

Ατομική Διπλωματική Εργασία

**ΠΡΟΒΛΕΨΗ ΖΗΤΗΣΗΣ ΦΥΣΙΚΟΥ ΑΕΡΙΟΥ**

**Χρίστος – Αιμίλιος Πραστίτης**

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ**



**ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ**

**Μάιος 2009**

# **ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ**

## **ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ**

### **Πρόβλεψη ζήτησης φυσικού αερίου**

**Χρίστος – Αιμίλιος Πρασίτης**

Επιβλέπων Καθηγητής

Δρ. Χρίστος Χριστοδούλου

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

Μάιος 2009

## **Ευχαριστίες**

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή, Δρ. Χρίστο Χριστοδούλου, που με εμπιστεύθηκε για την εκπόνηση αυτής της διπλωματικής εργασίας. Επίσης τον ευχαριστώ για την συνεργασία, την υπομονή και την καθοδήγηση που μου πρόσφερε κατά την διάρκεια της εργασίας αυτής.

Θα ήθελα επίσης να ευχαριστήσω την οικογένεια μου για την ατελείωτη αγάπη, υποστήριξη και συμπαράσταση που μου προσφέρουν.

## Περίληψη

Η διπλωματική αυτή εργασία έχει ως σκοπό την εφαρμογή νευρωνικών δικτύων στην προσπάθεια επίλυσης ενός πραγματικού προβλήματος. Την πρόβλεψη ζήτησης φυσικού αερίου για θέρμανση. Στόχος μας με αυτή την έρευνα είναι η απόδειξη των δυνατοτήτων των νευρωνικών δικτύων στην επίλυση δυναμικών προβλημάτων στον χρόνο σε ένα θορυβώδες περιβάλλον.

Στην εργασία αυτή αναπτύσσονται μεθοδολογία για την πρόβλεψη της ζήτησης του φυσικού αερίου για την επόμενη ώρα βασισμένοι σε πραγματικά δεδομένα ζήτησης φυσικού αερίου μιας μεγάλης εταιρίας, σε δεδομένα θερμοκρασιών και δεδομένα ταχυτήτων των ανέμων. Αυτά τα δεδομένα καλύπτουν ένα φάσμα 7 χρόνων για κάθε μέρα και κάθε ώρα. Θα υλοποιήσουμε ένα νευρωνικό δίκτυο τριών επιπέδων (3-layer Perceptron Neural Network) το οποίο θα εκπαιδευτούμε με τον αλγόριθμο ανάστροφης μετάδοσης του λάθους (Back Propagation Learning Algorithm). Προσπαθήσαμε να προσεγγίσουμε αυτό το πρόβλημα με δύο τεχνικές. Με την τεχνική του κινητού παραθύρου στον χρόνο, και με ένα στατικό δίκτυο. Στην τεχνική του κινητού παραθύρου, παρουσιάζουμε στις εισόδους του δικτύου τα δεδομένα ζήτησης σε μορφή χρονοσειράς, ελέγχοντας το μέγεθος του παραθύρου, δηλαδή το βάθος πίσω στον χρόνο που «βλέπει» το δίκτυο. Με αυτό τον τρόπο το δίκτυο μαθαίνει την συσχέτιση των δεδομένων με το πέρασμα του χρόνου. Στο στατικό δίκτυο εκτός από τις εισόδους θερμοκρασίας και ταχύτητας ανέμων, προσθέτουμε και εισόδους για τον τρέχον μήνα, είσοδο μέσου όρου της ζήτησης για την ίδια μέρα σε άλλες χρονιές καθώς και είσοδο για ένδειξη του κατά πόσο η μέρα υπό εξέταση είναι καθημερινή ή αργία.

Τα δίκτυα αυτά εκπαιδεύτηκαν και μετά από αρκετές συγκρίσεις αποτελεσμάτων και πειραματισμούς με τις παραμέτρους και τις δομές των δικτύων καταλήξαμε σε κάποιες τιμές όπου παίρναμε τα καλύτερα αποτελέσματα στην επιτυχία πρόβλεψης της ζήτησης του φυσικού αερίου. Τέλος συγκρίναμε τα αποτελέσματα των τεχνικών και καταλήξαμε στο ότι η προσέγγιση με την τεχνική του κινητού παραθύρου μας δίνει τα καλύτερα αποτελέσματα πρόβλεψης με 95.9041% επιτυχία έναντι του 85.9357% που πετύχαμε με το στατικό δίκτυο.

## Περιεχόμενα

<b>Κεφάλαιο 1</b>	<b>Εισαγωγή.....</b>	<b>1</b>
1.1	Πρόλογος	2
1.2	Σύντομη περιγραφή της προηγούμενης εργασίας στο θέμα.	3
1.3	Παράγοντες που επηρεάζουν την πρόβλεψη ζήτησης φυσικού αερίου	4
1.4	Νευρωνικά Δίκτυα πολλαπλών στρωμάτων Perceptron	5
1.4.1	McCulloch and Pitts	6
1.4.2	Perceptron	7
1.4.3	Δίκτυα πολλαπλών στρωμάτων Perceptron	9
1.4.4	Ο αλγόριθμος Back propagation	10
1.4.5	Προβλήματα του αλγόριθμου Back Propagation	14
1.5	Στατιστικές μέθοδοι για υπολογισμό του σφάλματος	14
<b>Κεφάλαιο 2</b>	<b>Προτεινόμενη λύση.....</b>	<b>17</b>
2.1	Μεθοδολογία	18
2.2	Δεδομένα	20
2.2.1	Ανάλυση δεδομένων	20
2.2.2	Προ-επεξεργασία δεδομένων	26
<b>Κεφάλαιο 3</b>	<b>Σχεδιασμός και Υλοποίηση.....</b>	<b>27</b>
3.1	Σχεδιασμός	28
3.2	Υλοποίηση	32
3.2.1	Περιγραφή των κλάσεων	32
3.2.2	Περιγραφή ροής δεδομένων	35
3.2.3	Διαφορές στις τεχνικές	36
<b>Κεφάλαιο 4</b>	<b>Αποτελέσματα .....</b>	<b>37</b>
4.1	Αποτελέσματα τεχνικής κινητού παραθύρου στον χρόνο	38
4.1.1	Αλλαγές στους ρυθμούς μάθησης και ορμής	40

4.1.2	Προσθήκη δεύτερου κρυφού επιπέδου	43
4.1.3	Αλλαγές στην δομή του δικτύου	46
4.1.4	Τελικά αποτελέσματα	49
4.2	Αποτελέσματα στατικού δικτύου	52
4.2.1	Αλλαγές στους ρυθμούς μάθησης και ορμής	54
4.2.2	Αλλαγές στην δομή του δικτύου	60
4.2.2.1	Προσθήκη δεύτερου κρυφού επιπέδου	60
4.2.2.2	Αύξηση των νευρώνων του κρυφού επιπέδου	62
4.2.3	Αλλαγές στα δεδομένα εκπαίδευσης και επαλήθευσης	65
4.2.4	Τελικά αποτελέσματα	67
<b>Κεφάλαιο 5</b>	<b>Συμπεράσματα</b>	<b>72</b>
5.1	Συμπεράσματα	73
5.2	Μελλοντική εργασία	74
<b>Βιβλιογραφία</b>		<b>76</b>
<b>Παραρτήματα</b>		<b>A-1</b>
Παράρτημα Α:	Κώδικας υλοποίησης τεχνικής κινητού παραθύρου	A-1
Αρχεία Header (Header files)		A-2
Αρχεία κλάσεων (Class files)		A-7
Παράρτημα Β:	Κώδικας υλοποίησης στατικού δικτύου	B-1
Αρχεία Header (Header files)		B-2
Αρχεία κλάσεων (Class files)		B-7
Παράρτημα Γ:	Κώδικας υλοποίησης βοηθητικών εργαλείων	Γ-1
Κώδικας υλοποίησης εργαλείου διόρθωσης δεδομένων		Γ-2
Κώδικας υλοποίησης εργαλείου προ-επεξεργασίας δεδομένων		Γ-5

# Κεφάλαιο 1

## Εισαγωγή

---

1.1 Πρόλογος	2
1.2 Σύντομη περιγραφή της προηγούμενης εργασίας στο θέμα	3
1.3 Παράγοντες που επηρεάζουν την πρόβλεψη ζήτησης φυσικού αερίου	4
1.4 Νευρωνικά Δίκτυα πολλαπλών στρωμάτων Perceptron	5
1.4.1 McCulloch and Pitts	6
1.4.2 Perceptron	7
1.4.3 Δίκτυα πολλαπλών στρωμάτων Perceptron	9
1.4.4 Ο αλγόριθμος Back propagation	10
1.4.5 Προβλήματα του αλγόριθμου Back Propagation	14
1.5 Στατιστικές μέθοδοι για υπολογισμό του σφάλματος	14

---

## 1.1 Πρόλογος

Με την ευχέρεια προσκόμισης της χρήσης φυσικού αερίου για συστήματα θέρμανσης στο εγγύς μέλλον και στην χώρα μας, μεγάλες εταιρίες πιθανόν να αναπτύξουν εγκαταστάσεις και συστήματα για παροχή αυτής της υπηρεσίας στους κάτοικους της χώρας μας. Ένα τέτοιο σύστημα σίγουρα θα περιέχει πολύπλοκες και τεράστιες σωληνώσεις οι οποίες θα μεταφέρουν το φυσικό αέριο από τον παροχέα στις οικίες των τελικών χρηστών.

