της εξόδου. i	33
Figure 23 Backpropagation στο επίπεδο της εξόδου.....	33
Figure 24 Ροή πληροφορίας νευρώνα στο back propagation.....	34
Figure 26 Backpropagation από το νευρώνα j του επιπέδου L-2 στο νευρώνα i του επιπέδου L-1.	36
Figure 29 Παράδειγμα dropout	40
Figure 30 Internal covariate shift.....	41
Figure 31 Ακρίβεια εκπαίδευσης με και χωρίς batch normalization στο σετ δεδομένων MNIST.	41
Figure 32 Βηματική συνάρτηση $f(x)=u(x)$	49
Figure 33 Διάγραμμα Εφαπτομένη.....	
Figure 35 Ανορθωμένη γραμμική συνάρτηση Ράμπας	50
Figure 36 Συνάρτηση Ράμπας leaky Rel.....	51
Figure 37 Υλοποίηση lif νευρώνα και μείωση πολυπλοκότητας με χρήση shifters.....	55
Figure 38 Υλοποίηση neural computing hardware unit(NCHU)	56
Figure 39 - Προτεινόμενο νευρομορφικό σύστημα προς υλοποίηση για FPGA.....	56
Figure 40 Υλοποίηση για την δημιουργία spiking neural network σε blocks υλικού	57
Figure 41 Εσωτερικό δίκτυωμα NM500	58
Figure 42 Hardware που χρησιμοποιήθηκε για την σύγκριση.....	59

Figure 43 Χρόνος εκπαίδευσης μοντέλου στα διάφορα σενάρια.....	59
Figure 44 Χρόνος επεξεργασίας στις διάφορες πλατφόρμες για συγκεκριμένο dataset.....	60
Figure 45 Καταναλισκόμενη ενέργεια για την εκπλήρωση της εκπαίδευσης	61
Figure 46 Μέση κατανάλωση ισχύος ανα νευρώνα που παρέχει η κάθε πλατφόρμα	61
Figure 47 Παραμετρική σχέση παθητικών στοιχείων	62
Figure 48 Figure 49 Η εικόνα (a) δείχνει την γενική δομή της διάταξης memristor.....	63
Figure 49 Μετακίνηση Ιόντων Με την εφαρμογή θετικής τάσης	
Figure 50 Μοντελο simmons	67
Figure 51 Συγκριση μοντέλων Memristor	68
Figure 52 Μια ολογραφική αρχιτεκτονική ONN.....	71
Figure 53 Υλοποίηση νευρωνικού με την χρήση κυματοδηγών	73
Figure 54 Εικονοποίηση mjt array	74
Figure 55 MJT κελί	75
Figure 56 Liquid State machine.....	76
Figure 57 Δοκιμή μιας τυπικής συνεδριας καταγραφής νοητικών κινήσεων.....	78
Figure 58 Λειτουργικά μέρη ενός βιολογικού νευρώνα.	79
Figure 59 Παράδειγμα κωδικοποίησης ρυθμού νευρωνικών σημάτων.....	82
Figure 60 Οπτική αναπαράσταση άθροισης μετασυναπτικών δυναμικών	84
Figure 61 Υλοποίηση δυο επιπέδων μια εκτέλεση εργασίας VPR.....	92
Figure 62 Αρχιτεκτονική ανίχνευσης κίνησης.	96
Figure 63 Υλοποίηση κωδικοποίησης εικόνας στο Ματι	97
Figure 64 Τοπογραφικός χάρτης νευρώνων.....	99
Figure 65 supervised εκπαίδευση κατα Hebb.....	102
Figure 66 Classical conditioning με χρήση STDP σύναψης.....	103
Figure 67 Reward modulated σύναψη.	105
Figure 68 Διάγραμμα αποφάσεων Μαρκoβ.Απεικονίζει τις πιθανές καταστ	107

Περιεχόμενα

ABSTRACT.....	5
Keywords.....	5
Κατάλογος εικόνων.....	6
1.-Βασικό θεωρητικό υπόβαθρο – Εισαγωγή στην Μηχανική μάθηση.....	11
1.1 Μηχανική μάθηση.....	11
1.1.1 Ιστορικά στοιχεία	11
1.2 Εισαγωγή στη βαθιά μάθηση.....	11
1.2.1 Ιστορική αναδρομή deep Learning.....	12
1.3 Η εξέλιξη των DNNs σε σχέση με τα νευρωνικά.....	12
1.4 Βασικές Αρχές Τεχνητών Νευρωνικών Δικτύων - Αρχιτεκτονικές νευρωνικών δικτύων	13
1.4.1 Perceptron.....	15
1.4.2 MultiLayer Perceptron – MLP	17
1.4.3 Συνελκτικά δίκτυα	18
1.5 Αναδρομικά νευρωνικά δίκτυα - RNN.....	22
1.5.1 Απλό αναδρομικό δίκτυο	22
1.5.2 Long Short-Term Memory - LSTM.....	23
1.5.3 Gated Recurrent Unit – GRU.....	24
1.5.4 Αναδρομικά νευρωνικά δίκτυα διπλής κατευθύνσεως.....	26
1.6 Εκπαίδευση νευρωνικών δικτύων.....	27
1.6.1 Αλγόριθμοι βελτιστοποίησης	27
1.6.2 Αλγόριθμοι εύρεσης βαρών	32
1.6.3 Συναρτήσεις σφάλματος ή κόστους	39
1.6.4 Τεχνικές κανονικοποίησης – Πρόβλημα overfitting.....	40
1.7 Συναρτήσεις ενεργοποίησης.....	49
1.7.1 Βηματική συνάρτηση.....	49
1.7.2 Σιγμοειδείς συναρτήσεις	49
1.7.3 Ομαλοποιημένη εκθετική συνάρτηση – Softmax	50
1.7.4 Ανορθωμένη γραμμική συνάρτηση ράμπας – REL.....	50
1.7.4.1 Leaky REL.....	51
1.8 Εφαρμογές των νευρωνικών δικτύων	51
1.9 Πλεονεκτήματα – μειονεκτήματα ΤΝΔ	52
2 - Νευρομορφική υπολογιστική.....	52
2.1 Εισαγωγή.....	52
2.2 Εμπνευση για την προσέγγιση προς την νευρομορφική υπολογιστική.....	53
2.3 Νευρομορφικό υλικό – Accelerators - Ενεργειακή αποδοτικότητα.....	54

2.3.1	Αρχιτεκτονική FPGA προσαρμοσμένη στις ανάγκες ενός TNN	55
2.3.2	Αρχιτεκτονική εμπορικής λύσης NM500.....	58
2.3.3	Ενεργειακή απόδοση των CPU, GPU και NM500 για την υλοποίηση νευρωνικού δικτυώματος.....	59
2.4	Υλοποιήσεις hardware για την δημιουργία νευρώνων	61
2.4.1	Memristor	61
2.4.2	Photonics	69
2.4.3	Spintronics	74
2.5	Νευρωνικά δίκτυα αιχμών	75
2.6	Liquid state Machines	76
3	Νευρωνικά Δίκτυα Αιχμών	78
3.1	Νευροφυσιολογία του ανθρώπινου εγκεφάλου	79
3.1.1	Νευρώνες.....	79
3.1.2	Νευρωνικά σήματα	79
3.1.3	Μετάδοση σημάτων.....	80
3.2	Νευρωνική Κωδικοποίηση	80
3.2.1	Κωδικοποίηση Ρυθμού	81
3.2.2	Κωδικοποίηση Παλμού	82
3.2.3	Κωδικοποίηση Πληθυσμού	83
3.3	Μοντελοποίηση νευρώνων.....	84
3.3.1	Δυναμική νευρώνων	84
3.3.2	Μοντέλα νευρώνων	85
3.3.3	Μοντέλα συνάψεων	87
3.4	Συναπτική πλαστικότητα και μάθηση	88
3.4.1	Διαδικασία Μάθησης.....	88
3.4.2	Πλαστικότητα εξαρτώμενη από τον χρονισμό των αιχμών	89
3.4.3	Μάθηση Ενός Περάσματος	89
3.4.4	Εκπαίδευση κατά Hebbian	90
4	ΕΦΑΡΜΟΓΕΣ SNN.....	91
4.1	Υπολογιστική όραση	91
4.1.1	Visual place Recognition(VPR)	91
4.1.1.1	Υλοποίηση μέσω SNN – Μεθοδολογία	92
4.1.2	Ανίχνευση κίνησης	95
4.1.2.1	Επεξεργασία πληροφορίας με βάση τα συμβάντα(Event Based processing).....	96
4.1.2.2	Κωδικοποίηση εικόνας – Τοπογραφικοί χάρτες	97
4.2	Ρομποτική.....	99
4.2.1	Μη επιτηρούμενη εκπαίδευση στην ρομποτική	101
4.2.2	Επιτηρούμενη εκπαίδευση στην ρομποτική.....	101

4.2.3 Classical conditioning(Κλασσική συνθήκη)	103
4.2.4 Operant Conditioning(Λειτουργική συνθήκη)	104
4.2.5 Εκπαίδευση reward-modulated	105
4.2.6 Reinforcement Learning(Ενισχυμένη εκπαίδευση).....	107
5 Συμπεράσματα – Προτάσεις για μελλοντική διερεύνηση	108
6 Βιβλιογραφία	110
7 Συντομογραφίες.....	112

1.-Βασικό θεωρητικό υπόβαθρο – Εισαγωγή στην Μηχανική μάθηση

1.1 Μηχανική μάθηση

Η μηχανική μάθηση (ML) επιτρέπει στις μηχανές να μαθαίνουν χωρίς σαφή προγραμματισμό (Mahdavinejad et al., 2018). Έχει εξελιχθεί από την υποδιαίρεση της επιστήμης των υπολογιστών (AI) και της τεχνητής νοημοσύνης (AI) (Lewis & Denning, 2018) και την αναγνώριση προτύπων και τη θεωρία της μάθησης υπολογιστών (Mahdavinejad et al., 2018) στον κορυφαίο ερευνητικό τομέα της τεχνητής νοημοσύνης και της αρχιτεκτονικής συστήματος υπολογιστών (Lewis & Denning, 2018). Την τελευταία δεκαετία, οι επενδύσεις σε υλικό και λογισμικό μηχανικής μάθησης έχουν αυξηθεί εκθετικά, ταιριάζοντας μόνο με παρόμοιες επενδύσεις στην τεχνολογία blockchain (Lewis & Denning, 2018). Αυτό το κεφάλαιο εισάγει τη μηχανική μάθηση και τον τρόπο εφαρμογής της. Αναλύει τα πρότυπα ροής προσωπικού και τα πρότυπα ενδιαφέροντος που εξάγονται από αυτά τα δεδομένα. Προωθείται η ανάπτυξη υπηρεσιών και εφαρμογών βάσει της τοποθεσίας.

1.1.1 Ιστορικά στοιχεία

Στις αρχές του 1940 υπήρξε ιδιαίτερη προσοχή στους αυτόματους υπολογιστές, μιας και κάποιος πίστευαν ότι οι λογικοί υπολογισμοί του εγκεφάλου ήταν δυνατοί εξαιτίας της νευρωνικής του δομής (Lewis & Denning, 2018).

Το 1943, ο Warren McCulloch και ο Walter Pitts έγραψαν μια περίφημη πρόταση για την κατασκευή ενός υπολογιστή με στοιχεία παρόμοια με τους νευρώνες: «Επειδή η νευρική δραστηριότητα χαρακτηρίζεται από «Όλα ή τίποτα», επομένως είναι δυνατό να διαχειριστούμε νευρικά συμβάντα και να μεσολαβήσουμε τη σχέση τους με την προτασιακή λογική. (McCulloch and Pitts, 1943). Κάθε νευρώνας έχει εισόδους από πολλούς άλλους νευρώνες και εξόδους από πολλούς άλλους νευρώνες. Η είσοδος σταθμίζεται. Όταν η σταθμισμένη είσοδος υπερβαίνει το όριο νευρώνων, θα μεταπηδήσει από τη "Βαθιά μάθηση και τη μηχανική μάθηση: Κατάσταση 0" στην κατάσταση 1. Μια μηχανή οργανωμένη σαν εγκέφαλος έχει νόημα. Ως εκ τούτου, οι McCulloch και Pitts έθεσαν τα θεμέλια για μελλοντικά τεχνητά νευρωνικά δίκτυα (Lewis & Denning, 2018) [https://en.wikipedia.org/wiki/Machine_learning]

1.2 Εισαγωγή στη βαθιά μάθηση

Από τη δεκαετία του 1950, ένα μικρό μέρος της τεχνητής νοημοσύνης (AI), που συνήθως αναφέρεται ως μηχανική μάθηση (ML), έχει φέρει επανάσταση σε διάφορους τομείς τις τελευταίες δεκαετίες. Το νευρωνικό δίκτυο (NN) είναι ένα υποπεδίο της μηχανικής μάθησης που δημιούργησε τη βαθιά μάθηση (DL) που έχει αναπτυχθεί εκτενώς από το 2006 (Alom et al., 2018). Αυτό είναι ένα νέο μεγάλο και ταχέως αναπτυσσόμενο πεδίο που μπορεί να αλλάξει σημαντικά

τον τρόπο με τον οποίο βλέπουμε την τεχνητή νοημοσύνη και τα επιτεύγματά της (Sherkhane & Vora, 2017). Το σχήμα 4-1 δείχνει την ταξινόμηση της τεχνητής νοημοσύνης (Alom et al., 2018). Από την έναρξή της, η βαθιά μάθηση δημιουργεί όλο και περισσότερη σύγχυση. Λόγω της ικανότητάς της να χρησιμοποιεί δεδομένα εισόδου τεχνητού στρώματος νευρώνων (LeCun et al., 2018), έχει επιτύχει μεγάλη επιτυχία σε όλα σχεδόν τα πεδία εφαρμογών (LeCun et al., 2018). , 2015).

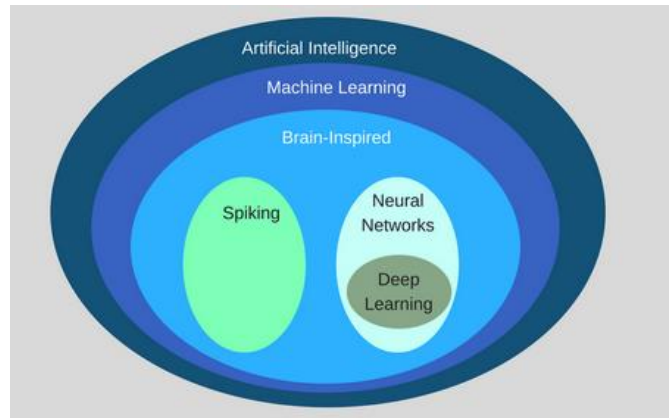


Figure 1 Συσχέτιση ML, AI, NN ΠΗΓΗ:
https://en.wikipedia.org/wiki/Machine_learning

1.2.1 Ιστορική αναδρομή deep Learning

Το ερευνητικό πεδίο της βαθιάς μάθησης και των τεχνητών νευρωνικών δικτύων γεννήθηκε από τη φιλοδοξία της δημιουργίας ενός υπολογιστικού συστήματος παρόμοιου με τον ανθρώπινο εγκέφαλο. Αλλά για να οικοδομήσουμε ένα τέτοιο σύστημα, πρέπει να είμαστε σε θέση να κατανοήσουμε τις λειτουργίες του ανθρώπινου γνωστικού συστήματος. Για το λόγο αυτό, συνιστάται να περπατάτε προς τα πίσω σε όλη τη διαδρομή. Από το 300 π.Χ., έχουν γίνει προσπάθειες για την κατανόηση των λειτουργιών του ανθρώπινου εγκεφάλου. Σχετικά με το έργο του Αριστοτέλη «Associationism» (Wang L. & Ranjan, 2015). Η ιστορία των ανθρώπων που θέλουν να κατανοήσουν τον εγκέφαλο ξεκινά κάπως έτσι. Επειδή μια τέτοια ιδέα απαιτεί από τους επιστήμονες να κατανοήσουν τον μηχανισμό του συστήματος ανθρώπινης αναγνώρισης (Pouyanfar et al., 2018)[19]

1.3 Η εξέλιξη των DNNs σε σχέση με τα νευρωνικά

Αν και το ANN εισήχθη πριν από δεκαετίες, η τάση ανάπτυξης του DNN ξεκίνησε το 2006 όταν οι Hinton και Salakhutdinov εισήγαγαν την έννοια των δικτύων βαθιάς πεποίθησης (Hinton & Salakhutdinov, 2006). Έκτοτε, η τεχνολογία αυτή έχει προσελκύσει την προσοχή σε διάφορους τομείς της τεχνητής νοημοσύνης όπως η γνωστική, η Αναζήτηση εικόνων, μηχανή αναζήτησης, ανάκτηση πληροφοριών, επεξεργασία φυσικής γλώσσας (Mohammadi et al., 2018).

Ποιο συγκεκριμένα έχουμε:

- 2006: Ο Geoffrey Hinton παρουσιάζει τα Deep Belief Networks (DBNs) και την layerwise τεχνική προ-εκπαίδευσης (pretraining technique), εκκινώντας την εποχή της βαθιάς μάθησης (Wang L. & Ranjan, 2015). Επίσης το εργαστήριο Hinton λύνει το πρόβλημα εκπαίδευσης των DNNs (Hinton, Osindero & The, 2006), (Hinton & Salakhutdinov, 2006).
- 2009: Οι Salakhutdinov και Hinton παρουσιάζουν τις Deep Boltzmann Machines (Wang L. & Ranjan, 2015).

- 2012: Ο Geoffrey Hinton παρουσιάζει το Dropout, ένα αποτελεσματικό τρόπο εκπαίδευσης των neural networks (Wang L. & Ranjan, 2015) και ο Alex Krizhevsky παρουσιάζει το AlexNet (Krizhevsky, Sutskever & Hinton, 2012).

Ορισμένες αναπαραστάσεις στη βαθιά μάθηση, γνωστές και ως μάθηση αναπαράστασης (Deng, 2014), είναι εμπνευσμένες από το νευρικό σύστημα ("Introduction to Beginners in Deep Learning", 2015). Η βαθιά εκμάθηση αντικαθιστά τα χειροποίητα μετρήσιμα χαρακτηριστικά με αποτελεσματικούς αλγόριθμους μάθησης χωρίς επίβλεψη ή ημι-εποπτευόμενη και ιεραρχική εξαγωγή χαρακτηριστικών (Bengio, 2009).[Wikipedia.org]

1.4 Βασικές Αρχές Τεχνητών Νευρωνικών Δικτύων - Αρχιτεκτονικές νευρωνικών δικτύων

Αυτή η ενότητα επιχειρεί να περιγράψει ορισμένα από τα βασικά χαρακτηριστικά της δομής, της λειτουργίας και της απόδοσης των TNN όσο το δυνατόν συνοπτικά. Ωστόσο, λόγω της τεράστιας ανάπτυξης που παρατηρείται στο πεδίο (σε θεωρητικό και εφαρμοσμένο επίπεδο), οποιαδήποτε πιθανή εκδοχή αυτών των χαρακτηριστικών θεωρείται παράνομη για παρουσίαση και ανάλυση. Αντίθετα, εισάγει τις πιο κοινές δομές, παραμέτρους και αλγόριθμους που είναι συνήθως TND. [21]

Όπως αναφέρθηκε στο προηγούμενο κεφάλαιο, οι τεχνητοί νευρώνες TND είναι οργανωμένοι σε διάφορα επίπεδα παράλληλης διάταξης. Αυτές οι ακολουθίες παράλληλου επιπέδου αποτελούν ολόκληρο το TND. Φυσικά, στο TND, δεν είναι όλα τα επίπεδα ίδια, διαφέρουν ως εξής:

- Το επίπεδο εισόδου είναι το πρώτο επίπεδο του TND, όπου εμφανίζονται τα δεδομένα εισόδου και ο αριθμός των νευρώνων είναι ίσος με τη μεταβλητή δεδομένων.
- Το κρυφό στρώμα συνδέει το προηγούμενο επίπεδο νευρώνων με το επόμενο επίπεδο νευρώνων. Ο αριθμός των κρυφών επιπέδων που περιλαμβάνονται στο TND ορίζεται από τον σχεδιαστή χρήστη και επηρεάζει το "βάθος" και την πολυπλοκότητά του (μάλλον κανένα).
- Το επίπεδο εξόδου είναι το τελευταίο στρώμα του TND. Αυτά δείχνουν το τελικό αποτέλεσμα μετά την εκμάθηση και ο αριθμός των νευρώνων είναι ίσος με τις πιθανές μεταβλητές εξόδου του αποτελέσματος.

Τα ΤΝΔ κατηγοριοποιούνται ανάλογα με την αρχιτεκτονική τους και τον τρόπο με τον οποίο συνδέονται οι νευρώνες μεταξύ τους:

- Σε νευρωνικά δίκτυα με χρήση feedforward. Σε αυτή την περίπτωση, το σήμα αποστέλλεται από την είσοδο στην έξοδο μέσω του νευρώνα, αλλά όχι το αντίστροφο. Αυτά τα δίκτυα μπορούν να χωριστούν σε δίκτυα ενός επιπέδου (όπως πολυστρωματικά perceptrons) ή δίκτυα πολλαπλών επιπέδων (όπως perceptron πολλαπλών επιπέδων), ανάλογα με το αν περιέχουν πολλά κρυφά επίπεδα.
- • Νευρωνικό δίκτυο με ανατροφοδότηση. Σε αυτή την περίπτωση, το νευρωνικό δίκτυο περιέχει επίσης τουλάχιστον έναν βρόχο ανάδρασης. Επομένως, τουλάχιστον ένα επίπεδο νευρώνων είναι υπεύθυνο για την ανατροφοδότηση του σήματος εξόδου στις εισόδους όλων των άλλων νευρώνων (βλ. παρακάτω σχήμα)..

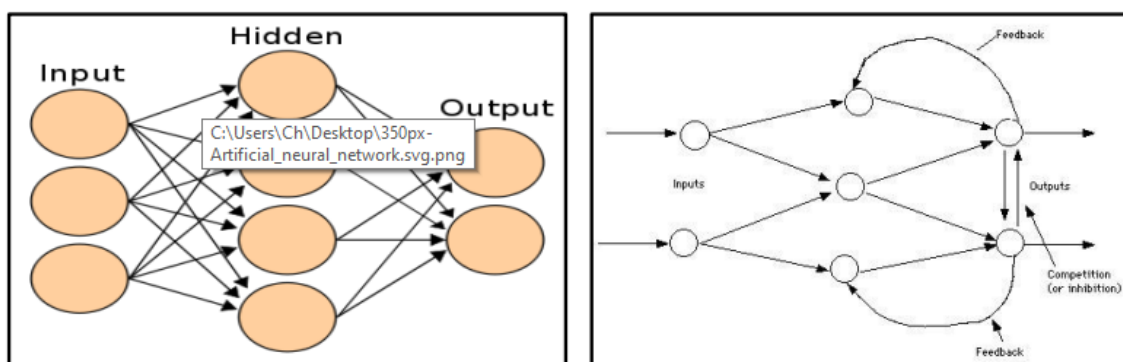


Figure 2 Νευρωνικά με ανατροφοδότηση και χωρίς[5]

1.4.1 Perceptron

Το perceptron προτάθηκε για πρώτη φορά από τον Frank Rosenblatt [9] το 1958 και αποτελεί την πιο βασική μονάδα νευρωνικών δικτύων. Όταν προτάθηκε από τον Frank Rosenblatt, ήταν ένα νευρωνικό δίκτυο ενός επιπέδου σχεδιασμένο να ταξινομεί δυαδικά διανύσματα χαρακτηριστικών εισόδου. Η λειτουργία του περιγράφεται από την παρακάτω συνάρτηση. [Wikipedia.org/perceptron]:

$$f(x) = \sigma(W^T * x + b) \quad (1)$$

Όπου W^T είναι ο πίνακας με τα βάρη, x είναι η είσοδος, b είναι μία σταθερά (bias) και σ είναι η συνάρτηση ενεργοποίησης. Για το perceptron του Frank Lorenblatt, η συνάρτηση ενεργοποίησης ήταν σταδιακή και το b ήταν το κατώφλι.




Figure 3 Το perceptron του Frank Rosenblatt ΠΗΓΗ :

https://commons.wikimedia.org/wiki/File:Perceptron_moj.png#/media/File:Perceptron_moj.png

Όπως φαίνεται από το σχήμα 2 και τη συνάρτηση (2), το μοντέλο αυτό πολλαπλασιάζει κάθε τιμή εισόδου με το αντίστοιχο βάρος του, στη συνέχεια προσθέτει όλες τις τιμές και ελέγχει εάν αυτό το άθροισμα υπερβαίνει το όριο. Εάν ναι, τότε η έξοδος του συστήματος ήταν 1, αυτό σημαίνει ότι η είσοδος ανήκει στην κατηγορία A, εάν η έξοδος δεν είναι μηδέν και η είσοδος ανήκει στην κατηγορία B.

$$f(x) = \begin{cases} 1, & w^T * x + b > 0 \\ 0, & \text{else} \end{cases} \quad (2)$$

Ο αλγόριθμος εκπαίδευσης μοντέλου βασίζεται στον υπολογισμό του σφάλματος μεταξύ των πραγματικών και των προβλεπόμενων τιμών και στην αναβάθμιση των βαρών με βάση την ακόλουθη εξίσωση:

$$w_{new}(n) = w_{old}(n) + lr \cdot (d(n) - y(n)) \cdot x(n) \quad (3)$$

Όπου n είναι το στοιχείο του συνόλου εκπαίδευσης στο οποίο βρισκόμαστε, I_n είναι η σταθερά ρυθμού μάθησης, d είναι η πραγματική τιμή εξόδου για το στοιχείο n , y είναι η τιμή που εκτιμάται από το σύστημα για το στοιχείο n . Ο ίδιος ο Rosenblatt έχει αποδείξει με το Perceptron Θεώρημα σύγκλισης ότι ο αλγόριθμος συγκλίνει σε πεπερασμένα βήματα και παράγει σωστά αποτελέσματα εάν οι κλάσεις του προβλήματος είναι γραμμικά διαχωρίσιμες. Παρά την αρχική επιτυχία του perceptron το 1969, οι Minsky και Papert [22] απέδειξαν την αδυναμία του να προβλέψει μη γραμμικά μοντέλα όπως η συνάρτηση XOR. Αυτό έκανε την επιστημονική κοινότητα να χάσει την εμπιστοσύνη στα νευρωνικά δίκτυα και να παγώσει την έρευνα για αρκετά χρόνια.




Figure 4 το perceptron για τη λύση των πυλών AND και OR εκτός της XOR ΠΗΓΗ <https://ynebula.tistory.com/22>.

1.4.2 MultiLayer Perceptron – MLP

Το πολυστρωματικό perceptron είναι μια εξέλιξη του απλού μοντέλου perceptron. Αποτελείται από τουλάχιστον 3 επίπεδα (input-hidden-output), καθένα από τα οποία μπορεί να έχει 1 ή περισσότερες νευρώνες. Αυτό το μοντέλο δημιουργήθηκε για να ξεπεράσει τα προβλήματα της απλής αρχιτεκτονικής perceptron. Αν και το όνομά του περιλαμβάνει τη λέξη perceptron, οι νευρώνες του χρησιμοποιούν διαφορετική αρχιτεκτονική από τους νευρώνες perceptron. Σε αντίθεση με τα perceptron των οποίων οι λειτουργίες ενεργοποίησης είναι σταδιακά, οι νευρώνες MLP χρησιμοποιούν μη γραμμικές συναρτήσεις, όπως σιγμοειδές, tanh και ούτω καθεξής.




Figure 5 Προβλημα xor ΠΗΓΗ
<http://www.byclb.com/TR/Tutorials/neural>

Η επέκταση επιπέδου και η αλλαγή της συνάρτησης ενεργοποίησης επιτρέπουν στο δίκτυο να επιλύει μη γραμμικά προβλήματα όπως το XOR..

Οι multilayer νευρώνες perceptron μπορούν να συνδεθούν πλήρως ή μερικώς. Το Σχήμα 18 στη σελίδα 23 δείχνει την αναπαράσταση ενός πλήρως συνδεδεμένου MLP. Ένα από τα προβλήματα με την αρχική αδυναμία δημιουργίας MLP είναι η αδυναμία εφαρμογής αλγορίθμων εκμάθησης perceptron. Ο αλγόριθμος ανάστροφης διάδοσης που αναλύθηκε στο κεφάλαιο 1.6.1 δίνει μια λύση σε αυτό το πρόβλημα.

1.4.3 Συνελκτικὰ δίκτυα

Το νευρωνικό συνελκτικό δίκτυο έχει ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και ένα ή περισσότερα ενδιάμεσα κρυφά επίπεδα. Η σημαντική διαφορά μεταξύ αυτών και άλλων νευρωνικών δικτύων είναι ότι η είσοδος τους δεν είναι πλέον διάνυσμα, αλλά μπορεί να είναι ένας πίνακας. Επίσης η σημαντική διαφορά είναι ο τρόπος υπολογισμού της εξόδου. Σε αντίθεση με τον κλασικό τρόπο εφαρμογής του εσωτερικού γινομένου μεταξύ του διανύσματος εισόδου και του αντίστοιχου διανύσματος βάρους, στην περίπτωση ενός συγκλίνοντος νευρωνικού δικτύου ή εξόδου, υπολογίζεται με τη διαδικασία σύγκλισης μεταξύ της εισόδου και του πυρήνα σύγκλισης. Το βασικό μέρος του κρυφού στρώματος του συνεκτικού δικτύου είναι η εφαρμογή της συνάρτησης ενεργοποίησης και το επίπεδο συγκέντρωσης του επιπέδου σύγκλισης εξόδου. [24].

1.4.3.1 Επίπεδο συνέλιξης

Το επίπεδο συνέλιξης περιλαμβάνει είσοδο, χάρτη χαρακτηριστικών και συνάρτηση ενεργοποίησης που εφαρμόζεται στον χάρτη χαρακτηριστικών και δίνοντας έξοδο και τον πυρήνα σύγκλισης που περιέχει το βάρος του χάρτη χαρακτηριστικών. Για λόγους απλότητας και κατανόησης, αντιμετωπίζουμε την είσοδο του δικτύου σύγκλισης ως πίνακα μεγέθους $W \times H \times 3$ και τον πυρήνα σύγκλισης ως πίνακα μεγέθους $L \times M \times 3$. Ο αριθμός των νευρώνων στο επίπεδο σύγκλισης είναι ίσος με τον αριθμό των στοιχείων του χάρτη χαρακτηριστικών. Η διάδοση της πληροφορίας από την είσοδο στον νευρώνα ολοκληρώνεται με τη σύγκλιση της εισόδου και του συγκλίνοντος πυρήνα. Επομένως, ο πυρήνας συνέλιξης σαρώνει όλα τα πλάτη και τα ύψη της εισόδου, εφαρμόζοντας το εσωτερικό γινόμενο μεταξύ τους [24].




Figure 6 Συνελκτικό επίπεδο με ένα χάρτη χαρακτηριστικών. ΠΗΓΗ https://commons.wikimedia.org/wiki/File:Convolutional_Neura

Εκτός από το μέγεθος του πυρήνα, έχουμε επίσης δύο υπερπαραμέτρους, το μέγεθος του βήματος και το padding. Το βήμα μετατόπισης καθορίζει την πυκνότητα των δειγμάτων εισόδου. Ουσιαστικά καθορίζει πόσες χωρικές μονάδες θα κινηθεί ο πυρήνας σε όλο το πλάτος και το ύψος της εισόδου. Μια μικρή τιμή του βήματος μετατόπισης σημαίνει πιο πυκνή δειγματοληψία αλλά μεγαλύτερο όγκο δεδομένων, ενώ μια μεγαλύτερη τιμή έχει ως αποτέλεσμα ένα λεπτότερο δείγμα εξόδου και μικρότερο όγκο δεδομένων. Το πληρωτικό χρησιμοποιείται για την πλήρωση της περιφέρειας της

εισόδου. Αυτή η υπερπαράμετρος στοχεύει να διατηρήσει την είσοδο σταθερή ενώ εφαρμόζει τον πυρήνα σταθερών διαστάσεων. Σε μια πιο γενική περίπτωση, θα εισάγουμε $W_1 \times H_1 \times D_1$, N πυρήνες πηνίου $L_1 \times M_1 \times D_1$, βήμα μετατόπισης S και πλήρωση P . Τότε η έξοδος δικτύου θα έχει το μέγεθος $W_2 \times H_2 \times N$ που υπολογίζεται με τον ακόλουθο τύπο:

$$H_2 = \frac{H_1 - M_1 + 2P}{S} + 1 \quad (4)$$

$$W_2 = ((W_1 L_1 + 2P) + 1) \quad (5)$$




Figure 7 Συνελκτικό επίπεδο με N χάρτες χαρακτηριστικών. [10]

1.4.3.2 Επίπεδο συγκέντρωσης

Η συγκέντρωση ή το επίπεδο δειγματοληψίας είναι ένα βασικό χαρακτηριστικό των συγκλίνων νευρωνικών δικτύων. Συναντώνται ανάμεσα σε συγκλίνοντα στρώματα, αλλά δεν υπάρχουν απαραίτητα μεταξύ κάθε στρώματος. Ο κύριος σκοπός τους είναι να μειώσουν τη διάσταση της εξόδου κρυφού επιπέδου, μειώνοντας έτσι τη μνήμη που απαιτείται για την αποθήκευσή τους και τους υπολογισμούς που πρέπει να ολοκληρωθούν.

Το επίπεδο συγκέντρωσης έχει επίσης τον δικό του πυρήνα (δισδιάστατο) $W_1 \times H_1$, το βήμα μετατόπισης S και την αντίστοιχη επένδυση P . Ο πυρήνας σαρώνει τα $gray$ που θέλει να δειγματίσει κατά ύψος, πλάτος και βάθος. Λόγω των δύο διαστάσεων του πυρήνα, η διάσταση βάθους παραμένει η ίδια. Οι δύο πιο βασικές μέθοδοι δειγματοληψίας δεδομένων είναι η μέση συγκέντρωση [14] και η μέγιστη συγκέντρωση [23]. Το πρώτο επιλέγει τον μέσο όρο όλων των τιμών μεταξύ των πλαισίων εφαρμογής του πυρήνα, ενώ το δεύτερο είναι η μέγιστη τιμή. Σύμφωνα με τη δημοσίευση του Scherer [24], η μέγιστη συγκέντρωση είναι υψηλότερη από τη μέση συγκέντρωση επειδή επιλέγει πιο σημαντικά χαρακτηριστικά, παρέχει ταχύτερη σύγκλιση μοντέλων και καλύτερα και πιο γενικά αποτελέσματα.

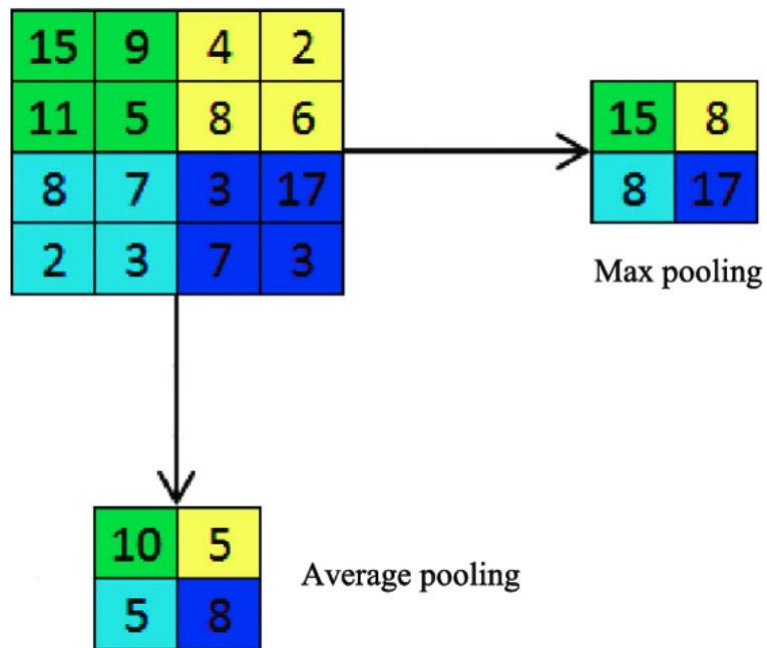
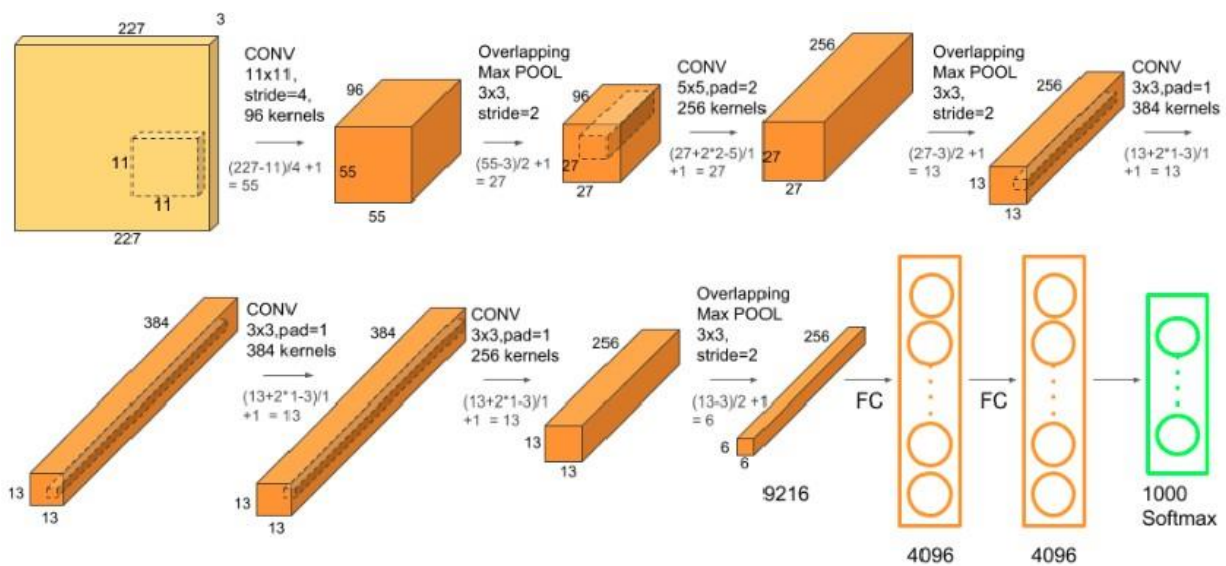


Figure 8 Συγκέντρωση μέσης και μέγιστης τιμής ΠΗΓΗ Wikipedia.org

Οι πιο συνηθισμένες τιμές υπερ-παραμέτρων για το επίπεδο συγκέντρωσης είναι πυρήνας 2x2 και βήμα μετατόπισης $S=2$. Οι τιμές αυτές προσφέρουν υποτετραπλασιασμό των αρχικών δεδομένων. Για παράδειγμα αν έχουμε έναν πίνακα διαστάσεων 100x100x256, το αποτέλεσμα μετά το επίπεδο συγκέντρωσης θα είναι 50x50x256.

