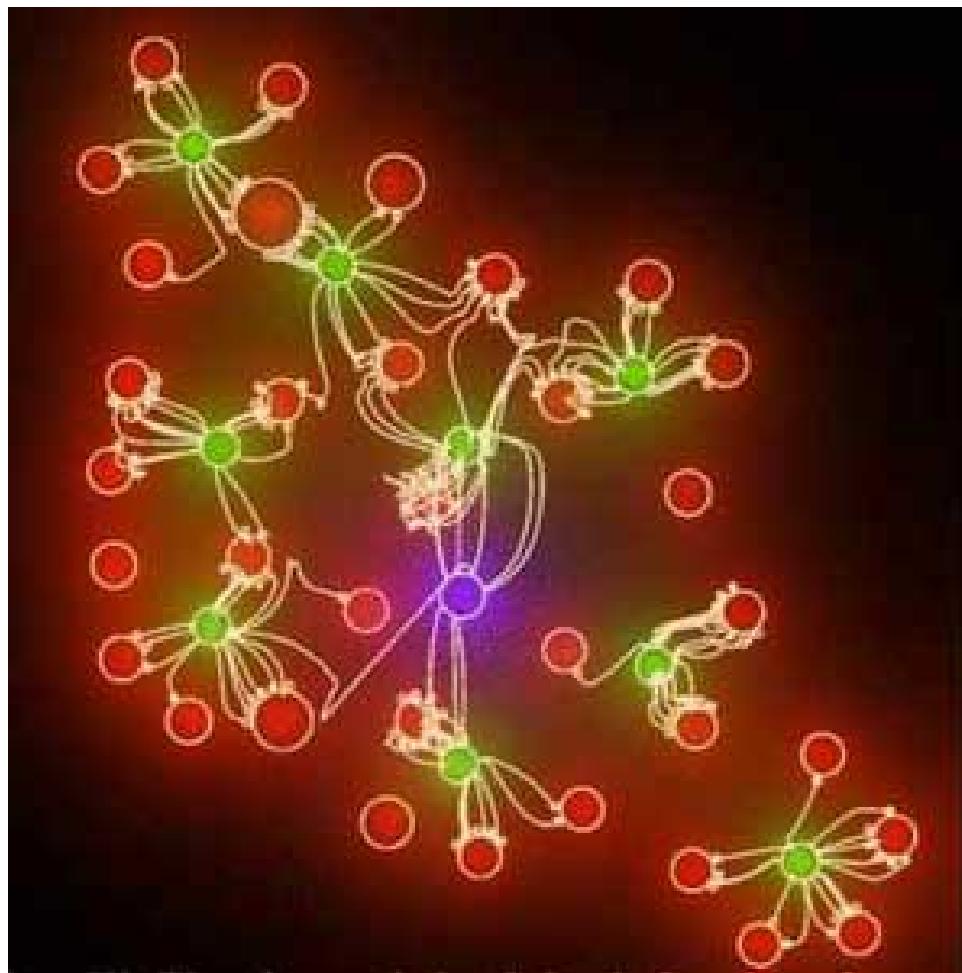




Ανώτατο Τεχνολογικό Επαγγελματικό Ίδρυμα Κρήτης
Παράρτημα Χανίων
Τμήμα Ηλεκτρονικών Μηχανικών

Πτυχιακή Εργασία

Μεθοδολογία Αμφίδρομων Νευρωνικών Δικτύων & Νευρωνικών Δικτύων Ενεργειακών καταστάσεων



Από τον Χλωρό Γεώργιο

Επιβλέπων καθηγητής:
Δρ. Αντώνιος Κωνσταντάρας

Απρίλιος του 2010



Ανώτατο Τεχνολογικό Επαγγελματικό Ίδρυμα Κρήτης
Παράρτημα Χανίων
Τμήμα Ηλεκτρονικών Μηχανικών

Μεθοδολογία Αμφίδρομων Νευρωνικών Δικτύων & Νευρωνικών Δικτύων Ενεργειακών καταστάσεων

Πτυχιακή Εργασία

Χλωρός Γεώργιος

Επιβλέπων: Δρ. Αντώνιος Κωνσταντάρας

Επιτροπή Αξιολόγησης : Δρ. Αντώνιος Κωνσταντάρας
: Αντώνιος Ζερβουδάκης
: Δρ. Αντώνιος Δασκαλάκης

Ημερομηνία Παρουσίασης: 28 / 05 / 2010

Αύξων Αριθμός Πτυχιακής Εργασίας:

Περίληψη. Αυτή η εργασία περιγράφει νευρωνικά δίκτυα ενεργειακών καταστάσεων τύπου Hopfield καθώς και την μεταβλητή ανάδρασης: ένα μοναδικό τρόπο υλοποίησης πίνακα που επιτρέπει την εξέλιξη των νευρωνικών δικτύων με εγγενή επιβλεπόμενη μαθησιακή ικανότητα. Αυτό διευρύνει την κλίμακα των δικτύων που μπορούν να εξελιχθούν αποδοτικά συγκρινόμενα με προηγούμενες προσεγγίσεις και επίσης επιτρέπει στα δίκτυα να είναι αντιστρέψιμα, δηλαδή μόλις ένα δίκτυο έχει εξελιχθεί για έναν δεδομένο προβληματικό τομέα και έχει εκπαιδευτεί σε ένα συγκεκριμένο σετ εντολών, το δίκτυο τότε μπορεί να λειτουργήσει ανάποδα για να παρατηρήσουμε τι είδους χαρτογράφηση έχουμε μάθει ή για χρήση σε προβλήματα ελέγχου. Δίνεται μια επίδειξη του είδους των αυτό εκπαιδευόμενων δικτύων που θα μπορούσαν να εξελιχθούν.

Abstract. This final year project thesis describes energy state neural networks as well as the forward – backward module: a simple building block that allows the evolution of neural networks with intrinsic supervised learning ability. This expands the range of networks that can be efficiently evolved compared to previous approaches, and also enables the networks to be invertible i.e. once a network has been evolved for a given problem domain, and trained on a particular dataset, the network can then be run backwards to observe what kind of mapping has been learned, or for use in control problems. A demonstration is given of the kind of self-training networks that could be evolved.

Ευχαριστίες

Ευχαριστώ θερμά τον καθηγητή μου, κύριο Αντώνη Κωνσταντάρα για την στήριξη και την βοήθεια που μου προσέφερε όλο αυτό το διάστημα της επιμέλειας της πτυχιακής μου εργασίας. Αρχικά θα ήθελα να τον ευχαριστήσω για την επιλογή του θέματος και για την ενκαίρια που μου έδωσε να ασχοληθώ με ένα τόσο ενδιαφέρον αλλά ταυτόχρονα και σημαντικό θέμα όσο αυτό των Νευρωνικών Δικτύων. Ένα θέμα που είναι στην αιχμή της τεχνολογίας και χωρίς την δική του προτροπή και καθοδήγηση δεν θα μπορούσε να υλοποιηθεί. Η υπομονή του, η ικανότητα του να σε προσανατολίζει τόσο στην εύρεση βιβλιογραφίας και στην επεξήγηση των πολλών τεχνικών όρων ήταν ανεκτίμητη. Για όλους αυτούς τους λόγους μα και για πολλούς άλλους νοιώθω την ανάγκη να εκφράσω την ευγνωμοσύνη μου και να πω ένα μεγάλο ευχαριστώ. Επίσης οφείλω να ευχαριστήσω στην εξεταστική επιτροπή για τον χρόνο της και την δίκαιη και ορθή κρίση της.

Τέλος θα ήθελα να ευχαριστήσω τους γονείς μου για την ηθική και υλική τους υποστήριξη όλα αντά τα χρόνια.

Περιεχόμενα

1. Κεφάλαιο 1^ο: Νευρωνικά Δίκτυα Hopfield

1.1. Εισαγωγή.....	06
1.1.1. Παράδειγμα.....	08
1.1.2. Παράδειγμα εκμάθησης.....	10
1.2. Ανάλυση του δικτύου Hopfield: Υπολογιστική ενέργεια.....	10
1.2.1. Παράδειγμα.....	11
1.2.2. Παράδειγμα εκμάθησης.....	12
1.3. Δίκτυα Hopfield και σταθερές καταστάσεις.....	13
1.4. Σχεδιάζοντας σταθερές καταστάσεις σε ένα δίκτυο Hopfield.....	16
1.5. Εκπαίδευντας ένα δίκτυο Hopfield για απαιτούμενες σταθερές καταστάσεις.....	23
1.6. Μια πρακτική εφαρμογή των δικτύων Hopfield.....	29
1.6.1. Block Truncation Coding (BTC) Σχηματικό συμπίεσης εικόνας.....	30
1.6.2. Δίκτυα Hopfield BTC – Σχηματικό συμπίεσης εικόνας.....	32
1.6.3. Παράδειγμα.....	33
1.6.4. Παράδειγμα εκμάθησης.....	37

2. Κεφάλαιο 2^ο : Η δομή της Ανάδρασης για την εξέλιξη των νευρωνικών δικτύων με εγγενής συμπεριφορές μάθησης

2.1. Εισαγωγή.....	39
2.2. Υπόβαθρο.....	39
2.3. Η μεταβλητή ανάδρασης.....	41
2.3.1. Ένας γενικός κόμβος ανάδρασης	41
2.3.2. Ημιτονοειδείς και συνημιτονοειδείς μεταβλητές.....	42
2.3.3. Παραγωγή και άθροιση μεταβλητών.....	43
2.3.4. Μεταβαλλόμενες καταστάσεις.....	44
2.4. Παράδειγμα: Φτιάχνοντας έναν απλό ρομποτικό βραχίονα.....	46
2.5. Συζήτηση και συμπεράσματα.....	23

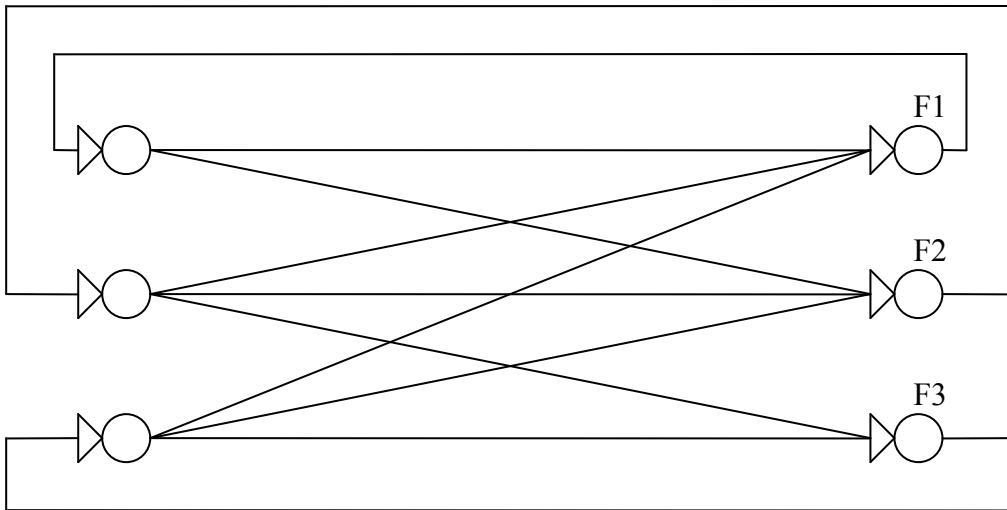
Βιβλιογραφία.....	48
-------------------	----

Κεφάλαιο 1^ο:

Νευρωνικά Δίκτυα Hopfield

1.1. Εισαγωγή

Ένα νευρωνικό δίκτυο Hopfield αποτελείτε από ένα επίπεδο MCP νευρώνων με ανάδραση. Κάθε νευρώνιο έχει εισόδους οι οποίες προέρχονται από της εξόδους των άλλων νευρώνων. Μια απλή αναπαράσταση ενός δικτύου Hopfield με τρία νευρώνια απεικονίζεται παρακάτω.



Προσέξτε ότι τα στοιχεία στα αριστερά δεν είναι νευρώνια, αλλά είναι ουσιαστικά στοιχεία εισόδου / εξόδου που επιτρέπουν στο διάγραμμα να σχεδιαστεί καθαρά.

Εφόσον κάθε έξοδος από τα νευρώνια χρησιμοποιείτε σαν είσοδος για κάθε νευρώνιο, ο συμβολισμός που χρησιμοποιούμε για τα βάρη του δικτύου πρέπει να περιλαμβάνει δύο προϋποθέσεις: Ένα για να δείχνει από ποιο νευρώνιο έρχεται η έξοδος και ένα άλλο για να δείχνει σε ποιο νευρώνιο πηγαίνει η είσοδος. Θα ονομάσουμε δικτυακό βάρος το κομμάτι από την έξοδο του νευρώνα i σε μια είσοδο του νευρώνα j W_{ji} .

Κάθε νευρώνας ίσως να έχει επίσης μια είσοδο εξωτερική η οποία αναφέρεται ως X_i . Προς το παρόν θα θεωρήσουμε την περίπτωση όπου $X_i=0$ για όλα τα i και έτσι δεν υπάρχουν εξωτερικές είσοδοι.

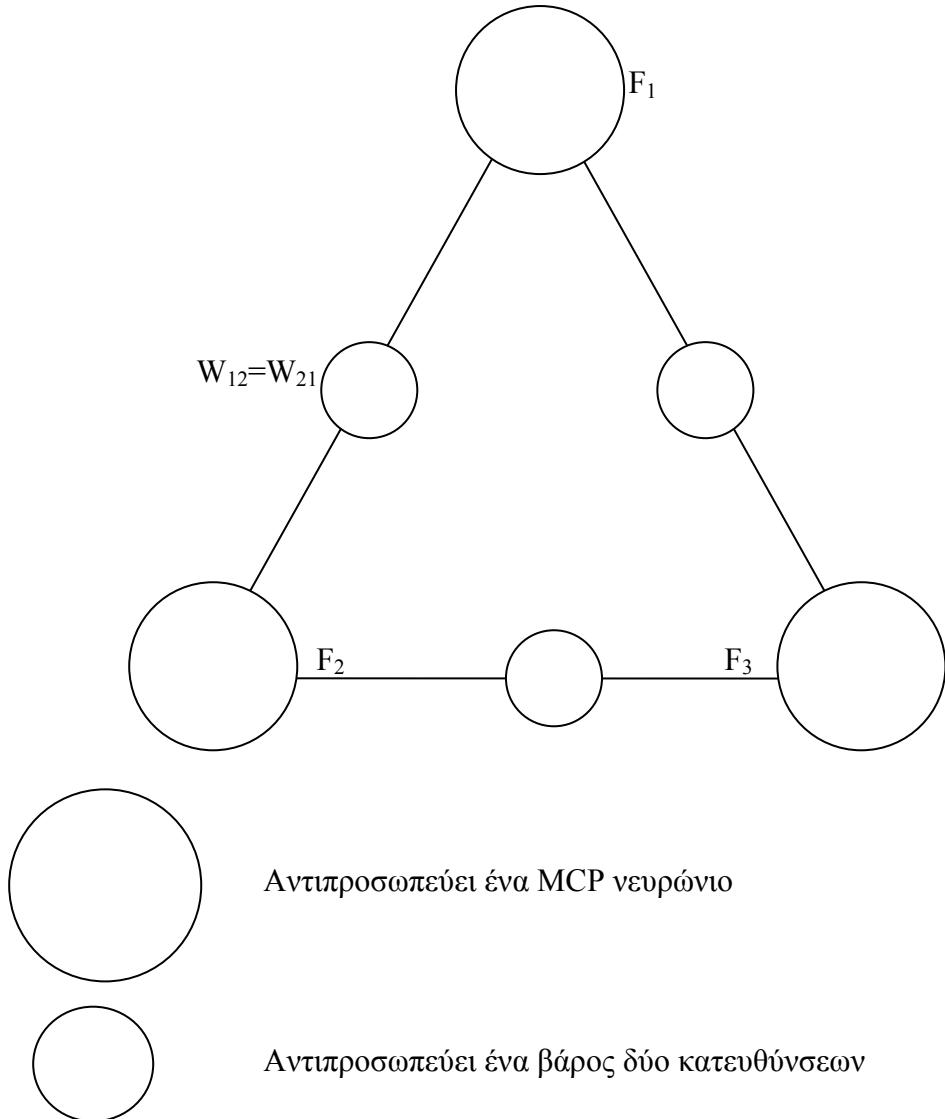
Θα θεωρήσουμε δίκτυα όπου η έξοδος ενός νευρώνα δεν χρησιμοποιείτε ως είσοδος στο ίδιο νευρώνιο. Αυτό μπορεί να γίνει εφικτό αφαιρώντας μερικές από τις διασυνδέσεις στο παρακάτω διάγραμμα, ή πιο απλά και βολικά θέτοντας:

$$W_{ii} = \quad \text{για κάθε } i$$

Επίσης θα εξετάσουμε την περίπτωση όπου του δικτύου ο πίνακας συναπτικών βαρών είναι συμμετρικός – εννοώντας ότι το βάρος από την έξοδο i σε μια είσοδο του νευρώνα j είναι το ίδιο με το βάρος από την έξοδο j σε μια είσοδο του νευρώνα i, πχ

$$W_{ij} =$$

Εισάγοντας αυτούς του περιορισμούς έχουμε τη δυνατότητα να χρησιμοποιήσουμε ένα ποιο απλό διάγραμμα. Έτσι υπάρχει μια σύνδεση δύο κατευθύνσεων ανάμεσα σε οποιαδήποτε δύο νευρώνια (πχ νευρώνιο i και νευρώνιο j) η οποία μπορεί να προσδιοριστεί από ένα βάρος $W_{ij}=W_{ji}$. Μια ποιο απλή αναπαράσταση δίνεται παρακάτω, πάλι για ένα δίκτυο Hopfield με τρις νευρώνες.



