


Ατομική Διπλωματική Εργασία

**ΔΙΚΤΥΟ ΑΙΣΘΗΤΗΡΩΝ
ΜΕ ΝΕΥΡΩΝΙΚΗ ΔΟΜΗ ΓΙΑ ΑΠΟΚΤΗΣΗ
ΠΡΟΣΑΡΜΟΣΤΙΚΟΤΗΤΑΣ**

Αντρέας Καμηλάρης

ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ



ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

Ιούνιος 2007

ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

**Δίκτυο Αισθητήρων
με Νευρωνική Δομή για απόκτηση
Προσαρμοστικότητας**

Αντρέας Καμηλάρης

Επιβλέπων Καθηγητής

Αντρέας Πιτσιλλίδης

Η Ατομική αυτή Διπλωματική Εργασία υποβλήθηκε προς μερική
εκπλήρωση των απαιτήσεων απόκτησης του πτυχίου Πληροφορικής του
Τμήματος Πληροφορικής του Πανεπιστημίου Κύπρου

Ιούνιος 2007

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου κ. Αντρέα Πιτσιλλίδη και τον κ. Κρις Χριστοδούλου για την υποστήριξη και καθοδήγηση που μου πρόσφεραν κατά την διάρκεια της υλοποίησης αυτής της εργασίας, αλλά και για την επίτευξη μιας άψογης συνεργασίας.

Επίσης τον μεταπτυχιακό φοιτητή του τμήματος, Παναγιώτη Αντρέου για την πολύτιμη βοήθεια που μου πρόσφερε κατά την διάρκεια της υλοποίησης του προσομοιωτή που ανέπτυξα, όσον αφορά κυρίως την εύρεση πραγματικών δεδομένων μετρήσεων για τις ανάγκες του σεναρίου.

Περίληψη

Τα ασύρματα δίκτυα αισθητήρων είναι μια πολύ υποσχόμενη πρόσφατη τεχνολογία, την οποία οι επιστήμονες φιλοδοξούν να εισαγάγουν στην καθημερινή μας ζωή. Ήρθε η στιγμή να διευρύνουμε τις γνώσεις μας όσον αφορά την νέα αυτή τεχνολογία και να αναζητήσουμε τρόπους ή μηχανισμούς ώστε να επιτύχουμε τη βέλτιστη λειτουργία ενός τέτοιου δικτύου.

Οι ομοιότητες μεταξύ ασύρματων δικτύων αισθητήρων και νευρωνικών δικτύων δείχνουν ότι ένα συνδυασμένο σύστημα θα ήταν ένα ενδιαφέρον θέμα έρευνας. Οι αδυναμίες που παρουσιάζει ένα ασύρματο δίκτυο αισθητήρων πιστεύουμε ότι μπορούν να αντιμετωπιστούν με τη μετατροπή τους σε νευρωνικό δίκτυο με τα πλεονεκτήματα που προσφέρει.

Στο άρθρο αυτό θα παρουσιάσουμε αρχικά την γενική θεωρία πίσω από τα δίκτυα αισθητήρων, τα νευρωνικά δίκτυα με τους πιο δημοφιλείς αλγορίθμους εκμάθησης στα δίκτυα αυτά και θα μελετήσουμε με αναλυτικό τρόπο τα προβλήματα που γεννά μια τέτοια μετατροπή με τους πιθανούς τρόπους αντιμετώπισης αυτών των προβλημάτων. Ακολούθως θα παραθέσουμε την αποδεικτική μέθοδο που θα ακολουθήσουμε για να αξιολογήσουμε την απόδοση του μοντέλου μας μέσα από κάποιο αντιπροσωπευτικό σενάριο και θα αναφέρουμε τους μαθηματικούς συλλογισμούς και την διεργασία που θα ακολουθήσουμε για επίτευξη της προσέγγισης μας.

Τέλος θα παρουσιάσουμε τα αποτελέσματα που θα εξαχθούν, με χρήση γραφικών παραστάσεων και θα βγάλουμε τα συμπεράσματα μας σχετικά με την πιθανή επιτυχία της διπλωματικής αυτής εργασίας.

Περιεχόμενα

Κεφάλαιο 1 Εισαγωγή	- 1 -
1.1 Ορισμός του Προβλήματος	- 1 -
1.2 Σκοπός της Μελέτης	- 2 -
1.3 Το πρόβλημα της προσαρμοστικότητας	- 3 -
1.4 Μια υποσχόμενη τεχνολογία.....	- 3 -
 Κεφάλαιο 2 Θεωρία	- 5 -
2.1 Οι αισθητήρες σήμερα	- 5 -
2.2 Δίκτυα Αισθητήρων	- 7 -
2.3 Νευρωνικά Δίκτυα	- 9 -
2.3.1 Αλγόριθμος Back-Propagation	- 10 -
2.3.2 Χάρτες Kohonen	- 13 -
2.3.3 Ενισχυτική Μάθηση.....	- 15 -
2.4 Η προσαρμοστικότητα γενικά	- 18 -
 Κεφάλαιο 3 Περιγραφή Προβλήματος	- 20 -
3.1 Αναλυτική Περιγραφή Προβλήματος	- 20 -
3.2 Γενικά Προβλήματα	- 24 -
3.2.1 Δίκτυα Αισθητήρων	- 24 -
3.2.1.1 Συλλογή Δεδομένων και Επεξεργασία	- 24 -
3.2.1.2 Αξιοπιστία Δεδομένων.....	- 25 -
3.2.1.3 Συντήρηση Λογισμικού.....	- 25 -
3.2.2 Νευρωνικά Δίκτυα	- 26 -
3.2.2.1 Εκμάθηση Δικτύου	- 26 -
3.2.2.2 Μαθηματικό Υπόβαθρο	- 26 -
3.2.2.3 Ευελιξία	- 27 -
3.2.2.4 Ύπαρξη Παραδειγμάτων	- 28 -
3.3 Συγκεκριμένα Προβλήματα	- 28 -
3.3.1 Γεωγραφική Κατανομή	- 29 -
3.3.2 Ομαδοποίηση	- 30 -
3.3.2.1 Αλγόριθμος LEACH.....	- 31 -
3.3.2.2 Αλγόριθμος MINA/UNPF	- 32 -
3.3.3 Ευρωστία	- 33 -
3.3.4 Εξελξιμότητα	- 35 -
3.3.5 Κατανάλωση Ενέργειας	- 36 -
3.3.6 Συγχρονισμός	- 38 -
3.3.7 Ακεραιότητα Δεδομένων	- 40 -
3.3.8 Ανακάλυψη Γνώσης.....	- 40 -

Κεφάλαιο 4 Αξιολόγηση Απόδοσης..... - 42 -

4.1 Αποδεικτική Μέθοδος.....	- 42 -
4.2 Σκοπός της Προσομοίωσης	- 43 -
4.3 Σύγκριση με άλλους Προσομοιωτές	- 45 -
4.4 Περιγραφή Σεναρίου	- 46 -
4.5 Μαθηματικός Συλλογισμός.....	- 48 -
4.6 Υποθέσεις και Περιορισμοί.....	- 52 -
4.7 Επιλογή Αισθητήρων	- 54 -
4.8 Δομή Νευρωνικού Δικτύου.....	- 58 -
4.8.1 Απλό Σενάριο.....	- 59 -
4.8.2 Σενάριο Πραγματικών Δεδομένων	- 63 -
4.9 Προ-επεξεργασία	- 68 -
4.9.1 Απλό Σενάριο.....	- 68 -
4.9.2 Σενάριο Πραγματικών Δεδομένων	- 70 -
4.9.3 Ένα απροσδόκητο πρόβλημα των Δεδομένων.....	- 73 -

Κεφάλαιο 5 Παρουσίαση Αποτελεσμάτων - 76 -

5.1 Μέθοδος Εξαγωγής Αποτελεσμάτων	- 76 -
5.2 Διαδικασία Εκμάθησης Δικτύου	- 77 -
5.3 Διαδικασία Ελέγχου Δικτύου	- 80 -
5.4 Εκμάθηση Vs Έλεγχος.....	- 83 -
5.5 Κατανάλωση Ενέργειας	- 84 -
5.6 Ευρωστία Δικτύου	- 88 -
5.7 Εκμάθηση Vs Χρόνος	- 93 -

Κεφάλαιο 6 Συμπεράσματα..... - 97 -

6.1 Γενικά Συμπεράσματα.....	- 97 -
6.2 Μελλοντική Εργασία.....	- 101 -
6.3 Προκλήσεις	- 102 -
6.4 Επίλογος.....	- 103 -

Παράρτημα Α Υλοποίηση Προσομοιωτή.....A-1

A.1 Πληροφορίες Προσομοίωσης	A-1
A.2 Εκδόσεις Προσομοιωτή	A-2
A.2.1 Έκδοση 1: Απλό Σενάριο.....	A-3
A.2.2 Έκδοση 2: Πραγματικό Σενάριο.....	A-5
A.2.3 Έκδοση 3: Παράγοντας Ευρωστία.....	A-6
A.2.4 Έκδοση 4: Πραγματικοί Αισθητήρες	A-7
A.2.5 Έκδοση 5: Κατανάλωση Ενέργειας	A-8
A.3 Υλοποίηση ενός Αισθητήρα	A-10
A.4 Αρχικοποιήσεις.....	A-14

Βιβλιογραφία..... 1

Κεφάλαιο 1

Εισαγωγή

1.1 Ορισμός του Προβλήματος	1
1.2 Σκοπός της Μελέτης	2
1.3 Το πρόβλημα της προσαρμοστικότητας	3
1.4 Μια υποσχόμενη τεχνολογία	3

1.1 Ορισμός του Προβλήματος

Η έρευνα μέχρι στιγμής στα ασύρματα δίκτυα αισθητήρων βρίσκεται σε προχωρημένο βαθμό στο επίπεδο του ατομικού αισθητήρα. Αρκετό μέρος της έρευνας αναλώνεται στο υλικό και το λογισμικό που πρέπει να χρησιμοποιηθεί σε μια τέτοια συσκευή, ώστε να μπορεί να επιλύει τα προβλήματα που παρουσιάζονται σε δύσκολα και εχθρικά περιβάλλοντα, σε περιβάλλοντα στα οποία η πρόσβαση και η εκτέλεση εργασιών κρίνεται δύσκολη έως ανέφικτη. Μπορούμε έτσι να πούμε, σχεδόν με βεβαιότητα, ότι οι αισθητήρες που κυκλοφορούν σήμερα στο εμπόριο, αποτελούν σχεδόν ολοκληρωμένες υπολογιστικές συσκευές με πολλές δυνατότητες. Παρ' όλα αυτά, τα μεγάλα ερωτήματα παραμένουν σχετικά με το ποιες είναι οι δυνατότητες ενός ασύρματου δικτύου αισθητήρων, ποια προβλήματα προσπαθούμε να επιλύσουμε με αυτό και πώς μπορούμε να τα επιλύσουμε αποδοτικά.


Με λίγα λόγια, πώς θα χρησιμοποιήσουμε το δίκτυο αισθητήρων στην ολότητα του, ώστε να πετύχουμε τη βέλτιστη δυνατή του λειτουργία.

Πολλοί επιστήμονες έχουν αναλώσει την ερευνητική τους εργασία ανακαλύπτοντας αλγόριθμους και μεθόδους που σκοπό έχουν την επίλυση προκλήσεων όπως η κατανάλωση ενέργειας, η αποδοτική δρομολόγηση των

δεδομένων και η ομαδοποίηση των αισθητήρων μεταξύ τους. Οι εργασίες αυτές βασίζονται κυρίως σε σύνθετα μαθηματικά μοντέλα και επιστημονικές αναλύσεις προσομοιώσεων. Παράλληλα, τα τελευταία όμως χρόνια, μεγάλος αριθμός επιστημόνων έχει στραφεί προς την παρατήρηση και μελέτη δικτύων που υπάρχουν στη φύση, προσπαθώντας να αντλήσουν γνώση από την νομοτέλεια με την οποία λειτουργούν τα δίκτυα αυτά. Παραδείγματα τέτοιων κατανεμημένων δικτύων είναι αποικίες βακτηρίων, μελισσώνες αλλά και το ανθρώπινο σώμα. Τα δίκτυα αυτά αποτελούν μεγάλη πρόκληση στην επιστημονική κοινότητα και στο μέλλον οι έρευνες μάλλον θα εστιαστούν προς την κατεύθυνση αυτή.

1.2 Σκοπός της Μελέτης

Με αυτά στο μυαλό, σκεφτήκαμε να ερευνήσουμε την top-down προσέγγιση μετατροπής ενός ασύρματου δικτύου αισθητήρων σε νευρωνικό δίκτυο, με σκοπό την επίλυση συγκεκριμένων προβλημάτων που αντιμετωπίζουν τα δίκτυα αυτά. Στο κάτω-κάτω πολλοί ιεραρχικοί οργανισμοί και κυβερνήσεις εργάζονται σαν νευρωνικά δίκτυα, προσπαθώντας να ελέγξουν τα περιβάλλοντά τους και να πετύχουν κάποιο κοινό στόχο. Κάθε άνθρωπος- αισθητήρας-νευρώνας έχει την ικανότητα να φιλτράρει, να επεξεργαστεί την πληροφορία πριν την στείλει στο πιο πάνω επίπεδο. Τα τεχνητά νευρωνικά δίκτυα μπορούν να παρομοιαστούν ως μια μαθηματική ιεραρχία από συναρτήσεις μεταξύ της εισόδου στην αρχή και της εξόδου στο τέλος. Η μετατροπή αυτή, σε θεωρητικό επίπεδο, αποτελεί μια υποσχόμενη τεχνολογία, δεδομένου των μεγάλων πλεονεκτημάτων που προσφέρουν τα νευρωνικά δίκτυα. Στο Σχήμα 1.1 φαίνεται μια αρχική προσέγγιση της ιδέας που βρίσκεται πίσω από τη διπλωματική αυτή εργασία. Οι αισθητήρες μορφώνονται σε μια καθορισμένη τοπολογία ώστε να εξυπηρετήσουν ένα συγκεκριμένο σκοπό, στην περίπτωση μας να δημιουργήσουν ένα νευρωνικό δίκτυο.



Σχήμα 1.1 Παράδειγμα Νευρωνικού Δικτύου

Χαρακτηριστικά των δικτύων αυτών όπως είναι η ευρωστία, η χαμηλή κατανάλωση ενέργειας και η ευελιξία λειτουργίας, τα κάνει εξαιρετικά ελκυστικά για να τα μελετήσουμε εις βάθος. Παρ' όλα αυτά το μεγαλύτερο πλεονέκτημα που παρέχουν τα νευρωνικά δίκτυα και μας δίνει και το ουσιαστικότερο κίνητρο να τα μελετήσουμε, είναι η προσαρμοστικότητα.

1.3 Το πρόβλημα της προσαρμοστικότητας

Ένα από τα κυριότερα θέματα που απασχολούν την επιστημονική κοινότητα τη σημερινή εποχή είναι η δημιουργία και ανάπτυξη «έξυπνων» μηχανών. Μηχανών που θα έχουν την ικανότητα να αφομοιώνουν το περιβάλλον τους και να αντλούν γνώση από αυτό, έστω και εάν το «προγραμματισμένο» περιβάλλον έχει αλλάξει. Με λίγα λόγια, στόχος είναι η απόκτηση από τα μηχανήματα αυτά προσαρμοστικότητας.

1.4 Μια υποσχόμενη τεχνολογία

Ρίχνοντας μια ματιά στο διαδίκτυο, εύκολα μπορεί κάποιος να διαπιστώσει ότι η έρευνα για την πιθανότητα συνδυασμού δικτύων αισθητήρων και νευρωνικών δικτύων βρίσκεται ακόμη πολύ πίσω. Δεν έχει μελετηθεί ακόμα σε μεγάλο βαθμό

από τους επιστήμονες της πληροφορικής η κοινή χρήση των δύο αυτών τεχνολογιών και αυτό ακριβώς το γεγονός κάνει την παρούσα εργασία αρκετά σημαντική, καθώς ελπίζουμε ότι με τον ένα ή με τον άλλο τρόπο, θα συνεισφέρει στο τέλος στην συνολική έρευνα στην κατεύθυνση των δικτύων αισθητήρων.


Κεφάλαιο 2

Θεωρία

2.1 Οι αισθητήρες σήμερα.....	5
2.2 Δίκτυα Αισθητήρων	7
2.3 Νευρωνικά Δίκτυα	9
2.4 Η προσαρμοστικότητα γενικά.....	18

2.1 Οι αισθητήρες σήμερα

Ένας ατομικός αισθητήρας ορίζεται ως μια υπολογιστική μηχανή περιορισμένου μεγέθους που έχει την ικανότητα να μετρά δεδομένα από το περιβάλλον και να τα επεξεργάζεται¹. Τα δεδομένα αυτά μπορεί να είναι κίνηση, θερμοκρασία, υγρασία κ.α. Το μέγεθος των αισθητήρων κυμαίνεται από μερικά εκατοστά μέχρι και μεγέθους ενός κόκκου σκόνης. Ένας αισθητήρας γενικά αποτελείται από κάποιον ελεγκτή, που είναι υπεύθυνος για τη γενική του λειτουργία, από μια συσκευή ασύρματης επικοινωνίας με άλλους αισθητήρες, από την μνήμη του, δυναμική και στατική, από τους αισθητήρες του, οι οποίοι του δίνουν τη δυνατότητα να μετρά δεδομένα που βρίσκονται στο περιβάλλον του και φυσικά από την παροχή ενέργειας που του παρέχει την απαιτούμενη ισχύ ώστε να λειτουργεί. Στο Σχήμα 2.1 παρατηρούμε με ποιο τρόπο συνδυάζονται τα μέρη ενός αισθητήρα μεταξύ τους.



Σχήμα 2.1 Μέρη ενός Αισθητήρα

Οι πιο διαδεδομένοι ελεγκτές που χρησιμοποιούνται για την κατασκευή αισθητήρων είναι της Texas Instruments και της Atmel. Λειτουργούν σε ταχύτητες μέχρι και 4 MHz. Η τεχνολογία που χρησιμοποιείται για την κατασκευή της μνήμης των αισθητήρων είναι συνήθως FLASH.

Το μέσο που χρησιμοποιείται για την επικοινωνία μεταξύ των αισθητήρων είναι ηλεκτρομαγνητικό πεδίο σε ραδιοσυχνότητες. Οι πιθανές καταστάσεις μιας συσκευής επικοινωνίας είναι μετάδοση (transmission mode), λήψη (receive mode), κατάσταση μη απασχόλησης (idle mode) και κατάσταση ύπνου (sleep mode). Η μετάδοση δεδομένων φτάνει τα 250 Kbps σε πρωτόκολλο επικοινωνίας IEEE 802.11 b/g/a κυρίως. Η ακτίνα μετάδοσης δεδομένων ενός αισθητήρα κυμαίνεται από μερικές δεκάδες μέχρι και μερικές εκατοντάδες μέτρα.

Νευραλγικής σημασίας στη λειτουργία ενός αισθητήρα είναι η παροχή ενέργειας που θα εφοδιάσει τα κυκλώματα του. Χρησιμοποιούνται κυρίως μπαταρίες λιθίου ή αλκαλικές. Εξυπακούεται ότι η κατανάλωση ενέργειας για κάθε λειτουργία του αισθητήρα πρέπει να είναι η ελάχιστη δυνατή ώστε να μεγιστοποιείται η ζωή του. Οι εταιρείες κατασκευής ισχυρίζονται ότι οι αισθητήρες τους έχουν μέχρι και 3 χρόνια ζωής αλλά πρακτικά αντέχουν μέχρι και 6 μήνες λόγω κυρίως των μεγάλων διαρροών ενέργειας προς το περιβάλλον.

Είναι προφανές ότι η επιλογή του λειτουργικού συστήματος που θα εγκατασταθεί σε μια τέτοια συσκευή είναι εξαιρετικά σημαντική. Πρέπει να παραμένει σχετικά απλό με μικρό μέγεθος κώδικα ενώ ταυτόχρονα με αρκετές ικανότητες. Πρέπει να

διασφαλίζει πρόσβαση στους πόρους της συσκευής με εύχρηστο τρόπο, ενώ παράλληλα να προστατεύει τους πόρους αυτούς από ταυτόχρονη πρόσβαση (πρόβλημα ταυτοχρονίας). Μετά από πολλές εισηγήσεις και δοκιμές επικράτησε η ιδέα της χρήσης ενός λειτουργικού συστήματος που εργάζεται με επί μέρους τμήματα (components), τα οποία διαφέρουν από τις κλασικές διεργασίες καθώς μοιράζονται τον ίδιο χώρο διευθύνσεων και δεν παρέχεται προστασία κατά την εκτέλεση μεταξύ τους. Τα τμήματα αυτά αλληλεπιδρούν με την ανταλλαγή ασύγχρονων γεγονότων (asynchronous events). Το λειτουργικό σύστημα που υιοθέτησε αυτά τα χαρακτηριστικά αναπτύχθηκε από το UC Berkeley ως run-time περιβάλλον για τους αισθητήρες του και του δόθηκε το όνομα TinyOS. Σήμερα είναι το πιο διαδεδομένο λειτουργικό σύστημα που χρησιμοποιείται.

Στο Σχήμα 2.2 βλέπουμε ένα τυπικό αισθητήρα και μπορούμε να συγκρίνουμε το μέγεθος του με ένα κοινό φύλλο χαρτιού της τράπουλας.



Σχήμα 2.2 Μέγεθος τυπικού Αισθητήρα

2.2 Δίκτυα Αισθητήρων

Τα ασύρματα δίκτυα αισθητήρων είναι συλλογές από μικρές αυτόνομες υπολογιστικές συσκευές, κατανεμημένες στο χώρο, που επικοινωνούν ως μια ομάδα για να συλλέγουν δεδομένα². Αφού συλλέξουν δεδομένα, ο σκοπός των αισθητήρων είναι να τα προωθήσουν μέσω του ασύρματου δικτύου.

Λόγω του χαμηλού κόστους τους, μπορεί να χρησιμοποιηθεί ένας μεγάλος αριθμός από αισθητήρες σε μια περιοχή με αποτέλεσμα το ασύρματο δίκτυο να

γίνεται ανθεκτικό σε λάθη. Τα δίκτυα αυτά έχουν την ικανότητα να επεκταθούν σε μια αφιλόξενη και ίσως δύσβατη περιοχή, όπου μπορούν να παραμείνουν για χρόνια, παρακολουθώντας και μετρώντας κάποιες συγκεκριμένες περιβαλλοντικές μεταβλητές χωρίς την ανάγκη επαναφόρτισης/αντικατάστασης των πηγών ενέργειας των αισθητήρων.

Μοναδικά χαρακτηριστικά τέτοιων δικτύων που τα διαχωρίζουν από άλλα δίκτυα υπολογιστών είναι το γεγονός ότι αποτελούνται από περιορισμένης κλίμακας μικρούς αισθητήρες, οι οποίοι διαθέτουν περιορισμένη ενέργεια λειτουργίας, τοποθετούνται σε σκληρές περιβαλλοντικές συνθήκες, χαρακτηρίζονται από δυναμικές δικτυακές τοπολογίες, παρουσιάζουν φαινόμενα κινητικότητας των κόμβων (node mobility), αποτυχίας λειτουργίας των αισθητήρων (node failure) καθώς και λάθη στην μετάδοση των δεδομένων λόγω των ανωμαλιών του γύρω περιβάλλοντος. Εξυπακούεται ότι τα δίκτυα αυτά λειτουργούν χωρίς την παρουσία κάποιου επόπτη-συντονιστή ενώ οι αισθητήρες μεταξύ τους παρουσιάζουν ετερογένεια.

Αρχικά η ανάπτυξη των δικτύων αυτών εμπνεύστηκε από στρατιωτικές εφαρμογές όπως παρακολουθήσεις στο πεδίο της μάχης. Ασύρματα δίκτυα αισθητήρων χρησιμοποιούνται σήμερα σε πολλές εφαρμογές που περιλαμβάνουν έλεγχο και παρακολούθηση συγκεκριμένων περιβαλλόντων και φυσικών βιοτόπων, υγειονομικές εφαρμογές, συστήματα αυτοματισμών και έλεγχο κυκλοφορίας αλλά και σε κάποιες περιπτώσεις σε ανίχνευση σεισμών και ακραίων καιρικών φαινομένων.

Πολλά πρωτόκολλα και αλγόριθμοι έχουν αναπτυχθεί για τη λειτουργία και την επικοινωνία των αισθητήρων μεταξύ τους, ενώ πολλές τεχνολογίες και πλατφόρμες έχουν σχεδιαστεί για έλεγχο και δοκιμή των δικτύων αυτών. Οι αλγόριθμοι αυτοί στοχεύουν κυρίως στην μείωση της κατανάλωσης ενέργειας κατά την χρήση των αισθητήρων, στην αποδοτική και αξιόπιστη δρομολόγηση των πακέτων στο δίκτυο αισθητήρων καθώς και στην ευρωστία και αυτονομία του δικτύου αυτού. Η λογική πίσω από τον σχεδιασμό των συστημάτων αυτών βασίζεται στη θεωρία γύρω από τους κατανεμημένους αλγορίθμους.

Στις πλείστες των ρεαλιστικών εφαρμογών τα δεδομένα που συλλέγονται από το ασύρματο δίκτυο αισθητήρων αποθηκεύονται στη μορφή αριθμητικών τιμών σε κάποιο κεντρικό σταθμό βάσης. Ο σταθμός αυτός είναι κάποια υπολογιστική μηχανή μεγαλύτερης ισχύος με ικανότητες επεξεργασίας και αποθήκευσης μεγάλης ποσότητας δεδομένων και φυσικά επικοινωνίας με τον έξω κόσμο.

2.3 Νευρωνικά Δίκτυα

Τα νευρωνικά δίκτυα, σε γενικές γραμμές, προσπαθούν να μοντελοποιήσουν τον τρόπο με τον οποίο εργάζεται ο ανθρώπινος εγκέφαλος. Αποτελούνται από διασυνδεδεμένα στοιχεία που επεξεργάζονται δεδομένα, γνωστά και ως νευρώνια. Το μαθηματικό τους υπόβαθρο περιλαμβάνει κυρίως μαθηματικές εκφράσεις απλών, γραμμικών και μη συναρτήσεων. Τα νευρώνια έχουν την ικανότητα να εκπαιδεύονται, ώστε να αντιδρούν ορθά στα προβλήματα που αντιμετωπίζουν. Στις πλείστες των περιπτώσεων, ο σκοπός τους είναι η ανάλυση πολύπλοκων φαινομένων, στα οποία είναι δύσκολη αν όχι αδύνατη η μοντελοποίηση ή η επίλυση με ορθόδοξα μαθηματικά μοντέλα.

Ουσιαστικά ο συνδυασμός ενός αριθμού νευρώνων σε μια νευρωνική δομή έχει σκοπό την ανάπτυξη καλά σχεδιασμένων συστημάτων εκμάθησης που εκπαιδεύονται με προσαρμοστικό τρόπο να επιλύουν πολύπλοκα, μη γραμμικά προβλήματα από ένα σετ παραδειγμάτων ή από γνώση που αντλούν από το περιβάλλον τους ή από κάποιο άλλο εξωτερικό παράγοντα. Έχουν την ικανότητα της γενίκευσης της γνώσης που αποκτούν ώστε να αντιμετωπίζουν απρόβλεπτα σενάρια. Με λίγα λόγια είναι αυτό-προσαρμοζόμενα συστήματα (self-adaptive systems).

Στις πλείστες των περιπτώσεων η επεξεργασία των δεδομένων γίνεται παράλληλα παρά σειριακά. Από τη στιγμή που το νευρωνικό δίκτυο εξαρτάται αποκλειστικά από τα νευρώνια-μέλη του για να πραγματοποιήσει τη λειτουργία του, αποκτά το μοναδικό χαρακτηριστικό να μπορεί να λειτουργεί αποδοτικά ακόμα και αν κάποια νευρώνια πεθάνουν ή υπολειτουργήσουν. Έτσι τα δίκτυα

αυτά χαρακτηρίζονται συνήθως από ευρωστία σε λάθη ή αποτυχίες (fault tolerance).

Από τη στιγμή που ένα νευρωνικό δίκτυο εκπαιδεύεται, αποκτά την δυνατότητα να λειτουργεί εξαιρετικά αποδοτικά με μικρό ενεργειακό κόστος. Η γνώση δε που αποκτά, αντιπροσωπεύεται εσωτερικά στην δομή του νευρωνικού δικτύου και δεν υπάρχει πρόσβαση σε αυτή την αναπαράσταση.


Τα νευρωνικά δίκτυα χρησιμοποιούνται ευρέως σε επιστήμες όπως τη νευρολογία, την τεχνητή νοημοσύνη, την βιολογία και τη γνωστική μοντελοποίηση (cognitive modeling).

Στα επόμενα υποκεφάλαια θα εξετάσουμε τους πιο δημοφιλείς αλγόριθμους νευρωνικών δικτύων, οι οποίοι γνωρίζουν άνθηση σε ένα μεγάλο εύρος επιστημονικών και τεχνολογικών εφαρμογών. Θα εξετάσουμε αναλυτικά την λειτουργία τους και θα επιλέξουμε μέσα από την μελέτη τους τον κατάλληλο για χρήση στο πρόβλημα που μελετάμε.

2.3.1 Αλγόριθμος Back-Propagation

Πρόκειται για τον πιο δημοφιλή αλγόριθμο που χρησιμοποιείται για την εκμάθηση ενός νευρωνικού δικτύου. Λέγεται και εκμάθηση με δάσκαλο. Σύμφωνα με αυτόν, το δίκτυο μαθαίνει με τη βοήθεια παραδειγμάτων, αναλύοντας σε κάθε επανάληψη-παραδειγμα το λάθος στην έξοδο του νευρωνικού δικτύου.

Στο Σχήμα 2.3 μπορούμε να δούμε το νευρωνικό μοντέλο, όπως χρησιμοποιείται σε αυτόν τον αλγόριθμο.



Σχήμα 2.3 Νευρωνικό Μοντέλο

Σύμφωνα με αυτό το μοντέλο (Mc Cullock and Pits model), κάθε νευρώνιο του δικτύου παίρνει τις τιμές εξόδου των νευρωνίων που βρίσκονται στο προηγούμενο επίπεδο όπως αυτά καθορίζονται από τη δομή του νευρωνικού δικτύου (x_i). Οι τιμές εξόδου αυτές πολλαπλασιάζονται με τις αντίστοιχες τιμές των βαρών που συνδέουν το τρέχον νευρώνιο με τα προηγούμενα (w_i).

Το άθροισμα αυτών των γινομένων ($\sum x_i \cdot w_i$) σε επόμενη φάση, περνά από μια μαθηματική συνάρτηση (συνήθως χρησιμοποιείται η σιγμοειδής συνάρτηση αλλά κάποιες φορές προτιμάται η συνάρτηση κατωφλίου) και δημιουργείται μια καινούρια τιμή, η οποία είναι η τρέχων τιμή εξόδου του συγκεκριμένου νευρωνίου τη συγκεκριμένη χρονική στιγμή. Αυτή η τιμή προωθείται στο νευρωνικό δίκτυο με πανομοιότυπο τρόπο μέχρι να παραχθεί η τελική τιμή (ή οι τελικές τιμές) του δικτύου.


Στην έξοδο τώρα του νευρωνικού δικτύου, κατά τη διαδικασία της εκμάθησης, οι τιμές που υπολογίζονται δεν είναι οι ενδεικνυόμενες, όπως αυτό φαίνεται από τις ορθές τιμές εξόδου των παραδειγμάτων (τις οποίες γνωρίζουμε εκ των προτέρων). Για τη μείωση του σφάλματος αυτού, τα βάρη των νευρωνίων τροποποιούνται προς τα πίσω (backwards) κατά μήκος του νευρωνικού δικτύου, μέχρι, μετά από ένα σημαντικό αριθμό παραδειγμάτων, το σφάλμα μειώνεται αισθητά και γίνεται ασήμαντο. Αυτή η διαδικασία λαμβάνει χώρα σε κάθε νευρώνιο, σε κάθε επανάληψη (νέο παράδειγμα), μέχρι που στο τέλος το νευρωνικό δίκτυο συγκλίνει προς την λύση του προβλήματος, αποκτώντας την ικανότητα εκμάθησης του προβλήματος που του παρουσιάζεται και παρέχοντας ορθές πληροφορίες στην έξοδο βάσει φυσικά των δεδομένων στις εισόδους του δικτύου.

Επιγραμματικά η διαδικασία εκμάθησης του νευρωνικού δικτύου είναι η ακόλουθη:

1. Παρουσιάζουμε ένα καινούριο παράδειγμα στο νευρωνικό μας δίκτυο.
2. Το δίκτυο υπολογίζει, βάσει των τιμών του παραδείγματος, κάποια τιμή στην έξοδο του, που πρόκειται ουσιαστικά για κάποια πιθανότητα μεταξύ 0 και 1.

3. Η έξοδος του δικτύου συγκρίνεται με την επιθυμητή έξοδο όπως αυτή φαίνεται από το τρέχων παράδειγμα. Υπολογίζεται το σφάλμα.
4. Τα βάρη των νευρωνίων τροποποιούνται ώστε να μειωθεί το συγκεκριμένο σφάλμα.
5. Η διαδικασία αυτή συνεχίζεται μέχρι το συνολικό σφάλμα να μειωθεί αισθητά και να γίνει μηδαμινό.

Στο Σχήμα 2.4 μπορούμε να δούμε μια απλή δομή ενός νευρωνικού δικτύου που λειτουργεί με τον αλγόριθμο Back-Propagation. Φαίνονται επίσης ευδιάκριτα οι συνδέσεις μεταξύ των νευρωνίων.



Σχήμα 2.4 Δομή Νευρωνικού Δικτύου Back-Propagation

Όπως φαίνεται πολύ επιγραμματικά στο Σχήμα 2.4, το νευρωνικό δίκτυο ομαδοποιείται σε επίπεδα, με το πρώτο επίπεδο να καλείται επίπεδο εισόδου, το τελευταίο επίπεδο να λέγεται επίπεδο εξόδου και τα ενδιάμεσα επίπεδα να καλούνται κρυφό επίπεδο. Όπως προαναφέραμε, η γνώση, μετά την εκμάθηση

του δικτύου, αποθηκεύεται εσωτερικά στο κρυφό επίπεδο του δικτύου με τη μορφή τιμών στα βάρη που συνδέουν τα νευρώνια μεταξύ τους.

Κρίνοντας από την λειτουργία του αλγορίθμου, συμπεραίνουμε ότι για να λειτουργήσει ορθά, πρέπει να υπάρχει ένας μεγάλος αριθμός από παραδείγματα. Τα παραδείγματα αυτά πρέπει να προ-επεξεργαστούν, ώστε να αντιπροσωπευτούν ορθά εντός του νευρωνικού δικτύου, σε μορφή που να μπορεί το δίκτυο να κατανοήσει. Πρέπει να είναι συγκεκριμένα και να ακολουθούν την μορφή (τιμές εισόδου-επιθυμητή έξοδος). Η συλλογή αυτών των δεδομένων προϋποθέτει μεγάλη προσπάθεια και αυξάνει την δυσκολία εγκατάστασης ενός τέτοιου δικτύου.

Στην υλοποίηση του, ο αλγόριθμος αυτός προϋποθέτει την χρήση ενός αριθμού από παραμέτρους, οι οποίες καθορίζουν σε μεγάλο βαθμό και την λειτουργία του. Οι σημαντικότερες από αυτές τις παραμέτρους είναι ο ρυθμός μάθησης που καθορίζει τον ρυθμό με τον οποίο εκπαιδεύεται το νευρωνικό δίκτυο και ο παράγοντας ορμής (momentum), ο οποίος βοηθά το δίκτυο κατά την διαδικασία της εκμάθησης να μην μείνει προσκολλημένο σε κάποιο τοπικό ελάχιστο, όπως αυτό ορίζεται στην διαδικασία αναπαράστασης του προβλήματος.

Στην γενική του μορφή, ο αλγόριθμος αυτός δεν προσφέρεται για επίλυση προβλημάτων όπου ζητείται πλήρης προσαρμοστικότητα με το περιβάλλον διότι η ανάγκη παρουσίας εξειδικευμένων παραδειγμάτων καθιστά αδύνατη την υλοποίηση του σε κάποιο άγνωστο περιβάλλον. Εξ άλλου, λόγω της μορφής του, απαιτεί την παρουσία ενός υπολογιστή-επόπτη ή μιας εξωτερικής πηγής με ευθύνη την παροχή στο δίκτυο των παραδειγμάτων.