Εκ φύσεως όμως το φυσικό αέριο κινείται πάρα πολύ αργά σε ένα τέτοιο σύστημα σωληνώσεως, καλύπτοντας αποστάσεις της τάξεως των μερικών μέτρων μόνο κάθε δευτερόλεπτο. Έχοντας να καλύψει τεράστιες αποστάσεις μέσα και ίσως και μεταξύ πόλεων, μπορούμε να δούμε ότι με αυτήν την ταχύτητα το αέριο που εισέρχεται στο σύστημα θα θέλει πολύ χρόνο μέχρι να φτάσει τον τελικό του προορισμό. Άρα για κάποια δεδομένη στιγμή, η ποσότητα κατανάλωσης του φυσικού αερίου για την στιγμή αυτή είναι διαφορετική από την ποσότητα που πρέπει να εισαχθεί στο σύστημα.

Οπότε, μια έγκυρη και γρήγορη πρόβλεψη της ζήτησης του φυσικού αερίου για κάποια συγκεκριμένη ώρα είναι αναγκαία από αρκετά πιο πριν, ώστε να γίνει μία σωστή ποσοτικά τροφοδότηση φυσικού αερίου στο σύστημα, και σε κατάλληλη ώρα, για να φτάσει η ποσότητα αυτή στα άκρα του δικτύου του συστήματος όταν θα γίνει η κατανάλωση του. Μπορούμε να δούμε πως ο χρόνος διεκπεραίωσης της πρόβλεψης πρέπει να κατάλληλος ώστε λαμβάνοντας υπόψη και τον χρόνο που χρειάζεται το φυσικό αέριο για να φτάσει στον προορισμό του, να φτάσει στον σωστό χρόνο όπου θα γίνει η κατανάλωση του, για την οποία είχε γίνει η πρόβλεψη αυτή. Επίσης, αυτή η πρόβλεψη πρέπει να είναι όσο το δυνατό πιο ορθή. Δηλαδή όσο πιο κοντά στην πραγματική ζήτηση του φυσικού αερίου στην χρονική στιγμή – στόχο της πρόβλεψης. Με μια σωστή πρόβλεψη θα διοχετεύεται στο σύστημα ποσότητα φυσικού αερίου η οποία ούτε θα ξεπερνάει την ζήτηση, αλλά ούτε θα είναι μικρότερη από την αναγκαία.

Με την κατασκευή ενός τέτοιου συστήματος ικανού να παράγει μια τέτοια σωστή πρόβλεψη και σε μικρό χρονικό διάστημα, οι εταιρίες θα μπορούν να αυξήσουν την παραγωγικότητα τους καθώς και να μειώσουν δραματικά τις δαπάνες τους σε έξοδα



λόγω αγοράς περισσότερου φυσικού αερίου από ότι χρειάζονται, ή σε ζημιές λόγω μη ικανοποιημένων πελατών, οι οποίοι πιθανόν να τερματίσουν την συνδρομή τους με την εταιρία διότι δεν είχαν θέρμανση λόγω έλλειψης φυσικού αερίου στο σύστημα από μια λανθασμένη πρόβλεψη.

Στόχος αυτής της διπλωματικής εργασίας είναι η μελέτη, η εύρεση μέσα από πειραματισμούς καθώς και η κατασκευή ενός κατάλληλου συστήματος ικανού να παράγει μια τέτοια πρόβλεψη, ορθά και γρήγορα. Για την μελέτη και υλοποίηση αυτή προμηθευτήκαμε πραγματικά δεδομένα ζήτησης φυσικού αερίου καθώς και δεδομένα θερμοκρασιών και ταχυτήτων ανέμων. Θα χρησιμοποιήσουμε διάφορες αρχιτεκτονικές νευρωνικών δικτύων και αλγορίθμων εκμάθησης τους, και μέσα από πειραματισμούς και σύγκριση αποτελεσμάτων θα προσπαθήσουμε να καταλήξουμε σε μια ιδανική τεχνική υλοποίησης για ένα νευρωνικό δίκτυο που θα παράγει τα καλύτερα αποτελέσματα. Αυτά δηλαδή με το μικρότερο σφάλμα στις προβλέψεις.

## **1.2 Σύντομη περιγραφή της προηγούμενης εργασίας στο θέμα**

Μέχρι σήμερα έχουν γίνει αρκετές προσεγγίσεις στην προσπάθεια επίλυσης αυτού του προβλήματος, χρησιμοποιώντας διάφορες μεθοδολογίες, είτε αυτές είναι μέσω νευρωνικών δικτύων, είτε μέσω άλλων στατιστικών μεθόδων. Για παράδειγμα σε μια τεχνική χρησιμοποιήθηκαν συστήματα ασαφούς λογικής μαζί με νευρωνικά δίκτυα στην δημιουργία ενός συστήματος που συνδυάζε τρία διαφορετικά νευρωνικά δίκτυα. Τα αποτελέσματα των προβλέψεων του συστήματος τους παρουσιάζουν σημαντική βελτίωση έναντι στατιστικών μεθόδων μέσου όρου [4]. Οι προβλέψεις έγιναν πάνω σε δεδομένα ζήτησης φυσικού αερίου για μια περιοχή στην Πολωνία που κάλυπταν ένα φάσμα περίπου δύο χρόνων. Εκτέλεσαν προβλέψεις για καθημερινές μέρες μόνο, για μία εβδομάδα και για τέσσερις εβδομάδες. Στην καθημερινή πρόβλεψη είχαν ελάχιστο ποσοστό αποτυχίας 4.04% έναντι του 4.56% που είχαν οι στατιστικές μέθοδοι. Στην εβδομαδιαία πρόβλεψη είχαν ποσοστό αποτυχίας 7.04% έναντι 10.64% που είχαν με τις στατιστικές μεθόδους και στην πρόβλεψη των τεσσάρων εβδομάδων είχαν ποσοστό αποτυχίας 7.73% έναντι 21.64%. Ένα άλλο παράδειγμα είναι η μέθοδος των Musilek, et al [5], όπου χρησιμοποίησαν ένα σύστημα που συνδυάζει νευρωνικά δίκτυα μαζί με το σύστημα προβλέψεων ELVIRA το οποίο συνδυάζει μεταξύ άλλων στατιστικές

μεθόδους, case – based reasoning και rule based συστήματα. Το νευρωνικό δίκτυο με ανάδραση λειτουργούσε σαν «πύλη» στο σύστημα, όπου τα δεδομένα περνούσαν πρώτα από αυτό, πριν δοθούν στο στατιστικό μοντέλο. Τα αποτελέσματα τους δείχνουν πιο εύστοχες προβλέψεις στην ζήτηση του φυσικού αερίου αφού βελτίωσαν τις προβλέψεις του συστήματος, από 95.7% επιτυχία σε προβλέψεις με 25% απόκλιση από τις πραγματικές τιμές σε 99.8% και από 80.3% επιτυχία σε προβλέψεις με 10% απόκλιση από τις πραγματικές τιμές σε 94%. Μία άλλη μελέτη αναφέρει την σημαντικότητα της ύπαρξης παλαιότερων δεδομένων και χρησιμοποίησής τους στην πρόβλεψη της ζήτησης του φυσικού αερίου [6]. Τέτοιου τύπου παρόμοια δεδομένα έχουμε προμηθευτεί και εμείς για την υλοποίηση αυτής της εργασίας (περισσότερα για αυτά αργότερα). Με τα ίδια δεδομένα είχε γίνει και μια παλαιότερη προκαταρκτική μελέτη μέσω προσομοιωτών νευρωνικών δικτύων όπου χρησιμοποιήθηκαν κυρίως τα δεδομένα ζήτησης των παλαιότερων χρόνων στην προσπάθεια για πρόβλεψη της διαφοράς της ζήτησης του φυσικού αερίου μεταξύ δύο ημερών[1].