1.4.3.3 Περίληψη συνελκτικών δικτύων

Εν ολίγοις, οι πληροφορίες εισάγονται στο δίκτυο σύγκλισης με τη μορφή πίνακα. Ο πίνακας διέρχεται από μια σειρά κρυφών στρωμάτων, τα οποία αποτελούνται από συμφωνικά επίπεδα ή συμφωνικά επίπεδα συνδεδεμένα σε σειρά με ένα συγκεντρωμένο επίπεδο. Σε αυτή τη διαδρομή, το μέγεθος του πίνακα πληροφοριών θα αλλάξει και οι πιο χρήσιμες λειτουργίες θα επιλεγούν ανάλογα με το βάρος του χάρτη χαρακτηριστικών. Στη συνέχεια, στην έξοδο του τελευταίου κρυφού στρώματος του παραπάνω τύπου, ο πίνακας πληροφοριών μετατρέπεται σε διάνυσμα και τροφοδοτείται σε μια σειρά πλήρως συνδεδεμένων στρωμάτων. Τέλος, πριν την έξοδο, το διάνυσμα πληροφοριών περνά από ένα επίπεδο soft-max, το οποίο εκχωρεί μια πιθανότητα σε κάθε κατηγορία του αρχικού προβλήματος. Η παρακάτω εικόνα δείχνει ένα παράδειγμα.



AlexNet Network - Structural Details													
Input			Output			Layer	Stride	Pad	Kernel size		in	out	# of Param
227	227	3	55	55	96	conv1	4	0	11	11	3	96	34944
55	55	96	27	27	96	maxpool1	2	0	3	3	96	96	0
27	27	96	27	27	256	conv2	1	2	5	5	96	256	614656
27	27	256	13	13	256	maxpool2	2	0	3	3	256	256	0
13	13	256	13	13	384	conv3	1	1	3	3	256	384	885120
13	13	384	13	13	384	conv4	1	1	3	3	384	384	1327488
13	13	384	13	13	256	conv5	1	1	3	3	384	256	884992
13	13	256	6	6	256	maxpool5	2	0	3	3	256	256	0
						fc6			1	1	9216	4096	37752832
						fc7			1	1	4096	4096	16781312
						fc8			1	1	4096	1000	4097000
Total												62,378,344	

Figure 9 AlexNet. ΠΗΓΗ <https://towardsdatascience.com/>

1.5 Αναδρομικά νευρωνικά δίκτυα - RNN

Βασικό πρόβλημα των νευρωνικών δικτύων που είδαμε στις προτύτερα είναι η μοντελοποίηση συστημάτων εξαρτώμενα από τον χρόνο. Στο μοντέλο που αναλύθηκε, η έξοδος εξαρτάται μόνο από την τρέχουσα κατάσταση της εισόδου, όχι από την προηγούμενη κατάσταση. Τα αναδρομικά νευρωνικά δίκτυα λύνουν αυτό το πρόβλημα προσθέτοντας ανατροφοδότηση μεταξύ των καταστάσεων. Αυτή η παραλλαγή τους δίνει πλεονεκτήματα στη μοντελοποίηση δυναμικών συστημάτων και τους δίνει χαρακτηριστικά μνήμης. Επομένως, η έξοδος του συστήματος στο $t + 1$ εξαρτάται όχι μόνο από την είσοδο εκείνη τη στιγμή, αλλά και από τα δεδομένα από τη στιγμή t ή ακόμα και παλαιότερα. Αυτά τα δίκτυα είναι κατάλληλα για εφαρμογές που σχετίζονται με βίντεο [25], φωνή [6] [3] [26], ανάλυση χρονοσειρών [25] και οικονομικά μοντέλα [27]. Σε γενικές γραμμές, είναι ιδανικά για ακολουθιακά προβλήματα δεδομένων

1.5.1 Απλό αναδρομικό δίκτυο

Ένα αναδρομικό νευρωνικό δίκτυο αποτελείται από την είσοδο x , την έξοδο o , μία κρυφή κατάσταση h και τις παραμέτρους θ που αποτελούνται από τα βάρη και τις μεροληψίες (bias). Η γενική συνάρτηση που περιγράφει τη λειτουργία του είναι:

$$h_t = f(x_t, h_{t-1}, \theta) \quad (6)$$




Figure 10 "Ξεδίπλωμα" του RNN. ΠΗΓΗ www.datascience.eu/

Για να μπορέσουμε να κατανοήσουμε και να περιγράψουμε περαιτέρω αυτό το μοντέλο, πρέπει να το «επεκτείνουμε» στον παραπάνω υπολογιστικό γραφό, όπως φαίνεται στο σχήμα 10. Έτσι μπορούμε να ορίσουμε πώς λειτουργεί με μεγαλύτερη μαθηματική ακρίβεια:

$$a_t = Ux_t + Wh_{t-1} + b \quad (7)$$

$$h_t = \sigma_h(a_t) \quad (8)$$

$$o_t = c + v h_t \quad (9)$$

$$y_t = \sigma_y(o_t)$$

(10)

1.5.2 Long Short-Term Memory - LSTM

Το προαναφερθέν απλό αναδρομικό μοντέλο νευρωνικών δικτύων αποτυγχάνει να προσομοιώσει αποτελεσματικά τις μακροπρόθεσμες εξαρτήσεις. Αυτή η αδυναμία πηγάζει από τον αλγόριθμο εκπαίδευσης. Λόγω της οπισθοδιάδοσης του χρόνου, όσο περισσότερο προχωράμε, τόσο πιο πιθανό είναι η εκτιμώμενη κλίση να είναι πολύ μικρή ή πολύ μεγάλη, οδηγώντας στο πρόβλημα της εξαφάνισης των κλίσεων ή των εκρηκτικών κλίσεων. Μια αρχιτεκτονική για την επίλυση αυτού του προβλήματος είναι το νευρωνικό δίκτυο αναδρομικής μακροπρόθεσμης μνήμης (LSTM). [29].




Figure 11 : LSTM αρχιτεκτονική[6].

$$\begin{matrix} | \\ x_t \end{matrix}$$

Τα δομικά μέρη ενός LSTM δικτύου είναι:

- Η πύλη εισόδου (input gate) i_t
- Η πύλη εξόδου (output gate) o_t
- Η πύλη λήθης (forget gate) f_t
- Ένα κύτταρο μνήμης (memory cell) c_t
- Η κρυφή κατάσταση (hidden state) h_t

Θεωρούμε ότι x_t η είσοδος τη χρονική στιγμή t , b η μεροληψία (bias) και \odot το γινόμενο Hadamard. Τότε οι σχέσεις που περιγράφουν αυτό το μοντέλο είναι:

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (11)$$

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (12)$$

$$\tilde{c}_t = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (13)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (14)$$

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (15)$$

$$h_t = o_t \odot \tanh(c_t) \quad (16)$$

Διαισθητικά, η ερμηνεία των παραπάνω εξισώσεων και η λειτουργία του LSTM είναι η εξής:

- Αρχικά, η πύλη λήθης καθορίζει πόσες πληροφορίες από προηγούμενες καταστάσεις είναι χρήσιμες και θα πρέπει να αποθηκευτούν στην εσωτερική μνήμη.
- Η πύλη εισόδου αποφασίζει ποιες τιμές της εσωτερικής μνήμης θα ανανεωθούν.
- Η μεταβλητή c_t περιέχει υποψήφια πρόσθετα για εσωτερική μνήμη
- Η εσωτερική μνήμη περιέχει όλες τις πληροφορίες από τις τρέχουσες και προηγούμενες συνθήκες. Από το (14) μπορούμε να δούμε ότι η προηγούμενη τιμή της μνήμης πολλαπλασιάζεται με την έξοδο της λήθης πύλης και η νέα υποψήφια τιμή c_t πολλαπλασιάζεται με την πύλη.
- Η πύλη εξόδου καθορίζει ποια είναι τα σημαντικά μέρη της τρέχουσας εσωτερικής μνήμης και τα φιλτράρει σύμφωνα με το (16), παρέχοντάς μας έτσι μια νέα κρυφή κατάσταση, η οποία είναι η τελική έξοδος του συστήματος

1.5.3 Gated Recurrent Unit – GRU

Μια παραλλαγή της αρχιτεκτονικής LSTM είναι η GRU που προτείνεται από τον Kyunghyun Cho. Η αρχιτεκτονική GRU είναι μια απλούστερη μορφή LSTM επειδή μειώνει τον αριθμό των πυλών και η μονάδα μνήμης είναι ενσωματωμένη στην κρυφή κατάσταση. Η πύλη που ελέγχει τη ροή των πληροφοριών είναι η πύλη επαναφοράς r_t και η πύλη πληροφοριών

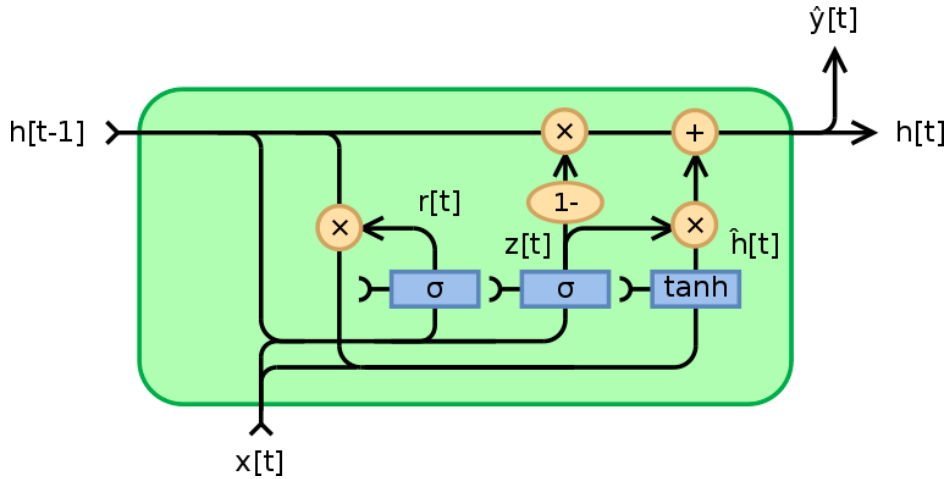


Figure 12 GRU αρχιτεκτονική ΠΗΓΗ https://commons.wikimedia.org/wiki/File:Gated_Recurrent_Unit_base_t

Οι εξισώσεις που περιγράφουν τη λειτουργία της είναι:

$$z_t = \sigma(W_z \cdot x_t + U_z \cdot h_{t-1} + b_z) \quad (17)$$

$$r_t = \sigma(W_r \cdot x_t + U_r \cdot h_{t-1} + b_r) \quad (18)$$

$$\tilde{h}_t = \tanh(W_h \cdot x_t + U_h \cdot (r_t \odot h_{t-1}) + b_h) \quad (19)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (20)$$

Αντίστοιχα με προηγουμένως, διαισθητικά η λειτουργία της GRU αρχιτεκτονικής είναι η εξής:

- Υπολογίζεται η z_t και η r_t χρησιμοποιώντας την τωρινή και την προηγούμενη κρυφή κατάσταση.
- Υπολογίζεται η υποψήφια τωρινή κρυφή κατάσταση h_t με την πύλη επαναφοράς να ελέγχει πόση από την πληροφορία της προηγούμενης κρυφής κατάστασης θα χρησιμοποιηθεί.
- Τέλος υπολογίζεται η έξοδος, δηλαδή η νέα κρυφή κατάσταση με την πύλη ενημέρωσης να ελέγχει πόση πληροφορία θα πάρει από την υποψήφια τωρινή κατάσταση και πόση από την προηγούμενη κρυφή κατάσταση.

Το πλεονέκτημα της GRU αρχιτεκτονικής έχει να κάνει με την ταχύτητα, μίας και έχοντας μία πύλη λιγότερη, οι πολλαπλασιασμοί πινάκων που πρέπει να γίνουν μειώνονται. Σε σχέση με τα αποτελέσματα όμως, συμφωνά με τις δοκιμές που έχουν γίνει [31], σε μεγάλα σετ δεδομένων τα

GRU δίκτυα έχουν χειρότερη απόδοση από τα LSTM δίκτυα. Οπότε σε περιπτώσεις που δεν υπάρχουν περιορισμοί υπολογιστικής ισχύος τα LSTM προτιμούνται.

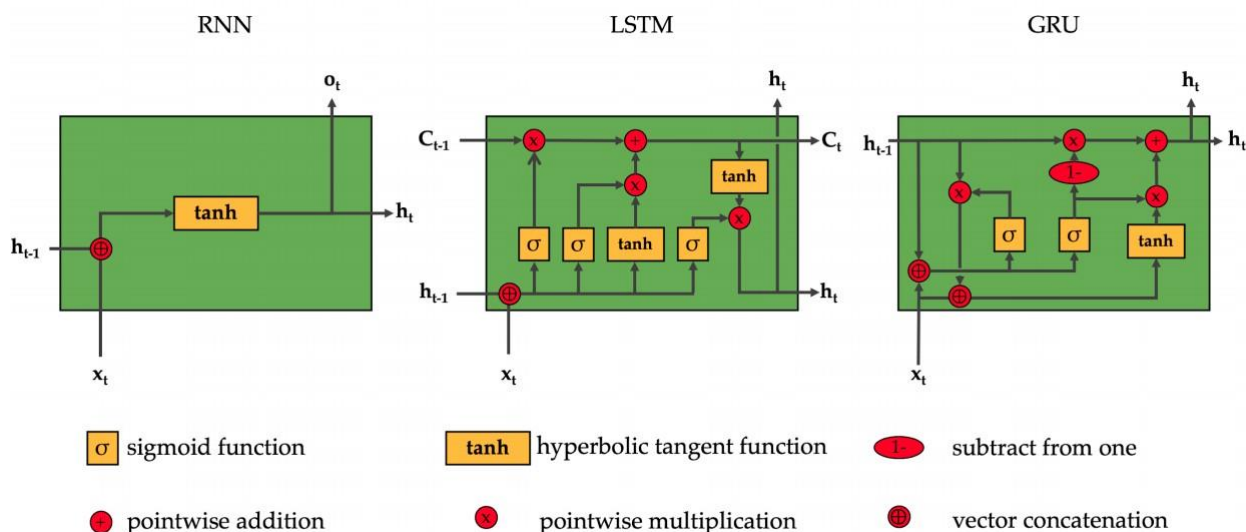


Figure 13 Σχηματική σύγκριση των αρχιτεκτονικών RNN [80]

1.5.4 Αναδρομικά νευρωνικά δίκτυα διπλής κατεύθυνσεως

Μέχρι στιγμής, σε όλες τις αναδρομικές αρχιτεκτονικές νευρωνικών δικτύων που έχουμε εξετάσει, η ροή των πληροφοριών είναι μόνο προς μία κατεύθυνση και εξετάζεται μόνο η προηγούμενη κατάσταση. Ωστόσο, σε πολλές περιπτώσεις, μπορούμε να αντλήσουμε χρήσιμες πληροφορίες για την κατάσταση από μελλοντικές καταστάσεις. Από αυτή την παρατήρηση, προέκυψε η ιδέα ενός αμφίδρομου ή αμφίδρομου ανάδρομου νευρωνικού δικτύου [4]. Ουσιαστικά, τα αμφίδρομα ανάδρομα δίκτυα είναι δύο ανάδρομα δίκτυα που επεξεργάζονται δεδομένα εισόδου αντίστροφα. Αυτό κάνει την έξοδο τη χρονική στιγμή t να εξαρτάται από τις τρέχουσες, παρελθούσες και μελλοντικές συνθήκες. Το σχηματικό διάγραμμα για να μας βοηθήσει να το κατανοήσουμε καλύτερα φαίνεται στο παρακάτω σχήμα.




Figure 14 Δομή αμφίδρομου αναδρομικού δικτύου. ΠΗΓΗ <https://towardsdatascience.com/understanding-bidirectional-rnn-in-pytorch-5bd25a5dd66>

1.6 Εκπαίδευση νευρωνικών δικτύων

1.6.1 Αλγόριθμοι βελτιστοποίησης

Ο αλγόριθμος βελτιστοποίησης είναι βασικό μέρος της εκπαίδευσης των νευρωνικών δικτύων. Ο σκοπός αυτών των αλγορίθμων είναι να βρουν κατάλληλες παραμέτρους συστήματος για την ελαχιστοποίηση της συνάρτησης Κόστους/Απώλειας. Ουσιαστικά ορίζουν ένα μαθηματικό μοντέλο στο οποίο οι παράμετροι του συστήματος θα αλλάξουν έτσι ώστε να συγκλίνουν στο καλύτερο μοντέλο..

1.6.1.1 Gradient Descent

Ο αλγόριθμος gradient descent είναι ο πιο διάσημος αλγόριθμος βελτιστοποίησης στα νευρωνικά δίκτυα και είναι επίσης η βάση των περισσότερων αλγορίθμων βελτιστοποίησης που χρησιμοποιούνται σήμερα. Όπως και άλλοι αλγόριθμοι βελτιστοποίησης, σκοπός του είναι να βρει τις παραμέτρους που οδηγούν στη μικρότερη συνάρτηση σφάλματος. Αυτό επιτυγχάνεται μέσω μιας επαναληπτικής διαδικασίας που ενημερώνει τις παραμέτρους του συστήματος με βάση την κλίση της συνάρτησης σφάλματος παραμέτρου. Αν θεωρήσουμε ως παραμέτρους του συστήματος το w και το b τότε:

$$w_{new} = w_{old} - lr \cdot \nabla_w J(x, y; w, b) \quad (21)$$

$$b_{new} = b_{old} - lr \cdot \nabla_b J(x, y; w, b) \quad (22)$$

ο lr είναι μια υπερπαραμέτρος που ονομάζεται ρυθμός εκμάθησης. Ο τρόπος επιλογής του είναι πολύ σημαντικός, γιατί η επιλογή μιας μεγάλης τιμής θα προκαλέσει μεγάλη αλλαγή στις παραμέτρους και μπορεί να προκαλέσει συνεχείς αποτυχίες απόπειρες εύρεσης της συνάρτησης μικρότερου κόστους. Αντίθετα, μια πολύ μικρή τιμή του ρυθμού εκμάθησης μπορεί να καθυστερήσει σημαντικά τη σύγκλιση του αλγορίθμου στο ελάχιστο.

- Ο βασικός αλγόριθμος gradient descent ή batch gradient descent σε κάθε επανάληψη θα αναβαθμίσει τις παραμέτρους του συστήματος για κάθε στοιχείο του συνόλου εκπαίδευσης, το οποίο είναι πολύ ακριβό για πολύ μεγάλα σύνολα δεδομένων. Αυτή η λύση συνοδεύεται από δύο παραλλαγές του αλγορίθμου gradient descent, δηλαδή στοχαστική gradient descent και mini-batch gradient descent. Έτσι διακρίνουμε τις ακόλουθες τρεις καταστάσεις:

- Batch Gradient Descent: Αναβάθμιση των εκπαιδευσίμων παραμέτρων λαμβάνοντας υπόψη όλο το σύνολο (batch) του σετ εκπαίδευσης:

- $\theta = \theta - lr \nabla_{\theta} J(x^{1:N}, y^{1:N}; \theta)$

- Stochastic Gradient Descent: Αναβάθμιση των εκπαιδευσίμων παραμέτρων λαμβάνοντας υπόψη ένα τυχαίο δείγμα από το σύνολο του σετ εκπαίδευσης:

$$\theta = \theta - lr \nabla_{\theta} J(x^i, y^i; \theta) \text{ όπου } i \text{ ένα τυχαίο δείγμα.}$$

- Mini-Batch Gradient Descent: Αναβάθμιση των εκπαιδευσίμων παραμέτρων λαμβάνοντας

υπόψη ενός υποσυνόλου του σετ εκπαίδευσης κάθε φορά:

$$\vartheta = \vartheta - lr \nabla J(x^{i:i+m}, y^{i:i+m}; \vartheta)$$

Η τρίτη κατάσταση είναι η χρυσή τομή μεταξύ των δύο πρώτων. Αν και στην πρώτη έχουμε μια πιο ήπια διαδρομή που σίγουρα θα είναι πιο κοντά στην ελάχιστη τιμή που ψάχνουμε μετά από κάθε επανάληψη, θα χρειαστεί πολύς χρόνος για να την εφαρμόσουμε. Στη δεύτερη περίπτωση, έχουμε μειώσει πολύ τον χρόνο, αλλά η διαδρομή θα είναι πιο απότομη και δεν υπάρχει εγγύηση σύγκλισης στο ελάχιστο. Ο σκοπός της τρίτης περίπτωσης είναι να διατηρήσει τον ενθουσιασμό των άλλων δύο περιπτώσεων, δηλαδή να υπάρχει μια ομαλή διαδρομή για να φτάσουμε στο ελάχιστο της συνάρτησης κόστους και να μειώσουμε τον χρόνο [24].




Figure 15 Διαδρομή σύγκλισης των διαφορετικών τύπων gradient descent. ΠΗΓΗ <https://suniljangirblog.wordpress.com/2018/12/13/variants-of-gradient-descent/>

1.6.1.2 Gradient Descent με momentum

Στην περίπτωση που η κλίση της συνάρτησης κόστους είναι πολύ κυρτή, ο αλγόριθμος gradient descent αντιμετωπίζει πολλές δυσκολίες, δηλαδή είναι τοπικά ελάχιστα. Σε αυτή την περίπτωση, οι παράγωγοι τείνουν προς την κατεύθυνση του τοπικού ελαχίστου, το οποίο μπορεί να μην οδηγήσει στο συνολικό ελάχιστο, και πολλές φορές μπορούν να ταλαντωθούν γύρω από αυτά τα σημεία για μεγάλο χρονικό διάστημα. Η λύση σε αυτό το πρόβλημα προέρχεται από μια τεχνολογία που ονομάζεται GRD με momentum. Ουσιαστικά, αυτή περιέχει πληροφορίες που σχετίζονται με προηγούμενες αλλαγές παραμέτρων. Εάν το ρεύμα και οι προηγούμενες αλλαγές δείχνουν προς την ίδια κατεύθυνση, τότε καθώς η ορμή πιέζει προς τη σωστή κατεύθυνση, η σύγκλιση θα επιταχυνθεί. Εάν η κατεύθυνση της αλλαγής είναι διαφορετική, τότε κανονικοποιεί την ταλάντωση της διαδρομής στο συνολικό ελάχιστο [24].

$$m_t = \beta m_{t-1} - lr \nabla_{\theta} J(\theta_{t-1}) \quad (23)$$

$$\vartheta_t = \vartheta_{t-1} + m_t \quad (24)$$




Figure 16 Αριστερά η διαδρομή που ακολουθείτε με την τεχνική gradient descent χωρίς momentum και δεξιά με momentum ΠΗΓΗ <https://towardsdatascience.com/stochastic-gradient-descent-with-momentum-a84097641a5d>.

Μια παραλλαγή του grad momentum είναι το Νεστόροφ momentum. Από την κλασική ορμή, διαφέρει μιας και βασίζεται στη θέση θ_t βάσει παραμέτρων για τον υπολογισμό της κλίσης, εισάγεται επίσης η έννοια της ταχύτητας. Υπολογίστε λοιπόν τη νέα προσωρινή θέση $\tilde{\theta} = \theta + \beta m$ και στη συνέχεια υπολογίστε την κλίση σύμφωνα με τον παραπάνω τύπο ορμής

$$m_t = \beta m_{t-1} - lr \nabla_{\theta_{t-1}} J(\theta_{t-1} + \beta m_{t-1}) = \beta m_{t-1} - lr \nabla_{\theta_{t-1}} J(\tilde{\theta}) \quad (25)$$

$$\theta_t = \theta_{t-1} + m_t \quad (26)$$

1.6.1.3 RMSProp




Figure 17 Διαφορά μεταξύ απλού και Nesterov momentum ΠΗΓΗ https://golden.com/wiki/Nesterov_momentum

Ο αλγόριθμος RMSProp προτάθηκε από τον Geoff Hinton. Αν και δεν έχει κυκλοφορήσει επίσημα, έχει χρησιμοποιηθεί σε πολλές εφαρμογές. Αυτός ο αλγόριθμος ανήκει στην οικογένεια των αλγορίθμων προσαρμοστικού ρυθμού μάθησης. Το κύριο χαρακτηριστικό αυτών των αλγορίθμων είναι ότι προσαρμόζουν τον ρυθμό εκμάθησης κάθε παραμέτρου σε κάθε βήμα. Αυτή η προσαρμογή πραγματοποιείται διατηρώντας τον κινητό μέσο όρο του τετραγώνου της κλίσης κάθε στοιχείου.

Στη συνέχεια, διαιρέστε αυτόν τον μέσο όρο με τον νέο όρο κλίσης.

$$E[g^2]_t = \beta \cdot E[g^2]_{t-1} + (1-\beta)g_t^2 \quad (27)$$

$$\theta_t = \theta_{t-1} - \frac{lr}{\sqrt{E[g^2]_t + \varepsilon}} \cdot g_t \quad (28)$$

Όπου lr είναι ο μη προσαρμοσμένος ρυθμός εκμάθησης, θ_t είναι το διάνυσμα παραμέτρων του χρόνου t , g_t είναι το διάνυσμα κλίσης της συνάρτησης κόστους και $E[g^2]_t$ είναι ο κινητός μέσος όρος του τετραγώνου της κλίσης. Επιπλέον, το β είναι μια υπερπαραμέτρος που καθορίζει τις πληροφορίες που κατέχονται από την προηγούμενη τιμή και το ε είναι ένας πολύ μικρός όρος που χρησιμοποιείται για την προστασία της βαθμολογίας της σχέσης (28) από τη διαίρεση με το μηδέν. Οι συνιστώμενες τιμές των παραμέτρων lr , β , ε είναι 0,001, 0,9 και 10^{-8} .

1.6.1.4 Adam

Ο αλγόριθμος του Adam [11] είναι ίσως ο πιο ευρέως χρησιμοποιούμενος. Συνδυάζει το RMSProp με την μέθοδο GRD με momentum. Αυτός ο αλγόριθμος χρησιμοποιεί τον κινητό μέσο όρο m_t της κλίσης g_t και τον κινητό μέσο όρο v_t του τετραγώνου της κλίσης g_t . Ταυτόχρονα, διατηρεί τις πληροφορίες του κινούμενου μέσου όρου από την προηγούμενη κατάσταση. Η εξίσωση που περιγράφει τη συνάρτησή του είναι [23]:

$$m_t = \beta_1 \cdot m_{t-1} + (1-\beta_1)g_t \quad (29)$$

$$v_t = \beta_2 \cdot v_{t-1} + (1-\beta_2)g_t^2 \quad (30)$$

$$\hat{m}_t = \frac{m_t}{1-\beta_1^t} \quad (31)$$

$$\hat{v}_t = \frac{v_t}{1-\beta_2^t} \quad (32)$$

$$\theta_t = \theta_{t-1} - lr \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \varepsilon}} \quad (33)$$




Figure 19 Σύγκριση μεταξύ των αλγορίθμων βελτιστοποίησης σε ένα CNN με το MNIST σετ δεδομένων. ΠΗΓΗ <https://towardsdatascience.com/neural-network-optimization-algorithms-1a44c282f61d>

Στην πραγματικότητα, οι κινητοί μέσοι όροι m_t και v_t είναι προσεγγίσεις της πρώτης και της δεύτερης ροπής των κλίσεων των συναρτήσεων κόστους $E [g_t]$ και $E [g_t^2]$, αντίστοιχα. Εφόσον η αρχικοποίηση κάνει $m_0 = v_0 = 0$, εισάγονται ορισμένα σφάλματα σε αυτές τις μεθόδους. Διορθώστε αυτά τα σφάλματα εισάγοντας τις εξισώσεις (31) και (32). Τα β_1 και β_2 είναι υπερπαραμέτροι που ελέγχουν την προηγούμενη πληροφορία κινητού μέσου όρου. Οι τιμές τους ορίζονται σε 0,9 και 0,999 και σπάνια αλλάζουν. Το Lr είναι ο μη προσαρμοσμένος ρυθμός εκμάθησης, συνήθως 0,001, και το ϵ χρησιμοποιείται για να αποτρέψει τη διαίρεση της βαθμολογίας της συνάρτησης (33) με το μηδέν και η τιμή του είναι συνήθως 10^{-8} .

Αν και ο αλγόριθμος Adam έχει επιτύχει αρχική επιτυχία λόγω της γρήγορης σύγκλισης, δεν έχει συγκλίνει στη βέλτιστη λύση σε όλα τα πεδία εφαρμογής. Για παράδειγμα, πολλά από τα πιο προηγμένα αποτελέσματα ταξινόμησης εικόνων χρησιμοποιώντας το σύνολο δεδομένων CIFAR εξακολουθούν να επιτυγχάνονται χρησιμοποιώντας ορμή SGD. Σύμφωνα με το δημοσίευμα του Ashia c. Willson, όταν τα στοιχεία του συνόλου δεδομένων παρουσιάζουν μεγάλη ποικιλομορφία, οι αλγόριθμοι που χρησιμοποιούν προσαρμοστικές μεθόδους δεν θα έχουν τέτοια γενικά αποτελέσματα. Μια άλλη δημοσίευση έδειξε ότι με τη χρήση του αλγόριθμου Adam στα πρώτα στάδια της εκπαίδευσης, όταν το πρότυπο SGD πληρείται, το αποτέλεσμα θα φτάσει στο επίπεδο γενίκευσης του SGD με ορμή [23].

1.6.2 Αλγόριθμοι εύρεσης βαρών

Όλες οι τεχνικές βελτιστοποίησης που αναφέρονται παραπάνω στοχεύουν στην εύρεση των καλύτερων παραμέτρων με το μικρότερο σφάλμα. Προϋπόθεση για αυτό είναι να βρεθεί η κλίση της συνάρτησης κόστους με βάση τις παραμέτρους κάθε βήματος. Αυτό επιτυγχάνεται μέσω ενός από τους πιο γνωστούς αλγόριθμους, ο οποίος ονομάζεται αλγόριθμος backpropagation των feedforward νευρωνικών δικτύων, και μια παραλλαγή του, ο αλγόριθμος backpropagation through time που χρησιμοποιείται για τις αναδρομικές

1.6.2.1 Backpropagation

Έστω ότι έχουμε ένα σετ δεδομένων εκπαίδευσης $D: \{x_i, y_i : i=1..N\}$ όπου x_i το διάνυσμα εισόδου και y_i το διάνυσμα της πραγματικής τιμής της εξόδου για το στοιχείο i . Έστω επίσης νευρωνικό δίκτυο L επιπέδων όπου κάθε επίπεδο έχει $M = \{M_1, M_2, \dots, M_L\}$ νευρώνες. Άρα έχουμε M_1 στοιχεία στην είσοδο, M_L στοιχεία στην έξοδο και $L-2$ κρυφά επίπεδα.




Figure 21 Multilayer Perceptron

Ο σκοπός της backpropagation είναι να βρεθεί η τιμή κλίσης της συνάρτησης κόστους σε σχέση με το βάρος, έτσι ώστε να βελτιστοποιηθεί ο αλγόριθμος για την ανανέωση του βάρους. Ας υποθέσουμε ότι ως συνάρτηση σφάλματος, έχουμε το μέσο τετραγωνικό σφάλμα του που στοιχείου του συνόλου δεδομένων:

$$E(n) = \frac{1}{M_L} \sum_{i=1}^{M_L} (x_i^{[L]}(n) - y_i(n))^2 \quad (34)$$

Έτσι λοιπόν ο backpropagation αλγόριθμος θέλει να υπολογίσει τη μεταβολή (gradient) που πρέπει να γίνει σε όλα τα βάρη των συνάψεων μεταξύ των νευρώνων:

$$\Delta w_{ki}^{[l-1]} = -lr \frac{\partial E(n)}{\partial w_{ki}^{[l-1]}(n)} \quad (35)$$

Όπου i ο νευρώνας του επιπέδου $l-1$ που ξεκινάει η σύναψη και k ο νευρώνας του επιπέδου l που καταλήγει. Η μεταβλητή lr είναι ο ρυθμός μάθησης.

Αρχικά ορίζουμε την τιμή ενεργοποίησης $z_i^{[l]}$ κάθε νευρώνα δηλαδή την τιμή της εξόδου του νευρώνα πριν εφαρμοστεί η συνάρτηση ενεργοποίησης $\sigma_i(\cdot)$

$$x_i^{[l]} = \sigma_i(z_i^{[l]}(n)) \quad (36)$$




Figure 23 Backpropagation στο επίπεδο της εξόδου.

Ο αλγόριθμος εκπαίδευσης έχει δύο βήματα:

1. Εμπρόσθια Τροφοδοσία όπου οι πληροφορίες εισόδου μεταβιβάζονται από τον ένα νευρώνα στον άλλο μέχρι να φτάσουν στην έξοδο

2. Το Backpropagation που συγκρίνει την πρόβλεψη (τιμή εξόδου) με την πραγματική τιμή, βρίσκουμε πόσο πρέπει να αλλάξει κάθε παράμετρος συστήματος (βάρη και αποκλίσεις) προκειμένου να μειωθούν τα σφάλματα και να ληφθούν καλύτερες προβλέψεις.

Ο αλγόριθμος backpropagation ξεκινά από το τελευταίο στρώμα. Ας υποθέσουμε ότι βρισκόμαστε στον νευρώνα k στο επίπεδο εξόδου και θέλουμε να βρούμε την αλλαγή (βαθμίδα) που πρέπει να εφαρμοστεί στο βάρος της σύναψης που παράγεται από τον νευρώνα i στο προηγούμενο στρώμα:

$$\Delta_{w_{ki}}^{[L-1]} = -lr \cdot \frac{\partial E(n)}{\partial w_{ki}^{[L-1]}(n)}$$

Από την εικόνα 19 φαίνεται ότι στον υπολογισμό της τιμής του $x_k^{[L]}$ του νευρώνα k του επιπέδου L , συνεισφέρουν όλοι οι νευρώνες του προηγούμενου επιπέδου. Άρα παίρνουμε τη συνάρτηση:

$$x_k^{[L]}(n) = \sigma(\sum_{i=1}^{M_{L-1}} w_{ki}^{[L-1]} x_i^{[L-1]} + b^{[L-1]}) \quad (38)$$

Όπου σ η συνάρτηση ενεργοποίηση και b η σταθερά μεροληψίας/bias. Επίσης η τιμή ενεργοποίησης του νευρώνα:

$$z_k^{[L]} = \sum_{i=1}^{M_{L-1}} w_{ki}^{[L-1]}(n) x_i^{[L-1]} + b^{[L-1]} \quad (39)$$




Figure 25 Ροή πληροφορίας νευρώνα από το νευρώνα i στο νευρώνα k του επιπέδου εξόδου.

Από το σχήμα 20 και σύμφωνα με τον κανόνα της αλυσίδας του διαφορικού λογισμού:

$$\frac{\partial E(n)}{\partial w_{ki}^{[L-1]}(n)} = \frac{\partial z_k^{[L]}(n)}{\partial w_{ki}^{[L-1]}(n)} * \frac{\partial x_k^{[L]}(n)}{\partial z_k^{[L]}(n)} * \frac{\partial E(n)}{\partial x_k^{[L]}(n)} \quad (40)$$

Παραγωγίζοντας τη συνάρτηση (39) :

$$\frac{\partial z_k^{[L]}(n)}{\partial w_{ki}^{[L-1]}(n)} = x_i^{[L-1]}(n) \quad (41)$$

Αντίστοιχα την (36):

$$\frac{\partial x_k^{[L]}(n)}{\partial z_k^{[L]}(n)} = \sigma_k \left(z_k^{[L]}(n) \right) \quad (42)$$

Δηλαδή παίρνουμε την παράγωγο της συνάρτησης ενεργοποίησης και για αυτό το λόγο επιλέγουμε μία μη γραμμική παραγωγίσιμη συνάρτηση ενεργοποίησης αντί για τη βηματική που θα έχει παράγωγο 0.

Τέλος από την (34) προκύπτει:

$$\frac{\partial E(n)}{\partial x_k^{[L]}(n)} = \frac{2}{M_L} * \left(x_k^{[L]}(n) - y_k(n) \right) = \frac{2}{M_L} e_k(n) \quad (43)$$

Συνδυάζοντας την (41) , την (42) και την (43) προκύπτει η τιμή της μεταβολής του βάρους της σύνδεσης μεταξύ i και k:

$$\Delta w_{ki}^{[L-1]}(n) = -lr \frac{\partial E(n)}{\partial w_{ki}^{[L-1]}(n)} = -lr x_i^{[L-1]}(n) \cdot \sigma'_k \left(z_k^{[L]}(n) \right) \frac{2}{M_L} \cdot e_k(n) \quad (44)$$

$$\text{Θέτοντας } \delta_k^{[L]}(n) = \sigma'_k \left(z_k^{[L]}(n) \right) \frac{2}{M_L} \cdot e_k(n) \text{ παίρνουμε:} \quad (45)$$

$$\Delta w_{ki} = -lr \cdot x_i^{[L-1]}(n) \cdot \delta_k^{[L]}(n) \quad (46)$$

Η ίδια διαδικασία επαναλαμβάνεται αναδρομικά και για τα βάρη των προηγούμενων επιπέδων.

$$\frac{\partial E(n)}{\partial w_{ij}^{[L-2]}(n)} = \frac{\partial z_j^{[L-1]}(n)}{\partial w_{ij}^{[L-2]}(n)} * \frac{\partial x_i^{[L-1]}(n)}{\partial z_j^{[L-1]}(n)} * \frac{\partial E(n)}{\partial x_i^{[L-1]}(n)} \quad (47)$$




Figure 26 Ροή πληροφορίας από το $l-2$ στο l .

Όπου z_{ij} η τιμή ενεργοποίησης του νευρώνα i του επιπέδου $L-1$ που προέρχεται από το νευρώνα j του επιπέδου $L-2$:

$$z_{ij}^{[L-1]}(n) = w_{ij}^{[L-2]}(n) \cdot x_j^{[L-2]}(n) + b^{[L-2]} \quad (48)$$

Αντίστοιχα όπως στην (39) η συνολική τιμή ενεργοποίησης του νευρώνα i του επιπέδου $L-1$:

$$z_i^{[L-1]}(n) = \sum_{j=1}^{M_{L-2}} z_{ij}^{[L-1]}(n) = \sum_{j=1}^{M_{L-2}} (w_{ij}^{[L-2]}(n) \cdot x_j^{[L-2]}(n) + b^{[L-2]}) \quad (49)$$

$$\text{και } x_i^{[L-1]}(n) = \sigma_i(z_i^{[L-1]}(n)) = \sigma\left(\sum_{j=1}^{M_{L-2}} (w_{ij}^{[L-2]}(n) \cdot x_j^{[L-2]}(n) + b^{[L-2]})\right) \quad (50)$$




Figure 27 Ροή πληροφορίας από το νευρώνα j του επιπέδου L-2 στο νευρώνα i του επιπέδου L-1.