2.3.2 Χάρτες Kohonen


Οι Χάρτες Kohonen είναι ένας αλγόριθμος που χρησιμοποιεί εκμάθηση χωρίς επίβλεψη για να παραγάγει χαμηλών διαστάσεων αναπαράσταση των παραδειγμάτων εκμάθησης, διατηρώντας παράλληλα τις τοπολογικές ιδιότητες του χώρου εισόδου. Με πιο απλά λόγια, έχει την ικανότητα ο συγκεκριμένος αλγόριθμος να ομαδοποιεί μαζί παρόμοια δεδομένα. Ο αλγόριθμος αυτός είναι

μερικώς εμπνευσμένος από τον τρόπο με τον οποίο ο ανθρώπινος εγκέφαλος διαχειρίζεται το σύνολο των αισθήσεων του, σε διαφορετικά μέρη του εγκεφάλου το καθένα.

Σε μαθηματικό επίπεδο, το δίκτυο Kohonen εκφράζεται ως ένας χάρτης αυτό-οργάνωσης (self-organizing map), που αντιπροσωπεύει ένα ενός επιπέδου feed-forward δίκτυο όπου οι έξοδοι οργανώνονται σε ένα χαμηλότερου επιπέδου πλέγμα (συνήθως 2 ή 3^{ων} διαστάσεων). Κάθε είσοδος συνδέεται με όλα τα νευρώνια εξόδου. Προσαρτημένος σε κάθε νευρώνιο εξόδου, υπάρχει ένας πίνακας βαρών που έχει τις ίδιες διαστάσεις με τα διανύσματα εισόδου.

Εδώ πρέπει να τονιστεί ότι ο αριθμός των διαστάσεων εισόδου είναι συνήθως μεγαλύτερος από τις διαστάσεις του πλέγματος εξόδου. Αυτός είναι και ο κύριος λόγος που χρησιμοποιούνται τα συγκεκριμένα δίκτυα, για μείωση των διαστάσεων ενός προβλήματος ή μιας συνάρτησης.

Στο Σχήμα 2.5 φαίνεται ο τρόπος με τον οποίο λειτουργεί η εκμάθηση στα δίκτυα Kohonen.



Σχήμα 2.5 Εκμάθηση σε ένα Δίκτυο Kohonen

Ουσιαστικά πρόκειται για μια υλοποίηση της λεγόμενης ανταγωνιστικής εκμάθησης. Όταν ένα παράδειγμα εκμάθησης δίνεται στο δίκτυο, υπολογίζεται η ευκλείδεια απόσταση από όλα τα διανύσματα βαρών. Το νευρώνιο με το διάνυσμα βαρών πιο κοντά στο διάνυσμα εισόδου καλείται η καλύτερα ταιριασμένη μονάδα (Best Matching Unit-BMU). Τα βάρη του BMU και των

νευρωνίων της γύρω περιοχής (γειτονιάς), προσαρμόζονται σύμφωνα με το διάνυσμα εισόδου. Το μέγεθος των προσαρμογών μειώνεται με το χρόνο σιγά-σιγά και είναι φυσικά μικρότερο για νευρώνια μακριά από το BMU.

Εξυπακούεται ότι ο συγκεκριμένος αλγόριθμος δεν μπορεί να χρησιμοποιηθεί για επίλυση του προβλήματος που μελετούμε καθώς είναι περισσότερο αλγόριθμος ομαδοποίησης δεδομένων παρά αλγόριθμος για απόκτηση γνώσης.

2.3.3 Ενισχυτική Μάθηση


Η ενισχυτική μάθηση¹⁴ αναφέρεται σε μια κλάση προβλημάτων στα πληροφοριακά συστήματα όπου κάποιος πράκτορας εξερευνά ένα περιβάλλον, στο οποίο μπορεί και αντιλαμβάνεται την τρέχουσα κατάσταση του και εκτελεί κάποιες ενέργειες βάσει αυτής του της κατάστασης. Το περιβάλλον, σε αυτή τη περίπτωση, παρέχει μια ανταμοιβή στον πράκτορα, ανάλογα με την ενέργεια που εκτελεί, η οποία μπορεί να είναι θετική ή αρνητική. Η παρούσα μέθοδος εκμάθησης καλείται «εκμάθηση με κριτή» και είναι ο πιο φυσικός τρόπος μάθησης.

Οι αλγόριθμοι ενισχυτικής μάθησης προσπαθούν να βρουν μια πολιτική μεγιστοποίησης της συσσωρευτικής ανταμοιβής για τον πράκτορα κατά τη διάρκεια του προβλήματος. Για να αποκτήσει αρκετή θετική ανταμοιβή, ο πράκτορας πρέπει να προτιμά ενέργειες τις οποίες δοκίμασε στο παρελθόν και βρήκε να είναι αποτελεσματικές στην παραγωγή θετικής ανταμοιβής. Για να ανακαλύψει όμως τέτοιες ενέργειες, πρέπει να δοκιμάσει πράξεις που δεν επέλεξε ποτέ στο παρελθόν. Με λίγα λόγια, ο πράκτορας πρέπει να εκμεταλλευτεί το τι γνωρίζει για να αποκτήσει θετική ανταμοιβή, αλλά παράλληλα πρέπει να εξερευνήσει το περιβάλλον για να κάνει καλύτερη επιλογή ενεργειών στο μέλλον. Το δίλημμα έγκειται στο γεγονός ότι ούτε η εκμετάλλευση, ούτε η εξερεύνηση μπορούν να χρησιμοποιηθούν χωρίς μερική αποτυχία σε κάποιο στόχο. Ο πράκτορας πρέπει να δοκιμάζει μια ποικιλία από ενέργειες και σταδιακά να προτιμά αυτές που εμφανίζονται οι καλύτερες. Σε ένα στοχαστικό στόχο, κάθε ενέργεια πρέπει να δοκιμαστεί πολλές φορές για να αποκτηθεί μια αξιόπιστη

εκτίμηση της αναμενόμενης ανταμοιβής. Μπορούμε να πούμε ότι ο πράκτορας μαθαίνει αποκτώντας εμπειρία.

Η ενισχυτική μάθηση διαφέρει από την εκμάθηση με δάσκαλο στο γεγονός ότι τα ορθά ζευγάρια εισόδου-εξόδου (παραδείγματα), δεν παρουσιάζονται σε κανένα σημείο, ούτε οι μη-βέλτιστες ενέργειες διορθώνονται ρητά. Περαιτέρω, υπάρχει μια εστίαση στην on-line απόδοση, η οποία περιλαμβάνει την εύρεση μιας ισορροπίας μεταξύ εξερεύνησης (ανεξερεύνητου εδάφους) και εκμετάλλευσης (της τρέχων γνώσης).

Επιγραμματικά, μπορούμε να δούμε στο Σχήμα 2.6 το τί περιγράψαμε μέχρι στιγμής με λόγια.



Σχήμα 2.6 Ενισχυτική Μάθηση

Το περιβάλλον, όπως το έχουμε περιγράψει, παρέχει τις εισόδους στο δίκτυο, δέχεται την έξοδο και μεταδίδει ένα ενισχυτικό σήμα. Αναλαμβάνει το ρόλο του κριτή ο οποίος αξιολογεί τις ενέργειες του πράκτορα. Το σήμα δεν παρέχει την καλύτερη ενέργεια για να ακολουθηθεί, απλά αξιολογεί την συγκεκριμένη πράξη. Κάθε ενέργεια συσχετίζεται με μια ανταμοιβή/ποινή.

Στην διαδικασία υλοποίησης της ενισχυτικής μάθησης πρέπει να συμπεριλάβουμε την συνάρτηση αξίας (value function), η οποία καθορίζει τι είναι καλό σε βάθος χρόνου, ενώ η συνάρτηση ανταμοιβής (reward function) απλά δείχνει τι είναι καλό με κάποια ενδιάμεση έννοια για κάποιο δεδομένο χρονικό διάστημα.


Επίσης, κάθε συγκεκριμένη υλοποίηση πρέπει να έχει την πολιτική της, η οποία καθορίζει ποια ενέργεια ο πράκτορας πρέπει να πάρει σε κάθε σενάριο που μπορεί να συναντήσει. Περιγράφεται ως μια συνάρτηση που συσχετίζει την κατάσταση του περιβάλλοντος με την κάθε ενέργεια. Μπορεί να είναι άπληστη (greedy), μη-άπληστη (non-greedy) ή μπορεί να είναι ισορροπημένη (balanced), που πρόκειται για συνδυασμό εξερεύνησης και εκμετάλλευσης.

Συνοψίζοντας για τον συγκεκριμένο αλγόριθμο μπορούμε να πούμε ότι πρόκειται για μια εξαιρετικά προσαρμοστική (adaptive) ιδέα που πηγάζει από τον φυσικό τρόπο με τον οποίο μαθαίνουν να συμπεριφέρονται πολλά ζώα και σε ορισμένες περιπτώσεις και ο άνθρωπος. Ο πράκτορας (το δίκτυο αισθητήρων στην περίπτωση μας), δεν έχει καθόλου γνώση στην αρχή, αλλά με την πάροδο του χρόνου, με τη βοήθεια εξερεύνησης και εκμετάλλευσης, αρχίζει να αποκτά πείρα και γνώση. Φυσικά για να το πετύχει αυτό πρέπει να υπάρχει ένα περιβάλλον με πλήρη έλεγχο της κατάστασης, που να έχει την δυνατότητα να αξιολογεί κάθε πράξη του πράκτορα και να παρέχει ένα σήμα ανταμοιβής ή ποινής.

Ρίχνοντας μια ματιά στον συγκεκριμένο αλγόριθμο, μπορούμε να πούμε ότι υπάρχει προοπτική να χρησιμοποιηθεί για το πρόβλημα που προσπαθούμε να επιλύσουμε αλλά πρέπει να τροποποιηθεί κάπως ώστε να γίνει πιο προσαρμοστικός.

Ουσιαστικά το πρόβλημα συνοψίζεται στο γεγονός ότι το περιβάλλον πρέπει να έχει πλήρη επίγνωση της κατάστασης και να αξιολογεί συνεχώς τον πράκτορα και τις πράξεις του. Η αξιολόγηση αυτή είναι μια δύσκολη διαδικασία στην περίπτωση που ο πράκτορας είναι μια οντότητα με σύνθετες λειτουργίες. Τα πράγματα βελτιώνονται αισθητά στο σενάριο στο οποίο ο πράκτορας είναι ουσιαστικά ένα τεχνητό νευρωνικό δίκτυο (Artificial Neural Network -ANN). Σε αυτή την περίπτωση απλοποιείται ο ρόλος του περιβάλλοντος που πρέπει να αξιολογήσει σχετικά απλές λειτουργίες που επιτελούνται στην έξοδο ενός νευρωνικού δικτύου και με αυτό τον τρόπο πιθανώς να καθίσταται δυνατή η επίλυση ενός σημαντικού αριθμού από προβλήματα, στα οποία ζητείται προσαρμοστικότητα στο περιβάλλον.

Στο Σχήμα 2.7 βλέπουμε πώς τροποποιείται ο αλγόριθμος σε αυτή τη περίπτωση.



Σχήμα 2.7 Παραλλαγή Ενισχυτικής Μάθησης

Γενικά, ο αλγόριθμος «ενισχυτικής μάθησης» παρέχει ένα μεγάλο σύνολο από προσεγγίσεις και πιθανές μαθηματικές εφαρμογές που καλύπτουν ένα επίσης μεγάλο σύνολο από προβλήματα. Οι επιστήμονες που χρησιμοποιούν τον συγκεκριμένο αλγόριθμο πρέπει να έχουν βαθιά γνώση και εμπειρία του αντικειμένου λόγω ακριβώς της πολύπλοκης δομής και λειτουργίας του.

2.4 Η προσαρμοστικότητα γενικά

Δεδομένου ότι η κυριότερη πρόκληση στην διπλωματική αυτή εργασία αποτελεί η επίτευξη προσαρμοστικότητας από κάποιο δίκτυο αισθητήρων που βρίσκεται καταμετρημένο σε κάποια γεωγραφική περιοχή, θεωρήσαμε σημαντικό να συμπεριλάβουμε την έννοια της προσαρμοστικότητας ως θεωρητικό αντικείμενο στην εργασία μας και να εξηγήσουμε στον αναγνώστη τί ακριβώς σημαίνει.

Η προσαρμοστικότητα ως έννοια ορίζεται ως μια φυσιολογική διαδικασία ή ένα συμπεριφοριστικό γνώρισμα ενός οργανισμού που έχει εξελιχθεί κατά τη διάρκεια μιας μικρής ή μακρίας χρονικής περιόδου με τη διαδικασία της φυσικής επιλογής έτσι ώστε να αυξάνει την αναμενόμενη μακροπρόθεσμη παραγωγική επιτυχία του οργανισμού³. Στη φύση οι οργανισμοί που προσαρμόζονται στο περιβάλλον τους είναι σε θέση να λαμβάνουν τον αέρα, το ύδωρ, τα τρόφιμα και τις θρεπτικές

ουσίες, να αντιμετωπίζουν τις φυσικές καταστάσεις όπως τη θερμοκρασία, το φως και τη θερμότητα, να υπερασπίζονται από τους φυσικούς εχθρούς τους και να μπορούν να ανταποκρίνονται στις αλλαγές που συμβαίνουν γύρω τους.

Η προσαρμοστικότητα γενικά κατηγοριοποιείται σε δομική, συμπεριφοριστική ή φυσιολογική. Οι δομικές προσαρμογές είναι ειδικά μέρη του σώματος ενός οργανισμού που τον βοηθούν να επιζήσει στο φυσικό βióτοπό του (π.χ., χρώμα δέρματος, μορφή, σώμα που τον καλύπτει).



Σχήμα 2.8 Προσαρμοστικότητα στη Φύση

Οι συμπεριφοριστικές προσαρμογές είναι ειδικοί τρόποι με τους οποίους ένας οργανισμός συμπεριφέρεται για να επιζήσει στο φυσικό βióτοπό του. Οι φυσιολογικές προσαρμογές είναι συστήματα παρόντα σε έναν οργανισμό που του επιτρέπουν να εκτελέσει ορισμένες βιοχημικές αντιδράσεις (π.χ. έκκριση δηλητηρίου, διατήρηση μιας σταθερής θερμοκρασίας στο σώμα του).

Οι οργανισμοί που δεν κατορθώνουν να προσαρμοστούν κατάλληλα στο περιβάλλον τους είτε θα πρέπει να κινηθούν από το βióτοπο τους είτε πρόκειται να εξαλειφθούν σε βάθος χρόνου.

Κεφάλαιο 3

Περιγραφή Προβλήματος

3.1 Αναλυτική Περιγραφή Προβλήματος	20
3.2 Γενικά Προβλήματα.....	24
3.3 Συγκεκριμένα Προβλήματα	28

3.1 Αναλυτική Περιγραφή Προβλήματος

Αφού παρουσιάσαμε αναλυτικά την γενική θεωρία πίσω από τα δίκτυα αισθητήρων και τα νευρωνικά δίκτυα, αφού εφοδιάσαμε τον αναγνώστη με το αναγκαίο γνωστικό υπόβαθρο, ήρθε η στιγμή να περιγράψουμε αναλυτικά το πρόβλημα που προσπαθούμε να λύσουμε και την προσέγγιση που ακολουθούμε, μέσω ενός παραδειγματικού, δύσκολου περιβάλλοντος.

Θεωρούμε ως δεδομένη την ύπαρξη μιας δύσβατης, μεγάλης γεωγραφικά περιοχής, η οποία παρουσιάζει μεγάλες φυσικές ανωμαλίες καθιστώντας εξαιρετικά δύσκολη την πρόσβαση από κάποια ανθρώπινη ομάδα. Μια τέτοια περιοχή είναι και αυτή που εμφανίζεται στο Σχήμα 3.1.



Σχήμα 3.1 Δύσβατο Περιβάλλον

Στο αφιλόξενο αυτό περιβάλλον τοποθετούνται τυχαία (με ρίψη από αεροπλάνο ή με άλλο τρόπο) αισθητήρες, κάποιοι από τους οποίους έχουν την ικανότητα να μετρούν κάποια συγκεκριμένη ποσότητα όπως θερμοκρασία, υγρασία, κίνηση κ.α. ενώ κάποιοι άλλοι από αυτούς είναι απλά επιφορτισμένοι με την λειτουργία προώθησης και επεξεργασίας δεδομένων. Δεδομένου ότι κατανέμονται τυχαία στον χώρο, οι αισθητήρες αυτοί, διατηρούν μια τυχαία τοπολογία, καθιστώντας άγνωστο τον υπολογισμό εκ των προτέρων της αρχικής τους θέσης.

Στο σύνολο τους οι αισθητήρες αυτοί επικοινωνούν ασύρματα, έχουν όμως περιορισμένη κάλυψη στην μετάδοση τους. Επίσης λειτουργούν με μπαταρία, έτσι έχουν περιορισμένο χρόνο ζωής που κυμαίνεται από κάποιους μήνες μέχρι και μερικά χρόνια.

Το ασύρματο αυτό δίκτυο από αισθητήρες καλείται, σύμφωνα με τις προδιαγραφές μας, να μετατραπεί σε ένα νευρωνικό δίκτυο συγκεκριμένης μορφής και δομής, ώστε να αποκτήσει την ικανότητα επίλυσης κάποιου προβλήματος. Το πρόβλημα αυτό είναι άμεσα συνυφασμένο με τα φυσικά φαινόμενα τα οποία μετρούν οι αισθητήρες με την ικανότητα λήψης μετρήσεων (πηγές δεδομένων). Προβλήματα τέτοιας μορφής είναι ο υπολογισμός της πιθανότητας σεισμού, η αναγνώριση κάποιου συγκεκριμένου αντικειμένου ή

άλλης οντότητας στην περιοχή και η πρόβλεψη καιρικών φαινομένων όπως θερμοκρασίας, υγρασίας κ.α. Ανάλογα με την δυσκολία και την πολυπλοκότητα του προβλήματος, αυξάνεται γραμμικά και το μέγεθος του νευρωνικού δικτύου.

Ασφαλώς ένα υποσύνολο μόνο των αισθητήρων θα συμμετέχει στην δημιουργία του νευρωνικού δικτύου με τους υπόλοιπους απλά να συνυπάρχουν στον χώρο εκτελώντας άλλες ανεξάρτητες διεργασίες ή περιμένοντας να αντικαταστήσουν κάποιο γειτονικό αισθητήρα σε περίπτωση που κάποιος από αυτούς πεθάνει, δηλαδή μένει από μπαταρία.

Το ζητούμενο στην νευρωνική μορφολογία των αισθητήρων είναι να δημιουργήσουν ένα προσαρμοστικό σύστημα με ικανότητα εκμάθησης του δεδομένου προβλήματος και απόκτησης γνώσης από το περιβάλλον τους. Η νευρωνική αυτή δομή πρέπει να προσδίδει επίσης χαρακτηριστικά στο δίκτυο αισθητήρων όπως ευρωστία, χαμηλή κατανάλωση ενέργειας και ακεραιότητα των δεδομένων.

Δεδομένου ότι κύριο στοιχείο που επιζητούμε από το δίκτυο μας είναι η πλήρης προσαρμοστικότητα στο περιβάλλον του, χωρίς την ύπαρξη κάποιου εξωτερικού υπολογιστή ή άλλης μηχανής επόπτη, επιλέξαμε ως αλγόριθμο νευρωνικών δικτύων την εκμάθηση με κριτή, την οποία περιγράψαμε ενδελεχώς στο προηγούμενο κεφάλαιο.


Η εκμάθηση με κριτή ή καλύτερα η ενισχυτική μάθηση όπως λέγεται, προϋποθέτει την ύπαρξη ενός αισθητήρα στον ρόλο του περιβάλλοντος, με ικανότητα να μπορεί να αξιολογεί τα αποτελέσματα του τεχνητού νευρωνικού δικτύου όπως διαμορφώνεται από τους αισθητήρες της περιοχής. Ουσιαστικά στέλνει ένα μήνυμα αμοιβής στο επίπεδο εξόδου του δικτύου σε περίπτωση ορθής πρόβλεψης του προβλήματος που μελετάται και ένα μήνυμα ποινής σε περίπτωση λανθασμένης πρόβλεψης.

Ο αισθητήρας αυτός, παραμένει απλός, ώστε να μην αφαιρεθεί το χαρακτηριστικό της προσαρμοστικότητας από το μοντέλο μας. Το μόνο του αναγκαίο χαρακτηριστικό είναι να μπορεί να μετρά τα ίδια φυσικά φαινόμενα που μετρούν οι πηγές των δεδομένων. Γεωγραφικά ο αισθητήρας αυτός ενδείκνυται

να βρίσκεται κοντά στο επίπεδο εξόδου του νευρωνικού δικτύου ώστε να επικοινωνεί αποδοτικά με τα νευρώνια εξόδου.

Με την ίδια λογική οι πηγές των δεδομένων, οι αισθητήρες δηλαδή που αναλαμβάνουν τον ρόλο των νευρώνων εισόδου, ενδείκνυται να είναι τοποθετημένοι γεωγραφικά πλησίον ο ένας του άλλου ώστε να δημιουργήσουν μια αποτελεσματική δομή νευρωνικού δικτύου.

Στο Σχήμα 3.2 φαίνεται παραστατικά το μοντέλο, που περιγράψαμε με λόγια.



Σχήμα 3.2 Μοντέλο Νευρωνικού Δικτύου με χρήση Αισθητήρων

Παρατηρούμε στο Σχήμα 3.2 πώς σχηματίζονται τα επίπεδα, πώς διαχωρίζονται το ένα από το άλλο και με ποιο τρόπο επικοινωνούν μεταξύ τους. Φυσικά το Σχήμα 3.2 δείχνει ένα μόνο κρυφό επίπεδο, ενώ στην πραγματικότητα υπάρχουν δύσκολα προβλήματα τα οποία απαιτούν την ύπαρξη δύο επιπέδων. Περισσότερα από δύο επίπεδα κρίνονται ως πλεονάζων σε μια νευρωνική δομή, δεδομένου ότι, σύμφωνα με το θεώρημα Kolmogorov⁴, δύο επίπεδα είναι αρκετά για την επίλυση οποιουδήποτε μη γραμμικού προβλήματος.

Σε γενικές γραμμές, το πρόβλημα συνοψίζεται στο γεγονός οι αισθητήρες που βρίσκονται τυχαία κατανεμημένοι στον χώρο, καλούνται να ομαδοποιηθούν σε επίπεδα, ανάλογα και με τις ικανότητες τους (το επίπεδο εισόδου να αποτελείται από πηγές δεδομένων), ώστε να μετατραπούν σε ένα καλά ορισμένο γεωγραφικά, τεχνητό νευρωνικό δίκτυο.

3.2 Γενικά Προβλήματα

Δεδομένου ότι προσδιορίστηκε πλήρως το πρόβλημα που μελετούμε σε αυτή τη διπλωματική εργασία, πρέπει να μελετήσουμε κάποια γενικά προβλήματα που αντιμετωπίζουν τα δίκτυα αισθητήρων και τα νευρωνικά δίκτυα ώστε να μπορέσουμε, μέσα από την αντιμετώπιση του προβλήματος, να εξάγουμε κάποια συμπεράσματα σχετικά με το ποσοστό στο οποίο επιλύσαμε κάθε επί μέρους δυσκολία που αντιμετωπίζουν τα δίκτυα αυτά. Με λίγα λόγια, η παράθεση των προβλημάτων αυτών, σκοπό έχει να μας βοηθήσει στο τέλος να κρίνουμε αντικειμενικά το βαθμό στον οποίο επιλύσαμε την εργασία που μας ανατέθηκε σε όλους τους επί μέρους της τομείς.

Κατά την παράθεση των προβλημάτων αυτών αμέσως πιο κάτω, θεωρούμε ως δεδομένη την ύπαρξη της δομής που μελετούμε και εξετάζουμε τις δυσκολίες αυτές λαμβάνοντας πάντα υπόψη την προαναφερθέν δομή, η οποία σε κάποιες περιπτώσεις διευκολύνει και σε κάποιες δυσχεραίνει τα σενάρια που ελέγχουμε.

3.2.1 Δίκτυα Αισθητήρων

3.2.1.1 Συλλογή Δεδομένων και Επεξεργασία

Πολλή έρευνα γίνεται γύρω από το θέμα της συλλογής των δεδομένων σε ένα αισθητήρα, της επεξεργασίας των δεδομένων αυτών και της χρησιμοποίησης μόνο των αναγκαίων πληροφοριών ώστε να μεταδοθούν μόνο χρήσιμα στοιχεία και να μειωθεί η συνολική κίνηση (traffic) του δικτύου καθώς και το ποσό ενέργειας που καταναλώνει ο κόμβος κάθε φορά. Σε ένα εκπαιδευμένο

νευρωνικό δίκτυο δεν υπάρχει αυτό το πρόβλημα καθώς η γνώση του δικτύου βρίσκεται στα βάρη μεταξύ των αισθητήρων-νευρώνων, με αποτέλεσμα οι αισθητήρες να έχουν απλά το ρόλο της προώθησης των δεδομένων που παίρνουν από τις εισόδους τους.

3.2.1.2 Αξιοπιστία Δεδομένων

Λόγω της φύσης του ασύρματου δικτύου είναι φυσικό τα δεδομένα σε αρκετές περιπτώσεις να αλλοιώνονται ή και να χάνονται με αποτέλεσμα να δημιουργείται μια αναξιπιστία όσον αφορά την εγκυρότητα των πληροφοριών. Υπάρχουν φυσικά αλγόριθμοι που μειώνουν αυτή την πιθανότητα αλλά ασφαλώς προσθέτουν πολυπλοκότητα και βαρυφορτώνουν το δίκτυο διακίνησης των πληροφοριών. Στα νευρωνικά δίκτυα υπάρχει μεγαλύτερη αξιοπιστία λόγω της απλότητας των δεδομένων που διακινούνται ενώ υπάρχει μαθηματικά ορισμένο το σφάλμα σε κάθε νευρώνιο εξόδου με αποτέλεσμα να υπάρχει η ικανότητα καλύτερης αναγνώρισης της ορθότητας των πληροφοριών κάθε φορά.

3.2.1.3 Συντήρηση Λογισμικού

Σε ένα ασύρματο δίκτυο με ένα μεγάλο αριθμό από κόμβους, η ανανέωση του λογισμικού ή ο απομακρυσμένος προγραμματισμός (remote programming) των αισθητήρων είναι μια εξαιρετικά πολύπλοκη εργασία η οποία κρίνεται σε ένα τυχαίας κατανομής ασύρματο δίκτυο αμφίβολη έως και αδύνατη.

Παρ' όλα αυτά, δεδομένου ότι η λειτουργία ενός νευρωνικού δικτύου βασίζεται σε απλούς, τυποποιημένους αλγορίθμους, και λαμβάνοντας υπόψη ότι η γνώση του δικτύου αποθηκεύεται εσωτερικά στα βάρη μεταξύ των νευρώνων του δικτύου, η συντήρηση του λογισμικού περνά σε δεύτερη μοίρα στην προκειμένη περίπτωση.

3.2.2 Νευρωνικά Δίκτυα

3.2.2.1 Εκμάθηση Δικτύου

Είναι λεπτές οι ισορροπίες όσον αφορά την εκμάθηση σε ένα νευρωνικό δίκτυο. Υπάρχει ο κίνδυνος έλλειψης ικανοποιητικού αριθμού από παραδείγματα με αποτέλεσμα το δίκτυο να μην προλάβει να μάθει, ενώ από την άλλη υπάρχει και ο κίνδυνος το δίκτυο να τροφοδοτηθεί με τόσα πολλά παραδείγματα ώστε να παρουσιαστεί το φαινόμενο της «παπαγαλίας», δηλαδή το φαινόμενο στο οποίο το δίκτυο παύει να γενικεύει και ακολουθά πιστά τις διαδικασίες. Η συνάρτηση λάθους είναι ενδεικτική του πότε πρέπει να σταματά η εκμάθηση και πρέπει να λαμβάνεται σοβαρά υπόψη στη διαδικασία της μάθησης.

Επίσης μειονέκτημα αποτελεί το γεγονός ότι σε κάποιες περιπτώσεις το δίκτυο χρειάζεται πολύ μεγάλο αριθμό παραδειγμάτων για την εκπαίδευση του, κάτι που συνεπάγεται μεγάλο χρονικό διάστημα και κατανάλωση ενέργειας, που στις πλείστες των περιπτώσεων δεν προσφέρεται για την αποστολή που πρέπει να επιτελέσει.

Στο σενάριο που εξετάζουμε, δεδομένου ότι η εκμάθηση γίνεται ενισχυτικά, απουσιάζουν τα παραδείγματα με τα προβλήματα που προκαλούν, παραμένει όμως ο κίνδυνος το δίκτυο να χρειάζεται μεγάλο χρονικό διάστημα για να συγκλίνει με ότι αυτό συνεπάγεται για την λειτουργία του.

Στο πρόβλημα της υπέρ-εκμάθησης που αναλύσαμε πριν, τον ρόλο της παρακολούθησης της συνάρτησης λάθους μπορούν να αναλάβουν τα νευρώνια εξόδου, τα οποία πρέπει να είναι σε θέση να ενημερώνουν το δίκτυο πότε ενδείκνυται να σταματά η διαδικασία εκπαίδευσης.

3.2.2.2 Μαθηματικό Υπόβαθρο

Λαμβάνοντας υπόψη το γεγονός ότι τα νευρωνικά δίκτυα βρίσκονται ακόμη σε αναπτυξιακή διαδικασία, κάθε σενάριο και κάθε πρόβλημα πρέπει να αντιμετωπίζεται ξεχωριστά και ανεξάρτητα από τα άλλα, χωρίς κάποιες

ξεκάθαρες αρχές να μπορούν να ακολουθηθούν. Δεν υπάρχει πουθενά στον κόσμο αυτή τη στιγμή τεκμηρίωση που να δεικνύει ποιοι συγκεκριμένοι αλγόριθμοι είναι οι καλύτεροι να χρησιμοποιηθούν για γενικές περιπτώσεις προβλημάτων. Η έρευνα βασίζεται σχεδόν αποκλειστικά στον έλεγχο και στην προσομοίωση σεναρίων. Μετρικές όπως ο αριθμός των νευρωνίων στο δίκτυο, ο ρυθμός μάθησης ή ο αριθμός των κρυφών επιπέδων του νευρωνικού δικτύου πρέπει να αποφασιστούν μετά από επίπονη προσπάθεια και αρκετές προσομοιώσεις της κάθε υλοποίησης που μελετάται.

Γενικά η γνώση βασίζεται πάνω στην πείρα παρά την τεράστια πρόοδο που επιτελείται στον συγκεκριμένο τομέα. Αυτό το γεγονός φυσικά αποτελεί μεγάλο μειονέκτημα στην περίπτωση μας καθώς μας υπαγορεύει να ξοδέψουμε σημαντικό χρόνο στην προσπάθεια επίλυσης του προβλήματος μας σε προσομοιώσεις, παρατηρήσεις και συνεχείς μετρήσεις παραγόντων και μεταβλητών ώστε να εξαχθούν οι ορθές τιμές που θα δίνουν την ικανότητα στο δίκτυο μας να προσαρμόζεται στο περιβάλλον του.

3.2.2.3 Ευελιξία

Όπως παραθέσαμε στην διατύπωση του προβλήματος που εξετάζουμε, αναθέσαμε σε ένα back-propagation νευρωνικό δίκτυο τον ρόλο του πράκτορα στην «εκμάθηση με κριτή» προσέγγιση μας. Πρέπει όπως να λάβουμε υπόψη το γεγονός ότι σε γενικές γραμμές τα back-propagation δίκτυα χαρακτηρίζονται από στατικότητα και αδράνεια στην αλλαγή της δομής τους, ώστε να αδυνατούν από την μια στιγμή στην άλλη να αντιμετωπίσουν διαφορετικό πρόβλημα. Συγκεκριμένες τοπολογίες λύνουν συγκεκριμένα προβλήματα ενώ κάθε πρόβλημα προϋποθέτει και διαφορετική νευρωνική δομή.

Για παράδειγμα, στην περίπτωση που επιθυμούμε να υπολογίσουμε τις καιρικές συνθήκες σε κάποια περιοχή και χρησιμοποιούμε ένα αριθμό από αισθητήρες που μετρούν θερμοκρασία ή υγρασία πρέπει (ή μάλλον ενδείκνυται) να χρησιμοποιήσουμε κάποια συγκεκριμένη τοπολογία νευρωνίων. Στη περίπτωση που πρέπει να αλλάξουμε τη λειτουργία του νευρωνικού μας δικτύου ώστε να

υπολογίζει πλέον την ποσότητα νερού και υγρασίας σε μια περιοχή προφανώς πρέπει να αλλάξει και η τοπολογία μας.

Αυτό το γεγονός ασφαλώς δημιουργεί κάποιες δυσκολίες όσον αφορά το πρόβλημα της πλήρους προσαρμοστικότητας ενός νευρωνικού δικτύου σε κάποια γεωγραφική περιοχή και μας περιορίζει στην εξέταση ενός συγκεκριμένου σεναρίου σε κάθε περίπτωση.

Φυσικά η προσέγγιση μας αυτή είναι καθαρά θεωρητική διά τον λόγο ότι οι πηγές δεδομένων (data sources) σε κάποια περιοχή μάλλον εκ κατασκευής μετρούν κάτι συγκεκριμένο π.χ. κίνηση ή θόρυβο. Έτσι περιορίζεται εξ ορισμού η ζητούμενη ευελιξία.

3.2.2.4 Ύπαρξη Παραδειγμάτων

Ένα σοβαρό μειονέκτημα των νευρωνικών δικτύων και κυρίως του αλγορίθμου back-propagation είναι το γεγονός ότι χρειάζεται ένα σημαντικό αριθμό από παραδείγματα για την συνολική εκπαίδευση του νευρωνικού δικτύου. Αυτά τα παραδείγματα, όπως είδαμε και στην θεωρία, εισάγονται στο δίκτυο το ένα μετά το άλλο και το δίκτυο προχωρεί προς την επίλυση του προβλήματος συγκλίνοντας σιγά-σιγά. Αυτά τα παραδείγματα, στις πλείστες των περιπτώσεων χρειάζονται προ-επεξεργασία για να γίνουν κατανοητά από το δίκτυο. Είναι πασιφανές ότι η ανάγκη ύπαρξης παραδειγμάτων μειώνει σε σημαντικό βαθμό τον παράγοντα προσαρμοστικότητα.

Στην δική μας περίπτωση, καταφέραμε να αποφύγουμε την ανάγκη χρήσης έτοιμων παραδειγμάτων, με τη βοήθεια της «εκμάθησης με κριτή» προσέγγισης που αποφασίσαμε να ακολουθήσουμε.

3.3 Συγκεκριμένα Προβλήματα

Αφού μελετήσαμε διεξοδικά τις γενικές δυσκολίες που μπορούν να παρουσιαστούν σε δίκτυα της φύσης και δομής που μελετούμε, ήρθε η στιγμή να εξερευνήσουμε τα συγκεκριμένα και ειδικά προβλήματα που αντιστοιχούν στο

πρόβλημα μας και τα οποία θα συναντήσουμε στον δρόμο μας κατά την διάρκεια της απόπειρας μας να το επιλύσουμε. Είναι ασφαλώς αφελές να ισχυριστούμε ότι γνωρίζουμε από πριν κάθε δυσκολία που θα αντιμετωπίσουμε. Απλά παραθέτουμε και αναλύουμε τις μεγαλύτερες δυσκολίες που θα βρούμε στον δρόμο μας ώστε να είμαστε σε θέση να προχωρήσουμε λαμβάνοντας τις σοβαρά υπόψη και γνωρίζοντας εκ των προτέρων τους περιορισμούς και τις αδυναμίες μας.

Όπως και στην παράθεση των γενικών προβλημάτων έτσι και εδώ, θεωρούμε ως δεδομένη την ύπαρξη της δομής που μελετούμε και εξετάζουμε τις δυσκολίες αυτές λαμβάνοντας πάντα υπόψη την προαναφερθέν δομή, η οποία σε κάποιες περιπτώσεις διευκολύνει και σε κάποιες δυσχεραίνει τα σενάρια που ελέγχουμε.

3.3.1 Γεωγραφική Κατανομή

Το πρόβλημα της γεωγραφικής κατανομής αφορά το γεγονός ότι βρισκόμαστε σε ασύρματο περιβάλλον και η τοπολογία του χώρου μπορεί να μην ευνοεί την χρησιμοποίηση του δικτύου αισθητήρων ώστε να μετατραπεί σε ένα νευρωνικό δίκτυο. Φυσικά αυτή είναι η περίπτωση στην οποία το δίκτυο αισθητήρων είναι τυχαία κατανεμημένο στο χώρο, η κατανομή των αισθητήρων δεν είναι πυκνή (dense) στην περιοχή, ενώ έχουν σχετικά μικρή κάλυψη (coverage) για αποστολή δεδομένων, ο πομπός τους δηλαδή δεν καλύπτει μεγάλη περιοχή γεωγραφικά. Λαμβάνοντας υπόψη και το γεγονός ότι οι αισθητήρες εκ κατασκευής στην παρούσα τους μορφή έχουν περιορισμένη κινητικότητα (mobility), μειώνεται ακόμη περισσότερο η ευελιξία όσον αφορά την ικανότητα αποδοτικής κατανομής στον χώρο σύμφωνα με τις προδιαγραφές μας.