### **1.3 Παράγοντες που επηρεάζουν την πρόβλεψη ζήτησης φυσικού αερίου**

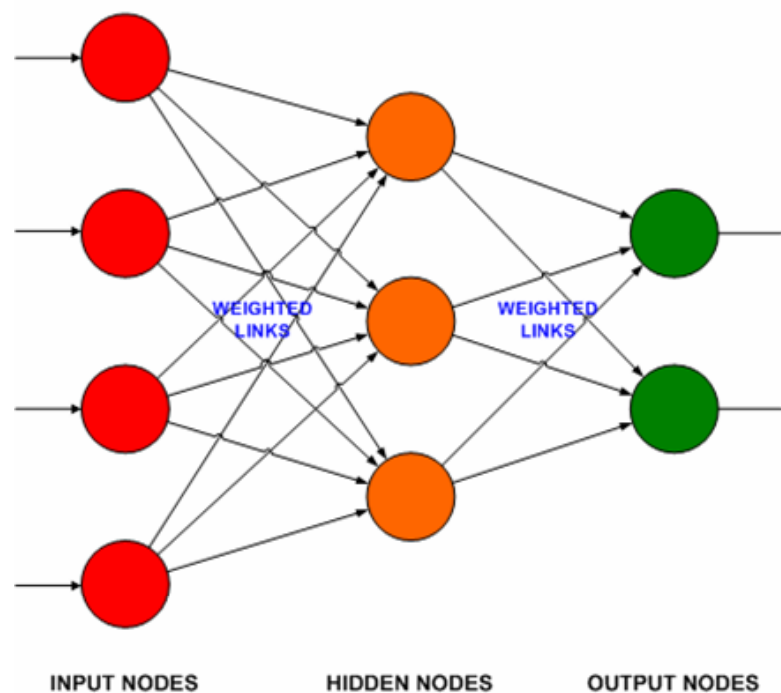
Όπως αναφέραμε πιο πάνω, το πρόβλημα αυτό χαρακτηρίζεται από την δυναμικότητα του, και την εξάρτηση του από εξωτερικούς παράγοντες. Μερικοί από αυτούς τους παράγοντες είναι:

1. Οι καιρικές συνθήκες που επικρατούν την μέρα για την οποία θα γίνει η πρόβλεψη. Πιο συγκεκριμένα η θερμοκρασία και οι ταχύτητες των ανέμων.
2. Η μέρα μέσα στην βδομάδα για την οποία θέλουμε να κάνουμε πρόβλεψη. Ανάλογα με το τι μέρα είναι, έχουμε διαφορετικές καταναλώσεις φυσικού αερίου. Η μεγαλύτερη διαφορά παρατηρείται μεταξύ του Σαββατοκύριακου και των καθημερινών, όπου στα σαββατοκύριακα παρατηρείται περισσότερη κατανάλωση / ζήτηση. Οπότε η πληροφορία αυτή είναι αναγκαία για το δίκτυο που θα κατασκευάσουμε, για να μας δώσει σωστό αποτέλεσμα. Αυτή η πληροφορία μπορεί να κωδικοποιηθεί ως 1 Boolean τιμή, για ένδειξη αν η μέρα είναι καθημερινή ή αργία.

3. Η εποχή που βρισκόμαστε μέσα στον χρόνο. Προφανώς ανάλογα με την εποχή, η κατανάλωση / ζήτηση του φυσικού αερίου για σκοπούς θέρμανσης θα είναι διαφορετική, με περισσότερη ζήτηση τους πιο κρύους μήνες του χρόνου, και μικρότερη ζήτηση στους πιο ζεστούς. Αυτή η πληροφορία πρέπει να δοθεί στο δίκτυο μας, και αυτό μπορεί να γίνει με την κωδικοποίηση του αριθμού του τρέχον μήνα σε δυαδική μορφή.

#### 1.4 Νευρωνικά Δίκτυα πολλαπλών στρωμάτων Perceptron


Ένα τεχνητό νευρωνικό δίκτυο, ή απλά νευρωνικό δίκτυο, είναι ένα μαθηματικό και υπολογιστικό μοντέλο βασισμένο στα βιολογικά νευρωνικά δίκτυα. Αποτελείται από πολλαπλές διασυνδεδεμένες μονάδες τεχνητών νευρώνων όπου γίνεται η επεξεργασία των δεδομένων. Η ανάπτυξη των νευρωνικών δικτύων ξεκίνησε από την επιθυμία των ανθρώπων να εξομοιώσουν την ικανότητα του ανθρώπινου εγκεφάλου στην μάθηση και στην γενίκευση. Όπως φαίνεται και στο πιο κάτω σχήμα (σχήμα 1.1), οι νευρώνες είναι οργανωμένοι σε επίπεδα (layers). Στο απλό αυτό παράδειγμα έχουμε το επίπεδο εισόδου, ένα κρυφό επίπεδο και το επίπεδο εξόδου.



Σχήμα 1.1: Ένα απλό νευρωνικό δίκτυο.

### 1.4.1 McCulloch and Pitts

Οι πρώτες προσπάθειες σχετικά με την μοντελοποίηση ενός τεχνητού νευρώνα με υπολογιστή, έγιναν από τους Warren McCulloch και Walter Pitts το 1943 [7]. Ο τεχνητός αυτός νευρώνας (σχήμα 1.2) είναι σε θέση να κατηγοριοποιεί τις εισόδους διαχωρίζοντας τις σε δύο κλάσεις. Στο απλό αυτό μοντέλο υπάρχει μια σειρά από εισόδους  $I_1, I_2, I_3, \dots, I_n$  και μια έξοδος  $Y$ .




Σχήμα 1.2: Ένας τεχνητός νευρώνας.

Τα  $W_1, W_2, W_3, \dots, W_n$  είναι βάρη κανονικοποιημένα σε μικρές τιμές και συσχετίζονται με μία είσοδο. Το Sum είναι το άθροισμα των εισόδων πολλαπλασιασμένα με τα βάρη. Το T είναι η τιμή του κατωφλίου. Οι τιμές του Sum και της εξόδου υπολογίζονται ως εξής:

$$Sum = \sum_{i=1}^N I_i W_i, \quad y = f(Sum).$$

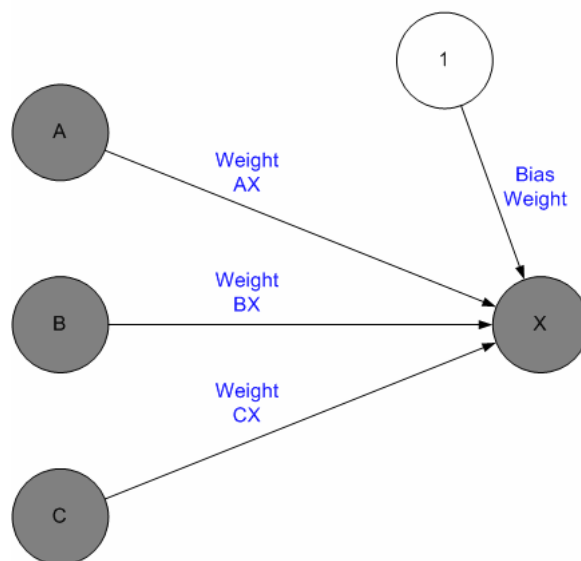
Σε αυτό το μοντέλο η συνάρτηση  $f$  είναι μια απλή συνάρτηση κατωφλίου, συνήθως με κατώφλι την τιμή 1, όπως φαίνεται στο πιο κάτω σχήμα (σχήμα 1.3):



Σχήμα 1.3: Μια απλή συνάρτηση κατωφλίου.

### 1.4.2 Perceptron

Στα τέλη της δεκαετίας του '50 ο Frank Rosenblatt παρουσίασε ένα δίκτυο που αποτελείτο από μονάδες νευρώνων μοντελοποιημένες με μια αναβαθμισμένη μέθοδο βασισμένη στο μοντέλο των McCulloch και Pitts. Ο Rosenblatt συνένωσε το μοντέλο νευρώνα των McCulloch και Pitts και την μέθοδο μάθησης του Hebbian όπου έχουμε προσαρμογή των βαρών, δημιουργώντας έτσι το μοντέλο perceptron. Επίσης στο αναβαθμισμένο αυτό μοντέλο του νευρώνα, ο Rosenblatt πρόσθεσε ακόμα μία είσοδο που αναπαριστά το bias (b), όπως φαίνεται στο σχήμα (σχήμα 1.4):




Σχήμα 1.4: Η προσθήκη του bias σε ένα τεχνητό νευρώνα.