Αρχικά από το σχήμα 22 και με βάση τον κανόνα της αλυσίδας του διαφορικού λογισμού:

$$\frac{\partial E(n)}{\partial x_i^{[L-1]}(n)} = \sum_{k=1}^{M_L} \frac{\partial z_k^{[L]}(n)}{\partial x_i^{[L-1]}(n)} \cdot \frac{\partial x_k^{[L]}(n)}{\partial z_k^{[L]}(n)} \cdot \frac{\partial E(n)}{\partial x_k^{[L]}(n)} \quad (51)$$

Παραγωγίζοντας την (34) , (36) και (39) προκύπτει:

$$\frac{\partial E(n)}{\partial x_i^{[L-1]}(n)} = \sum_{k=1}^{M_L} w_{ki}^{[L-1]}(n) \cdot \sigma'_k(z_k^{[L]}(n)) \cdot \left(\frac{2}{M_L}\right) \cdot e(n) \quad (52)$$

Από την (48) προκύπτει:

$$\frac{\partial z_{ij}^{[L-1]}(n)}{\partial w_{ij}^{[L-2]}(n)} = x_j^{[L-2]}(n) \quad (53)$$

$$\text{και } \frac{\partial x_i^{[L-1]}(n)}{z_i^{[L-1]}(n)} = \sigma'_i(z_i^{[L-1]}(n)) \quad (54)$$

Άρα από την (52),(53), 54) και την (45) προκύπτει:

$$\frac{\partial E(n)}{\partial w_{ij}^{[L-1]}(n)} = x_i^{[L-2]}(n) \cdot \sigma'_i(z_i^{[L-1]}(n)) \cdot \sum_{k=1}^{M_L} \delta_k^L(n) w_{ki}(n)^{[L-1]} \quad (55)$$

$$\text{Θέτοντας } \delta_i^{[L-1]}(n) = \sigma'_i(z_i^{[L-1]}(n)) \cdot \sum_{k=1}^{M_L} \delta_k^L(n) w_{ki}^{[L-1]}(n) \text{ καταλήγουμε:} \quad (56)$$

$$\Delta w_{ij}^{[L-2]}(n) = -lr \cdot x_j^{[L-2]}(n) \cdot \delta_i^{[L-1]}(n) \quad (57)$$

Ανακεφαλαιώνοντας , για κάθε ένα από τα Ν στοιχεία του σετ δεδομένων, υπολογίζονται οι διορθώσεις όλων των συναπτικών βαρών μεταξύ των νευρώνων. Έτσι αν η σύναψη που ενώνει τους κόμβους i ενός επιπέδου l-1 και j ενός επιπέδου l, τότε:

$$\Delta w_{ji}^{[l-1]}(n) = -lr \cdot x_j^{[l-1]}(n) \cdot \delta_j^{[l]}(n) \quad (58)$$

Και διακρίνουμε τις δύο εξής περιπτώσεις:

1. Αν ο j νευρώνας ανήκει στο επίπεδο εξόδου, δηλαδή l=L, τότε:

$$\delta_j^{[L]}(n) = \frac{2}{M_L} \cdot e(n) \cdot \sigma_j'(z_j^{[L]}(n)) \quad (59)$$

$$\text{όπου } z_j^{[L]}(n) = \sum_{i=1}^{M_{L-1}} (w_{ji}^{[L-1]}(n) \cdot x_i^{[L-1]}(n) + b^{[L-1]}) .$$

2. Αν ο νευρώνας j ανήκει σε ένα κρυφό επίπεδο:

$$\delta_j^{[l]}(n) = \sigma_j'(z_j^{[l]}(n)) \cdot \sum_{k=1}^{M_{l+1}} (\delta_k^{[l+1]}(n) w_{kj}^{[l]}(n)) \quad (60)$$

$$\text{Όπου } z_j^l = \sum_{m=1}^{M_{l-1}} (w_{jm}^{[l-1]}(n) \cdot x_m^{[l-1]}(n) + b^{[l-1]}) .$$

Μέσο τετραγωνικό σφάλμα – Mean squared error

Το μέσο τετραγωνικό σφάλμα είναι η πιο διάσημη και απλούστερη συνάρτηση σφάλματος. Είναι ουσιαστικά ένα μέτρο, μας δείχνει την απόσταση μεταξύ της προβλεπόμενης εξόδου του συστήματος και της πραγματικής εξόδου y_n .

1.6.3 Συναρτήσεις σφάλματος ή κόστους

Η συνάρτηση σφάλματος ή κόστους είναι απαραίτητο στοιχείο για την εκπαίδευση νευρωνικών δικτύων και την ποιοτική αξιολόγησή του. Ανάλογα με τον τύπο της εφαρμογής, υπάρχουν πολλές συναρτήσεις σφάλματος που μπορούν να παράγουν διαφορετικά αποτελέσματα. Παρακάτω θα δούμε μερικά από τα πιο συνηθισμένα. Αυτή η συνάρτηση σφάλματος είναι κατάλληλη για εφαρμογές παλινδρόμησης, όπου η τιμή που πρέπει να προβλεφθεί από το νευρωνικό δίκτυο είναι συνεχής ή πραγματική.

1.6.3.1 Εγκάρσια εντροπία – Cross-Entropy

Η συνάρτηση σφάλματος πλευρικής εντροπίας προέρχεται από τη θεωρία πληροφοριών, όπου η πλευρική εντροπία μεταξύ των δύο κατανομών p και q της τυχαίας μεταβλητής X μας λέει εάν η κωδικοποίηση μπορεί να βασίζεται στην κατανομή q αντί στην πραγματική κατανομή p . Ουσιαστικά, η εγκάρσια εντροπία είναι ένα μέτρο σύγκρισης μεταξύ δύο κατανομών.

Στα νευρωνικά δίκτυα, η πλευρική εντροπία χρησιμοποιείται για προβλήματα ταξινόμησης, δηλαδή το πρόβλημα των εισόδων που πρέπει να αντιστοιχιστούν σε μία από τις πιθανές κλάσεις K . Σε αυτήν την περίπτωση, η πλευρική εντροπία είναι ένα μέτρο της σύγκρισης μεταξύ της προβλεπόμενης εξόδου y' και της πραγματικής εξόδου y και υπολογίζεται. Σύμφωνα με τον τύπο:

$$J_{crossEntropy} = - \sum_{i=0}^k (y_i \cdot \log(\hat{y}_i))$$

Όπου το K είναι μια συλλογή κλάσεων. Είναι επίσης σημαντικό να τονίσουμε τι είναι τα σύμβολα πιθανότητας, ώστε να κυμαίνονται από τιμές 0 έως 1. Έτσι, για παράδειγμα, για έξοδο, εάν μια συγκεκριμένη είσοδος ανήκει στην κλάση $i = 2$ και η έξοδος είναι $[0, 0, 1, 0]$, για παράδειγμα, μπορεί να είναι $[0,1, 0,3, 0,6, 0,1]$.

1.6.4 Τεχνικές κανονικοποίησης – Πρόβλημα overfitting

Ένα από τα πιο βασικά προβλήματα που αντιμετωπίζουν τα νευρωνικά δίκτυα είναι το γνωστό πρόβλημα του overfitting. Προβλήματα προκύπτουν όταν το μοντέλο εκπαιδεύεται «πολύ καλά» στο εκπαιδευτικό σετ, ώστε να μην μπορεί να ανταποκριθεί σε δεδομένα που δεν προέρχονται από αυτό. Για το λόγο αυτό, μερικές τεχνικές που ονομάζονται τεχνικές τακτοποίησης χρησιμοποιούνται για τη μείωση αυτού του φαινομένου και την παραγωγή μοντέλων με πιο γενικά αποτελέσματα.

1.6.4.1 Dropout

Αυτή η τεχνολογία προτάθηκε από τον Geoffrey Hinton για να λύσει το πρόβλημα της υπερεκπαίδευσης. Η τεχνική βασίζεται στην αδρανοποίηση τυχαίων νευρώνων και των συνάψεών τους. Κάνοντας αυτό για κάθε δείγμα στο σετ εκπαίδευσης θα δημιουργηθεί ένα νευρωνικό δίκτυο με διαφορετική δομή κάθε φορά, αναγκάζοντας το δίκτυο να μην βασίζεται σε συγκεκριμένες διαδρομές που ενισχύονται από την υπερεκπαίδευσης. Πιο συγκεκριμένα, εκχωρούμε μια πιθανότητα p σε κάθε νευρώνα του δυναμικού επιπέδου, όπου ο νευρώνας μπορεί να απενεργοποιηθεί. Επομένως, εκχωρούμε μια πιθανότητα απενεργοποίησης q στους νευρώνες στο επίπεδο εισόδου, συνήθως $q < p$. Επομένως, σε κάθε επανάληψη, εκπαιδεύεται ένα τροποποιημένο μοντέλο που αγνοεί την ύπαρξη ορισμένων νευρώνων. Με αυτόν τον τρόπο, άλλοι νευρώνες αναγκάζονται να «αναλάβουν» λίγο πολύ την ευθύνη για την πρόβλεψη της παραγωγής. Επειδή το βάρος θα είναι υψηλότερο από την κανονική τιμή λόγω της παραπάνω διαδικασίας, μετά από κάθε αναβάθμιση βάρους, δηλαδή στο τέλος κάθε μίνι παρτίδας (mini-batch), θα μειώνουμε το βάρος και θα προσπαθούμε να προσεγγίσουμε τον μέσο όρο όλων των διαφορετικών μοντέλων.




Figure 28 Παράδειγμα dropout ΠΗΓΗ <https://www.educative.io/edpresso/what-is-dropout-in-neural-networks>

1.6.4.2 Κανονικοποίηση δέσμης – Batch Normalization

Η τεχνική κανονικοποίησης δέσμης προτάθηκε από τους Ioffe και Szegedy, με σκοπό την επιτάχυνση της εκπαίδευσης και τη μείωση της υπερεκπαίδευσης. Λόγω των συναρτήσεων ενεργοποίησης, ιδιαίτερα των μη γραμμικών συναρτήσεων, η έξοδος του επιπέδου του νευρωνικού δικτύου κινείται προς ανεπιθύμητες κατευθύνσεις (κίνηση εσωτερικών συμμεταβλητών), με αποτέλεσμα σημαντική επιβράδυνση στην προπόνηση. Ο σκοπός αυτής της τεχνολογίας είναι να μετασχηματίσει την είσοδο ή την έξοδο της συνάρτησης ενεργοποίησης έτσι ώστε όλα τα κρυφά επίπεδα να έχουν κοινή κατανομή διατηρώντας παράλληλα σημαντικά χαρακτηριστικά




Figure 29 Internal covariate shift [24].

Ο τρόπος που επιτυγχάνεται αυτό είναι με την εισαγωγή επιπέδων που κάνουν τον εξής μετασχηματισμό:

$$\hat{x} = \gamma \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (72)$$

Το μ και το σ είναι ο μέσος όρος και σ^2 η διακύμανση που υπολογίζεται επί όλων τωνδειγμάτων ενός minibatch. Το ϵ είναι μία σταθερά που χρησιμοποιείται για την αποφυγή τυχόν προβλημάτων που μπορεί να προκύψουν από τον υπολογισμό της διακύμανσης. Το γ και το β




Figure 30 Ακρίβεια ως προς τα βήματα εκπαίδευσης με και χωρίς batch normalization στο σετ δεδομένων MNIST[22].

είναι παράμετροι του συστήματος που εκπαιδεύονται όπως και τα βάρη έτσι ώστε να επιλέγονται οι κατανομές για κάθε επίπεδο που ελαχιστοποιούν το σφάλμα.

1.6.4.3 Κανονικοποίηση L1, L2

Η τεχνολογία Regularization χρησιμοποιείται ευρέως στα νευρωνικά δίκτυα για τη μείωση του φαινομένου της υπερεκπαίδευσης. Ο τρόπος για να γίνει αυτό είναι να προσθέσετε έναν επιπλέον όρο στη συνάρτηση σφάλματος για να "τιμωρήσετε" βάρη με πολύ υψηλές τιμές.

Μία από τις πιο γνωστές τεχνικές regularization είναι η L1 ή αλλιώς Lasso . Με βάση αυτή την τεχνική προστίθεται στη συνάρτηση σφάλματος η L1 νόρμα των βαρών:

$$J_{L1}(w) = J(w) + \beta \|w\|_1 = J(w) + \beta |w| \quad (73)$$

Όπου β είναι η υπερπαράμετρος που επιλέγει ο χρήστης. Η αλλαγή βάρους μπορεί να ολοκληρωθεί από τον παραπάνω τύπο:

$$\frac{\partial J_{L1}}{\partial w} = \frac{\partial J(w)}{\partial w} + \text{sgn}(\beta) \quad (74)$$

Ουσιαστικά, αυτή η τεχνική ωθεί τα ασήμαντα βάρη στο μηδέν, δημιουργώντας ένα πιο απλό μοντέλο. Μια παρόμοια τεχνική είναι η τακτοποίηση L2 ή κορυφογραμμής [41], η οποία προσθέτει το τετράγωνο του κανόνα βάρους L2 στη συνάρτηση σφάλματος:

$$J_i(w) = J(w) + \beta (\|w\|_2)^2 = J(w) + \beta w^2 \quad (75)$$

Όπου αντίστοιχα η β είναι μία υπερ-παράμετρος και η μεταβολή των βαρών δίνεται από τη σχέση:

$$\frac{\partial J_{L2}(w)}{\partial w} = \frac{\partial J(w)}{\partial w} + 2\beta w \quad (76)$$

Η τεχνική L2 regularization δεν μηδενίζει τα ασήμαντα βάρη απλά τα ωθεί σε τιμές κοντά στο μηδέν. Επίσης όσο πιο κοντά στο μηδέν βρίσκεται ένα βάρος τόσο μειώνεται η ποινή που δέχεται.

1.7 Συναρτήσεις ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης αποτελούν βασικό υποσύστημα των ΝΝ επειδή καθορίζουν την έξοδο του νευρώνα και εισάγουν μη γραμμικά χαρακτηριστικά στο νευρωνικό δίκτυο. Παρακάτω θα των πιο βασικών συναρτήσεων ενεργοποίησης.

1.7.1 Βηματική συνάρτηση

Η βηματική συνάρτηση αποτελεί την πρώτη συνάρτηση ενεργοποίησης που χρησιμοποιήθηκε στα νευρωνικά δίκτυα και συγκεκριμένα στο Perceptron.

$$u(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (77)$$

Γενικά, η βηματική συνάρτηση είναι μία μη γραμμική συνάρτηση και για αυτό δεν χρησιμοποιείται σε πολύπλοκα προβλήματα.




Figure 31 Βηματική συνάρτηση $f(x)=u(x)$. ΠΗΓΗ <https://www.intmath.com/>

1.7.2 Σιγμοειδείς συναρτήσεις

Οι σιγμοειδείς συναρτήσεις είναι μια οικογένεια συναρτήσεων με χαρακτηριστικές καμπύλες «S». Είναι ίσως οι πιο κοινές συναρτήσεις στον τομέα των νευρωνικών δικτύων και οι δύο πιο διάσημες συναρτήσεις είναι οι λογιστικές συναρτήσεις και οι υπερεφαπτομένες. Ο τομέας τους είναι ολόκληρο το σύνολο των πραγματικών αριθμών, αλλά τα σύνολα τιμών τους είναι διαφορετικά. Η λογιστική συνάρτηση με το όνομα "ενεργοποίηση σιγμοειδούς" έχει ένα σύνολο τιμών $[0,1]$, που ορίζεται ως εξής [Wikipedia.org/sigma_functions]:

$$f(x) = 1 / (1 + e^{-x}) \quad (78)$$

Όπως φαίνεται στο Σχήμα 28, μια πολύ μεγάλη αρνητική τιμή εισόδου δίνει μια έξοδο πολύ κοντά στο μηδέν. Αυτό μπορεί να οδηγήσει σε πολύ χαμηλές τιμές κλίσης, γεγονός που μπορεί να προκαλέσει προβλήματα στην εκπαίδευση των νευρωνικών δικτύων. Για το λόγο αυτό, συχνά επιλέγεται η υπερβολική εφαπτομένη (tanh)

Η υπερβολική εφαπτομένη έχει σύνολο τιμών $[-1,1]$ και ορίζεται: $f(x) = \tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ (79)




Figure 32 Διαγράμμα $\tanh()$

1.7.3 Ομαλοποιημένη εκθετική συνάρτηση – Softmax




Figure 33 Υπερβολική εφαπτόμενη

Όπως γνωρίζουμε, η κανονικοποιημένη εκθετική συνάρτηση ή softmax είναι η γενίκευση των λογιστικών συναρτήσεων σε περισσότερες διαστάσεις. Χρησιμοποιείται κυρίως για προβλήματα Η ταξινόμηση πολλαπλών κλάσεων χρησιμοποιείται ως το επίπεδο εξόδου για την ανάθεση της πιθανότητας P_k καθεμιάς από τις κλάσεις K στην έξοδο. Αντιπροσωπεύεται συναρτησιακά ως εξής:

$$f(x) = \frac{e^x}{\sum_{i=0}^K e^{x_i}} \quad i = 0, 1, \dots, K, x = (x_1, x_2, \dots, x_n) \in \mathbb{R} \quad (80)$$

1.7.4 Ανορθωμένη γραμμική συνάρτηση ράμπας – REL

Η Η τροποποιημένη γραμμική συνάρτηση είναι ίσως η πιο ευρέως χρησιμοποιούμενη συνάρτηση ενεργοποίησης. Ο νευρώνας που τον χρησιμοποιεί ως συνάρτηση ενεργοποίησης ονομάζεται διορθωμένη γραμμική μονάδα ή RELU για συντομία. Η συνάρτηση που το περιγράφει είναι:

$$f(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & \text{else} \end{cases} \quad (81)$$

Η ανορθωμένη γραμμικής συνάρτηση ράμπας δεν είναι γραμμική συνάρτηση, αλλά είναι πολύ κοντά σε γραμμική συνάρτηση. Αυτό το καθιστά ιδανική συνάρτηση επειδή προσδίδει μη γραμμικά χαρακτηριστικά στο μοντέλο και ταυτόχρονα διευκολύνει τη διαδικασία βελτιστοποίησης. Ένα από τα προβλήματα που αντιμετωπίζει αυτή η συνάρτηση είναι ότι για τις αρνητικές τιμές εισόδου, η έξοδος είναι μηδέν. Αυτό θα αναγκάσει ορισμένους νευρώνες να αδρανοποιηθούν και να παραμείνουν σε αυτή την κατάσταση καθ' όλη την περίοδο της εκπαίδευσης. Αυτό το πρόβλημα ονομάζεται «θάνατος του RELU» και έχουν προταθεί διάφορες παραλλαγές του REL για την επίλυσή του. Ένα από αυτά είναι το Leaky-REL.




Figure 34 Ανορθωμένη γραμμική συνάρτηση Ράμπας

1.7.4.1 Leaky REL

Η Leaky REL δηλαδή η ανορθωμένη συνάρτηση γραμμικής ράμπας που έχει σχεδιαστεί για την επίλυση του προβλήματος "πεθαίνοντας RELU". Ουσιαστικά, αυτό που κάνει δεν είναι να μηδενίζει την έξοδο μιας αρνητικής τιμής εισόδου, αλλά να την πολλαπλασιάζει με μια τιμή 0,01. Η συνάρτηση που το περιγράφει είναι η εξής:




Figure 35 Τροποποιημένη συνάρτηση Ράμπας leaky Rel

1.8 Εφαρμογές των νευρωνικών δικτύων

Οι προσομοιώσεις των παραδειγμάτων βιολογικών υπολογιστών που εφαρμόζονται από τα TND έχουν πολύ καλά αποτελέσματα για πολλά είδη προβλημάτων. αυτά είναι "

- Η κατηγορία των NP προβλημάτων τα οποία περιλαμβάνουν προβλήματα δρομολόγησης, αναζήτησης κτλπ
- Η κατηγορία προβλημάτων αναγνώρισης π.χ αναγνώριση φωνής, εικόνας
- Η κατηγορία ελέγχου των οποίων τα δεδομένα είναι ελλιπή και ασαφή
- Όλα αυτά τα προβλήματα χαρακτηρίζονται από πολυδιάστατο χώρο, πολυπλοκότητα και άγνωστες συσχετίσεις μεταξύ των μεταβλητών. Επιπλέον, όπως φαίνεται παρακάτω, τα TND παρέχουν κυρίως λύσεις σε προβλήματα που σχετίζονται με ανθρώπινους παράγοντες, όπως η αναγνώριση φωνής και εικόνας. Συγκεκριμένα, οι περιοχές όπου τα νευρωνικά δίκτυα παρέχουν ικανοποιητικές λύσεις είναι οι εξής:

- Επεξεργασία εικόνας και μηχανική όραση π.χ ταίριασμα εικόνας,
- Επεξεργασία σήματος π.χ ανάλυση σεισμικού σήματος
- Αναγνώριση προτύπων π.χ εξαγωγή χαρακτηριστικών με βάση βιομετρικά χαρακτηριστικά,
- Οικονομία π.χ ανάλυση αγοράς μετοχών , εκτίμηση φερεγγυότητας δανειζόμενου πελάτη
- τεχνητή νοημοσύνη π.χ υλοποίηση έμπειρων συστημάτων
- Πρόβλεψη χρονοσειρών
- Επικοινωνία ανθρώπου υπολογιστή

1.9 Πλεονεκτήματα – μειονεκτήματα ΤΝΔ

Δεδομένου ότι το νευρωνικό δίκτυο είναι ένα αντικείμενο που δεν έχει διερευνηθεί διεξοδικά ως υπολογιστικό μοντέλο επειδή είναι σχετικά νέο, πρέπει να τονίσουμε τα πλεονεκτήματα και τα μειονεκτήματα σε σύγκριση με τις παραδοσιακές υπολογιστικές μεθόδους. Οι προσδοκίες σε αυτόν τον τομέα είναι υψηλές. Σε γενικές γραμμές, οι πολυεθνικές εταιρείες είναι κατάλληλες για την επίλυση συγκεκριμένων τύπων προβλημάτων, ειδικά εκπαιδευτικών προβλημάτων που επιλύονται μέσω τυπικής συνάφειας. Η ιδέα ότι οι πολυεθνικές εταιρείες μπορούν να λύσουν όλα τα εκπαιδευτικά προβλήματα δεν είναι ρεαλιστική. Αφενός, τα κύρια πλεονεκτήματά τους είναι τα εξής: Έμφυτος προγραμματισμός

- Ανοχή σε βλάβες λόγω του παραλληλισμού
- Σχεδιασμένα να είναι προσαρμοζόμενα
- Δεν υπάρχει η ανάγκη για χαρακτηρισμό του προβλήματος πέρα από το σύνολο των προτύπων εκπαίδευσης

Τα αρνητικά τους είναι όμως τα εξής:

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

2 - Νευρομορφική υπολογιστική

2.1 Εισαγωγή

Ο νευρομορφικός υπολογισμός χρησιμοποιεί ένα σύστημα ολοκλήρωσης πολύ μεγάλης κλίμακας (VLSI) που περιέχει ηλεκτρονικά αναλογικά κυκλώματα για την προσομοίωση της νευροβιολογικής αρχιτεκτονικής που υπάρχει στο νευρικό σύστημα. Ένας νευρομορφικός υπολογιστής/τσιπ είναι κάθε συσκευή που χρησιμοποιεί φυσικούς τεχνητούς νευρώνες (από πυρίτιο) για υπολογισμούς. Πρόσφατα, ο όρος νευρομορφολογία έχει χρησιμοποιηθεί για να περιγράψει αναλογικά, ψηφιακά, μικτά αναλογικά/ψηφιακά VLSI και τυπικά συστήματα λογισμικού (για αντίληψη ή πολυαισθητηριακή ολοκλήρωση) του νευρικού συστήματος. Η εφαρμογή του νευρομορφικού υπολογισμού σε επίπεδο υλικού μπορεί να επιτευχθεί μέσω μεμρίστορ που βασίζονται σε οξειδία, [6] σπιντρονική μνήμη, διακόπτες κατωφλίου και τρανζίστορ.

Μια βασική πτυχή της νευρομορφικής μηχανικής είναι να κατανοήσουμε πώς τα σχήματα μεμονωμένων νευρώνων, κυκλωμάτων, εφαρμογών και συνολικής αρχιτεκτονικής δημιουργούν τους απαιτούμενους υπολογισμούς, επηρεάζουν τον τρόπο έκφρασης των πληροφοριών, επηρεάζουν την ευρωστία της βλάβης, ενσωματώνουν τη μάθηση και την τοπική ανάπτυξη και προσαρμόζονται σε αλλαγές (Πλαστικότητα) και προωθούν την εξελικτική αλλαγή [1] [2].

2.2 Εμπνευση για την προσέγγιση προς την νευρομορφική υπολογιστική

Ο νευρομορφικός υπολογισμός εμπνέεται από την κατανόησή μας για τη δομή και τη λειτουργία του εγκεφάλου και τη μετατροπή της κατανόησής μας για τις λειτουργίες του εγκεφάλου σε γνώση σε συστήματα υπολογιστών. Σε γενικές γραμμές, αυτή η μέθοδος εστιάζει κυρίως στην αναπαραγωγή των παρόμοιων ιδιοτήτων του βιολογικού υπολογισμού και του ρόλου των νευρώνων στις γνωστικές λειτουργίες. Οι βιολογικές διεργασίες των νευρώνων και των συνάψεων τους είναι εξαιρετικά περίπλοκες, επομένως είναι δύσκολο να προσομοιωθούν τεχνητά. Ένα βασικό χαρακτηριστικό του βιολογικού εγκεφάλου είναι ότι όλη η επεξεργασία στους νευρώνες χρησιμοποιεί αναλογικά χημικά σήματα. Αυτό καθιστά δύσκολη την αναπαραγωγή του εγκεφάλου σε έναν υπολογιστή, επειδή η τρέχουσα γενιά υπολογιστών είναι εντελώς ψηφιακή. Ωστόσο, τα χαρακτηριστικά αυτών των τμημάτων μπορούν να ληφθούν μέσω μαθηματικών συναρτήσεων, οι οποίες συλλαμβάνουν στενά την ουσία της λειτουργίας των νευρώνων.

Ο στόχος της νευρομορφικής επιστήμης των υπολογιστών δεν είναι η τέλεια μίμηση του εγκεφάλου και όλων των λειτουργιών του, αλλά η εξαγωγή γνωστών πληροφοριών σχετικά με τη δομή και τη λειτουργία του για χρήση σε πραγματικά συστήματα υπολογιστών. Κανένα νευρομορφικό σύστημα δεν θα ισχυριστεί ή θα προσπαθήσει να αναπαραγάγει κάθε στοιχείο νευρώνων και συνάψεων, αλλά όλοι επιμένουν ότι οι υπολογισμοί κατανέμονται σε μεγάλο βαθμό σε μια σειρά μικρών υπολογιστικών στοιχείων παρόμοια με τους νευρώνες. Αν και αυτό το συναίσθημα είναι τυπικό, οι ερευνητές επιδιώκουν αυτόν τον στόχο με διαφορετικούς τρόπους.

2.3 Νευρομορφικό υλικό – Accelerators - Ενεργειακή αποδοτικότητα

Τα τεχνητά νευρωνικά δίκτυα συνήθως αποτελούνται από μεγάλο αριθμό κόμβων, ή νευρώνων, όπου σε κάθε νευρώνα μπορεί να εκχωρηθεί διαφορετική τιμή ή συναπτικό βάρος. Ο υπολογισμός των βαρών των νευρώνων κατά την εκπαίδευση ενός TNN απαιτεί υψηλή υπολογιστική ισχύ, επομένως η παράλληλη επεξεργασία μπορεί να είναι σωτήρια. Για να επιταχυνθεί η διαδικασία και η απόδοση της εκπαίδευσης, οι CPU πολλών πυρήνων και οι GPU είναι μερικά από τα διαθέσιμα εργαλεία που διαθέτουμε και είναι και άμεσα διαθέσιμα ως υλικά. Ωστόσο, οι CPU και οι GPU είναι συσκευές γενικής χρήσης που καταναλώνουν ενέργεια. Τα TNN είναι ενεργειακά δαπανηρά το οποίο είναι ένα από τα κρίσιμα προβλήματα που εμποδίζουν την εφαρμογή του σε συστήματα περιορισμένα σε ισχύ, όπως ενσωματωμένες συσκευές, συμπεριλαμβανομένων των έξυπνων κινητών συσκευών.

Για να καταστεί το νευρωνικό δίκτυο περισσότερο ενεργειακά αποδοτικό, έχει μελετηθεί η χρήση ειδικά σχεδιασμένου υλικού αφιερωμένου στην απόδοση του νευρικού δικτύου. Η εφαρμογή των FPGA είναι μια τέτοια προσπάθεια για την επίτευξη ενεργειακά αποδοτικής επεξεργασίας νευρωνικού δικτύου. Μια άλλη προσέγγιση είναι η εφαρμογή από την ASIC μοντέλων νευρωνικών δικτύων. Ειδικά, νευρομορφικά τσιπ έχουν αναπτυχθεί για την εφαρμογή υπολογιστών που μοιάζουν με τον εγκέφαλο για να ξεπεράσουν το πρόβλημα συμφόρησης της μνήμης σε παράλληλη επεξεργασία με επεξεργαστές αρχιτεκτονικής von Neumann. Εκτός από πολλές ερευνητικές προσπάθειες, υπάρχουν επίσης εμπορικά νευρομορφικά τσιπ διαθέσιμα στην αγορά, όπως το Loihee της Intel και το Neuromem της General Vision[4].

Το ZISC (Υπολογιστής μηδενικού συνόλου οδηγιών) είναι μια υλοποίηση TNN που επιτρέπει μαζικά παράλληλη επεξεργασία ψηφιακών δεδομένων, πλατφόρμα που έχει δημιουργηθεί από την IBM. Με βάση την τεχνολογία ZISC, η General Vision ανέπτυξε τσιπ CM1K που αποτελείται από 1.024 νευρώνες που μπορούν να αποθηκεύουν και να επεξεργάζονται διανύσματα μήκους 256 byte. Διάδοχος του συγκεκριμένου είναι το τσιπ NM500 που αποτελείται από 576 νευρώνες οι οποίοι έχουν ακριβώς την ίδια συμπεριφορά με το CM1K, αλλά λειτουργεί με υψηλότερο ρυθμό ρολογιού και καταναλώνει λιγότερη ενέργεια.[18]

Στην συγκεκριμένη παράγραφο θα γίνει διενεύνηση της αρχιτεκτονικής του NM500 chip, μιας υλοποίησης σε fpga με βάση το LIF μοντελο και η σύγκριση του με CPU και GPU με βάση την ενεργειακή απόδοση αυτών υπο το ίδιο φορτίο εργασίας.

2.3.1 Αρχιτεκτονική FPGA προσαρμοσμένη στις ανάγκες ενός TNN

Ο σχεδιασμός μιας μηχανής με ταχύτερες δυνατότητες επεξεργασίας πληροφοριών από ό,τι οι άνθρωποι έχουν επιστήσει την προσοχή στον υπολογισμό για δεκαετίες. Υπάρχει μια κλασική λύση για μια τέτοια μηχανή, γνωστή ως αρχιτεκτονική von Neumann. Ωστόσο, μπορούν να παρατηρηθούν διαφορές στη δομή, τις απαιτήσεις ισχύος και τις ικανότητες επεξεργασίας όταν αυτή η αρχιτεκτονική συγκρίνεται με τον ανθρώπινο εγκέφαλο, ο οποίος σε σύγκριση με έναν βιολογικό εγκέφαλο, θέτει ένα φυσικό ερώτημα σχετικά με τη δυνατότητα δημιουργίας υποκατάστατων αρχιτεκτονικών με βάση νευρικά μοντέλα .

Τον τελευταίο καιρό, προκειμένου να πραγματοποιηθούν μοντέλα νευρικού συστήματος ως ένα νευρομορφικό σύστημα, έχουν χρησιμοποιηθεί αναδιαμορφώσιμες ψηφιακές πλατφόρμες, Έχοντας ενδιαφέροντα χαρακτηριστικά όπως να είναι χαμηλού κόστους, ευέλικτος, αξιόπιστος, και έχοντας ψηφιακή ακρίβεια, κάνετε τις προγραμματισμένες συστοιχίες πυλών πεδίου (FPGAs) ως ιδανική επιλογή για να σχεδιάσει τα νευρομορφικά κυκλώματα και τα συστήματα . Έτσι το νευρομορφικό σύστημα που προτείνεται για την δημιουργία μέσω fpga είναι με βάση τη χρήση STDP (πλαστικότητα δικτύων αιχμών) καθώς και του μοντέλου Leaky Integration and Fire (LIF).

Στη συγκεκριμένη αρχιτεκτονική, όλοι οι υπολογισμοί εκτελούνται χρησιμοποιώντας αριθμητική σταθερού σημείου 32-bit για να δημιουργηθεί μια ισορροπία μεταξύ ακρίβειας και κόστους. Λόγω της ενεργειακής απόδοσης και της φύσης που καθοδηγείται από συμβάντα, τα μοντέλα spiking έχουν γίνει ιδιαίτερα ελκυστικά σε νευρομορφικές υλοποιήσεις σε σύγκριση με τα άλλα συστήματα. Από την άποψη του υλικού, πιο αποτελεσματική και χαμηλού κόστους νευρομορφική υλοποίηση μπορεί να επιτευχθεί χρησιμοποιώντας απλούστερους υπολογισμούς. Δεδομένου ότι ένας πολλαπλασιαστής είναι ένα μάλλον δαπανηρό μπλοκ υλικού, όσον αφορά το μέγεθος του κυκλώματος και την κατανάλωση ενέργειας, η αριθμητική λειτουργία του shifting προτιμάται ιδιαίτερα για την υλοποίηση του πολλαπλασιασμού και της διαίρεσης με το 2. Κατά συνέπεια, οι σταθεροί συντελεστές στο σημείο 2 πρέπει να τροποποιηθούν, για να ξαναγραφτούν σε powers του 2. Στο σχεδιασμό μας, το διακριτό βήμα ($h/\tau_m = 0,1$) προσεγγίζεται κατά $0,125 = 1/8 = 1/(2^3)$. [11]




Figure 36 Υλοποίηση lif νευρώνων και μείωση πολυπλοκότητας με χρήση shifters [11]

Αυτό εφαρμόζεται με τρεις αριθμητικές δεξιές μετατοπίσεις όπως φαίνεται στο παρακάτω σχήμα. Επομένως, σε κάθε διάγραμμα προγραμματισμού, απαιτούνται λιγότερα βήματα για τη δημιουργία της εξόδου, γεγονός που έχει ως αποτέλεσμα υψηλότερη ταχύτητα υπολογισμού

Αφότου βελτιστοποιηθεί ο LIF νευρώνας με βάση την παραπάνω υλοποίηση, το νευρομορφικό μας σύστημα θα αποτελείται από τις NCHU που αναλύσαμε παραπάνω.

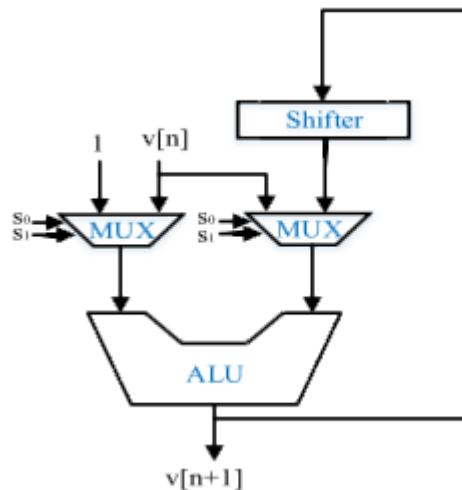


Figure 37 Υλοποίηση neural computing hardware unit(NCHU) με βάση την απλουστευμένη υλοποίηση του lif[11]

Στην συγκεκριμένη αρχιτεκτονική τα βάρη των συνάψεων αποθηκεύονται στην μνήμη των βαρών, το input provider unit παρέχει τις κατάλληλες εισόδους στο μοντέλο, την κατάλληλη χρονική στιγμή. Επίσης το control unit ορίζει κατάλληλα τα σήματα χρονισμού και την σειρά των βημάτων για την λειτουργία της μηχανής καταστάσεων.

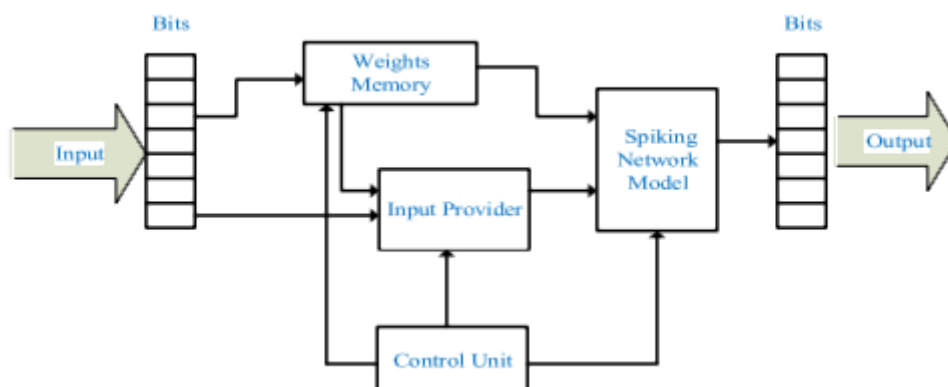


Figure 38 - Προτεινόμενο νευρομορφικό σύστημα προς υλοποίηση για FPGA[11]

Όσο αναφορά για την υλοποίηση του πυροδοτούμενου νευρωνικού δικτύου , το συγκεκριμένο θα αποτελείται από 6 NCHU, μια SRAM και μία NCHU εξόδου που θα βγάζει τον τελικό παλμό.