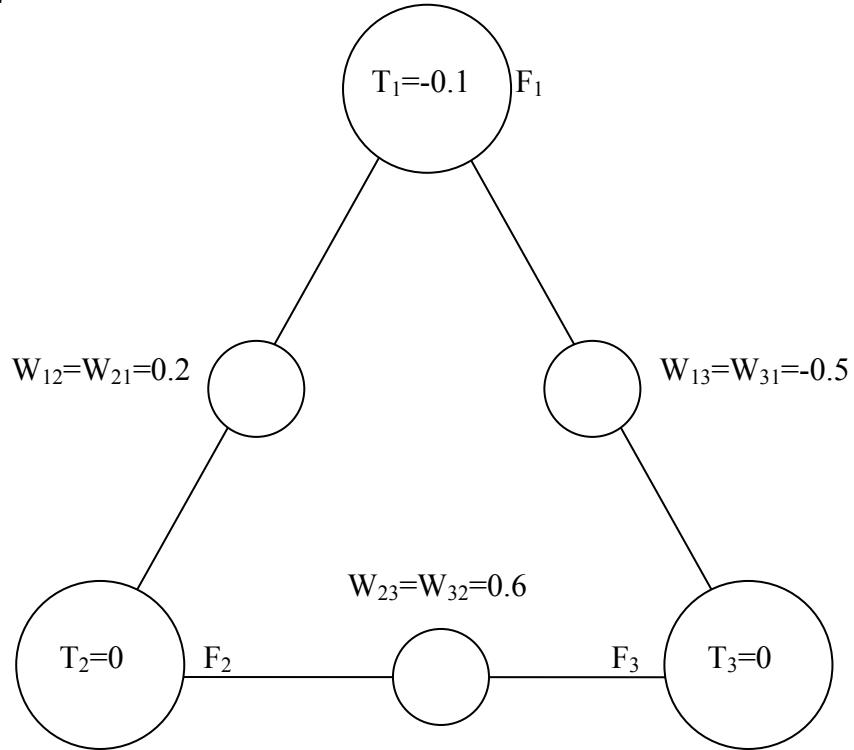
Ένας βασικός παράγοντας για το δίκτυο Hopfield είναι ότι έχει μια ασύγχρονη λειτουργία. Αυτό σημαίνει ότι ένα νευρώνιο μπορεί να επιχειρήσει να εκπέμψει στο δικό του χρόνο και δεν είναι συγχρονισμένο με τις προσπάθειες εκπομπής των άλλων νευρώνων στο δίκτυο. Αυτό μπορούμε να το ερμηνεύσουμε ότι σε οποιαδήποτε στιγμή οποιαδήποτε νευρώνιο στο δίκτυο έχει την ίδια πιθανότητα να επιχειρήσει να εκπέμψει. Για ένα δίκτυο που αποτελείται από τρία νευρώνια όπως επάνω, κάθε νευρώνιο έχει πιθανότητα $1/3$ να είναι το επόμενο νευρώνιο που θα εκπέμψει.

Οποιαδήποτε δεδομένη στιγμή, η έξοδος F_i κάθε νευρώνα είναι ή 0 ή 1. Έτσι το δίκτυο λέγεται ότι είναι σε μια συγκεκριμένη κατάσταση που προσδιορίζεται από την έξοδό του. Για παράδειγμα, η κατάσταση του δικτύου με τρία νευρώνια ορίζεται ως $F_1 F_2 F_3$. Εφόσον κάθε έξοδος είναι δυαδική, υπάρχουν οχτώ διαφορετικές πιθανές

καταστάσεις για ένα δίκτυο τριών νευρώνων. Γενικά για ένα δυαδικό δίκτυο Hopfield με N νευρώνες, υπάρχουν 2^N καταστάσεις που ίσως υπάρχουν.

1.1.1. Παράδειγμα

Ένα δίκτυο Hopfield με τρείς νευρώνες έχει βάρη και κατώφλια όπως ορίζεται στο σχέδιο παρακάτω.



Μπορούμε να αναλύσουμε αυτό το δίκτυο για να καθορίσουμε την επόμενη του κατάσταση από οποιαδήποτε συγκεκριμένη τωρινή κατάσταση. Εφόσον δεν ξέρουμε από πριν ποιος νευρώνας θα είναι ο επόμενος που θα επιχειρήσει να εκπέμψει, πρέπει να σκεφτούμε όλες τις περιπτώσεις ξεχωριστά και να ονομάσουμε τις μεταβλητές της κατάστασης με της κατάλληλες πιθανότητες.

Θα θεωρήσουμε την τωρινή κατάσταση ότι είναι 010 αρχικά, πχ
 $F_1=0 \quad F_2=1 \quad F_3=0$

Αν ο νευρώνας ένα είναι ο επόμενος που θα επιχειρήσει να εκπέμψει, τότε θα μπορούμε να προβλέψουμε αν θα εκπέμψει ή όχι κοιτάζοντας τον κανόνα ενεργοποίησης για το νευρώνα ένα. Το άθροισμα των βαρών εισόδου συμπεριλαμβανομένου του κατωφλίου (γνωστό ως ενεργοποίηση) στο νευρώνα ένα φαίνεται να είναι:

$$F_2 W_{12} + F_3 W_{13} - T_1 = (1 * 0.2) + (0 * (-0.5)) + 0.1 = 0.3$$

Αυτή η τιμή είναι μεγαλύτερη του μηδενός και έτσι ο νευρώνας ένα θα εκπέμψει ($F_1=1$). Έτσι το δίκτυο αλλάζει στην κατάσταση 110 αν F_1 είναι ο επόμενος νευρώνας που θα επιχειρήσει να εκπέμψει. (πιθανότητα $1/3$)

Παρόλα αυτά, πρέπει επίσης να σκεφτούμε τις περιπτώσεις όπου ο νευρώνας δύο ή τρία είναι ο επόμενος που θα επιχειρήσει να εκπέμψει από την τωρινή κατάσταση 010. Αν ο νευρώνας 2 είναι ο επόμενος, η ενεργοποίηση του είναι:

$$F_1 W_{12} + F_3 W_{23} - T_2 = (0 * 0.2) + (0 * 0.6) - 0 = 0$$

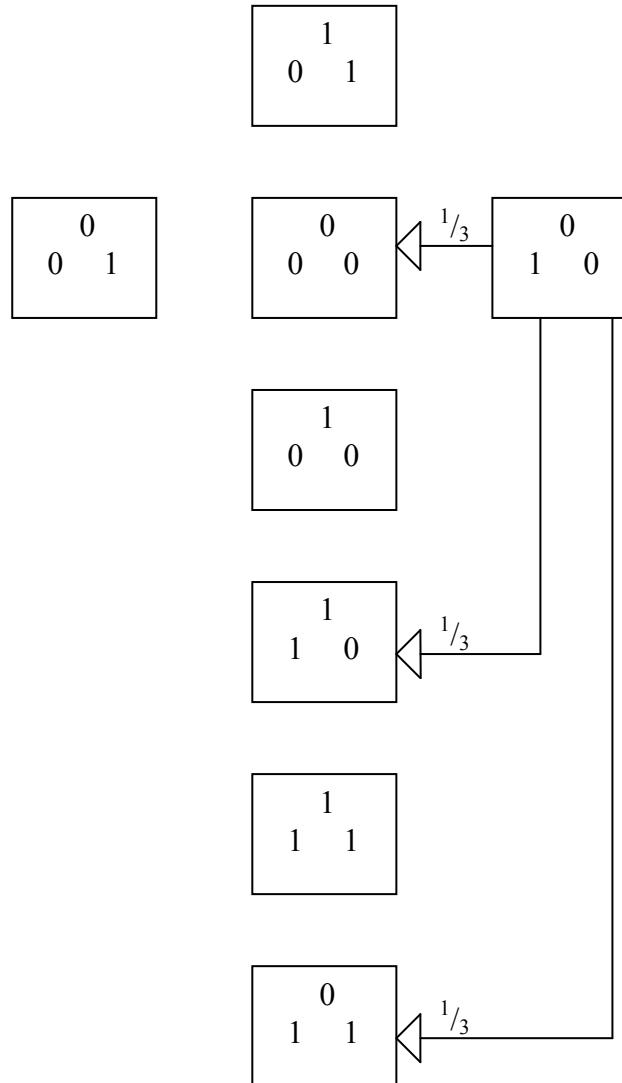
Η ενεργοποίηση είναι ίση με το μηδέν και έτσι $F_2=0$. Άρα η επόμενη κατάσταση από 010 είναι 000, αν το F_2 επιχειρήσει να εκπέμψει, πάλι με πιθανότητα $\frac{1}{3}$.

Αν ο νευρώνας τρία είναι ο επόμενος που θα επιχειρήσει να εκπέμψει, η ενεργοποίηση του θα είναι:

$$F_1 W_{31} + F_2 W_{32} - T_3 = (0 * (-0.5)) + (1 * 0.6) - 0 = 0.6$$

Η ενεργοποίηση είναι μεγαλύτερη από το μηδέν και έτσι $F_3=1$. Έτσι η επόμενη κατάσταση από 010 είναι 011, αν το F_3 επιχειρήσει να εκπέμψει, πάλι με πιθανότητα $\frac{1}{3}$.

Ένα διάγραμμα που δείχνει όλες τις πιθανές καταστάσεις και μεταβάσεις δίνεται παρακάτω.



1.1.2. Παράδειγμα εκμάθησης

Συμπληρώστε το διάγραμμα μετάβασης κατάστασης δικτύων Hopfield που δίνεται παραπάνω.

1.2. Ανάλυση του δικτύου Hopfield: Υπολογιστική ενέργεια

Για το παράδειγμα που δόθηκε παραπάνω, είδαμε ότι το δίκτυο τελικά σταθεροποιείτε στην τελευταία κατάσταση 011. Ένα ιδιαίτερο χαρακτηριστικό των δικτύων Hopfield είναι ότι έχουν τελική κατάσταση η οποία είναι σταθερή, πχ η πιθανότητα του δικτύου να παραμείνει σε αυτήν την κατάσταση είναι 1(οριστικό).

Είναι χρήσιμο να συσχετίζει μια ποσότητα με κάθε κατάσταση στο δίκτυο, η οποία ελαττώνεται (ή παραμένει ίδια) κάθε φορά που ένας νευρώνας αλλάζει την κατάσταση του. Αυτή η ποσότητα ονομάζεται υπολογιστική ενέργεια και της έχει δοθεί το σύμβολο E. Έτσι κάθε μετάβαση στο διάγραμμα της κατάστασης έχει την επίδραση να ελαττώνει το E ή να το αφήνει ίδιο. Κάθε μετάβαση της κατάστασης περιλαμβάνει μόνο ένα νευρώνα που αλλάζει κατάσταση, εξαιτίας της ασυγχρόνιστης λειτουργίας του δικτύου. Έτσι η αλλαγή της ενέργειας, ΔE, εξαιτίας μιας αλλαγής στην κατάσταση της εξόδου F_i του νευρώνα i, πρέπει να είναι αρνητική ή μηδενική. Ο νευρώνας i αλλάζει κατάσταση κάτω από μια ή δύο συνθήκες:

1. $F_i=0$ προτού η μετάβαση και η ενεργοποίηση είναι θετική. Σε αυτή την περίπτωση η F_i αλλάζει σε 1 και η αλλαγή στο F_i ορίζεται ως ΔF_i και είναι +1.
2. $F_i=1$ προτού η μετάβαση και η ενεργοποίηση είναι αρνητική. Σε αυτή την περίπτωση η F_i αλλάζει σε 0 και η $\Delta F_i=-1$.

Θέλουμε αυτή η αλλαγή στην κατάσταση να αντιστοιχεί σε μια αρνητική αξία του ΔE, έτσι ώστε η μετάβαση να έχει την επίδραση της μείωσης της συνολικής ενέργειας E. Αυτό μπορεί να επιτευχθεί ορίζοντας το ΔE ως:

$$\Delta E = -\Delta F_i * \text{activation} = -\Delta F_i (\sum W_{ij} F_j - T_i)$$

Χρησιμοποιώντας αυτό τον ορισμό το ΔE διασφαλίζει ότι κάθε αλλαγή στην κατάσταση αντιστοιχεί σε μια αρνητική (ή μηδενική) αξία του ΔE, μειώνοντας έτσι την ενέργεια του δικτύου.

Είναι σωστό λοιπόν να ορίσουμε την ενέργεια του νευρώνα i ως:

$$E_i = -F_i(\sum W_{ij}F_j - T_i) = -\sum W_{ij}F_jF_i + F_iT_i$$

Η ολική ενέργεια E του δικτύου σχετίζεται με το άθροισμα της ενέργειας όλων των νευρώνων. Ο Hopfield όρισε το E ως:

$$E = -\frac{1}{2}\sum \sum W_{ij}F_jF_i + \sum F_iT_i$$

Ο μισός όρος συμπεριλαμβάνεται για να δικαιολογήσει το γεγονός ότι μερικοί όροι συναντώνται δύο φορές όταν παίρνουμε συνολικά αθροίσματα. (θυμηθείτε ότι $W_{ij}=W_{ji}$).

Έτσι μπορούμε να δούμε ότι το δίκτυο Hopfield ρυθμίζεται σε μια σταθερή κατάσταση και κάθε μετάβαση κατάστασης ελαττώνει την ενέργεια (ή πηγαίνει σε μια κατάσταση με την ίδια ενέργεια).

Το δίκτυο Hopfield είναι χρήσιμο σε πρακτικές εφαρμογές, εφόσον παρέχει ένα μέσο βελτιστοποίησης. Για ένα δεδομένο πρόβλημα, αν μια έκφραση για το E μπορεί να οριστεί έτσι ώστε ένα ελάχιστο του E να αντιστοιχεί σε μια καλή λύση για το πρόβλημα, τότε το δίκτυο Hopfield μπορεί να χρησιμοποιηθεί για να ελαχιστοποιήσει το E και να βρει αυτή την καλή λύση. Ένα παράδειγμα της χρήσεις του δικτύου Hopfield για συμπίεση ψηφιακών εικόνων θα συζητηθεί αργότερα.

1.2.1. Παράδειγμα

Γυρνώντας στο παράδειγμα της σελίδας 8 μπορούμε τώρα να υπολογίσουμε την ενέργεια E του δικτύου για κάθε μια από της οχτώ καταστάσεις με χαμηλότερη ή την ίδια ενέργεια. Εφόσον το δίκτυο έχει τρείς νευρώνες, μπορούμε να καθορίσουμε τα όρια στα αθροίσματα από το 1 έως το 3. πχ

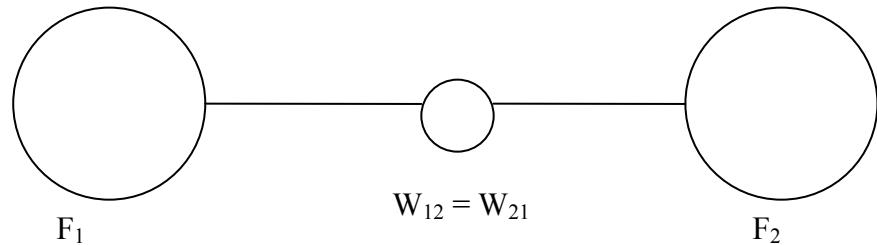
$$E = -\frac{1}{2}\sum_{i=1}^3 \sum_{j=1}^3 W_{ij}F_jF_i + \sum_{i=1}^3 F_iT_i$$

Η ενέργεια για την κατάσταση 101 φαίνεται ότι είναι:

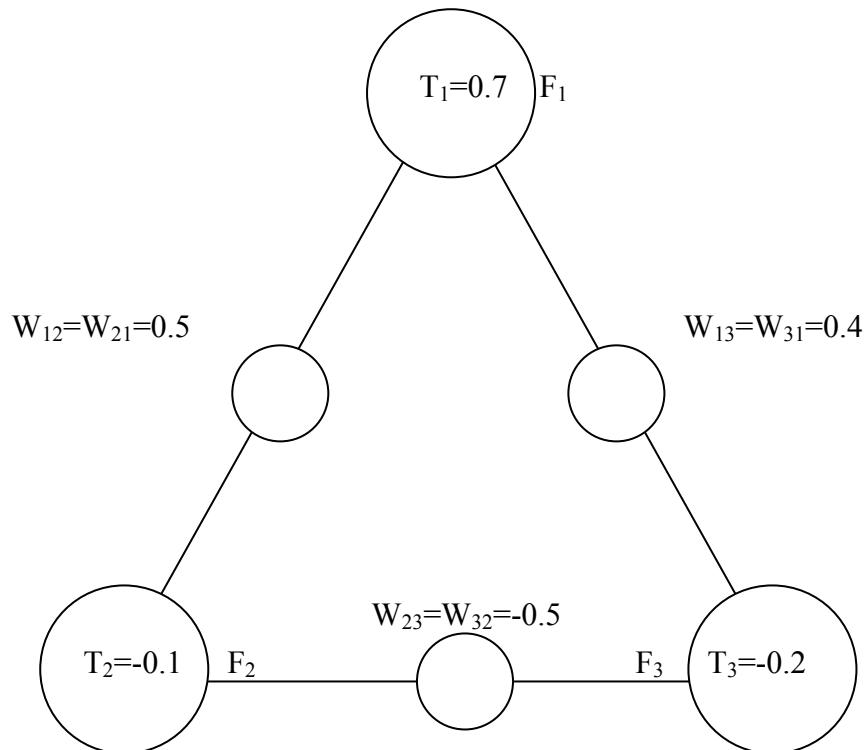
$$E_{101} =$$

1.2.2. Παράδειγμα εκμάθησης

- Συμπληρώστε το παραπάνω διάγραμμα υπολογίζοντας την υπολογισμένη ενέργεια που συσχετίζεται με κάθε μια από τις 8 καταστάσεις.
- Το δίκτυο Hopfield δύο νευρώνων που φαίνεται παρακάτω έχει βάρη $W_{12}=W_{21}=0.4$. Το κατώφλι για το νευρώνα 1 είναι $T_1=0$ και για το νευρώνα $T_2=-0.2$. Σχεδιάστε το διάγραμμα μετάβασης κατάστασης και υπολογίστε την υπολογισμένη ενέργεια για κάθε μια από τις τέσσερις καταστάσεις.