Οπότε και ο αναβαθμισμένος τύπος υπολογισμού των αθροισμάτων έχει ως ακολούθως:

$$Sum = \sum_{i=1}^N I_i W_i + b_i$$


Τα δίκτυα perceptron χαρακτηρίζονται ως εμπρόσθια (feed forward), διότι τα δεδομένα κινούνται στο δίκτυο από νευρώνα σε νευρώνα μόνο προς μία κατεύθυνση (σχήμα 1.5). Το επίπεδο εισόδου παίρνει τα δεδομένα από είσοδο και τα διοχετεύει στο δίκτυο. Κάθε νευρώνας του κρυφού επιπέδου παίρνει ως είσοδο το σταθμισμένο άθροισμα (weighted sum) των εξόδων του επιπέδου εισόδου, και το περνούν από την συνάρτηση ενεργοποίησης τους, σε αυτήν την περίπτωση την συνάρτηση κατωφλίου (threshold function). Το αποτέλεσμα που παράγεται είναι η έξοδος του νευρώνα. Τέλος οι νευρώνες του επιπέδου εξόδου, παίρνουν σαν είσοδο το σταθμισμένο άθροισμα των εξόδων του κρυφού επιπέδου, και το περνούν και πάλι από την συνάρτηση ενεργοποίησης τους, όπου το αποτέλεσμα θα είναι τόσο η έξοδος των νευρώνων αυτών, αλλά και η έξοδος (η μέρος της εξόδου αν έχουμε περισσότερους από ένα νευρώνες στο επίπεδο εξόδου) του ίδιου του δικτύου.



**Σχήμα 1.5:** Ένα εμπρόσθιο (feed forward) δίκτυο.

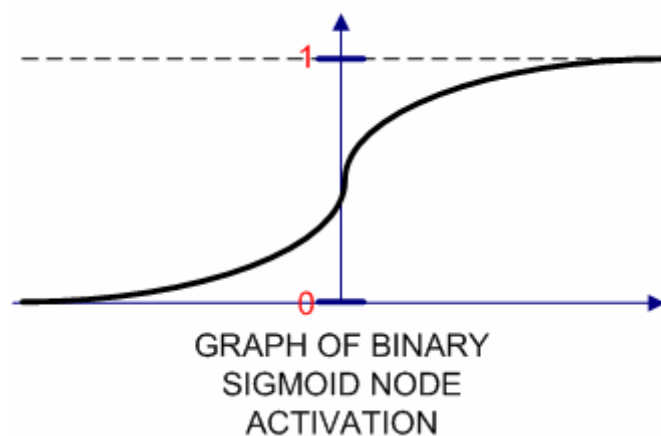
### 1.4.3 Δίκτυα πολλαπλών στρωμάτων Perceptron

Τα δίκτυα perceptron χρησιμοποιήθηκαν με μεγάλη επιτυχία σε εφαρμογές επίλυσης προβλημάτων ταξινόμησης. Όμως παρατηρήθηκε ότι για προβλήματα τα οποία δεν είναι γραμμικά διαχωρίσιμα τα δίκτυα perceptron δεν μπορούν να προσφέρουν λύση. Με την χρήση πολλαπλών στρωμάτων perceptron όμως (σχήμα 1.6), καθώς και την εισαγωγή μη γραμμικών συναρτήσεων ενεργοποίησης, όπως η σιγμοειδής συνάρτηση (σχήμα 1.7), μπορούμε να λύσουμε μη γραμμικά διαχωρίσιμα προβλήματα.



Σχήμα 1.6: Ένα δίκτυο πολλαπλών στρωμάτων perceptron.

Στα δίκτυα πολλαπλών στρωμάτων perceptron μπορούμε να χρησιμοποιήσουμε αντί της συνάρτησης κατωφλίου, την μη γραμμική σιγμοειδή συνάρτηση (σχήμα 1.7):



Σχήμα 1.7: Η σιγμοειδής συνάρτηση.

Η συνάρτηση αυτή δίνεται από τον τύπο:

$$y = \frac{1}{1 + e^{-x}}$$

Όπου  $x$  είναι το άθροισμα των γινομένων των βαρών επί τις εισόδους.

Η συνάρτηση αυτή επιστρέφει τιμές μεταξύ 0 και 1. Σε αντίθεση με την συνάρτηση κατωφλίου που μας επιστρέφει μόνο 0 ή 1, η σιγμοειδής συνάρτηση μας επιστρέφει και ενδιάμεσες τιμές. Με αυτό το τρόπο μπορούμε να ξέρουμε πόσο κοντά είμαστε στο κατώφλι, ώστε να κάνουμε ανάλογες αλλαγές μετά στα βάρη μας κατά την μάθηση του δικτύου. Επίσης η σιγμοειδής συνάρτηση είναι και παραγωγίσιμη, πράγμα που μας δίνει την δυνατότητα παίρνοντας την παράγωγο σε κάποιο σημείο να ξέρουμε πόσο αυξάνεται ή μειώνεται η συνάρτηση σε αυτό το σημείο.

#### **1.4.4 Ο αλγόριθμος Back propagation**

Ο αλγόριθμος μάθησης back propagation διατυπώθηκε αρχικά από τον Paul Werbos το 1974, αλλά δεν ήταν μέχρι το 1986 και μέσα από την δουλειά των E. Rumelhart, Geoffrey E. Hinton και Ronald J. Williams [7] που αναγνωρίστηκε, και οδήγησε σε μια αναγέννηση στον τομέα της έρευνας των τεχνητών νευρωνικών δικτύων. Ο αλγόριθμος αυτός είναι ίσως η πιο διαδομένη μέθοδος εκπαίδευσης τεχνητών νευρωνικών δικτύων και βασίζεται στην επιβλεπόμενη μάθηση (supervised learning). Στην επιβλεπόμενη μάθηση έχουμε τα επιθυμητά δεδομένα εξόδου, και μαζί με την έξοδο του δικτύου που αποτελεί την έξοδο πρόβλεψης του, μπορούμε να υπολογίσουμε το λάθος του. Σκοπός μας είναι η μείωση αυτού του λάθους, δηλαδή του λάθους μεταξύ των πραγματικών δεδομένων και των εξόδων του δικτύου. Για να το πετύχουμε αυτό πρέπει να αλλάξουμε τα βάρη στο δίκτυο κατάλληλα ώστε το σφάλμα στο επόμενο πέρασμα να έχει μειωθεί.

Ο αλγόριθμος back propagation αποτελείται από δύο φάσεις. Η πρώτη φάση είναι το εμπρόσθιο πέρασμα (feed forward phase) όπου όπως και στα δίκτυα perceptron τα δεδομένα μεταφέρονται μόνο προς τα εμπρός. Αρχικοποιούμε τα βάρη και τα κατώφλια



των νευρώνων με μικρές τυχαίες τιμές από -1 ως 1. Ο αλγόριθμος αυτός απαιτεί όπως η συνάρτηση ενεργοποίησης να είναι παραγωγίσιμη, και η πιο διαδεδομένη συνάρτηση ενεργοποίησης είναι η σιγμοειδής συνάρτηση (αυτήν θα χρησιμοποιήσω και για την διεκπεραίωση αυτής της εργασίας). Αρχικά τα δεδομένα εισόδου δίνονται στο επίπεδο εισόδου, το οποίο τα δίνει στο κρυφό επίπεδο. Η έξοδος του κάθε νευρώνα στο κρυφό επίπεδο (ή στα κρυφά επίπεδα αν είναι περισσότερα από ένα) καθώς και η έξοδος του κάθε νευρώνα στο επίπεδο εξόδου, υπολογίζεται από το άθροισμα των γινομένων των εισόδων τους. Οπότε για κάθε νευρώνα  $j$  σε κάθε επίπεδο υπολογίζουμε την έξοδο του με τον ακόλουθο τύπο:

$$Y_j = \sum_{i=0}^{i=n} O_i * W_{ij}$$

Όπου  $Y_i$  είναι η έξοδος του νευρώνα,  $O_i$  είναι η έξοδος που έρχεται από έναν νευρώνα του προηγούμενου επιπέδου και μπαίνει ως είσοδος σε αυτόν τον νευρώνα, και  $W_{ij}$  είναι το βάρος της σύνδεσης αυτού του νευρώνα με τον νευρώνα του προηγούμενου επιπέδου. Το αποτέλεσμα περνάει από την σιγμοειδή συνάρτηση. Η έξοδος αυτή όταν υπολογιστεί, δίνεται ως είσοδος στους νευρώνες του επόμενου επιπέδου, μέχρι να φτάσουμε στο επίπεδο εξόδου. Στο επίπεδο εξόδου αυτό το αποτέλεσμα θα είναι και η έξοδος (ή κομμάτι της εξόδου αν έχουμε περισσότερους από έναν νευρώνες στο επίπεδο εξόδου) του δικτύου μας. Όταν υπολογιστεί και αυτή η τιμή, τότε μπορούμε να υπολογίσουμε το σφάλμα στους νευρώνες εξόδου.

Εδώ ξεκινά η δεύτερη φάση του αλγόριθμου back propagation, όπου παίρνουμε τις τιμές από τους νευρώνες του επιπέδου εξόδου και υπολογίζουμε το σφάλμα χρησιμοποιώντας τις επιθυμητές τιμές εξόδου. Για την εύρεση του σφάλματος χρησιμοποιήσαμε την συνάρτηση του μέσου τετραγωνικού σφάλματος (mean squared error):

$$\text{MSE} = \frac{1}{N} \sum_{i=0}^n (t_i - o_i)^2$$

Όπου  $t_i$  είναι η επιθυμητή έξοδος και  $o_i$  είναι η πραγματική έξοδος για κάθε νευρώνα  $n$ . Στο τέλος διαιρούμε με το μέγεθος των δεδομένων εκπαίδευσης  $N$ .