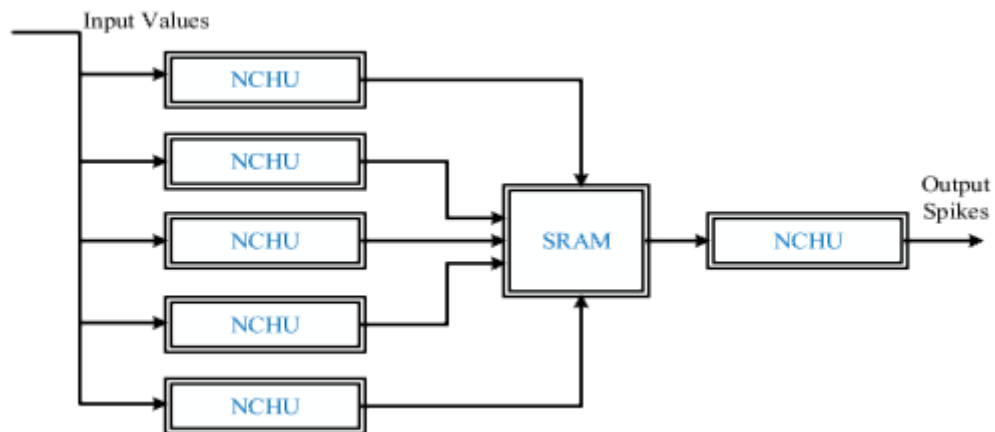


Figure 39 Υλοποίηση για την δημιουργία spiking neural network σε blocks υλικού[11]

Οι NCHUs υλοποιούνται με σχεδιασμό για pipelining .Η SRAM χρησιμοποιείται για την αποθήκευση τιμών εξόδου κάθε νευρώνα για την υλοποίηση του pipelining. Δεδομένου όμως ότι το σύστημα έχει σχεδιαστεί να λειτουργεί ακολουθιακά , η SRAM χρησιμεύει ως ένας buffer για την αποθήκευση του stream μεταξύ των επιπέδων στο δίκτυο. Κάθε φορά που το NCHU ολοκληρώνει την εργασία του, γράφει το ενδιάμεσο αποτέλεσμα στην SRAM και συνεχίζει την επεξεργασία μιας άλλης εισόδου. Με αυτόν τον τρόπο, οι εφαρμοσμένοι νευρώνες μπορούν να λειτουργήσουν ανεξάρτητα και ακόμη και ασύγχρονα κατόπιν δικής μας παραμετροποίησης.[11]

Τέλος για την εκπαίδευση των βαρών στο spiking δίκτυο, χρησιμοποιείται η τεχνική Stdp off-chip learning, η οποία θα αναλυθεί σε πιο κάτω κεφάλαιο. Στην συγκεκριμένη τεχνική ο πίνακας βαρών λαμβάνεται με την εκπαίδευση του νευρωνικού δικτύου μέσω λογισμικού χρησιμοποιώντας STDP και στη συνέχεια, τα έγκυρα βάρη αποθηκεύονται και μεταφέρονται στο τσιπ.

2.3.2 Αρχιτεκτονική εμπορικής λύσης NM500

Το νευρομορφικό τσιπ που θα ερευνήσουμε την αρχιτεκτονική του είναι το NM500 από τη Nerves, η οποία βασίζεται στην τεχνολογία NeuroMem από την general vision. Το συγκεκριμένο τσιπ NM500 έχει 576 νευρώνες. Ένας νευρώνας υλικού είναι ένα πανομοιότυπο στοιχείο που μπορεί να αποθηκεύσει και να επεξεργαστεί πληροφορία ταυτόχρονα. Συγκεκριμένα συμπεριφέρεται τους νευρώνες μέσα του ως ένα κ-nearest Network ή ως έναν radial Basis Classifier.

Ένας νευρώνας NM500 έχει ένα μοντέλο και μία ακτίνα επιρροής μετά τη διαδικασία εκπαίδευσης, η οποία είναι αποθηκευμένη στην μνήμη του. Όταν παρέχονται δεδομένα για ταξινόμηση(classification), κάθε νευρώνας υπολογίζει την απόσταση ενός σημείου δεδομένων από το μοντέλο του και πυροδοτεί εάν η απόσταση είναι μικρότερη από την τιμή επιρροής(influence field). Κάθε νευρώνας αναφέρει την απόκριση των άλλων στο παράλληλο δίαυλο και αν ένας άλλος νευρώνας αναφέρει μικρότερη τιμή επιρροής, τότε το σήμα απορρίπτεται.

Η αρχιτεκτονική του NM500 δεν έχει διαμορφωθεί για να υλοποιήσει ένα deep neural network, το οποίο μπορεί να επηρεάσει την ακρίβεια για συγκεκριμένες εφαρμογές. Ωστόσο, επειδή το νευρικό δίκτυο έχει μόνο ένα hidden layer, ο χρόνος ταξινόμησης(classification) στο νευρομορφικό υλικό γίνεται σχεδόν σταθερός για κάθε περίπτωση classification. Επίσης λαμβάνοντας υπόψη την απλότητα της διαμόρφωσης του υλικού, θα μπορούσε να είναι κατάλληλο για ενσωματωμένα συστήματα των οποίων οι απαιτήσεις μπορούν να ικανοποιηθούν από ένα σχετικά απλό νευρωνικό δίκτυο.[18]

Συγκεκριμένα για την αρχιτεκτονική NM 500, το δίκτυό του είναι τριών επιπέδων: ένα επίπεδο εισόδου, ένα hidden layer και ένα επίπεδο εξόδου. Όλοι οι νευρώνες στο τσιπ μπορούν να θεωρηθούν κόμβοι στο hidden layer. Κάθε νευρώνας του έχει χώρο αποθήκευσης 256 byte, ο οποίος περιορίζει το μέγεθος εισόδου σε λιγότερο ή ίσο με 256 byte. Το μέγεθος εξόδου είναι 2 byte, οπότε ο αριθμός των ετικετών στο classification περιορίζεται σε 65.536. Τα δεδομένα εισόδου και οι εντολές τροφοδοτούνται σε κάθε νευρώνα παράλληλα και μεταξύ τους οι νευρώνες είναι daisy-chained για να σηματοδοτήσουν τον επόμενο νευρώνα και έτσι να δεχτεί τα δεδομένα εισόδου διαδοχικά. Μιας και δεν υπάρχει η δυνατότητα υλοποίησης Deep neural network με ένα κρυφό layer, τα κρυφά layer μπορούν να υλοποιηθούν με την χρήση πολλαπλών chip NM500 μπορεί να επεκταθεί συσσωρεύοντας πολλά τσιπ NM500.

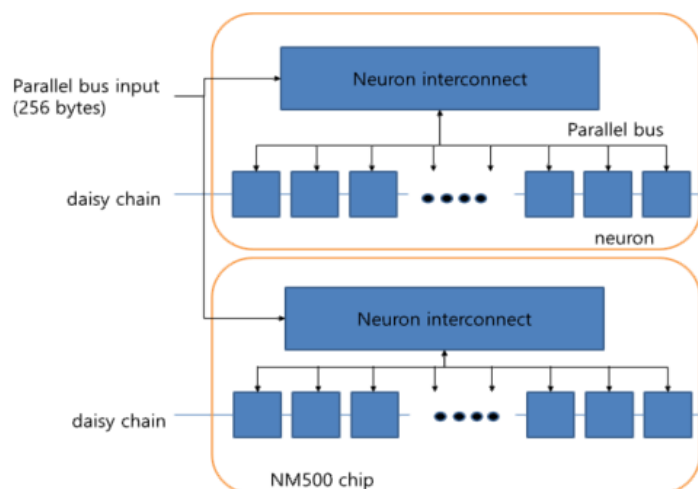


Figure 40 Εσωτερικό δίκτυωμα NM500 [18]

2.3.3 Ενεργειακή απόδοση των CPU, GPU και NM500 για την υλοποίηση νευρωνικού δικτυωματος

Για την αξιολόγηση ενός εμπορικά διαθέσιμου νευρομορφικού τσιπ (NM500) με αυτά των πυρήνων GPU και CPU σε ενσωματωμένες συσκευές, χρησιμοποιήθηκε το ίδιο νευρωνικό δίκτυο και το ίδιο dataset για την εκπαίδευση αυτών. Επίσης για τα συγκεκριμένα πειραματικά δεδομένα, χρησιμοποιήθηκε σύστημα μόνο με CPU που περιελάμβανε τον επεξεργαστή Exynos5422, ο οποίος αποτελείται από 4 γρήγορους (μεγάλους) πυρήνες και 4 slow (little). Επειδή οι μικροί πυρήνες είναι πολύ αργοί για να χρησιμοποιηθούν για την επεξεργασία του νευρικού δικτύου, μόνο μεγάλοι πυρήνες χρησιμοποιήθηκαν στη συγκριση. Ως σύστημα GPU, χρησιμοποιήθηκε το board Jetson Nano της Nvidia με 128 πυρήνες GPU. Το νευρωνικό δίκτυο στο σύστημα αυτό, υλοποιήθηκε χρησιμοποιώντας τη βιβλιοθήκη Tensorflow-GPU.

Συγκεκριμένα μετρήθηκαν οι μεταβλητές, κατανάλωση ενέργειας και χρόνος για την υλοποίηση του classification ενός σετ εικόνων, αυξάνοντας παράλληλα τον αριθμό των νευρώνων

System Type	Accelerator	CPU	Memory
CPU system	None	Octa-core ARM @2 GHz (A15 x 4 & A7 x 4)	2 GB LPDDR4
GPU system	GPU (128 cores)	Quad-core ARM @1.43 GHz A57 x 4	4 GB LPDDR4
Neuromorphic system	NM500 (up to 7 chips)	-	256 B per each neuron

Figure 41 Hardware που χρησιμοποιήθηκε για την σύγκριση[18]

στο νευρικό δίκτυο. Τα πειραματικά αποτελέσματα δείχνουν ότι ο χρόνος που απαιτείται για να μάθει το νευρομορφικό τσιπ τον ίδιο όγκο δεδομένων είναι περίπου 13-15 φορές μικρότερος από αυτόν που απαιτείται για το ενσωματωμένο σύστημα με 128 πυρήνες GPU.




Figure 42 Χρόνος εκπαίδευσης μοντέλου στα διάφορα σενάρια[18]

Από την άλλη, ο χρόνος που απαιτείται για την ταξινόμηση ενός συνόλου δεδομένων παραμένει σχεδόν σταθερός για τον νευρομορφικό επεξεργαστή λόγω της αρχιτεκτονικής του νευρικού δικτύου με ένα μόνο κρυφό στρώμα. Στην ταξινόμηση, η GPU επεξεργάζεται δεδομένα ταχύτερα από το νευρομορφικό τσιπ, αλλά ο χρόνος επεξεργασίας τείνει να αυξάνεται καθώς αυξάνεται ο αριθμός των νευρώνων. Έτσι, αναμένεται ότι τα νευρομορφικά τσιπ μπορούν να υπερτερούν του συστήματος GPU με μεγαλύτερο αριθμό νευρώνων, αλλά αυτό δεν θα μπορούσε να δοκιμαστεί λόγω του περιορισμού στην επεκτασιμότητα του πίνακα αξιολόγησης για τα νευρομορφικά τσιπ.




Figure 43 Χρόνος επεξεργασίας στις διάφορες πλατφόρμες για συγκεκριμένο dataset[18]

Εκτός αυτών, δεδομένου ότι τα περισσότερα ενσωματωμένα συστήματα εξαρτώνται από την περιορισμένη παροχή ηλεκτρικού ρεύματος, όπως οι μπαταρίες, η ενεργειακή απόδοση είναι ένας κρίσιμος παράγοντας για το σχεδιασμό ενός συστήματος. Στα πειράματά μας, η ενέργεια που απαιτείται για τα τσιπ NM500 για την επεξεργασία μιας παρουσίας δεδομένων εισόδου είναι μικρότερη από το 1/35 αυτής που απαιτείται από το επιταχυνόμενο ενσωματωμένο σύστημα GPU για την εκπαίδευση του νευρικού δικτύου, ενώ η κατανάλωση ενέργειας του συστήματος GPU στην ταξινόμηση είναι μόνο 1,22-2,37 φορές υψηλότερη από εκείνη των τσιπ NM500. Επειδή το νευρικό δίκτυο του NM500 έχει μόνο ένα κρυφό στρώμα, ο χρόνος επεξεργασίας για την ταξινόμηση του δεδομένου συνόλου δεδομένων παραμένει σχεδόν ο ίδιος, παρόλο που ο αριθμός των νευρώνων αυξάνεται, ενώ η κατανάλωση ενέργειας αυξάνεται γραμμικά. Αντίθετα, ο χρόνος ταξινόμησης του συστήματος GPU είναι σχεδόν γραμμικά ανάλογος με τον αριθμό των νευρώνων, ενώ η κατανάλωση ενέργειας παραμένει αμετάβλητη. [18]




Figure 44 Καταναλισκόμενη ενέργεια για την εκπλήρωση της εκπαίδευσης[18]

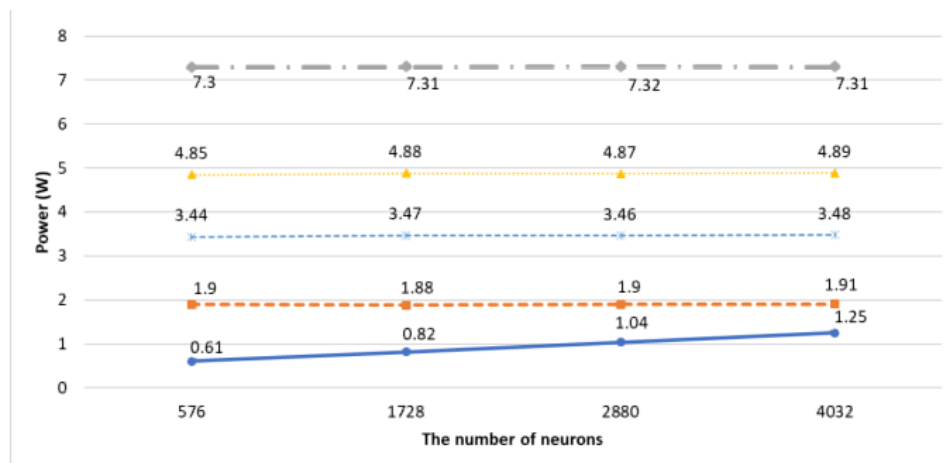


Figure 45 Μέση κατανάλωση ισχύος ανα νευρώνια που παρέχει η κάθε πλατφόρμα[18]

Ως εκ τούτου, η ενέργεια για τα νευρομορφικά τσιπ να ταξινομήσουν τα δεδομένα αναμένεται να είναι κοντά στο 50% αυτού για το σύστημα GPU καθώς αυξάνεται ο αριθμός των τσιπ. Είναι ενδιαφέρον να σημειωθεί ότι τα νευρομορφικά τσιπ είναι ιδιαίτερα ενεργειακά αποδοτικά στην εκπαίδευση του νευρικού δικτύου σε σύγκριση με το σύστημα CPU.

2.4 Υλοποιήσεις hardware για την δημιουργία νευρώνων

2.4.1 Memristor

2.4.1.1 Γενικά για το memristor

Ο ηλεκτρονικός εξοπλισμός παίζει σημαντικό ρόλο στην καθημερινή ζωή και στη βελτίωση της ποιότητας της ανθρώπινης ζωής. Τα προϊόντα χαμηλής ενέργειας και υψηλής ταχύτητας που μπορούν να αποθηκεύσουν πληροφορίες ονομάζονται μνήμες και υπάρχουν σχεδόν σε όλες τις ηλεκτρονικές συσκευές. Ως εκ τούτου, ως τύπος ολοκληρωμένου κυκλώματος, οι ηλεκτρονικές συσκευές αποθήκευσης αποτελούν σημαντικό μέρος της δημιουργίας προϊόντων υψηλής τεχνολογίας. Συνήθως ταξινομούνται ανάλογα με το χρονικό διάστημα που αποθηκεύονται οι

πληροφορίες σε πτητικές (οι πληροφορίες χάνονται μόλις σταματήσει η τροφοδοσία) και μη πτητικές (διατηρούν τις πληροφορίες για μεγάλο χρονικό διάστημα ακόμα και μετά τη διακοπή της ηλεκτρικής ισχύος).

Ο εγκέφαλος είναι ένα όργανο με μοναδικές λειτουργίες. Μπορεί να αποθηκεύσει πληροφορίες και να τις μεταδώσει σε άλλα μέρη του σώματος μέσω κατάλληλων μηχανισμών. Έτσι, ο επόμενος στόχος της τεχνολογίας είναι να επιτρέψει στη μνήμη να αναπαράγει τις λειτουργίες του ανθρώπινου εγκεφάλου όσο το δυνατόν περισσότερο. Για το σκοπό αυτό, αναπτύχθηκε ένας κλάδος που ονομάζεται Neuromorphic Engineering για να ασχολείται με δομές που βασίζονται στο βιολογικό νευρικό σύστημα. Ο Carver Mead χρησιμοποίησε για πρώτη φορά τον όρο νευρομορφικό σύστημα για να περιγράψει ηλεκτρονικά αναλογικά κυκλώματα που μιμούνται το βιολογικό νευρικό σύστημα. Τα τρία βασικά παθητικά ηλεκτρονικά στοιχεία ενός κυκλώματος είναι οι αντιστάσεις, οι πυκνωτές και τα πηνία. [9] Ο L.O. Chua παρατήρησε ότι στις συναρτήσεις των παραμέτρων των παθητικών στοιχείων, το ρεύμα και η τάση έχουν μια γραμμική




Figure 46 Παραμετρική σχέση παθητικών στοιχείων [9]

μέσω του νόμου του ohm. Το ίδιο ισχύει και για τη γραμμική σχέση μεταξύ του φορτίου και της τάσης μέσω του πυκνωτή. Επομένως, το πηνίο συνδέει την αλλαγή της μαγνητικής ροής με το ρεύμα. Ωστόσο, δεν υπάρχει σχέση μεταξύ των αλλαγών στη μαγνητική ροή και των αλλαγών στο φορτίο. Επομένως, πρέπει να υπάρχουν περισσότερα στοιχεία για τη δημιουργία τετραγωνικής συμμετρίας. L.O. Επομένως, ο Chua πρότεινε ένα memristor στο οποίο η σχέση $M = d\phi / dq$ μειώνεται, όπου M είναι το memristor, το οποίο είναι συνάρτηση του φορτίου και έχει μονάδα αντίστασης (Ohm) [9]

Το memristor είναι ένα μη γραμμικό παθητικό στοιχείο με δύο ακροδέκτες που μπορεί να ελέγξει το ρεύμα που διαρρέει το ηλεκτρονικό κύκλωμα όπου βρίσκεται. Το σημαντικό πλεονέκτημα μιας συσκευής memristor η δυνατότητα απομνημονεύσης της ποσότητας του φορτίου που περνά μέσα από αυτήν. Η λειτουργία του memristor βασίζεται στην αλλαγή της αντίστασης. Είναι επίσης σημαντικό να σημειωθεί ότι τα memristors ανήκουν στην κατηγορία της μη πτητικής μνήμης. Τέλος, σημαντικό χαρακτηριστικό της συσκευής είναι η δομή της ναοκλίμακας, η οποία μπορεί να μειώσει σημαντικά το κόστος κατασκευής.

2.4.1.2 Το φαινόμενο εναλλαγής αντίστασης

Οι συσκευές Memristor ανήκουν σε έναν τύπο μνήμης που ονομάζεται resistive switch ή RRAM, δηλαδή ωμική μνήμη τυχαίας πρόσβασης. Αυτοί οι τύποι αναμνήσεων είναι πολύ συνηθισμένοι λόγω της απλής διαδικασίας κατασκευής τους. Μια τέτοια μνήμη είναι μια συσκευή μέταλλου-μονωτή-μέταλλου, στην οποία η θέση του μονωτή διατηρείται από ένα οξειδίο μετάλλου. Ένα στρώμα διηλεκτρικού υλικού και δύο μεταλλικά ηλεκτρόδια αρκούν για την παραγωγή μιας απλής μορφής μνήμης RRAM. Υπάρχουν δύο πολύ βασικές καταστάσεις των διακοπών αντίστασης. Η πρώτη είναι η κατάσταση υψηλής αντίστασης (HRS), η οποία είναι η κατάσταση απενεργοποίησης της συσκευής. Αντίθετα, η δεύτερη είναι η κατάσταση χαμηλής αντίστασης (LRS) και είναι η κατάσταση λειτουργίας (κατάσταση ON). Η μετάβαση από το HRS στο LRS ονομάζεται διαδικασία SET και η αντίθετη διαδικασία ονομάζεται διαδικασία RESET. Ο λόγος για τον οποίο αυτό το είδος μνήμης είναι τόσο ελκυστικό είναι ότι είναι πολύ μικρές σε μέγεθος, μόνο νανόμετρα και συνδυάζουν τα πλεονεκτήματα της λειτουργίας με πολύ μικρή παροχή τάσης.

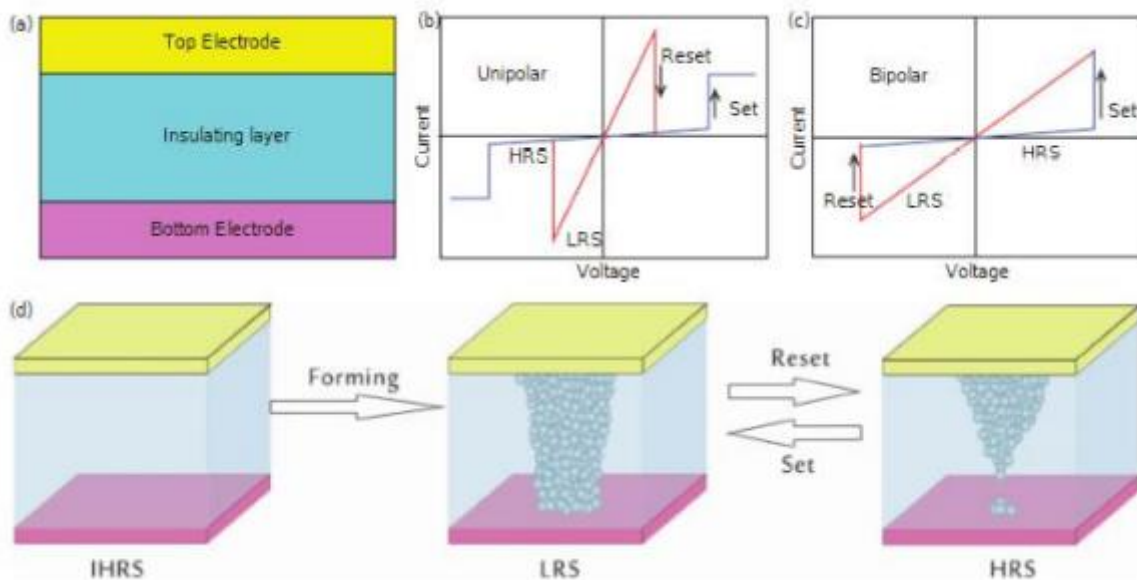


Figure 47 Figure 48 Η εικόνα (a) δείχνει την γενική δομή της διάταξης memristor. Η (b) αναφέρεται σε ένα διάγραμμα μονοπολικού φαινομένου εναλλαγής αντίστασης, όπου στο διάγραμμα I-V φαίνονται οι καταστάσεις SET/RESET. Η (c) παραθέτει το διπολικό φαινόμενο εναλλαγής αντίστασης με τις καταστάσεις SET/RESET. Η εικόνα (d) δείχνει την δημιουργία και την μερική καταστροφή του αγώγιμου μονοπατιού μέσα στον όγκο του διηλεκτρικού. [9]

Το φαινόμενο της εναλλαγής αντίστασης χωρίζεται κυρίως σε δύο κατηγορίες. Υπάρχουν μονοπολικά και διπολικά φαινόμενα. Στην πρώτη περίπτωση, η εναλλαγή SET και RESET γίνεται κάτω από την ίδια πολικότητα τάσης. Αντίθετα, στο διπολικό φαινόμενο χρειάζεται αλλαγή της πολικότητας της τάσης. Οι μνήμες που χρησιμοποιούνται κυρίως είναι αυτές που έχουν διπολικά εφέ, γιατί παρατηρούν καλύτερα τα χαρακτηριστικά της μνήμης, αποθηκεύουν και καταγράφουν πληροφορίες. Γενικά, στη διπολική μνήμη, η διαδικασία δημιουργίας μιας αγώγιμης διαδρομής μεταξύ δύο ηλεκτροδίων για να δούμε το φαινόμενο ανταλλαγής αντίστασης δεν έχει ακόμη συζητηθεί στην επιστημονική κοινότητα. [30

2.4.1.3 Linear Ion Drift Model Memristor

Σύμφωνα με τον L.O chua., σχετικά με την ύπαρξη του τέταρτου παθητικού στοιχείου, οι ερευνητές άρχισαν να αναζητούν στοιχεία που θα μπορούσαν να την οδηγήσουν να αποδείξει πειραματικά την ύπαρξη του memristor. Βασικό στοιχείο είναι το διάγραμμα ρεύματος-τάσης της συσκευής, το οποίο θα πρέπει να δείχνει χαρακτηριστική υστέρηση. Στην πραγματικότητα, η HP ήταν η πρώτη που έκανε αυτή την ανακάλυψη, και παρουσίασε περαιτέρω το πρώτο και βασικότερο μοντέλο του memristor, το οποίο βασίζεται στον μαθηματικό τύπο που έδωσε ο Chua. Το πρώτο μοντέλο είναι το μοντέλο γραμμικής μετατόπισης ιόντων, που αναπτύχθηκε από τον R.S. Williams και την ομάδα του στα εργαστήρια HP. Η ομάδα της HP συζητά ένα ιδανικό μοντέλο memristor στο οποίο οι τρύπες μπορούν να κινούνται σε όλο το μήκος του στρώματος TiO_2 , αλλά αυτό μπορεί στην πραγματικότητα να μην ισχύει. Αρχικά, εάν οι κενές θέσεις οξυγόνου μετακινηθούν κατά μήκος ολόκληρης της συσκευής, το μήκος των οπών και των περιοχών που έχουν προστεθεί θα είναι μηδέν.

Επομένως, υπάρχουν μόνο περιοχές που δεν θα είναι doped, επομένως η συσκευή δεν θα λειτουργήσει επειδή δεν θα υπάρξει αλλαγή στην εφαρμογή θετικής ή αρνητικής τάσης. Επομένως, συμπεραίνουμε ότι οι κενές θέσεις οξυγόνου κινούνται κατά μήκος του ορίου μεταξύ των δύο στρωμάτων. Αυτό μπορεί να γίνει εύκολα κατανοητό παρατηρώντας τη μαθηματική σχέση (2.8). R_{on} είναι η αντίσταση της συσκευής όταν $w(t) = d$, και R_{off} είναι η αντίσταση όταν $w(t) = 0$. Επομένως, το $w(t)$ βρίσκεται μεταξύ του κλειστού χώρου $[0, D]$. Επομένως, πρέπει να βρεθεί ένα μαθηματικό μοντέλο στο οποίο υπάρχουν κατάλληλες μεταβλητές για να επιβεβαιωθεί ότι η οπή κινείται μόνο κατά μήκος του ορίου του memristor. Για το σκοπό αυτό, οι ερευνητές πρότειναν την ύπαρξη μιας συνάρτησης, που ονομάζεται συνάρτηση παραθύρου $f(w)$ (συνάρτηση παραθύρου), η οποία λύνει το πρόβλημα του ορίου της κίνησης της κενής θέσης οξυγόνου.




Figure 49 Μεταφορά ιόντων εντός του memristor

Τέλος, πρέπει να σημειωθεί ότι τα memristors έχουν δύο βασικές καταστάσεις λειτουργίας παρόμοιες με τα τρανζίστορ. Η πρώτη είναι η κατάσταση αγωγιμότητας. Αυτή τη στιγμή, η αντίσταση στο memristor αρχίζει να μειώνεται και τα ηλεκτρόνια αρχίζουν να ρέουν, δηλαδή το ρεύμα αρχίζει να ρέει μέσω της συσκευής (LRS). Η δεύτερη είναι η κλειστή κατάσταση, όπου συμβαίνει το αντίθετο (HRS). Καθώς η αντίσταση αυξάνεται, όλο και λιγότερο ρεύμα παρέχεται στο κύκλωμα. Η διαδικασία μετάβασης από τη μια κατάσταση στην άλλη ονομάζεται συμπεριφορά μεταγωγής

2.4.1.4 Nonlinear Ion Drift Model Memristor

• Τα πρώτα πειραματικά δεδομένα των κατασκευασμένων memristors δείχνουν ότι σε αυτές τις συσκευές δεν υπάρχει γραμμική αναλογία ρεύματος ή τάσης και w , όπως θα περίμεναν από τον μαθηματικό τύπο του μοντέλου HP. Μέσω συνεχούς έρευνας, ο Lehtonen και η ομάδα του εισήγαγαν ένα μοντέλο memristor που ονομάζεται μοντέλο μη γραμμικής μετατόπισης ιόντων. Η σχέση μεταξύ ρεύματος και τάσης σε αυτό το μοντέλο και w φαίνεται στις παρακάτω εξισώσεις:

$$\bullet i(t) = wn\beta \sinh(av(t)) + x[\exp(\gamma v(t)) - 1] \quad (82)$$

$$\bullet dw(t)/dt = av^m(t) * f(w) \quad (83)$$

Τα A , β , γ , m και x είναι οι παράμετροι που βρέθηκαν από πειραματικές μετρήσεις. Το N είναι μια μεταβλητή που σχετίζεται με το ρεύμα. Σε αυτόν τον τύπο memristor, η μεταβλητή w παίρνει μια τιμή στο διάστημα $[0,1]$. Στο συγκεκριμένο μοντέλο, ενδιαφέροντα είναι τα γραφήματα τάσης και ρεύματος. Πιο συγκεκριμένα, στην κατάσταση ON «συμμετέχουν» πάρα πολλοί ημίτονο, όπως μπορούμε να δούμε στη μαθηματική σχέση (82). Υπάρχει ένα εκθετικό μέρος στην κατάσταση OFF. Επομένως, είναι εύκολο να κατανοήσουμε την ασυμμετρία μεταξύ αυτών των συναρτήσεων. Αυτή η ασυμμετρία είναι ένα πλεονέκτημα για τη συσκευή, επειδή για μικρές τάσεις, η διαδικασία ανάγνωσης είναι συμφέρουσα και για μεγαλύτερες τιμές, η διαδικασία γραφής είναι συμφέρουσα.

2.4.1.5 Simmons Tunnel Barrier Model

Σε αντίθεση με το μοντέλο της HP και το μη γραμμικό μοντέλο μετατόπισης ιόντων, ο Matthew D. Pickett και η ομάδα του πρότειναν ένα διαφορετικό μοντέλο memristor το 2009 που μπορεί να προσεγγίσει καλύτερα τη συμπεριφορά πραγματικών συσκευών. Η πιο σημαντική διαφορά από το παραπάνω μοντέλο είναι ότι δεν περιέχει δύο αντιστάσεις σε σειρά, αλλά μια αντίσταση σε σειρά με φράγμα ηλεκτρονιακής σήραγγας. Λόγω της εκθετικής εξάρτησης της κίνησης των ιονισμένων προσμίξεων, το μοντέλο παρουσιάζει μη γραμμική και ασύμμετρη συμπεριφορά μεταγωγής




Figure 50 Μοντέλο simmons[30]

Η μαθηματική σχέση που περιγράφεται από αυτό το μοντέλο memristor είναι πιο περίπλοκη από τα δύο παραπάνω μοντέλα. Γι' αυτό και η θεωρητική του μοντελοποίηση έχει γίνει πιο δύσκολη. Η σχέση για την περιγραφή των παραπάνω φαίνεται πιο κάτω.

Το x είναι το πλάτος του φραγμού, το οποίο αντιστοιχεί στη μεταβλητή w στο Σχήμα 46. Το E είναι το φορτίο του ηλεκτρονίου, η παράμετρος \bar{A} αντιπροσωπεύει την περιοχή του μπλοκ και το B είναι η τιμή. R_s είναι η αντίσταση του memristor και φ_1 είναι το ύψος του φραγμού. Οι μεταβλητές C_{off} , C_{on} , a_{off} , a_{on} , i_{off} , i_{on} είναι παράμετροι. Πιο συγκεκριμένα, οι μεταβλητές C_{off} και ζονται σχετίζονται με την αλλαγή του πλάτους του φραγμού της σήραγγας ηλεκτρονίων. Αντίστοιχα, το i_{off} αναφέρεται στο τρέχον όριο στο φράγμα. Αυτό το μοντέλο έχει μια ειδική λειτουργία. Όπως είδαμε στην Εξίσωση 84, δεν υπάρχει συνάρτηση παραθύρου (f). Αντίθετα, έχουμε παραμέτρους a_{off} και a_{on} , που είναι τα άνω και κάτω όρια του x . Τέλος, μια σημαντική παρατήρηση είναι ότι η μεταβλητή v είναι η εσωτερική τάση της συσκευής, η οποία δεν είναι απαραίτητα ίση με την εφαρμοζόμενη εξωτερική τάση, v_g [9]

(84)

$$i(t) = \bar{A}(x, v_g) \varphi_1(v_g, x) \exp[-B(v_g, x) \varphi_1^{0.5}(v_g, x)] - \bar{A}(x, v_g) (\varphi_1(v_g, x) + e|v_g|) \exp[B(v_g, x) (\varphi_1(v_g, x) + e v_g)^{0.5}]$$

(85)

$$v_g = v - i(t)R_s$$

$$\frac{dx}{dt} = \begin{cases} C_{off} \sinh\left(\frac{i}{i_{off}}\right) \exp\left[-\exp\left(\frac{x - a_{off}}{w_c} - \frac{|i|}{b}\right) - \frac{x}{w_c}\right], & i > 0 \\ C_{on} \sinh\left(\frac{i}{i_{on}}\right) \exp\left[-\exp\left(\frac{x - a_{on}}{w_c} - \frac{|i|}{b}\right) - \frac{x}{w_c}\right], & i < 0 \end{cases} \quad (86)$$

2.4.1.6 Threshold Adaptive Memristor Model (TEAM)

Όπως αναφέρθηκε από το εμπόδιο της σήραγγας Simmons, είναι ένα απερίγραπτο μοντέλο. Οι Kwantyski et al. Πρότειναν μια απλούστερη και γενικότερη διάταξη που είναι κοντά στο φυσικό μοντέλο. Ο μαθηματικός τύπος του μοντέλου έχει ως εξής:

$$v(t) = \left[R_{off} + \frac{R_{off} - R_{on}}{x_{off} - x_{on}} (x - x_{on}) \right] i(t) \quad (87)$$

ή

$$v(t) = R_{on} \exp\left(\frac{\lambda}{x_{off} - x_{on}} (x - x_{on})\right) i(t) \quad (88)$$

$$\frac{dx(t)}{dt} = \begin{cases} k_{off} \left(\frac{i(t)}{i_{off}} - 1\right)^{a_{off}} f_{off}(x), & 0 < i_{off} < i \\ 0, & i_{on} < i < i_{off} \\ k_{on} \left(\frac{i(t)}{i_{on}} - 1\right)^{a_{on}} f_{on}(x), & i < i_{on} < 0 \end{cases} \quad (89)$$

Model	Linear ion drift	Nonlinear ion drift	Simmons tunneling barrier	TEAM
State variable	$0 \leq w \leq D$	$0 \leq x \leq 1$	$a_{off} \leq x \leq a_{on}$	$x_{on} \leq x \leq x_{off}$
Control mechanism	Current	Voltage	Current	Current
I-V relation	Explicit	Explicit	Ambiguous	Explicit
Memristance relation	Explicit	Ambiguous	Ambiguous	Explicit
Generic	No	No	No	Yes
Accuracy	Lowest	Low accuracy	Highest	Sufficient
Threshold exists	No	No	Yes	Yes

Figure 51 Συγκριση μοντέλων Memristor

Όπως παρατηρήσαμε από την Εξίσωση 89, η εξάρτηση του ρεύματος από την παράγωγο της εσωτερικής μεταβλητής κατάστασης x δεν είναι εκθέτης αλλά πολυώνυμο. Επιπλέον, σε αυτό το μοντέλο, η μεταβλητή x παραμένει σταθερή όταν είναι κάτω από ένα συγκεκριμένο όριο. Σε αυτόν τον τύπο μοντέλου, βλέπουμε δύο διαφορετικές εξισώσεις τάσης-ρεύματος. Όταν το memristor αλλάζει γραμμικά, χρησιμοποιείται η Εξίσωση 87. Αντίθετα, όταν αλλάζει εκθετικά ως προς το x , όπως στο μοντέλο φραγμού σήραγγας Simmons, ισχύει η σχέση 88, όπου $\lambda = \ln(R_{on} / R_{off})$. Μεταξύ αυτών, τα R_{on} και R_{off} είναι οι τιμές αντίστασης των x_{on} και x_{off} αντίστοιχα. Οι μεταβλητές i_{off} και i_{on} δίνουν τα άνω και κάτω όρια του ρεύματος στη συσκευή. Για να λειτουργήσει αυτό το μοντέλο, χρειάζεστε συναρτήσεις παραθύρου, τις οποίες χρησιμοποιείτε μεταβλητές f_{on} και f_{off} . Αυτές οι συναρτήσεις κινούνται γύρω από τα όρια της περιοχής $[x_{on}, x_{off}]$.

2.4.2 Photonics

2.4.2.1 Γενικά για τα ONN(Optical Neural Networks)

Το οπτικό νευρωνικό δίκτυο μπορεί να επεξεργαστεί τις πληροφορίες παράλληλα χρησιμοποιώντας την τεχνολογία που βασίζεται στον ελεύθερο χώρο και την ολοκληρωμένη πλατφόρμα. Κατά τη διάρκεια του τελευταίου μισού αιώνα, η ανάπτυξη ολοκληρωμένων κυκλωμάτων περιορίστηκε από το νόμο του Μουρ , καθώς επίσης γνωρίζουμε ότι τα νευρωνικά δίκτυα βασίζονται στον ψηφιακό υπολογιστή για διαδοχικούς υπολογισμούς πραγματικού χρόνου. Έτσι κρίνεται απαραίτητο να αναπτυχθούν τα ONN για επεξεργασία σε πραγματικό χρόνο καθώς επίσης και για την μείωση του όγκου των συσκευών που θα χρησιμοποιούν αυτές τις υλοποιήσεις.[33]

Οι γραμμικές λειτουργίες στα νευρωνικά δίκτυα περιλαμβάνουν πολλούς πολλαπλασιασμούς πινάκων, επομένως είναι σκόπιμο ο σχεδιασμός του ONN να εξετάσει τη χρήση οπτικών μεθόδων για την επίτευξη τέτοιων γραμμικών λειτουργιών. Επίσης πέρα από τις γραμμικές λειτουργίες ενός NN, πρέπει να εξετάσουμε και τις μη γραμμικές λειτουργίες αυτού όπως την συνάρτηση ενεργοποίησης του NN, η οποία είναι ζωτικής σημασίας στα βαθιά νευρωνικά δίκτυα. Στην πραγματικότητα, εάν τα βαθιά νευρωνικά δίκτυα δεν έχουν μη γραμμική ενεργοποίηση, τα κρυμμένα στρώματα στο δίκτυο είναι ισοδύναμα με ένα μόνο γραμμικό στρώμα, οπότε είναι αδύνατο να μάθουμε και να αναγνωρίσουμε το μη γραμμικό μοντέλο. Η έλλειψη άμεσης και αποτελεσματικής μη γραμμικότητας στην οπτική περιορίζει σοβαρά τον ρόλο της στον υπολογισμό της βαθιάς μάθησης, όπως επίσης και η αποτελεσματικότητα της οπτικής στην συνάρτηση ενεργοποίησης στα NN.