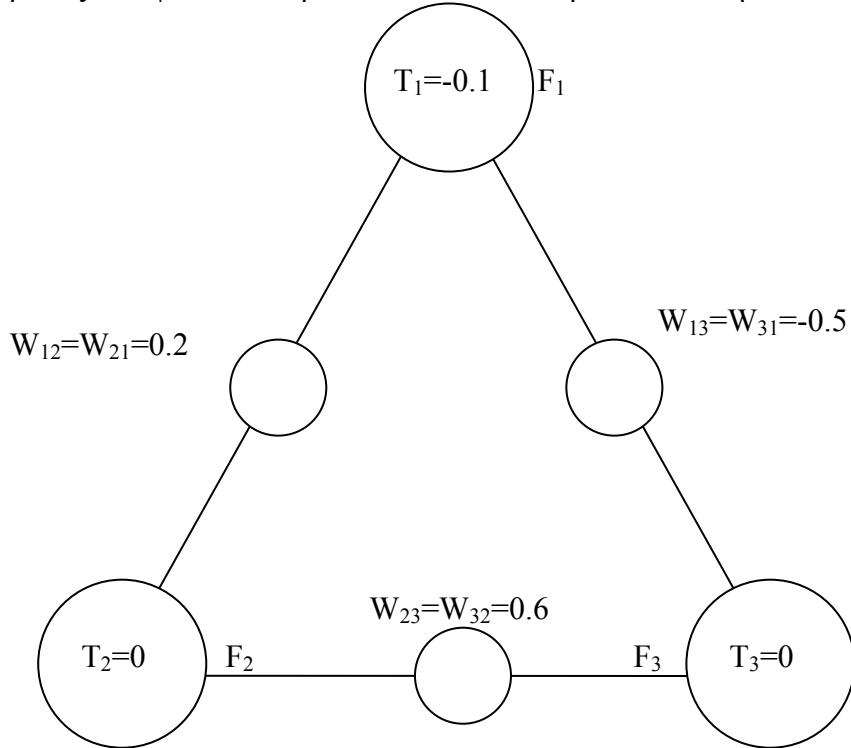


- Σχεδιάστε το διάγραμμα μετάβασης κατάστασης και υπολογίστε την ενέργεια για κάθε κατάσταση για το δίκτυο Hopfield τριών νευρώνων που φαίνεται παρακάτω.



1.3. Δίκτυα Hopfield και σταθερές καταστάσεις

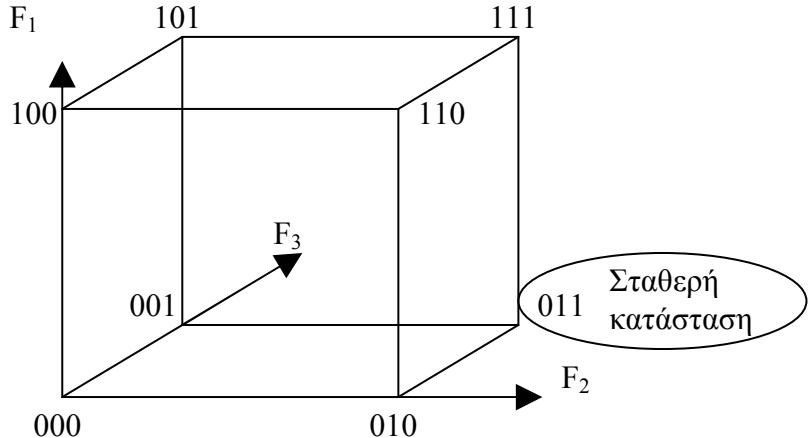
Για το παράδειγμα που είδαμε νωρίτερα (σελ 8), φάνηκε ότι το δίκτυο Hopfield με τρείς νευρώνες που φαίνεται παρακάτω πάντα σταθεροποιείτε στην κατάσταση 011.



Μπορούμε έτσι να δούμε ότι για το συγκεκριμένο δίκτυο, η τελική κατάσταση (αφού οι επαναλήψεις έχουν οδηγήσει σε μια σταθερή κατάσταση) έχει μια πιθανότητα 100% να είναι 011, άσχετα από την αρχική κατάσταση. Ο πίνακας παρακάτω δείχνει την πιθανότητα όλων των πιθανών τελικών καταστάσεων για κάθε πιθανή αρχική κατάσταση.

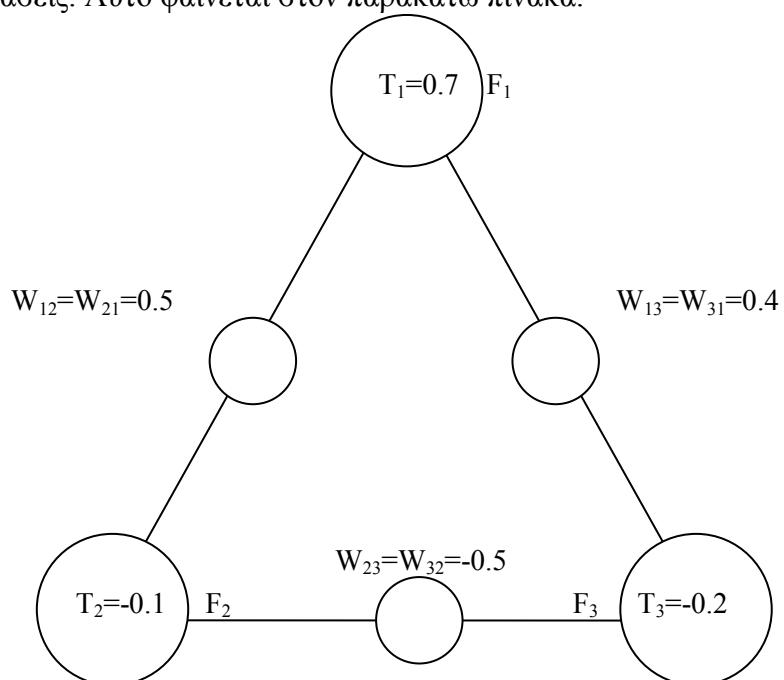
Αρχηγή κατάσταση			Τελική κατάσταση			% Prob.
F1	F2	F3	F1	F2	F3	
0	0	0	0	1	1	100
0	0	1	0	1	1	100
0	1	0	0	1	1	100
0	1	1	0	1	1	100
1	0	0	0	1	1	100
1	0	1	0	1	1	100
1	1	0	0	1	1	100
1	1	1	0	1	1	100

Κάθε μετάβαση του δικτύου έχει σαν αποτέλεσμα να αλλάζει μόνο μια έξοδο του νευρώνα. Όπως με το νευρώνα MCP, μπορούμε να δούμε όλες τις πιθανές καταστάσεις του δικτύου σαν γωνίες ενός κύβου στον τρισδιάστατο χώρο της εισόδου. Προσέξτε τώρα ότι οι είσοδοι σε ένα νευρώνα είναι οι έξοδοι των άλλων νευρώνων, έτσι ο χώρος μπορεί σωστά να οριστεί ως «ο χώρος εξόδου» ή «ο χώρος της κατάστασης». Κάθε διάσταση του κύβου αντιπροσωπεύει μια από της καταστάσεις σύμφωνα με της τιμές των F_1 , F_2 και F_3 .



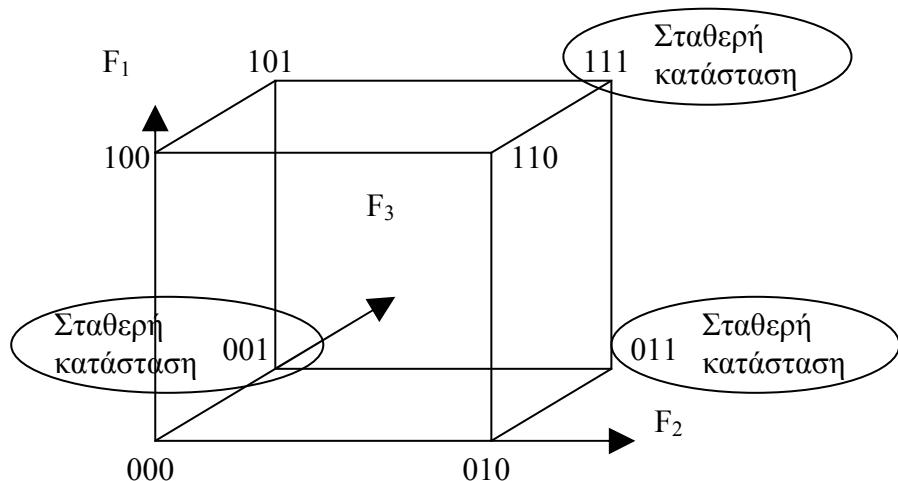
Κάθε μετάβαση κατάστασης αντιστοιχεί με την μετακίνηση από την τωρινή γωνία σε μια από τις τρείς πιθανές συνεχόμενες γωνίες, εφόσον μόνο ένας από τους νευρώνες αλλάζει κατάσταση κάθε στιγμή (ασύγχρονη λειτουργία). Εφόσον για αυτό το παράδειγμα υπάρχει μόνο μια σταθερή κατάσταση, το δίκτυο πρέπει τελικά να φτάσει σε αυτή την κατάσταση. Τα μονοπάτια μπορούν να σχεδιαστούν στο παραπάνω διάγραμμα με αναφορά στα διαγράμματα μετάβασης της κατάστασης στη σελίδα 4.

Παρόλα αυτά, το δίκτυο τριών νευρώνων όπως φαίνεται παρακάτω (παράδειγμα 1.2.2 σελίδα 12) έχει πάνω από μια σταθερή κατάσταση και έτσι η πιθανότητα να φτάσει μια συγκεκριμένη τελική κατάσταση είναι λιγότερο από 100% για κάποιες αρχικές καταστάσεις. Αυτό φαίνεται στον παρακάτω πίνακα.



Αρχηκή κατάσταση			Τελική κατάσταση			% Prob.
F1	F2	F3	F1	F2	F3	
0	0	0				
0	0	1				
0	1	0				
0	1	1				
1	0	0				
1	0	1				
1	1	0				
1	1	1				

Το αντίστοιχο διάγραμμα χώρου της κατάστασης μπορεί να σχεδιαστεί:



1.4. Σχεδιάζοντας σταθερές καταστάσεις σε ένα δίκτυο Hopfield

Είναι χρήσιμο να μπορούμε να σχεδιάσουμε ένα δίκτυο Hopfield (να υπολογίσουμε τις σωστές τιμές για τα βάρη και τα κατώφλια) έτσι ώστε να υπάρχουν προκαθορισμένες σταθερές καταστάσεις. Όπως είδαμε νωρίτερα, αυτές οι σταθερές καταστάσεις αντιστοιχούν σε τοπικά ελάχιστα της υπολογιστικής ενέργειας και για αυτό αναφέρονται συχνά ως ενεργειακά επίπεδα.

Ως παράδειγμα, θα θεωρήσουμε το σχέδιο του δικτύου Hopfield τριών νευρώνων με δύο πιθανές σταθερές καταστάσεις, επιλέγοντας ως 001 και 111. Το δίκτυο θα πρέπει να μπορεί να φτάσει σε μια από αυτές τις καταστάσεις από οποιαδήποτε αρχική κατάσταση.

Πρέπει να εξετάσουμε κάθε νευρώνα για κάθε σταθερή κατάσταση και να βεβαιωθούμε ότι δεν αλλάζει την κατάσταση του – αυτό θα βεβαιώσει ότι οι απαιτούμενες καταστάσεις είναι σταθερές.

Κατάσταση 001

Η F_1 δεν πρέπει να εκπέμπει άρα

$$W_{12}F_2 + W_{13}F_3 - T_1 \leq 0$$

αλλά για την κατάσταση 001, $F_2=0$ και $F_3=1$ και έτσι μπορούμε να γράψουμε:

$$W_{13} - T_1 \leq 0 \quad (\text{ανισότητα } 1^{\text{η}})$$

Η F_2 δεν πρέπει να εκπέμπει, οδηγώντας σε

$$W_{23} - T_2 \leq 0 \quad (\text{ανισότητα } 2^{\text{η}})$$

Η F_3 δεν πρέπει να εκπέμπει, οδηγώντας σε

$$-T_3 > 0$$

ή αντίστοιχα

$$T_3 < 0 \quad (\text{ανισότητα } 3^{\text{η}})$$

Για να είναι σταθερή η κατάσταση 001, όπως απαιτείτε, οι τρείς ανισότητες παραπάνω πρέπει να ικανοποιούνται.

Κατάσταση 111

Η F_1 πρέπει να εκπέμπει:

(ανισότητα 4°)

Η F_2 πρέπει να εκπέμπει:

(ανισότητα 5°)

Η F_3 πρέπει να εκπέμπει:

(ανισότητα 6°)

Αν σιγουρέψουμε ότι και οι έξι ανισότητες ικανοποιηθούν, τότε οι καταστάσεις 001 και 111 θα είναι σταθερές όπως απαιτείται.

Γενικά, για ένα δίκτυο με N νευρώνες και M απαιτούμενες σταθερές καταστάσεις, υπάρχουν ανισότητες που πρέπει να ικανοποιηθούν.

Ικανοποιώντας της ανισότητες:

Προφανώς υπάρχουν πολλές πιθανές τιμές για τα βάρη και τα κατώφλια οι οποίες θα ικανοποιήσουν της παραπάνω έξι ανισότητες. Αρχικά θα εξετάσουμε μια συγκεκριμένη ομάδα τιμών. Θα επιχειρήσουμε να βρούμε μια ομάδα τιμών τέτοια ώστε όλα τα βάρη και τα κατώφλια να βρίσκονται μεταξύ -1 και +1.

Ας πούμε ότι $W_{13}=0.5$ άρα

$W_{13}=W_{31}=0.5$

Η ανισότητα 1 μπορεί τώρα να χρησιμοποιηθεί για να δώσει μια κλίμακα για το T_1 . Μπορούμε να δούμε ότι το T_1 πρέπει να βρίσκεται μεταξύ 0.5 και 1, έτσι θα ορίσουμε ότι το T_1 είναι για παράδειγμα 0.7.

$T_1=0.7$

Η ανισότητα 4 δίνει μια κλίμακα για το W_{12} η οποία πρέπει να βρίσκεται μεταξύ $W_{12}=W_{21}=$

Η ανισότητα 3 δίνει το T_3

$T_3=$

Η ανισότητα 6 δίνει το W_{32}

$W_{32}=W_{23}=$

Οι ανισότητες 2 και 5 μαζί δείχνουν ότι το T_2 πρέπει να είναι στην κλίμακα

$T_2=$

Ελέγξτε και τις έξι ανισότητες να βεβαιωθείτε ότι όλες οι απαραίτητες συνθήκες έχουν ικανοποιηθεί.