Σε αυτή τη φάση χρησιμοποιείται η μέθοδος κατάβασης κλίσης με στόχο την ελαχιστοποίηση του λάθους της εκπαίδευσης εφαρμόζοντας κατάλληλες αλλαγές στα βάρη. Σύμφωνα με την μέθοδο αυτή, η αλλαγές στα βάρη πρέπει να είναι ανάλογες του αρνητικού της παραγώγου της συναρτήσεως του λάθους ως προς τα βάρη. Οπότε πρέπει να βρούμε το λάθος που αναλογεί σε κάθε νευρώνα ώστε να αλλάξουμε τα βάρη του ανάλογα. Πρώτα βρίσκουμε το λάθος που αναλογεί σε κάθε νευρώνα του επιπέδου εξόδου:

$$\delta_{pj} = o_{pj}(1 - o_{pj})(t_{pj} - o_{pj})$$

Όπου  $O_{pj}$  είναι η έξοδος του νευρώνα  $j$  και  $t_{pj}$  είναι η επιθυμητή για τον νευρώνα αυτό.

Έπειτα, όπως προϋποθέτει και το όνομα του αλγορίθμου, εφαρμόζουμε μια ανάστροφη μετάδοση του λάθους στο δίκτυο, ξεκινώντας από το επίπεδο εξόδου κινούμενοι προς τα πίσω. Για τον υπολογισμό του λάθους που αναλογεί στους εσωτερικούς νευρώνες χρησιμοποιούμε τον τύπο:

$$\delta_{pj} = o_{pj}(1 - o_{pj}) \sum_{k=0}^n \delta_{pk} w_{jk}$$

Όπου  $O_{pj}$  είναι η έξοδος του νευρώνα  $j$ ,  $\delta_{pk}$  είναι το λάθος που έρχεται από τον νευρώνα  $k$  του επόμενου επιπέδου (επόμενου διότι πάμε αντίθετα) και  $W_{jk}$  είναι το βάρος μεταξύ αυτών των δύο νευρώνων.

Όταν τελειώσει ο υπολογισμός αυτής της «κατανομής» του λάθους πρέπει να πάμε και να αλλάξουμε τα βάρη. Η αλλαγή στα βάρη του επιπέδου εξόδου γίνεται με τον πιο κάτω τύπο:

$$w_{ij}(t+1) = w_{ij}(t) + n \delta_{pj} o_{pi}$$

Όπου  $n$  είναι ο ρυθμός μάθησης (learning rate),  $\delta_{pj}$  είναι το λάθος του νευρώνα και  $O_{pi}$  είναι η έξοδος του νευρώνα του προηγούμενου επιπέδου. Η τιμή του ρυθμού μάθησης είναι μια σταθερά τιμή η οποία καθορίζει το πόσο αργά ή γρήγορα εκπαιδεύεται το δίκτυο.

Η αλλαγή στα βάρη  $\Delta w_{jk}(t)$  για τους νευρώνες των κρυφών επιπέδων γίνεται με τον τύπο:

$$\Delta w_{jk}(t) = \eta \cdot \delta_j \cdot O_j + \lambda \cdot \Delta w_{jk}(t-1)$$

Όπου το  $\eta$  είναι ο ρυθμός μάθησης και  $\lambda$  είναι η ορμή (momentum) την οποία πολλαπλασιάζουμε με την προηγούμενη αλλαγή που έγινε στο βάρος  $\Delta w_{jk}(t-1)$ . Η ορμή είναι επίσης μια σταθερά τιμή, η οποία είναι ανάλογη της αλλαγής των βαρών και μπορεί να μεγαλώσει ή να μικρύνει την τρέχουσα αλλαγή των βαρών.  $\delta_j$  είναι το λάθος του νευρώνα και  $O_j$  είναι η έξοδος του νευρώνα.

### 1.4.5 Προβλήματα του αλγόριθμου Back Propagation

Ένα πρόβλημα που μπορεί να παρουσιαστεί κατά την εκπαίδευση ενός δικτύου με τον αλγόριθμο back propagation είναι το πρόβλημα του εγκλωβισμού σε τοπικά ελάχιστα και το κόλλημα της εκπαίδευσης. Αυτό το πρόβλημα παρατηρείται όταν ο αλγόριθμος κατάβασης κλίσης σταματάει σε τοπικό ελάχιστο και όχι στο ολικό ελάχιστο. Αυτό έχει ως συνέπεια την πολύ μικρή μείωση του λάθους. Με την προσθήκη των παραμέτρων της ορμής (momentum) και ρυθμού μάθησης (learning rate) όμως μπορούμε να μειώσουμε την πιθανότητα εμφάνισης αυτού του προβλήματος. Επίσης, αυξάνοντας τον αριθμό των κρυφών νευρώνων, αυξάνουμε την ικανότητα του δικτύου στην κωδικοποίηση των δεδομένων και μειώνουμε την πιθανότητα της παρουσίας του προβλήματος του κολλήματος σε τοπικά ελάχιστα.

Ένα άλλο πρόβλημα είναι το πρόβλημα της υπέρ-εκπαίδευσης το οποίο εμφανίζεται όταν το δίκτυο υπέρ-εκπαιδευτεί πάνω στα δεδομένα εισόδου. Σε αυτήν την περίπτωση το δίκτυο χάνει την δυνατότητα της γενίκευσης σε νέα δεδομένα διότι μαθαίνει τα δεδομένα που χρησιμοποιήθηκαν για εκπαίδευση «παπαγαλία». Για μείωση της εμφάνισης αυτού του προβλήματος πρέπει να σταματάμε την εκπαίδευση έγκαιρα. Επίσης, μειώνοντας τον αριθμό των κρυφών νευρώνων, μπορούμε να μειώσουμε την δυνατότητα του δικτύου στην κωδικοποίηση των δεδομένων μειώνοντας την πιθανότητα παρουσίας του προβλήματος της «παπαγαλίας».

### 1.5 Στατιστικές μέθοδοι για υπολογισμό του σφάλματος

Το Τετραγωνικό σφάλμα (Squared Error, SE). Είναι το σφάλμα ως προς την τετραγωνική απόκλιση των πραγματικών τιμών από τις προβλεπόμενες τιμές. Το σφάλμα αυτό δίνεται από τον τύπο:

$$SE = \frac{1}{2} \sum_{i=0}^n (t_i - o_i)^2$$

Όπου το  $n$  είναι ο αριθμός των νευρώνων στο επίπεδο εξόδου,  $t_i$  είναι η επιθυμητή έξοδος και  $O_i$  είναι η πραγματική (προβλεπόμενη) έξοδος.

Το μέσο τετραγωνικό σφάλμα (Mean Squared Error, MSE). Είναι το σφάλμα ως προς την μέση τιμή της τετραγωνικής απόκλισης των πραγματικών τιμών από τις προβλεπόμενες τιμές. Το σφάλμα αυτό δίνεται από τον τύπο:

$$\text{MSE} = \frac{1}{N} \sum_{i=0}^n (t_i - o_i)^2$$

Όπου το  $n$  είναι ο αριθμός των νευρώνων στο επίπεδο εξόδου,  $t_i$  είναι η επιθυμητή έξοδος,  $O_i$  είναι η πραγματική (προβλεπόμενη) έξοδος και  $N$  είναι το μέγεθος των δεδομένων μας.

Το μέσο σχετικό σφάλμα (Mean Relative Error, MRE). Είναι το σφάλμα ως προς τον μέσο όρο των απολύτων τιμών της απόκλισης των πραγματικών τιμών από τις προβλεπόμενες τιμές σε σχέση με τις πραγματικές τιμές. Το σφάλμα αυτό δίνεται από τον τύπο:

$$\text{MRE} = \frac{1}{N} \sum_{i=0}^n |t_i - o_i|/t_i$$

Όπου το  $n$  είναι ο αριθμός των νευρώνων στο επίπεδο εξόδου,  $t_i$  είναι η επιθυμητή έξοδος,  $O_i$  είναι η πραγματική (προβλεπόμενη) έξοδος και  $N$  είναι το μέγεθος των δεδομένων μας.

Το μέσο απόλυτο σφάλμα (Mean Absolute Error). Είναι το σφάλμα ως προς τον μέσο όρο των απολύτων τιμών της απόκλισης των πραγματικών τιμών από τις προβλεπόμενες τιμές. Το σφάλμα αυτό δίνεται από τον τύπο:

$$\text{MAE} = \frac{1}{N} \sum_{i=0}^n |t_i - o_i|$$

Όπου το  $n$  είναι ο αριθμός των νευρώνων στο επίπεδο εξόδου,  $t_i$  είναι η επιθυμητή έξοδος,  $O_i$  είναι η πραγματική (προβλεπόμενη) έξοδος και  $N$  είναι το μέγεθος των δεδομένων μας.