Έτσι, η εφαρμογή του ONN πρέπει να εξετάσει την οπτική γραμμική λειτουργία και τη μη γραμμική ενεργοποίηση. Η οπτική γραμμική λειτουργία μπορεί να πραγματοποιηθεί από FSOI (free space optical interconnection) και WOI(waveguide optical interconnection).

2.4.2.2 Χρήση FSOI για την υλοποίηση ONN

Με το FSOI αναφερόμαστε στον τρόπο διασύνδεσης στον οποίο το οπτικό σήμα διαδίδεται σε ελεύθερο χώρο μετά την εκπομπή του από τον πομπό και τελικά φθάνει στον δέκτη μετά την αλλαγή της οπτικής διαδρομής μέσω ορισμένων οπτικών στοιχείων, όπως ο φακός. Οι γραμμικές λειτουργίες στο ONN μπορούν να εφαρμοστούν μέσω του FSOI. Οι τεχνικές για την υλοποίηση των ONN είναι οι MLA(micro-lens array), SLM(spatial light modulator) και HOE(holographic element) που θα αναλυθούν παρακάτω.[33]

2.4.2.2.1 Χρήση SLM για την υλοποίηση FSOI ONN

Κατά την δεκαετία του 1980 δημιουργήθηκαν τα πρώτα ONN και το μαθηματικό μοντέλο τους προτάθηκε για πρώτη φορά από τον Hopfield το 1982 . Κατά τη διάρκεια αυτής της περιόδου, αναδυόμενες οπτικές τεχνολογίες όπως η οπτική μεταβλητότητα μπορούν να εκτελέσουν εργασίες κατωφλίου(threshold operations), οι οποίες ήταν απαραίτητες για την υλοποίηση αυτού του μοντέλου. Το SLM είναι μια συσκευή που διαμορφώνει τη χωρική κατανομή των κυμάτων φωτός καθώς και τη δέσμη σε πραγματικό χρόνο . Το συγκεκριμένο αποτελεί βασικό συστατικό της

επεξεργασίας οπτικών πληροφοριών σε πραγματικό χρόνο, της οπτικής πληροφορικής και άλλων συστημάτων. Παρακάτω θα γίνει μια προσπάθεια , να εισαγάγουμε τον τρόπο χρήσης του SLM για την πραγματοποίηση οπτικής διασύνδεσης και την κατασκευή του ONN.

Το 1985, η D.Pasltis και η H.Farhat ανέφεραν για πρώτη φορά ότι το νευρωνικό δίκτυο Hopfield (HNN) με βάση τον οπτικό πολλαπλασιαστή, θα μπορούσε να βελτιώσει την ακρίβεια και την ευρωστία της επεξεργασίας οπτικών πληροφοριών. Ωστόσο, ένα τέτοιο σύστημα έχει προβλήματα με τον κορεσμό σύναψης στο υλικό που σχετίζεται με το δίκτυο διασύνδεσης καθώς και με το ότι το δίκτυο συγκλίνει αργά. Κατά το επόμενο έτος, η H.K.Liu et al. εισήγαγε τον εσωτερικό επεξεργαστή οπτικής συστοιχίας , ο οποίος δεν χρειαζόταν να υπολογίσει εκ των προτέρων τον πίνακα διασύνδεσης και η διάσταση του πίνακα μειώθηκε κατά τη διαδικασία υπολογισμού, οπότε η συγκλίνουσα ταχύτητα του δικτύου ήταν ταχύτερη από εκείνη του πρώτερου μοντέλου. Παρόλο όμως που και τα δύο μοντέλα δεν είναι μεγάλα σε φυσικό μέγεθος, δεν ευνοείται η προώθηση μεγάλης κλίμακας.[33]

Ο Ohta et al. επωφελούμενος από την ανάπτυξη ολοκληρωμένης οπτικής, το 1989, σχεδίασε ένα μικροσκοπικό ενσωματωμένο τσιπ βασισμένο στο ONN, χρησιμοποιώντας την μάσκα SLM αντί της στατικής μάσκας, καταφέροντας να προσομοιώσει ένα σύστημα με 32 νευρώνες, το οποίο ήταν μια αρχική προσπάθεια για την υλοποίηση της συσχετιστικής οπτικής μνήμης. Επιπλέον, η Ying Zuο et al υλοποίησε AONN με ρυθμιζόμενες γραμμικές λειτουργίες χρησιμοποιώντας φακούς SLM και μετασχηματισμούς Fourier . Έτσι μέσω του συγκεκριμένου AONN μπορούν να ληφθούν στοιχεία πινάκων και μέσω συγκεκριμένου αλγορίθμου ανάδρασης να οδηγηθούμε σε ένα αποτέλεσμα με υψηλή ακρίβεια.

2.4.2.2.2 Χρήση συστοιχιών φακών (MLA) για την υλοποίηση FSOI ONN

Το MLA αποτελείται από μια σειρά φακών με κατάλληλη ρύθμιση για το διάφραγμα του φωτός και εστιακό βάθος σε επίπεδο μικρομέτρων. Στο συγκεκριμένο ,μια πλήρης κυματομορφή λέιζερ μπορεί να χωριστεί σε πολλά μικροσκοπικά μέρη στο εσωτερικό της συσκευής και κάθε μέρος αυτής να επικεντρώνεται από τον αντίστοιχο φακό. Με βάση αυτό μπορεί να υλοποιηθεί η διαδικασία της διαμόρφωσης κύματος φωτός, καθώς επίσης και δέσμες που ανήκουν σε άλλα σημεία στον χώρο της συσκευής να συγχωνευθούν για την υλοποίηση της γραμμικής πρόσθεσης. Παρακάτω γίνεται αναφορά στη χρήση του MLA για την πραγματοποίηση οπτικής διασύνδεσης και των τεχνιτών νευρωνικών δικτύων.

Το 1993, ο Yasunori Kuratomi πρότεινε ένα ONN με το χαρακτηριστικό της εξαγωγής διανυσμάτων καθώς και ένα καινοτόμο εξοπλισμό εξαγωγής διανυσμάτων (FEOND).Ο συγκεκριμένος είναι ένας μικρός πίνακας φακών 2×2 που χρησιμοποιείται στο δίκτυο για την απεικόνιση των ίδιων τεσσάρων περιοχών του δικτυωτού μοτίβου και την εστίαση αυτών των εικόνων στο FEOND, υλοποιώντας έτσι τη λειτουργία της πρώτης κρυφής στρώσης. Το δίκτυο αυτό, μπορεί να αναγνωρίσει σωστά χειρόγραφα γράμματα, τα οποία είναι εύκολο να εφαρμοστούν στην οπτική, αλλά δεν έχει ούτε μεταβλητότητα κλίμακας ούτε μεταβλητότητα μετατόπισης.

Επίσης εάν η θέση ή το μέγεθος των γραμμάτων αλλάξει σημαντικά, τα χαρακτηριστικά του διανύσματος θα αλλάξουν επίσης. Επιπλέον, η Taiwei Lu εισήγαγε ένα δισδιάστατο υβριδικό ONN χρησιμοποιώντας μια οθόνη βίντεο υψηλής ανάλυσης ως προγραμματιζόμενη συσχετιστική

μνήμη. Με αυτό βελτίωσε το μοντέλο Hopfield, πραγματοποιώντας έτσι και οπτική διασύνδεση αλλά και αποθήκευση μνήμης χρησιμοποιώντας MLA και μάλιστα με αυτοπροσαρμοσιμότητα. Ωστόσο, λόγω των περιορισμών της εκτροπής απεικόνισης και της ανίχνευσης φωτός, ο αριθμός των νευρώνων που τοποθετήθηκαν στη δομή ήταν σημαντικά περιορισμένος.

Με βάση αυτό, η ομάδα του Jianwen Yang πρότεινε ένα ONN που χρησιμοποιούσε συστοιχίες φακών και μήκη κύματος προερχόμενα από στοιχεία υγρού κρυστάλλου για να υλοποιήσει την πράξη της αφαίρεσης. Η συγκεκριμένη αφαίρεση μεταξύ του θετικού και του αρνητικού του προσομοιωτικού νευρώνα μετατρέπεται στην προσθήκη τιμών που προέρχονται από τα υγρα κρύσταλα. Το θέμα στην συγκεκριμένη περίπτωση είναι η δυσκολία της επεξεργασίας της κατάστασης ενός δισδυάστατου νευρώνα μιας και το δυναμικό όριο που σχετίζεται με τις εισόδους καθορίζεται σε μία μόνο μάσκα. Προκειμένου όμως να λυθεί το πρόβλημα της εκτροπής και να επεξεργαστούν τους νευρώνες εισόδου σε δύο διαστάσεις, η ομάδα του Yang παρουσίασε μια πειραματική συσκευή με νευρώνες 32 x 32, η διασύνδεση της οποίας πραγματοποιήθηκε με ομοαξονική συστοιχία φακών και εκτροπή κάτι το οποίο οδήγησε στην βελτίωση της.

2.4.2.2.3 Υλοποίηση ολογραφικού στοιχείου (HOE) για ONN(single layer)

Ένα μοντέλο νευρωνικού δικτύου μπορεί να αποτελείται από διάφορα διασυνδεδεμένα στρώματα. Η αρχή λειτουργίας πίσω από τα νευρωνικά με δύο στρώματα, είναι η ίδια με αυτή με μονό στρώμα, αλλά χρησιμοποιείται η ίδια υλοποίηση και στα υπόλοιπα στρώματα. Έτσι και με το ολογραφικό σύστημα μονού στρώματος του οποίου η αρχιτεκτονική επιβάλλει ένα επίπεδο εισόδου συνδεδεμένο με το επίπεδο εξόδου μέσω ενός ολογραφικού σχήματος διασύνδεσης.

Οι οπτικές διασυνδέσεις επιτυγχάνονται με ένα ολόγραμμα οπτικών αντικειμένων σε ποικίλα βάθη από το στρώμα εξόδου που αφαιρείται ως σταθμισμένες διασυνδέσεις μεταξύ των νευρώνων εισόδου και εξόδου. Κάθε νευρώνας εισόδου είναι ένα τμήμα που είτε μπλοκάρει (ανενεργός νευρώνας) τη δέσμη φωτός εισόδου είτε του επιτρέπει να περάσει (ενεργός νευρώνας) και στη συνέχεια




Figure 52 Μια ολογραφική αρχιτεκτονική ONN όπου η στρώση εισόδου συνδέεται με το επίπεδο εξόδου μέσω ενός ολογραφικού πίνακα. Κάθε στοιχείο εισόδου είναι ένας μηχανισμός κλείστρου (ελεγχόμενη διαφάνεια) που μπορεί ή δεν μπορεί να αφήσει τη δέσμη αναφοράς να περάσει. Η ολογραφική διασύνδεση είναι είτε μια 1D σειρά ολογραμμάτων ταινιών είτε μια 2D σειρά σημειακών ολογραμμάτων που κατευθύνει το φως στον ανιχνευτή στρώματος εξόδου μέσω κυλινδρικού φακού, δημιουργώντας έτσι σταθμισμένες συνδέσεις μεταξύ κάθε στοιχείου εισόδου και εξόδου[33]

φωτίζει το σχετικό ολόγραμμα του. Ο νευρώνας εισόδου μπορεί επομένως να είναι ένα απλό οπτικό κλείστρο ή ένα SLM που οδηγείται από έναν εξωτερικά ελεγχόμενο μηχανισμό εισόδου, όπως ένας υπολογιστής. Κάθε νευρώνας εξόδου είναι ένα οπτικό κλείστρο που καταγράφει τις συλλογικές εντάσεις των διαφόρων αντικειμένων σημείου στο προβαλλόμενο οπτικό πεδίο του. Ένας κυλινδρικός φακός χρησιμοποιείται για τη συλλογή των ακτίνων φωτός και την προβολή τους συλλογικά στον νευρώνα εξόδου. Ο νευρώνας εξόδου μπορεί επομένως να είναι μια συσκευή ανίχνευσης φωτός, όπως ένας εμπορικός οπτικός αισθητήρας που χρησιμοποιείται στις ψηφιακές φωτογραφικές μηχανές. Τέλος, το επίπεδο ολογράμματος διασύνδεσης αποτελείται από ένα ολόγραμμα πίνακα σημείων που αποτελείται από σημεία σε διάφορα βάθη τα οποία αφορούν τις σχετικές σταθμισμένες διασυνδέσεις τους.[33]

Ωστόσο, η χρήση ενός ενιαίου ολογράμματος για ολόκληρο το σύνολο των διασυνδέσεων μπορεί να οδηγήσει σε μειωμένη ανάλυση μέσω αντίστροφης συνένωσης στη φάση ανασυγκρότησης. Τέλος, κάθε νευρώνας εισόδου είναι ανεξάρτητος από τους άλλους νευρώνες στο στρώμα εισόδου και στις διασυνδέσεις του με τους νευρώνες του στρώματος εξόδου, κάθε νευρώνας εισόδου συνδέεται με το στρώμα εξόδου μέσω του δικού του ολόγραμμα που ονομάζεται ταινία ολόγραμματος(hologram strip).Το συγκεκριμένο σύστημα διασύνδεσης μπορεί να καθιερωθεί μέσω μιας 1D σειράς ολογραμμάτων ταινιών σύνδεσης μίας εισόδου-σε-πολλές εξόδους, είναι επίσης κατάλληλο να εφαρμοστεί μια 2D σειρά ολογραμμάτων διασύνδεσης ενός σημείου διασύνδεσης μίας εισόδου προς μία έξοδο για κάθε διασύνδεση εισόδου-εξόδου

2.4.2.3 Χρήση WOI για την υλοποίηση ONN

Οι οπτικοί κυματοδηγοί είναι συσκευές που καθοδηγούν τη διάδοση των κυμάτων φωτός και χωρίζονται σε δύο κατηγορίες. Το ένα είναι κυλινδρικός οπτικός κυματοδηγός , που συχνά ονομάζεται οπτική ίνα. Το άλλο είναι ο ολοκληρωμένος οπτικός κυματοδηγός , συμπεριλαμβανομένων των πλανητικά οπτικών κυματοδηγών και των οπτικών κυματοδηγών τύπου stripe.

2.4.2.3.1 ONN: βασισμένα στην υλοποίηση με οπτικές ίνες

Η F.Duport et al το 2012 πρότεινε μια εφαρμογή εξ ολοκλήρου οπτική με βάση την υπολογιστικής δεξαμενής, η οποία υλοποιούνται μέσω μιας συστοιχίας οπτικών ενισχυτών . Η εκπαίδευση εκτός σύνδεσης πραγματοποιείται με τη χρήση της εναλλαγής καθυστέρησης ινών ενός μη γραμμικού κόμβου, στον οποίο η μη γραμμικότητα πραγματοποιείται με τη χρήση της επίδρασης κέρδους κορεσμού του οπτικού ενισχυτή ημιαγωγών .

Μετά αυτού, ο T.Cheng et al. πρότεινε ένα σύστημα ONN βασισμένο στην υπολογιστική δεξαμενής το 2019 , όπου στην συγκεκριμένη περίπτωση οι οπτικοί νευρώνες μπορεί να υλοποιηθούν με βάση τους κατευθυντικούς συζευκτές, οπτικές ίνες και ενισχυτές.

Επίσης σε επόμενη προσπάθεια ερευνητών , χρησιμοποιήσαν ενισχυτές για να συνειδητοποιήσουν το κατώφλι ορίου, το οποίο ισοδυναμεί με μη γραμμική ενεργοποίηση,

όπου τα αποτελέσματα έδειξαν ότι το ONN μπορεί να παρέχει καλύτερη απόδοση και να αναγνωρίσει τη κυματομορφή σήματος εισόδου.

2.4.2.3.2 ONN: BASED ON INTEGRATED OPTICAL WAVEGUIDE PLATFORM(υλοποίηση με ολοκληρωμένους κυματοδηγούς)

Η ενσωμάτωση των οπτικών στοιχείων μπορεί να μειώσει σημαντικά το χώρο που καταλαμβάνουν οι νευρώνες, ειδικά με την χρήση υλικών PCM(phase change materials), γεγονός που επιφέρει μεγάλες αλλαγές στην περαιτέρω ανάπτυξη του ONN. Το 2011, ο C.David Wright εισήγαγε τη χρήση PCM για αριθμητικό και βιο-εμπνευσμένο υπολογισμό , και παρείχε το πειραματικό πρότυπο για την απόδειξη του "επεξεργαστή" με βάση το PCM (υλικό αλλαγής φάσης), επιδυκνύοντας την λειτουργικότητα των τέσσαριων βασικών λειτουργιών, της προσθεσης, του πολλαπλασιασμού, της διαίρεσης και της αφαίρεσης και αποθηκεύοντας ταυτόχρονα τα αποτελέσματα. Την ίδια χρονιά, Η D.Kuzum ανέφερε νέες ηλεκτρονικές συνάψεις νανοκλίμακας βασισμένες σε PCM για αποθήκευση οπτικών δεδομένων και μη πτητική αποθήκευση . Γενικότερα , Οι συνεχείς μεταβάσεις αντίστασης στο PCM (υλικό αλλαγής φάσης) χρησιμοποιούνται για να προσομοιώσουν τις ιδιότητες των βιολογικών συνάψεων έτσι ώστε να πραγματοποιηθούν οι συναπτικοί κανόνες εκμάθησης.

Τέλος, γενικότερα, οι ενσωματωμένες φωτονικές πλατφόρμες και συσκευές έχουν βιώσει ταχεία ανάπτυξη από το 2008 έως το 2018 και έχουν γίνει όλο και πιο ώριμες. Έτσι να προκύψουν ONN που βασίζονται σε ολοκληρωμένη τεχνολογία διασύνδεσης οπτικών κυματοδηγών.

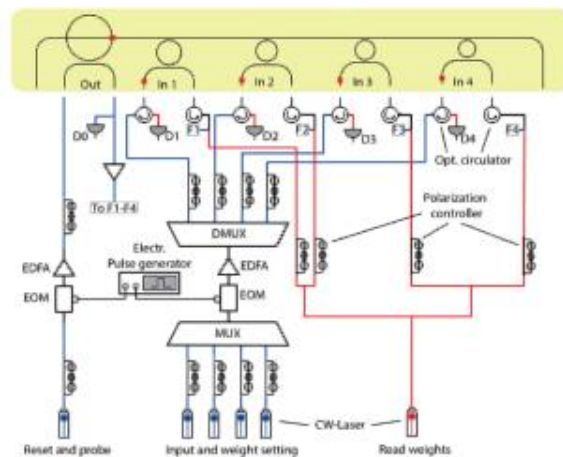


Figure 53 Υλοποίηση νευρωνικού με την χρήση κυματοδηγών[33]

2.4.3 Spintronics

2.4.3.1 Γενικά για τις Spintronic Συσκευές

Οι συσκευές Spintronic, οι οποίες έχουν μελετηθεί εκτενώς ως μονάδες μνήμης, έχουν εγγενώς τις απαιτούμενες δυναμικές ιδιότητες των βασικών στοιχείων (νευρώνες και συνάψεις) σε ANN . Η μη γραμμική δυναμική ενός τεχνητού νευρώνα μπορεί να αντικατασταθεί από την δυναμική μαγνήτισης (magnetization dynamics), καθώς η τελευταία περιγράφεται από τη μη γραμμική εξίσωση Landau-Lifshitz-Gilbert. Η μεταβλητή αντίσταση που χρησιμοποιείται στις συσκευές μαγνητικής μνήμης είναι φυσικά τεχνητές συνάψεις, των οποίων η μη κινητικότητα μειώνει περαιτέρω την κατανάλωση ενέργειας. Επιπλέον, η εξαιρετικά μεγάλη αντοχή των μαγνητικών συσκευών είναι ιδιαίτερα κατάλληλη για την εφαρμογή επαναπρογραμματιζόμενων νευρωνικών δικτύων.

Στη συνέχεια, η εστίαση της προηγούμενης έρευνας περί spintronics, η οποία είχε ως στόχο την ανάπτυξη συσκευών μνήμης, θα επεκταθεί κατάλληλα για την επίτευξη νευρωνικών spintronic δικτύων . Για παράδειγμα, η υλοποίηση μιας συσκευής ως συσκευή μνήμης, χρειάζεται μόνο να ανιχνεύσει τις στατικές καταστάσεις πριν και μετά τη μαγνητική εναλλαγή, ενώ η δυναμική διαδικασία μαγνήτισης είναι απαραίτητη τόσο για τη νευρομορφική πληροφορική όσο και για τη στοχαστικότητα. Ένα απαραίτητο βήμα για την υλοποίηση του υλικού των νευρωνικών δικτύων spintronic είναι η εύρεση των κατάλληλων συσκευών για την αντικατάσταση των μαθηματικών μοντέλων στα υπολογιστικά μοντέλα, όπου οι νευρώνες και οι συνάψεις περιγράφονται συνήθως από διαφορικές εξισώσεις.

Ειδικότερα για τα ANN, Οι συνάψεις είναι η αποθήκευση σε νευρωνικά δίκτυα και πρέπει να παραμετροποιηθούν στην διαδικασία εκπαίδευσης. Τα μεμριστορες , λόγω της μεταβλητότητας της αντίστασης τους, χρησιμοποιούνται ευρέως στην εφαρμογή των συνάψεων υλικού. Για την υλοποίηση των συγκεκριμένων διατάξεων, χρησιμοποιήθηκε η μαγνητική σύνδεση σηράγγων μαγνησίου-οξειδίου (MTJ) στην οποία η παραλλαγή αντίστασης ελέγχεται από την τάση. [16]

Ετσι θα προσπαθήσουμε παρακάτω να δούμε τις βασικές τεχνολογίες υλοποίησης spintronic κελιών-νευρώνων για την αξιόπιστη χρήση της τεχνολογίας αυτής.

2.4.3.2 Spin Transfer Torque technology μέσω του MTJ

Η spin transfer torque τεχνολογία βασίζεται στο φαινόμενο MTJ(magnetic transfer junction) κατά το οποίο με την εφαρμογή τάσης σε μία διάταξη αλλάζει το spin με την χρήση κατάλληλα πολωμένου ρεύματος . Συγκεκριμένα, ένα από τα μαγνητικά στρώματα έχει σταθερό σιδηρομαγνητικό προσανατολισμό και χρησιμεύει ως αναφορά, έτσι το στρώμα ονομάζεται επίπεδο

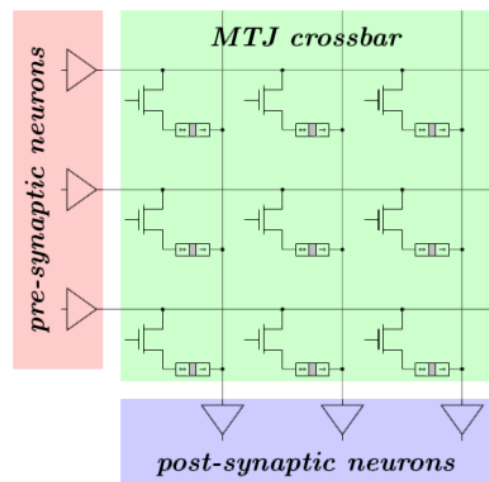


Figure 54 Εικονοποίηση mjt array [31]

αναφοράς.

Το άλλο σιδηρομαγνητικό στρώμα είναι ελεύθερο να αλλάξει τον μαγνητικό προσανατολισμό του, εξ ου και ονομάζεται Ελεύθερο Στρώμα. Το περιεχόμενο του MTJ αντιπροσωπεύεται από την κατάσταση μαγνήτισης της ελεύθερης στρώσης σε σχέση με το επίπεδο αναφοράς, όπου μπορεί είτε να μαγνητιστεί προς την ίδια κατεύθυνση με εκείνη του στρώματος αναφοράς, που ονομάζεται παράλληλη κατάσταση (P), είτε μπορεί να μαγνητιστεί στην αντίθετη μαγνητική κατεύθυνση, την κατάσταση αντι-παράλληλου (AP). Για την αλλαγή της κατάστασης, απαιτείται ένα ρεύμα εγγραφής μεγαλύτερο από κρίσιμο ρεύμα της συστοιχίας MTJ. Ανάλογα με την κατεύθυνσή του ρεύματος, το κελί αλλάζει είτε από P σε AP είτε από AP σε P. Στην κατάσταση P, το MTJ παρουσιάζει χαμηλή αντίσταση (RP), ενώ η κατάσταση AP έχει ως αποτέλεσμα υψηλή αντίσταση (RAP). Οι καταστάσεις αυτές μπορούν να χρησιμοποιηθούν για την ανάγνωση της κατάστασης του κάθε μαγνητικού κελιού. Ειδικότερα για την τεχνολογία MJT θα μιλήσουμε στην επόμενη παράγραφο.




Figure 55 MJT κελί[31]

2.5 Νευρωνικά δίκτυα αιχμών

Η νευρωνική επικοινωνία με την τεχνολογία των ΤΝΔ πρώτης γενιάς που αναπτύχθηκε βασίζεται σε γενικές υποθέσεις και απλοποιημένες υποθέσεις, οδηγώντας σε μη ρεαλιστικές προσομοιώσεις και γενικότερη μοντελοποίηση του ανθρώπινου εγκεφάλου. Για παράδειγμα, οι νευρώνες στον εγκέφαλο επικοινωνούν μεταξύ τους μέσω της ανταλλαγής ηλεκτρικών ερεθισμάτων, που ονομάζονται επίσης αιχμές.

Η ανάπτυξη του προκύπτοντος πολύπλοκου βιολογικού μοντέλου, που ονομάζεται τεχνητό νευρωνικό δίκτυο αιχμής, στοχεύει στην προσομοίωση της πολύπλοκης δομής του ανθρώπινου εγκεφάλου και της επεξεργασίας και μετάδοσης νευρωνικών πληροφοριών με τον πιο ρεαλιστικό τρόπο. Σε σύγκριση με τις συνήθεις συνεχείς μεταβλητές, το ΤΝΔ χρησιμοποιεί την ακολουθία αιχμής ως μηχανισμό για την εσωτερική παρουσίαση πληροφοριών και έχει τουλάχιστον την ίδια απόδοση υπολογιστικού κόστους με την παραδοσιακά ΝΝ. [7]

Πρόσφατα, πολλές μελέτες έχουν χρησιμοποιήσει NN σε πρακτικές εφαρμογές και τα αποτελέσματα είναι πολλά υποσχόμενα για την επίλυση πρακτικών πολύπλοκων προβλημάτων. Σημαντική πρόοδος έχει σημειωθεί στις εφαρμογές τους στην αναγνώριση ομιλίας, στην μηχανική όραση και σε άλλους τομείς. Προκειμένου να κατανοηθεί πλήρως η λειτουργία των NN, είναι απαραίτητο να γίνει μια ολοκληρωμένη εισαγωγή στη λειτουργία του ανθρώπινου εγκεφάλου και στους ορισμούς που χρησιμοποιούνται στη νευροφυσιολογία, επειδή τα NN χρησιμοποιούν αυτές τις λειτουργίες και τους αντίστοιχους ορισμούς. Τα παραπάνω θα αναλυθούν στο Κεφάλαιο 3.

2.6 Liquid state Machines

Πολλά πολύπλοκα προβλήματα υπολογισμού έχουν μια αρχή, η οποία περιλαμβάνει όχι μόνο τη σημασία των δεδομένων εισόδου, αλλά και την ακριβή σειρά και ακρίβειά τους στο χρόνο. Διαδικασίες όπως η αναγνώριση ομιλίας, η ανίχνευση αντικειμένων, ο έλεγχος ρομπότ και ακόμη και η βιομετρική αναγνώριση είναι εγγενώς χρονοβόρες διαδικασίες επειδή θεωρείται ότι απαιτούν τη χρήση (τεχνητής) νοημοσύνης. Ωστόσο, τα περισσότερα μοντέλα υπολογισμού όχι μόνο δεν λαμβάνουν ρητά υπόψη τη χρονική διάσταση των δεδομένων, αλλά επίσης δεν μετατρέπουν τα δεδομένα εισόδου που σχετίζονται με το χρόνο σε στατικά δεδομένα, όπως η χρήση ουρών..

Αυτές οι μέθοδοι αφηφούν τις πληροφορίες χρόνου που περιέχονται στα δεδομένα. Πιο συγκεκριμένα, για ένα συγκεκριμένο χρονικό παράθυρο, η χρονική συσχέτιση των δεδομένων εισόδου συμπιέζεται σε ένα στατικό στιγμιότυπο, με αποτέλεσμα τη μερική απώλεια, ενώ χάνεται η χρονική συσχέτιση μεταξύ διαφορετικών χρονικών παραθύρων. Λόγω του τρόπου κατασκευής της, η Μηχανή Υγρής Κατάστασης (LSM) αποφεύγει τέτοια προβλήματα. Συγκεκριμένα, το LSM είναι ένα υπολογιστικό μοντέλο και η δομή του φαίνεται στο παρακάτω σχήμα: 1) Η δεξαμενή του κόμβου περιοδικής αλληλεπίδρασης λαμβάνει ερεθίσματα από την είσοδο $u(t)$, εξάγει την τρέχουσα ή ρευστή κατάσταση $x(t)$ και χρησιμοποιεί μια μέθοδο ανάγνωσης Πάρτε την έξοδο f^M για να μετατρέψετε την πολυδιάστατη ρευστή κατάσταση $x(t)$ στο επιθυμητό αποτέλεσμα $y(t)$. [32]




Figure 56 Liquid State machine[33]

Οι επαναληπτικές δομές που έχουν σχηματιστεί στις περιοδικές συνδέσεις μεταξύ των κόμβων της δεξαμενής προκαλούν μία αλληλεπίδραση τύπου βραχύχρονης μνήμης, όπου στην περίπτωση αυτή η επίδραση των δεδομένων που δίνεται στο δίκτυο διατηρείται για κάποιο χρονικό διάστημα μέχρι να σβήσει. Αυτή η ιδιότητα ονομάζεται χρονική ενσωμάτωση. Η

δεξαμενή(reservoir) ή το ρευστό(liquid) μπορεί να είναι οποιοδήποτε είδος δικτύου το οποίο έχει επαρκή εσωτερική δυναμική.

Σε αυτούς τις διατάξεις, η πραγματική ταυτότητα της συνάρτησης εξόδου δεν έχει δηλωθεί με ακρίβεια, δηλαδή μπορεί να είναι οποιαδήποτε μέθοδος στατιστικής ανάλυσης ή αναγνώρισης προτύπων. Οι πιθανές συναρτήσεις εξόδου μπορεί να περιλαμβάνουν γραμμική πρόβλεψη, ανάλυση διαχωρισμού Fisher, αλγόριθμους perceptron και τάξεις MLP που έχουν εκπαιδευτεί για backpropagation. Θα πρέπει να σημειωθεί ότι το ρευστό δεν εκπαιδεύεται από μόνο του, αλλά του δίνεται μια ευρετική λειτουργία για την τυχαία παραγωγή «ενδιαφέροντων» ρευστών. Προσαρμόστε μόνο τη λειτουργία εξόδου έτσι ώστε το LSM να μπορεί να εκτελέσει αυτήν τη διαδικασία.

Σε σύγκριση με τα παραδοσιακά επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), ο διαχωρισμός μεταξύ του ρευστού και της λειτουργίας εξόδου του παρέχει δύο επιπλέον πλεονεκτήματα. Αρχικά, η λειτουργία εξόδου είναι συνήθως πιο εύκολη στην εκπαίδευση από το ρευστό, το οποίο είναι ένα περιοδικά συνδεδεμένο δίκτυο. Επιπλέον, η δομή LSM επιτρέπει τη χρήση πολλαπλών συναρτήσεων εξόδου για το ίδιο ρευστό και κάθε συνάρτηση εξόδου μπορεί να εκπαιδευτεί ώστε να εκτελεί διαφορετικές διεργασίες χρησιμοποιώντας τα ίδια δεδομένα εισόδου και το ίδιο ρευστό. Αυτό σημαίνει ότι το ρευστό χρειάζεται να υπολογιστεί μόνο μία φορά, γεγονός που επιτρέπει την παράλληλη επεξεργασία του LSM χωρίς την ανάγκη πρόσθετης ισχύος επεξεργασίας.

3 - Νευρωνικά Δίκτυα Αιχμών

Ενόψει της παράκαμψης των απλών υποθέσεων και γενικεύσεων της υπάρχουσας τεχνολογίας νευρωνικών δικτύων πρώτης γενιάς και από την επιθυμία να κατανοηθούν καλύτερα οι πραγματικές δυνατότητες επεξεργασίας των νευρωνικών πληροφοριών, σε συνδυασμό με τις αυξανόμενες δυνατότητες των υπολογιστικών συστημάτων στην επιστήμη, η κοινότητα έχει αναπτύξει σύνθετα βιο-μαθηματικά μοντέλα, που ονομάζεται Spike Neural Network (SNN), στοχεύει στην προσομοίωση της πολύπλοκης δομής του ανθρώπινου εγκεφάλου και του τρόπου με τον οποίο επεξεργάζεται και επεξεργάζεται τις πληροφορίες με τον πιο ρεαλιστικό τρόπο. Σε σύγκριση με τις συνήθεις συνεχείς μεταβλητές, τα TNA χρησιμοποιούν αιχμές ως μηχανισμό για την εσωτερική παρουσίαση πληροφοριών και σε ορισμένες εφαρμογές έχουν τουλάχιστον την ίδια απόδοση υπολογιστικού κόστους με τα παραδοσιακά τεχνητά νευρωνικά δίκτυα [47]. Τα τελευταία χρόνια, έχουν γίνει πολλές μελέτες σχετικά με τη χρήση του TNA σε πρακτικές εφαρμογές και τα αποτελέσματα φαίνονται πολλά υποσχόμενα για την επίλυση πρακτικών πολύπλοκων προβλημάτων [5].

Σε αυτή την ενότητα θα παρουσιάσουμε τα θεμελιώδη χαρακτηριστικά των ΝΔΑ και τα σημεία στα οποία αυτά διαφέρουν από τα παραδοσιακά τεχνητά νευρωνικά δίκτυα. Αρχικά, θα απεικονίσουμε τον τρόπο με τον οποίο οι βιολογικοί νευρώνες λειτουργούν και διαβιβάζουν σήματα μεταξύ τους. Έπειτα, θα παρουσιαστούν οι μαθηματικές αναπαραστάσεις των νευρωνικών δυναμικών που χρησιμοποιούν τα ΝΔΑ. Τέλος, θα γίνει μία εισαγωγή στα εργαλεία που χρησιμοποιούνται για την προσομοίωση αυτών των νευρωνικών δικτύων, είτε με τη χρήση κατάλληλου λογισμικού είτε με τη βοήθεια νευρομορφικού υλικού.



Figure 57 Συνεδριας καταγραφής νοητικών κινήσεων

3.1 Νευροφυσιολογία του ανθρώπινου εγκεφάλου

Σε κυτταρικό επίπεδο, το κεντρικό νευρικό σύστημα αποτελείται από δύο τύπους κυττάρων: νευρώνες (η βασική υπολογιστική μονάδα του εγκεφάλου) και νευρογλοιακά κύτταρα (δομή και μεταβολική δομή κυττάρων υποστήριξης). Εδώ, θα επικεντρωθούμε στο πρώτο, επειδή οι νευρώνες είναι τα βασικά στοιχεία ανώτερων εγκεφαλικών λειτουργιών όπως η νοημοσύνη, η σκέψη και η δράση. Ο ανθρώπινος εγκέφαλος περιέχει περίπου 100 δισεκατομμύρια τέτοιες υπολογιστικές μονάδες και τέσσερις τάξεις μεγέθους συνδέσεων και συνάψεων. Αν και οι εγκεφαλικοί νευρώνες είναι πολύ περίπλοκοι και μεγάλοι ως όργανο, λόγω του σχήματός τους, οι εγκεφαλικοί νευρώνες μπορούν να στείλουν σήματα σε άλλα κύτταρα με εξαιρετικά γρήγορη ταχύτητα και ακρίβεια μέσω των συνάψεων.

3.1.1 Νευρώνες

Ένας τυπικός νευρώνας αποτελείται από τρία λειτουργικά μέρη: δενδρίτες, κυτταρικά σώματα και άξονες (βλ. Εικόνα 60). Οι δενδρίτες των νευρώνων λαμβάνουν ερεθίσματα από άλλους νευρώνες και μεταδίδουν νευρωνικά σήματα στο κυτταρικό σώμα. Το σώμα είναι το κύριο μέρος των νευρώνων, ως μη γραμμικός ρυθμιστής, που πυροδοτεί σήματα εξόδου όταν η αθροιστική συνολική είσοδος σήματος των νευρώνων υπερβαίνει ένα δεδομένο όριο. Το σήμα εξόδου διαδίδεται από τον εκθετικό κώνο (το σημείο όπου το σώμα συνδέεται με τον άξονα) κατά μήκος του άξονα σε άλλους νευρώνες. Οι περισσότεροι νευρώνες έχουν μόνο έναν άξονα, αλλά μπορεί να συνδέονται με πολλούς νευρώνες μέσω αξόνων

Η διάδοση του σήματος από έναν νευρώνα σε έναν άλλο νευρώνα συμβαίνει στη συμβολή αυτών των δύο νευρώνων, τη σύναψη (Εικόνα 60). Η ρύθμιση είναι απλή: ένα προσυναπτικό κελί στέλνει ένα σήμα και ένα άλλο μετασυναπτικό κελί λαμβάνει το σήμα. [8]




Figure 58 Λειτουργικά μέρη ενός βιολογικού νευρώνα. Ένα προσυναπτικό κύτταρο (a) συνδέεται με ένα μετασυναπτικό κύτταρο μέσω μίας (b) σύναψης και μεταφέρει το (c) δυναμικό δράσης κατά μήκος του νευρώνα[7]

3.1.2 Νευρωνικά σήματα

Τα νευρικά σήματα που διαδίδονται μεταξύ των νευρώνων είναι πολύ μικρά σε πλάτος και διάρκεια ηλεκτρικών παλμών (δυναμικά δράσης). Το σχήμα 60 (γ) δείχνει την καταγραφή του δυναμικού δράσης που παρατηρήθηκε από τους Hodgkin και Huxley στον άξονα των καλαμαριών. Ένα τυπικό δυναμικό δράσης, ή συνήθως ονομάζεται ακίδα, έχει πλάτος περίπου

100 mV και διαρκεί 1-2 χιλιοστά του δευτερολέπτου. Συνήθως, υπάρχει μια χρονική περίοδος μετά την κορύφωση που οι νευρώνες δεν ανταποκρίνονται σε περαιτέρω ερεθίσματα. Αυτή η ελάχιστη χρονική διαφορά μεταξύ των δύο κορυφών του νευρώνα είναι η μη διεγερμένη περίοδος κατά την οποία δεν μπορούν να παραχθούν άλλες αιχμές.