Στην καθόλου ακραία περίπτωση όπου το νευρωνικό δίκτυο δεν μπορεί να σχηματιστεί με την δεδομένη τοπολογία του δικτύου αισθητήρων σε κάποια περιοχή, μια σκέψη θα μπορούσε να είναι η δημιουργία ενός μικρότερης εμβέλειας νευρωνικού δικτύου, το οποίο ενδεχομένως να μπορούσε να λύσει το ζητούμενο πρόβλημα, σπαταλώντας κατά πάσα πιθανότητα περισσότερο χρόνο για να μάθει ή καλύτερα για να προσαρμοστεί στις απαιτήσεις του προβλήματος.

Μια πιο πρακτική θεώρηση στην πιο πάνω περίπτωση θα ήταν η ικανότητα κάθε αισθητήρα να παραστήσει περισσότερα από ένα νευρώνια ⁵ (που στην πραγματικότητα του αναλογούν σύμφωνα με τις προδιαγραφές που θέσαμε).

Φυσικά δεν πρόκειται να μελετήσουμε ένα τέτοιο σενάριο στο παρόν άρθρο, όμως η δυνατότητα αυτή υπάρχει και είναι εφαρμόσιμη σε κάποιες περιπτώσεις. Στο κάτω-κάτω στην περίπτωση που επιλέξουμε για την επίλυση του προβλήματος αισθητήρες με ικανότητα παροχής πολλαπλών μετρήσεων, πιθανότατα θα επιλέξουμε μια προσέγγιση πανομοιότυπη με την πιο πάνω.

3.3.2 Ομαδοποίηση

Ίσως η μεγαλύτερη πρόκληση στα δίκτυα αυτά, αποτελεί η επίλυση του προβλήματος της αποδοτικής ομαδοποίησης (clustering) των αισθητήρων μεταξύ τους ώστε να επιλύουν τις εργασίες που τους ανατίθενται. Στο σενάριο που εξετάζουμε είναι αναγκαίο το δίκτυο αισθητήρων μας, για να μπορέσει να μετατραπεί σε νευρωνικό δίκτυο να εφαρμόσει κάποιες ομαδοποιήσεις. Οι ομαδοποιήσεις αυτές λαμβάνουν χώρα εντός του πράκτορα και συγκεκριμένα του εσωτερικού back-propagation νευρωνικού δικτύου. Αυτές οι ομαδοποιήσεις αφορούν κυρίως τον σχηματισμό των αισθητήρων σε επίπεδα (layers), που ποικίλλουν σε μέγεθος και αριθμό ανάλογα με το πρόβλημα που πρέπει να επιλυθεί. Συνήθως πρέπει να γίνουν 3-4 ομαδοποιήσεις σε επίπεδα συνολικά, ενώ πάντα τηρείται η δομή ενός τεχνητού νευρωνικού δικτύου (επίπεδο εισόδου-κρυφό επίπεδο-επίπεδο εξόδου).

Επίσης επιθυμητό είναι οι ομάδες που θα δημιουργηθούν να τηρούν τις αναλογίες και τις κατευθύνσεις στο χώρο, δηλαδή τα δρομολόγια των πακέτων να οδεύουν προς τις δεξαμενές (sinks) μας, ενώ κάθε ομάδα-επίπεδο να κατανέμεται κάθετα σε σχέση με την έξοδο του νευρωνικού δικτύου.

Κάθε επίπεδο περιλαμβάνει ένα καθορισμένο αριθμό από αισθητήρες, που και αυτό εξαρτάται από το είδος του σεναρίου που εξετάζουμε. Πιο προβλέψιμοι είναι οι αριθμοί των ομάδων των επιπέδων εισόδου και εξόδου καθώς το επίπεδο εισόδου εξαρτάται αποκλειστικά από τον αριθμό πηγών δεδομένων (data


sources) που υπάρχουν, ενώ το επίπεδο εξόδου εξαρτάται, ανάλογα, από τον αριθμό εξόδων που εμείς ζητούμε από το νευρωνικό μας δίκτυο να εξάγει.

Για παράδειγμά αν λύνουμε το πρόβλημα σεισμού, ζητούμε στην έξοδο μόνο μια πιθανότητα, κάτι που μπορεί να παρασταθεί από ένα και μόνο αισθητήρα. Στην περίπτωση που κάνουμε αναγνώριση χαρακτήρων, μπορεί να χρειαστούμε μέχρι και 26 εξόδους, με την κάθε μια να αντιστοιχεί στο γράμμα που της αναλογεί (στο αγγλικό αλφάβητο).

Εξετάσαμε κατά την διάρκεια της μελέτης μας κάποιες τεχνολογίες και αλγόριθμους οι οποίοι προσφέρουν ικανότητες ομαδοποίησης στον χώρο των δικτύων αισθητήρων. Παρουσιάζουμε περιγραφικά τους πιο σημαντικούς και ιδανικούς για την περίπτωση μας από αυτούς.

3.3.2.1 Αλγόριθμος LEACH

Μια διαδεδομένη αρχιτεκτονική είναι η λεγόμενη Low-Energy Adaptive Clustering Hierarchy (LEACH)⁶. Στην LEACH οι αισθητήρες που βρίσκονται κοντά ο ένας με τον άλλο δημιουργούν μια ομάδα. Οι κόμβοι στην ομάδα στέλνουν τα δεδομένα τους στον αρχηγό της ομάδας (cluster-head), ο οποίος επιλέγεται αρχικά τυχαία και έχει την ευθύνη να στείλει αυτά τα δεδομένα στον κεντρικό σταθμό (base station) ή φυσικά στο επόμενο επίπεδο, όσον αφορά το δικό μας σενάριο και την νευρωνική μας δομή. Για να επεκτείνει τη ζωή του δικτύου, το LEACH επίσης πραγματοποιεί τυχαία περιστροφή των αρχηγών στις ομάδες, μεταξύ όλων των αισθητήρων που αποτελούν την συγκεκριμένη ομάδα, ώστε να μειώνεται σταδιακά η κατανάλωση ενέργειας ανά αισθητήρα. Χρησιμοποιείται ένα βασισμένο σε TDMA πρωτόκολλο MAC (Medium Access Control), που επιτυγχάνει τον συντονισμό των μεταδόσεων μέσα στην ομάδα. Η φιλοσοφία και λειτουργία του αλγορίθμου αυτού φαίνεται στο Σχήμα 3.3.




Σχήμα 3.3 Αλγόριθμος LEACH

3.3.2.2 Αλγόριθμος MINA/UNPF

Ένας άλλος αλγόριθμος, που φαίνεται να ταιριάζει αρκετά με το σενάριο που εξετάζουμε είναι ο αλγόριθμος MINA/UNPF. Πρόκειται για μια πολλαπλών κόμβων (multi-hop) αρχιτεκτονική βασισμένη σε δέντρα (tree-based), που χρησιμοποιεί επίπεδα με τρόπο πανομοιότυπο με τον τρόπο που λειτουργούν τα τεχνητά νευρωνικά δίκτυα. Στην αρχιτεκτονική αυτή, όλοι οι αισθητήρες του δικτύου που έχουν την ίδια απόσταση (σε κόμβους) από τον κεντρικό σταθμό (base station) ομαδοποιούνται σε ένα layer.

Στην γενική μορφή του αλγορίθμου, ο αριθμός των επιπέδων και ο αριθμός των κόμβων σε κάθε επίπεδο καθορίζεται από τη γεωγραφική κατανομή των αισθητήρων και την τοποθεσία του κεντρικού σταθμού. Για παράδειγμα όταν 100 αισθητήρες τοποθετηθούν τυχαία σε ένα 250x250 m πεδίο, ο MINA/UNPF θα δημιουργήσει 4-5 επίπεδα, αν ο κεντρικός σταθμός βρίσκεται στο κέντρο του πεδίου, και 8-9 επίπεδα αν ο κεντρικός σταθμός βρίσκεται σε κάποια από τις γωνίες. Το MAC πρωτόκολλο που χρησιμοποιείται βασίζεται σε Time-Division CDMA (TCDMA). Τα πακέτα διανέμονται από επίπεδο σε επίπεδο μέχρι να φτάσουν τον κεντρικό σταθμό.

Το Σχήμα 3.4 δείχνει ένα δίκτυο που αποτελείται από ένα κεντρικό σταθμό, 10 αισθητήρες και 3 κινητούς αισθητήρες (mobile sensors). Οι κινητοί αισθητήρες ασφαλώς δεν ταιριάζουν στην περίπτωση μας.



Σχήμα 3.4 Αλγόριθμος MINA/UNPF

Εξυπακούεται ότι ο MINA/UNPF ίσως είναι λιγότερο ενεργειακά αποδοτικός από τον LEACH αλλά είναι μάλλον πιο ιδανικός για την περίπτωση που εξετάζουμε.

3.3.3 Ευρωστία

Υπάρχει μεγάλη έρευνα όσον αφορά τον παράγοντα ευρωστία σε ένα δίκτυο αισθητήρων, σε συνδυασμό πάντα με την ανεκτικότητα του δικτύου σε λάθη, τα οποία μπορεί να προέρχονται από την μετάδοση των δεδομένων, από την κακή λειτουργία κάποιου αισθητήρα που παρακολουθεί και μετρά κάποιο γεγονός ή κάποια ποσότητα όπως θερμοκρασία, κίνηση κ.α. ή ακόμα και από την απώλεια ενός αριθμού από κόμβους του δικτύου λόγω έλλειψης ενέργειας ή λόγω φυσικής δυσλειτουργίας.

Στο σενάριο μας η ευρωστία εξασφαλίζεται εν μέρει από τη δομή που χρησιμοποιούμε και αυτό επειδή τα νευρωνικά δίκτυα έχουν ως ένα από τα μεγάλα τους πλεονεκτήματα την ευρωστία και την ανεκτικότητα σε λάθη. Αυτό ασφαλώς είναι απότοκο του κατανεμημένου περιβάλλοντος στο οποίο λειτουργούν. Μετρήσεις που γίνονται συνεχώς σε νευρωνικά δίκτυα δείχνουν ότι

το δίκτυο σε κάποιες περιπτώσεις μπορεί να λειτουργεί αποδοτικά, ακόμη και στη περίπτωση που χάσει μέχρι και το 20% των νευρώνων του. Αυτό το φαινόμενο ασφαλώς ισχύει και στον εγκέφαλο, όπου παρά το γεγονός ότι χάνουμε καθημερινά χιλιάδες νευρώνες, δεν επηρεάζεται (σε ένα φυσιολογικό άνθρωπο), ούτε στο παραμικρό η μνήμη του ή οι ανώτερες λειτουργίες του. Φυσικά στο σενάριο μας η απώλεια νευρώνων μεταφράζεται σε απώλεια αισθητήρων κυρίως λόγω του ότι μένουν από μπαταρία.

Η ικανότητα αντιμετώπισης λαθών είναι και αυτή εφικτή εκ κατασκευής από το νευρωνικό μας δίκτυο, καθώς στις μεταδόσεις μεταξύ των αισθητήρων, ανταλλάσσεται συνήθως μικρός αριθμός από float τιμές (έξοδοι νευρώνων και τιμές που διατηρούν στα βάρη τους), με αποτέλεσμα η πιθανότητα λάθους να είναι εξαιρετικά μικρή. Ακόμα και στη περίπτωση που μεταδοθεί λάθος τιμή σε κάποια σύνδεση (σύναψη στην νευρολογία), λόγω του γεγονότος ότι συμμετέχουν πολλοί νευρώνες στην παραγωγή του τελικού αποτελέσματος, το σφάλμα παραμένει στις πλείστες των περιπτώσεων ανεπαίσθητα χαμηλό.

Υπάρχουν κάποιες μελέτες στη συγκεκριμένη κατεύθυνση που εισηγούνται κάποιες μεθόδους ανίχνευσης λαθών σε κάποια σημεία και συνέχισης της λειτουργίας με χρήση κάποιας συνάρτησης που μειώνει το σφάλμα την τρέχων χρονική στιγμή⁷.

Μια επιτυχημένη προσέγγιση προς αυτή την κατεύθυνση, που αφορά όμως κυρίως δίκτυα αισθητήρων και όχι νευρωνικά δίκτυα, είναι η ομαδοποίηση των επιπέδων (ξεχωριστά) σε spanning trees, τα οποία μπορούν να κατασκευάσουν σταθερά και αξιόπιστα junction trees⁸. Η δομή αυτή, υπόσχεται ότι μπορεί να λύσει μια πλατιά κατηγορία από προβλήματα διαταραχών (inference problems) που αφορούν κυρίως δεδομένα που προέρχονται από πιθανότητες και συναθροίσεις (aggregations), όπως άλλωστε και τα δεδομένα που διακινούνται σε δίκτυα ανάλογα με αυτά που μελετούμε. Η αρχιτεκτονική αυτή ισχυρίζεται ότι είναι εύρωστη και στη παρουσία αποτυχίας στη μετάδοση δεδομένων ή και σε θάνατο κάποιου αισθητήρα. Η φιλοσοφία του αλγορίθμου είναι ότι γείτονες σε μια περιοχή μπορούν να ομαδοποιηθούν σε spanning trees με κάποιο αντιπρόσωπο εξ αυτών να αναλαμβάνει το ρόλο της ρίζας, ενώ όταν γίνει αυτό δημιουργείται

ένα junction tree, στο οποίο κάθε κόμβος έχει τοπικές πληροφορίες για ένα υποσύνολο των μεταβλητών του προβλήματος. Αναφέρουμε την προσέγγιση αυτή θεωρητικά για πιθανή χρήση από μελλοντικούς ερευνητές του συγκεκριμένου προβλήματος.

Στο συγκεκριμένο μοντέλο που εξετάζουμε, κριτήριο ευρωστίας αποτελεί η παρουσία του κριτή-περιβάλλοντος. Η παρουσία του κριτή ως ένας αισθητήρας με ικανότητες παρακολούθησης και καταμέτρησης ενός γεγονότος, αλλά και μετάδοσης συνολικής αξιολόγησης στο τεχνητό νευρωνικό δίκτυο, προϋποθέτει αξιόπιστη και σταθερή λειτουργία από τον συγκεκριμένο κόμβο. Αν υπολειπουργεί η χειρότερα πεθάνει κάποιο νευρώνιο εσωτερικά του τεχνητού νευρωνικού δικτύου, το δίκτυο το ίδιο έχει την ικανότητα να συνεχίσει αρκετά αξιόπιστα την λειτουργία του. Αν όμως πεθάνει ο συγκεκριμένος αισθητήρας, τότε μάλλον το μοντέλο παύει να λειτουργεί ολοκληρωτικά. Η υπόθεση αυτή ισχύει μόνο για την διαδικασία της εκμάθησης του δικτύου, καθώς μετά από αυτήν ο συγκεκριμένος αισθητήρας είναι άχρηστος για την λειτουργία του δικτύου. Οι ευθύνες του σταματούν μόλις το νευρωνικό δίκτυο αποκτήσει γνώση και συγκλίνει προς το πρόβλημα που του ανατέθηκε. Για τον λόγο αυτό ο συγκεκριμένος αισθητήρας πρέπει να επιλεγεί προσεκτικά και να πρόκειται για μια αξιόπιστη υπολογιστική μηχανή με αρκετά αποθέματα ενέργειας λειτουργίας.

Ίσως η εναλλακτική χρήση ενός αριθμού από αισθητήρες προσανατολισμένους για αυτή την εργασία να έλυνε το πρόβλημα καθώς στην περίπτωση που πέθαινε ο καθ' ύλη αρμόδιος αισθητήρας, θα μπορούσε, λίγο πριν, να έδινε τον έλεγχο σε κάποιον άλλο, παρόμοιο αισθητήρα. Αυτό φυσικά θα προϋπόθετε ίσως μετάδοση της πλήρους του κατάστασης στον νέο αισθητήρα όπως παραδείγματος χάριν ενός πίνακα πληροφοριών. Είναι μια λεπτομέρεια την οποία δεν πρόκειται να λάβουμε υπόψη κατά την μελέτη του προβλήματος.

3.3.4 Εξελισιμότητα

Περισσότερο για χάρη πληρότητας, αναφέρουμε το θέμα εξελισιμότητα στην έρευνα μας, για να σχολιάσουμε το γεγονός ότι το νευρωνικό μας δίκτυο,

παρουσιάζει εξελισιμότητα όσον αφορά τις ικανότητες του και αυτό είναι αδιαμφισβήτητο, δεν παρουσιάζει όμως εξελισιμότητα όσον αφορά τη δομή του και αυτό γιατί αφοτου το δίκτυο μας εκπαιδευτεί ώστε να αναγνωρίζει κάποιο πρόβλημα, πλέον δεν χρειάζονται άλλοι αισθητήρες υπό μορφή νευρώνων για να διευκολύνουν τη λειτουργία του. Δεν τίθεται θέμα ενσωμάτωσης σε ένα εκπαιδευμένο νευρωνικό δίκτυο περισσότερων νευρώνων για βελτίωση της λειτουργίας του διά τον λόγο ότι η γνώση αναπαρίσταται εσωτερικά του δικτύου υπό μορφή βαρών μεταξύ των νευρωνίων και μια πιθανή προσθήκη νευρώνα θα διατάραζε την αναπαράσταση του προβλήματος.

Η μόνη περίπτωση στην οποία πιθανόν να παρουσιαζόταν η ανάγκη ενσωμάτωσης επιπλέον νευρώνων είναι η περίπτωση στην οποία το δίκτυο δεν μπορεί να μάθει με την τρέχουσα του δομή και αναζητά και άλλους νευρώνες ώστε να διευρύνει τις ικανότητες του που αφορούν κυρίως επίλυση πιο σύνθετων μη-γραμμικών προβλημάτων. Φυσικά ισχύει και το ανάποδο, δηλαδή σε ένα δίκτυο όπου παρατηρείται το φαινόμενο της υπέρ-εκμάθησης (over-learning), όταν το δίκτυο πλέον αδυνατεί να γενικεύει, σε αυτή τη περίπτωση αφαιρούνται τυχαία νευρώνες ώστε να επιτευχθεί η ζητούμενη γενίκευση (generalization).

Υπάρχει η σκέψη προτου πεθάνει κάποιος αισθητήρας (πιθανώς λόγω έλλειψης ενέργειας) να μεταβιβάσει τη λειτουργία του σε κάποιο γειτονικό κόμβο, ο οποίος ίσως να μην συμμετέχει στο νευρωνικό δίκτυο, αλλά βρίσκεται στην περιοχή, σε ένα τυχαία κατανεμημένο δίκτυο.

3.3.5 Κατανάλωση Ενέργειας

Η κατανάλωση ενέργειας γενικά δεν αποτελεί ελεγχόμενη παράμετρο στα νευρωνικά δίκτυα λόγω κυρίως της κατανεμημένης τους δομής.

Σε ένα εκπαιδευμένο όμως νευρωνικό δίκτυο η κατανάλωση ενέργειας δεν είναι ανησυχητικά μεγάλη δεδομένου ότι μόνο οι υπολογισμοί κάθε νευρωνίου πρέπει να μεταδοθούν από αυτό το νευρώνιο, στα νευρώνια του επόμενου επιπέδου. Αυτοί οι υπολογισμοί παίρνουν την μορφή απλών float τιμών, έτσι τα

μεταδιδόμενα δεδομένα διατηρούν μικρό μέγεθος, διατηρώντας έτσι και την ενέργεια μετάδοσης (transmission energy) σε χαμηλά επίπεδα.

Παρ' όλα αυτά, τα πράγματα αλλάζουν στην διαδικασία της μάθησης όπου αυξάνεται αισθητά ο αριθμός της μετάδοσης δεδομένων, δεδομένου ότι σε κάθε επανάληψη εκμάθησης πρέπει να εκτελεστεί η διαδικασία προς τα μπροστά για τον υπολογισμό της τρέχουσας πιθανότητας και μετά προς τα πίσω ώστε να τροποποιηθούν οι τιμές των βαρών των νευρωνίων με ορθότερες τιμές.

Υπάρχει και η κατανάλωση ενέργειας που γίνεται κατά την επικοινωνία μεταξύ του πράκτορα και του περιβάλλοντος (στην δική μας περίπτωση) η οποία όμως περιορίζεται στην ανταλλαγή δύο απλών μηνυμάτων σε κάθε επανάληψη εκμάθησης στο δίκτυο μας και δεν είναι ανησυχητική.

Σε γενικές γραμμές η διαδικασία της εκμάθησης αποτελεί τον πιο σημαντικό παράγοντα κατανάλωσης ενέργειας σε ένα νευρωνικό δίκτυο γι' αυτό και πρέπει να αποφεύγονται δομές και προβλήματα που απαιτούν τεράστιο όγκο δεδομένων μέχρι κάποιο δίκτυο να εκπαιδευτεί.

Φυσικά το γεγονός της απλότητας των μεταδιδόμενων πακέτων σε συνδυασμό με το ότι οι μεταδόσεις γίνονται κατά κόρον σε γειτονικούς κόμβους (single-hop), χωρίς την ανάγκη πολύπλοκης δρομολόγησης των δεδομένων, καθιστά το μοντέλο μας αρκετά εύχρηστο όσον αφορά τον παράγοντα ενέργεια ακόμα και σε αυτή την περίπτωση στην οποία το νευρωνικό δίκτυο χρειάζεται μεγάλο αριθμό παραδειγμάτων και επαναλήψεων για να εκπαιδευτεί.

Υπάρχουν κάποια άρθρα στο διαδίκτυο, που εισηγούνται τεχνικές περιορισμού της κατανάλωσης ενέργειας με την βοήθεια ειδικών μεθόδων, όπως την μερική εκπαίδευση του νευρωνικού δικτύου σε κάποιους αισθητήρες μεγάλης υπολογιστικής ισχύς και μετά την κατανομή των αποτελεσμάτων σε λιγότερο ικανούς αισθητήρες. Αυτή η ιδέα, αν και ακραία, μειώνει την μετάδοση πακέτων σε πολύ σημαντικό βαθμό. Μια άλλη ιδέα είναι ο αποκλεισμός από τους υπολογισμούς (και από την μετάδοση δεδομένων αντίστοιχα), νευρωνίων που διατηρούν βάρη με τιμές κοντά στο μηδέν. Τα νευρώνια αυτά ελάχιστα επηρεάζουν μέσω των τιμών τους αυτών το τελικό αποτέλεσμα.

Τέλος μια τελευταία προσέγγιση για μείωση της ενέργειας αποτελεί και η υλοποίηση των αλγορίθμων ομαδοποίησης που μελετήσαμε σε προηγούμενο υποκεφάλαιο. Εκεί οι αισθητήρες που ανήκουν σε μια ομάδα-επίπεδο επικοινωνούν μόνο με τον ομαδάρχη, ο οποίος έχει αποκλειστικά την ευθύνη της προώθησης των δεδομένων στο επόμενο επίπεδο ή στην έξοδο.

3.3.6 Συγχρονισμός

Ένα ακόμη εμπόδιο που εμφανίζεται στην προσέγγιση μας, είναι το θέμα του συγχρονισμού των αισθητήρων στα επίπεδα του νευρωνικού δικτύου, καθώς και των επιπέδων μεταξύ τους. Δεδομένου ότι πρόκειται για feed-forward δίκτυα (με κατανομημένη φυσικά δομή) το πρόβλημα απλοποιείται, δεδομένου ότι δεν χρειάζεται η ύπαρξη πολύπλοκων ομαδοποιήσεων μεταξύ των κόμβων, ούτε ακριβείς global συγχρονισμοί μεταξύ των ρολογιών των νευρωνίων του δικτύου.

Το πρόβλημα στην περίπτωση μας περιορίζεται στο γεγονός ότι οι πηγές δεδομένων πρέπει να μετράνε τιμές σε τακτά χρονικά διαστήματα, να τις στέλνουν feed-forward στο επόμενο επίπεδο, και το επόμενο επίπεδο μόνο αφού αντιληφθεί ότι όλοι οι νευρώνες που το αποτελούν έχουν ενημερωθεί-ανανεωθεί, να προωθεί τα αποτελέσματα στο επόμενο, στην νευρωνική δομή, επίπεδο.

Η λειτουργία αυτή που επιτελούν τα νευρωνικά δίκτυα μας βοηθά να περιορίσουμε το θέμα συγχρονισμού στη μορφή μηνυμάτων και να μην περιπλέξουμε τα πράγματα συγχρονίζοντας τα ρολόγια των νευρώνων, globally ή locally.

Εξάλλου, πιθανότατα εκ κατασκευής, το δίκτυο μπορεί να είναι προγραμματισμένο να προωθεί δεδομένα μόνο στη περίπτωση που οι πηγές δεδομένων μετρήσουν κάτι το ασυνήθιστο ή το διαφορετικό σε σχέση με την κατάσταση του περιβάλλοντος. Με λίγα λόγια θα περιοριστούμε στο θέμα συγχρονισμός στο ούτως καλούμενο ασύγχρονο συγχρονισμό (asynchronous timing) και θα δώσουμε βάση σε μια event-triggered προσέγγιση.

Οι περισσότεροι αλγόριθμοι και υλοποιήσεις που βρίσκονται στο διαδίκτυο ασχολούνται με *global synchronous timing constraints*, χωρίς να δίνουν βάρος στην περίπτωση που εξετάζουμε.

Μια πολύ πιθανή υλοποίηση την οποία προτείνουμε, η οποία λύνει αρκετά απλά και γραμμικά το πρόβλημα, είναι η ανάθεση σε ένα νευρώνιο κάθε επιπέδου (που μπορεί ήδη να είναι επιλεγμένο από τον αλγόριθμο ομαδοποίησης που θα χρησιμοποιηθεί) να έχει την ευθύνη της συλλογής από όλους τους αισθητήρες του επιπέδου, των τιμών και μετρήσεων τους, και της προώθησης (αφού βεβαιωθεί ότι έλαβε τις τιμές από όλους) στο επόμενο επίπεδο ή στην έξοδο αν πρόκειται για το επίπεδο εξόδου. Σε αυτή την ενδεχόμενη υλοποίηση μόνο δύο κόμβοι χρειάζεται να επικοινωνήσουν μεταξύ επιπέδων (μήνυμα δεδομένων και μήνυμα αναγνώρισης), ενώ η έγκυρη προώθηση των δεδομένων εξασφαλίζεται σε μεγάλο βαθμό.

Ο συγχρονισμός επιτυγχάνεται στους υπεύθυνους νευρώνες, καθώς μόνο όταν έχουν πλήρη στοιχεία προωθούν τα δεδομένα τους. Αμέσως το επόμενο επίπεδο γνωρίζει ότι δέχτηκε δεδομένα από το προηγούμενο και με αυτό το τρόπο η *feed-forward* λειτουργία του δικτύου εξασφαλίζεται.

Είναι σημαντικό να τονιστεί εδώ ότι στην διαδικασία της μάθησης, μόλις τα δεδομένα φτάσουν στο επίπεδο εξόδου, πρέπει να σταλούν στον αισθητήρα που ανάλαβε τον ρόλο του περιβάλλοντος. Μόνο αφού το περιβάλλον αξιολογήσει τα αποτελέσματα και στείλει πίσω ένα *feedback* μήνυμα, ξεκινά η διαδικασία της προσαρμογής των βαρών εσωτερικά του τεχνητού νευρωνικού δικτύου.

Φυσικά το ίδιο ισχύει και στην περίπτωση της *backward* μάθησης. Το επόμενο επίπεδο μέσω κάποιου υπεύθυνου αισθητήρα στέλνει τα δεδομένα στο προηγούμενο επίπεδο σε κάποιο αντίστοιχο υπεύθυνο κόμβο, ο οποίος με τη σειρά του ενημερώνει τους κόμβους του επιπέδου στο οποίο ανήκει. Για να πετύχει αυτή η προσέγγιση πρέπει ο υπεύθυνος αυτός νευρώνας να μπορεί να επικοινωνεί αποτελεσματικά με τους αισθητήρες του επιπέδου του (να βρίσκεται σε ιδανικό γεωγραφικά σημείο) και να έχει την ικανότητα να αντιλαμβάνεται την περίπτωση στην οποία κάποιος κόμβος παρουσιάσει αποτυχία (*failure*), και να

τον αντικαθιστά με κάποιο άλλο, που βρίσκεται στο γύρω περιβάλλον ή να συνεχίζει τη λειτουργία του νευρωνικού δικτύου χωρίς αυτόν.

3.3.7 Ακεραιότητα Δεδομένων

Η ακεραιότητα των δεδομένων είναι ένα γενικό πρόβλημα που αντιμετωπίζουν τα ασύρματα δίκτυα στο σύνολο τους και αφορά κυρίως χάσιμο πακέτων ή αλλαγή των δεδομένων κατά την αποστολή από κόμβο σε κόμβο. Αυτό φυσικά είναι απότοκο του ασύρματου περιβάλλοντος και των ανωμαλιών που υπάρχουν στην περιοχή.

Στην περίπτωση που εξετάζουμε, εξασφαλίζεται κάπως η ακεραιότητα των δεδομένων καθώς δεν έχουμε, γενικά, δρομολόγηση πολλαπλών κόμβων (multi-hop routing) αλλά απευθείας επικοινωνία μεταξύ των αισθητήρων. Επίσης, όπως προαναφέραμε, η δομή των μεταδιδόμενων πακέτων και το περιεχόμενό τους, καθιστά εκ κατασκευής το δίκτυο ανθεκτικό σε τέτοιου είδους λάθη.

3.3.8 Ανακάλυψη Γνώσης

Αφήσαμε τον συγκεκριμένο παράγοντα τελευταίο, δεδομένου ότι η ανακάλυψη γνώσης και η προσαρμοστικότητα αποτέλεσαν το έναυσμα για να ασχοληθούμε με την συγκεκριμένη διπλωματική εργασία.

Ως βασική προδιαγραφή στην εργασία μας, δηλώσαμε την ανάγκη δημιουργίας ενός ασύρματου δικτύου αισθητήρων με ικανότητα εκπαίδευσης και προσαρμογής στο πρόβλημα που προσπαθεί το δίκτυο να επιλύσει.

Ένα τέτοιο δίκτυο, με ικανότητες άντλησης γνώσης από το περιβάλλον του, αναζητούμε να υλοποιήσουμε και αποτελεί πραγματική πρόκληση η προσπάθειά μας αυτή δεδομένης της πρωτοτυπίας της έρευνας αυτής.

Το γεγονός ότι το τεχνητό νευρωνικό δίκτυο, που αναλαμβάνει το ρόλο του πράκτορα στην προσέγγισή μας, δεν χρειάζεται ένα μεγάλο αριθμό από προεπεξεργασμένα δεδομένα για να μάθει, αλλά μαθαίνει απλά μέσω της

αξιολόγησης των μετρήσεων που συμβαίνουν σε ένα αισθητήρα-παρατηρητή, μας γεμίζει με αισιοδοξία ότι βρισκόμαστε στον ορθό δρόμο.

Μια πιθανή επιτυχία στην αντιμετώπιση του προβλήματος, θα έδινε μεγάλη ώθηση στο μοντέλο μας για περαιτέρω εξερεύνηση και μελέτη και ίσως θα άλλαζε τον τρόπο σκέψης σε παρόμοια μη γραμμικά προβλήματα που απαιτούν προσαρμοστικότητα από το δίκτυο που καλείται να τα επιλύσει.

Δυστυχώς, μέχρι πρόσφατα, τα νευρωνικά δίκτυα απαιτούν ακριβές μεθόδους (σε υπολογισμούς, ενέργεια και κόστος) για απόκτηση γνώσης. Ισχυριζόμαστε ότι είναι δυνατό το μοντέλο μας να προσδώσει προσαρμοστικότητα στο δίκτυο με λιγότερη χρήση των διαθέσιμων πόρων.

Κεφάλαιο 4

Αξιολόγηση Απόδοσης

4.1 Αποδεικτική Μέθοδος.....	42
4.2 Σκοπός της Προσομοίωσης	43
4.3 Σύγκριση με άλλους Προσομοιωτές	45
4.4 Περιγραφή Σεναρίου	46
4.5 Μαθηματικός Συλλογισμός.....	48
4.6 Υποθέσεις και Περιορισμοί.....	52
4.7 Επιλογή Αισθητήρων	54
4.8 Δομή Νευρωνικού Δικτύου	58
4.9 Προ-επεξεργασία	68

4.1 Αποδεικτική Μέθοδος

Η φύση και η δομή του προβλήματος καθιστούν την χρήση μαθηματικού μοντέλου για την επίλυση του αδύναμη. Το πολύπλοκο μαθηματικό υπόβαθρο των νευρωνικών δικτύων και της «εκμάθησης με κριτή» συγκεκριμένα, σε συνδυασμό με το κατανεμημένο περιβάλλον στο οποίο λειτουργούν οι αισθητήρες, με τις ανωμαλίες που διακρίνουν το περιβάλλον λειτουργίας τους, μας υποχρεώνουν να αναζητήσουμε την επίλυση του προβλήματος μέσω κάποιας προσομοίωσης.

Στην επιστημονική κοινότητα άλλωστε, στον χώρο των πληροφοριακών συστημάτων, τα πλείστα προβλήματα εκμάθησης επιλύονται και αποδεικνύονται με χρήση μοντελοποίησης και προσομοίωσης.

Φυσικά η χρήση προσομοίωσης μέσω ενός συγκεκριμένου προγράμματος καθορίζει ως αναγκαστική τη παρουσία υποθέσεων και περιορισμών στην προγραμματιστική κατασκευή του μοντέλου ενώ ελλοχεύει ο κίνδυνος να απουσιάσει η γενίκευση δεδομένου ότι το συγκεκριμένο πρόγραμμα θα είναι σχεδιασμένο για να επιλύει συγκεκριμένο σενάριο-στιγμιότυπο του προβλήματος, με συγκεκριμένες τιμές και μετρήσεις.

Για τον λόγο αυτό κατά τον σχεδιασμό του προσομοιωτή ενδείκνυται σε κάθε σημείο να γίνεται γενική και ολική προσέγγιση στο θέμα, έχοντας στο μυαλό μας το συνολικό πρόβλημα που πρέπει να επιλύσουμε και όχι κάποια ειδική του περίπτωση.

Προσπάθεια γίνεται ώστε οι υποθέσεις και οι περιορισμοί να περιοριστούν στο ελάχιστο ώστε η προσομοίωση να πλησιάζει το μεγαλύτερο δυνατό βαθμό την πραγματικότητα. Ο ενδεδειγμένος σχεδιασμός του προσομοιωτή μειώνει και την πιθανή μελλοντική εργασία που ενδέχεται να χρειάζεται να γίνει από τον γράφοντα σε περίπτωση συνέχισης της συγκεκριμένης διπλωματικής εργασίας.

Πρέπει να τονιστεί ότι η επιτυχής χρήση του προσομοιωτή σε ένα αριθμό από σενάρια αποτελεί ικανή αλλά όχι αναγκαία συνθήκη για την γενική επίλυση οποιουδήποτε προβλήματος που εμπίπτει στην συγκεκριμένη κατηγορία προβλημάτων. Θα αποτελέσει όμως ένα ισχυρό παράγοντα ο οποίος θα συνηγορεί ότι το μοντέλο είναι όντως επιτυχές και ότι η συγκεκριμένη προσέγγιση είναι εφαρμόσιμη σε προβλήματα που αναζητούν προσαρμοστικότητα και άντληση γνώσης από το περιβάλλον.

4.2 Σκοπός της Προσομοίωσης

Αφού αποφασίστηκε η προσομοίωση ως αποδεικτική μέθοδος στην διεκπεραίωση της διπλωματικής αυτής εργασίας, πρέπει να καταγραφούν και οι στόχοι του υπό μελέτη προσομοιωτή καθώς και οι συγκεκριμένοι σκοποί τους οποίους πρέπει να εξυπηρετεί.

Ο γενικός σκοπός του προσομοιωτή είναι ασφαλώς η όσο γίνεται πιο ακριβής προσομοίωση του μοντέλου που περιγράψαμε στο κεφάλαιο «Περιγραφή

Προβλήματος». Η προσομοίωση αυτή πρέπει να παρέχει στον χρήστη την ικανότητα ανά πάσα στιγμή να γνωρίζει το γνωστικό επίπεδο του δικτύου αισθητήρων-νευρωνικού δικτύου και τον βαθμό κατανόησης-σύγκλισης στο πρόβλημα που του παρουσιάζεται. Ο καλύτερος τρόπος για επίτευξη του σκοπού αυτού είναι ο υπολογισμός του σφάλματος σε κάθε επανάληψη παραδείγματος εκμάθησης, κάθε φορά δηλαδή που οι πηγές δεδομένων μετρούν κάποιο φυσικό φαινόμενο και το στέλνουν στο υπόλοιπο δίκτυο για μελέτη και εκμάθηση. Η αποθήκευση του σφάλματος αυτού σε αρχείο σε συνδυασμό με τον τρέχων αριθμό επανάληψης είναι ικανά να δώσουν μια ακριβή εικόνα της συμπεριφοράς του δικτύου κατά την φάση της εκμάθησης.