Ανισότητα 1^η:

Ανισότητα 2^η:

Ανισότητα 3^η:

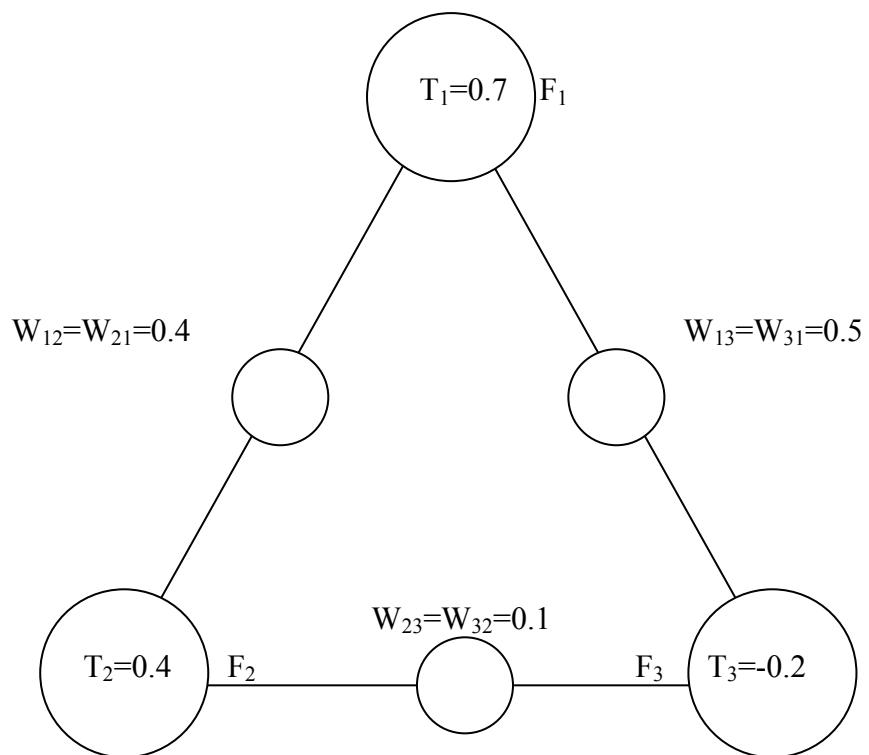
Ανισότητα 4^η:

Ανισότητα 5^η:

Ανισότητα 6^η:

Έτσι μπορεί να φανεί ότι τα βάρη και τα κατώφλια ικανοποιούν και τις έξι ανισότητες.

Ένα διάγραμμα μπορεί να σχεδιαστεί δίνοντας τα βάρη του δικτύου και τα κατώφλια.



Η ενέργεια για κάθε κατάσταση και το διάγραμμα μετάβασης κατάστασης σχεδιασμένο για αυτό το δίκτυο μπορεί να βρεθεί.

$$\begin{array}{cc} 1 & \\ 0 & 0 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 1 & \\ 1 & 0 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 0 & \\ 1 & 0 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 0 & \\ 1 & 1 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 0 & \\ 0 & 0 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 1 & \\ 0 & 1 \\ \text{E =} & \end{array}$$

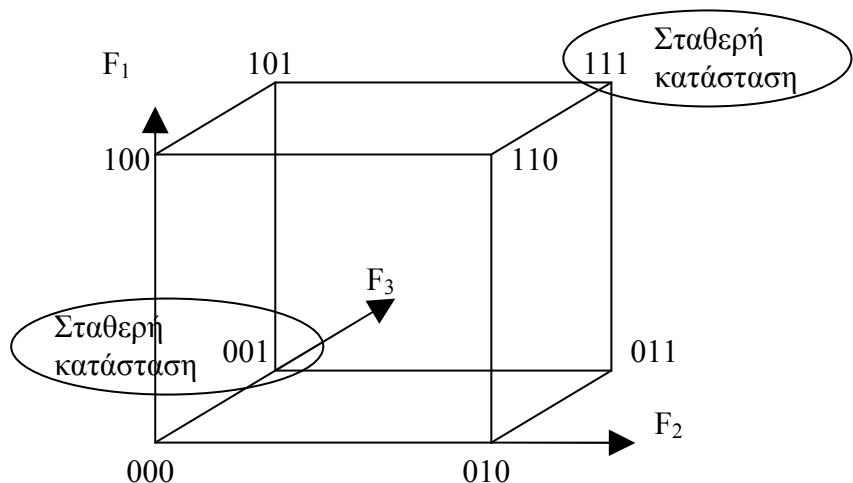
$$\begin{array}{cc} 1 & \\ 1 & 1 \\ \text{E =} & \end{array}$$

$$\begin{array}{cc} 0 & \\ 0 & 1 \\ \text{E =} & \end{array}$$

Μπορούμε να δούμε ότι οι δύο σταθερές καταστάσεις υπάρχουν όπως απαιτείτε.

Το διάγραμμα κατάστασης χώρου και ο πίνακας τελικής κατάστασης μπορούν να συμπληρωθούν παρακάτω για να δείξουν τη λειτουργία αυτού του δικτύου.

Αρχηγή κατάσταση	Τελική κατάσταση			% Prob.			
	F1	F2	F3	F1	F2	F3	
0	0	0					
0	0	1					
0	1	0					
0	1	1					
1	0	0					
1	0	1					
1	1	0					
1	1	1					



Εναλλακτική λύση για τις ανισότητες

Μια διαφορετική ομάδα από βάρη και κατώφλια η οποία ικανοποιεί της ίδιες έξη ανισότητες παραθέτεται παρακάτω:

$$W_{12}=W_{21}=0.5$$

$$W_{13}=W_{31}=0.4$$

$$W_{23}=W_{32}=-0.5$$

$$T_1=0.7$$

$$T_2=-0.1$$

$$T_3=-0.2$$

Μπορούμε να δούμε ότι αυτές οι τιμές ικανοποιούν τις ανισότητες, ελέγχοντας και τις έξι:

Ανισότητα 1^η:

Ανισότητα 2^η:

Ανισότητα 3^η:

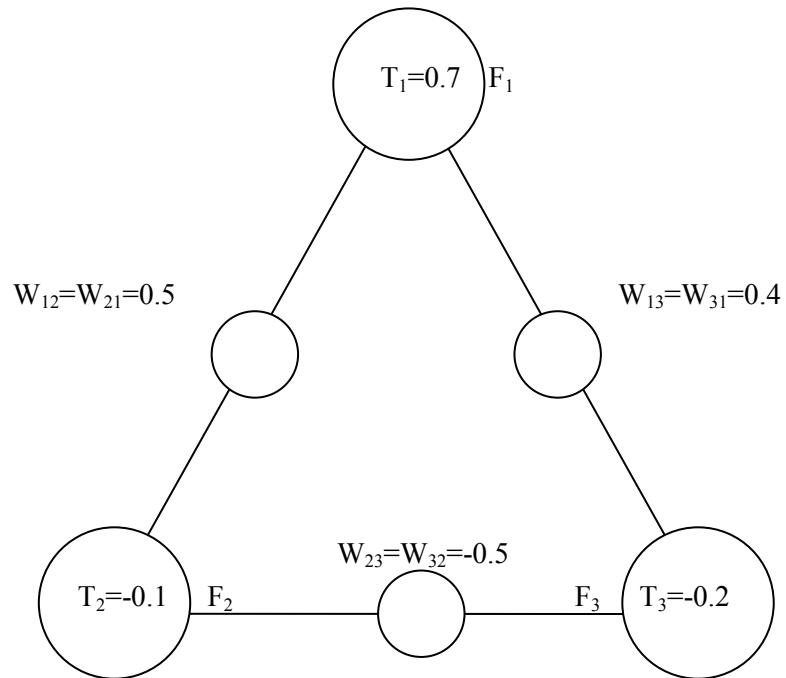
Ανισότητα 4^η:

Ανισότητα 5^η:

Ανισότητα 6^η:

Έτσι φαίνεται ότι τα βάρη και τα κατώφλια ξανά ικανοποιούν και τις έξι ανισότητες.

Ωστόσο, αυτά τα κατώφλια και τα βάρη τα πήραμε από το δίκτυο σελίδα 12 το οποίο έχει μια τρίτη σταθερή κατάσταση, η οποία δεν διευκρινίζεται στο σχέδιο. Το δίκτυο και το διάγραμμα μετάβασης της κατάστασης δίνονται παρακάτω.



$$E = \begin{bmatrix} 1 & & \\ 0 & 0 & \\ & & \end{bmatrix}$$

$$E = \begin{bmatrix} 0 & \\ 1 & 1 \end{bmatrix}$$

$$E = \begin{bmatrix} 1 & \\ 0 & 1 \end{bmatrix}$$

$$E = \begin{bmatrix} 1 & \\ 1 & 0 \end{bmatrix}$$

$$E = \begin{bmatrix} 0 & \\ 0 & 0 \end{bmatrix}$$

$$E = \begin{bmatrix} 1 & \\ 1 & 1 \end{bmatrix}$$

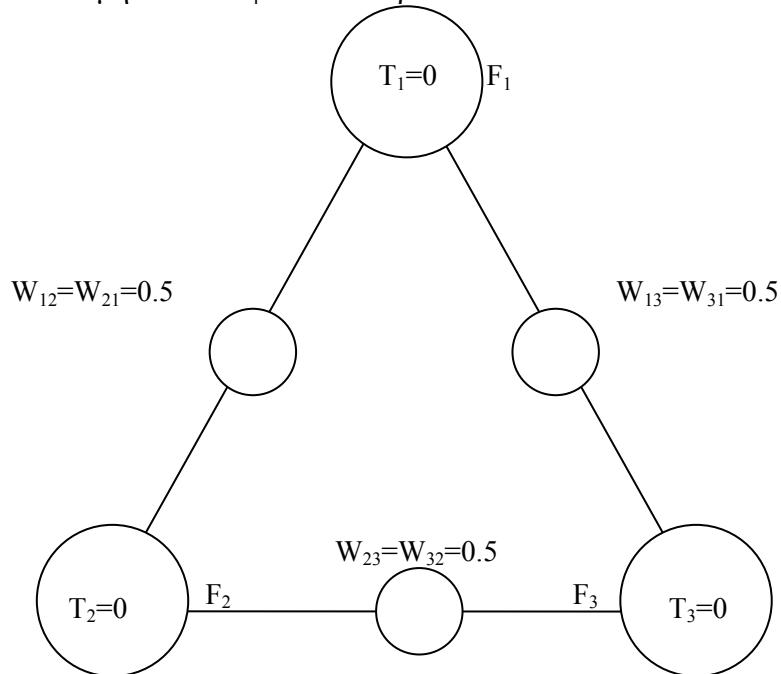
$$E = \begin{bmatrix} 0 & \\ 1 & 0 \end{bmatrix}$$

$$E = \begin{bmatrix} 0 & \\ 0 & 1 \end{bmatrix}$$

1.5. Εκπαιδεύοντας ένα δίκτυο Hopfield για απαιτούμενες σταθερές καταστάσεις

Σαν εναλλακτική στη μέθοδο σχεδιασμού δικτύου που περιγράψαμε παραπάνω, μπορούμε να εκπαιδεύσουμε ένα δίκτυο Hopfield να έχει τις απαιτούμενες σταθερές καταστάσεις. Αυτή η διαδικασία είναι παρόμοια με την εκπαίδευση ενός μονού MCP νευρώνα που είδαμε νωρίτερα. Όπως και πριν, η εκπαίδευση περιλαμβάνει την προσαρμογή των βαρών και κατωφλίων μέχρι το δίκτυο να λειτουργεί όπως απαιτείτε. Αυτό μπορεί να πραγματοποιηθεί χρησιμοποιώντας οποιονδήποτε από τους εκπαιδευτικούς αλγόριθμους που συζητήσαμε προηγουμένως. Οι ακόλουθες σημειώσεις καλύπτουν την χρήση του κανόνα Δέλτα (Delta Rule) όπως εφαρμόζεται στα δίκτυα Hopfield.

Ξανά θα θεωρήσουμε το παράδειγμα του δικτύου Hopfield τριών νευρώνων με δύο απετούμενες σταθερές καταστασης: 001 και 111. Μια αρχική κατανομή (δηλαδή αρχικές τιμές για τα βάρη και τα κατώφλια) του δικτύου πρέπει να διαλεχτεί – θα ορίσουμε όλα τα κατώφλια 0 και όλα τα βάρη 0.5 για αυτό το παράδειγμα. Αυτή η αρχική κατανομή δικτύου φαίνεται παρακάτω.



Η εκπαίδευση κατορθώνεται εφαρμόζοντας τον κανόνα εκπαίδευσης σε κάθε νευρώνα για κάθε μια από τις απαιτούμενες σταθερές καταστάσεις.

Θα ονομάσουμε τις σταθερές καταστάσεις A(001) και B(111) και θα εφαρμόσουμε τον κανόνα με την σειρά που δίνεται στην παρακάτω λίστα.

- Νευρώνας 1, σταθερή κατάσταση Α
- Νευρώνας 2, σταθερή κατάσταση Α
- Νευρώνας 3, σταθερή κατάσταση Α
- Νευρώνας 1, σταθερή κατάσταση Β
- Νευρώνας 2, σταθερή κατάσταση Β
- Νευρώνας 3, σταθερή κατάσταση Β

Σημειώστε ότι ο εκπαιδευτικός κανόνας μπορεί να εφαρμοστεί στους νευρώνες και στις απαιτούμενες σταθερές καταστάσεις και με άλλες σειρές – αυτή είναι μόνο μια επιλογή σειράς που χρησιμοποιείτε στο παράδειγμα παρακάτω.

Έχει βρεθεί ότι ένας νευρώνας θα εκπέμψει όταν δεν πρέπει ή δεν θα εκπέμψει όταν πρέπει και τότε μια προσαρμογή (ΔW) πρέπει να εφαρμοστεί στα κατάλληλα βάρη και κατώφλια σύμφωνα με τον κανόνα δέλτα. Τότε πρέπει να επιστρέψουμε στην πρώτη καταχώρηση στη λίστα και να συνεχίσουμε. Αν ταξινομήσουμε της επαναλήψεις με αυτόν τον τρόπο, τότε ξέρουμε ότι όλες οι απαιτήσεις έχουν ικανοποιηθεί όταν φτάνουμε στο τέλος της λίστας.

Θα επιλέξουμε έναν «ρυθμό εκμάθησης» όπου $\alpha=0.6$. Ο διορθωτικός παράγοντας ΔW_i για κάθε βάρος συνδεδεμένο με το νευρώνα i βρίσκεται χρησιμοποιώντας τη φόρμουλα:

$$\Delta W_i = \alpha \delta$$

(Σημειώστε ότι ο παράγοντας X_i παραλείπεται. Θα εφαρμόσουμε μόνο τον διορθωτικό παράγοντα σε βάρη και κατώφλια)

Έχοντας βρει το διορθωτικό παράγοντα, πρέπει να τον προσθέσουμε στα βάρη με εκπομπή εισόδου και να τον αφαιρέσουμε από τα κατώφλια του νευρώνα.

Η εκπαίδευση του δικτύου φαίνεται στα παρακάτω βήματα.



1) Κατάσταση A:001

Εδώ βλέπουμε ότι η ολική ενεργοποίηση στο νευρώνα 1 είναι 0.5 και έτσι ο νευρώνας 1 θα εκπέμψει. Ωστόσο η απαιτούμενη ενέργεια για το νευρώνα 1 δεν είναι να εκπέμψει και έτσι μερική διόρθωση είναι απαραίτητη.

$$\delta =$$

$$\Delta W_i =$$

Τέσι προσαρμόζουμε όλα τα βάρη στο νευρώνα 1 τα οποία προέρχονται από άλλους νευρώνες οι οποίοι εκπέμπουν – σε αυτή την περίπτωση αυτό σημαίνει ότι προσαρμόζουμε το W_{13} . Επίσης προσαρμόζουμε το κατώφλι T_1 . Οι νέες αξίες είναι:

$$W_{13} =$$

$$T_1 =$$

Εφόσον έχει γίνει μια διόρθωση σε αυτό το βήμα, επιστρέφουμε στην αρχή της λίστας για το επόμενο βήμα (σε αυτή την περίπτωση αυτό σημαίνει επανάληψη για το νευρώνα 1 στην κατάσταση A).



2) Κατάσταση A:001

Εδώ βλέπουμε ότι η ολική ενεργοποίηση (συμπεριλαμβανομένου του κατωφλίου) στο νευρώνα 1 είναι -0.7 και έτσι το νούμερο 1 δεν θα εκπέμψει (όπως απαιτείται). Έτσι $\delta=0$ και δεν χρειάζεται καμία διόρθωση για αυτό το βήμα.



3) Κατάσταση A:001

Εδώ βλέπουμε ότι η ολική ενεργοποίηση στο νευρώνα 2 είναι 0.5 και έτσι ο νευρώνας 2 ένας θα εκπέμψει. Αφού ο νευρώνας 2 απαιτείτε να μην εκπέμψει, χρειάζεται διόρθωση.

$$\delta =$$

$$\Delta W_2 =$$

Έτσι πρέπει να εφαρμόσουμε τον διορθωτικό παράγοντα στο W_{23} και T_2 . Οι νέες αξίες είναι:

$$W_{23} =$$

$$T_2 =$$

Αφού έχει γίνει μια διόρθωση, πάμε πίσω στην πρώτη καταχώρηση στη λίστα και συνεχίζουμε.



4) Κατάσταση A:001

Ξανά η ολική ενεργοποίηση στο νευρώνα 1 είναι -0.7 και έτσι ο νευρώνας 1 δεν θα εκπέμψει (όπως απαιτείτε). Έτσι δεν χρειάζεται καμία διόρθωση για αυτό το βήμα.

Παρόλο που αυτό το βήμα φαίνεται ότι είναι μια επανάληψη του βήματος 2, γενικά οι επιδράσεις της διορθώσεις μπορούν να αλλάξουν τα αποτελέσματα και έτσι πρέπει να επιστρέφουμε στην κορυφή της λίστας κάθε φορά που γίνεται μια διόρθωση.



5) Κατάσταση A:001



6) Κατάσταση A:001

Μπορούμε να δούμε ότι ο νευρώνας τρία δεν εκπέμπει όταν πρέπει.