## **Κεφάλαιο 2**

### **Προτεινομένη λύση**

---


2.1 Μεθοδολογία	18
2.2 Δεδομένα	20
2.2.1 Ανάλυση δεδομένων	20
2.2.2 Προ-επεξεργασία δεδομένων	26

---

## 2.1 Μεθοδολογία

Το πρόβλημα της πρόβλεψης ζήτησης του φυσικού αερίου χαρακτηρίζεται από την δυναμικότητα του, και την εξάρτηση του από εξωτερικούς παράγοντες. Χρησιμοποιώντας τις μεγάλες δυνατότητες των νευρωνικών δικτύων για επίλυση τέτοιων προβλημάτων, για την κατασκευή αυτής της πρόβλεψης θα υλοποιήσουμε ένα νευρωνικό δίκτυο που θα την παράγει, λαμβάνοντας υπόψη την γενική θεωρία για προβλέψεις και οδηγούμενοι από τις γενικές κατευθυντήριες γραμμές που έχουν τεθεί με σκοπό την επίτευξη υψηλής ακρίβειας στις προβλέψεις [2], [3]. Σε αυτή την εργασία προσπαθούμε να λύσουμε αυτό το πρόβλημα με δύο διαφορετικές μεθόδους.

Η πρώτη μέθοδος που θα χρησιμοποιήσουμε, είναι η μέθοδος του κινητού παραθύρου. Σε αυτή την μέθοδο υπάρχει ένα «παράθυρο» στα δεδομένα εισόδου, το οποίο κινείται μέσα στα δεδομένα καθώς περνάει ο χρόνος. Σε αυτή την μέθοδο θα χρησιμοποιήσουμε μόνο τα δεδομένα της χρονοσειράς της ζήτησης του φυσικού αερίου. Με αυτό το τρόπο θα εκμεταλλευτούμε την σχέση της ζήτησης του φυσικού αερίου με τον χρόνο. Τα δεδομένα μέσα στο παράθυρο παρουσιάζονται στο δίκτυο ως είσοδοι και η επιθυμητή έξοδος είναι η αμέσως επόμενη τιμή μετά το τέλος του παραθύρου. Το μέγεθος του παραθύρου καθορίζεται στην αρχή του προγράμματος και παραμένει σταθερό κατά την διάρκεια της εκπαίδευσης. Μεταβάλλοντας το μέγεθος του παραθύρου καθορίζουμε το πόσο πίσω στον χρόνο δεδομένα θα παρουσιάζουμε στο δίκτυο μας.



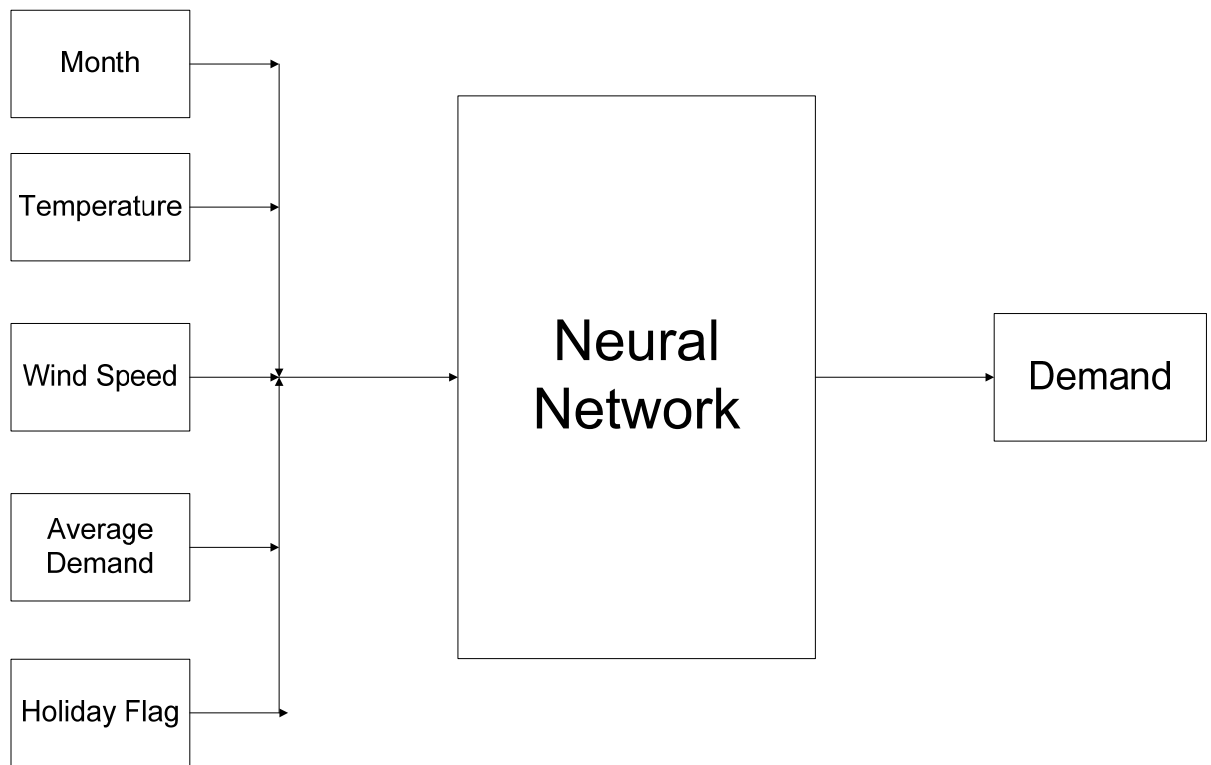
Σχήμα 2.1: Παράδειγμα κινητού παραθύρου.



Στο πιο πάνω σχήμα (σχήμα 2.1), βλέπουμε ένα παράδειγμα ενός κινητού παράθυρου στα δεδομένα μιας χρονοσειράς. Τα δεδομένα μέσα στο παράθυρο είναι τα δεδομένα εισόδου στο δίκτυο μας, και η τιμή αμέσως μετά το παράθυρο είναι η επιθυμητή έξοδος.

Χρησιμοποιώντας αυτήν την τεχνική θα παρουσιάσουμε στο δίκτυο μας κάποια δεδομένα ζήτησης φυσικού αερίου και θα προσπαθεί το δίκτυο να προβλέψει την ζήτηση του φυσικού αερίου για την επόμενη χρονική στιγμή. Θα μεταβάλλουμε το μέγεθος του παραθύρου μας στην προσπάθεια μας να καταλήξουμε σε ένα μέγεθος το οποίο μας προσφέρει τα καλύτερα αποτελέσματα στην πρόβλεψη.

Η δεύτερη μέθοδος που θα χρησιμοποιήσουμε είναι μια στατική μέθοδος (σχήμα 2.2) η οποία θα χρησιμοποιεί και τα δεδομένα των θερμοκρασιών και των ταχυτήτων των ανέμων. Θα δίνουμε στο δίκτυο ως είσοδο τον μήνα στον οποίο βρισκόμαστε, την πιο πρόσφατη τιμή της θερμοκρασίας, την πιο πρόσφατη τιμή της ταχύτητας των ανέμων, ένα μέσο όρο της ζήτησης του φυσικού αερίου για την περασμένη βδομάδα, καθώς και μια ένδειξη κατά πόσο η μέρα στην οποία βρισκόμαστε είναι καθημερινή μέρα, ή αν είναι σαββατοκύριακο ή αργία, διότι όπως αναφέρθηκε και πιο πριν, η κατανάλωση του φυσικού αερίου τα σαββατοκύριακα είναι αρκετά πιο αυξημένη μια και περισσότερος κόσμος βρίσκεται σπίτι. Αυτή η μέθοδος μας δίνει την δυνατότητα να συνδυάσουμε διάφορες παραμέτρους που επηρεάζουν την ζήτηση του φυσικού αερίου στην προσπάθεια μας να καταλήξουμε στα καλύτερα αποτελέσματα.



**Σχήμα 2.2:** Δομή δικτύου χρησιμοποιώντας την στατική μέθοδο.

## 2.2 Δεδομένα

Για αυτήν την διπλωματική εργασία έχουμε προμηθευτεί πραγματικά δεδομένα από μια μεγάλη βιομηχανική εταιρεία διανομής φυσικού αερίου. Τα δεδομένα αυτά περιέχουν την ζήτηση του φυσικού αερίου, καθώς και εξωγενείς παράγοντες όπως η θερμοκρασία και η ταχύτητα ανέμων. Αυτά τα δεδομένα καλύπτουν ένα φάσμα 7 χρόνων. Θα χρησιμοποιήσουμε αυτά τα δεδομένα, τόσο για την εκπαίδευση των δικτύων μας, αλλά και για την αξιολόγηση τους.