Σε μετέπειτα φάση, ο προσομοιωτής, πρέπει να τροποποιηθεί μερικώς ώστε να μπορεί να μοντελοποιήσει την λειτουργία του δικτύου αφού ολοκληρώσει, θεωρητικά, την διαδικασία της εκμάθησης και κατανοήσει-αναπαραστήσει στις εσωτερικές του δομές το πρόβλημα που του παρουσιάστηκε. Σε αυτή τη φάση πρέπει να είναι σχεδιασμένος ώστε να μπορεί να αποθηκεύει σε αρχείο το σφάλμα λειτουργίας για κάθε στιγμιότυπο υπολογισμού-πρόβλεψης.

Η αναπαράσταση των αισθητήρων πρέπει να πλησιάζει-προσεγγίζει πραγματική λειτουργία αισθητήρων και να βασίζεται σε πραγματικές μετρικές συγκεκριμένων μοντέλων αισθητήρων, ώστε να μπορούν να προσομοιωθούν αποτελεσματικά και ρεαλιστικά, παράγοντες όπως κατανάλωση ενέργειας και ευρωστία.

Ο προσομοιωτής αυτός πρέπει να είναι σχεδιασμένος ώστε να είναι ικανός να αναπαραστήσει οποιαδήποτε τοπολογία νευρωνικού δικτύου. Αναφερόμαστε στο τεχνητό νευρωνικό δίκτυο με τον ρόλο του πράκτορα στο μοντέλο που μελετούμε καθώς το άλλο μέρος της «εκμάθησης με κριτή» προσέγγισης, το περιβάλλον, δεν χρήζει γενικής αναπαράστασης.

Επίσης στα πλαίσια της αναπαράστασης οποιασδήποτε νευρωνικής δομής πρέπει να υπάρχει η πρόνοια επιλογής του επιθυμητού αριθμού πηγών δεδομένων, που έχουν τον παράλληλο ρόλο του επιπέδου εισόδου στο μοντέλο μας. Αυτή η ικανότητα θα μας δίδει την επιλογή χρήσης οποιουδήποτε σετ δεδομένων εκμάθησης του νευρωνικού μας δικτύου. Αν και η ενισχυτική μάθηση δεν προϋποθέτει την ύπαρξη παραδειγμάτων, όπως προαναφέραμε στο

κεφάλαιο «Θεωρία», εν τούτοις οι πηγές δεδομένων πρέπει από κάπου να αντλούν τα δεδομένα που καταμετρούν στους αισθητήρες τους, είτε αυτοί μετρούν θερμοκρασία, είτε κίνηση ή οτιδήποτε άλλο φυσικό φαινόμενο.

Παράγοντες εκμάθησης σε νευρωνικά δίκτυα back-propagation όπως ο ρυθμός μάθησης, η κλίση της σιγμοειδούς συνάρτησης, η αρχική τιμή του κατωφλίου (bias) και το momentum πρέπει να παρέχονται και να μπορούν να τροποποιούνται εύκολα από τον χρήστη του προσομοιωτή ώστε να διευκολύνεται η εκτέλεση διαφορετικών σεναρίων.

Οι σχεδιαστικές αυτές επιλογές θα μας προσφέρουν την ικανότητα να πειραματιστούμε με τον προσομοιωτή μας σε πολλές διαφορετικές τοπολογίες νευρωνικών δικτύων ώστε να επιλέγεται κάθε φορά η καλύτερη για το συγκεκριμένο σενάριο που επιλέγεται. Επίσης θα θέτει τον προσομοιωτή μας ως ένα γενικό εργαλείο χρήσης από επιστήμονες στον χώρο των υπολογιστών, σε παρόμοια προβλήματα που πιθανόν να παρουσιαστούν στο μέλλον και υπαγορεύουν επίλυση με μέθοδο παρόμοια με την προσέγγιση που ακολουθούμε.

4.3 Σύγκριση με άλλους Προσομοιωτές

Στο εμπόριο και φυσικά στο διαδίκτυο υπάρχουν αρκετοί έτοιμοι προσομοιωτές που προορίζονται και χρησιμοποιούνται για προσέγγιση διαφόρων δικτύων υπολογιστών⁹. Ωστόσο οι περισσότεροι από αυτούς αδυνατούν να προσφέρουν προσομοίωση δικτύων με αισθητήρες καθώς πρόκειται για συγκεκριμένες υπολογιστικές μηχανές μικρού μεγέθους που εργάζονται με ένα ιδιαίτερο λειτουργικό σύστημα (tinyOS). Στην κατηγορία αυτή εμπίπτουν και «τέρατα» προσομοίωσης στον χώρο των δικτύων όπως είναι ο Opnet Modeler¹⁰ και ο ModelSim¹¹ της MatLab.

Πολλοί άλλοι προσομοιωτές που χρησιμοποιούνται ευρέως στο χώρο όπως είναι ο NS-2¹² και ο TOSSIM¹³ δεν παρέχουν γραφικό περιβάλλον αλλά στηρίζονται στις προγραμματιστικές ικανότητες του χρήστη παρέχοντας ουσιαστικά μόνο το υπόβαθρο προσομοίωσης δικτύων αισθητήρων.

Δοκιμάσαμε επίσης κάποιους άλλους προσομοιωτές, μικρότερου βεληνεκούς από τους προαναφερθέντες, χωρίς τα επιθυμητά αποτελέσματα.

Καταλήξαμε έτσι στο συμπέρασμα ότι, η καλύτερη και ίσως η μοναδική οδός για το συγκεκριμένο μοντέλο που προτείνουμε, είναι η κατασκευή του δικού μας προσομοιωτή, ταιριασμένου ακριβώς στις ανάγκες μας και φυσικά με πλήρη επίγνωση και έλεγχο της κατάστασης σε κάθε φάση του σχεδιασμού, της υλοποίησης και της λειτουργίας του δικτύου.

Κατά τα άλλα η ανάπτυξη ενός προσομοιωτή από το μηδέν, αποτελεί από μόνο του μια πρόκληση για τον γράφοντα, δεδομένου ότι η χρήση ενός έτοιμου προσομοιωτή μειώνει γενικά την συνεισφορά προς την φοιτητική κοινότητα όσον αφορά την μελέτη του συγκεκριμένου προβλήματος.

Αναμφίβολα η πιθανότητα ταυτόχρονης λειτουργίας του δικού μας προσομοιωτή και ενός τρίτου για σύγκριση αποτελεσμάτων αποτελεί ιδανικό τρόπο διεκπεραίωσης της διπλωματικής αυτής εργασίας, αλλά δυστυχώς η απουσία γραφικού περιβάλλοντος ανάπτυξης στα δίκτυα αισθητήρων από τρίτους εξάλειψε αυτό το, ίσως ιδανικό, ενδεχόμενο.

4.4 Περιγραφή Σεναρίου

Παρά το γεγονός ότι επιδίωξη μας είναι η χρήση και η λειτουργία του μοντέλου σε γενικές συνθήκες λειτουργίας ενός δικτύου αισθητήρων και παρά το γεγονός ότι ο προσομοιωτής είναι σχεδιασμένος ώστε να μπορεί να επιλύσει οποιαδήποτε γενική περίπτωση, εν τούτοις είναι ανάγκη να συγκεκριμενοποιήσουμε το πρόβλημα που ζητείται να επιλυθεί σε κάποιο καθορισμένο σενάριο, που θα παραμένει όμως αρκετά γενικό, ώστε να μπορεί να αντιστοιχηθεί σε άλλες περιπτώσεις παρόμοιων προβλημάτων προσαρμοστικότητας που μπορεί να απαιτούν παρόμοια προσέγγιση επίλυσης.

Το σενάριο αυτό πρέπει να είναι αντιπροσωπευτικό της ιδέας την οποία μελετούμε και να είναι εμπνευσμένο από ρεαλιστικά προβλήματα που πιθανόν να αντιμετωπίζονται από επιστήμονες αυτή τη στιγμή σε κάποιο σημείο του πλανήτη.

Για το σκοπό αυτό και δεδομένης της ανάγκης επιλογής ενός σεναρίου που πραγματικά αναδεικνύει τις ικανότητες των νευρωνικών δικτύων όσον αφορά τον παράγοντα προσαρμοστικής εκμάθησης ενός προβλήματος, επιλέξαμε να προσομοιώσουμε το σενάριο πρόβλεψης θερμοκρασίας, σύμφωνα με τις υπάρχουσες τοπικές μετρήσεις που γίνονται σε κάποια συγκεκριμένη γεωγραφική περιοχή. Η πρόβλεψη αυτή πρέπει να γίνεται για κάποιο μελλοντικό χρονικό διάστημα, διάρκειας μιας ώρας μετά τις μετρήσεις που λαμβάνουν χώρα στις πηγές εισόδου. Η επιλογή του χρονικού διαστήματος της μιας ώρας δεν είναι τυχαία, καθώς ο αριθμός αυτός δίνει την δυνατότητα στο δίκτυο να εκπαιδευτεί σε ένα λογικό χρονικό περιθώριο (ίσως κάποιες εβδομάδες) και επίσης, σε περίπτωση επιτυχίας της προσέγγισης μας, παρέχει στην επιστημονική κοινότητα ένα χρήσιμο εργαλείο με πολλές πιθανές εφαρμογές στην βιομηχανία και αλλού, π.χ. σε έλεγχο με αισθητήρες του κλιματιστικού συστήματος ενός εργοστασίου με πρόβλεψη, για κάποιο καθορισμένο χρονικό διάστημα ή για τον έλεγχο της παραγωγής ηλεκτρικής ενέργειας προορισμένης για θερμότητα σε κάποιο ηλεκτροπαραγωγό σταθμό.

Ουσιαστικά θεωρούμε, όπως και στην γενική περιγραφή του προβλήματος, μια δύσβατη περιοχή στην οποία τοποθετούνται αισθητήρες, κατανεμημένοι τυχαία στον γεωγραφικό χώρο της περιοχής. Η τοποθέτηση τους μπορεί να γίνει με ρίψη από αεροπλάνο ή με άλλο τρόπο. Κάποιοι από αυτούς έχουν την ικανότητα να μετρούν θερμοκρασία (temperature), υγρασία (humidity) και φως (light) ενώ κάποιοι από αυτούς έχουν την ικανότητα απλά να επεξεργάζονται και να προωθούν δεδομένα με ασύρματη μετάδοση (κάτι που μπορούν να κάνουν και οι πρώτοι φυσικά). Οι αισθητήρες με ικανότητα μέτρησης των καιρικών αυτών φαινομένων χρησιμοποιούνται στο μοντέλο μας ως οι πηγές δεδομένων ή καλύτερα το επίπεδο εισόδου στο νευρωνικό μας δίκτυο. Ουσιαστικά χρησιμοποιούνται στην προσέγγιση μας για την μέτρηση φωτός και υγρασίας, διότι οι μετρήσεις φωτός κρίνονται ως αναξιόπιστες, δεδομένου ότι δεν επηρεάζουν σχεδόν καθόλου τις μελλοντικές προβλέψεις θερμοκρασίας.

Το συγκεκριμένο πρόβλημα του σεναρίου, εστιάζεται στην προσαρμοστική εκμάθηση από το δίκτυο αισθητήρων με τη νευρωνική δομή, της κατάστασης

θερμοκρασίας στην περιοχή και η πρόβλεψη, μετά την διαδικασία της εκμάθησης φυσικά, ακριβών θερμοκρασιών, σύμφωνα με τις μετρήσεις στις πηγές δεδομένων, μετά από το χρονικό διάστημα της μιας ώρας.

Στην δεδομένη αυτή περίπτωση, το περιβάλλον, έχει την ευθύνη να παραλαμβάνει τα προϊόντα εξόδου του νευρωνικού δικτύου και να ξεκινά ένα μετρητή διάρκειας μιας περίπου ώρας. Μετά από αυτή την ώρα μετρά την θερμοκρασία της περιοχής και ανάλογα με την διαφορά της μέτρησης αυτής από την πρόβλεψη που έγινε την προηγούμενη ώρα από το νευρωνικό δίκτυο, στέλνει στο επίπεδο εξόδου του δικτύου ένα σήμα αμοιβής, αν η διαφορά είναι μικρή και η πρόβλεψη κρίνεται επιτυχής ή ένα σήμα ποινής αν η διαφορά είναι μεγάλη και η πρόβλεψη κρίνεται ως αποτυχημένη.

4.5 Μαθηματικός Συλλογισμός

Στον χώρο των νευρωνικών δικτύων και των δικτύων αισθητήρων υπάρχουν πολλά πιθανά συγκεκριμένα μαθηματικά μοντέλα διαθέσιμα για χρήση στο σενάριο που εξετάζουμε. Ο αλγόριθμος μάθησης νευρωνικών δικτύων της «εκμάθησης με κριτή» παρέχει πολλές εναλλακτικές επιλογές χρήσης και λειτουργίας. Μια απλή έρευνα στο διαδίκτυο δείχνει την πληθώρα των προσεγγίσεων που χρησιμοποιούνται σε ένα μεγάλο αριθμό από προβλήματα που λύνονται με την συγκεκριμένη μέθοδο.

Στην παράγραφο αυτή θα καταγράψουμε τις συγκεκριμένες μαθηματικές ιδιότητες και δομές που επιλέξαμε για χρήση και υλοποίηση στην προσομοίωση μας.

Κατ' αρχήν η εκμάθηση γίνεται με την παρουσία περισσότερο ενός κριτή παρά ενός δασκάλου, όπως υπαγορεύει η ενισχυτική μάθηση, ο οποίος αξιολογεί τις πράξεις του τεχνητού νευρωνικού δικτύου χωρίς να παρέχει τις ορθές τιμές.

Ο πράκτορας σε κανένα σημείο δεν γνωρίζει την ορθή προβλεπόμενη τιμή θερμοκρασίας αλλά γνωρίζει, δοκιμάζοντας-προβλέποντας θερμοκρασίες, κατά πόσο πρόβλεψε ορθά ή λάθος.

Στην προσομοίωση μας θα χρησιμοποιήσουμε το Markov decision process framework, στο οποίο τον ρόλο του πράκτορα αναλαμβάνει ένα τεχνητό νευρωνικό δίκτυο. Η ενισχυτική μάθηση γίνεται με non-associative τρόπο καθώς μόνο ένα ενισχυτικό σήμα χρησιμοποιείται ως είσοδος στο νευρωνικό δίκτυο. Δεν υπάρχει στο σενάριο μας συνάρτηση αμοιβής (που καθορίζει τί είναι καλό σε βάθος χρόνου) και ο κανόνας εκμάθησης που χρησιμοποιείται είναι ο selective bootstrap.

Ο συγκεκριμένος κανόνας εκμάθησης (selective bootstrap) καθορίζει και τον κανόνα τροποποίησης των βαρών που θα χρησιμοποιηθεί στο εσωτερικό νευρωνικό δίκτυο, στο επίπεδο εξόδου. Πρόκειται ουσιαστικά για παραλλαγή του γνωστού κανόνα εκμάθησης Widrow-Hoff και παίρνει τιμές αποκλειστικά μηδέν και ένα, υπολογισμένες ως το ντετερμινιστικό κατώφλι των ζυγισμένων (weighted) αθροισμάτων τιμών εισόδου.

Ουσιαστικά η πράξη που γίνεται στον συγκεκριμένο κανόνα εκμάθησης είναι:

$$\Delta w(t) = n * (a(t)-s(t)) * x(t) \quad \text{Αν } r(t) = \text{επιτυχία και} \\ n * (1-a(t)-s(t)) * x(t) \quad r(t) = \text{αποτυχία}$$

όπου:

$r(t)$ είναι το ενισχυτικό σήμα,

$s(t)$ είναι το άθροισμα των ζυγισμένων τιμών εισόδου,

$a(t)$ είναι η τρέχουσα έξοδος,

$x(t)$ είναι η δεδομένη είσοδος την χρονική στιγμή t και

n είναι ο ρυθμός μάθησης.

Στο σημείο αυτό πρέπει να παραθέσουμε ότι χρειάστηκε αρκετή σκέψη και πολλή μελέτη για να επιλέξουμε τον κανόνα εκμάθησης που θα χρησιμοποιούσαμε κατά την διαδικασία της μάθησης στα εσωτερικά επίπεδα του νευρωνικού μας δικτύου (επίπεδο εισόδου και κρυφό επίπεδο) έχοντας να επιλέξουμε μεταξύ του selective bootstrap και του Widrow-Hoff κανόνα. Ουσιαστικά το δίλημμα πήγαζε από το ερώτημα αν στο εσωτερικό τεχνητό νευρωνικό δίκτυο ισχύουν οι κανόνες

που ισχύουν στην ενισχυτική μάθηση ή οι κανόνες που ισχύουν στο τεχνητό νευρωνικό δίκτυο ως οντότητα (π.χ. back-propagation Widrow-Hoff rule).


Αφού ερευνήσαμε αρκετές προσεγγίσεις στο διαδίκτυο και αφού συμβουλευτήκαμε τη θεωρία στην «εκμάθηση με κριτή» προσέγγιση ¹⁴ , αποφασίσαμε να επιλέξουμε τον κανόνα μάθησης selective bootstrap στα εσωτερικά επίπεδα του νευρωνικού μας δικτύου.

Στο κάτω-κάτω η selective bootstrap προσέγγιση παρέχει μια μέθοδο τροποποίησης βαρών συγκεκριμένο για κάθε νευρώνιο ενώ ο κανόνας Widrow-Hoff καθορίζει την τροποποίηση βαρών ως την ίδια ακριβώς για όλα τα νευρώνια κάθε επιπέδου. Αποφασίστηκε έτσι ως πιο ακριβής μέθοδος με καλύτερα αποτελέσματα.

Ασφαλώς η καλύτερη απάντηση στο ερώτημα μπορεί να δοθεί μέσω της προσομοίωσης όπου δοκιμάσαμε και συγκρίναμε σε ένα απλό σενάριο με απλά δεδομένα την συμπεριφορά του δικτύου με τους δύο κανόνες μάθησης ξεχωριστά.

Στο Σχήμα 4.1 βλέπουμε την γραφική παράσταση του σφάλματος σε σχέση με τον αριθμό επαναλήψεων για τους δύο κανόνες μάθησης, Όπως εύκολα μπορούμε να παρατηρήσουμε και με τους δύο κανόνες το δίκτυο μαθαίνει στον ίδιο αριθμό επαναλήψεων με αρκετά παρόμοιο τρόπο, αφού το σφάλμα σχετικά διακυμαίνεται με τον ίδιο τρόπο.

Παρατηρούμε εν γένει ότι ο κανόνας Widrow-Hoff παρέχει στην αρχική φάση της διαδικασίας εκμάθησης μικρότερες διακυμάνσεις στην παραγωγή του σφάλματος από τον selective bootstrap κανόνα. Εν τούτοις επιλέγουμε το δεύτερο λόγω των μεγάλων ομοιοτήτων γενικά στην παραγωγή του σφάλματος και λόγω της καλύτερης μαθηματικής του διατύπωσης στο μοντέλο που εξετάζουμε.



Σχήμα 4.1 Κανόνες Εκμάθησης στο Κρυφό Επίπεδο ενός Νευρωνικού Δικτύου

Η πολιτική που χρησιμοποιείται στο σενάριο μας είναι «άπληστη» (greedy), διευρύνοντας την τρέχουσα γνώση χωρίς την παρουσία προκαθορισμένης γνώσης.

Στο εσωτερικό τεχνητό νευρωνικό δίκτυο, κατά τα άλλα, ισχύουν οι μαθηματικοί υπολογισμοί που μελετήσαμε στο κεφάλαιο «Θεωρία» στο υποκεφάλαιο του αλγορίθμου back-propagation. Η συνάρτηση ενεργοποίησης (activation function) που επιλέξαμε είναι η σιγμοειδής συνάρτηση ενώ λάβαμε υπόψη στην προσομοίωση μας και στους υπολογισμούς, την κλίση της σιγμοειδούς συνάρτησης καθώς και το βάρος κατωφλίου (bias weight) σε κάθε νευρώνιο.

Το επίπεδο εισόδου κατά τη λειτουργία πρόβλεψης της θερμοκρασίας θεωρήσαμε ότι δεν είναι ενεργό. Οι τιμές που μετρά δηλαδή στους αισθητήρες του δεν περνούν από τη σιγμοειδή συνάρτηση, αλλά μεταφέρονται με τη μορφή που διατηρούν στο επόμενο επίπεδο όπως ορίζεται από την τοπολογία μας.

Πρέπει να σημειωθεί εδώ ότι για τον λόγο ότι οι τιμές που μετρούν οι αισθητήρες στο επίπεδο εισόδου παίρνουν μεγάλες τιμές που κυμαίνονται μεταξύ 16-27 °C (βαθμούς Κελσίου) όσον αφορά την θερμοκρασία και μεταξύ 19-52 % (ποσοστιαίες μονάδες) όσον αφορά την υγρασία (relative humidity), θεωρήσαμε ότι ενδείκνυται η κανονικοποίηση των αποτελεσμάτων, ώστε να έλθουν σε μορφή πιο κατανοητή από το νευρωνικό δίκτυο και να γίνεται κατ' επέκταση πιο ομαλά η λειτουργία πρόβλεψης.

Τελευταία απαραίτητη διευκρίνιση, σχετικά με το μαθηματικό υπόβαθρο του μοντέλου μας, πρέπει να γίνει σχετικά με τον τρόπο με τον οποίο ο αισθητήρας με ρόλο περιβάλλοντος στην ενισχυτική μας μάθηση «κωδικοποιεί» τις μετρήσεις που παίρνει, ώστε να γίνουν κατανοητές και πανομοιότυπες με αυτές στο τεχνητό νευρωνικό δίκτυο και να μπορούν να συγκριθούν και να αξιολογηθούν ορθά. Είχαμε να επιλέξουμε μεταξύ χρήσης της σιγμοειδούς συνάρτησης και χρήσης κανονικοποίησης των μετρήσεων, σύμφωνα με τις θερμοκρασίες που κυμαίνονται στη γεωγραφική αυτή περιοχή. Μετά από ένα αριθμό εκτελέσεων της προσομοίωσης, αποφασίσαμε ότι η κανονικοποίηση ήταν η μόνη πιθανή οδός λειτουργίας του μοντέλου μας καθώς με χρήση της σιγμοειδούς συνάρτησης το νευρωνικό δίκτυο είτε αδυνατούσε να μάθει, είτε μάθαινε μετά την πάροδο ενός τεράστιου χρονικού διαστήματος.

Προκαλεί ερωτηματικά η αποδοτικότητα των συναρτήσεων ενισχυτικής μάθησης που χρησιμοποιούμε. Πιθανόν στο μέλλον να βρεθούν μετά από σχετική έρευνα καλύτερες συναρτήσεις για χρήση με καλύτερες προσαρμοστικές ιδιότητες. Μια πιθανή μελλοντική προσέγγιση, ίσως αποτελεί η χρήση ενός look-up table με τιμές, όπου η κάθε τιμή αντιπροσωπεύει μια διαφορετική πιθανότητα αξιολόγησης από το περιβάλλον.

4.6 Υποθέσεις και Περιορισμοί

Λόγω της πολυπλοκότητας του μοντέλου που προσπαθούμε να προσομοιώσουμε, αναγκαστικά πρέπει να συμβιβαστούμε με κάποιες υποθέσεις και περιορισμούς, που αφενός διατηρούν μια σχετική απλότητα στην

προγραμματιστική μας δομή και αφετέρου μας επιτρέπουν να αφοσιωθούμε στην ουσία του προβλήματος που προσπαθούμε να επιλύσουμε.

Προσπάθεια μας είναι αυτοί οι περιορισμοί να επηρεάσουν στο ελάχιστο δυνατό βαθμό την προσομοίωση και κατ' επέκταση την αποδεικτική μέθοδο που ακολουθούμε, χωρίς να μειώνουν την σημαντικότητα των συμπερασμάτων όπως αυτά εξάγονται μέσα από αυτή τη προσέγγιση.

Οι σημαντικότερες υποθέσεις που έγιναν κατά την κατασκευή του προσομοιωτή είναι οι ακόλουθες:

- Οι γεωγραφικές θέσεις των αισθητήρων υπολογίζονται τυχαία αλλά δεν λαμβάνονται υπόψη στην δημιουργία των επιπέδων και στην γενικότερη δομή του νευρωνικού δικτύου.
- Ο αριθμός των αισθητήρων στην γεωγραφική περιοχή περιορίζεται στον ελάχιστο δυνατό, ώστε να επιτευχθεί η απαιτούμενη σφαιρική λειτουργία χωρίς την παρεμβολή άλλων, τρίτων αισθητήρων.
- Τα ασύρματα μηνύματα που μεταδίδονται μεταξύ των αισθητήρων έχουν απλή, βασική μορφή, μεταφέροντας πληροφορίες μόνο για τον αποστολέα, τον παραλήπτη, τις τιμές των βαρών και τις εξόδους του νευρωνίου-αποστολέα. Δεν μεταδίδονται πληροφορίες σύμφωνα με κάποιο πρωτόκολλο επικοινωνίας και τα πακέτα δεν περιέχουν επιπλέον πληροφορίες.
- Η ασύρματη επικοινωνία μεταξύ των αισθητήρων είναι εφικτή με την μετάδοση ενός μηνύματος με όχι περισσότερο από ένα αποδέκτης. Κάθε μήνυμα έτσι είναι μοναδικό και πρακτικά χρησιμεύει μόνο στον αποδέκτη, ο οποίος μπορεί να το δει και να το αποθηκεύσει στην μνήμη του. Άλλωστε ο τρόπος που λειτουργούν τα νευρωνικά δίκτυα υπαγορεύει την μοναδική αποστολή μηνυμάτων.
- Δεν συμπεριλαμβάνεται στην προσομοίωση το γεγονός ότι οι αισθητήρες έχουν ένα περιορισμένο εύρος μετάδοσης δεδομένων. Όλοι οι αισθητήρες θεωρούμε ότι μπορούν να στέλνουν απευθείας πακέτα, ο ένας στον άλλο, χωρίς χωρικούς περιορισμούς και χωρίς να λαμβάνονται υπόψη πιθανές ανωμαλίες του περιβάλλοντος όπως φυσικά εμπόδια (βουνά, κοιλάδες).

- Θέματα συγχρονισμού, συγκρούσεις πακέτων κατά την μετάδοση (transmission conflicts) καθώς και πιθανές τροποποιήσεις (corruption) ή χάσιμο των πακέτων (packet loss) αγνοούνται παντελώς από την προσομοίωση. Υποθέτουμε ότι κάθε πακέτο φτάνει στον προορισμό του το ενδεικνυόμενο χρονικά σημείο.
- Οι καθυστερήσεις (delays) μεταξύ των αισθητήρων επίσης αγνοούνται. Εδώ πρέπει να επισημανθεί ότι το μοντέλο που εξετάζουμε λειτουργά ασύγχρονα, επομένως η δεδομένη υπόθεση είναι εκ των ων ουκ άνευ.
- Η ομαδοποίηση των αισθητήρων στα επίπεδα του νευρωνικού δικτύου γίνεται με προκαθορισμένο τρόπο χωρίς να λαμβάνονται υπόψη θέματα απόδοσης και γεωγραφικής θέσης των κόμβων. Δεν χρησιμοποιείται κάποιος αλγόριθμος ομαδοποίησης και συνεπώς εγκαταλείπεται στην προσομοίωση και η ιδέα που είδαμε στο κεφάλαιο «Θεωρία» του κόμβου-ομαδάρχη (responsible node).

Αναμφίβολα οι υποθέσεις αυτές υποβαθμίζουν το ποσοστό ρεαλιστικότητας του προσομοιωτή και μειώνουν την αποδεικτική ισχύ της διπλωματικής εργασίας, αποτελούν όμως, στη γενική τους μορφή, εξειδικευμένα προβλήματα τα οποία μπορούν να επιλυθούν με κάπως βαθύτερη μαθηματική ανάλυση από μελλοντικούς ερευνητές.

Δεν αρνιόμαστε το γεγονός ότι ίσως η απουσία των περιορισμών αυτών να τροποποιούσε κάπως τα αποτελέσματα, όπως αυτά θα εξαχθούν μέσα από την προσομοίωση, αλλά πιστεύουμε ότι δεν θα τα επηρέαζε σε σημαντικό βαθμό και δεν θα άλλαζε την γενική ιδέα που εξάγεται μέσα από αυτά.

4.7 Επιλογή Αισθητήρων

Στο σημείο αυτό, δεδομένου ότι επιλέξαμε την προσομοίωση ως την αποδεικτική μας μέθοδο, έφτασε η στιγμή να επιλέξουμε τα μοντέλα αισθητήρων που θα χρησιμοποιήσουμε κατά την υλοποίηση και τον προγραμματισμό του προσομοιωτή μας. Η διαδικασία επιλογής αισθητήρων δεν ήταν μια εύκολη

διαδικασία, λαμβάνοντας υπόψη την πληθώρα που υπάρχουν στο παζάρι, με τις διαφορετικές ικανότητες και χαρακτηριστικά του κάθε τύπου ξεχωριστά.

Συνοψίσαμε αρχικά τα γενικά στοιχεία που πρέπει να υποστηρίζει το μοντέλο ή τα μοντέλα αισθητήρων που θα επιλέξουμε.

Πρέπει, σύμφωνα με τις προδιαγραφές που θέσαμε, να πληρούν τις πιο κάτω γενικές προϋποθέσεις:

- Να επικοινωνούν με ασύρματη μετάδοση πληροφοριών.
- Να είναι συμβατά με το πρωτόκολλο μετάδοσης δεδομένων IEEE 802.15.4.
- Να διατηρούν ενσωματωμένη on-board αντένα, ακριβώς για την ασύρματη μετάδοση πληροφοριών που προαναφέραμε.
- Να λειτουργούν με ένα ανοικτής-πηγής (open-source) λειτουργικό σύστημα, κατά προτίμηση το tinyOS.
- Να λειτουργούν με ένα επεξεργαστή χαμηλής ισχύος, με μνήμη τουλάχιστον μερικών δεκάδων KB.
- Να διαθέτουν το απαιτούμενο ποσό ενέργειας αποθηκευμένο σε μορφή μπαταριών, ώστε να έχουν αρκετά μεγάλο διάστημα ζωής, ικανό να αντεπεξέλθει στα χρονικά όρια της διαδικασίας εκπαίδευσης και λειτουργίας του μοντέλου που μελετάμε.
- Τουλάχιστον το ένα μοντέλο από αυτά που θα επιλέξουμε (αν επιλέξουμε περισσότερα από ένα) πρέπει να έχει εγκατεστημένους ειδικούς αισθητήρες μέτρησης θερμοκρασίας και υγρασίας.

Σύμφωνα με τις προδιαγραφές που θέσαμε, η επιλογή αισθητήρων έγινε μια σχετικά εύκολη διαδικασία, καθώς μειώθηκε αισθητά η λίστα με τα διαθέσιμα μοντέλα για χρήση. Στόχος μας ήταν η επιλογή κάποιων αισθητήρων που να μας βοηθούν, εκτός από την χρήση τους στην προσομοίωση, να εξάγουμε κάποια χρήσιμα συμπεράσματα, που να αφορούν κατανάλωση ενέργειας στα μοντέλα αυτά αλλά και άλλες χρήσιμες συγκρίσεις μεταξύ των τύπων αυτών αισθητήρων. Για την επιτυχία επίτευξης συγκρίσεων μεταξύ μοντέλων, αποφασίσαμε όπως υιοθετήσουμε δύο συνολικά μοντέλα αισθητήρων, στα οποία το ένα μοντέλο θα

έχει ικανότητα μετρήσεων καιρικών φαινομένων ενώ το άλλο μοντέλο θα διατηρεί μόνο τις ιδιότητες που προαναφέραμε.

Η εταιρία κατασκευής αισθητήρων η οποία μας έπεισε για την τελική μας επιλογή ήταν τελικά η CrossBow technologies¹⁵, η οποία αποτελεί μια πολύ αξιόπιστη εταιρία στον χώρο.

Τα μοντέλα, εν τέλει, της συγκεκριμένης εταιρίας που επιλέξαμε είναι ο TelosB¹⁶, με δυνατότητες μέτρησης θερμοκρασίας και υγρασίας, και ο Imote2¹⁷, που θα χρησιμοποιηθεί στην προσέγγισή μας απλά για επεξεργασία και προώθηση δεδομένων. Με λίγα λόγια, στην νευρωνική μας τοπολογία, οι πηγές δεδομένων και ο αισθητήρας περιβάλλοντος αντιπροσωπεύονται με TelosB αισθητήρες, ενώ το κρυφό επίπεδο και το επίπεδο εξόδου με Imote2 αισθητήρες.

Στο Σχήμα 4.2 βλέπουμε ένα αισθητήρα τύπου TelosB. Όπως φαίνεται υπάρχει εγκατεστημένο USB port για απευθείας σύνδεση με ηλεκτρονικό υπολογιστή. Το μοντέλο αυτό αισθητήρα είναι προσεκτικά σχεδιασμένο για χαμηλή κατανάλωση ενέργειας, χαρακτηριστικό που θα προσπαθήσουμε να επιβεβαιώσουμε μέσω της προσομοίωσης μας.



Σχήμα 4.2 Αισθητήρας TelosB

Στο Σχήμα 4.3 παρατηρούμε ένα αισθητήρα τύπου Imote2. Από τον αισθητήρα αυτό απουσιάζουν οι ενσωματωμένοι αισθητήρες μέτρησης καιρικών φαινομένων, διατηρεί όμως στο σύνολο του πιο πολύπλοκο σχεδιασμό και δομή καθώς διαθέτει μεγαλύτερη επεξεργαστική ισχύ και περισσότερες υπολογιστικές δυνατότητες.



Σχήμα 4.3 Αισθητήρας Imote2

Θεωρήσαμε χρήσιμο να παραθέσουμε σε μορφή πίνακα τις μετρικές που θα χρησιμοποιήσουμε για την απόδειξη του μοντέλου μας μέσω της προσομοίωσης που θα ακολουθήσουμε. Ουσιαστικά ο Πίνακας 4.1 παρουσιάζει περιληπτικά τις κύριες δυνατότητες και χαρακτηριστικά των αισθητήρων, σε σχέση πάντα με τον ρόλο που θα επιτελέσει ο κάθε αισθητήρας στην νευρωνική δομή στην οποία συμμετέχει.

Χαρακτηριστικά	Επίπεδο Εισόδου	Κρυφό Επίπεδο	Επίπεδο Εξόδου	Αισθητήρας Περιβάλλοντος
Τύπος Αισθητήρα	TelosB	Imote2	Imote2	TelosB
Μπαταρία που χρησιμοποιείται	AA	AAA	AAA	AA
Ενέργεια Μπαταρίας (J)	9360	5071	5071	9360
Αριθμός Μπαταριών	2	3	3	2
Αρχική Συνολική Ενέργεια (J)	18720	15213	15213	18720
Τάση (Voltage) σε κατάσταση λειτουργίας (V)	3	4.5	4.5	3
Τάση (Voltage) σε κατάσταση ύπνου (V)	1.8	3.2	3.2	1.8
Ένταση Ρεύματος(Draw) στην εκπομπή(mA)	23	44	44	23
Ένταση Ρεύματος στην λήψη (mA)	23	44	44	23
Ένταση Ρεύματος σε κατάσταση ύπνου (μΑ)	51	390	390	51
Χρόνος Ξυπνήματος (Wake-Up Time) (μs)	606	606	606	606
Ρυθμός Μετάδοσης (Data Rate) (kbps)	250	250	250	250
Ενέργεια ανά Εντολή Εκτέλεσης (nJ)	1	1	1	1

Πίνακας 4.1 Τεχνικά Χαρακτηριστικά Αισθητήρων

Αισιοδοξούμε ότι τα συγκεκριμένα μοντέλα που επιλέξαμε, τα οποία διαθέτουν όλα τα μεγάλα πανεπιστήμια του κόσμου, είναι αρκετά αντιπροσωπευτικά της θεωρίας αισθητήρων όπως την γνωρίσαμε. Πρόκειται για πρόσφατες τεχνολογικές κατασκευές που ενσωματώνουν στην δομή τους όλα τα αναγκαία

χαρακτηριστικά και ιδιότητες των σύγχρονων αισθητήρων που κυκλοφορούν στο παζάρι.

4.8 Δομή Νευρωνικού Δικτύου

Όπως προαναφέραμε και στο κεφάλαιο «Θεωρία», κάθε τοπολογία νευρωνικού δικτύου λύνει διαφορετικά ένα συγκεκριμένο πρόβλημα και διαφορετικά προβλήματα γενικά. Κάθε γραμμικό ή μη-γραμμικό πρόβλημα, ουσιαστικά χρειάζεται συγκεκριμένη προσέγγιση και πρέπει να αντιμετωπιστεί ξεχωριστά.