$\delta =$

$\Delta W_3 =$

Κανένα βάρος δεν προσαρμόζεται (αφού οι νευρώνες 1 και 2 δεν εκπέμπουν) αλλά το κατώφλι για το νευρώνα 3 προσαρμόζεται.

$T_3 =$



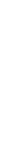
7) κατάσταση A:001



8) κατάσταση A:001



9) κατάσταση A:001



10) κατάσταση B:111

$\delta =$

$\Delta W_1 =$

Πρέπει να εφαρμόσουμε τον διορθωτικό παράγοντα στο W_{12} , W_{13} και T_1 .

Οι νέες τιμές είναι:

$W_{12} =$ $W_{13} =$ $T_1 =$



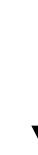
11) κατάσταση A:001

$$\delta =$$
$$\Delta W_1 =$$

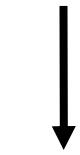
Πρέπει να εφαρμόσουμε το διορθωτικό παράγοντα στο W_{13} και T_1 .
Οι νέες τιμές είναι:



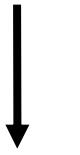
12) κατάσταση A:001



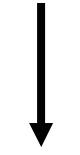
13) κατάσταση A:001



14) κατάσταση A:001



15) κατάσταση B:111

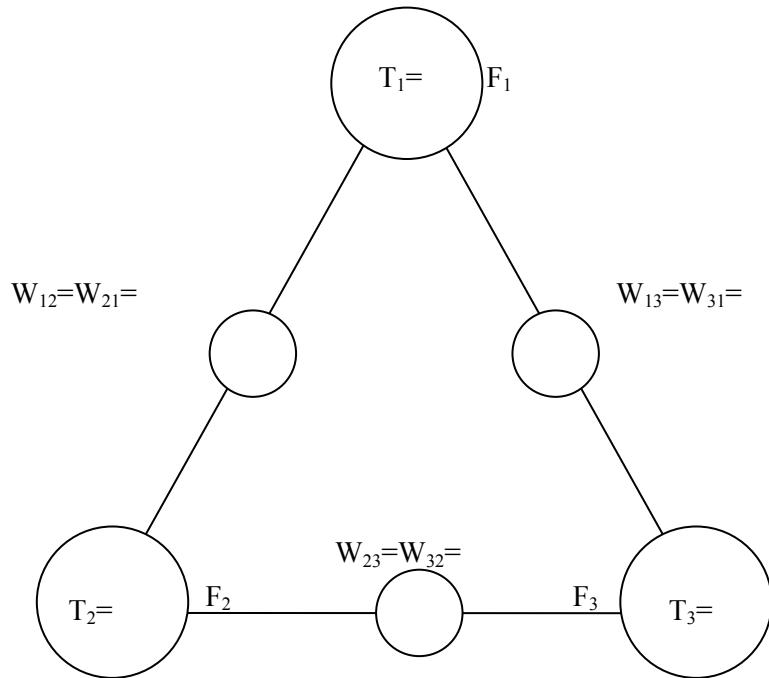


16) κατάσταση B:111



17) κατάσταση B:111

Έχουμε τώρα ολοκληρώσει την λίστα των καταστάσεων και έτσι το δίκτυο είναι εκπαιδευμένο. Η τελική κατανομή του δικτύου φαίνεται παρακάτω.



Η λειτουργία του δικτύου μπορεί να επιβεβαιωθεί ότι είναι όπως απαιτείται ερευνώντας τις μεταβάσεις της κατάστασης. Όπως συνήθως, θα φτιάξουμε το διάγραμμα μετάβασης της κατάστασης έτσι ώστε οι καταστάσεις με χαμηλή ενέργεια να εμφανίζονται ποιο χαμηλά.

$$\begin{matrix} & 0 \\ 1 & & 0 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 1 \\ 0 & & 0 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 0 \\ 1 & & 1 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 1 \\ 1 & & 0 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 1 \\ 0 & & 1 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 0 \\ 0 & & 0 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 1 \\ 1 & & 1 \\ \text{E =} & \end{matrix}$$

$$\begin{matrix} & 0 \\ 0 & & 1 \\ \text{E =} & \end{matrix}$$

Σημειώστε ότι οποιαδήποτε μέθοδος σχεδιασμού ενός δικτύου Hopfield μπορεί να παράγει και ανεπιθύμητα ενεργειακά ακρότατα σε συνδυασμό με τα απαιτούμενα ενεργειακά ακρότατα. Μερικοί συνδυασμοί απαιτούμενων σταθερών καταστάσεων είναι αδύνατον να επιτευχθούν. Όπως είδαμε και νωρίτερα μπορεί να περιλαμβάνονται στο δίκτυο και παραπάνω νευρώνες με σκοπό να ξεπεραστεί αυτό το πρόβλημα.

1.6. Μια πρακτική εφαρμογή των δικτύων Hopfield

Οι ακόλουθες σημειώσεις δείχνουν μια σύντομη εισαγωγή στη συμπίεση εικόνας καθώς και μερικές λεπτομέρειες μιας τεχνικής συμπίεσης εικόνας βασισμένης στα δίκτυα νευρώνων Hopfield.

Βασικά, ο στόχος της συμπίεσης εικόνας είναι να μειώσει το ποσό των στοιχείων (bits) που απαιτείτε για να απεικονίσουμε μια ψηφιακή εικόνα. Μια εικόνα 256 x 256 ακίδες (για παράδειγμα), με κάθε ακίδα να αντιπροσωπεύεται από 8bits (256 διαφορετικά γκρι επίπεδα) απαιτεί πάνω από 500.000 bits (64Kbyte) για να αναπαραστήσει ολοκληρωτικά την εικόνα. Είναι προφανές ότι σε ορισμένες εφαρμογές, πχ αρχειοθέτηση εικόνων, ιατρικές απεικονίσεις επεξεργασία δορυφορικών εικόνων, κλπ ο χώρος αποθήκευσης σύντομα γίνεται μη πρακτικά μεγάλος εφόσον πολλές διαφορετικές εικόνες χρειάζεται να αποθηκευτούν. Οι απαιτήσεις αποθήκευσης (πχ χώρος δισκέτας) για μια εικόνα μπορεί να μειωθούν ελαττώνοντας τον αριθμό των bits που χρειάζονται για να αναπαράγουν την εικόνα – γνωστό ως συμπίεση εικόνας.

Άλλο ένα κίνητρο για συμπίεση εικόνας είναι η αναμετάδοση. Αν μια εικόνα είναι να μεταδοθεί σε ένα κανάλι, τότε 64Kbytes στοιχείων πρέπει να αναμεταδοθούν (για το μέγεθος και την ανάλυση που συζητήθηκε από πάνω). Αυτό θα χρειαστεί συγκεκριμένο χρόνο ανάλογα με το εύρος ζώνης μετάδοσης ενός καναλιού. Ωστόσο, αν το ποσό των στοιχείων που απαιτούνται μπορεί να μειωθεί, τότε απαιτείτε λιγότερος χρόνος για το ίδιο bandwidth (ή εναλλακτικά απαιτείτε ο ίδιος χρόνος σε ένα κανάλι με μικρότερο εύρος ζώνης)

Οι τεχνικές συμπίεσης εικόνας μπορούν να ταξινομηθούν σε δύο τύπους:

1. Τεχνική με μικρές απόλυτες (διατηρούν πληροφορίες). Όπως υπονοεί και το όνομα, αυτές οι τεχνικές μπορούν να μειώσουν το ποσό των στοιχείων που απαιτείτε για να αναπαραστήσει μια εικόνα, καθώς συγκρατεί όλες τις πληροφορίες στην εικόνα. Έτσι η ανασυγκροτημένη εικόνα είναι ένα ακριβές αντίγραφο της αυθεντικής (μη συμπιεσμένης) εικόνας και δεν εισάγονται λάθη. Αυτές οι τεχνικές είναι χρήσιμες σε εφαρμογές όπου το χάσιμο πληροφοριών είναι ανεπίτρεπτο, πχ συμπίεση ιατρικών ή νομικών εικόνων.
2. Τεχνική με απώλειες, οι οποίες επίσης μειώνουν το ποσό των στοιχείων που απαιτούνται για να αναπαραστήσουν μια εικόνα, αλλά παράγουν μια ανασυγκροτημένη εικόνα που είναι μια προσέγγιση της αυθεντικής. Έτσι έχουμε μια όχι τέλεια αναπαράσταση, η οποία μπορεί να είναι αποδεκτή σε ορισμένες εφαρμογές, πχ τηλεόραση, μεταδόσεις fax κλπ. Η διαφορά μεταξύ της αυθεντικής (μη συμπιεσμένης) εικόνας και της αναδομημένης εικόνας μπορεί να φαίνεται ως επιπρόσθετος θόρυβος (ή λάθη) και έτσι μπορεί να μετρηθεί για να φτιάξουμε ένα όριο της ποιότητας της αναπαράστασης.

Ένα συνηθισμένο μέτρο των λαθών σε μια αναδομημένη εικόνα είναι το «mean square error» (MSE)

$$\text{MSE} = \frac{1}{N} \sum_{n=0}^{N-1} (x(n) - x_r(n))^2$$

Όπου:

$x(n)$ είναι οι τιμές των ακίδων της αυθεντικής εικόνας

$x_r(n)$ είναι οι τιμές της αναδομημένης εικόνας

N είναι ο συνολικός αριθμός των ακίδων της εικόνας

1.6.1. Block Truncation Coding (BTC) Σχηματικό συμπίεσης εικόνας

Το BTC είναι ένα σχέδιο απλής συμπίεσης εικόνας το οποίο λειτουργεί με μικρούς κύβους όλης της εικόνας. Θα θεωρήσουμε ένα κομμάτι μεγέθους 4×4 ακίδων, ένα παράδειγμα του οποίου δίνεται παρακάτω.

184	180	174	163
183	181	176	163
181	177	176	162
180	176	173	162

Το BTC λειτουργεί κατηγοριοποιώντας κάθε ακίδα στον πίνακα σε μια από της δύο κατηγορίες (κατάσταση 1 ή 0) σύμφωνα με την τιμή της ακίδας. Η απλή μέθοδος κατάταξης που χρησιμοποιείτε στο αρχικό σχέδιο για την αλλαγή τιμής είναι η σύγκρισή της τιμής κατωφλίου με τον μέσο όρο όλων των κατωφλίων. Οποιαδήποτε τιμή της ακίδας είναι κάτω από το μέσο όρο κατωφλίου τοποθετείτε στην κατάσταση 0 ενώ αν είναι πάνω από την τιμή του, τοποθετείτε στη κατάσταση 1.

Στον πίνακα που φαίνεται παραπάνω, η μεσαία τιμή φαίνεται ότι είναι 174.4 και έτσι οι ακίδες ταξινομούνται όπως φαίνεται παρακάτω. Αυτή η κατάταξη του ενός bit ανά ακίδα είναι γνωστή ως bitmap.

Σε αυτή την συγκεκριμένη περίπτωση, δέκα ακίδες είναι στην κατάσταση 1 και έξι στην κατάσταση 0. Ο μέσος όρος της τιμής κάθε μιας κατάστασης υπολογίζεται και προσαρμόζεται έτσι ώστε να μπορεί να παρουσιαστεί χρησιμοποιώντας 8bits. Σε αυτό το παράδειγμα η κατάσταση 0 των ακίδων έχει μέση τιμή 166 και η κατάσταση 1 των ακίδων έχει μέσο όρο 179.

Τα συμπιεσμένα στοιχεία για των πίνακα ζωγραφικής φαίνονται παραπάνω όπως και οι μέσες τιμές των 8bit για της δύο καταστάσεις. Έτσι έχουμε μειώσει τον αριθμό των δεδομένων που είναι απαραίτητα για να παρουσιάσουν τον πίνακα, με κόστος μερικής απώλειας πληροφοριών. Το ποσό με το οποίο ο πίνακας έχει συμπιεστεί (αναφερόμενο ως συχνότητα συμπίεσης) μπορεί να βρεθεί όπως φαίνεται παρακάτω:

Για ένα πίνακα των 16 ακίδων με γκρι επίπεδα που παρουσιάζονται σε 8bits:

Μη συμπιεσμένος πίνακας απαιτεί bits

Συμπιεσμένος πίνακας απαιτεί bits

Συχνότητα συμπίεσης =

Ένας άλλος τρόπος να εκφράσεις τη συχνότητα συμπίεσης είναι η συχνότητα των bit – σε αυτή την περίπτωση ο μέσος αριθμός των bit που απαιτούνται για να απεικονίσουν μια ακίδα είναι δύο bits ανά ακίδα.

Η αναδόμηση του πίνακα είναι εφικτή με bits στη ζωγραφική με την τιμή που αντιστοιχεί στο μέσο όρο της κατάλληλης κατάστασης. Στο παραπάνω παράδειγμα αυτό θα έφτιαχνε το αναδομημένο πίνακα που φαίνεται παρακάτω.

Συγκρίνοντας το με τον αρχικό πίνακα, παρατηρούμε ότι είναι διαφορετικοί και έτσι βλέπουμε ότι έχουν γίνει λάθη στον αναδομημένο πίνακα. Αυτά τα λάθη μπορούν να μετρηθούν χρησιμοποιώντας το MSE – για αυτό το παράδειγμα το MSE είναι 15.3.

1.6.2. Δίκτυα Hopfield BTC – Σχηματικό συμπίεσης εικόνας

Μπορούμε να χρησιμοποιήσουμε ένα δίκτυο Hopfield ως εναλλακτικό τρόπο ταξινόμησης των ακίδων μέσα σε ένα πίνακα. Όπως είδαμε νωρίτερα, το δίκτυο Hopfield σταθεροποιείτε στη μικρότερη τιμή υπολογιστικής ενέργειας. Αν ορίσουμε την υπολογιστική ενέργεια έτσι ώστε το ελάχιστο να αντιστοιχεί σε μια καλή ταξινόμηση, τότε το δίκτυο θα κατατάξει καλά της ακίδες. Ο Hopfield έδειξε ότι τα βάρη W_{ij} και τα κατώφλια T_i του δικτύου μπορούν να βρεθούν χρησιμοποιώντας τη φόρμουλα:

$$W_{ij} = \frac{\theta^2 E}{\theta F_i \theta F_j}$$

$$T_i = -\frac{\theta E}{\theta F_i} \mid F_j = 0$$

Για να χρησιμοποιήσουμε το δίκτυο Hopfield για συμπίεση εικόνας, χρειαζόμαστε ένα δίκτυο που αποτελείτε από δεκαέξι νευρώνες για να κατατάξουμε ένα πίνακα 4x4 ακίδων. Κάθε νευρώνας σχετίζεται με μια συγκεκριμένη ακίδα στον πίνακα και οι αντίστοιχες έξοδοι του νευρώνα F_i (0 ή 1), όταν το δίκτυο έχει φτάσει μια σταθερή κατάσταση, δίνη την κατάσταση των ακίδων.

Ένας σωστός ορισμός της υπολογιστικής ενέργειας, που «ενθαρρύνει» παρόμοιες ακίδες να ταξινομηθούν στην ίδια κατάσταση είναι:

$$E = \sum_{i=1}^M \sum_{j=1}^M F_i F_j (x(i) - x(j))^2 + \sum_{i=1}^M \sum_{j=1}^M (1 - F_i)(1 - F_j) (x(i) - x(j))^2$$

Έτσι ελαχιστοποιώντας το E αντιστοιχεί με την τοποθέτηση των ακίδων με παρόμοιες τιμές στην ίδια κατάσταση (0 ή 1). Οι ακίδες με μεγάλες διαφορές ανάμεσα στις τιμές τους τοποθετούνται σε διαφορετικές καταστάσεις.

Τα βάρη και τα κατώφλια του δικτύου δίνονται από τους τύπους:

$$W_{ij} = -4[x(i) - x(j)]^2$$

$$T_i = -2 \sum_{j=1}^M [x(i) - x(j)]^2$$

Όπου M είναι ο αριθμός των ακίδων στον πίνακα (M=16 στα παραδείγματα που δίνονται)

1.6.3. Παράδειγμα

Ένας 4x4 πίνακας που αποσπάστηκε από μια μεγαλύτερη εικόνα φαίνεται παρακάτω (ίδιο παράδειγμα με πριν)

184	180	174	163
183	181	176	163
181	177	176	162
180	176	173	162

Χρησιμοποιώντας ένα δίκτυο Hopfield για να ταξινομήσουμε αυτές τις τιμές των 16 ακίδων όπως περιγράφεται παραπάνω, παίρνουμε:

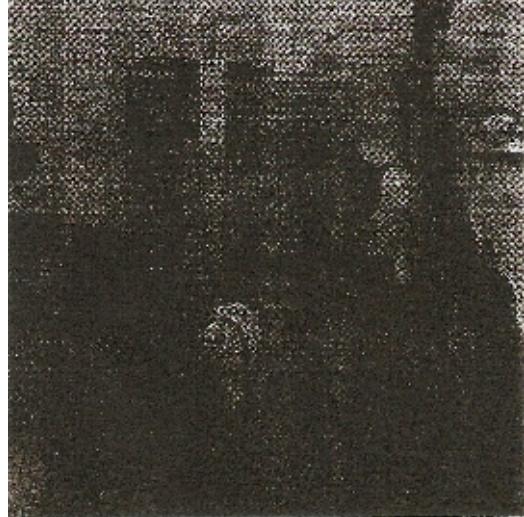
1	1	1	0
1	1	1	0
1	1	1	0
1	1	0	0

Για αυτό το παράδειγμα βρίσκουμε ότι η μετρήσιμη μέση τιμή της κατάστασης των 0 ακίδων είναι 164 και η μετρήσιμη μέση τιμή της κατάστασης των 1 ακίδων είναι 178. Ξανά ο αναμεταδιδόμενος ή αποθηκευμένος πίνακας (δηλ τα συμπιεσμένα στοιχεία) αποτελούνται από την εικόνα και της δύο μέσες τιμές για τον πίνακα των 16bits.