### 2.2.1 Ανάλυση δεδομένων

Τα δεδομένα της ζήτησης του φυσικού αερίου περιέχουν την ζήτηση του φυσικού αερίου κάθε μέρα ανά ώρα σε εκατομμύρια κυβικά μέτρα (millions of cubic meters mcm) . Τα δεδομένα της θερμοκρασίας περιέχουν τις θερμοκρασίες κάθε μέρα ανά δύο ώρες σε βαθμούς Κελσίου. Τέλος τα δεδομένα της ταχύτητας των ανέμων, περιέχουν τις ταχύτητες των ανέμων για κάθε μέρα ανά τέσσερις ώρες σε κόμβους (knots). Αυτά

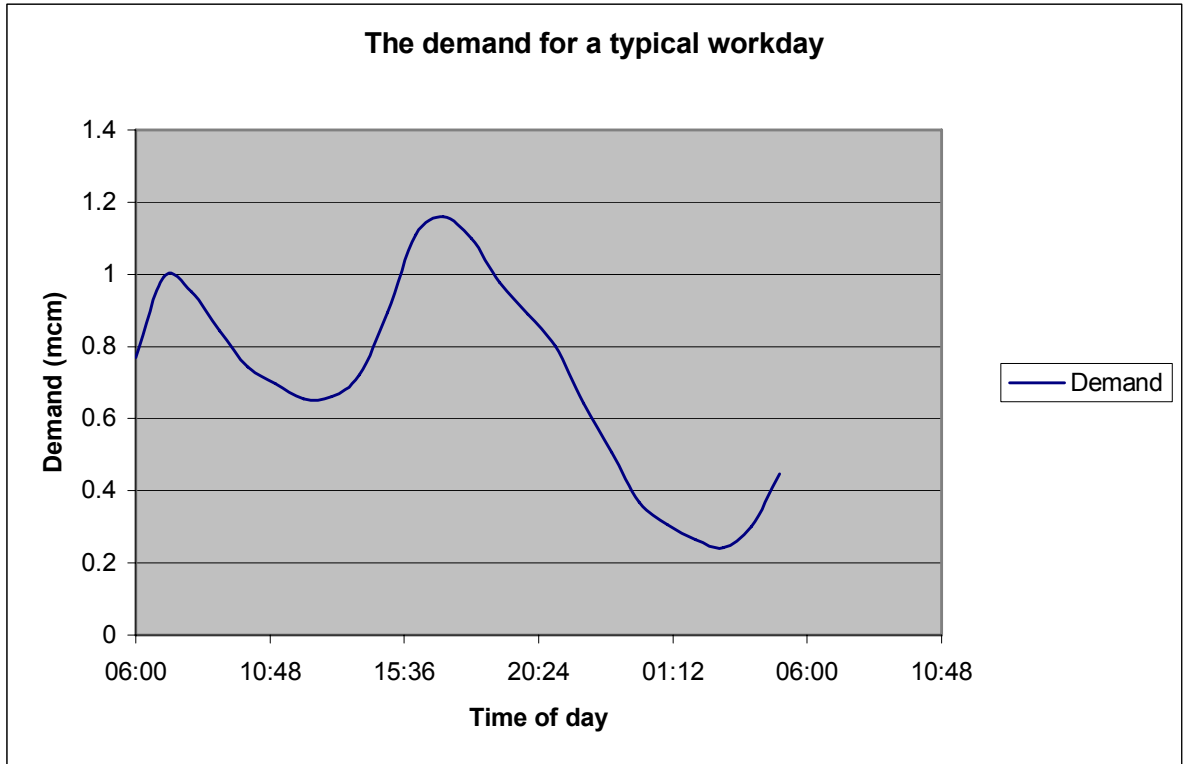
τα δεδομένα όπως αναφέραμε πιο πάνω καλύπτουν ένα φάσμα 7 χρόνων, ξεκινώντας από της 2 του Μάη του 1990, μέχρι τις 30 του Σεπτεμβρίου του 1997.

Στα πιο κάτω σχήματα βλέπουμε την γραφική παράσταση της ζήτησης του φυσικού αερίου σε σχέση με τον χρόνο, κατά την διάρκεια μιας ημέρας (σχήματα 2.3 – 2.6). Για την παραγωγή αυτών των γραφικών παραστάσεων χρησιμοποιήθηκαν κάποιες τυχαίες μέρες από δεδομένα. Πήραμε δεδομένα από κάποιες τυπικές καθημερινές μέρες, χειμερινές και καλοκαιρινές καθώς από αργίες.


Γενικά παρατηρούμε ότι κατά την διάρκεια μιας τυπικής καθημερινής μέρας, η ζήτηση στο φυσικό αέριο είναι περισσότερη στις πρωινές ώρες, όπου ο περισσότερος κόσμος βρίσκεται σπίτι του, μόλις έχουν σηκωθεί και ετοιμάζονται να πάνε δουλειά. Μετά παρατηρείται μία πτώση στην ζήτηση, μια και ο περισσότερος κόσμος βρίσκεται στην δουλειά. Κατά αργά το απόγευμα, παρατηρείται πάλι αύξηση στην ζήτηση, αφού ο κόσμος έχει σχολάσει από τις δουλειές του και έχει επιστρέψει σπίτι. Τέλος κατά τις νυκτερινές ώρες παρατηρείται μείωση της ζήτησης, διότι ο κόσμος έχει πάει για ύπνο.

Συγκρίνοντας μια τυπική καθημερινή μέρα, με μια αργία, παρατηρούμε ότι η ζήτηση στο φυσικό αέριο δεν μειώνεται σχεδόν καθόλου από το πρωί ως το μεσημέρι, και μάλιστα σε κρύες μέρες παρατηρείται και αύξηση. Αυτό οφείλεται στο γεγονός ότι στις αργίες πολύς κόσμος παραμένει στο σπίτι την μέρα, μια και δεν έχουν δουλειά. Τέλος παρατηρούμε ότι οι τιμές στην ζήτηση του φυσικού αερίου είναι αρκετά αυξημένες κατά τους χειμερινούς μήνες.


Στα δεδομένα θερμοκρασιών (σχήματα 2.7 και 2.8) παρατηρούμε, όπως είναι και λογικό, πιο αυξημένες θερμοκρασίες στις ώρες της μέρας όπου υπάρχει ηλιοφάνεια, με κορύφωση τις μεσημεριανές ώρες. Στις καλοκαιρινές μέρες έχουμε πολύ πιο μεγάλες θερμοκρασίες από ότι στις χειμερινές. Στα δεδομένα των ταχυτήτων των ανέμων (σχήματα 2.9 και 2.10) δεν παρατηρούμε κάποιο σταθερό μοτίβο, παρόλα αυτά μπορούμε να παρατηρήσουμε πως κατά τους χειμερινούς μήνες οι ταχύτητες των ανέμων είναι πιο αυξημένες παρά στους καλοκαιρινούς.




Σχήμα 2.3: Η ζήτηση για μια τυπική καθημερινή μέρα σε χειμερινό μήνα.




Σχήμα 2.4: Η ζήτηση για μια τυπική καθημερινή μέρα σε καλοκαιρινό μήνα.




Σχήμα 2.5: Η ζήτηση για μια τυπική αργία σε καλοκαιρινό μήνα.




Σχήμα 2.6: Η ζήτηση για μια τυπική αργία σε χειμερινό μήνα.




Σχήμα 2.7: Η θερμοκρασία σε μια καλοκαιρινή μέρα.



Σχήμα 2.8: Η θερμοκρασία σε μια χειμερινή μέρα.



Σχήμα 2.9: Οι ταχύτητες των ανέμων σε μια καλοκαιρινή μέρα.



Σχήμα 2.10: Οι ταχύτητες των ανέμων σε μια χειμερινή μέρα.

### 2.2.2 Προ-επεξεργασία δεδομένων

Υπήρχαν μερικά προβλήματα με τα δεδομένα αυτά. Σε πολλές περιπτώσεις στα δεδομένα κάποιες τιμές έλειπαν. Αυτό το πρόβλημα υπήρχε και στα δεδομένα της ζήτησης του φυσικού αερίου, καθώς και στα δεδομένα των θερμοκρασιών και των ταχυτήτων των ανέμων.

Ένα άλλο πρόβλημα ήταν η διαμόρφωση των αρχείων. Μερικές τιμές ήταν χωρισμένες με μονά διαστήματα, άλλες με πολλαπλά διαστήματα, με αποτέλεσμα να κάνει την σάρωση των αρχείων πιο δύσκολη.