Ισχύει το θεώρημα βεβαίως ότι κάθε νευρωνικό δίκτυο με ικανοποιητικό αριθμό από νευρώνια είναι σε θέση να επιλύσει ένα συγκεκριμένο σενάριο σε κάποιο χρονικό διάστημα, μόνο που το χρονικό αυτό διάστημα, στην περίπτωση που το δίκτυο δεν πληροί τις αναγκαίες προϋποθέσεις αριθμού νευρώνων, μπορεί να είναι πολύ μεγάλο καθιστώντας το νευρωνικό δίκτυο ασύμφορο να υλοποιηθεί.

Προσπάθεια στην υλοποίησή μας, είναι η προσέγγιση του προβλήματος χρησιμοποιώντας τις καλύτερες δυνατές παραμέτρους, οι οποίες εξάγονται μέσα από διαρκείς εκτελέσεις της προσομοίωσης και σύγκρισης αποτελεσμάτων. Με την εύρεση των παραμέτρων αυτών καθίσταται πιο ομαλή η διαδικασία της εκμάθησης του δικτύου εντός λογικών χρονικών ορίων.

Το σενάριο, όπως διακρίνει και ο αναγνώστης, χαρακτηρίζεται από αρκετή πολυπλοκότητα και από συντονισμό ενός σημαντικού αριθμού από παραμέτρους ώστε να λειτουργήσει ορθά. Πρόκειται για ένα δύσκολο εγχείρημα με απρόβλεπτα αποτελέσματα και αναμφίβολα αρκετές εκτελέσεις του προσομοιωτή, με τροποποίηση κάθε φορά των μεταβλητών και των σταθερών του προβλήματος.

Για τον λόγο αυτό αποφασίσαμε όπως μελετήσουμε δύο διαφορετικά σενάρια ή καλύτερα υπό-σενάρια της ίδιας ιδέας-προσέγγισης που εισηγηθήκαμε, ενός απλού σεναρίου και ενός σύνθετου σεναρίου πραγματικών δεδομένων. Ο σκοπός είναι η επίτευξη λειτουργίας εκμάθησης στο απλό σενάριο όπου θεωρητικά το εγχείρημα θα είναι ευκολότερο και η σύγκλιση του δικτύου θα επέλθει λογικά σε πεπερασμένο χρονικό διάστημα. Πιθανή επιτυχία στο απλό

σενάριο θα μας δώσει την απαιτούμενη ώθηση και ψυχολογία ώστε να επικεντρωθούμε ακολούθως στο σενάριο πραγματικών δεδομένων, το οποίο αποτελεί και την πραγματική πρόκληση της διπλωματικής αυτής εργασίας.

4.8.1 Απλό Σενάριο


Στο απλό σενάριο που επιλέξαμε να προσεγγίσουμε σε πρώτη φάση, επιδιώξαμε να κρατήσουμε την πολυπλοκότητα και τον βαθμό δυσκολίας σε χαμηλά επίπεδα. Θεωρήσαμε την ύπαρξη στο επίπεδο εισόδου τεσσάρων αισθητήρων, οι οποίοι έχουν τον ρόλο των πηγών δεδομένων στην προσομοίωση μας και ενός αισθητήρα στο επίπεδο εξόδου, ο οποίος έχει την αποκλειστική ευθύνη της παραγωγής του τελικού αποτελέσματος-τιμής εξόδου του νευρωνικού δικτύου σε κάθε επανάληψη καθώς και της επικοινωνίας με τον αισθητήρα-περιβάλλον για αξιολόγηση του νευρωνικού δικτύου στο σύνολο του.

Δεδομένου ότι στο απλό αυτό σενάριο ζητούμε όσο γίνεται περισσότερη απλοποίηση χρήσης του μοντέλου μας, επιλέξαμε ένα γραμμικό πρόβλημα για επίλυση από το δίκτυο μας. Στο πρόβλημα αυτό ζητείται μεν από το νευρωνικό δίκτυο η πρόβλεψη της τιμής της θερμοκρασίας σε διάστημα μιας ώρας από τις μετρήσεις που λαμβάνουν χώρα στο επίπεδο εισόδου, πρόκειται δε για μια απλή πρόβλεψη μέσου όρου θερμοκρασίας, σύμφωνα με την προ-επεξεργασία την οποία κάναμε στα δεδομένα εισόδου.

Εξάλλου, αγνοήσαμε στο σενάριο αυτό τις μετρήσεις υγρασίας και φωτός (που μπορούν να μετρήσουν οι αισθητήρες-πηγές δεδομένων σύμφωνα με τις προδιαγραφές του σεναρίου μας) και επικεντρωθήκαμε αποκλειστικά στις απλές μετρήσεις θερμοκρασίας τις οποίες εμείς με εύκολο τρόπο δημιουργήσαμε.

Όπως προαναφέραμε, προτού πούμε με βεβαιότητα ότι με το απλό αυτό σενάριο το νευρωνικό δίκτυο μπορεί να μάθει το πρόβλημα που του αντιστοιχεί σε λογικό χρονικό διάστημα, πρέπει να επιλέξουμε προσεκτικά τις τιμές τις οποίες θα δώσουμε στις μεταβλητές-παραμέτρους της προσομοίωσης ώστε να επιτύχουμε τον μέγιστο βαθμό σύγκλισης του δικτύου στο πρόβλημα που του δώσαμε να


επιλύσει. Σε όλες τις περιπτώσεις εύρεσης τιμών παραμέτρων χρησιμοποιούμε την προσομοίωση για να επιλέξουμε τις ορθές τιμές που θα χρησιμοποιηθούν. Κατ' αρχήν πρέπει να ρυθμίσουμε τον αριθμό των νευρώνων που θα τοποθετηθούν στο κρυφό επίπεδο του νευρωνικού μας δικτύου. Ο ακριβής αριθμός των νευρώνων του επιπέδου αυτού είναι ίσως ο πιο σημαντικός παράγοντας για την ομαλή λειτουργία του δικτύου και την ομαλή διαδικασία εκμάθησης. Όπως φαίνεται και στο Σχήμα 4.4 ο ενδεικνυόμενος αριθμός νευρώνων στο κρυφό επίπεδο είναι τρία νευρώνια καθώς σε αυτή τη περίπτωση η εκμάθηση γίνεται με τον μικρότερο ρυθμό διακυμάνσεων του σφάλματος. Παρ' όλα αυτά δεδομένου ότι παρουσιάζουν μεγάλη ομοιότητα οι παραστάσεις μεταξύ τους, το δίκτυο θα μπορούσε να μάθει στον ίδιο χρόνο και με διαφορετικό αριθμό νευρώνων, ίσως τεσσάρων ή και έξι με ελάχιστη διαφορά στον χρόνο εκμάθησης.



Σχήμα 4.4 Εκμάθηση Vs Αριθμός Νευρωνίων Κρυφού Επιπέδου

Ακολουθώντας πρέπει να ρυθμιστεί ο ρυθμός μάθησης του νευρωνικού δικτύου καθώς ως παράμετρος είναι και αυτός με την σειρά του πολύ σημαντικός για την


καλή λειτουργία του δικτύου. Όπως φαίνεται και στο Σχήμα 4.5 με ψηλό ρυθμό μάθησης (0.8) η εκμάθηση παρουσιάζει τεράστιες διακυμάνσεις και το δίκτυο πρακτικά αδυνατεί να μάθει. Όταν όμως ο ρυθμός μάθησης μειωθεί στις τιμές 0.4 και 0.2 η διαδικασία της εκμάθησης γίνεται πολύ ομαλή και το δίκτυο μαθαίνει αρκετά καλά και σχεδόν γραμμικά. Επιλέγουμε για ρυθμό μάθησης τελική τιμή 0.2 καθώς είναι η πιο ομαλή παράσταση στην γραφική μας.



Σχήμα 4.5 Ρυθμός Μάθησης Vs Σφάλμα

Τελευταία ρύθμιση παραμέτρου στο σενάριο αυτό είναι η τιμή που θα επιλεγεί για τα όρια επιτυχίας μεταξύ των οποίων ο αισθητήρας με τον ρόλο του περιβάλλοντος κρίνει ως επιτυχή μια πρόβλεψη του τεχνητού νευρωνικού δικτύου. Δεν θεωρήσαμε αναγκαία την παράθεση γραφικής παράστασης για επιλογή της ενδεικνυόμενης τιμής που θα επιλέγαμε για τον παράγοντα αυτό, επειδή η μόνη τιμή στην οποία συνέκλινε το δίκτυο μας ήταν η τιμή 0.5. Το γεγονός αυτό είναι κάπως περίεργο, η εξαγωγή της τιμής αυτής όμως επιλέχθηκε σχετικά απλά με την σύγκριση των μεταβλητών κατά την εκτέλεση του προγράμματος (διαδικασία debugging με χρήση breakpoints). Ουσιαστικά,

βρήκαμε την τιμή στην οποία μετά από κάποιο αριθμό επαναλήψεων, το δίκτυο άρχισε να μαντεύει σωστά την προβλεπόμενη θερμοκρασία της επόμενης ώρας. Στο Σχήμα 4.6 μπορούμε να δούμε μια πιθανή τοπολογία του παρόντος δικτύου αισθητήρων στην νευρωνική δομή την οποία προσπαθούμε να πετύχουμε. Βλέπουμε με τα βελάκια τον τρόπο με τον οποίο επικοινωνούν οι διάφοροι αισθητήρες μεταξύ τους στην τοπολογία στην οποία τους ορίσαμε.



Σχήμα 4.6 Νευρωνική Τοπολογία Δικτύου Αισθητήρων στο Απλό Σενάριο

Παρουσιάζουμε, εν κατακλείδι, συνοπτικά τις παραμέτρους σε αντιστοιχία με τις ορθές τιμές που πρέπει να χρησιμοποιηθούν κατά την προσομοίωση για να επιτευχθούν τα μέγιστα δυνατά αποτελέσματα, κάτι που δείχνει ο Πίνακας 4.2:

Αριθμός Νευρωνίων Κρυφού Επιπέδου	3
Ρυθμός Μάθηση	0.2
Όρια Επιτυχίας	0.5
Συνάρτηση Σύγκλισης Δεδομένων Περιβάλλοντος	Κανονικοποίηση
Αλγόριθμος Εκμάθησης Νευρωνικού Δικτύου	Selective bootstrap
Αριθμός Επαναλήψεων (προσεγγιστικά)	133

Πίνακας 4.2 Ορθές Τιμές Παραμέτρων Απλού Σεναρίου

Με τη ρύθμιση των μεταβλητών του προβλήματος με αυτές τις τιμές, μπορούμε να πούμε με βεβαιότητα ότι το μοντέλο λειτουργεί με τον καλύτερο δυνατό τρόπο.

4.8.2 Σενάριο Πραγματικών Δεδομένων

Αφού μελετήσαμε το απλό σενάριο και πειστήκαμε σε κάποιο βαθμό ότι όντως η ιδέα και το μοντέλο που επινοήσαμε είναι εφαρμόσιμο, ήρθε η ώρα να μελετήσουμε την προσέγγιση μας στον πραγματικό κόσμο. Ήρθε η στιγμή να εκτελέσουμε την προσομοίωση μας με όσο το δυνατό πιο ρεαλιστικά δεδομένα και καταστάσεις.

Θεωρήσαμε, όπως και στο απλό σενάριο, την ύπαρξη τεσσάρων αισθητήρων-πηγών δεδομένων που λειτουργούν ως το επίπεδο εισόδου στη νευρωνική μας δομή καθώς και ένα αισθητήρα, επιφορτισμένο με την λειτουργία του επιπέδου εξόδου, με τις αντίστοιχες λειτουργίες που περιγράψαμε και πριν.

Το πρόβλημα που πρέπει να επιλυθεί σε αυτό το σενάριο είναι μη-γραμμικό καθώς ζητείται η πρόβλεψη της θερμοκρασίας για την επόμενη ώρα, αφού όμως μετρήσουν οι πηγές δεδομένων με τους αισθητήρες τους, τιμές για θερμοκρασία και υγρασία. Βασισμένο λοιπόν το νευρωνικό δίκτυο σε τέσσερις ξεχωριστές τιμές (όσες και οι πηγές δεδομένων) θερμοκρασίας και υγρασίας, πρέπει να αποκτήσει γνώση και να προβλέπει την θερμοκρασία την ερχόμενη ώρα.


Σε αυτή την περίπτωση χρειάζεται να γίνει προσεκτική επιλογή των δεδομένων που θα δοθούν ως είσοδος στα νευρώνια εισόδου και δεν μπορεί να τελεστεί μια απλή προεργασία όπως έγινε στην περίπτωση του απλού σεναρίου. Ο τρόπος που επιλέγηκαν τα δεδομένα αυτά θα περιγραφεί αναλυτικά στο αμέσως επόμενο υπό-κεφάλαιο.

Όπως προαναφέραμε και στην περίπτωση του απλού σεναρίου, για να βεβαιωθούμε ότι στο μοντέλο που εξετάζουμε το νευρωνικό δίκτυο μπορεί να συγκλίνει σε λογικό χρονικό διάστημα στην επίλυση του προβλήματος, πρέπει να κάνουμε προσεκτική επιλογή τιμών, τις οποίες θα δώσουμε στις μεταβλητές-παραμέτρους της προσομοίωσης. Για την εύρεση των κατάλληλων τιμών των παραμέτρων χρησιμοποιούμε την προσομοίωση για να επιλέξουμε τις ορθές τιμές που θα χρησιμοποιηθούν.

Ακολουθώντας την ίδια διαδικασία με πριν, πρέπει αρχικά να ρυθμίσουμε τον αριθμό των νευρωνίων που θα τοποθετηθούν στο κρυφό επίπεδο του


νευρωνικού μας δικτύου. Στο Σχήμα 4.7 παρουσιάζεται μια γραφική παράσταση που πηγάζει από ένα αριθμό εκτελέσεων της προσομοίωσης και με τη βοήθεια της οποίας μπορούμε να επιλέξουμε με αρκετή ακρίβεια τον επιθυμητό αριθμό νευρώνων στο κρυφό επίπεδο. Όπως βλέπουμε, ο ιδανικός αριθμός νευρώνων είναι ο αριθμός 8 καθώς σε αυτή την περίπτωση η παράσταση διατηρεί την παραβολική της μορφή χωρίς έντονες διακυμάνσεις. Όταν τα νευρώνια του κρυφού επιπέδου αυξηθούν σε 10, αυξάνεται αισθητά και η διακύμανση κατά την εκμάθηση, ενώ με τον αριθμό 12 παρατηρείται ακόμα μεγαλύτερη διακύμανση. Εν τούτοις, παρά την παρουσία των διακυμάνσεων παρατηρούμε ότι και στις τρεις παραστάσεις, το δίκτυο μαθαίνει στον ίδιο αριθμό επαναλήψεων, άρα στο ίδιο χρονικό διάστημα.

Επομένως επιλέγεται τελικά ο αριθμός 8 για τον αριθμό των νευρώνων του κρυφού επιπέδου. Αναφέρουμε εδώ ενδεικτικά ότι στην περίπτωση επιλογής 6 νευρώνων το δίκτυο αδυνατεί να προσαρμοστεί στα δεδομένα του προβλήματος και να αναπαραστήσει στην δομή του την απαιτούμενη γνώση.



Σχήμα 4.7 Εκμάθηση Vs Αριθμός Νευρωνίων Κρυφού Επιπέδου


Σε επόμενο στάδιο ρυθμίζουμε την επιθυμητή τιμή του ορίου επιτυχίας. Σε αντίθεση με το απλό σενάριο στο οποίο η τιμή αυτή ήταν λίγο πολύ οφθαλμοφανής, σε αυτή την περίπτωση χρειάζεται η βοήθεια γραφικής παράστασης για να εξαχθεί η ενδεικνυόμενη τιμή. Χρησιμοποιήσαμε πέντε διαφορετικές τιμές ορίου επιτυχίας ώστε να επιλέξουμε την καλύτερη που θα χρησιμοποιηθεί στην προσομοίωση μας όπως φαίνεται στο Σχήμα 4.8. Με τις τιμές 0.5, 0.4 και 0.3 οι παραστάσεις παρουσιάζουν μεγάλη αστάθεια και δεν προσφέρονται για επιλογή ενώ οι τιμές 0.2 και 0.1 είναι αρκετά παρόμοιες με την τιμή 0.1 να ακολουθεί μια αρκετά ομαλή μορφή ώστε να επιλεγεί, χωρίς δισταγμό. Μικρότερες τιμές δεν λύνουν το πρόβλημα και δεν τέθηκε θέμα καν για περίληψη τους στην γραφική παράσταση.



Σχήμα 4.8 Όριο Επιτυχίας Vs Εκμάθηση


Στην επόμενη φάση καθορίζουμε την τιμή την οποία θα δώσουμε στον ρυθμό μάθησης του νευρωνικού μας δικτύου. Πολύ εύκολα διακρίνεται από το Σχήμα

4.9 ότι η καλύτερη τιμή είναι 0.3 καθώς η αναφερόμενη παράσταση παρουσιάζει εξαιρετική μορφή. Καθώς αυξάνεται ο ρυθμός μάθησης και παίρνει μεγαλύτερες τιμές, 0.4 και 0.5, η εκμάθηση γίνεται μεν στον ίδιο χρόνο-αριθμό επανάληψης, παρουσιάζονται όμως διακυμάνσεις και ανωμαλίες στην μορφή των αντίστοιχων δύο παραστάσεων. Αναφέρουμε ενδεικτικά ότι στην περίπτωση που ο ρυθμός μάθησης μειωθεί στο 0.1 ή σε κάποια μικρότερη τιμή, το δίκτυο χρειάζεται τεράστιο αριθμό επαναλήψεων (για τα δεδομένα μας) για να συγκλίνει στην επίλυση του προβλήματος, που φτάνει μέχρι και τις 1500 επαναλήψεις.



Σχήμα 4.9 Ρυθμός Μάθησης Vs Σφάλμα

Στο Σχήμα 4.10 βλέπουμε μια πιθανή τοπολογία του δικτύου αισθητήρων στην νευρωνική δομή που προσπαθούμε να πετύχουμε. Με τα βελάκια, όπως και πριν, φαίνεται ο τρόπος με τον οποίο επικοινωνούν οι διάφοροι αισθητήρες μεταξύ τους στο μοντέλο που επιλέξαμε.



Σχήμα 4.10 Νευρωνική Τοπολογία Δικτύου Αισθητήρων στο Πραγματικό Σενάριο

Παρουσιάζουμε τέλος, όπως και πριν, στον Πίνακα 4.3, συνοπτικά τις μεταβλητές του προβλήματος σε σχέση με τις ενδεικνυόμενες τιμές που πρέπει να χρησιμοποιηθούν στην προσομοίωση για να επιτευχθεί η καλύτερη δυνατή λειτουργία του μοντέλου μας.

Αριθμός Νευρωνίων Κρυφού Επιπέδου	8
Ρυθμός Μάθηση	0.3
Όρια Επιτυχίας	0.1
Συνάρτηση Σύγκλισης Δεδομένων Περιβάλλοντος	Κανονικοποίηση
Αλγόριθμος Εκμάθησης Νευρωνικού Δικτύου	Selective bootstrap
Αριθμός Επαναλήψεων (προσεγγιστικά)	568

Πίνακας 4.3 Ορθές Τιμές Παραμέτρων Πραγματικού Σεναρίου

Με την ρύθμιση των μεταβλητών του προβλήματος με αυτές τις τιμές, μπορούμε να βεβαιωθούμε ότι η προσέγγισή μας θα λειτουργήσει με αποδοτικό τρόπο και

απομένει να κρίνουμε στο επόμενο κεφάλαιο, κατά την παρουσίαση των αποτελεσμάτων, εάν και εφόσον επιτύχαμε τον σκοπό μας.

4.9 Προ-επεξεργασία

Η πιο χρονοβόρα και επίπονη διαδικασία στον χώρο των νευρωνικών δικτύων αποτελεί αναμφισβήτητα η προεργασία των δεδομένων, τα οποία θα δοθούν ως είσοδος στο νευρωνικό δίκτυο (και ως έξοδος στην περίπτωση του back-propagation αλγορίθμου τον οποίο δεν εξετάζουμε). Τα δεδομένα αυτά πρέπει να τροποποιηθούν και να επεξεργαστούν ώστε να έρθουν σε μια ιδανική μορφή και να γίνουν ικανά για κατανόηση από το νευρωνικό δίκτυο.

Η διαδικασία αυτή είναι εξαιρετικά σημαντική για την λειτουργία της προσομοίωσης διότι η εκπαίδευση γίνεται σύμφωνα με τα δεδομένα που παρουσιάζονται στο δίκτυο. Η απόκτηση γνώσης από το δίκτυο αισθητήρων θα γίνει σύμφωνα με τις πληροφορίες αυτές και τον τρόπο με τον οποίο θα τις χειριστεί σε μετέπειτα φάση το νευρωνικό δίκτυο κατά την διαδικασία της εκμάθησης. Φυσικά, αναγκαίο συστατικό στην διαδικασία αυτή είναι η απόκτηση από το νευρωνικό δίκτυο του χαρακτηριστικού της γενίκευσης, η οποία όμως θα προέλθει μόνο από την σφαιρική επιλογή δεδομένων εισόδου που θα καλύπτουν όλες τις πτυχές του προβλήματος και θα βοηθούν το δίκτυο να εκπαιδευτεί για όλες τις πιθανές δυνατές περιπτώσεις, που στο σενάριο μας συγκεκριμένα αφορούν όλες τις διαφορετικές κλιματολογικές αλλαγές που μπορεί να παρατηρηθούν στην γεωγραφική περιοχή στην οποία αναφερόμαστε.

4.9.1 Απλό Σενάριο

Στο σενάριο αυτό η απλότητα των δεδομένων είναι το βασικό ζητούμενο σε αυτό το στάδιο της προσομοίωσης. Χρειαζόμαστε, για τις ανάγκες του σεναρίου, τέσσερις πηγές δεδομένων που να μετρούν σε τακτά χρονικά διαστήματα την θερμοκρασία της περιοχής και ένα αισθητήρα σε ρόλο περιβάλλοντος, που να

μπορεί να μετρά τις μελλοντικές θερμοκρασίες στην ίδια γεωγραφική περιοχή μετά την πάροδο του δεδομένου χρονικού διαστήματος της μιας ώρας.

Προσπαθήσαμε να δημιουργήσουμε απλά και συνάμα σχετικά ρεαλιστικά, αληθοφανή δεδομένα εισόδου. Χρησιμοποιώντας το εργαλείο Microsoft Excel 2003, που ανήκει στο πακέτο εφαρμογών γραφείου Microsoft Office 2003, δημιουργήσαμε τέσσερις διαφορετικές στήλες, οι οποίες αντιπροσωπεύουν τις πηγές δεδομένων και μια πέμπτη στήλη, η οποία αντιπροσωπεύει το περιβάλλον. Αρχικοποιήσαμε τις πηγές δεδομένων με χαμηλές τιμές θερμοκρασίας (περίπου 5 °C) στην πρώτη εγγραφή της αντίστοιχης για κάθε πηγή δεδομένων στήλης (first corresponding row) και αυξάναμε σχεδόν ανεπαίσθητα τις τιμές θερμοκρασίας της στήλης σε κάθε καινούρια της γραμμή, με διαφορετική αυξητική τιμή για κάθε πηγή δεδομένων ξεχωριστά, τέτοια όμως ώστε όλες οι πηγές δεδομένων να παρουσιάζουν παρόμοια μετρικά χαρακτηριστικά θερμοκρασίας μέχρι την τελευταία μέτρηση που θα εμφανιζόταν σαν επανάληψη μάθησης στην προσομοίωση μας. Ως αποτέλεσμα καταφέραμε, μετά από αρκετές προσπάθειες, να δημιουργήσουμε 2000 εγγραφές (records) δεδομένων με την θερμοκρασία να κυμαίνεται μεταξύ 5-30 °C, που είναι μια πολύ λογική διακύμανση θερμοκρασίας για μια γεωγραφική περιοχή στην οποία εναλλάσσεται νύχτα (5 °C) και μέρα (30 °C).

Η αυξητική τιμή για κάθε πηγή δεδομένων ήταν ανεπαίσθητα διαφορετική ώστε η κάθε πηγή να μετρά διαφορετική θερμοκρασία, όπως πρέπει να συμβαίνει και στην πραγματικότητα όπου σε διαφορετικά μέρη της ίδιας περιοχής παρουσιάζονται εναλλαγές στην μέση θερμοκρασία.

Η δημιουργία τέλος της πέμπτης στήλης, που αντιστοιχούσε στα δεδομένα που μετρά ο αισθητήρας περιβάλλοντος ήταν μια πολύ απλή διαδικασία καθώς ήταν απλά ο μέσος όρος των τεσσάρων άλλων στηλών. Με αυτό τον τρόπο, εξασφαλίζεται η γραμμικότητα του προβλήματος, ως προδιαγραφή στην υλοποίηση του συγκεκριμένου σεναρίου. Ωστόσο για να δώσουμε ένα μικρό βαθμό δυσκολίας στο πρόβλημα αποφασίσαμε να προσθέσουμε ένα τυχαίο αριθμό στις μετρήσεις του περιβάλλοντος που κυμαίνεται μεταξύ 0.01 και 0.05 °C.

Με το τέλος της διαδικασίας αυτής, αντιγράψαμε απλά την κάθε στήλη σε ένα διαφορετικό αρχείο κειμένου (text document), δημιουργώντας πέντε διαφορετικά αρχεία με 2000 εγγραφές το καθένα, τα οποία δώσαμε ως είσοδο στην προσομοίωση μας.

4.9.2 Σενάριο Πραγματικών Δεδομένων


Η προηγούμενη προσέγγιση προεργασίας των δεδομένων ασφαλώς δεν μπορεί να εφαρμοστεί στο πραγματικό μας σενάριο, καθώς στην περίπτωση αυτή θα αποφασιστεί εάν σε συνθήκες πραγματικού κόσμου το μοντέλο μας είναι εφαρμόσιμο και λειτουργικό. Ασφαλώς, αναγκαία προϋπόθεση για την ύπαρξη ρεαλιστικών συνθηκών λειτουργίας της προσέγγισης μας, αποτελεί η παρουσία πραγματικών και αξιόπιστων δεδομένων τα οποία θα χρησιμοποιηθούν ως είσοδος στην προσομοίωση μας.

Τα δεδομένα αυτά ασφαλώς δεν μπορεί να είναι τυχαία και φτιαχτά αλλά πρέπει να είναι προϊόν πραγματικών μετρήσεων, από πραγματικούς αισθητήρες, σε κάποιο πραγματικό περιβάλλον λειτουργίας. Η παρουσία αξιόπιστων δεδομένων εξάλλου αυξάνει την αποδεικτική δύναμη της διπλωματικής αυτής εργασίας και εγγυάται την λειτουργικότητα του μοντέλου σε πιθανή περίπτωση επιτυχίας της προσέγγισης μας, όπως αυτή θα διαφανεί μέσα από τα αποτελέσματα της προσομοίωσης μας.

Για τον σκοπό αυτό θέσαμε ψηλά τον πήχη όσον αφορά την εξασφάλιση πραγματικών δεδομένων στην προσομοίωση μας κρίνοντας τον παράγοντα αυτό εξαιρετικά σημαντικό στην συνολική μας δραστηριότητα και ψάξαμε ενδελεχώς στο διαδίκτυο για πραγματικές πειραματικές μετρήσεις που έγιναν σε αισθητήρες οι οποίοι καταμέτρησαν θερμοκρασία και ίσως κάποιες άλλες ποσότητες.

Τελικά καταφέραμε να βρούμε τα δεδομένα που ζητούσαμε χάρη στην βοήθεια του Intel and Berkeley Research lab¹⁸ και των πειραμάτων που πραγματοποίησε σε αισθητήρες Mica2Dot την περίοδο μεταξύ 28^{ης} Φεβρουαρίου και 5^{ης} Απριλίου 2004¹⁹.

Συγκεκριμένα, 54 αισθητήρες Mica2Dot εγκαταστάθηκαν σε κάποια συγκεκριμένη γεωγραφική περιοχή, καταμετρώντας σε τακτά χρονικά διαστήματα των 31 δευτερολέπτων τοπολογικές πληροφορίες της περιοχής στην οποία τοποθετήθηκαν. Οι πληροφορίες αυτές περιλαμβάνουν μετρήσεις θερμοκρασίας, υγρασίας, φωτός(light) και τάσης(voltage). Η κατανομή των αισθητήρων έγινε με τέτοιο τρόπο ώστε να καταμετρηθεί με ακρίβεια η πλήρης κλιματολογική κατάσταση της περιοχής όπως φαίνεται και στο Σχήμα 4.11.



Σχήμα 4.11 Κατανομή Αισθητήρων στο Χώρο

Τα δεδομένα συλλέχθηκαν με το σύστημα επεξεργασίας TinyDB in-network query processing system, το οποίο είναι χτισμένο σε TinyOS πλατφόρμα. Πρακτικά καταμετρήθηκαν συνολικά σχεδόν 15000 διαφορετικές εγγραφές και αποθηκεύτηκαν σε 54 διαφορετικά αρχεία, συνολικού μεγέθους 150 MB. Ο Πίνακας 4.4 παρουσιάζει την ακριβή μορφή των δεδομένων όπως καταχωρήθηκαν στα αρχεία.

Ημερομηνία	Ωρα	Αριθμός Εποχής	Αριθμός mote	Θερμοκρασία	Υγρασία	Φως	Τάση
------------	-----	----------------	--------------	-------------	---------	-----	------

Πίνακας 1.4 Αρχική Μορφή Δεδομένων Εισόδου

Όπως προαναφέραμε, για το μοντέλο μας, τα μόνα στοιχεία που μας ενδιαφέρουν πραγματικά είναι η θερμοκρασία και η υγρασία, καθώς το φως και η τάση αποτελούν αναξιόπιστα κριτήρια πρόβλεψης μελλοντικής θερμοκρασίας λόγω της τυχαίας και άναρχης τους μορφής, όπως αυτή φαίνεται από προσεκτική μελέτη των δειγμάτων αυτών. Για σκοπούς προσομοίωσης αποφασίσαμε να τροποποιήσουμε τις εγγραφές των δεδομένων σύμφωνα με την μορφή που δείχνει ο Πίνακας 4.5 και να λάβουμε υπόψη στην υλοποίηση μας μόνο τις πρώτες δύο παραμέτρους που πρακτικά μας ενδιαφέρουν.

Θερμοκρασία	Υγρασία	Φως	Τάση
-------------	---------	-----	------

Πίνακας 4.5 Επεξεργασμένη Μορφή Δεδομένων Εισόδου

Δεδομένου ότι οι πηγές δεδομένων παραμένουν τέσσερις στην τοπολογία αυτή που εξετάζουμε, πρέπει να επιλέξουμε μετρήσεις από τέσσερις αισθητήρες από το σύνολο των 54 που υπάρχουν στην περιοχή. Με προσεκτική μελέτη της τοπολογίας του χώρου επιλέξαμε τους αισθητήρες με αριθμούς mote 1, 10, 20 και 47 όπως αυτοί φαίνονται με την πιο πάνω σήμανση στο Σχήμα 4.11. Οι αισθητήρες αυτοί καλύπτουν γεωγραφικά με τον καλύτερο τρόπο την δεδομένη περιοχή ενώ βρίσκονται σχετικά απομονωμένοι από φυσικά εμπόδια και από τους άλλους αισθητήρες με αποτέλεσμα να αυξάνεται η εγκυρότητα των τιμών που καταμετρούν ενώ τα αποτελέσματα των μετρήσεων είναι όσο το δυνατό πιο σφαιρικά και αντιπροσωπευτικά του περιβάλλοντος.

Στο τελευταίο στάδιο της προ-επεξεργασίας των δεδομένων σε αυτό το σενάριο, μένει ο καθορισμός των τιμών που θα δέχεται ο αισθητήρας περιβάλλοντος. Μετά από αρκετές σκέψεις απορρίψαμε το ενδεχόμενο ο αισθητήρας αυτός να πάρει τις τιμές κάποιου συγκεκριμένου mote όπως έγινε με τις πηγές των δεδομένων διότι επιζητούμε από αυτόν πλήρη γνώση των περιβαλλοντικών συνθηκών της περιοχής. Προτιμήσαμε να χρησιμοποιήσουμε τις μετρήσεις θερμοκρασίας και των 54 motes και να υπολογίσουμε τις επιθυμητές τιμές του αισθητήρα περιβάλλοντος βρίσκοντας τον μέσο όρο των motes αυτών. Με τον τρόπο αυτό βοηθούμε το περιβάλλον στο μοντέλο μας να διατηρεί μια συνολική

εικόνα της θερμοκρασίας της περιοχής και να μπορεί να αξιολογεί με την μεγαλύτερη δυνατή ακρίβεια τις προβλέψεις που επιτελούνται στο τεχνητό νευρωνικό δίκτυο κατά τη διαδικασία της μάθησης.


Εδώ πρέπει να αναφέρουμε ότι χρειάζεται μεγάλη προσοχή στον συγχρονισμό των μετρήσεων των πηγών δεδομένων και του αισθητήρα περιβάλλοντος. Οι μετρήσεις στα *motes* λαμβάνουν χώρα κάθε 30 περίπου δευτερόλεπτα, επομένως πρέπει να διαγράψουμε τις πρώτες 120 εγγραφές των μετρήσεων του περιβάλλοντος ($120 \text{ μετρήσεις} \times 30 \text{ δευτερόλεπτα} = 1 \text{ ώρα}$) καθώς αναφέρονται σε προηγούμενα, άγνωστα χρονικά διαστήματα. Με τον τρόπο αυτό διασφαλίζεται το γεγονός ότι με κάθε μέτρηση που γίνεται στις πηγές δεδομένων, γνωρίζουμε, με την πάροδο μιας ώρας, την σφαιρική θερμοκρασία στην περιοχή. Επιτυγχάνουμε έτσι στον μέγιστο δυνατό βαθμό να δημιουργήσουμε ρεαλιστικά δεδομένα, τα οποία μπορούν να ανταποκριθούν σε συνθήκες πραγματικού κόσμου, κρατώντας παράλληλα την διπλωματική αυτή εργασία σε ψηλά επίπεδα απόδοσης.

4.9.3 Ένα απροσδόκητο πρόβλημα των Δεδομένων

Παρά το γεγονός ότι η επιλογή των δεδομένων στο πραγματικό σενάριο κρίνεται ως ρεαλιστική και αξιόπιστη, δεδομένου ότι το νευρωνικό δίκτυο πρόκειται να μάθει σε ένα πεπερασμένο αριθμό επαναλήψεων, η επιλογή των δεδομένων που θα δοθούν ως είσοδος στο νευρωνικό δίκτυο πρέπει να είναι τέτοια, που να διασφαλίζει την σφαιρική απόκτηση γνώσης και την ολική εκπαίδευση του δικτύου για κάθε πιθανό καιρικό φαινόμενο της περιοχής.

Δυστυχώς κατά την εκπόνηση της διπλωματικής αυτής εργασίας αναλώθηκε σημαντικός χρόνος του γράφοντα αμελώντας να τυχαιοποιήσει τα δεδομένα εισόδου σύμφωνα με την διαδικασία προ-επεξεργασίας που περιγράφηκε αμέσως πριν. Αποτέλεσμα ήταν το δίκτυο να εκπαιδεύεται για συγκεκριμένα κλιματολογικά σενάρια και να αδυνατεί να προβλέπει κατά την μετέπειτα λειτουργία του, θερμοκρασίες με μεγάλη απόκλιση από τις θερμοκρασίες εκπαίδευσης του δικτύου. Αυτό το απροσδόκητο πρόβλημα μπορούμε να το

δούμε και γραφικά στο Σχήμα 4.12 όπου είναι οφθαλμοφανές ότι η πρόβλεψη επιτυγχάνεται για παρόμοια δεδομένα εισόδου ενώ αποτυγχάνει παντελώς καθώς οι κλιματολογικές συνθήκες της περιοχής αλλάζουν. Συγκεκριμένα το δίκτυο εκπαιδεύεται σε συνθήκες νύχτας όπου ασφαλώς η θερμοκρασία είναι αρκετά μικρότερη και αδυνατεί να προβλέψει συνθήκες μέρας όπου η θερμοκρασία αυξάνεται δραστικά. Αναφέρουμε ενδεικτικά ότι στην συγκεκριμένη εκτέλεση της διαδικασίας μάθησης, στην προσομοίωση, οι θερμοκρασίες των δεδομένων εισόδου κυμαίνονται μεταξύ 17-21 °C, θερμοκρασίες νύχτας στο περιβάλλον που καταμετρούμε.