Όπως και πριν, η αναδόμηση του πίνακα είναι εφικτή απλώς αντικαθιστώντας κάθε bit στην εικόνα με την αντίστοιχη μέση τιμή, δίνοντας τον αναδομημένο πίνακα που φαίνεται παρακάτω.

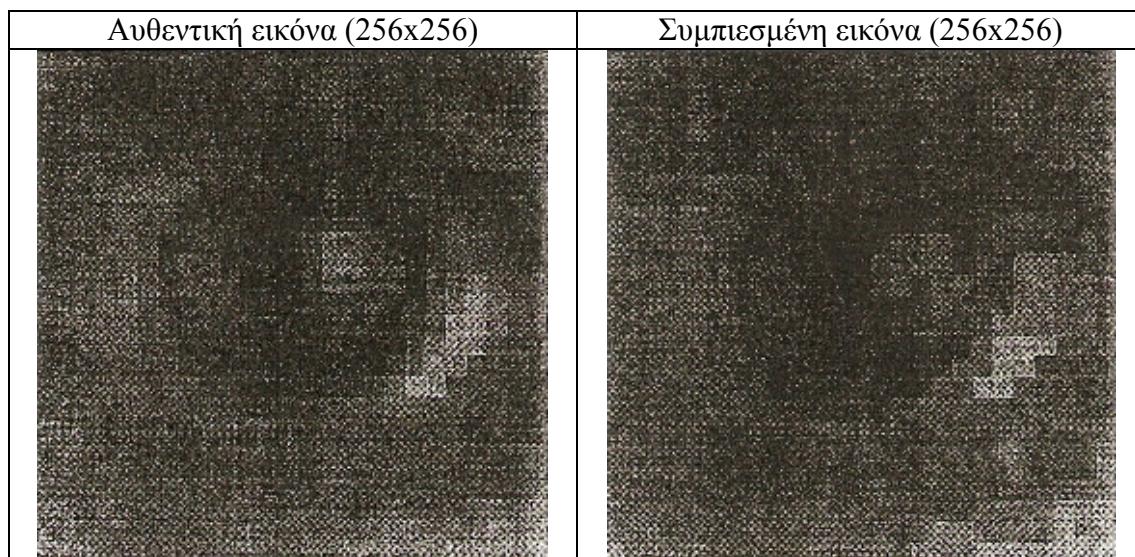
Για τον πίνακα στο παραπάνω παράδειγμα φαίνεται ότι το MSE είναι 12.9, όπως συγκρίνεται με το 15.3 της αυθεντικής μεθόδου.

Μια ολόκληρη εικόνα μπορεί να συμπιεστή στην ίδια συχνότητα συμπίεσης συμπιέζοντας κάθε 4x4 πίνακες ακίδων ανεξάρτητα. Μερικά τυπικά αποτελέσματα φαίνονται παρακάτω.

Αυθεντική εικόνα (256x256)	Συμπιεσμένη εικόνα (256x256)
	
	
	

Στα παραπάνω παραδείγματα, οι αναδομημένες εικόνες είναι παρόμοιες στην εμφάνιση με της αντίστοιχες αυθεντικές, ενώ η συμπιεσμένη εικόνα απαιτεί μόνο ένα τέταρτο του χώρου της δισκέτας για αποθήκευση.

Οι διαφορές που παρουσιάζονται από το σχήμα συμπίεσης γίνονται πιο ξεκάθαρες όταν οι εικόνες φαίνονται σε μεγαλύτερη μεγέθυνση. Για παράδειγμα ένα μικρό 25x25 κομμάτι της πρώτης εικόνας φαίνεται παρακάτω. Εφόσον οι ακίδες έχουν μεγεθυνθεί, οι διαφορές είναι πιο ξεκάθαρες.

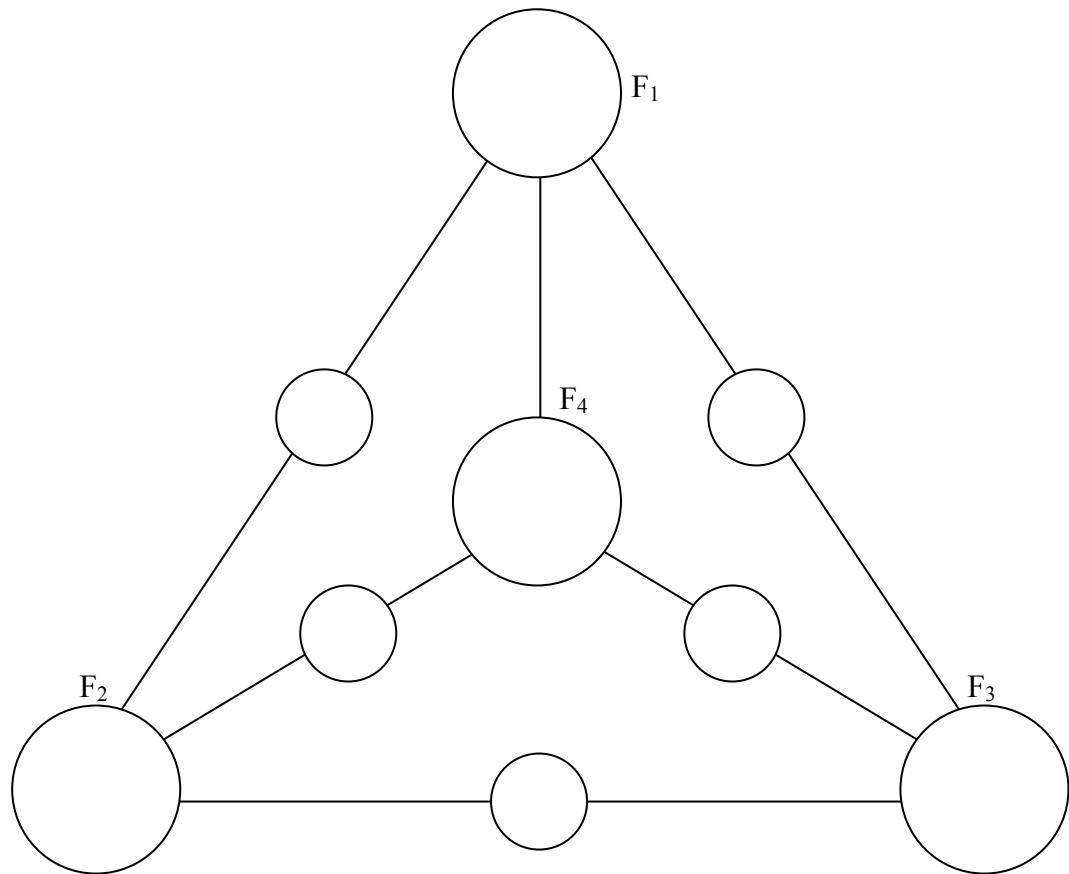


Παραλλαγές αυτής της τεχνική υπάρχουν, όπου μεγαλύτεροι πίνακες μπορούν να χρησιμοποιηθούν σε περιοχές της εικόνας που περιέχουν λίγη λεπτομέρεια. Έτσι μπορεί αρχικά να χρησιμοποιήσουμε 8x8 ακίδες, για παράδειγμα και σε περιοχές που περιέχουν μεγάλο ποσό λεπτομέρειας, θα παρουσιάσουν μεγάλα λάθη, Αυτές οι περιοχές μπορούν μετά να αποσυμπιεστούν χρησιμοποιώντας 4x4 πίνακα. Σημειώστε ότι αν το μέγεθος του πίνακα αυξηθεί, η συχνότητα συμπίεσης αυξάνεται με το κόστος ενός υψηλότερου MSE.

Για παράδειγμα, η συχνότητα συμπίεσης για ένα μόνο 8x8 πίνακα θα ήταν:

1.6.4. Παράδειγμα εκμάθησης

- 1) Ένα νευρωνικό δίκτυο Hopfield με τέσσερις νευρώνες όπως φαίνεται έχει βάρη και κατώφλια όπως ορίζονται παρακάτω.



$$W_{11}=W_{22}=W_{33}=W_{44}=0$$

$$T_1=0.70$$

$$W_{12}=W_{21}=0.7$$

$$T_2= -0.35$$

$$W_{13}=W_{31}=0.35$$

$$T_3= -0.38$$

$$W_{14}=W_{41}=1.05$$

$$T_4=0$$

$$W_{23}=W_{32}= -0.38$$

$$W_{24}=W_{42}= -1.40$$

$$W_{34}=W_{43}= -1.40$$

Κεφάλαιο 2^ο:

**Η δομή της Ανάδρασης για την
εξέλιξη των νευρωνικών δικτύων
με εγγενής συμπεριφορές μάθησης**

Η αμφίδρομη δομή για την εξέλιξη των νευρωνικών δικτύων με εγγενή συμπεριφορές μάθησης

Περίληψη. Αυτή η εργασία περιγράφει την μεταβλητή ανάδρασης: ένα μοναδικό τρόπο υλοποίησης πίνακα που επιτρέπει την εξέλιξη των νευρωνικών δικτύων με εγγενή επιβλεπόμενη μαθησιακή ικανότητα. Αυτό διευρύνει την κλίμακα των δικτύων που μπορούν να εξελιχθούν αποδοτικά συγκρινόμενα με προηγούμενες προσεγγίσεις και επίσης επιτρέπει στα δίκτυα να είναι αντιστρέψιμα, δηλαδή μόλις ένα δίκτυο έχει εξελιχθεί για έναν δεδομένο προβληματικό τομέα και έχει εκπαιδευτεί σε ένα συγκεκριμένο σετ εντολών, το δίκτυο τότε μπορεί να λειτουργήσει ανάποδα για να παρατηρήσουμε τι είδους χαρτογράφηση έχουμε μάθει ή για χρήση σε προβλήματα ελέγχου. Δίνεται μια επίδειξη του είδους των αυτό εκπαιδευόμενων δικτύων που θα μπορούσαν να εξελιχθούν.

2.1. Εισαγωγή

Παρά την εκτενή έρευνα στην εξέλιξη των νευρωνικών δικτύων, έχουν εκδοθεί σχετικά λίγα στοιχεία στην εξέλιξη των συμπεριφορών εκμάθησης για τα νευρωνικά δίκτυα. Σε αυτόν τον τομέα μπορούμε να αναγνωρίσουμε τέσσερα είδη προσέγγισης:

- Γράψτε μια ομάδα κανόνων εκμάθησης με μεταβλητές παραμέτρους για μια δεδομένη αρχιτεκτονική δικτύου και μετά την επιλογή των κανόνων και της παραμέτρους τους.
- Αναπτύξτε κάποιο αυθαίρετο είδος δικτύου και ελπίζεται ότι θα μάθει.
- Διευκρινίστε το βήμα εκμάθησης μιας αρχιτεκτονικής. Επιτρέψτε στην ανάδραση (υπεύθυνη για την μάθηση) να αναπτυχθεί με κάποιο αυθαίρετο τρόπο.
- Αναπτύξτε κάποιο αυθαίρετο είδος δικτύου, αλλά με ορισμένους ειδικούς περιορισμούς οι οποίοι να επιβάλουν ένα είδος συμπεριφοράς μάθησης να φτιαχτεί μέσα σε αυτό.

Παράδειγμα του πρώτου τύπου είναι η εργασία του Chalmers [1] και επίσης του Bengio [2], ενώ ένα παράδειγμα του δεύτερου τύπου μπορεί να βρεθεί στο [3]. Ο συγγραφέας έχει δουλέψει τον τρίτο τύπο [4], ενώ αυτή η εργασία εισάγει την έννοια μιας ομάδας μεταβλητών για να διευκολύνει τον τέταρτο τύπο.

2.2. Υπόβαθρο

Υπάρχουν δύο ξεχωριστές μέθοδοι κωδικοποίησης νευρωνικών δικτύων στα χρωμοσώματα: άμεση και έμμεση. Στην άμεση περίπτωση, μπορούμε να δούμε μια άμεση ανταπόκριση ανάμεσα σε κάθε μέρος του χρωμοσώματος και σε κάθε μέρος του δικτύου. Η έμμεση μέθοδος είναι αυτή που δεν υπάρχει καμία τέτοια ανταπόκριση. Οι περισσότερες κωδικοποίησεις που έχουν παρουσιαστεί στην λογοτεχνία έχουν την ιδιότητα ότι τα μικρά χρωμοσώματα μπορούν να προκαλέσουν μεγάλα δίκτυα.

Οι εξελικτικές μέθοδοι έχουν χρησιμοποιηθεί εκτενέστερα σε συνδυασμό με μια άμεση κωδικοποίηση και υπάρχουν εκατοντάδες εργασίες στην λογοτεχνία που έχουν υιοθετήσει αυτή την προσέγγιση. Μερικοί έχουν χρησιμοποιήσει μια

καθορισμένη αρχιτεκτονική και ανέπτυξαν μόνο τα βάρη αυτής της αρχιτεκτονικής [3,5] , άλλοι έχουν αναπτύξει και τη δομή και τα βάρη [6,7]. Ενδιαφέρουσες νευρωνικές λύσεις έχουν αναπτυχθεί σε προβλήματα πρόβλεψης της χρονικής ακολουθίας [8,9], παίζοντας tic-tac-toe [5] και στην ανάπτυξη δυναμικών δικτύων που μαθαίνουν να εξάγουν απλές ακολουθίες [3]. Αυτή η τελευταία προσέγγιση έχει ιδιαίτερη σχέση με την δουλειά που αναφέρεται αυτό, εφόσον η συμπεριφορά μάθησης εξελίχθηκε. Ωστόσο, εξαιτίας της χρήσης άμεσης κωδικοποίησης, η συμπεριφορά μάθησης δεν μεταφέρεται σε άλλα προβλήματα διαφορετικού μεγέθους. Επιπλέον, ενώ η άμεση μέθοδος κωδικοποίησης έχει την αρετή της απλότητας κλιμακώνεται χαμηλά και έτσι αρμόζει μόνο στην ανάπτυξη σχετικά μικρών δικτύων.

Για αυτό το λόγο έχει γίνει ενδιαφέρουσα δουλειά στην έμμεση κωδικοποίηση. Μερική από την πρώιμη δουλειά σε αυτό τον τομέα καταγράφηκε από τον Kitano το 1990 [10] και από τότε έχει ακολουθηθεί από γλώσσες δικτύου ανώτερης γενιάς και γραμματικές σχεδιασμένες από τον Gruau [11,12], Boers και Kuiper [13], Muhlenbein [14,15] και Sharman et al [16]. Όλοι αυτοί ωστόσο , είτε χρησιμοποιούν το GA (βασισμένο σε αλφαριθμητικά ή γραφήματα στην περιγραφή γλώσσας νευρώνα ή χρωμοσώματος) για να αναπτύξουν ένα συνεκτικό νευρωνικό δίκτυο, ή χρησιμοποιούν το GA για να αναπτύξουν μια καλή τοπολογία (ή να αναπτύξει μια καλή τοπολογία και ένα σετ από βάρη) η οποία εκπαιδεύεται μετά από ανάδρομη διάδοση σφάλματος.

Ο Kitano [17] έχει επίσης αναπτύξει ένα μοναδικό σκελετό στον οποίο η δομή του δικτύου και τα βάρη επιτρέπετε να αναπτυχθούν και το ακολούθησε με μια πιο βιολογικά λεπτομερή προσομοίωση [18]. Ακόμα και στο [17], ωστόσο, παρά τους ισχυρισμούς ότι όλες οι λεπτομέρειες του δικτύου μπορούν να αναπτυχθούν, αυτό δεν είναι ακριβώς αλήθεια, εφόσον ο μαθησιακός αλγόριθμος είναι καθορισμένος εκ των προτέρων να είναι ανάδρομη διάδοση σφάλματος παρόλο που η τοπολογία του δικτύου και τα αρχικά βάρη είναι ανεπτυγμένα.

Σε αντίθεση με αυτό, ο συγγραφέας [19,20,4] έχει δείξει πως είναι δυνατών να αναπτύξουμε τον μαθησιακό αλγόριθμο μέσα στον ίδιο ενιαίο σκελετό στον οποίο αναπτύσσονται οι άλλες λεπτομέρειες του δικτύου. Επίσης, σχετική δουλειά άξια ενδιαφέροντος είναι το “The strongly typed genetic programming of Montana” [21], το οποίο χρησιμοποιεί για να αναπτύξει προγράμματα που λειτουργούν κατηγορηματικά στο διάνυσμα του πίνακα και στη λίστα δομής δεδομένων, όπως επίσης και ποιο απλούς τύπους στοιχείων. Μέσα σε αυτό το σκελετό αναπτύσσεται (μεταξύ άλλων) ένας αλγόριθμος αναπροσδιόρισης του ανιχνευτεί-εκτιμητή εισόδου σε φίλτρα Kalman.