Το μέγεθος και η διάρκεια των πυροδοτήσεων δεν διαφέρουν πολύ μεταξύ των διαφορετικών ειδών και διατηρούν το ίδιο σχήμα με τον ηλεκτρικό παλμό που μεταδίδεται κατά μήκος του άξονα, όπως φαίνεται στο Σχήμα 60. Επομένως, το σχήμα του δυναμικού δράσης φέρει τις λιγότερες πληροφορίες, ενώ η συχνότητα και ο χρόνος αιχμής για την επίτευξη κωδικοποίησης μηνύματος. Η σειρά των δυναμικών δράσης που παράγονται από τους νευρώνες ονομάζονται αλληλουχίες ακίδων. Μπορούμε να σκεφτούμε μια σειρά κορυφών ως δυαδικά συμβάντα που συμβαίνουν σε διακριτό χρόνο, όπου το 1 αντιστοιχεί στην ύπαρξη της κορυφής και το 0 αντιστοιχεί στο αντίθετο. Επομένως, η κωδικοποίηση των πληροφοριών μπορεί να επιτευχθεί αλλάζοντας τη συχνότητα και το χρόνο αυτών των δυαδικών γεγονότων. [7]

3.1.3 Μετάδοση σημάτων

Η πυροδότηση, ως ηλεκτρικό σήμα διαδίδεται μέσω της τομής αυτών των νευρώνων σε άλλους νευρώνες, δηλαδή σε χημικές συνάψεις. Οι άξονες των προσυναπτικών νευρώνων είναι πολύ κοντά στους δενδρίτες (ή κυτταρικά σώματα) των μετασυναπτικών νευρώνων (περίπου 20 νανόμετρα). Ο μικροσκοπικός χώρος στη σύναψη που συνδέει δύο νευρώνες ονομάζεται κενό, όπως φαίνεται στο σχήμα 2.9 (β). Σε αυτή τη χημική σύνθεση, το δυναμικό δράσης που δημιουργείται από τον προσυναπτικό νευρώνα πυροδοτεί την απελευθέρωση συγκεκριμένων χημικών μορίων, δηλαδή του νευροδιαβιβαστή στη συναπτική σχισμή. Μόλις ένας μετασυναπτικός νευρώνας ανιχνεύσει την παρουσία ενός νευροδιαβιβαστή, ανοίγει ένα ειδικό κανάλι ιόντων για να επιτρέψει την είσοδο ρεύματος. Τα κανάλια ιόντων είναι διαμεμβρανικές πρωτεΐνες που εμπλέκονται ειδικά στη μεταφορά ανόργανων ιόντων μέσα και έξω από τα κύτταρα.

Η ικανότητα των νευρώνων να προσαρμόζουν τις μεθόδους επικοινωνίας τους ονομάζεται συναπτική πλαστικότητα. Οι αλλαγές στη συναπτική πλαστικότητα σχετίζονται με διαφορετικές μορφές μνήμης και μαθησιακής ικανότητας. Η αποτελεσματικότητα της συσταλτικής πλαστικότητας, όπως η κινητική της προσυναπτικής απόκρισης λόγω της απελευθέρωσης νευροδιαβιβαστών, δεν είναι σταθερή. Υπάρχουν πολλοί παράγοντες που επηρεάζουν τη διαδικασία της συναπτικής πλαστικότητας. Για παράδειγμα, η αλλαγή του χρονισμού της δραστηριότητας των υποδοχέων στους μετασυναπτικούς νευρώνες παίζει σημαντικό ρόλο. Η θεωρία πίσω από τη συναπτική πλαστικότητα θα συζητηθεί λεπτομερέστερα ες παρακάτω κεφάλαιο[17]

3.2 Νευρωνική Κωδικοποίηση

Η νευρωνική κωδικοποίηση (NC) είναι το πεδίο ανάλυσης και χαρακτηρισμού της σχέσης μεταξύ ερεθισμάτων και ατομικής ή ολικής νευρικής απόκρισης, της σχέσης μεταξύ της ηλεκτρικής δραστηριότητας των νευρώνων στο σύνολό τους και της διαδικασίας μετασχηματισμού και αναπαράστασης πληροφοριών σε κάποια μορφή. για μετάδοση και επεξεργασία.

Δεδομένου ότι οι νευρώνες χαρακτηρίζονται από το ότι μπορούν να μεταδώσουν σήματα γρήγορα σε μεγάλες αποστάσεις μέσω νευρικών ινών χρησιμοποιώντας τον μηχανισμό που

παράγει παλμούς (σε αυτή την περίπτωση, ενεργειακό δυναμικό (αιχμή)), έτσι σε πολλές περιπτώσεις, οι νευρώνες θα τους αλλάξουν. μεταδίδεται, δηλαδή το συντάσσουν σύμφωνα με διάφορα χρονικά και χωρικά πρότυπα, που συνήθως επηρεάζονται από εξωτερικούς παράγοντες όπως το φως, ο ήχος, η γεύση, η μυρωδιά και η αφή, είτε λόγω της φύσης του τελικού αποδέκτη, που μπορεί να είναι κάποιο αισθητήριο όργανο, όπως τα μάτια, η μύτη, η γλώσσα. Στην περίπτωση των δυναμικών δράσης, υπάρχει ένας παρόμοιος κωδικός, ο οποίος ποικίλλει ανάλογα με τη διάρκεια, το πλάτος, την ένταση και το μήκος του διαστήματος μεταξύ δύο διαδοχικών κορυφών στην ακολουθία των διαδοχικών κορυφών

Από αυτή την άποψη, η νευρωνική κωδικοποίηση στα ΠΝΝ είναι η διαδικασία κωδικοποίησης δεδομένων εισόδου στο δίκτυο σε μια κατάλληλη μορφή δεδομένων και αυτά τα δεδομένα μεταδίδονται ως σειριακά σήματα αιχμής στα ΠΝΝ. Η κωδικοποίηση των πληροφοριών εισόδου σε ένα σήμα αιχμής και η ανάλυση του χρόνου αιχμής για επεξεργασία και η λήψη της βέλτιστης απόφασης είναι τα κύρια και πιο δύσκολα αντικείμενα της έρευνας και της έρευνας του ΠΝΝ, επειδή η τυποποίηση των διαδικασιών και των μεθόδων είναι στις περισσότερες περιπτώσεις, Πώς αντιμετωπίζεται η πρόβλημα που πρέπει να λυθεί

Παρά τα παραπάνω ευρήματα, παραδοσιακά, υπάρχουν δύο βασικές θεωρίες για τη μέθοδο ΝΚ. Στη συνέχεια περιγράφεται η μέθοδος κωδικοποίησης ρυθμού και η μέθοδος κωδικοποίησης παλμού [17].

3.2.1 Κωδικοποίηση Ρυθμού

Η πρώτη θεωρία υποθέτει ότι ο μέσος ρυθμός πυροδότησης των νευρώνων μεταφέρει τα πάντα σχετικά με τη μετάδοση πληροφοριών. Ο μέσος όρος εκπομπής u συνήθως κατανοείται ως ο λόγος του μέσου αριθμού αιχμών n_{sp} που παρατηρούνται σε μια χρονική περίοδο, όπως φαίνεται στην ακόλουθη σχέση:

$$u = \frac{n_{sp}}{T} \quad (90)$$

Το μοντέλο αυτό είναι ιδιαίτερα επιτυχημένο σε εφαρμογές σε αισθητηριακές προσομοιώσεις ή στη χρήση μηχανοκίνητων νευρικών συστημάτων. Ωστόσο, η ιδέα του μέσου ρυθμού πυροδότησης έχει επικριθεί επανειλημμένα. Το κύριο επιχείρημα είναι ότι η μετάδοση πληροφοριών από τον έναν νευρώνα στον άλλο είναι σχετικά αργή, επειδή κάθε νευρώνας πρέπει να ενσωματώσει τη δραστηριότητα του προσυναπτικού νευρώνα για τουλάχιστον μία περίοδο. . χρόνος. Συγκεκριμένα, ο χρόνος απόκρισης του εγκεφάλου σε ορισμένα ερεθίσματα είναι τόσο σύντομος που δεν μπορεί να εξηγηθεί με αυτή τη μέθοδο. Για παράδειγμα, ο ανθρώπινος εγκέφαλος μπορεί να αναγνωρίσει οπτικά ερεθίσματα σε περίπου 150 χιλιοστά του δευτερολέπτου.

Όταν το ερέθισμα αλλάζει αργά και ο χρόνος παρατήρησης είναι αρκετά μεγάλος για να εκτιμηθεί ο μέγιστος ρυθμός εξόδου, η κωδικοποίηση ρυθμού λειτουργεί καλά. Ωστόσο, στην πράξη, ερεθίσματα όπως η οπτική αισθητηριακή είσοδος θα αλλάξουν γρήγορα και οι νευρώνες θα ανταποκριθούν σε σύντομο χρονικό διάστημα. Δεδομένου ότι η κωδικοποίηση χρόνου κωδικοποιεί πληροφορίες σε ακριβή χρονισμό αιχμής, είναι πιο κατάλληλη για την κωδικοποίηση ταχέως μεταβαλλόμενων ερεθισμάτων.

Είναι γνωστό ότι ένας μέτριος αριθμός νευρώνων εμπλέκεται στην επεξεργασία των οπτικών ερεθισμάτων. Εάν κάθε επίπεδο πρέπει να περιμένει για ένα χρονικό διάστημα για να λάβει τις πληροφορίες του ανώτερου επιπέδου, ο χρόνος αναγνώρισης θα είναι πολύ μεγαλύτερος από τον

προαναφερθέντα. Ωστόσο, υπάρχει μια άλλη εκδοχή της έννοιας του μέσου ρυθμού πυροδότησης, η οποία ορίζεται ως η μέση μέγιστη δραστηριότητα μιας ομάδας νευρώνων. Συγκεκριμένα, οι μετασυναπτικοί νευρώνες λαμβάνουν είσοδο με τη μορφή αιχμών από πληθυσμούς προσυναπτικών νευρώνων. Αυτή η ομάδα έχει μια ορισμένη μέγιστη δραστηριότητα, η οποία ορίζεται ως η αναλογία ενεργών νευρώνων σε σύντομο χρονικό διάστημα $[t, t + \Delta t]$, όπως φαίνεται στην ακόλουθη σχέση:

$$A = \frac{1}{\Delta t} \frac{n_{act}(t, t + \Delta t)}{N} \quad (91)$$

όπου $n_{act}(t, t + \Delta t)$ είναι ο αριθμός των νευρώνων στο διάστημα $[t, t + \Delta t]$ και N είναι ο συνολικός αριθμός των ομάδων νευρώνων. Θα πρέπει να σημειωθεί ότι σε αυτή την περίπτωση, η δραστηριότητα της ομάδας νευρώνων μπορεί να αλλάξει γρήγορα, ώστε να μπορεί να ανταποκριθεί γρήγορα σε μεταβαλλόμενα ερεθίσματα, βελτιστοποιώντας έτσι τη συνολική προσέγγιση.

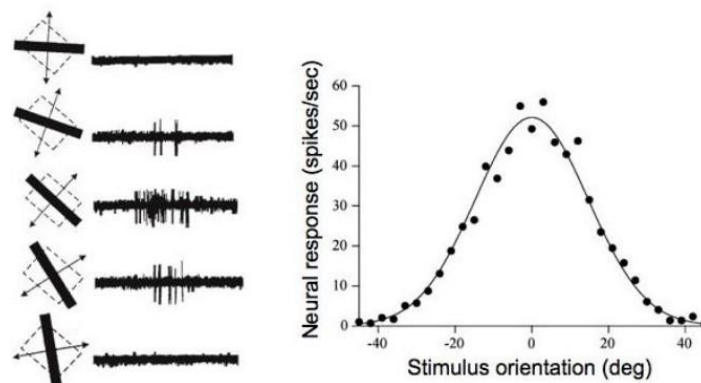


Figure 59 Παράδειγμα κωδικοποίησης ρυθμού νευρωνικών σημάτων. Αριστερά φαίνονται οι ακολουθίες αιχμών για διαφορετικούς προσανατολισμούς του ερεθίσματος ενός V1 κυττάρου μιας γάτας. Το τετράγωνο αναπαριστά το οπτικό υποδεκτικό πεδίο (receptive field) του νευρώνα, ενώ η μαύρη μπάρα τοποθετείται σε διαφορετικούς προσανατολισμούς. Δεξιά βλέπουμε την καμπύλη συντονισμού (tuning curve), ρυθμός παραγωγής αιχμών (σε αιχμές ανά δευτερόλεπτο) σε συνάρτηση με τον προσανατολισμό του ερεθίσματος (σε μοίρες), του νευρώνα [5]. Καθώς το ερέθισμα προ-σανατολιζεται στις 0 μοίρες ο ρυθμός παραγωγής αιχμών αυξάνεται [8]

3.2.2 Κωδικοποίηση Παλμού

Η δεύτερη θεωρία περιλαμβάνει μεθόδους κωδικοποίησης παλμών. Σε αυτή τη μέθοδο, λαμβάνεται ο ακριβής χρόνος μετάδοσης της κορυφής και το άθροισμα μετατρέπεται σε ώθηση, που είναι ο φορέας πληροφοριών μεταξύ των νευρώνων. Οι προσομοιώσεις υπολογιστή δίνουν πειραματικές ενδείξεις για τη χρονική συσχέτιση μεταξύ των κορυφών και αποδεικνύουν την αποτελεσματικότητα της μεθόδου, ειδικά στην εφαρμογή δυναμικών συστημάτων που εξαρτώνται από το χρόνο.

Μια μέθοδος κωδικοποίησης παλμού που βασίζεται στον χρονισμό της πρώτης αιχμής αμέσως μετά το σήμα αναφοράς ονομάζεται χρόνος πρώτης αιχμής, ο οποίος εμπνέεται από την οπτική επεξεργασία του ανθρώπινου ματιού. Σύμφωνα με αυτή τη μέθοδο, οι πληροφορίες κωδικοποιούνται στο χρόνο μεταξύ της ώρας έναρξης του ερεθίσματος και του χρόνου απόκρισης της πρώτης κορυφής. Ένας μόνος νευρώνας με ανασταλτικά δυναμικά και ανατροφοδότηση μπορεί να χρησιμοποιηθεί για κωδικοποίηση, αποτρέποντας έτσι τη μετάδοση

άλλων κορυφών.

Η κωδικοποίηση παλμών βασίζεται στο επιχείρημα ότι κάθε νευρώνας έχει χρόνο να εκπέμψει μόνο μερικές αιχμές που βοηθούν στην επεξεργασία του ερεθίσματος στο σύνολό του. Δεδομένου ότι το νέο ερέθισμα υποβάλλεται σε επεξεργασία μέσα στα πρώτα 20 έως 50 χιλιοστά του δευτερολέπτου μετά την εμφάνισή του, η προηγούμενη κορυφή μεταφέρει τις περισσότερες πληροφορίες σχετικά με το ερέθισμα και είναι συνήθως η πιο σημαντική πληροφορία.

Ένα τυπικό παράδειγμα χρήσης αυτού του είδους κωδικοποίησης για την προσομοίωση νευρώνων είναι η κωδικοποίηση των πληροφοριών που χρησιμοποιούνται για την προσομοίωση της αφής στα βιολογικά συστήματα. Η πληροφορία μεταδίδεται πρώτα στο σύστημα αφής με το δάχτυλο. Είναι μια ενδεικτική λύση στην περίπτωση της επεξεργασίας πληροφοριών σε πραγματικό χρόνο. Πολύ σημαντική είναι και η διαδικασία συσχέτισης και συγχρονισμού μεταξύ παλμών, που μπορεί να δημιουργήσει προϋποθέσεις για τη δυναμική κωδικοποίηση της πληροφορίας. Ωστόσο, μιλώντας γενικότερα, οποιοδήποτε χωροχρονικό μοτίβο παλμών μπορεί να είναι μια μέθοδος κωδικοποίησης συγκεκριμένων πληροφοριών, ακόμη και για κορυφές με σχετική χρονική καθυστέρηση, είναι δυνατό να κωδικοποιηθούν συγκεκριμένα ερεθίσματα.

3.2.3 Κωδικοποίηση Πληθυσμού

Η κωδικοποίηση πληθυσμού είναι μια τεχνική κωδικοποίησης που επιτρέπει την αντιστοίχιση της πραγματικής τιμής ενός συνόλου δεδομένων σε μια σειρά κορυφών που βασίζονται σε ένα σύνολο δεκτών πεδίων. Η επιλογή ενός δεκτικού πεδίου Gauss σε αυτή την περίπτωση επιτρέπει τη χρήση ενός συνόλου νευρώνων με επικαλυπτόμενες κατανομές ευαισθησίας για την κωδικοποίηση συνεχών τιμών. Κάθε μεταβλητή εισόδου κωδικοποιείται ανεξάρτητα από ένα σύνολο M μονοδιάστατων δεκτικών πεδίων. Συγκεκριμένα, το διάστημα $[I_{min}, n I_{max}]$ ορίζεται για τη μεταβλητή n . Το δεκτικό πεδίο Gauss του νευρώνα i δίνεται από το κέντρο του μ_i , όπως φαίνεται παρακάτω (Kasabov et al., 2014):

$$\mu_i = I_{min}^n + \frac{2i - 3}{2} \frac{(I_{max}^n - I_{min}^n)}{M - 2} \quad (93)$$

και από το πλάτος σ όπως παρακάτω (Kasabov et al., 2014)

που β , $1 < \beta < 2$ η παράμετρος που καθορίζει το πλάτος του κάθε γκαουσιανού πεδίου.

$$\sigma = \frac{\frac{1}{\beta} (I_{μαξ}^n - I_{min}^n)}{M - 2} \quad (94)$$

3.3 Μοντελοποίηση νευρώνων

3.3.1 Δυναμική νευρώνων

Το αποτέλεσμα της εισροής ιόντων στον μετασυναπτικό νευρώνα που προκαλείται από τη διάδοση της κορυφής είναι μια αλλαγή στη διαφορά δυναμικού μεταξύ του εσωτερικού και του εξωτερικού του κυττάρου. Αυτή η διαφορά δυναμικού ονομάζεται δυναμικό μεμβράνης. Όταν ο μετασυναπτικός νευρώνας δεν διεγείρεται, το δυναμικό της μεμβράνης του παραμένει σταθερό στο δυναμικό ηρεμίας. Μόλις επιτευχθεί η κορυφή, ανάλογα με τον τύπο της συστολής, το δυναμικό της μεμβράνης θα εκπολωθεί (αυξημένο δυναμικό) ή θα επαναπολωθεί (μειωμένο δυναμικό). Αμέσως μετά, λόγω διαρροής από τη μεμβράνη μέσω του καναλιού διαρροής, επανέρχεται αμέσως στο δυναμικό ηρεμίας. Η αλλαγή που προκαλείται από το δυναμικό δράσης ονομάζεται μετασυναπτικό δυναμικό (PSP) και το ποσοστό της ηλεκτρικής δραστηριότητας που παρέχεται ονομάζεται συναπτικό βάρος.

Ανάλογα με τον τύπο του νευροδιαβιβαστή που εκκρίνεται, η συναπτική μετάδοση μπορεί να είναι ερεθιστική επειδή προκαλεί την εκπόλωση της μεμβράνης του μετασυναπτικού νευρώνα, που ονομάζεται διεγερτικό μετασυναπτικό δυναμικό (EPSP), ή αναστέλλει το μετασυναπτικό νεύρο. Οι κορυφές που φτάνουν σε διαφορετικές συνάψεις του ίδιου μετασυναπτικού νευρώνα έχουν μετασυναπτικά δυναμικά διαφορετικού πλάτους, ανάλογα με την αποτελεσματικότητα μιας δεδομένης σύναψης [3]

Αξίζει να σημειωθεί ότι πολλαπλά μετασυναπτικά δυναμικά έχουν σωρευτικές επιδράσεις στο δυναμικό της μεμβράνης τόσο στο χώρο όσο και στο χρόνο. Η συσσώρευση είναι ουσιαστικά ένα απλό άθροισμα μετασυναπτικών δυναμικών έως ότου το δυναμικό της μεμβράνης φτάσει σε ένα δεδομένο όριο. Αυτό συμβαίνει όταν δημιουργούνται δυναμικά δράσης στους μετασυναπτικούς νευρώνες. Το σχήμα 61 δείχνει το άθροισμα του χρόνου και του χώρου των μετασυναπτικών δυναμικών υπό διαφορετικές συνθήκες. Η χρονική συσσώρευση αναφέρεται στο αθροιστικό αποτέλεσμα μιας μεμονωμένης σύναψης, ενώ η χωρική άθροιση είναι το μετασυναπτικό δυναμικό που προκαλείται από τον συνδυασμό πολλαπλών συνάψεων..

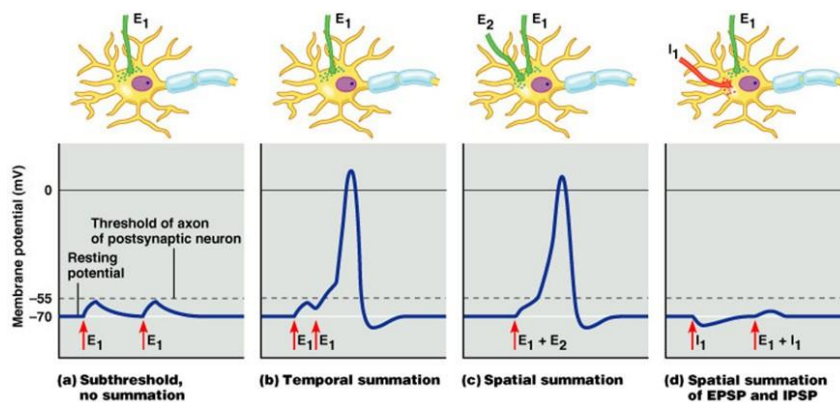


Figure 60 Οπτική αναπαράσταση άθροισης μετασυναπτικών δυναμικών[4]

Το δυναμικό της μεμβράνης και η αλληλουχία των κορυφών εξαρτάται από τον χρόνο και τους νευρώνες που βρίσκονται σε τεχνητά νευρωνικά δίκτυα (ΤΝΔ), όπως οι σιγμοειδείς μονάδες, χρησιμοποιούν μόνο αριθμητικές τιμές και δεν περιέχουν πληροφορίες χρόνου. Ένας τυπικός τεχνητός νευρώνας προσθέτει δεδομένα εισόδου και βάρη w_{ij} και εφαρμόζει τη συνάρτηση ενεργοποίησης f στο άθροισμα που προκύπτει. Συνήθως, η πόλωση (προκατάληψη) περιλαμβάνεται στο σταθμισμένο άθροισμα. Ταυτόχρονα, η είσοδος του νευρώνα που δημιουργεί την κορυφή είναι μια ακολουθία κορυφών που δημιουργείται από τον προσυναπτικό νευρώνα. Ως αποτέλεσμα, δημιουργούνται μετασυναπτικά δυναμικά σε μετασυναπτικούς νευρώνες, οι οποίοι με τη σειρά τους δημιουργούν μια σειρά από κορυφές. Αυτές οι θεμελιώδεις διαφορές στην είσοδο και την έξοδο και στους υπολογισμούς που εκτελούνται από κάθε νευρώνα έχουν οδηγήσει στη δημιουργία διαφόρων μοντέλων που περιγράφουν τη δυναμική των νευρώνων, τα οποία θα δούμε στην επόμενη ενότητα.

3.3.2 Μοντέλα νευρώνων

Σε αυτή την υποενότητα θα αναλύσουμε μερικά από τα πιο γνωστά μαθηματικά μοντέλα που περιγράφουν την δυναμική των νευρώνων. Όπως θα δούμε, για την μοντελοποίηση ενός νευρώνα αιχμών είναι απαραίτητη η μαθηματική περιγραφή της εξέλιξης του δυναμικού της μεμβράνης και ενός μηχανισμού παραγωγής αιχμών.

- **Μοντέλο ολοκλήρωσης πυροδότησης με απώλειες (LIF):** Η εξέλιξη του δυναμικού της μεμβράνης V μπορεί να μοντελοποιηθεί χρησιμοποιώντας ένα κύκλωμα RC (αντίστασης-πυκνωτής) που αποτελείται από χωρητικότητα μεμβράνης C_m και αντίσταση μεμβράνης R_m . Και οι δύο αυτές μεταβλητές εξαρτώνται από το ρεύμα εισόδου I . Όταν δεν υπάρχει είσοδος σε αδράνεια, το δυναμικό της μεμβράνης V παραμένει σε σταθερή τιμή V_{rest} . Όταν ο νευρώνας διαρρέει ρεύμα, ο πυκνωτής θα φορτιστεί από το ρεύμα $I_C(t)$ και η αντίσταση θα περάσει το ρεύμα $I_R(t)$. Όταν το ρεύμα εισόδου σταματήσει, το δυναμικό της μεμβράνης θα επιστρέψει σε μια στατική τιμή επειδή υπάρχει ρεύμα που ρέει μέσω της αντίστασης

$$I(t) = I_R(t) + I_C(t) = \frac{V - V_{rest}}{R_m} + C_m * \frac{dV}{dt} \quad (94),$$

$$(95)$$

Η συνηθισμένη μορφή του μοντέλου LIF περιγράφει την εξέλιξη του δυναμικού της μεμβράνης (όταν αυτό βρίσκεται κάτω από το κατώφλι), όπως φαίνεται από την Εξίσωση.

$$\frac{\tau_m * dv}{dt} = -v(v - v_{rest}) + R_m * I(t) \quad (96)$$

, όπου $\tau_m = C_m R_m$ η σταθερά χρόνου της μεμβράνης. Μόλις το δυναμικό μεμβράνης φτάσει την τιμή κατωφλίου V_{thresh} , λαμβάνει μία τιμή επανεκκίνησης (reset) V_{reset} , η οποία συνήθως είναι μικρότερη του V_{rest} .

Συνοψίζοντας, το μοντέλο LIF χρησιμοποιεί την γραμμική διαφορική Εξίσωση 96 για την περιγραφή της εξέλιξης του δυναμικού της μεμβράνης και μια τιμή κατωφλίου για την παραγωγή αιχμής.

- **Μοντέλο Hodgkin-Huxley:** Το βραβευμένο με Νόμπελ μοντέλο των Hodgkin και Huxley [41] εξήγησε τον ιοντικό μηχανισμό που δημιουργεί και διαδίδει δυναμικά δράσης στους άξονες των καλαμαριών. Το ρεύμα $I_R(t)$ που ρέει μέσω της αντίστασης της μεμβράνης προσδιορίζεται από τρία κανάλια ιόντων: ένα κανάλι διαρροής με αγωγιμότητα g_L , ένα κανάλι νατρίου με αγωγιμότητα g_{Na} και ένα κανάλι καλίου με αγωγιμότητα g_K . Το ρεύμα που διαρρέει αυτά τα κανάλια είναι ανάλογο με τη διαφορά μεταξύ του δυναμικού της μεμβράνης και του δυναμικού αντιστροφής κάθε καναλιού: $V - E_L$, $V - E_{Na}$ και $V - E_K$, αντίστοιχα. Επομένως, η ακόλουθη εξίσωση περιγράφεται ως εξής:

$$I(t) = I_L(t) + I_{Na}(t) + I_K(t) + I_C(t) \quad (97),$$

$$= g_L(V - E_L) + g_{Na}m^3h(V - E_{Na}) + g_Kn^4(V - E_K) + C_m \frac{dV}{dt} \quad (98)$$

Μπορούμε να δούμε το μοντέλο Hodgkin-Huxley ως μία μη γραμμική διαφορική εξίσωση με τέσσερις μεταβλητές: V , m , h και n , οι οποίες μεταβάλλονται με τον χρόνο.

$$\begin{aligned} C_m \frac{dV}{dt} &= I(t) - g_Kn^4(V - E_K) - g_{Na}m^3h(V - E_{Na}) - g_L(V - E_L) \\ \frac{dm}{dt} &= \alpha_m(V)(1 - m) - \beta_m(V)m \\ \frac{dn}{dt} &= \alpha_n(V)(1 - n) - \beta_n(V)n \\ \frac{dh}{dt} &= \alpha_h(V)(1 - h) - \beta_h(V)h \end{aligned} \quad (99)$$

, όπου $\alpha(V)$ και $\beta(V)$ συναρτήσεις του δυναμικού της μεμβράνης.

Σχετικά Όσον αφορά τον μηχανισμό εκκίνησης κορυφής, το πιο σημαντικό χαρακτηριστικό αυτού του μοντέλου είναι ο τρόπος με τον οποίο δημιουργεί δυναμικά δράσης αλλάζοντας μόνο τις προαναφερθείσες δυναμικές εσωτερικές μεταβλητές.

Η εξίσωση Hodgkin-Huxley παρέχει ένα λεπτομερές, ποσοτικό και αρκετά ακριβές μαθηματικό μοντέλο που μπορεί να εξηγήσει την εξέλιξη του δυναμικού της μεμβράνης και του δυναμικού δράσης. Ωστόσο, η αριθμητική του πολυπλοκότητα και η υψηλή μη γραμμικότητά του εμποδίζουν τη διαισθητική κατανόησή του και ταυτόχρονα καθιστούν υψηλό το υπολογιστικό κόστος προσομοιώσεων μεγάλης κλίμακας. Επομένως, η επιλογή του μοντέλου δυναμικής νευρώνων θα πρέπει να λαμβάνει υπόψη τους ερευνητικούς στόχους, την απαιτούμενη ακρίβεια και τη διαθέσιμη υπολογιστική ισχύ.

Μοντέλο Izhikevich: Το μοντέλο Izhikevich προτείνεται για την επίλυση του προβλήματος της υπολογιστικής πολυπλοκότητας του μοντέλου Hodgkin-Huxley και της ανεπαρκούς ικανότητας του μοντέλου LIF να αναπαράγει τη σύνθετη δυναμική των νευρώνων του φλοιού [45]. Επομένως, το μοντέλο του Izhikevich μπορεί να χρησιμοποιηθεί για την προσομοίωση ενός εγκεφαλικού μοντέλου μεγάλης κλίμακας που αποτελείται από βιολογικούς νευρώνες.

Το δυναμικό της μεμβράνης εξελίσσεται με βάση ενός ζεύγους εξισώσεων:

$$\frac{dV}{dt} = 0,04 V^2 + 5V + 140 - u - I(t) \quad (100)$$

$$\frac{du}{dt} = a(bV - u)$$

, όπου V είναι το δυναμικό της μεμβράνης και το u αναπαριστά την επαναφορά της μεμβράνης.

Σχετικά με την παραγωγή αιχμών, η έναρξη της ενεργοποίησης ενός δυναμικού δράσης παράγεται από την παρακάτω Εξίσωση. Ωστόσο, χρειάζεται και μία μέθοδος επαναφοράς:

$$V = c, \quad u = u + d, \quad \text{όταν } V \geq 30$$

Οι παράμετροι a , b , c και d είναι σταθερές και μπορούν να διαμορφωθούν κατάλληλα για να αναπαράγουν διάφορες δυναμικές πραγματικών βιολογικών νευρώνων .

3.3.3 Μοντέλα συνάψεων

Για την εφαρμογή νευρωνικών μοντέλων στη συναπτική διάδοση κορυφής, μπορούμε να χρησιμοποιήσουμε δύο τύπους συνάψεων: συνάψεις που βασίζονται στο ρεύμα και συνάψεις με βάση την αγωγιμότητα. Επομένως, η συναπτική έξοδος w καθορίζει την ισχύ του ρεύματος εισόδου που διαρρέει τη σύνδεση

$$I(t) = w(t)$$

είτε την ηλεκτρική αγωγιμότητα g_{syn} του καναλιού ιόντων:

, όπου το E_{syn} αναπαριστά το δυναμικό επαναφοράς της σύναψης. Αθροίζοντας όλα τα συναπτικά ρεύματα που καταλήγουν στον ίδιο μετασυναπτικό νευρώνα, ουσιαστικά αναπαριστούμε το εξωτερικό ρεύμα $I(t)$ για όλα τα νευρωνικά μοντέλα που αναφέρθηκαν στην

$$I(t) = g_{syn}(V - E_{syn}) = w(t)(V - E_{syn})$$

προηγούμενη ενότητα, δεδομένου ότι και οι δύο εξισώσεις περιγράφουν την ένταση του συναπτικού ρεύματος.

Σε σύγκριση με τα δυναμικά δράσης, το ρεύμα έχει συνήθως μεγαλύτερη χρονική σταθερά επειδή μειώνεται με την πάροδο του χρόνου. Επομένως, μια απλή εκθετική αναγωγή αρκεί για την προσομοίωση της υποβαθμισμένης απόδοσης του συμπεράσματος. Υποθέτοντας ότι έχουμε εμφάνιση αιχμών στους χρόνους $t = t_0, t_1, \dots, t_n$, το αρχικό βάρος της σύναψης είναι w_0 και η

συναπτική σταθερά χρόνου περιγράφεται από τη μεταβλητή τ_{syn} , το φθίνων συναπτικό ρεύμα (ή αγωγιμότητα) μπορεί να περιγραφεί από την ακόλουθη μαθηματική σχέση:

$$\omega(t) = \sum_k \omega_0 e^{-\frac{t-t_k}{\tau_{syn}}}$$

3.4 Συναπτική πλαστικότητα και μάθηση

3.4.1 Διαδικασία Μάθησης

Σε γενικές γραμμές, το κύριο χαρακτηριστικό του νευρωνικού δικτύου είναι η έμφυτη ικανότητα μάθησης. Η μάθηση μπορεί να οριστεί ως η σταδιακή βελτίωση της ικανότητας επίλυσης προβλημάτων του δικτύου. Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, η οποία μπορεί να θεωρηθεί ως μια επαναληπτική διαδικασία σταδιακής προσαρμογής των παραμέτρων δικτύου (συνήθως βάρη και πόλωση) σε κατάλληλες τιμές για την επιτυχή επίλυση του προβλήματος που εξετάζεται. Μόλις εκπαιδευτεί το δίκτυο, οι παράμετροί του θα σταθεροποιηθούν συνήθως στις κατάλληλες τιμές και από τότε θα είναι στην καλύτερη κατάσταση για να λύσει αυτό το πρόβλημα. Ο σκοπός είναι να κάνει το δίκτυο να έχει τα χαρακτηριστικά της ικανότητας γενίκευσης, δηλαδή να μπορεί να παρέχει τη σωστή έξοδο για τη νέα είσοδο και να είναι διαφορετική από την είσοδο που χρησιμοποιείται κατά την εκπαίδευση [10].

Η δυναμική του νευρωνικού δικτύου αιχμής καθορίζεται από τη συνδεσιμότητα του και την ισχύ των συναπτικών συνδέσεων. Η μάθηση σε ένα τέτοιο δίκτυο περιλαμβάνει την προσαρμογή των συνάψεων του μέσω επαναληπτικής βελτιστοποίησης. Η επιλογή του κατάλληλου αλγόριθμου μάθησης για το πρόβλημα εξαρτάται από τρία βασικά χαρακτηριστικά του μοντέλου που χρησιμοποιείται. Πρώτον, ορισμένοι αλγόριθμοι μπορούν να εφαρμοστούν μόνο σε συγκεκριμένες τοπολογίες δικτύου και νευρωνικά μοντέλα. Επομένως, το μοντέλο που θα επιλεγεί θα περιορίσει σημαντικά την επιλογή του αλγορίθμου εκμάθησης. Δεύτερον, ένα άλλο ερώτημα που προκύπτει είναι εάν η εκπαίδευση ή η εκμάθηση του συστήματος πρέπει να υλοποιηθεί σε υλικά ή το δίκτυο που έχει εκπαιδευτεί θα πρέπει να μεταφερθεί σε νευρομορφικά υλικά. Η τρίτη απόφαση που πρέπει να ληφθεί είναι εάν το δίκτυο εκπαιδεύεται με ή χωρίς επίβλεψη.

Διάφορα σοβαρά προβλήματα επηρεάζουν σημαντικά τη διαδικασία εκπαίδευσης στα ΠΝΝ, επειδή οι σαφείς απαιτήσεις εξαρτώνται από τα αποτελέσματα που σχετίζονται με την προκαθορισμένη είσοδο, τη διάταξη λειτουργίας που βασίζεται σε ακριβείς χωροχρονικές παραμέτρους, το λογισμικό ή το υλικό ασύγχρονης επεξεργασίας που συνήθως απαιτεί εξειδικευμένες πληροφορίες και αυτά. Οι δυσκολίες που προκαλούνται από την περίπλοκη αρχιτεκτονική και τοπολογία του δικτύου συνήθως δεν επιτρέπουν την εφαρμογή απλών μεθόδων εκμάθησης, όπως η backpropagation [28]. Οι πιο σημαντικές τεχνικές εκμάθησης που έχουν προταθεί και δοκιμαστεί περιστασιακά στην εφαρμογή NN φαίνονται παρακάτω. [10]

3.4.2 Πλαστικότητα εξαρτώμενη από τον χρονισμό των αιχμών

Όπως αναφέρθηκε στην προηγούμενη ενότητα, η συναπτική πλαστικότητα επιτρέπει διάφορες λειτουργίες μνήμης και μάθησης στο νευρικό επίπεδο του εγκεφάλου. Οι βιολογικές παρατηρήσεις παρέχουν στοιχεία ότι οι αλλαγές στη συναπτική απόδοση σχετίζονται άμεσα με τον χρονισμό των νευρώνων προσυναπτικών και μετασυναπτικών κορυφών [7]. Αυτή η λειτουργική αλληλεπίδραση μεταξύ της ενεργοποίησης της χρονικής άρθρωσης διαφορετικών συναπτικών οδών στους νευρώνες είναι ουσιαστικά μια σύνδεση μοριακού και κυτταρικού επιπέδου. Αυτή η συσχέτιση υπάρχει επειδή σε όλες αυτές τις περιπτώσεις, όλα συμβαίνουν σύγχρονα, χρονικά δεσμευμένα, προσυναπτική και μετασυναπτική ενεργοποίηση. Ο ρόλος αυτής της διαδικασίας συσχέτισης εκφράζεται πολύ χαρακτηριστικά μέσα από πειραματικές συνθήκες, στις οποίες ενεργοποιούνται ταυτόχρονα οι προσυναπτικοί και μετασυναπτικοί νευρώνες.