Σχήμα 4.12 Εκμάθηση Vs Έλεγχος

Ασφαλώς το πρόβλημα αυτό ήταν αρκετά σημαντικό και ήταν επιβεβλημένη η άμεση αντιμετώπιση του. Για το σκοπό αυτό βάλαμε όλα τα προ-επεξεργασμένα δεδομένα εισόδου στο πρόγραμμα που χρησιμοποιήσαμε και στην περίπτωση του απλού σεναρίου (Microsoft Excel 2003) και με την μέθοδο της συνάρτησης rand() δώσαμε τυχαίες τιμές σε κάθε εγγραφή μέτρησης. Ακολούθως, ταξινομήσαμε τα δεδομένα εισόδου βάσει των τυχαίων αυτών αριθμών που

παρήγαγε το πρόγραμμα, με αποτέλεσμα να πετύχουμε το ανακάτεμα των δεδομένων και την αποτελεσματική σφαιρικότητα τους ώστε να εκπαιδεύσουν το νευρωνικό δίκτυο για κάθε πιθανό κλιματολογικό ενδεχόμενο. Στην περίπτωση αυτή οι θερμοκρασίες των δεδομένων εισόδου κυμαίνονται μεταξύ 16-27 °C καλύπτοντας και την περίπτωση εκμάθησης του δικτύου σε θερμοκρασίες μέρας. Επιτυγχάνουμε έτσι, εν τέλει, πλήρη και σφαιρική εκμάθηση του δικτύου μας. Απομένει στο επόμενο κεφάλαιο να παρακολουθήσουμε τα τελικά μας αποτελέσματα και να κρίνουμε αντικειμενικά την προσομοίωση μας.

Κεφάλαιο 5

Παρουσίαση Αποτελεσμάτων

5.1 Μέθοδος Εξαγωγής Αποτελεσμάτων	76
5.2 Διαδικασία Εκμάθησης Δικτύου	77
5.3 Διαδικασία Ελέγχου Δικτύου	80
5.4 Εκμάθηση Vs Έλεγχος.....	83
5.5 Κατανάλωση Ενέργειας	84
5.6 Ευρωστία Δικτύου	88
5.7 Εκμάθηση Vs Χρόνος	93

5.1 Μέθοδος Εξαγωγής Αποτελεσμάτων

Η εξαγωγή των αποτελεσμάτων στην παρούσα διπλωματική εργασία έγινε με μια καθαρά πειραματική εργασία στην οποία χρησιμοποιήθηκε η προσομοίωση ως αποδεικτική μέθοδος. Αφού καθορίστηκαν οι παράμετροι συντονισμού του συστήματος, όσον αφορά κυρίως την νευρωνική του φύση, διαδικασία εξαιρετικά χρονοβόρα η οποία απαίτησε πάμπολλες εκτελέσεις του προσομοιωτή με διαφορετικές κάθε φορά τιμές στις βαρύνουσες μεταβλητές του προβλήματος και συνεχείς συγκρίσεις, έτρεξε σε τελικό στάδιο ο προσομοιωτής με τις ορθές-πρέπουσες τιμές και τα αποτελέσματα τα οποία εξήχθησαν, θεωρήθηκαν ως τα τελικά προϊόντα του προγραμματιστικού μοντέλου που υλοποιήσαμε.

Τα αποτελέσματα αυτά προήλθαν από συνεχή επανάληψη της αποθήκευσης της κατάστασης του δικτύου αισθητήρων και της νευρωνικής του δομής σε αρχείο. Ουσιαστικά ο καθρέπτης της ένδειξης πιθανής επιτυχίας της προσέγγισης μας αποτέλεσε κατά κύριο λόγο το τρέχων σφάλμα του δικτύου σε σχέση με την

διαφορά της προβλεπόμενης και της ορθής τιμής της θερμοκρασίας. Το σφάλμα αυτό καθόρισε σε κάθε βήμα, σε κάθε επανάληψη, την πρόοδο του νευρωνικού δικτύου όσον αφορά την διαδικασία της μάθησης. Αυτό λοιπόν το σφάλμα αποθηκεύσαμε για όλη την διαδικασία εκμάθησης του δικτύου αλλά και για τη διαδικασία ελέγχου. Δημιουργήσαμε έτσι σε πρώτη φάση δύο διαφορετικά αρχεία, το `error_training.txt` και το `error_testing.txt` τα οποία διατηρούν την μορφή «Αριθμός Επανάληψης Σφάλμα».

Με την χρήση αρχείου παρόμοιας δομής με τα δύο προηγούμενα και εκτελώντας τον προσομοιωτή σε συνθήκες λειτουργίας του μοντέλου, μελετήσαμε και τον παράγοντα ευρωστία στο δίκτυο μας ενώ για την μελέτη της κατανάλωσης ενέργειας αναγκαστήκαμε να χρησιμοποιήσουμε την προγραμματιστική λύση των breakpoints που μας προσφέρει πολύ απλά το Microsoft Visual Studio 2005. Βασικά εισάγαμε ένα breakpoint στην τελευταία εντολή του προγράμματος πριν τερματίσει και καταγράψαμε τις τιμές ενέργειας οι οποίες απέμειναν στους αισθητήρες κάθε επιπέδου ξεχωριστά.

Τα προαναφερθέντα αρχεία που δημιουργήσαμε, λόγω της ανάγκης μετατροπής σε μια κατανοητή μορφή, απλή για παρατήρηση και μελέτη, εισάγαμε στο εργαλείο Microsoft Excel 2003, με την βοήθεια του οποίου δημιουργήσαμε μια γραφική παράσταση για το καθένα από αυτά. Με αυτό τον τρόπο η παρατήρηση και η σύγκριση έγινε μια εύκολη διεργασία.

Στα επόμενα υποκεφάλαια θα μελετήσουμε κάθε αποτέλεσμα ξεχωριστά, θα σχολιάσουμε τις γραφικές παραστάσεις που δημιουργήθηκαν και θα προσπαθήσουμε να αξιολογήσουμε το μοντέλο μας και την ευρύτερη προσέγγιση που ακολουθήσαμε.


5.2 Διαδικασία Εκμάθησης Δικτύου

Δεν θα μπορούσαμε να ξεκινήσουμε την αναλυτική παρουσίαση των αποτελεσμάτων μας από άλλη διαδικασία πλην από την διαδικασία εκμάθησης η οποία έλαβε χώρα στο δίκτυο μας. Η διαδικασία αυτή, η οποία είναι ίσως η πιο

σημαντική στο μοντέλο που εξετάζουμε, καθορίζει και επηρεάζει σε μεγάλο βαθμό την πιθανή επιτυχία της προσέγγισης μας.


Μόνο γι' αυτή τη διαδικασία, θα παρουσιάσουμε αποτελέσματα και για το απλό σενάριο, το οποίο μελετήσαμε αρχικά, πριν προχωρήσουμε στην πραγματική πρόκληση που αποτέλεσε το σενάριο πραγματικών δεδομένων. Ο λόγος είναι ότι σε κατοπινό στάδιο, σταματήσαμε την ανάπτυξη του απλού σεναρίου προγραμματιστικά και ασχοληθήκαμε αποκλειστικά με το ρεαλιστικό σενάριο, καθιστώντας έτσι αδύνατη την συνέχεια εξαγωγής αποτελεσμάτων για το απλό σενάριο, που ούτως ή άλλως στους άλλους παράγοντες, είναι δευτερεύουσας σημασίας.

Ξεκινώντας έτσι από το απλό σενάριο, μπορούμε να μελετήσουμε τη διαδικασία εκμάθησης όπως αυτή φαίνεται στο Σχήμα 5.1. Η απλότητα του σεναρίου αντικατοπτρίζεται και στην ευκολία με την οποία το δίκτυο αποκτά την απαιτούμενη γνώση που ζητείται. Μόλις σε 133 επαναλήψεις εκπαίδευσης, το δίκτυο συγκλίνει στην επίλυση του προβλήματος, κάτι που φαίνεται από την τιμή του σφάλματος, το οποίο μηδενίζεται εντελώς. Η διαδικασία μάθησης είναι σχετικά ομαλή, κυρίως μετά τις πρώτες 10 επαναλήψεις, αριθμός ικανός για το δίκτυο να οργανώσει τη δομή του και να ξεκινήσει αποτελεσματικά τη διαδικασία της προσαρμοστικότητας.



Σχήμα 5.1 Διαδικασία Εκμάθησης Δικτύου στο Απλό Σενάριο

Παραθέτουμε, ακολούθως, τη διαδικασία εκμάθησης του μοντέλου μας στο πραγματικό σενάριο, όπως αυτή διαφαίνεται στο Σχήμα 5.2. Ασφαλώς, η πρόσθεση αρκετού βαθμού πολυπλοκότητας και η μετατροπή της φύσης του προβλήματος από γραμμικό σε μη-γραμμικό αυξάνει τη δυσκολία του δικτύου να προσαρμοστεί στις περιβαλλοντικές και κλιματολογικές συνθήκες της περιοχής, με αποτέλεσμα να χρειάζεται αισθητά μεγαλύτερο αριθμό επαναλήψεων εκμάθησης ώστε να προσαρμοστεί πλήρως στο πρόβλημα που του αναθέσαμε. Ωστόσο η διαδικασία εκμάθησης γίνεται αρκετά ομαλά χωρίς τις διακυμάνσεις που παρατηρήσαμε στο απλό σενάριο. Ο λόγος είναι ότι η πολύπλοκη δομή και τοπολογία του νευρωνικού δικτύου ουσιαστικά μειώνει το τυχαίο της διαδικασίας εκμάθησης καθώς η οργάνωση της γνώσης στο εσωτερικό του δικτύου, ως πιο σύνθετο έργο που είναι, μειώνει την πιθανότητα εμφάνισης διακυμάνσεων κατά την σύγκλιση των βαρών προς το επιθυμητό αποτέλεσμα, το οποίο είναι φυσικά ο μηδενισμός του σφάλματος.



Σχήμα 5.2 Διαδικασία Εκμάθησης Δικτύου στο Πραγματικό Σενάριο

Κατά προσέγγιση, χρειάζονται συνολικά περίπου 568 επαναλήψεις για την πλήρη εκπαίδευση του δικτύου, αριθμός που μπορεί να διαφοροποιείται ελαφρά μεταξύ διαφορετικών εκτελέσεων της προσομοίωσης. Ο αριθμός αυτός κρίνεται ως ικανοποιητικός δεδομένης της δυσκολίας του προβλήματος πρόβλεψης που μελετάμε. Τη συσχέτιση του αριθμού επαναλήψεων, με πραγματικό χρόνο, θα την μελετήσουμε σε επόμενο υποκεφάλαιο.


5.3 Διαδικασία Ελέγχου Δικτύου

Το πιο αξιόπιστο κριτήριο επιτυχίας μιας προσέγγισης στον ευρύτερο χώρο των νευρωνικών δικτύων, αποτελεί η ικανότητα πρόβλεψης του δικτύου σε συνθήκες λειτουργίας σε ένα ρεαλιστικό περιβάλλον. Αν και η διαδικασία εκμάθησης διατηρεί τη μεγαλύτερη σημαντικότητα όσον αφορά την πιθανή επιτυχία του μοντέλου, εν τούτοις η διαδικασία ελέγχου είναι αυτή η οποία θα απαντήσει με βεβαιότητα το ερώτημα εάν όντως το δίκτυο έχει εκπαιδευτεί αποτελεσματικά και σφαιρικά. Θυμίζουμε την αποτυχία της προσέγγισης μας προτού τυχαιοποιήσουμε τα δεδομένα, όπως αυτή φάνηκε από τον πρώιμο έλεγχο που διενεργήσαμε στο δίκτυο μας και καταγράψαμε στο προηγούμενο κεφάλαιο κατά την διαδικασία της προ-επεξεργασίας των δεδομένων.

Ποτέ δεν μπορεί κάποιος επιστήμονας να ισχυριστεί με βεβαιότητα ότι το νευρωνικό του δίκτυο έχει εκπαιδευτεί, απλά με τον μηδενισμό του σφάλματος κατά την διαδικασία της μάθησης. Χρειάζεται να γίνει ενδελεχής έλεγχος κατά την διάρκεια της λειτουργίας του δικτύου με πραγματικά, άγνωστα μέχρι στιγμής δεδομένα, στο εκπαιδευμένο δίκτυο.

Για το λόγο αυτό, εισάγαμε στο δίκτυο μας τον σημαντικό αριθμό των 800 άγνωστων εγγραφών δεδομένων, δεδομένα τα οποία έχουν την ίδια μορφή με την δομή των δεδομένων εκπαίδευσης.

Τα αποτελέσματα της διαδικασίας αυτής φαίνονται μέσα από το Σχήμα 5.3.



Σχήμα 5.3 Διαδικασία Ελέγχου Δικτύου

Βλέπουμε τη διαφορά κατ' αρχήν στις δύο παραστάσεις σε περίπτωση που κανονικοποιήσουμε τα δεδομένα εισόδου και στην περίπτωση που τα δώσουμε ακατέργαστα για επεξεργασία στο κρυφό επίπεδο του νευρωνικού δικτύου. Ασφαλώς η κανονικοποίηση αποτελεί παράγοντα αύξησης της απόδοσης του δικτύου μας και κρίνεται ως αναγκαία σύμφωνα με την μορφή των δεδομένων εισόδου.

Μελετώντας προσεκτικά τη γραφική παράσταση (αυτή με τα κανονικοποιημένα δεδομένα εισόδου καθώς αυτή πρακτικά μας ενδιαφέρει), μπορούμε να πούμε σχεδόν με βεβαιότητα ότι όντως το δίκτυο μας έχει εκπαιδευτεί ορθά και απόκτησε την απαιτούμενη γνώση ώστε να προβλέπει με σχετική ακρίβεια τις μελλοντικές τιμές θερμοκρασίας κατά την διαδικασία της λειτουργίας του.

Σε γενικές γραμμές το σφάλμα κυμαίνεται μεταξύ 0 και 0.01 που είναι εξαιρετικά αποδεκτές τιμές για το σφάλμα πρόβλεψης και εγγυούνται την αξιόπιστη λειτουργία της προσέγγισης μας.


Πρέπει στο σημείο αυτό να σχολιάσουμε την μορφή της γραφικής παράστασης, η οποία δεν διατηρεί ευθεία, οριζόντια γραμμή όπως είθισται σε παρόμοια σενάρια.

Ο λόγος είναι το γεγονός ότι κατά την τυχαιοποίηση των δεδομένων στην διαδικασία της προ-επεξεργασίας, προφανώς επιλέγηκαν περισσότερα δεδομένα εισόδου που αφορούν συγκεκριμένα χρονικά διαστήματα του ημερονυκτίου, δηλαδή περισσότερες μετρήσεις που έγιναν το μεσημέρι όπου επικρατούν συνθήκες ζέστης ή τις πρώτες πρωινές ώρες όπου ασφαλώς πέφτει αισθητά η θερμοκρασία. Με λίγα λόγια το σφάλμα μηδενίζεται στην περίπτωση που συμπίπτουν τα δεδομένα ελέγχου με την πλειοψηφία των χρονικών ορίων των μετρήσεων των δεδομένων εκπαίδευσης και αυξάνεται στην ακριβώς αντίθετη περίπτωση.

Η μορφή της γραφικής παράστασης έτσι κατά την διαδικασία ελέγχου κρίνεται απολύτως φυσιολογική και λογική.

Βλέποντας όμως μόνο το σφάλμα, κάποιος κοινός παρατηρητής, απλά υποψιάζεται την επιτυχία του μοντέλου και των προβλέψεων κατ' επέκταση. Αυτό που χρειάζεται να δει για να πειστεί πλήρως, είναι η ακριβής πρόβλεψη θερμοκρασίας που λαμβάνει χώρα στη διαδικασία λειτουργίας του συστήματος.


Στο Σχήμα 5.4 φαίνεται ακριβώς αυτή η αναπαράσταση, η οποία έχει παρθεί με από-κανονικοποίηση των τιμών ακριβούς θερμοκρασίας περιβάλλοντος και προβλεπόμενης θερμοκρασίας όπως αυτή εξάγεται κάθε φορά από το νευρωνικό δίκτυο αισθητήρων. Όπως δείχνει ξεκάθαρα η γραφική παράσταση, το δίκτυο προβλέπει, κάθε φορά (με μικρές εξαιρέσεις), αρκετά καλά την θερμοκρασία της επόμενης ώρας στην περιοχή. Υπάρχουν μάλιστα περιπτώσεις στις οποίες η πρόβλεψη είναι σχεδόν απόλυτη.



Σχήμα 5.4 Πρόβλεψη Θερμοκρασίας

5.4 Εκμάθηση Vs Έλεγχος

Θεωρήσαμε χρήσιμο να παραγάγουμε μια γραφική παράσταση στην οποία θα γίνεται σύγκριση του σφάλματος στην διαδικασία εκπαίδευσης με το σφάλμα στη διαδικασία ελέγχου. Θα μπορέσουμε έτσι να παρατηρήσουμε τη διαφορά μεταξύ της αρχικής γνώσης του δικτύου (που πρακτικά δεν υπάρχει), σε σχέση με τη τελική του γνώση και παράλληλα την πρόβλεψη της μελλοντικής θερμοκρασίας μετά το πέρας της εκμάθησης από το δίκτυο του προβλήματος. Στο Σχήμα 5.5 μπορούμε να δούμε τη σύγκριση αυτή σε μια μόνο γραφική παράσταση αν και πρέπει να τονίσουμε ότι οι δύο παραστάσεις είναι ανεξάρτητες η μια από την άλλη και γίνονται ασφαλώς σε διαφορετικό χρονικό σημείο.



Σχήμα 5.5 Εκμάθηση Vs Έλεγχος

Όπως φαίνεται, το σφάλμα στη διαδικασία εκμάθησης μηδενίζεται σιγά-σιγά όπως παρατηρήσαμε και πριν, ενώ το σφάλμα στη διαδικασία ελέγχου, αφού το δίκτυο εκπαιδευτεί, είναι εξαιρετικά χαμηλό, γεγονός που μας γεμίζει με αισιοδοξία και πειθώ ότι το μοντέλο προβλέπει πράγματι, με μεγάλη ακρίβεια, τις μελλοντικές τιμές θερμοκρασίας.

Μιλώντας με αριθμούς, βλέπουμε ότι στην αρχική φάση της διαδικασίας εκπαίδευσης, το δίκτυο παρουσιάζει σφάλμα στην πρόβλεψη της τάξης του 0.15, το οποίο σφάλμα σιγά-σιγά μηδενίζεται. Αντιθέτως, το σφάλμα στην διαδικασία ελέγχου, διατηρείται ανέκαθεν χαμηλό και κυμαίνεται όπως είδαμε και πριν, μεταξύ σχετικού μηδέν και 0.01.

5.5 Κατανάλωση Ενέργειας

Τα αποτελέσματα που εξάγουμε στην περίπτωση της κατανάλωσης ενέργειας αναφέρονται αποκλειστικά σε σχέση με τους δύο τύπους αισθητήρων που χρησιμοποιούμε, δηλαδή τον TelosB και τον Imote2.

Δεν αποτελούν σε καμιά περίπτωση γενικές εκτιμήσεις, σε σχέση με τους αισθητήρες στο σύνολο τους, αλλά μέσω των τεχνικών χαρακτηριστικών των δύο αυτών τύπων αισθητήρων, μπορούν να γίνουν ασφαλέστατα συγκρίσεις και για τα άλλα είδη αισθητήρων, σύμφωνα φυσικά με τα δικά τους μοναδικά κατασκευαστικά χαρακτηριστικά.

Τα αποτελέσματα αυτά, ασφαλώς, αποτελούν προϊόντα μοναδικής εκτέλεσης της προσομοίωσης και είναι ενδεικτικά για την κατανάλωση ενέργειας του δικτύου μας στην διαδικασία της μάθησης και μόνο. Μέσα από την παρατήρηση των δύο αυτών μοντέλων αισθητήρων και της συμπεριφοράς τους, μπορούμε να εξάγουμε πιο γενικά συμπεράσματα για την ενέργεια που σπαταλιέται σε ανάλογα δίκτυα κατά την διαδικασία της εκπαίδευσης.

Δεδομένου ότι η αποδεικτική μέθοδος γίνεται με χρήση προσομοίωσης, πρέπει αναγκαστικά να κάνουμε κάποιες υποθέσεις λειτουργίας των αισθητήρων κατά την διάρκεια ζωής τους, κυρίως σχετικά με την διαχείριση ενέργειας την οποία επιτελούν.

Αναφέρουμε εδώ αρχικά ότι στην προσομοίωση μας λαμβάνουμε υπόψη τα πλήρη τεχνικά χαρακτηριστικά και προδιαγραφές των δύο μοντέλων αισθητήρων που χρησιμοποιούμε, όπως αυτά εμφανίζονται από την κατασκευάστρια εταιρία CrossBow²⁰, και αναφερόμαστε κυρίως σε μετρικές όπως τάση (Voltage), ένταση (Amperes) και ρυθμός μετάδοσης δεδομένων (Data Rate).


Θεωρούμε ότι στο χρονικό διάστημα παρόδου μιας ώρας, στο οποίο αναμένουν οι αισθητήρες της τοπολογίας μας την αξιολόγηση της πρόβλεψης από τον αισθητήρα περιβάλλοντος, βρίσκονται όλοι σε κατάσταση βαθιού ύπνου (deep sleep mode), ώστε η κατανάλωση ενέργειας σε αυτά τα ομολογουμένως μεγάλα χρονικά διαστήματα που απαιτεί η διαδικασία εκπαίδευσης να είναι η ελάχιστη δυνατή.

Σχετικά με τους μαθηματικούς υπολογισμούς, σύμφωνα με τους οποίους υπολογίζουμε την κατανάλωση ενέργειας σε κάθε διεργασία που επιτελούν οι αισθητήρες, ο Πίνακας 5.1 παρουσιάζει τους υπολογισμούς αυτούς, όπως τους ενσωματώσαμε στην προσομοίωση μας.

Μετάδοση (Transmission)	$E = \text{Draw} * \text{Voltage} * \text{Bytes} / \text{Data Rate}$
Αποδοχή (Reception)	$E = \text{Draw} * \text{Voltage} * \text{Bytes} / \text{Data Rate}$
Εκτέλεση Εντολής	$E = \text{Number of Commands} * \text{Energy per Instruction}$
Κατάσταση Βαθιού Ύπνου (Sleep Mode)	$E = \text{Draw} * \text{Voltage} * \text{Seconds}$
Διαδικασία Ξυπνήματος (Wake-Up Operation)	$E = \text{Draw} * \text{Voltage} * \text{Seconds}$

Πίνακας 5.1 Μαθηματικοί Τύποι για Σενάρια Κατανάλωσης Ενέργειας

Έτσι, σύμφωνα με τους υπολογισμούς που δεικνύει ο Πίνακας 5.1, τρέξαμε την προσομοίωση μας και εξάγαμε τα αποτελέσματα που βλέπουμε στο Σχήμα 5.6, όσον αφορά τους αισθητήρες τύπου TelosB, οι οποίοι χρησιμοποιούνται στο επίπεδο εισόδου και στον αισθητήρα με ρόλο περιβάλλοντος.




Σχήμα 5.6 Κατανάλωση Ενέργειας στον TelosB αισθητήρα

Όπως παρατηρούμε, παρά το γεγονός ότι η εκπαίδευση χρειάστηκε τριψήφιο αριθμό επαναλήψεων εκμάθησης και αντίστοιχα μεγάλο χρονικό διάστημα για να επιτευχθεί, εν τούτοις η κατανάλωση ενέργειας στον συγκεκριμένο τύπο αισθητήρα είναι μηδαμινή και κυμαίνεται λίγο κάτω από το 1% της συνολικής ενέργειας του αισθητήρα, όπως αυτή είναι αποθηκευμένη στις μπαταρίες του. Το υπόλοιπο 99% αφήνεται στην λειτουργία του αισθητήρα αργότερα, όταν αυτός θα

συμμετέχει στην νευρωνική δομή του μοντέλου για την διενέργεια προβλέψεων θερμοκρασίας.

Στο Σχήμα 5.7, ανάλογα, παρουσιάζονται τα αποτελέσματα για την κατανάλωση ενέργειας στον τύπο αισθητήρα Imote2, αισθητήρας που χρησιμοποιείται για την δόμηση του κρυφού επιπέδου και του επιπέδου εξόδου στην νευρωνική μας τοπολογία.



Σχήμα 5.7 Κατανάλωση Ενέργειας στον Imote2 αισθητήρα

Σε αντίθεση με τον τύπο αισθητήρα TelosB, το συγκεκριμένο είδος αισθητήρα (Imote2), παρουσιάζει αισθητά μεγαλύτερη κατανάλωση ενέργειας κατά την ίδια διαδικασία εκμάθησης στην οποία συμμετείχε και ο TelosB. Συγκεκριμένα η κατανάλωση ενέργειας αγγίζει το 15%, με διαθέσιμη ενέργεια για λειτουργία 85%. Ο λόγος της αισθητής αυτής διαφοράς μεταξύ των δύο αυτών τύπων αισθητήρων, όσον αφορά την κατανάλωση ενέργειας, δεν έγκειται τόσο στην συμμετοχή τους στο νευρωνικό δίκτυο και συγκεκριμένα στο επίπεδο στο οποίο λειτουργεί ως νευρώνας ο αισθητήρας, όσο στην κατασκευαστική δομή των αισθητήρων αυτών. Ο TelosB είναι αρκετά πιο απλός σε σχεδιασμό και κατασκευή από τον Imote2, ο οποίος είναι αρκετά πιο πολύπλοκος αισθητήρας

με περισσότερη λεπτομέρεια και χαρακτηριστικά. Οι κατασκευαστές εξάλλου του TelosB διαφημίζουν αρκετά την εξοικονόμηση ενέργειας στην οποία προβαίνει ο τύπος αυτός αισθητήρα.

Κοιτάζοντας προσεκτικά την εκτέλεση της προσομοίωσης, παρατηρούμε ότι η μεγαλύτερη κατανάλωση ενέργειας δεν συμβαίνει κατά την μετάδοση δεδομένων, που περιορίζεται ούτως ή άλλως κυρίως σε περιορισμένες float τιμές, αλλά κατά την διάρκεια της φάσης στην οποία οι αισθητήρες βρίσκονται για μεγάλο χρονικό διάστημα σε κατάσταση βαθιού ύπνου. Σύμφωνα με τις προδιαγραφές των αισθητήρων αυτών η ένταση του ρεύματος στην φάση αυτή (Sleep Mode Draw), ενώ στον TelosB είναι μόλις 51 μA , στον Imote2 εκτοξεύεται στα 390 μA . Το γεγονός αυτό δημιουργεί και την αισθητή διαφορά στην κατανάλωση ενέργειας στους δύο αυτούς τύπους αισθητήρων.

5.6 Ευρωστία Δικτύου

Από το χρονικό σημείο που συλλάβαμε την ιδέα της μετατροπής ενός δικτύου αισθητήρων σε νευρωνικό δίκτυο, είχαμε υποθέσει πως ένα από τα πολύ σημαντικά χαρακτηριστικά των νευρωνικών δικτύων, η ευρωστία, θα ενσωματωνόταν στην νέα δομή που οραματιστήκαμε.

Με τον όρο ευρωστία αναφερόμαστε στην ομαλή και ορθή λειτουργία του δικτύου μας, ακόμα και στην περίπτωση απώλειας αισθητήρων λόγω βλάβης, έλλειψης ενέργειας ή άλλων φυσικών καταστροφών που προκαλούν ζημιά σε κάποιο μέρος του δικτύου.

Συγκεκριμένα, στην περίπτωση που εξετάζουμε, προσπάθεια μας είναι η συνέχιση της καλής λειτουργίας του δικτύου και της αξιόπιστης πρόβλεψης θερμοκρασιών, ακόμα και μετά από φυσική φθορά ή βλάβη ενός σημαντικού αριθμού από αισθητήρες, οι οποίοι συμμετέχουν στην νευρωνική μας τοπολογία. Για την εξαγωγή αποτελεσμάτων όσον αφορά τον συγκεκριμένο παράγοντα, τροποποιήσαμε προγραμματιστικά τον προσομοιωτή μας ώστε στην διαδικασία λειτουργίας του μοντέλου, μετά την διαδικασία εκμάθησης, να προβλέπει θερμοκρασίες αφού απώλεσε ένα αριθμό από αισθητήρες. Η απώλεια αυτή

μεταφράστηκε στην προσομοίωση με την παροχή μηδενικών τιμών στα βάρη ορισμένων αισθητήρων με αποτέλεσμα ουσιαστικά να μην συμμετέχουν στην σφαιρική πρόβλεψη που επιτελεί το νευρωνικό δίκτυο.


Αναφέρουμε εδώ ενδεικτικά ότι δεν ασχοληθήκαμε με το φαινόμενο του φυσικού θανάτου ενός αισθητήρα από ολική έλλειψη ενέργειας, διότι, όπως είδαμε στο προηγούμενο υποκεφάλαιο, κατά την εκπαίδευση, οι απώλειες ενέργειας στις μπαταρίες των αισθητήρων ήταν μικρές με αποτέλεσμα να μην υπάρχει η ικανότητα παρατήρησης του συγκεκριμένου σεναρίου. Έτσι, περιορίσαμε τις μετρήσεις μας στην διαδικασία ελέγχου και λειτουργίας του δικτύου με άγνωστα δεδομένα.

Όπως εύκολα μπορεί να μαντέψει ο αναγνώστης υπάρχουν δύο πιθανά σενάρια να μελετήσουμε. Η απώλεια νευρωνίων στο επίπεδο εισόδου και η αντίστοιχη απώλεια στο κρυφό επίπεδο. Δεν υφίσταται σενάριο απώλειας στο επίπεδο εξόδου καθώς στην δομή μας συμμετέχει μόνο ένας αισθητήρας. Φυσικά το γεγονός ότι στο επίπεδο εισόδου έχουμε μόλις 4 πηγές δεδομένων, ενώ στο κρυφό επίπεδο 8 αισθητήρες, δυσχεραίνει την προσομοίωση μας και μειώνει την γενικότητα των αποτελεσμάτων μας. Θα επιχειρήσουμε συνεπώς να προσεγγίσουμε το θέμα ειδικά και να γενικεύσουμε αργότερα, με ότι κινδύνους συνεπάγεται αυτή η γενίκευση.

Αρχικά μελετήσαμε τον παράγοντα ευρωστία στο επίπεδο εισόδου. Τρέξαμε μια εκτέλεση του προσομοιωτή χωρίς απώλειες στην αρχή και μετά αφαιρέσαμε από την δομή μας 1 και 2 πηγές δεδομένων κάθε φορά, με αποτέλεσμα την εξαγωγή συνολικά 3 παραστάσεων που φαίνονται γραφικά στο Σχήμα 5.8.


Όπως παρατηρούμε ευδιάκριτα, η απώλεια πηγών δεδομένων στοιχίζει στο νευρωνικό δίκτυο καθώς το σφάλμα αυξάνεται, σε μικρότερο βαθμό στην περίπτωση απώλειας μιας μόνο πηγής δεδομένων, και σε μεγαλύτερο βαθμό στην περίπτωση απώλειας δύο πηγών δεδομένων. Συγκεκριμένα ενώ χωρίς απώλεια αισθητήρων το σφάλμα κυμαίνεται από 0-0.012, στην απώλεια ενός αισθητήρα πάει στο 0-0.028, ενώ στην απώλεια δύο πηγών δεδομένων κυμαίνεται από 0-0.042. Αυξάνεται έτσι με γεωμετρικό ρυθμό, καθώς η απώλεια αισθητήρων αυξάνεται. Παρ' όλα αυτά η αύξηση αυτή του σφάλματος, πρέπει να

τονίσουμε ότι συμβαίνει κυρίως κατά την πρόβλεψη θερμοκρασιών για κλιματολογικά σενάρια στα οποία δεν εκπαιδεύτηκε στον μέγιστο δυνατό βαθμό το δίκτυο μας (όπως εξηγήσαμε στο υποκεφάλαιο «Διαδικασία Ελέγχου Δικτύου»). Για σενάρια στα οποία είναι τέλεια εκπαιδευμένο, το σφάλμα, παρά την ελάχιστη αύξηση σε κάθε παράσταση, παραμένει μηδενικό και αμελητέο και στα τρία σενάρια.



Σχήμα 5.8 Ευρωστία Δικτύου στο Επίπεδο Εισόδου

Παρά το ότι υπάρχει κάποια αύξηση στο σφάλμα, και συνεπώς μείωση του ποσοστού πρόβλεψης θερμοκρασίας κατά την λειτουργία του δικτύου, εν τούτοις πρέπει να παραδεχτούμε ότι το σφάλμα και στις τρεις παραστάσεις διατηρείται σε χαμηλά επίπεδα (ακόμη και στην χειρότερη περίπτωση). Αυτό μπορεί να φανεί και γραφικά στο Σχήμα 5.9, όπου αντιπαραβάλαμε στους ίδιους άξονες τις παραστάσεις που μελετάμε αλλά και το σφάλμα στην διαδικασία εκπαίδευσης του δικτύου. Όπως παρατηρούμε και στην γραφική παράσταση, η αύξηση του σφάλματος δεν είναι ανησυχητική και το δίκτυο παραμένει σε μια καλή κατάσταση λειτουργίας κατά την απώλεια νευρωνίων του επιπέδου εισόδου.



Σχήμα 5.9 Ευρωστία Δικτύου Vs Εκμάθηση στο Επίπεδο Εισόδου

Ο Πίνακας 5.2 παρουσιάζει το ποσοστό απώλειας νευρωνίων του επιπέδου εισόδου σε σχέση με το σφάλμα πρόβλεψης θερμοκρασίας,


Απώλεια Νευρωνίων Επιπέδου Εισόδου	Ποσοστό	Σφάλμα
0	0%	0.012
1	25.00%	0.028
2	50%	0.042

Πίνακας 5.2 Ποσοστό Απώλειας Νευρωνίων Vs Σφάλμα (Επίπεδο Εισόδου)

Σε επόμενο στάδιο μελετήσαμε τον παράγοντα ευρωστία στο κρυφό επίπεδο του νευρωνικού δικτύου. Η παρουσία στο επίπεδο αυτό 8 νευρωνίων εξασφάλιζε ότι τα αποτελέσματα θα ήταν πιο αξιόπιστα και γενικά από προηγούμενως.

Ακολουθώντας την ίδια μέθοδο που περιγράψαμε και πριν, για την εξαγωγή των αποτελεσμάτων μας από την προσομοίωση, παρατηρούμε στο Σχήμα 5.10 τα αποτελέσματα που πήραμε, σε γραφική μορφή. Τα αποτελέσματα είναι πολύ παρόμοια με τα αποτελέσματα που παρατηρήσαμε και πριν, όταν μελετήσαμε την ευρωστία στο επίπεδο εισόδου του νευρωνικού δικτύου. Συγκεκριμένα το σφάλμα χωρίς απώλεια αισθητήρων παίρνει τιμές από 0-0.015, στην απώλεια


ενός αισθητήρα πάει στο 0-0.03, ενώ στην απώλεια δύο πηγών δεδομένων κυμαίνεται από 0-0.043.



Σχήμα 5.10 Ευρωστία Δικτύου στο Κρυφό Επίπεδο

Συγκρίνοντας με τα αποτελέσματα που είδαμε στο επίπεδο εισόδου, στην περίπτωση αυτή βλέπουμε ότι η απώλεια νευρωνίων κρυφού επιπέδου επηρεάζει σε ελαφρώς μεγαλύτερο βαθμό την πρόβλεψη. Το κρυφό επίπεδο επομένως παίζει στο μοντέλο μας αρκετά σημαντικό ρόλο για την καλή λειτουργία του δικτύου και αποτελεί τον κυριότερο «χώρο» αναπαράστασης της γνώσης εσωτερικά του νευρωνικού δικτύου.

Στο Σχήμα 5.11, όπως και πριν, αντιπαραβάλλουμε το σφάλμα στην διαδικασία της εκπαίδευσης σε σχέση με τις μετρήσεις μας. Παρατηρούμε, όπως και πριν, έτσι και εδώ, ότι το σφάλμα παρά την μερική, γεωμετρική του αύξηση, δεν είναι ανησυχητικό και διατηρείται σε χαμηλά επίπεδα καθιστώντας την πρόβλεψη δυνατή και σε αυτές τις ακραίες περιπτώσεις απώλειας ενός αριθμού από νευρώνια.



Σχήμα 5.11 Ευρωστία Δικτύου Vs Εκμάθηση στο Κρυφό Επίπεδο

Ο Πίνακας 5.3 παρουσιάζει το ποσοστό απώλειας νευρωνίων του κρυφού επιπέδου σε σχέση με το σφάλμα πρόβλεψης θερμοκρασίας, ολοκληρώνοντας την παρουσίαση αποτελεσμάτων όσον αφορά τον συγκεκριμένο παράγοντα.