Τέλος, στο θέμα της κωδικοποίησης, παρουσιάζουμε κάποια ιδανικά στα οποία τα τεχνητά χρωμοσώματα που χρησιμοποιούνται για την εξέλιξη της νευρωνικής αρχιτεκτονικής θα πρέπει να αποβλέπουν σε αυτά:

- Το νευροδομικό στοιχείο θα πρέπει να είναι ατομικό. Αυτό θα επιτρέψει στην ανάπτυξη να συνεχιστεί τοποθετώντας μαζί τους ήδη υπάρχων δομημένους πίνακες με νέους τρόπους καθώς και την παραγωγή νέων δομημένων πινάκων.
- Το νευροδομικό στοιχείο θα πρέπει να είναι αναγνώσιμο από ανθρώπους – αφού περάσουμε πολύ χρόνο αναπτύσσοντας μια νέα λύση σε ένα ενδιαφέρον πρόβλημα, θα ήταν κρίμα να μπορούμε να το εκτιμάμε μόνο στο επίπεδο ζεύξης – πίνακα.
- Το νευροδομικό στοιχείο θα πρέπει να είναι παραμετροποιημένο. Έτσι έχοντας αναπτύξει ένα νέο τύπο αρχιτεκτονικής για μια τάξη προβλήματος θα

πρέπει να μπορούμε να το αλλάξουμε παραμετρικά για να καταπιαστούμε με σχετικά με αυτό προβλήματα διαφορετικού μεγέθους.

Η μεταβλητότητα είναι μεγάλης σημασίας για το καλό μηχανικό σχέδιο. Τα συστήματα που εκθέτουν πολύπλοκη και χρήσιμη συμπεριφορά συνήθως κατορθώνουν τέτοια συμπεριφορά μέσω της αλληλεπίδρασης πιο απλών μεταβλητών. Πολλά από τα προηγούμενα έμμεσα σχέδια κωδικοποίησης νευρώνων έχουν υπαρκτή μεταβλητότητα, αλλά την έχουν κατορθώσει μόνο κατά μια περιορισμένη έννοια. Αναλογιστείτε για παράδειγμα το σχέδιο κωδικοποίησης του Kitana [10]. Αυτό είναι βασισμένο στην άνευ περιεχομένου επανεγγραφή των πινάκων. Ενώ έχει αρκετή πολυπλοκότητα στο γενότυπο, το περισσότερο από αυτό δεν συνεχίζεται στο φαινότυπο, όπου είναι και το βασικό μέρος όπου η μεταβλητότητα είναι αναγκαία. Στο σχεδιασμό χρωμοσωμάτων για την ανάπτυξη νευρωνικών δικτύων το καλύτερο μέρος για να ζητήσουμε έμπνευση είναι η μηχανική του υλικού και του λογισμικού, όπου η αποδοτική χρήση μεταβλητότητας είναι τεράστιας σημασίας. Δεν είναι αρκετό να επιτρέπουμε χρήσιμες υποδομές να επαναλαμβάνονται – πρέπει επίσης να είναι σωστά αλληλένδετες.

2.3.Η μεταβλητή Ανάδρασης

Το προτεινόμενο διάγραμμα υλοποίησης είναι με μεταβλητή ανάδρασης. Αυτό αποτελείται από δύο συγκεκριμένες συμπεριφορές: Το μπροστινό κομμάτι και το πίσω κομμάτι. Οι λεπτομέρειες για κάθε μεταβλητή ανάδρασης μπορούν να αναπτυχθούν ή μπορούν να προκαθοριστούν. Εδώ δείχνουμε πώς να τις καθορίσουμε χειροκίνητα.

Ένα σύστημα με μεταβλητή ανάδρασης θέτει σε εφαρμογή δύο συμπεριφορές ή λειτουργίες – μια προς τα εμπρός και μια προς τα πίσω συμπεριφορά επιτυγχάνεται απλώς αναβαθμίζοντας μια ομάδα κελιών με μια συγκεκριμένη σειρά. Τα μη σημειωμένα κελιά υπολογίζουν την συνάρτηση λειτουργίας και συμπεριφέρονται ως τοπική αποθήκευση. Στις εικόνες 1-5 τα κύτταρα παρουσιάζονται με άσπρους κύκλους (μπροστά) και γκρι κύκλους (πίσω).

Ένα ολοκληρωμένο σύστημα με μεταβλητή ανάδρασης προσομοιώνεται από μεταβλητές στην εμπρός λειτουργία εκτελώντας την προς τα εμπρός λειτουργία κάθε μεταβλητής με σειρά από κάτω προς τα πάνω όπως είναι σχεδιασμένο στην εικόνα 7. Παρομοίως, η προς τα πίσω μεταβλητή προσομοιώνεται εκτελώντας την προς τα πίσω λειτουργία κάθε μεταβλητής με σειρά από πάνω προς τα κάτω.

Οι μεταβλητές ανάδρασης μπορούν να σχεδιαστούν για οποιαδήποτε διαφοροποιημένη λειτουργία. Εδώ δίνουμε απλώς ένα μικρό δείγμα και ένα παράδειγμα εφαρμογής.

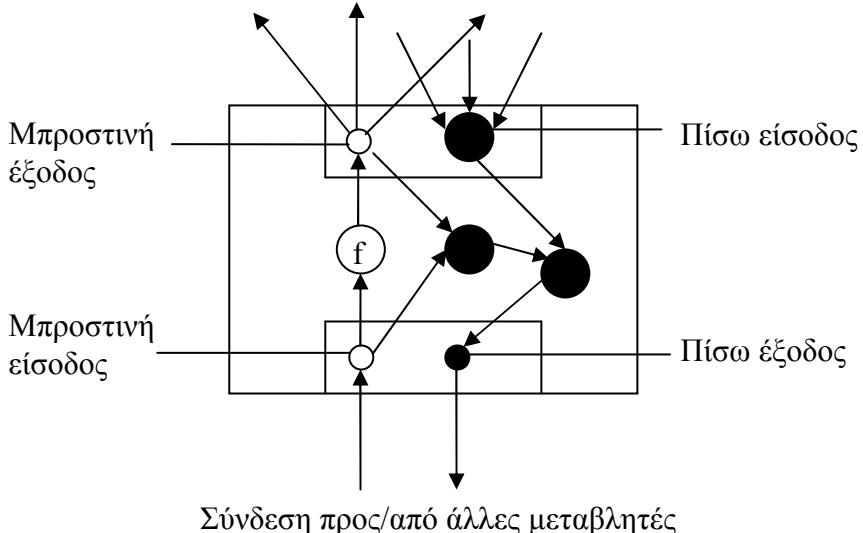
2.3.1 Ένας γενικός κόμβος ανάδρασης

Η γενική μορφή της μεταβλητής ανάδρασης απεικονίζεται στην εικόνα 1. Υπολογίζεται η λειτουργία f για την εμπρός συμπεριφορά. Για την προς τα πίσω συμπεριφορά υπολογίζει την παράγωγο f της λειτουργίας σύμφωνα με την είσοδο (ή ότι η εν μέρει παράγωγος η οποία προκύπτει από αυτή την συγκεκριμένη είσοδο), το

πολλαπλασιάζει με το συσσωρευμένο λάθος (στο \sum κελί) από την προς τα πίσω λειτουργία και το περνάει ξανά προς τα πίσω σαν έξοδο.

Σημειώστε ότι όλες οι συνδέσεις προς και από την εμπρός-πίσω μεταβλητή ομαδοποιούνται σε υποδοχές, όπου κάθε υποδοχή περιλαμβάνει δύο κελιά σύνδεσης, ένα για είσοδο και ένα για έξοδο. Η επάνω υποδοχή περιλαμβάνει την εμπρός έξοδο και την προς τα πίσω είσοδο, ενώ η χαμηλότερη υποδοχή περιλαμβάνει την εμπρός είσοδο και την προς τα πίσω έξοδο.

Σύνδεση προς/από άλλες μεταβλητές



Εικόνα 1. Ένας γενικός κόμβος ανάδρασης. Οι άσπροι κύκλοι είναι οι κόμβοι που υπολογίστηκαν κατά την διάρκεια της μπροστινής διαδικασίας, με σειρά από κάτω προς τα πάνω. Οι μαύροι κόμβοι υπολογίστηκαν στην προς τα πίσω λειτουργία σε σειρά από πάνω προς τα κάτω.

2.3.2 Ημιτονοειδείς και συνημιτονοειδείς μεταβλητές

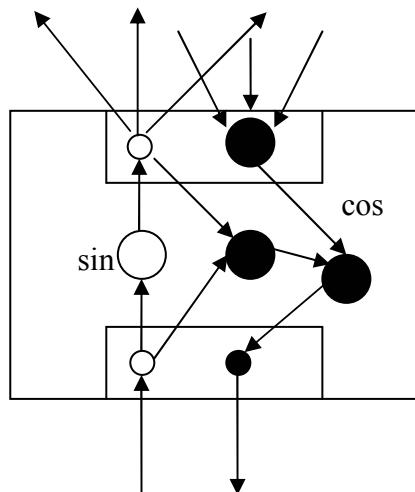
Οι ημιτονοειδείς και οι συνημιτονοειδείς μεταβλητές δεν χρησιμοποιούνται συχνά στα τεχνητά νευρωνικά δίκτυα, αν και μπορούν να παίζουν ένα χρήσιμο ρόλο για πολλές εφαρμογές. Η εικόνα 2 δείχνει την μεταβλητή ανάδρασης για την ημιτονοειδή λειτουργία. Η μεταβλητή ανάδρασης για το συνημίτονο μπορεί να γίνει ανταλλάσσοντας τους κόμβους ημίτονων με κόμβους συνημίτονων και καταργώντας την προς τα πίσω έξοδο.

Εικόνα 2. Στο μπροστινό μέρος ο κόμβος υπολογίζει το ημίτονο της μόνης της εισόδου και περνάει την έξοδο σε (πιθανών) πολλούς κόμβους. Στο πίσω μέρος, συσσωρεύεται ένα λανθασμένο σήμα από όλους τους κόμβους στους οποίους είναι συνδεδεμένη η έξοδος του, το πολλαπλασιάζει με την παράγωγο της εξόδου με βάση την μπροστινή είσοδο και το επιστρέφει στον κόμβο από τον οποίο πήρε είσοδο στο μπροστινό μέρος.

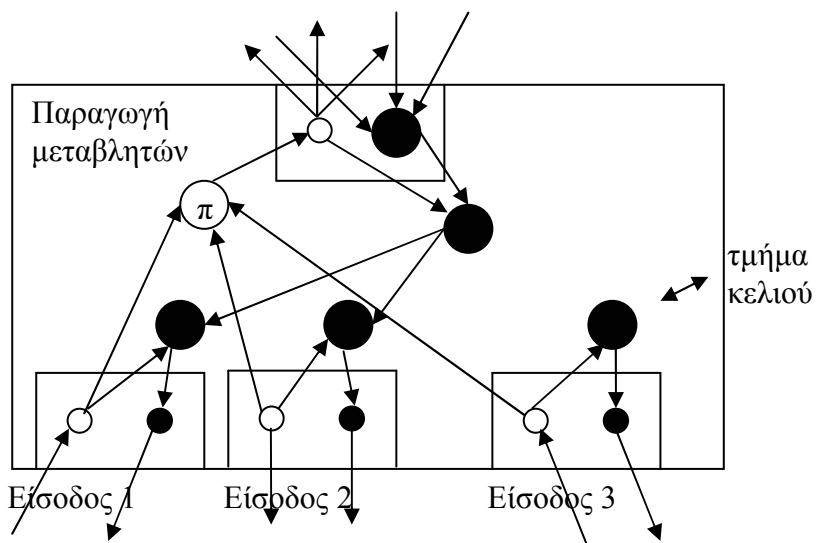
2.3.3 Παραγωγή και άθροιση μεταβλητών

Ο παραγόμενος κόμβος είναι ένα παράδειγμα ενός κόμβου ο οποίος μπορεί να πάρει πολλαπλές μπροστινές εισόδους. Εφόσον το τυμηματικό παράγωγο των λαθών του δικτύου με βάση κάθε είσοδο είναι διαφορετικό στην περίπτωση αυτού του τύπου κόμβου, τότε πρέπει και η αντίστοιχη πίσω έξοδος να είναι διαφορετική.

Ο αθροιστικός κόμβος (εικόνα 4.) επίσης παίρνει πολλαπλές εισόδους, αλλά σε αυτή την περίπτωση η πίσω είσοδος πηγαίνει απευθείας σε όλες της πίσω εξόδους.



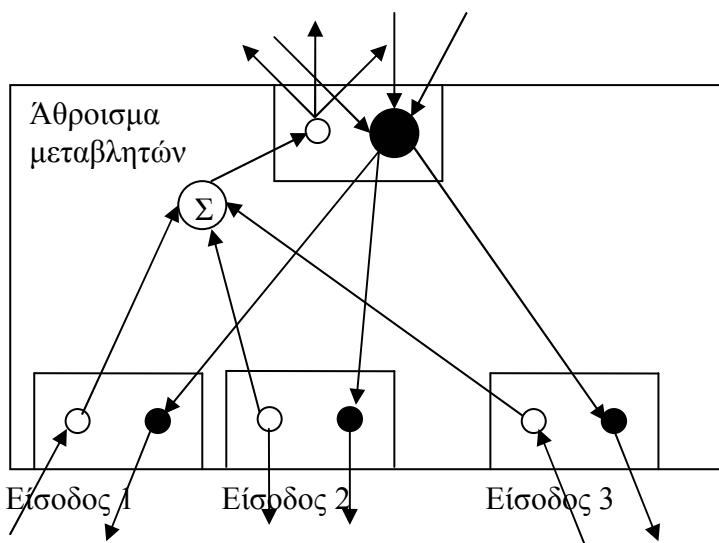
Εικόνα 2. Ένας ημιτονοειδής κόμβος ανάδρασης.



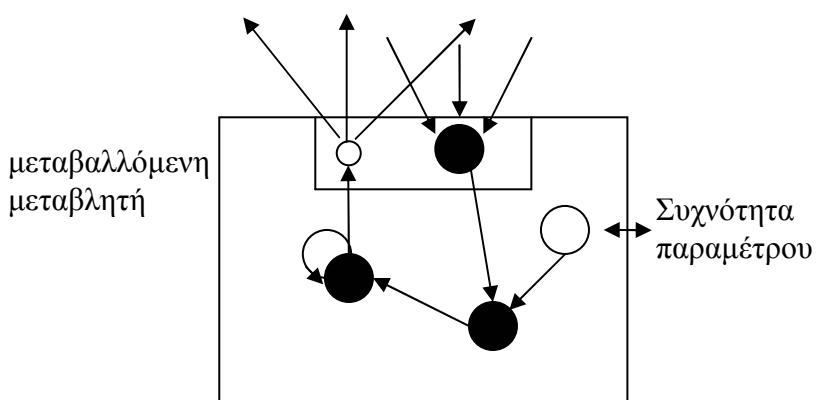
Εικόνα 3. Ένα πιο σύνθετο παράδειγμα: μια παραγωγή μεταβλητών με πολλαπλές εισόδους. Σε αυτή την περίπτωση πρέπει να επιστρέψει ένα διαφορετικό τυμηματικό παράγωγο σε κάθε είσοδο.

2.3.4 Μεταβαλλόμενες καταστάσεις

Οι μεταβαλλόμενες καταστάσεις μας παρέχουν ένα τρόπο να διπλασιάσουμε τις σημαντικές παραμέτρους μιας συγκεκριμένης νευρωνικής αρχιτεκτονικής μέσα στο ίδιο πλαίσιο των μεταβλητών ανάδρασης. Οι μεταβαλλόμενες καταστάσεις δεν κάνουν τίποτα για την μπροστινή συμπεριφορά. Η προς τα πίσω συμπεριφορά είναι για να αναβαθμιστεί το ίδιο στην αντίθετη κατεύθυνση της κλίσης του συσσωρευμένου λάθους στην προς τα πίσω είσοδο. Οι μεταβαλλόμενες καταστάσεις δεν έχουν μια μπροστινή είσοδο ή μια πίσω έξοδο. Αυτό που έχουν είναι μια παράμετρο συχνότητας η οποία χρησιμοποιείτε ως μαθησιακή συχνότητα και έχει σκοπό να αποδυναμώσει ή να ενισχύσει το επίπεδο προσαρμογής στην τιμή που είναι αποθηκευμένη στον κόμβο. Αυτό παρουσιάζεται στην εικόνα 5.



Εικόνα 4. Το άθροισμα των μεταβλητών. Σε αυτή την περίπτωση το κάθε παράγωγο επιστρέφει σε κάθε πίσω έξοδο.