Η συναπτική πλαστικότητα που προκαλείται από αυτή την κατάσταση ονομάζεται πλαστικότητα σχετιζόμενη με το χρόνο ακίδας (STDP) και ο βασικός μηχανισμός της φαίνεται στο Σχήμα 2.16 [95]. Για τα ΠΝΝ που θα χρησιμοποιήσουμε σε αυτήν την εργασία, θα εφαρμόσουμε μια παραλλαγή του κανόνα STDP, που είναι μια από τις πιο υποσχόμενες και ευρέως μελετημένες μορφές μάθησης μη εποπτευόμενων νευρωνικών δικτύων. Η βασική εξίσωση που περιγράφει την αλλαγή του βάρους της συνάψεως στο τυπικό μοντέλο STDP [95] είναι η εξής: [10]

$$\Delta w = \begin{cases} A_+ e^{-\frac{Dt}{\tau_+}} & \text{οταν } \Delta t \geq 0 \\ -A_- e^{\frac{Dt}{\tau_-}} & \text{οταν } \Delta t < 0 \end{cases} \quad (102)$$

Όταν η προσυναπτική κορυφή εμφανίζεται μετά την προσυναπτική κορυφή, το συναπτικό δυναμικό αυξάνεται, το οποίο ορίζεται από μια εκθετική καμπύλη με χρονική σταθερά τ_+ και αρχική τιμή A_+ . Οστόσο, όταν η μετασυναπτική κορυφή δημιουργείται πριν από τη σύναψη, θα μειώσουμε το βάρος συστολής σύμφωνα με την εκθετική καμπύλη που ορίζεται από τη σταθερά τ_1 και A_- . Το Δt ορίζει τη διαφορά μεταξύ του χρόνου άφιξης της προσυναπτικής κορυφής και του χρόνου έναρξης του δυναμικού δράσης που εκπέμπεται από τον νευρώνα. Εκτός από το τυπικό μοντέλο STDP που περιγράφεται από τις παραπάνω εξισώσεις, προτείνονται επίσης παραλλαγές κανόνων μάθησης STDP για την επίτευξη διαφορετικών ταχυτήτων εκμάθησης και ακρίβειας ταξινόμησης

3.4.3 Μάθηση Ενός Πέρασματος

Ο αλγόριθμος εκμάθησης με ένα πέρασμα είναι μια εξαιρετικά απλή και απλοποιημένη διαδικασία ταξινόμησης. Επειδή δεν απαιτεί ειδικούς υπολογιστικούς πόρους, μπορεί να ολοκληρωθεί σε πολύ γρήγορο χρόνο. Είναι κατάλληλος για γραμμικά προβλήματα ή ανάλυση δεδομένων που μπορεί να προέρχονται από τη διανομή [49].

Σε γενικές γραμμές η λειτουργία του αλγορίθμου περιγράφεται ως εξής:

- Πραγματοποιείται μια σειριακή εισαγωγή των δεδομένων-αντικειμένων στο σύστημα.
- Το πρώτο αντικείμενο γίνεται ο εκπρόσωπος της πρώτης κατηγορίας.

- Κάθε επόμενο αντικείμενο συγκρίνεται με όλους τους αντιπροσώπους της υπάρχουσας κατηγορίας κατά την επεξεργασία και ταξινομείται σε μια κατηγορία σύμφωνα με ορισμένα κριτήρια
- Μετά την αντιστοίχιση ενός είδους σε μια κατηγορία, οι εκπρόσωποι αυτής της κατηγορίας θα υπολογιστούν εκ νέου.
- Αν ένα νέο αντικείμενο αποτύχει να καταταχθεί σε μια από τις ήδη υπάρχουσες κατηγορίες, γίνεται εκπρόσωπος μιας νέας κατηγορίας .

3.4.4 Εκπαίδευση κατά Hebbian

Μία από τις παλαιότερες θεωρίες στη νευροεπιστήμη που εξηγεί την προσαρμογή των συναπτικών νευρώνων στον εγκέφαλο κατά τη διάρκεια της μαθησιακής διαδικασίας εισήχθη από τον Ντόναλντ Χεμ στο βιβλίο του του 1949 Η Οργάνωση της Συμπεριφοράς (Hebb, 1949). Η ιδέα αυτή συνοψίζεται στο βιβλίο του από τη φράση " Cells that fire together, wire together ", η οποία εκφράζεται με μαθηματικούς όρους ως

$$\Delta w_{i,j} \propto v_i v_j$$

όπου το w_{ij} αναφέρεται στην αλλαγή του συναπτικού βάρους μεταξύ του προσυναπτικού νευρώνα i και του μετασυναπτικού κυττάρου j . και v αντιπροσωπεύει τις δραστηριότητες αυτών των νευρώνων, αντίστοιχα.

Ο κανόνας μάθησης κατά Hebbian, όπου βασίζεται στον ακριβή χρόνο των προ και μετασυναπτικών αιχμών διαδραματίζει κρίσιμο ρόλο στην εμφάνιση μη γραμμικών λειτουργιών στα SNNs. Ο συγκεκριμένος κανόνας μάθησης έχει εφαρμοστεί με επιτυχία σε προβλήματα όπως η ομαδοποίηση εισροών, η αναγνώριση μοτίβων, ο διαχωρισμός πηγών, η μείωση της διάστασης, ο σχηματισμός συνενωτικών αναμνήσεων ή ο σχηματισμός αυτο-οργανωτικών χαρτών (Hinton και Sejnowski, 1999).[15]

4 -ΕΦΑΡΜΟΓΕΣ SNN

4.1 Υπολογιστική όραση

Η υπολογιστική όραση είναι ένα διεπιστημονικό επιστημονικό πεδίο που ασχολείται με τον τρόπο με τον οποίο οι υπολογιστές μπορούν να αποκτήσουν υψηλού επιπέδου κατανόηση από ψηφιακές εικόνες ή βίντεο. Από την άποψη της μηχανικής, επιδιώκει να κατανοήσει και να αυτοματοποιήσει εργασίες που μπορεί να κάνει το ανθρώπινο οπτικό σύστημα.

Οι εργασίες υπολογιστικής όρασης περιλαμβάνουν μεθόδους για την απόκτηση, επεξεργασία, ανάλυση και κατανόηση ψηφιακών εικόνων και εξαγωγή δεδομένων υψηλής διάστασης από τον πραγματικό κόσμο, προκειμένου να παράγουν αριθμητικές ή συμβολικές πληροφορίες, π.χ. με τις μορφές αποφάσεων. Η κατανόηση σε αυτό το πλαίσιο σημαίνει τη μετατροπή των οπτικών εικόνων (η εισαγωγή του αμφιβληστροειδή) σε περιγραφές του κόσμου που έχουν νόημα στις διαδικασίες σκέψης και μπορούν να προκαλέσουν την κατάλληλη δράση. Αυτή η κατανόηση εικόνας μπορεί να θεωρηθεί ως η εμπλοκή συμβολικών πληροφοριών από τα δεδομένα εικόνας χρησιμοποιώντας μοντέλα κατασκευασμένα με τη βοήθεια γεωμετρίας, φυσικής, στατιστικής και θεωρίας μάθησης. [13][26]

Το επιστημονικό υπόβαθρο της υπολογιστικής όρασης συσχετίζεται με τη θεωρία πίσω από τεχνητά συστήματα που εξάγουν πληροφορίες από εικόνες. Τα δεδομένα εικόνας μπορούν να λάβουν πολλές μορφές, όπως ακολουθίες βίντεο, προβολές από πολλές κάμερες και πολυδιάστατων δεδομένων π.χ. από σαρωτή 3D. Η τεχνολογική πειθαρχία της υπολογιστικής όρασης επιδιώκει να εφαρμόσει τις θεωρίες και τα μοντέλα της στην κατασκευή συστημάτων υπολογιστικής όρασης.

Στο συγκεκριμένο κεφάλαιο θα προσπαθήσουμε να προσεγγίσουμε την υπολογιστική όραση υπο το πρίσμα των Πυροδοτούμενων νευρωνικών δικτύων και συγκεκριμένα για την υλοποίηση του VPR(Visual place recognition) όπου αποτελεί μια εργασία στην οποία ένα ρομποτικό σύστημα είτε μια διάταξη θα είναι σε θέση να αναγνωρίσει και να αποφασίσει αν ένα μέρος στο οποίο βρίσκεται το έχει ήδη επισκεφτεί, είτε όχι. Επίσης ένα άλλο αντικείμενο που θα αναλυθεί είναι αυτό της ανιχνεύσης κίνησης μέσω της εισαγωγής πληροφορίας από έναν Σενσορα εικόνας και η εξαγωγή από ένα μοντέλο SNN σχετικής οφέλιμης πληροφορίας.

4.1.1 Visual place Recognition(VPR)

Η οπτική αναγνώριση θέσης (VPR) είναι η διαδικασία της αναγνώρισης του αν μία τοποθεσία την έχουμε ήδη επισκεφθεί δεδομένης της τρέχουσας τοποθεσίας και της προηγούμενης γνώσης των τόποθεσιών που έχουμε επισκεφθεί. Το πρόβλημα VPR μπορεί να θεωρηθεί ως πρόβλημα αντιστοίχισης προτύπων, όπου επιλέγεται η πλησιέστερη αντιστοίχιση μιας εικόνας ερωτήματος

από ένα σύνολο εικόνων – τοποθεσιών αναφοράς που μπορούν να συλληθούν από σημαντικά διαφορετικές οπτικές γωνίες.

Οι πρώτες υλοποιήσεις για την παροχή λύσεων στο πρόβλημα VPR εφάρμοσαν χειροποίητες αναπαραστάσεις χαρακτηριστικών(features) – είτε από τοπικά σημεία είτε με τη συγκέντρωση χαρακτηριστικών σε ολόκληρη την εικόνα. Πολλές από αυτές τις υλοποιήσεις μετατράπηκαν αργότερα σε deep neural networks ακολουθώντας την προσέγγιση NetVLAD(Vector of Locally Aggregated Descriptors), το οποίο μοντέλο υλοποιεί ένα επίπεδο ομαδοποίησης με την χρήση διαφορικών λειτουργιών και εκπαίδευση του μοντέλου από άκρο σε άκρο. Επίσης μια εννοιολογικά σχετική μέθοδος με την παραπάνω είναι η Bayesian Selective Fusion , η οποία βρίσκει την καλύτερη αντιστοιχία χρησιμοποιώντας διάφορα σύνολα εικόνων αναφοράς, παρόμοια με τη χρήση πολλαπλών συνόλων αναφοράς που χρησιμοποιούνται για την εκπαίδευση του SNN.[12]

Στο κομμάτι της καθαρά νευρομορφικής υπολογιστικής το μοντέλο SNN δύο στρώσεων των Diehl και Cook κατέδειξε την πιθανή ικανότητα των μοντέλων SNN στην επίλυση εργασιών αναγνώρισης μοτίβων, όπως η αναγνώριση ψηφίων, μεθοδολογία που θα την αναλύσουμε και πιο κάτω.

4.1.1.1 Υλοποίηση μέσω SNN – Μεθοδολογία

Σε αυτή την ενότητα θα παρουσιαστεί το μοντέλο SNN από τους Diehl και Cook για αναγνώριση ψηφίων με την τεχνική της εκπαίδευσης χωρίς επίβλεψη, πάνω στο οποίο θα χτιστεί και το σύστημα VPR . Το SNN περιέχει βιολογικά αληθοφανείς μηχανισμούς, συμπεριλαμβανομένων των νευρώνων Leaky-Integration-and-Fire (LIF), της εξαρτώμενης από τις αιχμές πλαστικότητα (STDP), και της ομοιόστασης, η οποία επιτρέπει την μη επιτηρημένη μάθηση. Με βάση τις μαθηματικές σημειώσεις των Diehl και Cook , το συγκεκριμένο μοντέλο αποτελείται από δύο στρώσεις, το επίπεδο εισόδου και το επίπεδο επεξεργασίας .[12]

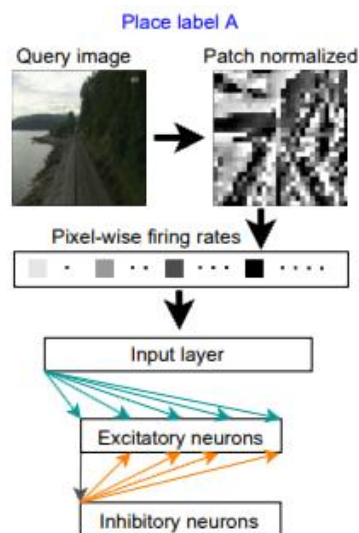


Figure 61 Υλοποίηση δυο επιπέδων μια εκτέλεση εργασίας VPR[12]

Το επίπεδο εισόδου μετατρέπει εικόνες εισόδου σε αιχμές που χρησιμοποιούν κωδικοποίηση ρυθμού, καθώς επίσης περιέχει ένα εικονοστοιχείο εικόνας ανά νευρώνα . Συγκεκριμένα ο αριθμός των νευρώνων είναι $KI = W \times H$, όπου W και H είναι το πλάτος και το ύψος της εικόνας εισόδου, αντίστοιχα. Έπειτα η εικόνα εισόδου μετατρέπεται σε ακίδες που διανέμονται με βάση την κατανομή Poisson χρησιμοποιώντας την ένταση του εικονοστοιχείου εισόδου ως ρυθμό πυροδότησης του νευρώνα (συχνότητα αιχμών) για τη δημιουργία αιχμών σε σύντομα χρονικά διαστήματα .

Οι νευρώνες στο στρώμα εισόδου είναι πλήρως συνδεδεμένοι (all-to-all σύνδεση) με όλους τους διεγερτικούς νευρώνες ΚΡ στο στρώμα επεξεργασίας. Το στρώμα επεξεργασίας περιέχει επίσης ανασταλτικούς νευρώνες ΚΡ. Ο ανασταλτικός νευρώνας k -th λαμβάνει είσοδο από έναν μόνο αντίστοιχο διεγερτικό νευρώνα k και με τη σειρά του αναστέλλει όλους τους διεγερτικούς νευρώνες εκτός από αυτόν από τον οποίο λαμβάνει τη σύνδεση. Αυτές οι ανασταλτικές συνδέσεις παρέχουν πλευρική αναστολή που επιτρέπει στο μοντέλο να συμπεριφέρεται παρόμοια με ένα σύστημα winner-takes-all. [20]

Στο στρώμα της επεξεργασίας , τα συναπτικά βάρη των συνδέσεων (μεταξύ των διεγερτικών και ανασταλτικών νευρώνων) είναι σταθερά. Η νευρωνική μάθηση γίνεται με την προσαρμογή των συνάψεων (συνδέσεις) από το στρώμα εισόδου στους διεγερτικούς νευρώνες χρησιμοποιώντας STDP το οποίο μοντελοποιεί τη συμπεριφορά των βιολογικών νευρώνων όπου το μέγεθος και η κατεύθυνση της αλλαγής στη συναπτική δύναμη (βάρος) επηρεάζεται από τον ακριβή χρονισμό των προσυναπτικών και μετασυναπτικών αιχμών.

Κατά τη διάρκεια της εκπαίδευσης , τα βάρη των συνάψεων αυξάνουν την ευαισθησία των νευρώνων για να ανταποκριθούν σε διαφορετικά ερεθίσματα. Συγκεκριμένα, όλα τα συναπτικά βάρη μοντελοποιούνται από την αλλαγή της συναπτικής αγωγιμότητας και συγκεκριμένα μετά από έναν προσυναπτικό νευρώνα εισόδου όπου στέλνεται μια αιχμή στον διεγερτικό μετασυναπτικό νευρώνα, η συναπτική σύνδεση αυξάνεται, διαφορετικά η αγωγιμότητα της συναψης(βάρος) μειώνεται εκθετικά. Αυτό διαμορφώνεται από:

$$Tge \frac{dGe}{dt} = -ge \quad (103)$$

όπου η διεγερτική μεταναπτική χρονική σταθερά υποδηλώνεται από το tge . Για συνάψεις με ανασταλτικό προσυναπτικό νευρώνα, το ίδιο μοντέλο χρησιμοποιείται για την ενημέρωση της αγωγιμότητας g_i , με ανασταλτικό μετασυναπτικό σταθερά χρόνου το tgi . Η νευρωνική μάθηση με STDP πραγματοποιείται με την προσαρμογή των συναπτικών βαρών μεταξύ του στρώματος εισόδου και των διεγερτικών νευρώνων στο στρώμα επεξεργασίας. Συγκεκριμένα τα βάρη μοντελοποιούνται χρησιμοποιώντας προσυναπτικά ίχνη x_{pre} , τα οποία είναι μετρητές που

καταγράφουν τον αριθμό των προσυναπτικών αιχμών. Η αλλαγή Δw στα συναπτικά βάρη αφότου λάφθει μια μετασυναπτική ακίδα διαμορφώνεται ως εξής:

$$\Delta w = \eta (X_{pre} - X_{tar})(W_{max} - W)^{\mu}$$

όπου η είναι το ρυθμός εκμάθησης, X_{tar} είναι η τιμή του προσυναπτικού ίχνους όταν λαμβάνεται μία μεταναπτική αιχμή, w_{max} είναι το μέγιστο βάρος, και μ είναι μια αναλογία που αντιπροσωπεύει την εξάρτηση της ενημέρωσης από το προηγούμενο βάρος.

Για να διασφαλιστεί ότι όλοι οι νευρώνες εξόδου ανταποκρίνονται σε διαφορετικά μοτίβα και ότι ο αριθμός των αιχμών που πυροδοτούνται από νευρώνες για διαφορετικές ετικέτες παραμένει εντός περιορισμένου αριθμού, υλοποιείται ο μηχανισμός της ομοιόστασης (εμπνευσμένο με βάση την βιολογία των ζωντανων οργανισμών). Η ομοιόσταση εφαρμόζεται από ένα προσαρμοστικό νευρωνικό όριο για τους διεγερτικούς νευρώνες, όπου το εσωτερικό όριο τάσης για την αύξηση μιας αιχμής αυξάνεται κατά μια σταθερή θ αφότου πυροδοτηθεί ο νευρώνας και έπειτα μειώνεται εκθετικά.

Για να υλοποιηθεί λοιπόν η λειτουργικότητα του VPR, θα χρειαστεί μια τεχνική η οποία θα εξασφαλίζει ότι η παραγωγή νέων κλάσεων λόγω των νέων εικόνων θα γίνει με τρόπο όπου κατά την διαδικασία της εκπαίδευσης θα γίνει ραφινάρισμα στα μοτίβα πυροδότησης των νευρώνων καθώς και στον χρονισμό αυτών. Για να πετύχουμε το συγκεκριμένο φιλτράρισμα κατά την παραγωγή νέων κλάσεων θα χρησιμοποιηθεί η τεχνική της νευρωνικής ανάθεσης με βάρος (neuronal weighted assignment).

Κατά την συγκεκριμένη τεχνική οι νευρώνες χωρίζονται σε ομάδες ανάλογα την ανάμειξη τους στις πυροδοτήσεις όσο αναφορά τα νέα μέρη κατά την εκπαίδευση. Έτσι έχουμε τις εξής ομάδες νευρώνων: : 1) νευρώνες που πυροδοτούνται σε μια συγκεκριμένη ετικέτα θέσης - κλάση, 2) νευρώνες που πυροδοτούνται σε δύο ετικέτες - κλάσεις και 3) νευρώνες που πυροδοτούνται για πολλές ετικέτες - κλάσεις. Η συγκεκριμένη κατηγοριοποίηση έγινε επίσης και με σκοπό την βελτίωση της απόδοσης κατά την εκπαίδευση.

Για την υποστήριξη των παραπάνω κατηγοριών χωρίζουμε και την ανάλογη κανονικοποίηση στις πυροδοτήσεις των νευρώνων στις εξής:

- Regularization by involvement (κανονικοποίηση με βάση το ποσοστό συμμετοχής)
- Normalization by response strength (κανονικοποίηση με το πόσο ισχυρά έχει εκπαιδευτεί για συγκεκριμένο μέρος)
- Penalize relevant neurons that did not spike (ποινή στους σχετικούς νευρώνες που δεν πυροδοτούνται)

Κατά την κανονικοποίηση με συμμετοχή, στο πρώτο βήμα ομαλοποίησης μειώνεται η συμβολή των νευρώνων που έχουν μάθει πολλές ετικέτες θέσεων, ειδικά αν ένας νευρώνας έχει μάθει περισσότερα από $\gamma\%$ των ετικετών θέσεων. Για αυτούς τους νευρώνες, ο ρυθμός πυροδότησης κανονικοποιείται από τον αριθμό των ετικετών θέσης που έχουν μάθει (ενώ τα ποσοστά πυροδότησης άλλων νευρώνων δεν είναι κανονικοποιημένα) ως εξής:

$$S_{i,l}^{Q'} = \begin{cases} S_{i,1}^Q \\ \frac{1}{w_i} S_{i,l}^Q \end{cases} \text{ αν } \omega_i < \gamma * R \quad (104)$$

οπου το $S_{i,l}^Q$ είναι οι κανονικοποιημένοι ρυθμοί πυροδότησης και το ω_i είναι ο αριθμός των τοποθεσιών που αναπαριστούνται από τον νευρώνα i

Ομαλοποίηση με βάση την ισχύ απόκρισης του νευρώνα: Το επόμενο βήμα κανονικοποίησης εξετάζει πόσο έντονα ο νευρώνας l έχει μάθει την ετικέτα l . Ενώ το παραπάνω βήμα κανονικοποίησης (Regularization by involvement) εξέτασε μόνο πόσα μέρη έχει μάθει ένας νευρώνας, αυτό το βήμα ομαλοποίησης εξηγεί επιπλέον τη δύναμη των αποκρίσεων ανά ετικέτα. Συγκεκριμένα:

Οπου γίνεται ουσιαστικά διερευνάται σε τι ποσοστό η ετικέτα l έχει εκπαιδευτεί στον συγκεκριμένο νευρώνα σε σχέση με άλλες ετικέτες που έχει μάθει.

$$S_{i,l}^Q = S_{i,l}^{Q'} * \frac{S_{i,l}^R}{\sum_m S_{i,m}^R} \quad (105)$$

Και τέλος η απόδοση ποινής στους σχετικούς νευρώνες που δεν πυροδοτούνται. Στο τελευταίο βήμα κανονικοποίησης υποβιβάζονται τα βάρη στους σχετικούς νευρώνες ανά ετικέτα, όταν με την παρουσία αυτής δεν πυροδοτούνται. Ο παράγοντας κανονικοποίησης στην περίπτωση αυτή, είναι ο αριθμός των πυροδοτήσεων (κατά τη διάρκεια της εκπαίδευσης) των νευρώνων που επίσης πυροδοτήθηκαν κατά το χρόνο ερωτήματος σε σχέση με τον αριθμό των πυροδοτήσεων όλων των νευρώνων που έχουν μάθει αυτή την ετικέτα. Συγκεκριμένα:

$$S_{i,l}^Q = S_{i,l}^Q * \widehat{\sum_m \frac{S_{i,m}^R * S_{i,m}^Q}{\sum_m S_{i,m}^R} > 0} \quad (106)$$

4.1.2 Ανίχνευση κίνησης

Συνεχίζοντας να λαμβάνουμε έμπνευση από βιολογικά συστήματα για να σχεδιάσουμε ένα δίκτυο ανίχνευσης κίνησης βλέπουμε ότι τα κύτταρα ενσωματώνουν περιοχές της εισόδου με ομοιόμορφο τρόπο (είτε οριζόντια είτε κάθετα) οι οποίες στη συνέχεια επικοινωνούν με έναν ανιχνευτή κίνησης. Οι νευρώνες ανίχνευσης κίνησης συνήθως απαιτούν δύο νευροδιαβιβαστές, ένας από τους οποίους έχει αργή δυναμική (χαμηλής διέλευσης ή καθυστέρηση) ενώ ο άλλος είναι παρών για σύντομο χρονικό διάστημα. Εάν και τα δύο σήματα φτάσουν στον ανιχνευτή σε παρόμοιο χρόνο, θα προκαλέσουν ενεργοποίηση (ανίχνευση κίνησης).

Οι καθυστερήσεις είναι εγγενείς στα νευρωνικά δίκτυα μιας και εάν εφαρμοστούν οι κατάλληλες καθυστερήσεις, οι εισοδοί θα φτάσουν ταυτόχρονα στον νευρώνα-στόχο, οπότε αυτό

θα επιτρέψει την αναγνώριση ενός συγκεκριμένου χωροχρονικού μοτίβου. Στο μοντέλο αυτό, η αργή – γρήγορη δυναμική συνδυάζεται με οριζόντιες ή κάθετες καθυστερήσεις μεταξύ των νευρώνων για τη μείωση των ψευδώς θετικών αποτελεσμάτων. Στο μοντέλο αυτό η συσσώρευση δύο συμβάντων εισόδου χρησιμοποιώντας τον αργό νευροδιαβιβαστή ανοίγει ένα παράθυρο 20 ms για να φτάσει η γρήγορη είσοδος το κατώφλι της. Επομένως αν η ταχέως αποσυντιθέμενη είσοδος παραληφθεί μέσα σε αυτό το παράθυρο, ο ανιχνευτής θα πυροδοτήσει .[12]

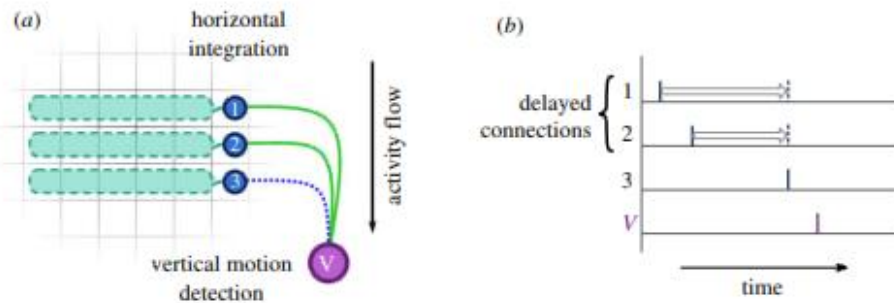


Figure 62 Αρχιτεκτονική ανίχνευσης κίνησης. Η κίνηση από το μωβ αντικείμενο περνάει με καθυστέρηση στους αισθητήρες. Τα spikes εφόσον περνούν από γραμμές καθυστέρησης στο sum τους έχουμε ισχυρή πυροδότηση[13]

4.1.2.1 Επεξεργασία πληροφορίας με βάση τα συμβάντα(Event Based processing)

Οι βιολογικοί αισθητήρες όρασης είναι αρκετά διαφορετικοί από τις κάμερες που κάνουν δειγματοληψία μέσω της λήψης καρε, καθώς δεν λαμβάνουν την εικόνα του συμβάντος με ομοιόμορφο ρυθμό, ούτε σε ομοιόμορφη ανάλυση. Διαφορετικά είδη έχουν διαφορετικές διαμορφώσεις, αλλά το ανθρώπινο μάτι αποτελείται από μια μικρή περιοχή υψηλής ανάλυσης – το fovea – στο κέντρο του οπτικού πεδίου και από μια πολύ μεγαλύτερη περιφέρεια όρασης που έχει πολύ χαμηλότερη ανάλυση σε συνδυασμό με αυξημένη ευαισθησία στην κίνηση. Εάν ανιχνευθεί κάποια απροσδόκητη κίνηση στην περιφέρεια, το μάτι μετακινείται γρήγορα για να δείξει στο fovea την περιοχή ενδιαφέροντος για λεπτομερέστερη ανάλυση. Με αυτόν τον τρόπο, χρειάζονται περιορισμένοι πόροι για την εξαγωγή των πιο σημαντικών πληροφοριών από τη σκηνή χωρίς σπατάλη ενέργειας που καταγράφει ολόκληρη τη σκηνή με την υψηλότερη ανάλυση. Επιπλέον, το ανθρώπινο μάτι είναι κυρίως ευαίσθητο στις αλλαγές στη φωτεινότητα που πέφτει στους μεμονωμένους αισθητήρες του. Αυτές οι αλλαγές υποβάλλονται σε επεξεργασία από στρώματα νευρώνων στον αμφιβληστροειδή μέσω των κυττάρων γάγγλιο του αμφιβληστροειδούς που παράγουν δυνατότητες δράσης, ή «αιχμές», που διαδίδονται μέσω του οπτικού νεύρου στον εγκέφαλο κάθε φορά που εντοπίζεται μια σημαντική αλλαγή.

Με βάση τα παραπάνω και την ανάγκη για ενεργειακή απόδοση μέσω του νευρομορφικού υλικού δημιουργήθηκαν αισθητήρες όρασης που βασίζονται σε συμβάντα (EVSs) , δηλαδή φωτοϋποδοχείς που αντιδρούν στις αλλαγές του φωτισμού . Τα EVS είναι κάμερες των οποίων το κοινό χαρακτηριστικό είναι να εκπέμπουν συμβάντα - πυροδοτήσεις μόνο όταν αισθάνονται επαρκή αλλαγή στη φωτεινότητα του στο τοπίο που εικονίζουν. Αυτοί οι υπολογισμοί γίνονται ανά εικονοστοιχείο σε επίπεδο τρανζίστορ, καθιστώντας τους εξαιρετικά αποτελεσματικούς, μιας και έχοντας κάθε εικονοστοιχείο να υπολογίζει τις αλλαγές του ανεξάρτητα, το EVS έχει υψηλό δυναμικό εύρος, επιτρέποντάς τους να καταγράφουν καθημερινές σκηνές καλύτερα από τις συμβατικές κάμερες.

Επιπλέον, δεδομένου ότι τα συμβάντα παράγονται μόνο όταν ένα εικονοστοιχείο θεωρεί ότι το περιβάλλον έχει αλλάξει, το κόστος ενέργειας μετάδοσης είναι επίσης χαμηλό. Στην παρακάτω ενότητα θα εξετάσουμε την επεξεργασία οπτικών πληροφοριών με βάση τα SNN που βασίζονται σε συμβάντα.

4.1.2.2 Κωδικοποίηση εικόνας – Τοπογραφικοί χάρτες

Οι αμφιβληστροειδείς των θηλαστικών κωδικοποιούν τις οπτικές πληροφορίες σε πολλαπλές αναπαραστάσεις χρησιμοποιώντας διακριτά χαρακτηριστικά , ακολουθώντας πιθανώς την αρχή της κωδικοποίησης πληροφορίας με τα λιγότερα σήματα .Επίσης υπάρχουν ενδείξεις ότι ορισμένα κελιά στον αμφιβληστροειδή κωδικοποιούν πληροφορίες φωτεινότητας χρησιμοποιώντας σχετικούς χρόνους πυροδότησης. [13]

Ο κύριος μηχανισμός για αυτή την κωδικοποίηση είναι ο ανταγωνισμός μεταξύ διαφορετικών αναπαραστάσεων μέσω πλευρικής αναστολής(lateral inhibition). Η συγκεκριμένη αρχή χρησιμοποιήθηκε και για να δημιουργήσουμε το νευρικό μας δίκτυο για την κωδικοποίηση εικόνας. Στο πρώτο επίπεδο του βιολογικού δικτύου , τα διπολικά κύτταρα δειγματοληπτούν την είσοδο σε μια κοντινή περιοχή. Τα συναπτικά βάρη υπολογίζονται σύμφωνα με μια δισδιάστατη gaussian κατανομή και αποθηκεύονται σε έναν πυρήνα (WB).




Figure 63 Υλοποίηση κωδικοποίησης εικόνας στο Ματι[13]

. Τα εισερχόμενα βάρη στη συνέχεια ομαλοποιούνται, έτσι ώστε να αθροιστούν σε ένα και να κλιμακώνονται από το απαιτούμενο βάρος, έτσι ώστε μια μόνο μια πυροδότηση να ενεργοποιήσει τον χαρακτηρισμένο διπολικό νευρώνα. Αυτό έχει ως αποτέλεσμα τη διανομή της απαιτούμενης δραστηριότητας σε ολόκληρο το πεδίο λήψης . Κάθε διπολικό κύτταρο διεγείρει ένα γαγγλίο κύτταρο και ένα amacrine νευρώνα, το τελευταίο επιβάλλοντας τον ανταγωνισμό καθώς αναστέλλει τα γαγγλιακά κύτταρα που συνδέονται με τα γειτονικά διπολικά κύτταρα. Τα βάρη για τις ανασταλτικές συνδέσεις –από την αμακρίνη έως τα γαγγλιακά κύτταρα– υπολογίζονται από τη διασταυρούμενη συσχέτιση των διπολικών πυρήνων εισόδου με την συγκεκριμένη σχέση:

Αυτά θα ομαλοποιηθούν και θα κλιμακωθούν όπως περιγράφεται από την παραπάνω

$$W_A = W_{B_1} * W_{B_2} \quad (106)$$

εξίσωση. Έτσι υπολογίζοντας τα βάρη με αυτόν τον τρόπο, οι γείτονες θα εμποδίζονται, αναλογικά με το πόσο παρόμοιες είναι οι περιοχές που αντιπροσωπεύουν. Τα αμακρίνη είναι ανασταλτικοί νευρώνες, οπότε τα βάρη τους (W_A) μπορούν να θεωρηθούν αρνητικά, πράγμα που σημαίνει ότι ο συνολικός υπολογισμός (f_G) του κυκλώματος μπορεί να λειτουργήσει ως φίλτρο κεντρικού περιβάλλοντος:

$$f_G \propto f_B(W_B) - W_A \quad (107)$$

Οι εικόνες αποτελούνται συνήθως από στοιχεία των οποίων η χωρική συχνότητα ποικίλλει, οπότε ένα μόνο μέγεθος πυρήνα εισόδου για διπολικά κύτταρα δεν επαρκεί για την αποτελεσματική κωδικοποίηση τους. Ένα διπολικό κύτταρο του οποίου το πεδίο λήψης είναι κοντά σε μια περιοχή εισόδου θα πρέπει να πυροδοτείται νωρίτερα από εκείνους που ταιριάζουν λιγότερο καλά. Ομοίως, το συνδεδεμένο γαγγλιανό κύτταρό του θα είναι το πρώτο που θα εκπέμπει μια αιχμή για την περιοχή αυτή. Επιπλέον, αυτό το διπολικό κύτταρο θα πρέπει να καταστείλει τη δραστηριότητα από γειτονικά γαγγλιανικά κύτταρα -σε κάθε κλίμακα- που μπορεί να προσπαθούν να αναπαραστήσουν την είσοδο.

Για την υλοποίηση του παραπάνω βιολογικού δικτυώματος θα γίνει χρήση τοπογραφικών χαρτών. Συγκεκριμένα Οι νευρωνικοί τοπογραφικοί χάρτες αποτελούνται από στρώματα νευρώνων των οποίων η αντίδραση σε διαφορετικά ερεθίσματα αλλάζει με την περιοχή – Βάρη σε συγκεκριμένη περιοχή . Μια τέτοια διάταξη χαρακτηρίζεται από τη διατήρηση της γειτονικής δραστηριότητας από την πηγή στο επίπεδο-στόχο και παρέχει πολλά πλεονεκτήματα όσον αφορά την διασύνδεση και την επεξεργασία πληροφοριών. Επίσης με την διάταξη αυτή η διασύνδεση βελτιστοποιείται, καθώς οι νευρώνες γενικά έχουν περιορισμένα πεδία λήψης δεδομένων και το ενδιαφέρον τους περιορίζεται χωρικά στον χάρτη. Το πιο σημαντικό με αυτή την διάταξης είναι ότι όταν οι νευρώνες σχηματίζουν πολλαπλούς ευθυγραμμισμένους χάρτες, ο καθένας λαμβάνει πληροφορίες από διαφορετική σκοπιά , παρουσιάζοντας έτσι πολλαπλές πληροφορίες στο δίκτυο προς αξιοποίηση .

Το προτεινόμενο μοντέλο για την υλοποίηση αυτή περιλαμβάνει τη συνεργασία δύο τύπων μηχανισμών: ο ένας θα είναι ανεξάρτητος από τη δραστηριότητα και ο δεύτερος θα είναι εξαρτώμενος από τη δραστηριότητα. Το πρώτο μοντέλο βασίζεται στην απόσταση μεταξύ των πιθανών συνεργαζόμενων νευρώνων προκειμένου να δημιουργηθεί μια νέα σύναψη - οι νευρώνες που είναι χωρικά ομαδοποιημένοι θα τείνουν να σχηματίζουν περισσότερες συνδέσεις από τους νευρώνες που είναι χωρικά απόμακροι.[13]




Figure 64 Τοπογραφικός χάρτης νευρώνων. Στο πρώτο επίπεδο λαμβάνονται τα ερεθίσματα του περιβάλλοντος και με το δεύτερο επίπεδο σχηματίζονται συνδέσεις όπου στο πρώτο επίπεδο έχουμε χωρικά πολλαπλές ενεργοποιήσεις[13]

Ο δεύτερος μηχανισμός αποτελείται από δύο επιμέρους μηχανισμούς: τον stdp, και έναν κανόνα αφαίρεσης νευρώνων από την «ομάδα». Το STDP, χρησιμοποιώντας τοπικές πληροφορίες πυροδοτήσεων, τροποποιεί τα βάρη των συνάψεων που συνδέουν τους νευρώνες μαζί, ενώ ο κανόνας αφαίρεσης, αφαιρεί κατά προτίμηση εκείνες τις συνάψεις που είναι καταθλιπτικές. Γενικότερα με τους μηχανισμούς αυτούς, οι συνάψεις που φέρουν «χρήσιμα» μοτίβα ή υποσύνολα μοτίβων με νευρώνες τείνουν να ενισχύονται, επομένως είναι πιο σταθερές μακροπρόθεσμα, ενώ αντιθέτως, συνάψεις που συνήθως μεταδίδουν ό, τι ισοδυναμεί με θόρυβο θα υποβαθμιστούν.

4.2 Ρομποτική

Η βιολογική νοημοσύνη των ζωντανών πλασμάτων αποτελεί αντικείμενο έρευνας εδώ και πολύ καιρό. Συγκεκριμένα η εξερεύνηση των δυνατοτήτων τους σχετικά με την αντίληψη, την απομνημόνευση, τη σκέψη. Σήμερα, λόγω των αυξανόμενων προσπαθειών μίμησης αυτών των δομικών και λειτουργικών αρχών, οι επιστήμονες έχουν διερευνήσει πώς ο εγκέφαλος, οι ενεργοποιητές ρομπότ και οι αισθητήρες θα μπορούσαν να συνεργαστούν για να δημιουργήσουν ρομπότ που εκτελούν αυτόνομα, σύνθετες λειτουργίες .

Ωστόσο τα ρομπότ, για να αποκτήσουν μεγαλύτερη αυτονομία και να λειτουργήσουν στον πραγματικό κόσμο, θα πρέπει να κατέχουν τις ακόλουθες ικανότητες: να αντιλαμβάνονται το περιβάλλον τους μέσω αισθητήρων (2) επεξεργασία περιττών πληροφοριών(θορύβου) με χαμηλή απόκριση και ενεργειακή απόδοτικότητα, να συμπεριφέρονται ορθά σε περιβάλλοντα με δυναμικές και μεταβαλλόμενες συνθήκες, οι οποίες απαιτούν ικανότητα αυτομάθησης.