Απώλεια Νευρωνίων Κρυφού Επιπέδου	Ποσοστό	Σφάλμα
0	0%	0.015
1	12.50%	0.03
2	25%	0.043

Πίνακας 5.3 Ποσοστό Απώλειας Νευρωνίων Vs Σφάλμα (Κρυφό Επίπεδο)

5.7 Εκμάθηση Vs Χρόνος

Αφήσαμε τελευταίο στην παρουσίαση των αποτελεσμάτων μας, τον παράγοντα χρόνο, που στην περίπτωση μας ορίζεται ως το χρονικό διάστημα το οποίο χρειάζεται το δίκτυο για να αποκτήσει πλήρη γνώση του περιβάλλοντος ή μαθηματικά τη χρονική διάρκεια μέχρι τον μηδενισμό του σφάλματος κατά την διάρκεια εκπαίδευσης του μοντέλου.

Το μέγεθος του χρονικού αυτού διαστήματος είναι πολύ σημαντικό για την πιθανότητα επιτυχίας της προσέγγισης μας καθώς πάντα ελλοχεύει ο κίνδυνος, ο χρόνος σύγκλισης να είναι τόσο μεγάλος, ώστε οι αισθητήρες να χάνουν όλη τους την ενέργεια προτού εκπαιδευτούν ή να τους μένει πολύ μικρό απόθεμα ενέργειας για μια αξιόπιστη λειτουργία πρόβλεψης που να διαρκεί σημαντικό χρονικό διάστημα.

Ασφαλώς το χρονικό διάστημα που χρειάζεται το δίκτυο να εκπαιδευτεί, μπορούμε να το προβλέψουμε μέσω της προσομοίωσης μας, απλά συγκρίνοντας τον αριθμό επαναλήψεων που χρειάζονται για την διαδικασία μάθησης σε σχέση με τον χρόνο αναμονής (κάθε φορά) μέχρι το περιβάλλον να αξιολογήσει σε κάθε επανάληψη την τρέχων πρόβλεψη του δικτύου.

Ξεκινώντας από το απλό σενάριο, παρατηρούμε ότι κατά μέσο όρο (σε σχέση με ένα αριθμό εκτελέσεων της προσομοίωσης), το δίκτυο χρειάζεται περίπου 133 επαναλήψεις μάθησης για να εκπαιδευτεί. Ο Πίνακας 5.4 παρουσιάζει τον συνολικό χρόνο εκμάθησης σε σχέση με το διάστημα καθυστέρησης που παρατηρείται στον αισθητήρα περιβάλλοντος κάθε φορά. Ενδεικτικά παραθέτουμε για σκοπούς πληρότητας της έρευνας μας αντίστοιχους χρόνους για διαφορετικά διαστήματα καθυστέρησης κατά την αξιολόγηση των αποτελεσμάτων εξόδου.

Καθυστέρηση Μετρήσεων Αισθητήρα Περιβάλλοντος	Χρόνος Εκμάθησης
2 ώρες	11 μέρες και 2 ώρες
1 ώρα	5 μέρες και 13 ώρες
30 λεπτά	2 μέρες και 18 ώρες
15 λεπτά	1 μέρα και 9 ώρες
10 λεπτά	22 ώρες

Πίνακας 5.4 Καθυστέρηση Μετρήσεων Vs Χρόνος Εκμάθησης (Απλό Σενάριο)

Στο σενάριο που εξετάζουμε, στο οποίο η αξιολόγηση της πρόβλεψης από τον αισθητήρα περιβάλλοντος γίνεται μετά από πάροδο μιας ώρας (σε κάθε επανάληψη μάθησης), το δίκτυο χρειάζεται 5 ½ μέρες για να μάθει, χρόνος πολύ καλός για το απλό αυτό σενάριο.

Στο πραγματικό σενάριο τώρα που εξετάζουμε, το οποίο, λόγω της πολυπλοκότητας του, παρουσιάζει ασφαλώς μεγαλύτερες απαιτήσεις σε χρόνο και επαναλήψεις εκμάθησης για την πλήρη προσαρμοστικότητα του δικτύου στο περιβάλλον λειτουργίας του, χρειάζονται περίπου κατά μέσο όρο 568 επαναλήψεις. Με την ίδια μέθοδο με πριν, παραθέτουμε τον συνολικό χρόνο εκμάθησης σε σχέση με το διάστημα καθυστέρησης, δείχνοντας για σκοπούς συγκρίσεων διαφορετικά διαστήματα καθυστέρησης. Ο Πίνακας 5.5 δείχνει αυτά τα αποτελέσματα.

Καθυστέρηση Μετρήσεων Αισθητήρα Περιβάλλοντος	Χρόνος Εκμάθησης
2 ώρες	1 μήνας και 19 μέρες
1 ώρα	24 μέρες και 12 ώρες
30 λεπτά	12 μέρες και 6 ώρες
15 λεπτά	6 μέρες και 3 ώρες
10 λεπτά	3 μέρες και 1 ώρα

Πίνακας 5.5 Καθυστέρηση Μετρήσεων Vs Χρόνος Εκμάθησης (Πραγματικό Σενάριο)

Όπως βλέπουμε, σύμφωνα με τις προδιαγραφές μας, μετά από την πάροδο ενός σχεδόν μήνα, το δίκτυο μπορεί, με την συνεχή του εκπαίδευση, να αναπαραστήσει το πρόβλημα που επιζητούμε.

Σε τελευταίο στάδιο, παραθέτουμε το χρονικό διάστημα που απομένει στο δίκτυο να λειτουργήσει για πρόβλεψη θερμοκρασιών, δεδομένης της ενέργειας την οποία σπαταλά κατά την διαδικασία της μάθησης. Το χρονικό αυτό διάστημα εξάγεται προσεγγιστικά αφού ληφθεί υπόψη ότι περίπου για 568 επαναλήψεις χρειάζονται 24 ½ μέρες για την πλήρη εκμάθηση από το δίκτυο του προβλήματος που του θέσαμε. Έτσι σύμφωνα με τις μετρικές αυτές και σύμφωνα με την διαθέσιμη ενέργεια που απομένει στους δύο τύπους αισθητήρων που μελετούμε, 99% στον TelosB και 85% στον Imote2, υπολογίσαμε τον συνολικό διαθέσιμο χρόνο λειτουργίας των αισθητήρων αυτών. Ο Πίνακας 5.6 δείχνει τους υπολογισμούς αυτούς.

TelosB	Imote2
2705 μέρες	163 μέρες

Πίνακας 5.6 Διαθέσιμος Χρόνος Λειτουργίας Αισθητήρων

Ασφαλώς, ο διαθέσιμος χρόνος λειτουργίας στον TelosB αισθητήρα, είναι μια καθαρά θεωρητική πρόβλεψη καθώς δεν υφίσταται πρακτικά τέτοιο ενδεχόμενο. Αντίθετα στον Imote2 πρόκειται για μια λογική πρόβλεψη που αντικατοπτρίζει πλήρως τις ικανότητες σε ζωή του συγκεκριμένου μοντέλου αισθητήρα.

Γενικά, ισχύει στον τομέα των αισθητήρων, ότι οι ενδεικτικές τιμές των κατασκευαστριών εταιριών όσον αφορά την διάρκεια ζωής των αισθητήρων τους, ισχύουν μόνο για ιδανικά περιβάλλοντα λειτουργίας και δεν παρατηρούνται ποτέ σε πραγματικές συνθήκες. Οι απώλειες ενέργειας προς το περιβάλλον είναι πάντα μεγάλες, σε βαθμό που η διάρκεια ζωής των αισθητήρων περιορίζεται πάντα σε μερικούς μήνες.

Κεφάλαιο 6

Συμπεράσματα

6.1 Γενικά Συμπεράσματα.....	97
6.2 Μελλοντική Εργασία.....	101
6.3 Προκλήσεις	102
6.4 Επίλογος.....	103

6.1 Γενικά Συμπεράσματα

Μετά από το πέρας της εκπόνησης της διπλωματικής αυτής εργασίας, αφού έγινε μια εις βάθος ανάλυση του προβλήματος και εκτιμήθηκαν οι δυνατότητες και οι αδυναμίες του μοντέλου επίλυσης, μετά από τον σχεδιασμό και την υλοποίηση ενός προσομοιωτή για απόδειξη της λειτουργικότητας της προσέγγισης μας, ήρθε η στιγμή να εξάγουμε τα συμπεράσματα μας όπως αυτά προέρχονται από τις παρατηρήσεις μας σε όλη τη διάρκεια της διαδικασίας.

Το σημαντικότερο ερώτημα που πρέπει να απαντηθεί είναι αν όντως το μοντέλο κρίνεται ως επιτυχές και προσεγγίζει το πρόβλημα με ακρίβεια. Εάν και εφόσον δηλαδή, το δίκτυο αισθητήρων με την νευρωνική δομή στην οποία το μετατρέπουμε, είναι ικανό μετά από την διαδικασία της εκπαίδευσης με ενισχυτική μάθηση, να αποκτήσει προσαρμοστικότητα στο περιβάλλον του και γνώση στο πρόβλημα που του ανατέθηκε. Πιστεύουμε ότι το ερώτημα αυτό απαντούν με αποτελεσματικό τρόπο τα σχετικά μας αποτελέσματα, όπως τα μελετήσαμε στο προηγούμενο κεφάλαιο, καθώς τόσο η διαδικασία εκμάθησης του δικτύου, όσο και η διαδικασία ελέγχου και λειτουργίας του εκπαιδευμένου πλέον δικτύου, γίνονται με πολύ ομαλό τρόπο, σχεδόν ιδανικά, με το σφάλμα, το

οποίο είναι ουσιαστικά το κριτήριο προβλεπτικότητας του δικτύου, να παραμένει σε χαμηλά επίπεδα για κάθε σενάριο πρόβλεψης, όπως αυτό ορίζεται από τα άγνωστα δεδομένα εισόδου.

Η διακύμανση του σφάλματος στην διαδικασία ελέγχου, δεν προκαλεί ανησυχία, καθώς πρόκειται για φυσιολογικό γεγονός που παρατηρείται σε όλων των μορφών νευρωνικά δίκτυα. Ανησυχία θα προκαλούσε ο απόλυτος μηδενισμός του σφάλματος, που στις πλείστες των περιπτώσεων ισοδυναμεί με υπέρ-εκπαίδευση του δικτύου και παρουσίαση του φαινομένου της «παπαγαλίας».

Από την αρχή σύλληψης της ιδέας της διπλωματικής αυτής εργασίας, μας ανησυχούσε το μέγεθος του χρονικού διαστήματος στο οποίο το δίκτυο αισθητήρων θα μπορούσε να εκπαιδευτεί αποτελεσματικά. Όπως με χαρά παρατηρούμε, στο συγκεκριμένο σενάριο που μελετήσαμε, το συγκεκριμένο χρονικό διάστημα δεν είναι ανησυχητικά μεγάλο και κυμαίνεται σε διάστημα σχεδόν ενός μήνα. Αν λάβουμε υπόψη ότι το σενάριο που προσομοιώσαμε αφορά πραγματικά δεδομένα και συμπεριλαμβάνει τόσο μετρήσεις υγρασίας, όσο και θερμοκρασίας, καθιστώντας την πρόβλεψη θερμοκρασίας ένα μη-γραμμικό πρόβλημα, μπορούμε να πούμε προσεγγιστικά ότι το μοντέλο μας μπορεί να επιλύσει ένα οποιοδήποτε μη-γραμμικό πρόβλημα σε λογικά χρονικά όρια, όπου τα χρονικά αυτά όρια δεν πρέπει σίγουρα να υπερβαίνουν την μισή διάρκεια ζωής των αισθητήρων.

Μέσα από την χρήση της προσομοίωσης, παρατηρήσαμε επίσης τον τεράστιο ρόλο που διαδραματίζουν τα δεδομένα εκπαίδευσης στην διαδικασία εκμάθησης του νευρωνικού δικτύου. Ο σημαντικός τους ρόλος αυτός διαφάνηκε όταν εκπαιδεύσαμε το δίκτυο μας, με ένα υποσύνολο των δεδομένων των καιρικών συνθηκών που επικρατούν στην περιοχή, στην οποία τοποθετήσαμε τους αισθητήρες μας. Αυτό επιβεβαιώθηκε στην διαδικασία ελέγχου, όταν το δίκτυο, μπορούσε να προβλέψει επιτυχώς μόνο παρόμοια δεδομένα σε σχέση με αυτά με τα οποία εκπαιδεύτηκε, δηλαδή μόνο τις κλιματολογικές συνθήκες τις οποίες γνώρισε. Όταν τυχαιοποιήσαμε τα δεδομένα, για να συμπεριλάβουν πλήρως τις περιβαλλοντικές συνθήκες της γεωγραφικής μας περιοχής, επιτύχαμε την

πρόβλεψη κάθε κλιματολογικού σεναρίου, όπως αυτό διαφάνηκε μέσα από τις τελικές γραφικές παραστάσεις της διαδικασίας ελέγχου.

Κρίνοντας την συνολική κατανάλωση ενέργειας που παρατηρήθηκε κατά την διαδικασία εκπαίδευσης, συμπεραίνουμε ότι είναι πολύ λίγη, σε σχέση με τις πραγματικές δυνατότητες σε αποθήκευση ενέργειας που διατηρούν οι σύγχρονοι αισθητήρες. Το γεγονός ότι το μοντέλο αισθητήρα TelosB είχε την ελάχιστη κατανάλωση ενέργειας του 1%, σε σχέση με τον Imote2 στον οποίο η αντίστοιχη κατανάλωση έφτασε το 15% έχει να κάνει με την σχεδιαστική δομή του TelosB, η οποία έγινε με στόχο κυρίως την μείωση της σπατάλης ενέργειας μέσα από τις διάφορες λειτουργίες του αισθητήρα και συνεπώς την αύξηση της διάρκειας ζωής του. Φυσικά πρέπει να συνυπολογίσουμε το γεγονός ότι ο TelosB είναι πιο σύνθετος αισθητήρας με περισσότερες δυνατότητες και φυσικά μεγαλύτερη σχεδιαστική πολυπλοκότητα, χαρακτηριστικά που ασφαλώς χρειάζονται μεγαλύτερη ισχύ και ενέργεια για να λειτουργήσουν.

Γενικά τα προαναφερθέντα αποτελέσματα είναι μια καθαρά θεωρητική προσέγγιση καθώς σε πραγματικές περιβαλλοντικές συνθήκες, οι αισθητήρες παρουσιάζουν τεράστιες απώλειες ενέργειας προς το περιβάλλον, γεγονός που περιορίζει το διάστημα ζωής τους σε μερικούς μόλις μήνες.

Ο παράγοντας που μας ξάφνιασε με τα αποτελέσματα που εξάγαμε, όσον τον αφορά, αποδείχτηκε να είναι ο παράγοντας ευρωστία. Ακόμα και στην περίπτωση που αφαιρέθηκαν από την νευρωνική μας δομή λόγω φυσικού θανάτου ή άλλων προβλημάτων ένας ή και δύο αισθητήρες (που αντιστοιχούν με το 25% και 50%, όσον αφορά το επίπεδο εισόδου και 12.5% με 25%, όσον αφορά το κρυφό επίπεδο αντίστοιχα της τοπολογίας μας), η λειτουργία πρόβλεψης του δικτύου παρέμεινε σχετικά σταθερή, με το σφάλμα ασφαλώς να αυξάνεται, αλλά όχι σε αισθητό βαθμό, με τις προβλέψεις να παραμένουν ακόμα και στην χειρότερη περίπτωση σχετικά αξιόπιστες. Το γεγονός αυτό προσδίδει μεγάλη ισχύ στην προσέγγιση μας καθώς ένα τεράστιο πλεονέκτημα των νευρωνικών δικτύων, καταφέραμε να το εφαρμόσουμε αποτελεσματικά σε ένα δίκτυο αισθητήρων, με την αστάθεια λειτουργίας που θεωρητικά διακρίνει τα δίκτυα αυτά.

Εμφανές μειονέκτημα στην διπλωματική αυτή εργασία αποτελεί το γεγονός ότι για την αποδεικτική μεθοδολογία της επιτυχίας της προσέγγισης μας επιλέξαμε συγκεκριμένο σενάριο και δεν αποδείξαμε γενικά την ισχύ του μοντέλου μας για κάθε πιθανό σενάριο. Αυτό φυσικά είναι κάτι που δεν θα μπορούσαμε πρακτικά να πραγματοποιήσουμε ίσως ποτέ και ξεφεύγει από τους στόχους της εργασίας μας.

Στο ίδιο μήκος κύματος, για την προσέγγιση του συγκεκριμένου σεναρίου που επιλέξαμε, χρησιμοποιήσαμε και υιοθετήσαμε συγκεκριμένο μαθηματικό μοντέλο, το οποίο αποτελεί μια μόνο συγκεκριμένη κατεύθυνση σε σχέση με τη χρήση του αλγορίθμου ενισχυτικής μάθησης, ο οποίος μπορεί να λειτουργεί με πολλές διαφορετικές μορφές.

Συνοψίζοντας, η επίλυση του προβλήματος που αντιμετωπίσαμε στην διπλωματική αυτή εργασία έγινε με βάση συγκεκριμένες επιλογές και αποφάσεις τις οποίες λάβαμε. Κάποιο άλλο παρόμοιο πρόβλημα και σενάριο ίσως απαιτήσει διαφορετικές επιλογές, κυρίως όσον αφορά την μαθηματική εφαρμογή της ενισχυτικής μάθησης. Ο επιστήμονας, που θα βρεθεί σε τέτοια παρόμοια θέση, πρέπει να είναι γνώστης σε μεγάλο βαθμό του «εκμάθησης με κριτή» αλγορίθμου, ώστε να επιλέξει με σοφία την προσέγγιση που ενδείκνυται να ακολουθηθεί.

Ωστόσο, δεδομένου ότι η επιλογή προβλήματος και σεναρίου δεν ήταν τυχαία, αλλά αποτέλεσε ένα ολοκληρωμένο, μη- γραμμικό πρόβλημα, αντιπροσωπευτικό στον χώρο της υπολογιστικής νευρωνικής και δεδομένου ότι το επιλύσαμε αποτελεσματικά, δίνοντας θετικά αποτελέσματα σε όλες τις πτυχές του μοντέλου που επιλέξαμε, αποτελεί αν όχι απόδειξη τότε ισχυρή ένδειξη ότι η παρούσα διπλωματική εργασία είναι επιτυχής και ότι όντως, η μετατροπή ενός δικτύου αισθητήρων σε νευρωνικό δίκτυο μπορεί να του προσδώσει πλήρη προσαρμοστικότητα στο περιβάλλον που λειτουργεί.

6.2 Μελλοντική Εργασία

Ασφαλώς, η επιτυχία της διπλωματικής αυτής εργασίας, δεν διασφαλίζει και την απαιτούμενη πληρότητα όσον αφορά το πρόβλημα που εξετάσαμε και παρουσιάσαμε. Αποδείχτηκε, με χρήση προσομοίωσης, η ισχύς του μοντέλου, αλλά για την πλήρη αποδοχή της προσέγγισης μας από την επιστημονική κοινότητα, πρέπει να γίνουν αρκετά πειράματα και μελέτες που να ενισχύουν τις ιδέες μας.

Πιστεύουμε ότι υπάρχουν αρκετά προβλήματα προσαρμοστικότητας, στα οποία, οι επιστήμονες που προσπαθούν να τα λύσουν, ίσως χρειάζεται να μελετήσουν τις προσεγγίσεις μας και να στραφούν προς τον χώρο των νευρωνικών δικτύων, με τις τεράστιες δυνατότητες που προσφέρουν.

Η διπλωματική αυτή εργασία, αν και κρίνεται πλήρης όσον αφορά την κάλυψη του θέματος και την αποδεικτική της ισχύ από τον συγγραφέα, εν τούτοις υπάρχουν κάποιοι παράγοντες και κάποιες πρακτικές που δεν ενσωματώθηκαν στην θεωρητική μας προσέγγιση και ίσως χρήζουν έρευνας από μελλοντικούς πιθανούς συνεχιστές του δρόμου που χαράξαμε.

Όσον αφορά την αξιολόγηση των προβλέψεων του νευρωνικού δικτύου, όπως αυτή λαμβάνει χώρα στον αισθητήρα περιβάλλοντος, η προσέγγιση μας, είναι καθαρά δυαδική, με τον αισθητήρα να επιστρέφει απλά μια τιμή, 0 ή 1, ανάλογα με το αν η πρόβλεψη ήταν μη επιτυχής ή επιτυχής αντίστοιχα. Η διαδικασία αξιολόγησης, παρ' όλα αυτά, θα μπορούσε να σχεδιαζόταν με διαφορετικό, ίσως καλύτερο, τρόπο, ώστε το περιβάλλον να επέστρεφε μια πιθανότητα ορθότητας της πρόβλεψης, παρά μια μεμονωμένη δυαδική τιμή. Η σκέψη αυτή θα μπορούσε να υλοποιηθεί πρακτικά με χρήση ενός look-up table με πιθανότητες, στις οποίες θα γινόταν συσχέτιση των προβλέψεων του νευρωνικού δικτύου.

Επίσης, όπως φαίνεται ξεκάθαρα στην εργασία αυτή, αναγκαστήκαμε να δεχτούμε ένα αριθμό υποθέσεων και περιορισμών όσον αφορά κυρίως την υλοποίηση του προσομοιωτή μας. Αυτές οι υποθέσεις ενδείκνυται στο μέλλον να εξαλειφθούν ώστε να προσομοιωθεί το μοντέλο μας κάτω από εντελώς ρεαλιστικές συνθήκες περιβάλλοντος.

Όσον αφορά επίσης τον προσομοιωτή, μπορεί σε περίπτωση περαιτέρω σχεδιασμού του να γίνει πιο λειτουργικός, με την ευχέρεια επιλογής περισσότερων παραμέτρων από τον χρήστη. Αυτό μπορεί να αφορά την κατανομή των αισθητήρων στον χώρο με χρήση διαφόρων συναρτήσεων τυχαιοποίησης (random functions) ή τον διαχωρισμό των καθυστερήσεων που παρατηρούνται σε καθυστέρηση μετάδοσης (transmission delay), καθυστέρηση ουράς (queuing delay) και καθυστέρηση επεξεργασίας (processing delay).

Όπως προαναφέραμε και στα γενικά συμπεράσματα, η χρήση συγκεκριμένου μαθηματικού μοντέλου και σεναρίου, αφαιρεί την γενικότητα από την εργασία αυτή και θα μπορούσε στο μέλλον η διπλωματική αυτή εργασία να δοθεί σε κάποιο άλλο φοιτητή, ο οποίος θα μπορούσε να προσπαθήσει να ενισχύσει την ισχύ της προσέγγισης μας με το εγχείρημα της επίλυσης διαφορετικού προβλήματος με διαφορετικό μαθηματικό υπόβαθρο (κυρίως σε σχέση με την νευρωνική φύση του προβλήματος).

Εν κατακλείδι, κυριότερη αδυναμία της εργασίας μας γενικά και του προσομοιωτή μας ειδικά, αποτελεί το ότι είναι υλοποιημένος, προσεγγίζοντας τα κατασκευαστικά χαρακτηριστικά των αισθητήρων που κυκλοφορούν στο εμπόριο, χωρίς την ενσωμάτωση του λειτουργικού τους συστήματος, που είναι στις πλείστες των περιπτώσεων το tinyOS. Μια μελλοντική προσομοίωση της προσέγγισης μας σε πλατφόρμα ρεαλιστικών αισθητήρων ίσως να αποτελεί το τελικό κριτήριο της επιτυχίας του μοντέλου μας. Τέτοιος ιδανικός προσομοιωτής μπορεί να είναι ο TosSim¹³ με τις μεγάλες δυνατότητες που ανεπιφύλακτα παρέχει.

6.3 Προκλήσεις

Οι σκέψεις και οι ιδέες που παραθέσαμε στην διπλωματική αυτή εργασία, πιστεύουμε ότι αποτελούν πρόκληση για την επιστημονική κοινότητα ώστε να τις εφαρμόσει σε προβλήματα προσαρμοστικότητας, τα οποία ίσως παραμένουν άλυτα στις μέρες μας. Η απόδειξη ότι ένα δίκτυο αισθητήρων, με χρήση νευρωνικής δομής και συγκεκριμένου μαθηματικού μοντέλου, μπορεί να αντλήσει

γνώση από το περιβάλλον του και να προσαρμόσει την λειτουργία του βάσει των συνθηκών της περιοχής του, προκαλεί από μόνο του θαυμασμό και υπαγορεύει στους ερευνητές να στρέψουν την ματιά τους και προς αυτή την κατεύθυνση στα μελλοντικά τους πειράματα.

6.4 Επίλογος

Μετά από το πέρας της συγκεκριμένης διπλωματικής εργασίας, διαφάνηκε ότι, όπως και στη καθημερινή μας ζωή, η στροφή προς την φύση αποτελεί μια επιτυχημένη και εγγυημένη προσέγγιση επίλυσης πολλών προβλημάτων. Η νομοτέλεια με την οποία λειτουργεί το σύμπαν και ο κόσμος, μικρόκοσμος και μακρόκοσμος, δεν μπορεί να μας αφήνουν απαθείς. Ήρθε η στιγμή η επιστήμη των κατανεμημένων συστημάτων και των δικτύων υπολογιστών να παρατηρήσει πιο αναλυτικά την φύση, όπως την έπλασε ο Δημιουργός, με την τόση σοφία με την οποία την προίκισε. Η συγκεκριμένη εργασία, όπως και αρκετές άλλες πριν από αυτή, απλά δεικνύουν ότι φυσικές προσεγγίσεις και αλγόριθμοι που πηγάζουν μέσα από παρατηρήσεις της λειτουργίας της ζωής, σε όλα τα επίπεδα, κρύβουν απαντήσεις σε ερωτήματα τα οποία μέχρι πρόσφατα θεωρούσαμε εξαιρετικά δύσκολα να προσεγγιστούν.

Ήδη ένας σημαντικός αριθμός επιστημόνων εξετάζει φυσικά φαινόμενα και λειτουργίες, τα οποία ενσωματώνουν στις μελέτες τους, προσδίδοντας τους χαρακτηριστικά και λειτουργίες που θεωρούνται «ανώτερες». Φυσικά η έρευνα στον συγκεκριμένο τομέα βρίσκεται ακόμα σε αρχικό στάδιο, αλλά απ' ότι φαίνεται, στο μέλλον, η τεχνολογία θα τελειοποιηθεί αντλώντας γνώση από τη φύση...

Παράρτημα Α

Υλοποίηση Προσομοιωτή

A.1 Πληροφορίες Προσομοίωσης	A-1
A.2 Εκδόσεις Προσομοιωτή	A-2
A.3 Υλοποίηση ενός Αισθητήρα	A-10
A.4 Αρχικοποιήσεις	A-14

A.1 Πληροφορίες Προσομοίωσης

Στον χώρο αυτό αποφασίσαμε να παραθέσουμε κάποιες πληροφορίες σχετικά με τον προσομοιωτή που αναπτύξαμε για την απόδειξη της ισχύος του μοντέλου μας. Σκοπός του προσομοιωτή ήταν ασφαλώς η αναλυτική και ακριβής αναπαράσταση του μοντέλου που περιγράψαμε στο Κεφάλαιο 3, ώστε, μέσα από τα αποτελέσματα που θα εξάγουμε κατά την εκτέλεση του προγράμματος να αποφασίσουμε για το ενδεχόμενο επιτυχίας ή αποτυχίας της δομής μας.

Η ενδεδειγμένη υλοποίηση του προσομοιωτή είναι καίριας σημασίας για την αποδεικτική ισχύ της προσέγγισής μας, όσον αφορά το πρόβλημα που προσπαθούμε να επιλύσουμε. Στην περίπτωση που η λειτουργία της προσομοίωσης κρίνεται ιδανική και λαμβάνονται όλοι οι παράμετροι υπόψη, διασφαλίζεται η επιτυχία της διπλωματικής αυτής εργασίας.

Θα προσπαθήσουμε για τον λόγο αυτό να είμαστε ακριβείς όσον αφορά την περιγραφή αυτή και να αιτιολογήσουμε κάθε πτυχή της προγραμματιστικής μας δομής.

Η απόφαση για την επιλογή του προγραμματιστικού περιβάλλοντος εργασίας στην περίπτωση μας ήταν μια εύκολη διαδικασία, δεδομένου ότι αναμφισβήτητα το

Microsoft Visual Studio 2005 αποτελεί ένα από τα καλύτερα και πιο ολοκληρωμένα προγράμματα που κυκλοφορούν αυτή τη στιγμή. Εφόσον μελετάμε ένα κατανεμημένο σύστημα με αυτόνομες υπολογιστικές συσκευές, η χρήση αντικειμενοστραφούς γλώσσας θεωρήθηκε μονόδρομος. Θεωρήσαμε ότι με μια αντικειμενοστραφή γλώσσα ο σχεδιασμός και η υλοποίηση θα ήταν μια ομαλότερη διαδικασία. Επιλέξαμε έτσι την γλώσσα προγραμματισμού C++, την οποία γνωρίζει ενδελεχώς ο συγγραφέας και προσφέρει πολλές προγραμματιστικές επιλογές στον προγραμματιστή, παρέχοντας αξιοπιστία και σταθερότητα.

Πετύχαμε κατά την διάρκεια του σχεδιασμού να προσδώσουμε ευκολία εξαγωγής αποτελεσμάτων από τον χρήστη με την αποθήκευση λεπτομερώς των αποτελεσμάτων σε αρχεία, στα οποία η πρόσβαση είναι εξαιρετικά εύκολη.

Προσπαθήσαμε να σχεδιάσουμε τον προσομοιωτή μας με γενικό τρόπο ώστε να είναι σε θέση να προσομοιώσει πολλά διαφορετικά σενάρια χωρίς τροποποίηση κώδικα από κάποιο τρίτο. Πράγματι, μετά την υλοποίηση, μπορούμε να πούμε με ικανοποίηση ότι ο προσομοιωτής, με μικρές τροποποιήσεις ακόμα και από κάποιο αρχάριο, μπορεί να χρησιμοποιηθεί για την προσπάθεια επίλυσης οποιουδήποτε προβλήματος. Αισιοδοξούμε έτσι, ότι ο προσομοιωτής αυτός, μπορεί να αποτελέσει ένα χρήσιμο εργαλείο για οποιονδήποτε επιστήμονα της νευρωνικής που επιθυμεί να προσομοιώσει το μοντέλο που παρουσιάσαμε σε αυτή τη διπλωματική εργασία.

A.2 Εκδόσεις Προσομοιωτή


Δεδομένου ότι η υλοποίηση μας έγινε σταδιακά και σε βήματα, αποφασίσαμε να δείξουμε συνοπτικά την προγραμματιστική μας προσπάθεια, όπως αυτή έγινε μέσα από την χρονιά που πέρασε. Συνολικά παραγάγαμε 5 διαφορετικές εκδόσεις του προσομοιωτή μας, σε κάθε μια από τις οποίες προσθέσαμε επιπλέον πολυπλοκότητα και δυνατότητες. Η επιλογή σταδιακής υλοποίησης έγινε ασφαλώς για την μείωση της δυσκολίας επίλυσης του προβλήματος και για την ελαχιστοποίηση της ύπαρξης σφαλμάτων κατά τον προγραμματισμό. Σε κάθε ξεχωριστή έκδοση ουσιαστικά επιτυγχάναμε και ένα συγκεκριμένο στόχο.

Αρχικά, υλοποιήσαμε τον προσομοιωτή ώστε να αντιμετωπίσει το απλό σενάριο που περιγράψαμε στο Κεφάλαιο 4. Μετά προσθέσαμε προγραμματιστικές επιλογές ώστε να αντιμετωπιστεί το πραγματικό σενάριο (με ρεαλιστικά δεδομένα) και ακολούθως τροποποιήσαμε τον κώδικα για μελέτη του παράγοντα ευρωστίας. Στην συνέχεια προβήκαμε σε μια ριζική αλλαγή του κώδικα για να προσδώσουμε χαρακτηριστικά πραγματικών αισθητήρων στις μεταβλητές του προβλήματος και τέλος, μέσα από την ενσωμάτωση μετρικών και επιπλέον χαρακτηριστικών για αισθητήρες καταφέραμε να μελετήσουμε σε επαρκή βαθμό την κατανάλωση ενέργειας στο σύνολο αισθητήρων που συμμετέχουν στο σενάριο. Καταφέραμε έτσι σε ένα σύνολο 5 εκδόσεων να προσεγγίσουμε σιγά-σιγά το πρόβλημα που αντιμετωπίζαμε και να το αναλύσουμε εις βάθος.

A.2.1 Έκδοση 1: Απλό Σενάριο

Στην αρχική αυτή έκδοση σκοπός μας ήταν η μελέτη του απλού σεναρίου όπως το είδαμε στο Κεφάλαιο 4, με σκοπό την λήψη απόφασης σχετικά με το ενδεχόμενο πιθανής επιτυχίας της προσέγγισής μας. Μια επιτυχία στο σενάριο αυτό θα μας έδινε την ώθηση να συνεχίσουμε την υλοποίηση μας στον πραγματικό κόσμο, ενώ μια πιθανή αποτυχία θα μας γλίτωνε από χρόνο και κόπο και θα μας υποδείκνυε την στροφή προς άλλες πιθανές προσεγγίσεις ή και τελειωτική εγκατάλειψη της προσπάθειας αυτής.

Δεδομένου ότι προγραμματίζουμε σε γλώσσα C++, η οποία είναι μια αντικειμενοστραφής γλώσσα με μεγάλες δυνατότητες, αποφασίσαμε τον σχεδιασμό του προσομοιωτή σε δύο κλάσεις. Την κλάση `Sensor.cpp` και την κλάση `SNsimulator.cpp`. Ουσιαστικά η κλάση `Sensor.cpp` υλοποιεί όλα τα αναγκαία, σε αυτό το στάδιο, χαρακτηριστικά των αισθητήρων που θα χρησιμοποιηθούν, ενώ η κλάση `SNsimulator.cpp` ουσιαστικά καλεί την κλάση `Sensor.cpp` για πρακτική λειτουργία της προσομοίωσης, η οποία λαμβάνει χώρα σε αυτή την κλάση. Η `SNsimulator.cpp` καθορίζει την δομή και την τοπολογία του δικτύου που θα χρησιμοποιηθεί καθώς και το περιβάλλον λειτουργίας των αισθητήρων. Το Σχήμα A.1 δείχνει τον σχεδιασμό που ακολουθούμε παραστατικά.



Σχήμα A.1 Σχεδιαστική Δομή Προσομοιωτή (Έκδοση 1)

Αναφέρουμε εδώ ενδεικτικά, ότι, σε αυτό το στάδιο, οι αισθητήρες έχουν όλοι τα ίδια χαρακτηριστικά και δεν χωρίζονται σε συγκεκριμένους τύπους. Παρουσιάζουν δηλαδή πλήρη ομογένεια και περιλαμβάνουν τις ίδιες ρυθμίσεις.

Στην έκδοση αυτή αποφασίσαμε κάποια γενικά χαρακτηριστικά της προσομοίωσης τα οποία θα ισχύουν σε όλες τις άλλες εκδόσεις και τα οποία θα καθορίζουν ουσιαστικά το περιβάλλον λειτουργίας των αισθητήρων καθώς και την γενική τοπολογία-δομή του μοντέλου μας. Τα χαρακτηριστικά αυτά παίρνουν κυρίως την μορφή σφαιρικών μεταβλητών (global variables) στην κορυφή του προγράμματος μας.

Επιλέξαμε, κατ' αρχήν, τον γεωγραφικό χώρο να είναι μια περιοχή 1000x1000m. Στα γεωγραφικά όρια της περιοχής αυτής καθορίζεται και η απόλυτη θέση κάθε αισθητήρα που συμμετέχει στο κατανεμημένο αυτό περιβάλλον και δίνεται σε αυτόν από το πρόγραμμα τυχαία.

Υπάρχει ενσωματωμένο στο πρόγραμμα ένα σφαιρικό ρολόι (global clock), υλοποιημένο με ένα μετρητή, ώστε να προσομοιώνονται πιθανές καθυστερήσεις μεταξύ των αισθητήρων κατά την λειτουργία τους.

Ενσωματώθηκαν επίσης στο πρόγραμμα παράμετροι χρήσιμοι για την νευρωνική φύση του δικτύου όπως ρυθμός μάθησης, τιμή κατωφλίου, κλίση σιγμοειδούς συνάρτησης και momentum. Καθορίστηκαν επίσης μεταβλητές αναγκαίες για την γενική λειτουργία του μοντέλου όπως αριθμός εποχών, συνολικός αριθμός επαναλήψεων εκμάθησης, επιτρεπτή τιμή λάθους στην οποία σταματά η διαδικασία εκμάθησης, όρια επιτυχίας σύμφωνα με τα οποία αξιολογεί ο αισθητήρας περιβάλλοντος τις προβλέψεις του νευρωνικού δικτύου στην ενισχυτικής μάθησης προσέγγιση μας καθώς και άλλα ειδικά χαρακτηριστικά όπως

παράμετροι κανονικοποίησης των δεδομένων εισόδου που αφορούν, σε αυτή τη περίπτωση, μετρήσεις θερμοκρασίας.