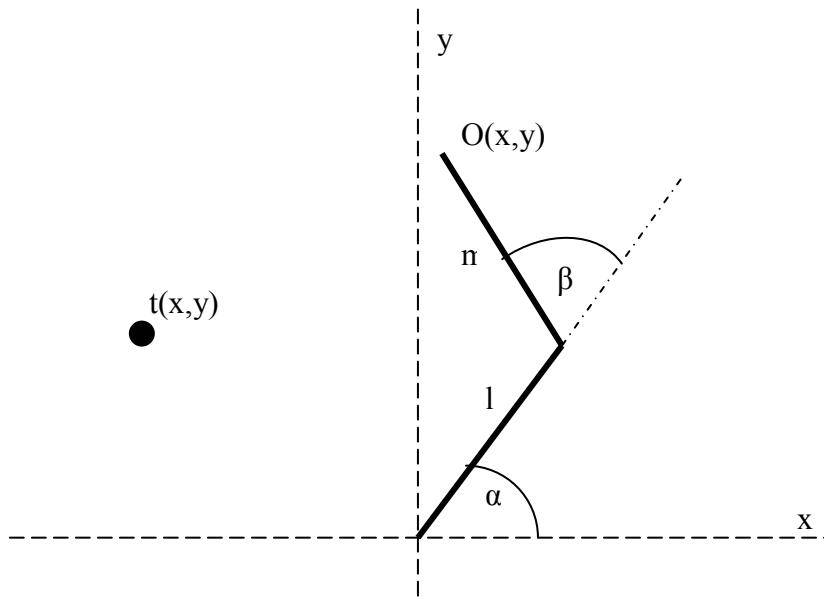


Εικόνα 5. Οι μεταβαλλόμενες καταστάσεις. Η παράμετρος συχνότητας είναι κάποια αρνητική σταθερά, η οποία θα καθοριστεί από δοκιμές ή εξέλιξη.

2.4.Παράδειγμα: Φτιάχνοντας έναν απλό ρομποτικό βραχίονα

Αυτό το παράδειγμα δείχνει τα πιθανά πλεονεκτήματα αυτής της προσέγγισης. Η εικόνα 6 δείχνει ένα απλό ρομποτικό βραχίονα με δύο κινητά τμήματα. Η άκρη του βραχίονα κινείται προσαρμόζοντας τις γωνίες α και β . Ας υποθέσουμε ότι τα μήκη l και m κάθε τμήματος έχουν οριστεί στην πραγματικότητα, αλλά είναι άγνωστα στο δίκτυο (εικόνα 7). Τότε το σύστημα μπορεί να εκπαιδεύτε όπως ακολούθως για να υπολογίσουμε τα μήκη. Για μια ομάδα εκπαιδευτικών δειγμάτων, οι γωνίες α και β είναι καθορισμένες και η θέση της άκρης στις συντεταγμένες x και y ταιριάζει με αυτές για να δημιουργήσει της εξόδους που στοχεύει για αυτές της εισόδους. Για κάθε εκπαιδευτικό δείγμα, το λάθος στην έξοδο δεδομένων των πρόσφατων εκτιμήσεων το l και m μεταδίδεται πίσω μέσο του δικτύου, με τη διαδικασία κάθε μεταβλητής που εκτελεί την προς τα πίσω δράση. Αυτή η εκπαιδευτική διαδικασία προχωράει μέχρι οι τιμές των l και m να συγκλίνουν στις πραγματικές τιμές των τμημάτων του ρομποτικού βραχίονα.

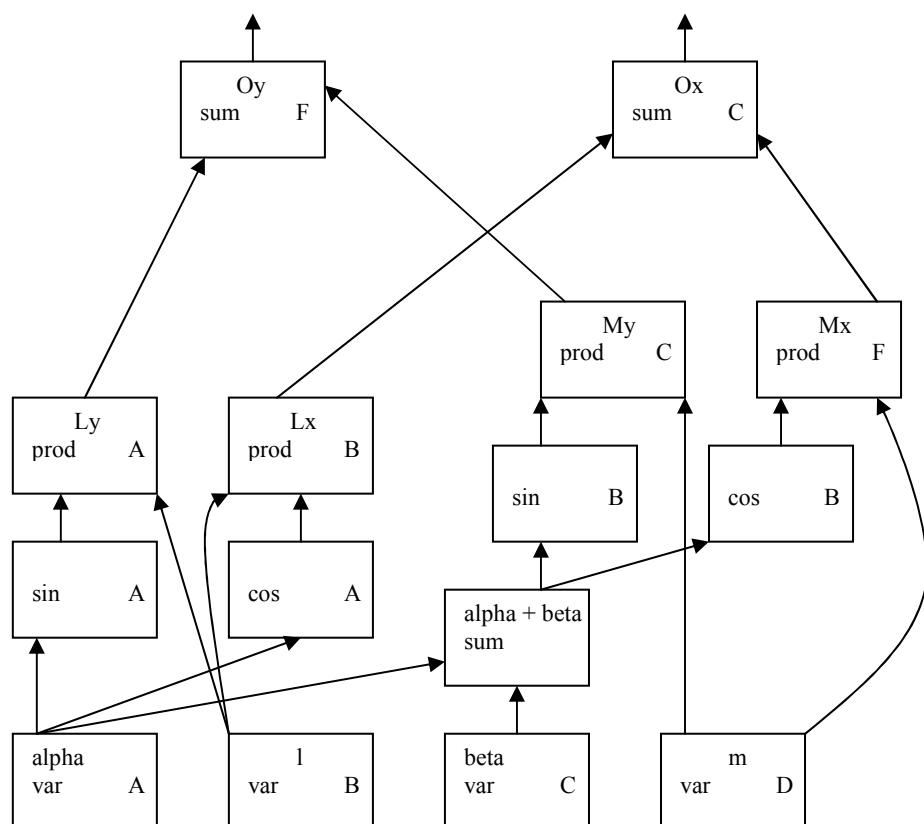
Η χαρτογράφηση από τις (α, β) συντεταγμένες στις (x, y) είναι λειτουργική (από πολλά σε ένα) και μπορεί να αναπαρασταθεί από την ανάδραση του δικτύου. Ας υποθέσουμε τώρα, καθώς αυτή η περίπτωση θα ήταν ποιο χρήσιμη, ότι θέλουμε να χαρτογραφήσουμε τις (x, y) συντεταγμένες για να βρούμε τις α και β γωνίες οι οποίες μπορούν να ορίσουν τη θέση της άκρης σε ένα συγκεκριμένο σημείο. Εφόσον αυτή είναι χαρτογράφηση από ένα - σε πολλά, δεν μπορούμε να την απεικονίσουμε με την φυσιολογική μπροστινή λειτουργία του δικτύου. Αντί γι αυτό, χρησιμοποιούμε το δίκτυο σε κατάσταση πίσω. Για ένα επιθυμητό στόχο (tx, ty) το λάθος μεταξύ του στόχου και του πρόσφατου σημείου εξόδου (Ox, Oy) πηγαίνει στης πίσω εισόδους των κόμβων Ox και Oy αντίστοιχα. Μετά το δίκτυο λειτουργεί αντίστροφα για να προσαρμόσει τις γωνίες α και β ενώ στη συνέχεια μπροστά για να υπολογίσει το πρόσφατο λάθος, μετά αντίστροφα πάλι και αυτή η διαδικασία επαναλαμβάνεται μέχρι το λάθος να είναι ικανοποιητικά μικρό. Η εικόνα 8 δείχνει τη συμπεριφορά του συστήματος. Κάθε ξαφνική αύξηση λάθους αντιστοιχεί σε μια μετακίνηση του στόχου. Σημειώστε ότι μετά από κάθε μετακίνηση, το σύστημα ανταποκρίνεται για να κουνήσει την άκρη προς το στόχο αρκετά γρήγορα.



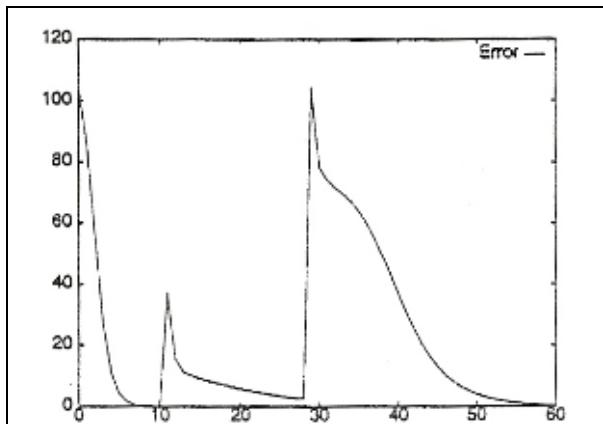
Εικόνα7. Η εικόνα 7 δείχνει τους προς τα εμπρός υπολογισμούς που είναι απαραίτητοι για να υπολογίσουμε τη θέση ενός ρομποτικού βραχίονα δύο βαθμών ελευθερίας με μήκων άκρων 1 και m και γωνίες άκρων α και β. Το β βρίσκεται σε σχέση με το α.

2.5 Συζήτηση και συμπεράσματα

Αυτή η εργασία έχει περιγράψει μια νέα και απλή μέθοδο για να διευκρινίσουμε αντίστροφα δίκτυα ανάδρασης με ενδογενείς μαθησιακές ικανότητες. Κάθε κατάσταση στο δίκτυο είναι τώρα μια μεταβλητή που έχει ένα μέρος ανάδρασης. Το εμπρός μέρος υπολογίζει κάποια διαφοροποιημένη λειτουργία της εισόδου του, ενώ το πίσω μέρος συγκεντρώνει το λάθος από της καταλήξεις των κόμβων και το πολλαπλασιάζει με το παράγωγο της λειτουργίας με βάση τους κόμβους της εμπρός εισόδου.



Εικόνα 7. Ένα δίκτυο με μεταβλητές ανάδρασης για να διευκρινίσουμε το ρομποτικό βραχίονα της εικόνας 6. Σημειώστε ότι για κάθε προς τα εμπρός σύνδεση στο διάγραμμα, υπάρχει επίσης μια προς τα πίσω σύνδεση που δεν φαίνεται για να είναι ποιο απλό το διάγραμμα.



Εικόνα 8. Γράφημα σφάλματος (ευκλείδεια απόσταση μεταξύ του στόχου και της άκρης του ρομποτικού βραχίονα) αναλογικά με το χρόνο. Κάθε ξαφνική αύξηση λάθους αντιστοιχεί με τη μετακίνηση του στόχου.

Από την μια, αυτό μπορούμε να το δούμε απλά ως μια αναδιατύπωση του γενικευμένου κανόνα delta [22]. Από την άλλη, αυτός ο απλός τρόπος καταστάσεων αν τον εξετάσει κανείς φαίνεται ότι είναι ένα σημαντικό βήμα μπροστά, για τους ερευνητές που ενδιαφέρονται για την εξέλιξη των νευρωνικών δικτύων, εφόσον προηγούμενη δουλειά είτε είχε περιορίσει το είδος δικτύου που αναπτύσσεται σε μια κλασσική πολυεπίπεδη αντίληψη ανάδρασης (τυπικά με ένα μη κλασσικό σχέδιο σύνδεσης), ή σε άλλους τύπους δικτύου (όπως υψηλότερης τάξης δικτύα [14] αλλά με το περιορισμό ότι οι ελεύθερες παράμετροι του δικτύου (πχ τα βάρη) να βρίσκονται μέσω μίας διαδικασίας τυχαίου «hill-climbing» [14] ή «simulated annealing» [16]. Γενικά μιλώντας, οι μέθοδοι gradient συγκλίνουν πολύ πιο γρήγορα από της perturbation μεθόδους και έτσι η προοπτική που προσφέρεται από αυτή την εργασία έχει μεγάλη σημασία.

Υπάρχουν δύο τρόποι που μπορεί αυτή η δομή να εφαρμοστεί σε αναπτυσσόμενες νευρωνικές αρχιτεκτονικές. Πρώτων κάθε άμεση ή έμμεση κωδικοποίηση που θα διευκρίνιζε σε φυσιολογικές συνθήκες ένα δίκτυο με απλά κελιά θα μπορούσε να χρησιμοποιηθεί το ίδιο καλά για να διευκρινίσει ένα δίκτυο από μεταβλητές ανάδρασης – με το άμεσο πλεονέκτημα ότι το δίκτυο θα έχει τι δική του ενσωματωμένη μαθησιακή συμπεριφορά και θα είναι πιθανά αναστρέψιμη. Η δεύτερη πιθανότητα είναι να αναπτύξουμε λεπτομέρειες από κάθε μεταβλητή, αντί να τις διευκρινίσουμε από πριν. Κάθε μεταβλητή ανάδρασης που παρουσιάστηκε εδώ διευκρινίστηκε όσον αφορά τα απλά κελιά, αλλά ξεκάθαρα, μια εναλλακτική θα ήταν να το διευκρινίσουμε όσον αφορά τις πολύπλοκες μεταβλητές. Αυτού του είδους η πολυεπίπεδη ιεραρχικά παρεμπόδιση έχει τη δυνατότητα να έχει μια σημαντική επίδραση στην τεχνητή ανάπτυξη των νευρωνικών δικτύων. Οι μεταβλητές ανάδρασης που παρουσιάστηκαν εδώ είναι ένα χρήσιμο βήμα προς αυτήν την κατεύθυνση.

Βιβλιογραφία:

1. D. Chalmers, “The evolutions of learning: an experiment in genetic connectionism,” in Proceedings of the 1990 Connectionist Models Summer School (D. Touretzky, J. Elman, T. Sejnowski and G. Hinton, eds.), San Francisco: Morgan Kaufman, (1990).
2. S. Bengio, Y. Bengio, and J. Cloutier, “Use of genetic programming for the search of a new learning rule for neural networks,” in Proceedings of IEEE International Conference on Evolutionary Computation, pp. 324-327, Orlando: IEEE, (1994).
3. B. Yamauchi and R. Beer, “Sequential behaviour and learning in evolved dynamical neural networks,” Adaptive Behaviour, vol. 2, pp.219 – 246, (1994).
4. S. Lucas, “Evolving neural networks learning behaviours with set-based chromosomes,” in Proceedings of European Symposium on Artificial Neural Networks (ESANN ’96), pp. 291-296, Brussels: D facto, (1996).
5. D. Fogel, “Using evolutionary programming to create networks that are capable of playing tic-tac-toe,” in Proceedings of IEEE International Conference on Neural Networks, pp. 875-880, San Francisco: IEEE, (1993).
6. D. Dasgupta and D. McGregor, “Designing application specific neural networks using the structured genetic algorithm,” in Proceedings of COGANN-92 – IEEE International Workshop on Combinations of Genetic Algorithms and Neural Networks, pp. 87-96, Baltimore: IEEE, (1992).
7. L. Marti, “Genetically generated neural networks ii: searching for an optimal representation,” in Proceedings of the International Joint Conference on Neural Networks (Baltimore ’92), pp. I, 221-226, San Diego, CA: IEEE, (1992).
8. J. McDonell and D. Waagen, “Neural network structure design by evolutionary programming,” in Proceedings of the Third Annual Conference on Evolutionary Programming (D. Fogel and W. Atmar, eds.), pp. 79-89, Evolutionary Programming Society, (1993).
9. J. McDonell, W. Page and D. Waagen, “Neural networks construction using evolutionary search,” in Proceedings of the Third Annual Conference on Evolutionary Programming (A. Sebald and L. Fogel, eds.), pp. 9-16, World Scientific, (1994).
10. H. Kitano, “Designing neural networks using genetic algorithm with graph generation system,” Complex Systems, vol. 4, pp. 461-476, (1990).
11. F. Gruau, “Cellular encoding of genetic neural networks,” Laboratoire de l’Informatique du Parallelisme Technical Report 92-21, Ecole Normale Supérieure de Lyon, (1992).
12. F. Gruau, “Automatic definition of modular neural networks,” Adaptive Behaviour, vol. 3, pp. 151-183, (1994).
13. E. Boers and H. Kuiper, :Biological metaphors and the design of modular artificial neural networks,” Master thesis, Department of Computer Science and Experimental and Theoretical Psychology, Leiden University, the Netherlands, (1993).
14. H. Muhlenbein and B. Zhang, “Synthesis of sigma-pi neural networks by the breeder genetic programming,” in Proceedings of IEEE International Conference on Evolutionary Computation, pp. 318-323, Orlando: IEEE, (1994).

15. B. Zhang and H. Muehlenbein, "Balancing accuracy and parsimony in genetic programming," *Evolutionary Computation*, vol. 3, pp. 17-38, (1995).
16. K. Sharman, A. Esparcia-Alcazar, and Y. Li, "Evolving signal processing algorithms by genetic programming," in *Proceedings of IEE 1st International Conference on Genetic Algorithms in Engineering Systems: Innovations and Application*, pp. 473-480, London: IEE, (1995).
17. H. Kitano, "Neurogenetic learning: An integrated model of designing and training neural networks using genetic algorithms," *Physica D*, vol. 75, pp. 225-238, (1994).
18. H. Kitano, "A simple model of neurogenesis and cell differentiation," *Artificial Life*, vol. 2, pp. 79-99, (1995).
19. S. Lucas, "Growing adaptive neural networks with graph grammars," in *Proceedings of European Symposium on Artificial Neural Networks (ESANN '95)*, pp. 235-240, Brussels: D facto, (1995).
20. S. Lucas, "Towards the open-ended evolution of neural networks," in *Proceedings of IEE 1st International Conference on Genetic Algorithms in Engineering Systems: Innovations and Application*, pp. 338-393, London: IEE, (1995).
21. D. Montana, "Strongly typed genetic programming," *Evolutionary Computation*, vol. 3, pp. 199-230, (1995).
22. D. Rumelhart, G. Hinton, and R. Williams, "Chapter 8: Learning internal representations," in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1: Foundations* (D. Rumelhart and J. McClelland, eds.), pp. 319-362, London: The MIT Press, (1986).

– Τέλος –