Για τις συγκεκριμένες ανάγκες, οι παραδοσιακές στρατηγικές ελέγχου με βάση τα συμβατικά τεχνητά νευρωνικά δίκτυα (ANNs) δεν μπορούν να καλύψουν αυτές τις προαναφερθείσες ανάγκες. Για να είμαστε συγκεκριμένοι, τα παραδοσιακά μοντέλα μέσω τεχνικών αριθμητικής ανάλυσης, κινηματικής συχνά αποτυγχάνουν να προσαρμοστούν σε άγνωστα περιβάλλοντα.[15]

Από την άλλη, τα συμβατικά ANNs είναι δύσκολο να επεξεργαστούν τις υψηλές υπολογιστικές απαιτήσεις για την αυτονόμηση ρομποτικών συσκευών, παρά την πρόοδο υλικού που κατέστησε τα μεγάλα νευρωνικά δίκτυα εφαρμόσιμα σε προβλήματα του πραγματικού κόσμου. Αυτό συμβαίνει, πρώτον διότι η εκπαίδευση τεχνητών νευρωνικών δικτύων είναι χρονοβόρα και μπορεί εύκολα να διαρκέσει πολλές ημέρες ακόμα και με τις υπερσύγχρονες αρχιτεκτονικές υλικού. Επίσης η εκπαίδευση δικτύων μεγάλης κλίμακας είναι υπολογιστικά δαπανηρή και η εκτίναξη τους παράγει συνήθως μεγάλες καθυστερήσεις . Δεύτερον, η εκτέλεση υπολογισμών με μεγάλα δίκτυα σε παραδοσιακό υλικό καταναλώνει συνήθως και πολλή ενέργεια . Ειδικά στις φορητές εφαρμογές όπως η ρομποτική , αυτά είναι σημαντικά μειονεκτήματα, στα οποία οι απαντήσεις σε πραγματικό χρόνο είναι σημαντικές και ο ενεργειακός εφοδιασμός είναι περιορισμένος.

Στη φύση, οι πληροφορίες υποβάλλονται σε επεξεργασία χρησιμοποιώντας σχετικά μικρούς πληθυσμούς νευρώνων στους ζωντανούς οργανισμούς. Συγκεκριμένα οι πυροδοτήσεις αυτών και ο ακριβής σχετικός χρόνος τους, είναι επαρκής για την προώθηση της μάθησης και της συμπεριφοράς. Ως εκ τούτου, μια ελπιδοφόρα λύση στις προκλήσεις ελέγχου της ρομποτικής θα μπορούσε να δοθεί από τα νευρωνικά δίκτυα που μιμούνται τους υποκείμενους μηχανισμούς του εγκεφάλου πολύ πιο ρεαλιστικά. Έτσι τα SNN λόγω της λειτουργικής ομοιότητάς τους με τον εγκέφαλο, έχουν δυνατότητες επεξεργασίας πληροφοριών και μάθησης με πολύ αποδοτικότερο τρόπο όσον αφορά την κατανάλωση ενέργειας και την μεταφορά δεδομένων για την μεταφορά των ερεθισμάτων.

Ωστόσο, εξακολουθεί να λείπει μια ολοκληρωμένη ανασκόπηση σχετικά με τον έλεγχο των ρομπότ που βασίζονται σε νευρωνικά δίκτυα. Ως εκ τούτου, σε αυτό το κεφάλαιο, θα γίνει μια επισκόπηση στην έρευνα των υπερσύγχρονων μεθόδων μοντελοποίησης, σχεδιασμού και εκπαίδευσης των SNN για τον έλεγχο μιας ποικιλίας εφαρμογών ρομποτικής

4.2.1 Μη επιτηρούμενη εκπαίδευση στην ρομποτική

Κατά την μη επιτηρούμενη μάθηση, δηλαδή της εκπαίδευσης με την απουσία άμεσων στόχων και λειτουργιών διόρθωσης και με την χρήση του STDP κατά το οποίο εάν μια προσυναπτική ακίδα προηγήθηκε μιας μετασυναπτικής ακίδας, θα μπορούσε να παρατηρηθεί μια ισχυροποίηση της συναπτικής δύναμης [Μακροπρόθεσμη ισχύς (LTP)], ενώ η αντίστροφη σειρά προκάλεσε κατάθλιψη [Μακροπρόθεσμη Κατάθλιψη (LTD) , έχουν εφαρμοστεί με επιτυχία σε πολλά προβλήματα. [15]

Συγκεκριμένα ο Wang et al. (2008) χρησιμοποίησε αυτή την προσέγγιση για να εκπαιδεύσει έναν ελεγκτή συμπεριφοράς με βάση το SNN για να επιτύχει την αποφυγή εμποδίων χρησιμοποιώντας αισθητήρα υπερήχων με ένα κινητό ρομπότ οδηγώντας το από διαφορετικές θέσεις εκκίνησης. Με την συγκεκριμένη υλοποίηση αποδείχτηκε ότι σε σύγκριση με άλλα κλασικά NNs, η ίδια υλοποίηση με SNN χρειάζεται λιγότερους νευρώνες και είναι σχετικά απλή. Στη συνέχεια, ο ίδιος επέκτεινε την λειτουργικότητα των ελεγκτών με ικανότητες ακολούθησης τοίχου και προσέγγισης ενός συγκεκριμένου μέρους. Σε μια παρόμοια έρευνα, ο Arena et al. (2010) παρουσίασε ένα SNN με βάση ένα μη επιτηρημένο πρότυπο μάθησης για να επιτρέψει στο ρομπότ να μάθει αυτόνομα πώς να πλοηγηθεί σε ένα άγνωστο περιβάλλον. Ο ελεγκτής τους επέτρεψε στο ρομπότ να μάθει χαρακτηριστικά αισθητήρων υψηλού επιπέδου, με βάση ένα σύνολο βασικών αντανακλαστικών, ανάλογα με τις εισόδους των αισθητήρων που περιελάμβανε.

4.2.2 Επιτηρούμενη εκπαίδευση στην ρομποτική

Στα μη-spiking νευρωνικά δίκτυα, τα τελευταία χρόνια έχουν βρεθεί πολλοί τρόποι αποτελεσματικής μάθησης από τα δεδομένα με ετικέτα. Ο Συγκεκριμένος τύπος μάθησης, όπου ένα νευρωνικό δίκτυο μιμείται ένα γνωστό αποτέλεσμα από δεδομένα ονομάζεται επιτηρούμενη μάθηση (Hastie et al., 2001). Μια ποικιλία διαφορετικών νευροεπιστημονικών μελετών έχει δείξει ότι αυτός ο τύπος μάθησης μπορεί επίσης να βρεθεί στον ανθρώπινο εγκέφαλο (Knudsen, 1994). Βέβαια, παρά την εκτεταμένη διερεύνηση αυτών των θεμάτων, οι ακριβείς μηχανισμοί εποπτευόμενης μάθησης στους βιολογικούς νευρώνες παραμένουν άγνωστοι.

Κατά συνέπεια των παραπάνω, ένας απλός τρόπος εκπαίδευσης των SNNs για εργασίες ελέγχου στα ρομπότ είναι η παροχή ενός εξωτερικού σήματος εκπαίδευσης που προσαρμόζει τις συνάψεις σε ένα επιτηρούμενο περιβάλλον εκπαίδευσης. Όταν ένα εξωτερικό σήμα εισέρχεται στο δίκτυο ως μετασυναπτική ακολουθία αιχμών, οι συνάψεις μπορούν να προσαρμόσουν τα βάρη τους, για παράδειγμα, χρησιμοποιώντας κανόνες μάθησης όπως τον STDP. Μετά από μια αρχική φάση εκπαίδευσης, αυτό θα κάνει το δίκτυο να μιμηθεί το σήμα εκπαίδευσης με ικανοποιητική ακρίβεια. Βέβαια, παρόλο που αυτή η προσέγγιση παρέχει έναν απλό, ευθύ τρόπο για τα δίκτυα




Figure 65 supervised εκπαίδευση κατά Hebb's. Το θάρος μεταξύ της προ και μετα συναψης μεταβάλλεται απο το σήμα S_{syn} [14]

εκπαίδευσης, η διαδικασία αυτή εξαρτάται από έναν εξωτερικό ελεγκτή. Έχουν προταθεί διάφορα μοντέλα σχετικά με τον τρόπο με τον οποίο αυτό θα μπορούσε η προσέγγιση αυτή να λειτουργήσει, είτε με τη χρήση προτύπων δραστηριότητας που πρόκειται να αναπαραχθούν (Miall και Wolpert, 1996) είτε με σήματα σφάλματος που πρέπει να ελαχιστοποιήσουν μια τιμή (Kawato και Gomi, 1992· Μοντγκόμερι κ.ά., 2002).[15]

Στο νευρικό σύστημα, αυτά τα σήματα εκπαίδευσης μπορεί να παρέχονται από αισθητηριακή ανάδραση ή άλλες εποπτικές νευρικές δομές (Carey et al., 2005). Ένα από αυτά τα μοντέλα που είναι κυρίως κατάλληλο για δίκτυα ενός επιπέδου ονομάζεται εποπτευόμενη μάθηση Hebbian (SHL). Με βάση τον κανόνα του Hebb's, ένα σήμα εκπαίδευσης χρησιμοποιείται για την εκπαίδευση του μετασυναπτικού νευρώνα να πυροδοτεί σε ώρες-στόχους και να παραμένει σιωπηλός σε άλλες χρονικές στιγμές. Αυτό μπορεί να εκφραστεί ως εξής:

$$w_{ij}^{new} = w_{ij}^{old} + \alpha v_i \cdot t_j$$

όπου w_{ij} είναι η συναπτική αποτελεσματικότητα μεταξύ ενός προσυναπτικού νευρώνα i και ενός μετασυναπτικού νευρώνα j , α είναι το ποσοστό μάθησης, v_i είναι η δραστηριότητα των προσυναπτικών νευρώνων και το t_j αντιπροσωπεύει το μετασυναπτικό σήμα διδασκαλίας.

Ο Carrillo et al. (2008) χρησιμοποίησε αυτή τη βασική προσέγγιση για να εκπαιδεύσει ένα SNN ώστε να ελέγξει ένα ρομποτικό βραχίονα με 2 βαθμούς ελευθερίας, λαμβάνοντας γωνίες και ταχύτητες, καθώς και τη θέση-στόχο ως εισόδους. Το μοντέλο αυτό εκπαιδεύτηκε προσομοιώνοντας τον βραχίονα ρομποτικής σε επτά διαφορετικούς στόχους επανειλημμένα. Σε αντίθεση με άλλους κανόνες μάθησης STDP, μόνο η μακροχρόνια καταστολή προκλήθηκε εξωτερικά από ένα σήμα κατάρτισης, το οποίο βασίστηκε στο σφάλμα του κινητήρα, δηλαδή τη διαφορά μεταξύ της επιθυμητής και της πραγματικής κατάστασης.

4.2.3 Classical conditioning(Κλασσική συνθήκη)

Η διαδικασία εκπαίδευσης classical conditioning αναφέρεται σε μια διαδικασία μάθησης στην οποία ένα βιολογικά ισχυρό ερέθισμα (π.χ. φαγητό) συνδυάζεται με ένα προηγουμένως ουδέτερο ερέθισμα (π.χ. ένα κουδούνι). Θα έχει ως αποτέλεσμα το ουδέτερο ερέθισμα να έρθει να προκαλέσει μια απάντηση (π.χ. σιελόρροια), η οποία συνήθως προκαλείται από το ισχυρό ερέθισμα. Στο διάσημο πείραμα κλασικής προετοιμασίας (Ρανλιον και Αηρερ, 2003), ο σκύλος του Ρανλιον μαθαίνει να συνδέει ένα ερέθισμα χωρίς ύπαρξη συνθήκης (unconditioned Stimulus)(US), στην συγκεκριμένη περίπτωση την λήψη τροφής, και ένα ρυθμισμένο ερέθισμα (Conditioned Stimulus)(CS), το χτύπημα ενός κουδούνιου. Παρόλο που δεν είναι σαφές πώς τα συγκεκριμένα ερεθίσματα που δίνονται στο πείραμά του υποβάλλονται σε επεξεργασία μέσα στον εγκέφαλο, η ίδια αρχή μάθησης μπορεί να χρησιμοποιηθεί και για εκπαίδευση στα SNN.

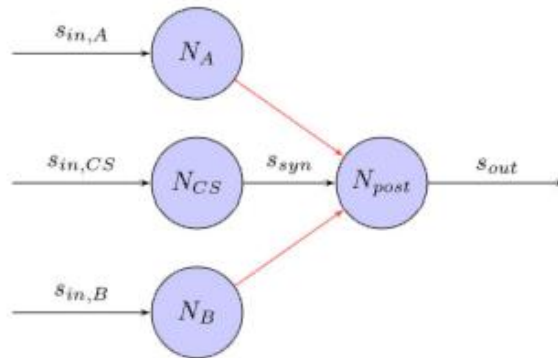


Figure 66 Classical conditioning με χρήση STDP σύναψης. Το unconditioned ερέθισμα A ή το B προκαλεί τον μετασυναπτικό νευρώνα να πυροδοτήσει αφότου όμως το conditioned ερέθισμα έχει πυροδοτηθεί στιγμιαία και έχει μεταβάλει τα βάρη ώστε και με την απουσία του, μόνο με την ύπαρξη των A,B να υπάρχει μετασυναπτική πυροδότηση [14]

Ακολουθώντας αυτή την αρχή, τα ρομπότ βιολογικής έμπνευσης μπορούν να μάθουν να συνδέουν ένα CS, π.χ. αισθητηριακές πληροφορίες, με μια US που λειτουργεί ως εξωτερικός ενισχυτής. Με αυτόν τον τρόπο, τα ρομπότ μπορούν να μάθουν να ακολουθούν την επιθυμητή συμπεριφορά με βάση τις αισθητήριες εισόδους. Ο Arena et al. (2009a,b, 2010) έδειξε πώς το classical conditioning μπορεί να χρησιμοποιηθεί για την αποφυγή εμποδίων και την προσέγγιση ενός στόχου. Αυτό το υλοποίησε με ένα SNN το οποίο αποτελούνταν από δύο κινητικούς νευρώνες εξόδου, τους αισθητήρες απόστασης και όρασης οι οποίοι λειτουργούσαν ως CS, ενώ οι αισθητήρες επαφής και στόχευσης λειτουργούν ως US. Με την πλοήγηση του ρομπότ σε ένα

προσχεδιασμένο κλειστό περιβάλλον, το ρομπότ έμαθε με επιτυχία να συνδέει το CS και τις US μαζί και να φτάνει στο στόχο χωρίς να χτυπήσει εμπόδια. Ο Wang et al. (2008, 2014) κατασκεύασε ένα χειριστήριο που διεγείρει δύο κινητικούς νευρώνες ως US. Συγκεκριμένα υλοποίησε ένα SNN ενός επιπέδου που χρησιμοποιεί δεδομένα αισθητήρων εγγύτητας ως CS το οποίο εκπαιδεύτηκε στη συνέχεια σε εργασίες όπως η αποφυγή εμποδίων και η επίτευξη στόχων.

Γενικότερα, για να εκπαιδευτούν με επιτυχία τέτοιες συμπεριφορές, θα πρέπει να δοθεί κάποιο CS για κάθε σχετικό ερέθισμα που πρέπει να μάθει το ρομπότ. Αυτό σημαίνει επίσης ότι το ρομπότ θα μάθει να συσχετίζει ερεθίσματα που μεταξύ τους έχουν κάποια καθυστέρηση, πράγμα το οποίο μας οδηγεί επίσης και στην εξοικονόμηση bandwidth και νευρωνικών συνδέσεων, μιας και το timing αποτελεί πληροφορία ερεθίσματος. Τέλους, η χρήση classical conditioning για τον έλεγχο ρομπότ ουσιαστικά σημαίνει την κατασκευή ενός εξωτερικού ελεγκτή που παρέχει το US για κάθε σχετική είσοδο, η οποία όμως να μην είναι εφικτή σε πολλές εργασίες.

4.2.4 Operant Conditioning(Λειτουργική συνθήκη)

Ενώ η εκπαίδευση classical condition ασχολείται με την παθητική συσχέτιση των US και CS ερεθισμάτων μεταξύ τους, η λειτουργική συνθήκη αποτελείται από τη συσχέτιση ερεθισμάτων με τις σχετικές αναδράσεις από τα ερεθίσματα αυτά και από ενεργά μεταβαλλόμενες συμπεριφορές. Ενωιολογικά, η λειτουργική συνθήκη περιλαμβάνει την εναλλαγή σχετικών συμπεριφορών και συνδέεται στενά με την ενισχυμένη μάθηση και την αλληλεπίδραση παράγοντα-περιβάλλοντος. [15]

Συγκεκριμένα, μια αντίδραση συμπεριφοράς ακολουθείται είτε από ενίσχυση είτε από τιμωρία. Η ενίσχυση μετά από μια συμπεριφορά θα προκαλέσει την αύξηση της συμπεριφοράς, αλλά αν η συμπεριφορά ακολουθείται από τιμωρία η συμπεριφορά θα μειωθεί. Όμως δεν έχει αναπτυχθεί ένα επίσημο μαθηματικό μοντέλο για την operant condition μιας και έχει ερευνηθεί κυρίως σε βιολογικούς και ψυχολογικούς τομείς.

Σε αυτό το πλαίσιο, ο Cyr et al. (2014) και ο Thériault (2015) ανέπτυξαν ένα μοντέλο OC που αποτελείται από έναν νευρώνα τροφοδοσίας εισόδου, έναν νευρώνα δράσης και έναν νευρώνα πρόβλεψης που λαμβάνει ανταμοιβές ή τιμωρίες. Με αυτή την απλή βασική αρχιτεκτονική και κανόνες μάθησης, όπως η εφαρμογή συνήθειας στα βάρη και το STDP, ήταν σε θέση να λύσουν απλές εργασίες που σχετίζονται με OC σε ένα προσομοιωμένο περιβάλλον, όπως το να απωθούν κουτιά. Σε μια άλλη δημοσίευση του Dumesnil et al. (2016a,β) εφαρμόστηκε ένας κανόνας μάθησης STDP εξαρτώμενος από την ανταμοιβή σε ένα ρομπότ που λειτουργεί εντός λαβύρινθου. Τελικά, το ρομπότ έμαθε την συσχέτιση δράσης – λειτουργίας, αν μια δράση ακολουθήθηκε συχνά από μια ανταμοιβή.

4.2.5 Εκπαίδευση reward-modulated

Κατά την εκπαίδευση με βάση την ανταμοιβή, στα νευρωνικά συστήματα η μετασυναπτική έξοδος εισέρχεται σε έναν νευρώνα ανταμοιβής και σε συσχέτιση με το σήμα εισόδου (προσυναπτικό) μεταβάλλει τα βάρη της σύναψης. Στην βιολογία, η χρήση μίας ή περισσότερων χημικών ουσιών που εκπέμπονται από έναν δεδομένο νευρώνα για τη ρύθμιση διαφορετικών πληθυσμών νευρώνων ονομάζεται νευροτροποποίηση (Hasselmo, 1999). Μια νευροτροπική ορμόνη αποτελεί και η ντοπαμίνη η οποία είναι ζωτικής σημασίας για τις εκτελεστικές λειτουργίες, τον έλεγχο της διαθεσης, τα κίνητρα, την εγρήγορση και τις ανταμοιβές. Οι περισσότεροι τύποι νευρολογικών ανταμοιβών αυξάνουν το επίπεδο της ντοπαμίνης στον εγκέφαλο, διεγείροντας έτσι τους νευρώνες (Schultz, 1998).




Figure 67 Reward modulated σύναψη. Η έξοδος του νευρώνα γίνεται είσοδος στον νευρώνα επιβράβευσης και μεταβάλλει ανάλογα το βάρος της σύναψης[14]

Εμπνευσμένη η εκπαίδευση αυτή από τους ντοπαμινεργικούς νευρώνες στον εγκέφαλο, οι επιδράσεις των γεγονότων STDP, συλλέγονται, και σήματα ανταμοιβής προκαλούν συναπτικές αλλαγές με την μεταβολή των βαρών. Σε αντίθεση με την εποπτευόμενη εκπαίδευση, όπως αναφέρθηκε προηγουμένως, οι ανταμοιβές μπορούν να αποδοθούν σε ερεθίσματα, ακόμη και αν έχουν κάποια καθυστέρηση. Αυτό μπορεί να είναι μια πολύ χρήσιμη ιδιότητα για τον έλεγχο των ρομπότ, επειδή μπορεί να απλοποιήσει τις απαιτήσεις ενός εξωτερικού σήματος εκπαίδευσης. Ένας απλός κανόνας μάθησης που συνδιάζει μοντέλα STDP και σήματα ανταμοιβής προτάθηκε από τους Florian (2007) και Izhikevich (2007). Στο R-STDP, το συναπτικό βάρος w αλλάζει με το σήμα ανταμοιβής R . Το ίχνος επιλεξιμότητας (eligibility trace) μιας σύναψης μπορεί να οριστεί ως,

$$C(t) = -\frac{c}{tc} + \omega(\Delta t)\delta\left(t - \frac{Spre}{post}\right) C1 \quad (108)$$

όπου το c είναι το ίχνος επιλεξιμότητας. $s_{pre/post}$ σημαίνει τον χρονισμό των μετασυναπτικών ή προσυναπτικών αιχμών. Το $C1$ είναι ένας σταθερός συντελεστής. T_c είναι μια χρονική σταθερά του ίχνους επιλεξιμότητας. $\delta(\cdot)$ είναι η συνάρτηση δέλτα του Dirac. Μετά από αυτό προκύπτει και το βάρος της σύναψης ως $W(t) = R(t) * c(t)$, με το $R(t)$ το σήμα ανταμοιβής.

Στη βιβλιογραφία, μια ποικιλία αλγορίθμων έχει δημοσιευθεί χρησιμοποιώντας αυτή τη βασική αρχιτεκτονική μάθησης για εκπαίδευση. Παρόλο που όλα βασίζονται στον ίδιο μηχανισμό, οι ανταμοιβές μπορούν να δομηθούν και να αποδοθούν με διαφορετικούς τρόπους.

- Ανταμοιβή συγκεκριμένων γεγονότων: Η πιο ευθύς εφαρμογή της μάθησης βάσει ανταμοιβής που χρησιμοποιεί ανταμοιβές που σχετίζονται με συγκεκριμένα γεγονότα.
- Ελάττωση του σφάλματος: Αντίθετα με την ανταμοιβή συγκεκριμένων γεγονότων, Η μάθηση επιτυγχάνεται εκτός σύνδεσης ελαχιστοποιώντας το σφάλμα μεταξύ αποκωδικοποιημένης πραγματικής και επιθυμητής εξόδου, η οποία παρέχεται από εξωτερικό γραμμικό ελεγκτή
- Έμμεσος έλεγχος για ελάττωση του σφάλματος: Για ορισμένες πιθανές εφαρμογές των SNNs, π.χ. νευροπροσθετικές συσκευές που εμφυτεύονται στον εγκέφαλο, ο άμεσος χειρισμός των συναπτικών βαρών μπορεί να μην είναι δυνατός. Έτσι με έμμεση εισαγωγή πυροδοτήσεων στους νευρώνες με εξωτερική συσκευή θα επιτραπεί η αλλαγή των συναπτικών βαρών.
- Metric Minimization(Ελαχιστοποίηση μετρικής): Η ίδια αρχή μπορεί επίσης να εφαρμοστεί για την ελαχιστοποίηση μιας καθολικής μετρικής σε για ένα νευρωνικό σύστημα που μπορεί να είναι ευκολότερο να κατασκευαστεί και να υπολογιστεί σε σχέση με την χρήση ενός εξωτερικού ελεγκτή.
- Reinforcing Associations(Ενισχυμένων συσχετίσεων): Όπως και στην εκπαίδευση classical condition, ένας κανόνας πλαστικότητας που εξαρτάται από την ντοπαμίνη (dopamine modulated) χρησιμοποιείται για να ενισχύσει την συσχέτιση μεταξύ US και CS ερεθισμάτων

4.2.6 Reinforcement Learning(Ενισχυμένη εκπαίδευση)

Στην προηγούμενη υποενότητα, παρουσιάστηκαν διάφορες προσεγγίσεις για την εκπαίδευση των SNNs με βάση τους κανόνες μάθησης hebbian. Αυτό έγινε είτε παρέχοντας ένα εποπτευόμενο σήμα εκπαίδευσης μέσω εξωτερικού ελεγκτή είτε χρησιμοποιώντας έναν κανόνα μάθησης που βασίζεται στην ανταμοιβή με διαφορετικούς τρόπους υλοποίησης της ανταμοιβής.

Σε γενικές γραμμές, όλες αυτές οι προσεγγίσεις έχουν εκπαιδευτεί σε εργασίες που δεν απαιτούν τον στοχασμό για το μέλλον, πράγμα πάνω στο οποίο βασίζονται οι θεωρίες ενισχυμένης μάθησης (reinforcement learning). Στην θεωρία ενισχυμένης μάθησης, κατά την εκμάθηση εξετάζονται πολλαπλά βήματα εκ των προτέρων μέσω μια διαδικασία απόφασης Markov (MDP).

Κατά τον αλγόριθμο του Markov, σε κάθε βήμα του, η διαδικασία βρίσκεται σε κάποια κατάσταση S και ο αλγόριθμος μπορεί να επιλέξει οποιαδήποτε ενέργεια a είναι διαθέσιμη σε κατάσταση S . Η διαδικασία ανταποκρίνεται στο επόμενο βήμα προχωρώντας τυχαία σε ένα νέο S' και δίνοντας την αντίστοιχη ανταμοιβή, στο μοντέλο πρόβλεψης, ανάλογα το τελικό αποτέλεσμα που προέκυψε $R_a(s, s')$. Ως εκ τούτου, έχουν δημοσιευθεί διάφοροι αλγόριθμοι που συνδυάζουν SNNs με αλγόριθμους ενισχυμένης εκπαίδευσης.




Figure 68 Διάγραμμα αποφάσεων Markov. Απεικονίζει τις πιθανές καταστάσεις και τις ανάλογες επιβραβεύσεις ανα μετάβαση ΠΗΓΗ Wikipedia.org/marcov desisiontree

Μερικά από τα μοντέλα που έχουν προταθεί για το κομμάτι της ρομποτικής είναι το *Temporal Difference*, κατά το οποίο, στην διαδικασία της εκπαίδευσης, ανάλογα με την κατάσταση που βρίσκεται την εκάστωτε στιγμή η μηχανή, κοιτάζει με ορίζοντα δυο-τριών βημάτων παραπέρα μέσω του MDP. Επίσης ένα άλλο μοντέλο είναι το *model-based* το οποίο χρησιμοποιεί ένα προγνωστικό μοντέλο για να κάνει ερωτήσεις της μορφής "τι θα συμβεί αν πάρω την x περίπτωση;" ούτως ώστε να επιλέξει την καλύτερη διαθέσιμη χ'.

5 Συμπεράσματα – Προτάσεις για μελλοντική διερεύνηση

Συνοψίζοντας, στην εργασία αυτή έγινε μια επισκόπηση της νευρομορφικής υπολογιστικής και ειδικότερα των πυροδοτούμενων νευρωνικών δικτύων όσο αναφορά τις πιθανές εφαρμογές τους. Ειδικότερα παρουσιάστηκαν μέθοδοι εκπαίδευσης των συγκεκριμένων μοντέλων, μέθοδοι κωδικοποίησης για την αλληλεπίδραση των συγκεκριμένων μοντέλων με ερεθίσματα του εξωτερικού περιβάλλοντος, προτάσεις για βελτιστοποιημένο υλικό πάνω στο οποίο μπορεί αποδοτικά να υλοποιηθεί ένα τέτοιο δίκτυο. Ακόμη παρουσιάστηκε η απόδοση εξειδικευμένου υλικού, από την άποψη αρχιτεκτονικής και εσωτερικής υλοποίησης αυτού (π.χ μεμριστορς), σε σχέση με την υλοποίηση αντίστοιχων αλγορίθμων σε CPU ή GPU, δείχνοντας την ανωτερότητα του εξειδικευμένου υλικού από πλευράς κατανάλωσης ενέργειας και απαίτησης σε χρόνο για την εκπαίδευση του εκάστωτε μοντέλου σε αυτά.

Ακολούθως η εργασία αυτή παρουσίασε μερικές από τις πιθανές υλοποιήσεις των πυροδοτούμενων νευρωνικών δικτύων στο κομμάτι της υπολογιστικής όρασης και της ρομποτικής, με γνώμονα την παρουσίαση της βιβλιογραφίας αναφορικά με καινοτόμες ιδέες που έχουν σκοπό να δώσουν λύση στα συγκεκριμένα προβλήματα.

Στο κομμάτι της υπολογιστικής όρασης και συγκεκριμένα στο κομμάτι του VPR μας έδειξε ότι ένα SNN δύο επιπέδων μπορεί να προσαρμοστεί για το έργο αναγνώρισης θέσεων (VPR), μέσω της εισαγωγής του weighted assignment scheme, κατά το οποίο υλοποιείται ικανοποιητικό φιλτράρισμα στην δημιουργία νέων ετικετών κατά την εκπαίδευση του μοντέλου, πράγμα το οποίο κάνει το μοντέλο πιο αποδοτικό, ευκολα εκπαιδεύσιμο και ενεργιακά αποδοτικό.

Στο κομμάτι της ανίχνευσης κίνησης, η όραση που βασίζεται σε συμβάντα προσφέρει μια σειρά από πλεονεκτήματα σε σχέση με τη συμβατική υπολογιστική όραση που βασίζεται σε καρέ λόγω της εγγενούς ικανότητάς της να υλοποιεί αποδοτικά την παροχή εικόνας, με τους ελάχιστους πόρους (μικρή περιοχή ουσιαστικής παροχής πληροφορίας σε σχέση με το υπολοιπο κομμάτι που ανταποκρίνεται μόνο στην ανίχνευση μεταβολής στην εικόνα). Επίσης, αν και ακόμα το κομμάτι του event vision, βρίσκεται σε πρώιμο στάδιο, η ύπαρξη αισθητήρων εικόνας που βασίζονται σε γεγονότα (EVS) και η γενικότερος επηρεασμός από τα βιολογικά μοντέλα μπορεί να οδηγήσει σε περαιτέρω ανάπτυξη του τομέα αυτού.

Στο κομμάτι της ρομποτικής και της συνύπαρξης του με τα SNN, παρουσιάστηκαν οι βασικές προσεγγίσεις μοντελοποίησης για το σχεδιασμό του νευρώνα, της σύναψης και του δικτύου. Επίσης,

οι λύσεις εκπαίδευσης των SNNs γενικά ταξινομούνται σε δύο τύπους που βασίζονται στον κανόνα του hebb και την ενισχυμένη μάθηση, για τα οποία δώθηκαν και αντίστοιχα παραδείγματα υλοποιήσεων. Βέβαια, η μεγαλύτερη πρόκληση για εργασίες ελέγχου που βασίζονται σε SNNs είναι η έλλειψη μιας καθολικής μεθόδου εκπαίδευσης των μοντέλων, καθώς το backpropagation είναι κομμάτι παλαιότερων γενιών νευρωνικών δικτύων και χρήζει προσαρμογής για την γενιά των SNN. Συγκεκριμένα, Κανένας από τους προτεινόμενους προς το παρόν αλγόριθμους γενικής χρήσης δεν είναι σε θέση, να μάθει μια εργασία με τον τρόπο που το κάνει ο αλγόριθμος οπισθοδιάδοσης, και να μετατραπεί αποδοτικά σε πυροδοτήσεις για την λειτουργία των SNN, με αποτέλεσμα να αποφεύγεται για την χρήση του σε πρακτικά θέματα. Ως εκ τούτου, απαιτούνται περισσότερες γνώσεις και αλληλεπιδράσεις από τους τομείς της νευροεπιστήμης και της ρομποτικής για να διερευνηθεί αυτός ο τομέας στο μέλλον.

Συμπερασματικά ο τομέας των SNN μπορεί να λάβει έμπνευση από τα βιολογικά μοντέλα, άλλα λόγω του ότι τόσο οι τομείς τόσο της νευροεπιστήμης, όσο και της υλοποίησης του υλικού (πιθανή χρήση κβαντικών υλοποιήσεων) βρίσκονται σε πρώιμο στάδιο, η ωρίμανση των σκέψεων και των υλοποιήσεων με το πέρασμα του χρόνου, πιθανό να μας οδηγήσει σε αξιόπιστα, εύκολα εκπαιδευσιμα και ενεργειακά αποδοτικά νευρωνικά δίκτυα.

6 Βιβλιογραφία

- [1.] Catherine D Schuman, Thomas E Potok, Robert M Patton, et al. A survey of neuromorphic computing and neural networks in hardware. In: arXiv preprint arXiv:1705.06963 (2017)
- [2.] Elisabetta Chicca, Fabio Stefanini, Chiara Bartolozzi, et al. Neuromorphic electronic circuits for building autonomous cognitive systems. In: Proceedings of the IEEE 102.9 (2014)
- [3.] Giacomo Indiveri, Bernabe Linares-Barranco, Tara Julia Hamilton, et al. Neuromorphic silicon neuron circuits. In: Frontiers in neuroscience 5 (2011), p. 73.
- [4.] Chetan Singh Thakur, Jamal Lottier Molin, Gert Cauwenberghs, et al. Large-scale neuromorphic spiking array processors: A quest to mimic the brain. In: Frontiers in neuroscience 12 (2018), p. 891.
- [5.] Wolfgang Maass. Networks of spiking neurons: the third generation of neural network models. In: Neural networks 10.9 (1997),
- [6.] Helene Paugam-Moisy and Sander M Bohte. Computing with spiking neuron networks. In: Handbook of natural computing 1 (2012),
- [7.] John Lazzaro and John Wawrzynek. Low-power silicon neurons, axons and synapses. In: Silicon implementation of pulse coded neural networks. Springer, 1994,
- [8.] Giacomo Indiveri, Fabio Stefanini, and Elisabetta Chicca. Spike-based learning with a generalized integrate and fire silicon neuron. In: Proceedings of 2010 IEEE International Symposium on Circuits and Systems. IEEE. 2010
- [9.] Σακελλαρόπουλος Διονύσιος, “Κατασκευή και χαρακτηρισμός διατάξεων μνήμης (ReRAM)”, 2018
- [10.] Daniel E. Feldman, “The Spike-Timing Dependence of Plasticity”, August 23, 2012
- [11.] Edris Zaman Farsa , Arash Ahmadi ,” A Low-Cost High-Speed Neuromorphic Hardware Based on Spiking Neural Network” , September 2019
- [12.] Somayeh Hussaini Michael Milford Tobias Fischer ,”Spiking Neural Networks for Visual Place Recognition via Weighted Neuronal Assignments”, 14 sept 21
- [13.] Garibaldi Pineda-García, Petrut, A. Bogdan and Steve B. Furber ,” Spiking neural networks for computer vision Michael Hopkins”, 2 May 2018
- [14.] Zhenshan Bing, Claus Meschede, Florian Röhrbein, Kai Huang and Alois C. Knoll , “A Survey of Robotics Control Based on Learning-Inspired Spiking Neural Networks” , 06 July 2018
- [15.] Jing Zhou , Jingsheng Chen , “Prospect of Spintronics in Neuromorphic Computing”
- [16.] Hyeryung Jang, Osvaldo Simeone, Brian Gardner, and André Grüning , “An Introduction to Probabilistic Spiking Neural Networks”, November 2019
- [17.] Konstantinos Demertzis , “Spiking Neural Networks: A Brief Introduction to the 3rd Generation of Neural Networks” July 2018
- [18.] Minseon Kang, Yongseok Lee and Moonju Park, “Energy Efficiency of Machine Learning in Embedded Systems Using Neuromorphic Hardware”, 29 June 2020

- [19.] M. Sit, B. Z. Demiray, Z. Xiang, G. J. Ewing, Y. Sermet, and I. Demir, "A Comprehensive Review of Deep Learning Applications in Hydrology and Water Resources," ArXiv, vol. Abs/2007.12269, 2020.
- [20.] Waseem Rawat and Zenghui Wang. Deep convolutional neural networks for image classification: A comprehensive review. *Neural Computation*, 29(9):2352–2449, sep 2017.
- [21.] F. Schilling, "The Effect of Batch Normalization on Deep Convolutional Neural Networks," 2016.
- [22.] A. Kolesnikov et al., "Big Transfer (BiT): General Visual Representation Learning," 2020.
- [23.] [35] N. Keskar and R. Socher, "Improving Generalization Performance by Switching from Adam to SGD," ArXiv, vol. abs/1712.07628, 2017.
- [24.] R. J. Williams and D. Zipser, "Gradient-based learning algorithms for recurrent networks and their computational complexity," 1995.
- [25.] J. Kolen and S. C. Kremer, "Gradient Flow in Recurrent Nets: The Difficulty of Learning LongTerm Dependencies," 2001.
- [26.] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Improving neural networks by preventing co-adaptation of feature detectors," ArXiv, vol. abs/1207.0580, 2012
- [27.] A. Almosova and N. Andresen, "Nonlinear Inflation Forecasting with Recurrent Neural Networks Latest version is available here," 2019.
- [28.] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [29.] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, pp. 1735–1780, 1997.
- [30.] Ping Hu, Shuxiang Wu and Shuwei Li, "Synaptic Behavior in Metal Oxide-Based Memristors", October 3d 2018
- [31.] Christopher Münch , Rajendra Bishnoi , Mehdi B. Tahoori "Reliable In-Memory Neuromorphic Computing using Spintronics" , , January 21–24, 2019
- [32.] D. Verstraeten * , B. Schrauwen, D. Stroobandt, J. Van Campenhout , "Isolated word recognition with the Liquid State Machine: a case study", 14 July 2005
- [33.] XIUBAO SUI , QIUHAO WU , JIA LIU , QIAN CHEN , AND GUOHUA GU "A Review of Optical Neural Networks", April 28, 2020

7 Συντομογραφίες

Συντομογραφία	Ανάλυση συντομογραφίας
FSOI	FREE SPACE OPTICAL IMPLEMENTATION
WOI	WAVEGUIDE OPTICAL IMPLEMENTATION
MLA	MICRO LENS ARRAY
SLM	SPACIAL LIGHT MODULATOR
HOE	HOLOGRAFIC ELEMENT
ONN	OPTICAL NEURAL NETWORK
VPR	VISUAL PLACE RECOGNITION
SNN	SPIKING NEURAL NETWORK
LIF	LEAKY INTEGRATION AND FIRE
STDP	SPIKE TIMING DEPENDENT PLASTICITY
CS	CONDITIONED STIMULUS
US	UNCONDITIONED STIMULUS
ANN	ARTIFICIAL NEURAL NETWORK
SHL	SINGLE HIDDEN NETWORK
OC	OPERANT CONDITION
MDP	MARKOV DECISION PROCESS
TEAM	THRESHOLD ADAPTIVE MODEL
STBM	SIMPSONS TUNNEL BARRIER MODEL
CPU	CENTRAL PROSECC UNIT
GPU	GRAFICS PROCESS UNIT
NCHU	NEURAL COMPUTING HARDWARE UNIT
SRAM	STATIC RANDOM ACESS MEMORY
FPGA	FIELD PROGRAMMABLE GATE ARRAY
ZISC	ZERO INSTRUCTION COMPUTER
VLSI	VERY LARGE SYSTEM INTEGRATION
NN	NEURAL NETWORK
LSM	LIQUID STATE MACHINE