Ο χρήστης της προσομοίωσης, σε πρώτη φάση, αποκτά την δυνατότητα να εκτελέσει ένα στιγμιότυπο της προσομοίωσης με βάση την τοπολογία που επέλεξε και να εξάγει αποτελέσματα σε μορφή αρχείου όσον αφορά το σφάλμα στην διαδικασία εκπαίδευσης του δικτύου.

A.2.2 Έκδοση 2: Πραγματικό Σενάριο

Στην έκδοση αυτή ενσωματώσαμε στον προσομοιωτή μας τις αναγκαίες προγραμματιστικές δομές ώστε να είναι σε θέση να προσομοιώσει το πραγματικό σενάριο που μελετάμε. Ασφαλώς πρόκειται για την πιο σημαντική έκδοση του προσομοιωτή διότι αυτή θα καθορίσει, σε γενικές γραμμές, αν όντως η προσέγγιση μας είναι επιτυχής καθώς σε αυτήν θα εξαχθούν συμπεράσματα που αφορούν την εκμάθηση του δικτύου, σε πρώτη φάση και την ομαλότητα λειτουργίας του δικτύου σε δεύτερη (διαδικασία ελέγχου), που θα αφορά κυρίως πρόβλεψη θερμοκρασίας. Αρχικά, ένα από τα πρώτα πράγματα που έπρεπε να γίνουν ήταν η τροποποίηση της κλάσης `Sensor.cpp` ώστε να ενσωματώσει τις αναγκαίες δυνατότητες για μέτρηση πραγματικών τιμών θερμοκρασίας και υγρασίας (αγνοήσαμε τις μετρήσεις τάσης και φωτός ως δευτερευόντως σημασίας).

Η συμπερίληψη των συγκεκριμένων μετρήσεων, είχε αντίκτυπο και στην κλάση `SNsimulator.cpp`, η οποία έπρεπε επίσης να τροποποιηθεί ώστε να μπορεί το νευρωνικό δίκτυο να υπολογίζει προβλέψεις για δεδομένα εισόδου όχι μόνο θερμοκρασίες, αλλά και ποσοστά σχετικής υγρασίας στην περιοχή.

Επίσης, δεδομένου ότι σε αυτή την έκδοση θα έπρεπε να υλοποιηθεί και η διαδικασία ελέγχου του συστήματος, η οποία διαδικασία ουσιαστικά αποτελείται από προσομοίωση του μοντέλου σε συνθήκες πραγματικής λειτουργίας στο περιβάλλον ζωής των αισθητήρων, τροποποιήθηκε ακόμη περισσότερο η κλάση `SNsimulator.cpp`, ώστε στο τέλος της διαδικασίας εκμάθησης να ξεκινά μια διεργασία στην οποία το δίκτυο αισθητήρων κρίνεται ως εκπαιδευμένο και

προβλέπει μελλοντικές θερμοκρασίες βασισμένο στην γνώση που άντλησε από το ίδιο το περιβάλλον.

Συμπεριλήφθησαν και κάποιοι άλλοι σχετικοί παράμετροι στον προσομοιωτή όπως παράμετροι κανονικοποίησης των δεδομένων εισόδου όσον αφορά τις μετρήσεις υγρασίας και αριθμός επαναλήψεων ελέγχου του δικτύου.

Αποκτήθηκε έτσι η ικανότητα από τον χρήστη του προσομοιωτή, σε αυτή τη φάση, να εκτελέσει ένα στιγμιότυπο της προσομοίωσης με βάση την τοπολογία που επέλεξε και να εξάγει αποτελέσματα σε μορφή αρχείων, όχι μόνο όσον αφορά το σφάλμα στην διαδικασία εκπαίδευσης του δικτύου, αλλά και το αντίστοιχο σφάλμα στην διαδικασία λειτουργίας-ελέγχου του δικτύου αυτού.

A.2.3 Έκδοση 3: Παράγοντας Ευρωστία

Αφού ολοκληρώθηκε η υλοποίηση της γενικής μορφής του προσομοιωτή, ώστε να είναι σε θέση ο χρήστης να εκπαιδεύσει ένα δίκτυο της δομής του μοντέλου μας και να το μελετήσει μετέπειτα σε συνθήκες λειτουργίας πραγματικού περιβάλλοντος, ήρθε η στιγμή να προσομοιωθούν συγκεκριμένοι παράγοντες που αφορούν χαρακτηριστικά και ιδιαιτερότητες των νευρωνικών δικτύων καθώς και των δικτύων αισθητήρων στο σύνολο τους. Ένας πρώτος παράγοντας που επιλέξαμε να εξετάσουμε, ο οποίος είναι ικανός να προσδώσει στο δίκτυο μας επιπλέον δυνατότητες και προοπτικές, είναι ο παράγοντας ευρωστία, όπως τον μελετήσαμε και τον παρουσιάσαμε στο Κεφάλαιο 5, κατά την παρουσίαση των αποτελεσμάτων. Ουσιαστικά τροποποιήσαμε τον κώδικα που αφορά την διαδικασία ελέγχου του μοντέλου μας και αφαιρέσαμε, μέσα από διαφορετικές εκτελέσεις του προσομοιωτή, διαφορετικό, κάθε φορά, αριθμό αισθητήρων από την νευρωνική μας δομή. Οι αισθητήρες αυτοί συμμετείχαν στην προσέγγιση μας, είτε στο επίπεδο εισόδου, είτε στο κρυφό επίπεδο της νευρωνικής τοπολογίας. Έτσι, καταφέραμε με τον τρόπο αυτό, να εξάγουμε χρήσιμα συμπεράσματα (μέσα από τα αρχεία της διαδικασίας ελέγχου του συστήματος) που αφορούν την ευρωστία του μοντέλου κατά την λειτουργία του, με μειωμένο αριθμό αισθητήρων, από τον αριθμό που αρχικά συμπεριλάμβανε κατά την διαδικασία της εκπαίδευσης του.

Προγραμματιστικά, για την επίτευξη της ζητούμενης λειτουργίας της προσέγγισης μας, προσθέσαμε κάποιες επιπλέον παραμέτρους στο σενάριο αυτό, οι οποίες αφορούν τον αριθμό των νεκρών αισθητήρων επιπέδου εισόδου και κρυφού επιπέδου.

Τροποποιήθηκε έτσι, σε αυτή την περίπτωση, το αρχείο της κλάσης `SNsimulator.cpp`, με την κλάση `Sensor.cpp` να παραμένει απaráλλακτη με πριν.

A.2.4 Έκδοση 4: Πραγματικοί Αισθητήρες


Η συγκεκριμένη έκδοση δεν αποσκοπεί στην μελέτη κάποιου παράγοντα ή στην λειτουργία του δικτύου κάτω από συγκεκριμένες, ιδιάζουσες συνθήκες, αλλά πρόκειται για ένα μεταβατικό στάδιο, που απαιτείται να γίνει ώστε να μελετηθεί, σε μετέπειτα έκδοση, η κατανάλωση ενέργειας στους αισθητήρες μας κατά την διαδικασία εκμάθησης του δικτύου.

Στο συγκεκριμένο σενάριο, ο προγραμματιστικός κώδικας που αφορούσε την διαδικασία ελέγχου της προσέγγισης μας, κρίνεται ως πλεονάζων, γι' αυτό και αφαιρείται για απλοποίηση της εργασίας μας.

Αυτό που απαιτείται σε αυτή την έκδοση είναι η μετατροπή των αισθητήρων από γενικές υπολογιστικές μηχανές περιορισμένων δυνατοτήτων, σε ρεαλιστικούς αισθητήρες οι οποίοι αντιπροσωπεύουν κάποια συγκεκριμένα μοντέλα που υπάρχουν στο παζάρι. Όπως είδαμε στο Κεφάλαιο 4, τα μοντέλα των αισθητήρων αυτών αποφασίστηκε όπως είναι ο `TelosB` και ο `Imote2`, προϊόντα της εταιρίας `Crossbow`. Έτσι, τροποποιήσαμε την κλάση `Sensor.cpp` και ενσωματώσαμε δύο υποκλάσεις της, την `TelosB.cpp` και την `Imote2.cpp`. Όπως ορθά μαντεύει ο αναγνώστης πρόκειται για συγκεκριμένες υλοποιήσεις των μοντέλων αισθητήρων `TelosB` και `Imote2`, σύμφωνα με τις προδιαγραφές της εταιρίας, όπως αυτές εμφανίζονται στην ιστοσελίδα της, στον τομέα που αφορά τα συγκεκριμένα μοντέλα²⁰.

Ασφαλώς η μετατροπή αυτή, η οποία φαίνεται γραφικά στο Σχήμα A.2, προσθέτει χαρακτηριστικά στην προσομοίωση μας τα οποία μόνο η αντικειμενοστρέφεια ως έννοια μπορεί να προσδώσει. Χαρακτηριστικά όπως κληρονομικότητα και

πολυμορφισμός διευκολύνουν σε μεγάλο βαθμό την υλοποίηση και την περαιτέρω μελλοντική ανάπτυξη της εφαρμογής μας.



Σχήμα A.2 Σχεδιαστική Δομή Προσομοιωτή (Έκδοση 4)

Η σχεδιαστική αυτή στροφή μας από το αρχικό πλάνο, όπως διαφάνηκε στο Σχήμα A.1, ήταν μια αναγκαία διαδικασία ώστε να κατηγοριοποιήσουμε ξεχωριστά τις δυνατότητες και τα χαρακτηριστικά κάθε αισθητήρα της τοπολογίας μας και να μπορούμε να τους αναλύσουμε σε επόμενο στάδιο, σε ατομικό ή σε ομαδικό (όσον αφορά το layer στο οποίο ανήκουν) επίπεδο.

Η υλοποίηση της κλάσης SNsimulator.cpp δεν παρατηρεί σε αυτό το στάδιο μεγάλες αλλαγές, λόγω του προσεκτικού καταμερισμού των ευθυνών της κλάσης Sensor.cpp, στις κλάσεις TelosB.cpp και Imote2.cpp, σε συνδυασμό με τον πολυμορφικό χαρακτήρα των δύο αυτών υποκλάσεων, ο οποίος τους δίδεται από την κληρονομική τους φύση.

A.2.5 Έκδοση 5: Κατανάλωση Ενέργειας

Στην τελευταία αυτή έκδοση του προσομοιωτή μας αποφασίσαμε όπως μελετήσουμε την κατανάλωση ενέργειας στους αισθητήρες που συμμετέχουν στην δομή του προβλήματος που εξετάζουμε. Βασικά πρόκειται για μια απόφαση, η

οποία λήφθηκε από πριν, δεδομένου ότι ο κύριος λόγος για τον οποίο υλοποιήσαμε στην προηγούμενη έκδοση κλάσεις πραγματικών αισθητήρων, ήταν ακριβώς για να μελετήσουμε στο στάδιο αυτό την συμπεριφορά τους αυτή, όσον αφορά την κατανάλωση ενέργειας.

Δεδομένης της διαίρεσης της κλάσης `Sensor.cpp` σε υποκλάσεις, η διαδικασία προσομοίωσης της ενέργειας κατανάλωσης απλοποιήθηκε αρκετά, καθώς τα βασικά σενάρια στα οποία παρατηρείται μεγάλη ενεργειακή ανάγκη είναι τα σενάρια στα οποία κάποιος αισθητήρας μεταδίδει ή δέχεται δεδομένα. Το συγκεκριμένο σενάριο υλοποιείται αποκλειστικά στην κλάση `Sensor.cpp` και με απλή τροποποίηση των σχετικών μεθόδων της κλάσης, επιτυγχάνεται η λειτουργία αυτή.

Τα άλλα σενάρια στα οποία παρατηρείται επίσης κατανάλωση ενέργειας και τα οποία εξετάζονται είναι η εκτέλεση ενός αριθμού εντολών στον επεξεργαστή του αισθητήρα, η λειτουργία κάποιου αισθητήρα σε κατάσταση βαθιού ύπνου, δεδομένου ότι στην κατάσταση αυτή παραμένει για ένα πολύ μεγάλο χρονικό διάστημα και τέλος η διαδικασία ξυπνήματος για μετάδοση, λήψη ή επεξεργασία δεδομένων, διαδικασία που επιβαρύνει σε δευτερεύων βαθμό βέβαια την κατανάλωση ενέργειας.

Στην τελευταία αυτή έκδοση απαιτείται ότι οι υποκλάσεις που αναπτύσσουμε αποτελούν ακριβείς υλοποιήσεις των μοντέλων αισθητήρων `TelosB` και `Imote2`, σύμφωνα με τις προδιαγραφές της εταιρίας και ότι οι τιμές που δίνονται στις κρίσιμες μετρικές των τύπων αυτών αισθητήρων, συνάδουν πλήρως με τα τεχνικά τους χαρακτηριστικά.

Η τελευταία αυτή έκδοση, διατηρεί μια προγραμματιστική δομή ώστε να μπορεί να χρησιμοποιηθεί σε περαιτέρω μελλοντικές μελέτες, που αφορούν μελέτη συγκεκριμένων παραγόντων σε σχέση με τα δίκτυα αισθητήρων, τα νευρωνικά δίκτυα και το μοντέλο που ακολουθούμε.

A.3 Υλοποίηση ενός Αισθητήρα

Οι αισθητήρες που κατασκευάζονται στις μέρες μας αποτελούν πλέον ολοκληρωμένες υπολογιστικές μηχανές μικρού μεγέθους. Ο σχεδιασμός και τα τεχνολογικά τους χαρακτηριστικά είναι σχεδόν τελειοποιημένα, σε σημείο που να προσεγγίζουν εξαιρετικές αποδόσεις κατά την λειτουργία τους.

Το γεγονός αυτό δυσχεραίνει, δυστυχώς, τον σχεδιασμό του προσομοιωτή μας καθώς είναι πολύ δύσκολο να επιτευχθεί ακριβής προσομοίωση κάθε χαρακτηριστικού ενός αισθητήρα.

Μεγάλο μειονέκτημα στην προσέγγιση μας, το γεγονός ότι οι ολοκληρωμένες αυτές συσκευές εργάζονται πλέον με δικό τους λειτουργικό σύστημα (tinyOS), κάτι που είναι αδύνατο να προσομοιωθεί με ένα πρόγραμμα, προϊόν εργασίας ενός εξαμήνου.

Επιλέξαμε έτσι να συμπεριλάβουμε τα κυριότερα στοιχεία που ουσιαστικά καθορίζουν και στον μεγαλύτερο βαθμό την λειτουργία ενός αισθητήρα, όπως αυτά καθορίζονται από τους πλέον σύγχρονους αισθητήρες που κυκλοφορούν στο παζάρι:

- Διάρκεια Ζωής, όπως αυτή καθορίζεται από τις μπαταρίες που τροφοδοτούν κάποιο συγκεκριμένο αισθητήρα και διασφαλίζει την λειτουργία του αισθητήρα μέχρι τον θάνατο του, από έλλειψη ενέργειας. Αναφέρουμε εδώ ενδεικτικά ότι η (αρχική) διάρκεια ζωής του αισθητήρα καθορίζεται από δύο άλλες μεταβλητές της κλάσης, τον αριθμό μπαταριών και τον τύπο μπαταριών που χρησιμοποιούνται, ο οποίος τύπος καθορίζει και την συνολική ενέργεια που αποθηκεύει κάθε μπαταρία.
- Χρόνος καθυστέρησης, περισσότερο για σκοπούς προσομοίωσης, ο χρόνος αυτός καθορίζει την συνολική καθυστέρηση αυτού του αισθητήρα από τους γειτονικούς του αισθητήρες.
- Γεωγραφική Θέση, (x,y position), η οποία ορίζει και την ακριβή γεωγραφική θέση του αισθητήρα στον χώρο.
- Ακτίνα, η οποία καθορίζει και την μέγιστη εμβέλεια εκπομπής ενός αισθητήρα.

- Μνήμη, η οποία χρησιμοποιείται για αποθήκευση και επεξεργασία ενός αριθμού τιμών, τις οποίες χρειάζεται ο αισθητήρας κατά την εργασία του. Κρατά τα περιεχόμενα του αισθητήρα στον χώρο αυτό και αντιπροσωπεύει την μνήμη τυχαίας προσπέλασης.
- Μετρητής Στοίβας, ο οποίος μετρητής καθορίζει την τρέχων κορυφή της μνήμης στην οποία υπάρχουν αποθηκευμένα δεδομένα και ουσιαστικά δεικνύει την θέση αποθήκευσης της επόμενης τιμής.
- Ταυτότητα αισθητήρα (sensor id), ένας μοναδικός αριθμός που διαχωρίζει τον αισθητήρα από τους άλλους που βρίσκονται στο περιβάλλον του.
- Χαρακτηριστικά που ορίζουν την ενεργειακή συμπεριφορά του αισθητήρα και περικλείονται στην τάση και στην ένταση του ρεύματος που χρησιμοποιείται για αποστολή/λήψη δεδομένων, στην αντίστοιχη τάση και ένταση κατά την διάρκεια της κατάστασης βαθιού ύπνου, στον χρόνο που χρειάζεται ο αισθητήρας να ξυπνήσει από την κατάσταση βαθιού ύπνου και στην ενέργεια ανά εντολή που καταναλώνει ο αισθητήρας.

Για τις ανάγκες της προσομοίωσης μας, αναγκαστήκαμε να προσθέσουμε κάποια ιδιαίτερα χαρακτηριστικά και μεταβλητές στους αισθητήρες, ώστε να είναι σε θέση να ανταποκριθούν στις ανάγκες του μοντέλου μας.

Τα ιδιαίτερα αυτά χαρακτηριστικά που αφορούν κυρίως την νευρωνική φύση των αισθητήρων και ενσωματώθηκαν κατά την προσπάθεια μας να τους μετατρέψουμε σε νευρώνια είναι:

- Τιμή Κατωφλίου, που αντιπροσωπεύει την τιμή κατωφλίου που εισάγεται σε κάθε νευρώνιο-αισθητήρα.
- Βάρος Κατωφλίου, που αντιπροσωπεύει το βάρος που συνδέει το υποθετικό, φαινομενικό κατώφλι στον αισθητήρα.
- Θέση Επιπέδου, παράμετρος που ουσιαστικά καθορίζει την ακριβή θέση του αισθητήρα στην νευρωνική τοπολογία που συμμετέχει.
- Ενισχυτικό Σήμα, που προσδιορίζει κατά την διαδικασία της εκμάθησης το τρέχων σήμα αξιολόγησης από τον αισθητήρα περιβάλλοντος, το

ενδεχόμενο δηλαδή επιτυχούς ή μη πρόβλεψης του νευρωνικού δικτύου για τα τρέχοντα δεδομένα εισόδου.

- Πίνακας Βαρών, ο οποίος προσομοιώνει τα υποθετικά βάρη μεταξύ των αισθητήρων ενός επιπέδου και του επόμενου. Στην περίπτωση αισθητήρα με ικανότητα μετρήσεων θερμοκρασίας και υγρασίας, υπάρχουν δύο πίνακες βαρών, ένας για κάθε κλιματολογική μετρική. Κατά την διαδικασία της εκμάθησης, δημιουργείται ένας δεύτερος, βοηθητικός πίνακας ο οποίος κρατά τις τιμές βαρών στην αμέσως προηγούμενη επανάληψη εκμάθησης του νευρωνικού δικτύου και χρησιμοποιείται βασικά για τον παράγοντα ορμής (momentum).
- Διαφορά Βαρών, πίνακας ίδιου μεγέθους με τον πίνακα βαρών ο οποίος καθορίζει κατά την διαδικασία εκπαίδευσης του δικτύου την διαφορά στην πρόβλεψη σε σχέση με το πραγματικό αποτέλεσμα θερμοκρασίας και χρησιμοποιείται για την τροποποίηση των βαρών σε κάθε επανάληψη.
- Τιμή εξόδου, μεταβλητή που αντιπροσωπεύει την τελική τιμή κάθε νευρωνίου αφού ζυγίσει τα βάρη με τις τιμές εισόδου από τα νευρώνια του προηγούμενου επιπέδου και περάσει την τιμή αυτή από την σιγμοειδή συνάρτηση.

Τέλος, προσδώσαμε κάποιες χρήσιμες λειτουργίες στους αισθητήρες μας, ώστε να μπορέσουν να εργαστούν στο περιβάλλον που τους τοποθετήσαμε για την επίλυση του προβλήματος που τους θέσαμε. Οι κύριες λειτουργίες είναι:

- `clear_memory()`: καθαρίζει τα περιεχόμενα της μνήμης του αισθητήρα, μηδενίζοντας την τιμή του μετρητή στοίβας.
- `retrieve_from_memory()`: επιστρέφει το τελευταίο στοιχείο που είναι αποθηκευμένο στην μνήμη του αισθητήρα.
- `reduce_energy(action, bits)`: μειώνει την ενέργεια του αισθητήρα σύμφωνα με την τρέχων πράξη που επιτελεί και σύμφωνα με τον αριθμό δεδομένων που συμμετέχουν σε αυτή την συγκεκριμένη πράξη (αφορά κυρίως μετάδοση/λήψη δεδομένων).

- `send_message(transceiver id, receiver id, message)`: προσομοιώνει την αποστολή ενός πακέτου με συγκεκριμένο περιεχόμενο (`message`) από κάποιο αισθητήρα με ταυτότητα `transceiver id` σε κάποιο άλλο με ταυτότητα `receiver id`.
- `normalize_input_data(function)`: κανονικοποιεί τα δεδομένα εισόδου σύμφωνα με την συνάρτηση (`function`) που δίνεται ως παράμετρος. Η κανονικοποίηση μπορεί να επιτευχθεί με ειδική συνάρτηση κανονικοποίησης ή με πέρασμα από κάποια σιγμοειδή ή άλλη συνάρτηση.
- `initialize_weights()`: αρχικοποιεί τα βάρη στην αρχή της προσομοίωσης, προτού ξεκινήσει η διαδικασία εκμάθησης, με μικρές τιμές που κυμαίνονται από 0 μέχρι 0.5.
- `initialize_bias()`: αρχικοποιεί, με μικρές τιμές, το βάρος του κατωφλίου πριν την έναρξη της διαδικασίας εκπαίδευσης του δικτύου.
- `set_layer(layer number)`: καθορίζει το επίπεδο στο οποίο ανήκει ο αισθητήρας, εάν και εφόσον συμμετέχει στο μοντέλο μας, στην νευρωνική τοπολογία που καθορίσαμε.
- `compute_input()`: υπολογίζει το άθροισμα των γινομένων των τιμών εξόδου των νευρωνίων του προηγούμενου επιπέδου και των αντίστοιχων βαρών τους, σύμφωνα με την θέση του συγκεκριμένου αισθητήρα στην νευρωνική δομή.
- `compute_final_output(function)`: υπολογίζει την τελική τιμή του αισθητήρα-νευρωνίου, η οποία είναι η τιμή που υπολογίζεται στην `compute_input()` μέθοδο, αφού περάσει από μια συνάρτηση, που μπορεί να είναι η σιγμοειδής συνάρτηση, μια συνάρτηση κανονικοποίησης ή μια άλλη συνάρτηση.
- `check_energy()`: ελέγχει αν ο αισθητήρας έχει την απαιτούμενη ενέργεια για την λειτουργία την οποία προσπαθεί να επιτελέσει. Στην περίπτωση που η ενέργεια του μηδενιστεί, η μέθοδος αυτή καθορίζει τον αισθητήρα ως νεκρό.
- `evaluate_signal()`: μέθοδος που λαμβάνει χώρα στον αισθητήρα περιβάλλοντος και έχει σαν σκοπό να αξιολογήσει την πρόβλεψη του

τεχνητού νευρωνικού δικτύου και να κρίνει, μέσα από τις δικές του μετρήσεις, αν η πρόβλεψη ήταν επιτυχής ή μη.

- `compute_difference(index,policy)`: υπολογίζει την απαιτούμενη τιμή σύμφωνα με την οποία τροποποιούνται τα βάρη του αισθητήρα με μοναδική ταυτότητα `index` κατά την διαδικασία μάθησης, λαμβάνοντας υπόψη την πολιτική (`policy`) που ακολουθείται κατά την διαδικασία. Η πολιτική αυτή είναι είτε ο αλγόριθμος Widrow-Hoff ή ο αλγόριθμος Selective Bootstrap.
- `adapt_bias_weights(policy)`: χρησιμοποιείται για την τροποποίηση των βαρών του συγκεκριμένου αισθητήρα, σύμφωνα με τους υπολογισμούς που έγιναν με την μέθοδο `compute_difference()`, βάσει της πολιτικής που ακολουθείται στο συγκεκριμένο σενάριο που εκτελείται.

A.4 Αρχικοποιήσεις

Στο τέλος του Παραρτήματος Α θεωρήσαμε χρήσιμο να παραθέσουμε τις γενικές μεταβλητές που χρησιμοποιήσαμε στην προσομοίωση μας σε συνδυασμό με τις τελικές τιμές τις οποίες δώσαμε σε αυτές τις παραμέτρους.

Η παράθεση αυτή τιμών, μπορεί να κρίνεται ως πλεονάζων σε γενικές αναπτύξεις προγραμμάτων, αλλά στην συγκεκριμένη προσομοίωση θεωρείται σημαντική διότι ουσιαστικά η σύγκλιση ενός νευρωνικού δικτύου, στο πρόβλημα που προσπαθεί να επιλύσει, επιτυγχάνεται μέσα από την εύρεση των ακριβών τιμών που πρέπει να δοθούν στις σχετικές μεταβλητές του προβλήματος.

Εξάλλου, όλοι οι μεγάλοι επιστήμονες με πείρα στα νευρωνικά δίκτυα, μπορούν να εξάγουν άμεσα κάποια συμπεράσματα για κάποιο πρόβλημα νευρωνικής φύσης, απλά με την εξέταση των τιμών που δίνονται στις σχετικές παραμέτρους του προβλήματος.

Η παρουσίαση αυτών των παραμέτρων εκτός από τις μεταβλητές νευρωνικής φύσης θα συμπεριλάβει και μεταβλητές που αφορούν τα δίκτυα αισθητήρων και κάποια χαρακτηριστικά του ρεαλιστικού περιβάλλοντος λειτουργίας τους.

Οι κυριότεροι παράμετροι του προσομοιωτή σε συνδυασμό με τις τιμές που λαμβάνουν είναι:

- AREA DISTANCE: τα γεωγραφικά όρια του περιβάλλοντος λειτουργίας των αισθητήρων. Καθορίζεται 1000x1000 m.
- MAXIMUM RADIO COVERAGE: η μέγιστη κάλυψη σε εκπομπή πακέτων από τους αισθητήρες του προβλήματος. Επιλέγηκε η τιμή των 30 m δεδομένου και των μικρών γεωγραφικά ορίων της περιοχής μας.
- MAXIMUM DELAY: η μέγιστη καθυστέρηση που μπορεί να παρατηρηθεί κατά την μετάδοση πακέτων σε κάποιο αισθητήρα. Επιλέξαμε μέγιστη τιμή τα 200 mseconds.
- MAXIMUM MEMORY: το μέγιστο ποσό μνήμης τυχαίας προσπέλασης (RAM) των αισθητήρων μας. Μετρίεται σε ακέραιο αριθμό float τιμών και δεδομένης της σχετικής πολυπλοκότητας του προβλήματος μας, δώσαμε στον παράγοντα αυτό την τιμή 40.
- MAXIMUM SENSOR ID NUMBER: η μέγιστη πιθανή τιμή ταυτότητας κάποιου αισθητήρα, λαμβάνοντας υπόψη ότι κάθε αισθητήρας του προβλήματος ορίζεται μοναδικά. Δώσαμε συμβολικά την τιμή 1000.
- SIGMOID SLOPE: η τιμή που δίνεται στην κλίση της σιγμοειδούς συνάρτησης και ουσιαστικά επηρεάζει την τελική τιμή που παίρνει κάθε νευρώνιο κατά την διαδικασία εκμάθησης και λειτουργίας του συστήματος. Η τιμή που επιλέγεται είναι η τιμή 1.
- LEARNING RATE: ο ρυθμός μάθησης της σύγκλισης του προβλήματος. Καθορίζει τον ρυθμό με τον οποίο εκπαιδεύεται το δίκτυο μας και παίρνει, μετά από προσεκτικές μελέτες, την τιμή 0.2.
- TIME_PREDICTION: το χρονικό διάστημα πρόβλεψης μελλοντικής θερμοκρασίας. Δεδομένου ότι επιθυμούμε πρόβλεψη για διάστημα μιας ώρας δίνουμε στην παράμετρο αυτή την τιμή 3600 δευτερόλεπτα.
- MOMENTUM: ο παράγοντας ορμής στην προσομοίωση μας που χρησιμοποιείται λόγω της νευρωνικής μορφής του προβλήματος μας και χρησιμοποιείται για αποφυγή παραμονής για μεγάλο χρονικό διάστημα του προσομοιωτή μας σε κάποιο τοπικό ακρότατο. Βασικά ο παράγοντας αυτός

παίζει δευτερεύοντα ρόλο στο σενάριο μας και λαμβάνει την τιμή 0.4 χωρίς προσεκτική μελέτη για επιλογή της πρέπουσας τιμής αυτής.

- BIAS: αντιπροσωπεύει το κατώφλι που χρησιμοποιείται ως είσοδος σε κάθε νευρώνιο. Παίρνει εξ ορισμού την τιμή 1.
- NUMBER OF LAYERS: ο αριθμός επιπέδων που θα χρησιμοποιηθούν στην νευρωνική μας τοπολογία, στον οποίο δεν συμπεριλαμβάνεται το επίπεδο εισόδου του δικτύου. Ουσιαστικά με τον παράγοντα αυτό καθορίζεται ο αριθμός κρυφών επιπέδων του δικτύου. Στην περίπτωση μας δίνουμε στην μεταβλητή αυτή την τιμή 2 που αφορά ένα κρυφό επίπεδο και ένα επίπεδο εξόδου.
- INPUT NEURONS: ο αριθμός των νευρώνων του επιπέδου εισόδου. Πήρε την τιμή 4.
- HIDDEN NEURONS: ο αριθμός των νευρώνων του κρυφού επιπέδου. Πήρε μετά από μελέτες την τιμή 8.
- OUTPUT NEURONS: ο αριθμός των νευρώνων του επιπέδου εξόδου. Λόγω της δομής μας, επιλέχθηκε ο αριθμός 1.
- EPOCH: ο αριθμός εποχών στον οποίο λειτουργεί η διαδικασία εκπαίδευσης. Πρόκειται ουσιαστικά για τον αριθμό επαναλήψεων στον οποίο εκπαιδεύεται το δίκτυο μας με όλα τα δεδομένα εισόδου. Χρησιμοποιούμε μόνο μια εποχή για τους σκοπούς της προσομοίωσης μας.
- TRAINING NUMBER: ο αριθμός επαναλήψεων εκμάθησης που χρησιμοποιείται στο μοντέλο μας. Επιλέξαμε 2000 επαναλήψεις συνολικά για εκμάθηση.
- ACCEPTABLE ERROR: η επιθυμητή τιμή του σφάλματος στην οποία θα σταματήσει η διαδικασία εκμάθησης. Υπάρχει έτσι η πιθανότητα να διακοπεί πρόωρα η διαδικασία, στην περίπτωση που το δίκτυο εκπαιδευτεί. Χρησιμοποιούμε τον παράγοντα αυτό για να αποφύγουμε να παρουσιαστεί το φαινόμενο της υπέρ-εκμάθησης στο δίκτυο μας. Δεδομένου ότι έπρεπε να βρούμε μια πολύ μικρή τιμή, επιλέξαμε την τιμή 0.00001.

- **SUCCESS LIMITS:** τα όρια επιτυχίας μέσα από τα οποία ο αισθητήρας περιβάλλοντος αξιολογεί την πιθανή επιτυχία ή όχι της πρόβλεψης του τεχνητού νευρωνικού δικτύου. Επιλέξαμε μετά από αρκετή σκέψη την τιμή 0.1.
- **MINIMUM TEMPERATURE VALUE:** η ελάχιστη τιμή θερμοκρασίας που παρατηρείται στα δεδομένα που μετρούν οι αισθητήρες μας. Χρησιμοποιείται για την κανονικοποίηση των δεδομένων. Έχει τιμή 16 °C.
- **MAXIMUM TEMPERATURE VALUE:** η αντίστοιχη μέγιστη θερμοκρασία των δεδομένων εισόδου. Παίρνει την τιμή 27 °C.
- **MINIMUM HUMIDITY VALUE:** η ελάχιστη τιμή υγρασίας που παρατηρείται στα δεδομένα που μετρούν οι αισθητήρες μας. Χρησιμοποιείται επίσης για κανονικοποίηση των δεδομένων. Παίρνει τιμή 19%.
- **MAXIMUM HUMIDITY VALUE:** η αντίστοιχη μέγιστη τιμή υγρασίας των δεδομένων εισόδου. Παίρνει τιμή 52%.
- **POLICY:** ο αλγόριθμος τροποποίησης βαρών που χρησιμοποιείται στην διαδικασία εκμάθησης του εσωτερικού νευρωνικού δικτύου. Χρησιμοποιείται είτε ο Widrow-Hoff rule , είτε η Selective Bootstrap προσέγγιση. Επιλέξαμε εν τέλει τον Selective Bootstrap αλγόριθμό.
- **ENVIRONMENT_OUTPUT:** μια τελευταία παράμετρος που κρίθηκε αναγκαία κατά την υλοποίηση της προσομοίωσης και αφορά την μέθοδο με την οποία οι μετρήσεις του αισθητήρα περιβάλλοντος προσαρμόζονται στις τιμές πρόβλεψης του νευρωνικού δικτύου, ώστε να μπορούν να εξαχθούν με ασφάλεια ακολούθως συμπεράσματα σχετικά με την επιτυχία της πρόβλεψης αυτής. Οι επιλογές ήταν η σιγμοειδής συνάρτηση και η διαδικασία κανονικοποίησης με την διαδικασία κανονικοποίησης να δίνει καλύτερα αποτελέσματα εν τέλει.

Βιβλιογραφία

- ¹ Holger Karl, Andreas Willig, *Protocols and Architectures for Wireless Sensor Networks*, Publisher: John Wiley & Sons, Ltd, 2005.
- ² http://en.wikipedia.org/wiki/Sensor_network/.
- ³ <http://en.wikipedia.org/wiki/Adaptation/>.
- ⁴ Kovacec A., Ribeiro B., Kolmogorov's Theorem: From Algebraic Equations and Nomography to Neural Networks, in *Proc. of the International Conference on Artificial Neural Networks and Genetics Algorithms (ICANNGA93)*, pages 40-47, *International Conference on Artificial Neural Networks and Genetics Algorithms, Innsbruck, Austria, April 1993*.
- ⁵ Mike Holenderski, Johan Lukkien, Tham Chen Khong, Trade-offs in the Distribution of Neural Networks in a Wireless Sensor Network, *International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP 2005) 5 - 8 December 2005, Melbourne Australia, 5 December 2005*.
- ⁶ Predrag Radivojac, Uttara Korad, Krishna M. Sivalingamt, Zoran Obradovic, Learning from Class-Imbalanced Data in Wireless Sensor Networks, *Vehicular Technology Conference, 2003. VTC 2003-Fall. 2003 IEEE 58th*, page(s): 3030-3034 Vol.5., 6-9 October 2003.
- ⁷ James M. Hereford, Tuze Kuyucu, Robust Neural Networks Using Motes, *IEEE Computer Society*, pages: 117 – 124, 2005.
- ⁸ Mark Paskin, Carlos Guestrin, Jim McFadden, A Robust Architecture for Distributed Inference in Sensor Networks, *SESSION: Architectures for inference, Article No. 8*, 2005.
- ⁹ Uwe Hatnik, Sven Altmann, Using ModelSim, Matlab/Simulink and NS for Simulation of Distributed Systems, *Proceedings of the International Conference on Parallel Computing in Electrical Engineering (PARELEC'04)IEEE*.
- ¹⁰ <http://www.meridian.com.sg/Products/modeler.html/>.
- ¹¹ <http://www.mathworks.com/access/helpdesk/help/toolbox/modelsim/>.
- ¹² <http://www.isi.edu/nsnam/ns/>.

¹³ Philip Levis and Nelson Lee, TOSSIM: A Simulator for TinyOS Networks, CS Berkeley, 17 September 2003.

¹⁴ Richard S. Sutton, Andrew G. Barto, Reinforcement Learning: An Introduction, MIT Press, Cambridge, MA, 1998.

¹⁵ <http://www.xbow.com/>.

¹⁶ <http://www.xbow.com/Products/productdetails.aspx?sid=252/>.

¹⁷ <http://www.xbow.com/Products/productdetails.aspx?sid=253/>.

¹⁸ <http://www.intel-research.net/berkeley/index.asp/>.

¹⁹ <http://berkeley.intel-research.net/labdata/>.

²⁰ <http://www.xbow.com/Products/productdetails.aspx?sid=156/>.