Για την επίλυση αυτών των προβλημάτων δημιουργήσαμε ένα εργαλείο με το οποίο να προ-επεξεργαστούμε τα δεδομένα, συμπληρώνοντας τις τιμές που έλειπαν και διαμορφώνοντας τα αρχεία με τέτοιο τρόπο ώστε η σάρωση τους να γίνεται πιο εύκολα. Για την συμπλήρωση των τιμών που έλειπαν, είτε ζήτησης φυσικού αερίου, είτε θερμοκρασιών, είτε ταχυτήτων ανέμων, πήραμε δείγματα τιμών από τις ίδιες μέρες και ώρες άλλων χρόνων, πήραμε ένα μέσο όρο από τις τιμές για τις ίδιες ώρες σε άλλα έτη. Τέλος δημιουργήσαμε ακόμα ένα μικρό εργαλείο το οποίο αφού διαβάσει όλα τα δεδομένα από τα τρία αυτά αρχεία δημιουργεί ένα νέο αρχείο που συνδυάζει τα δεδομένα αυτά με τέτοιο τρόπο και δομή, ώστε να κάνει την ανάγνωση τους από το δίκτυο πιο εύκολη, αλλά και πολύ πιο γρήγορη. Ο κώδικας της υλοποίησης αυτών των εργαλείων βρίσκεται στο παράρτημα Γ.



# Κεφάλαιο 3

## Σχεδιασμός και Υλοποίηση

---

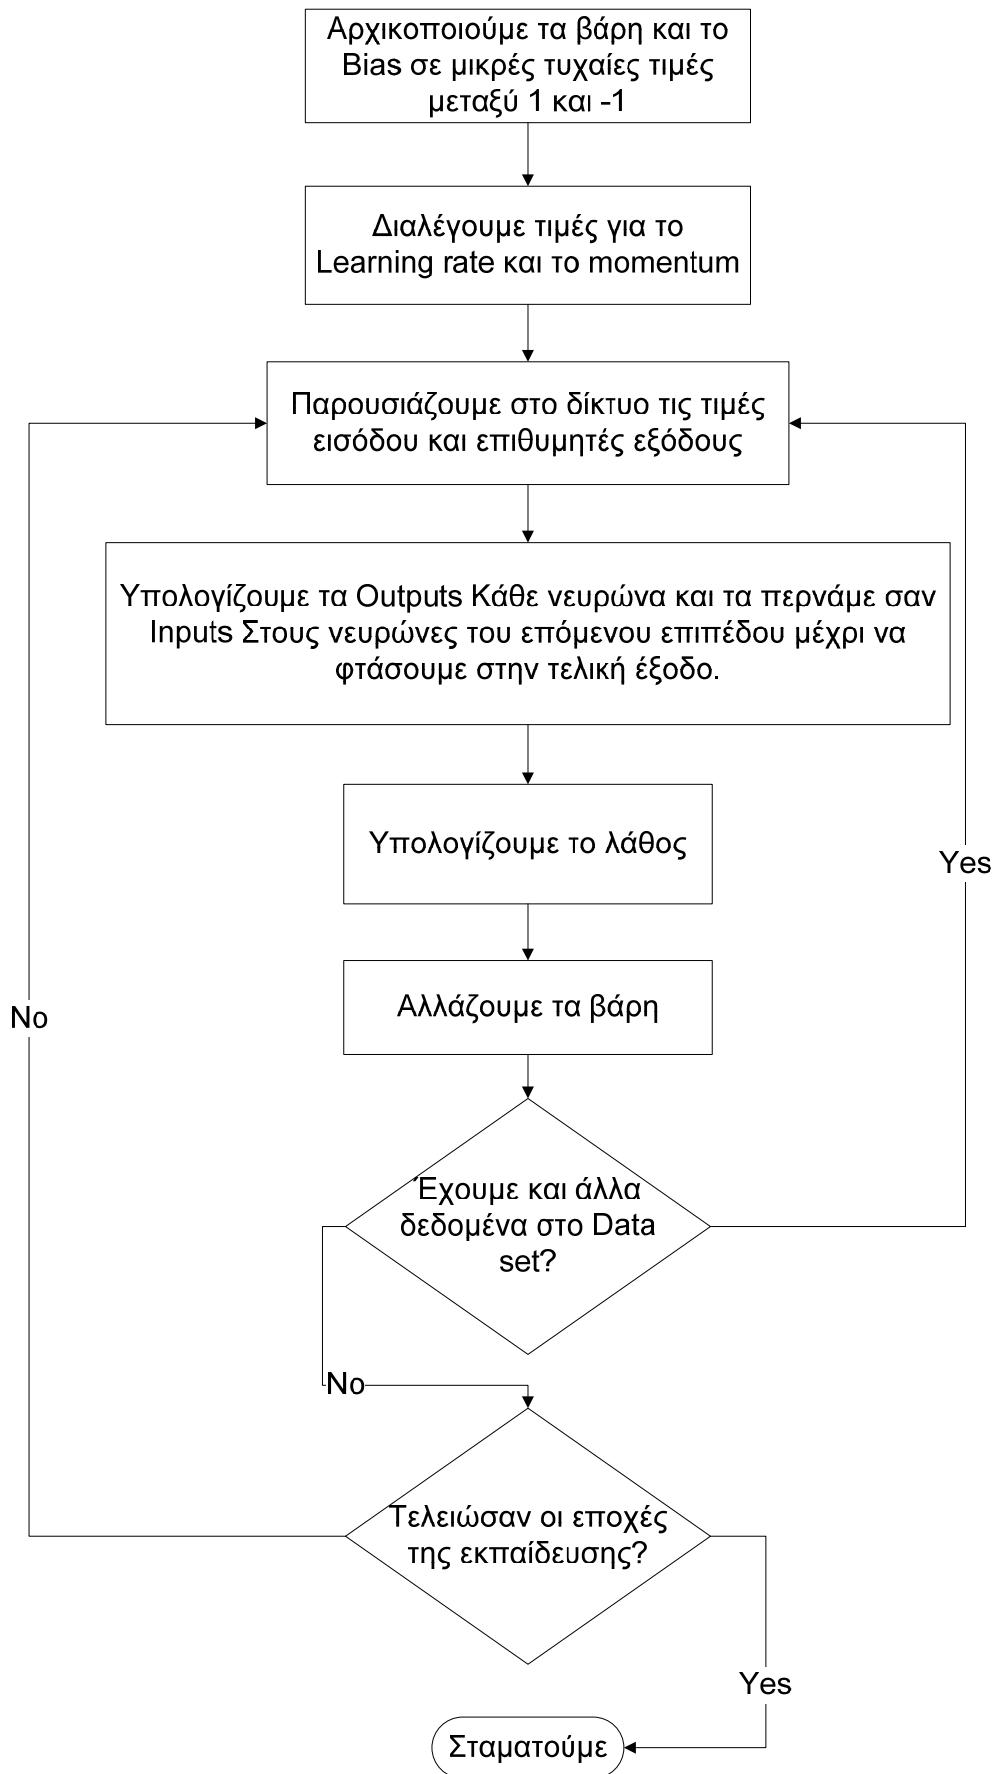
3.1 Σχεδιασμός	28
3.2 Υλοποίηση	32
3.2.1 Περιγραφή των κλάσεων	32
3.2.2 Περιγραφή ροής δεδομένων	35
3.2.3 Διαφορές στις τεχνικές	36

---

### 3.1 Σχεδιασμός

Όπως αναφέραμε και πιο πάνω, για την επίλυση αυτού του προβλήματος θα υλοποιήσουμε δύο νευρωνικά δίκτυα, χρησιμοποιώντας την τεχνική του κινητού παραθύρου στον χρόνο και ένα στατικό δίκτυο. Και στις δύο περιπτώσεις τα δίκτυα μας πρέπει να σχεδιαστούν κατάλληλα, ώστε να ακολουθούν τα βήματα του αλγορίθμου Back Propagation. Στο σχήμα 3.1 βλέπουμε ένα διάγραμμα ροής το οποίο περιγράφει τα βήματα αυτά του αλγόριθμου.

Τα νευρωνικά δίκτυα που σχεδιάστηκαν, πρέπει να περιέχουν τουλάχιστον τρία επίπεδα νευρώνων. Ένα επίπεδο για τις εισόδους, ένα κρυφό επίπεδο και το επίπεδο εξόδου. Το επίπεδο εισόδου δεν είναι ενεργό, απλά μεταδίδει τα δεδομένα εισόδου στο δίκτυο. Θα προσθέσουμε στο δίκτυο μας όμως και την δυνατότητα για δημιουργία και δεύτερου κρυφού επιπέδου, για να πειραματιστούμε, βλέποντας αν η δυνατότητα για μεγαλύτερη κωδικοποίηση των δεδομένων που προσφέρεται από την εισαγωγή ενός δεύτερου κρυφού επιπέδου, οδηγεί σε καλύτερα αποτελέσματα.



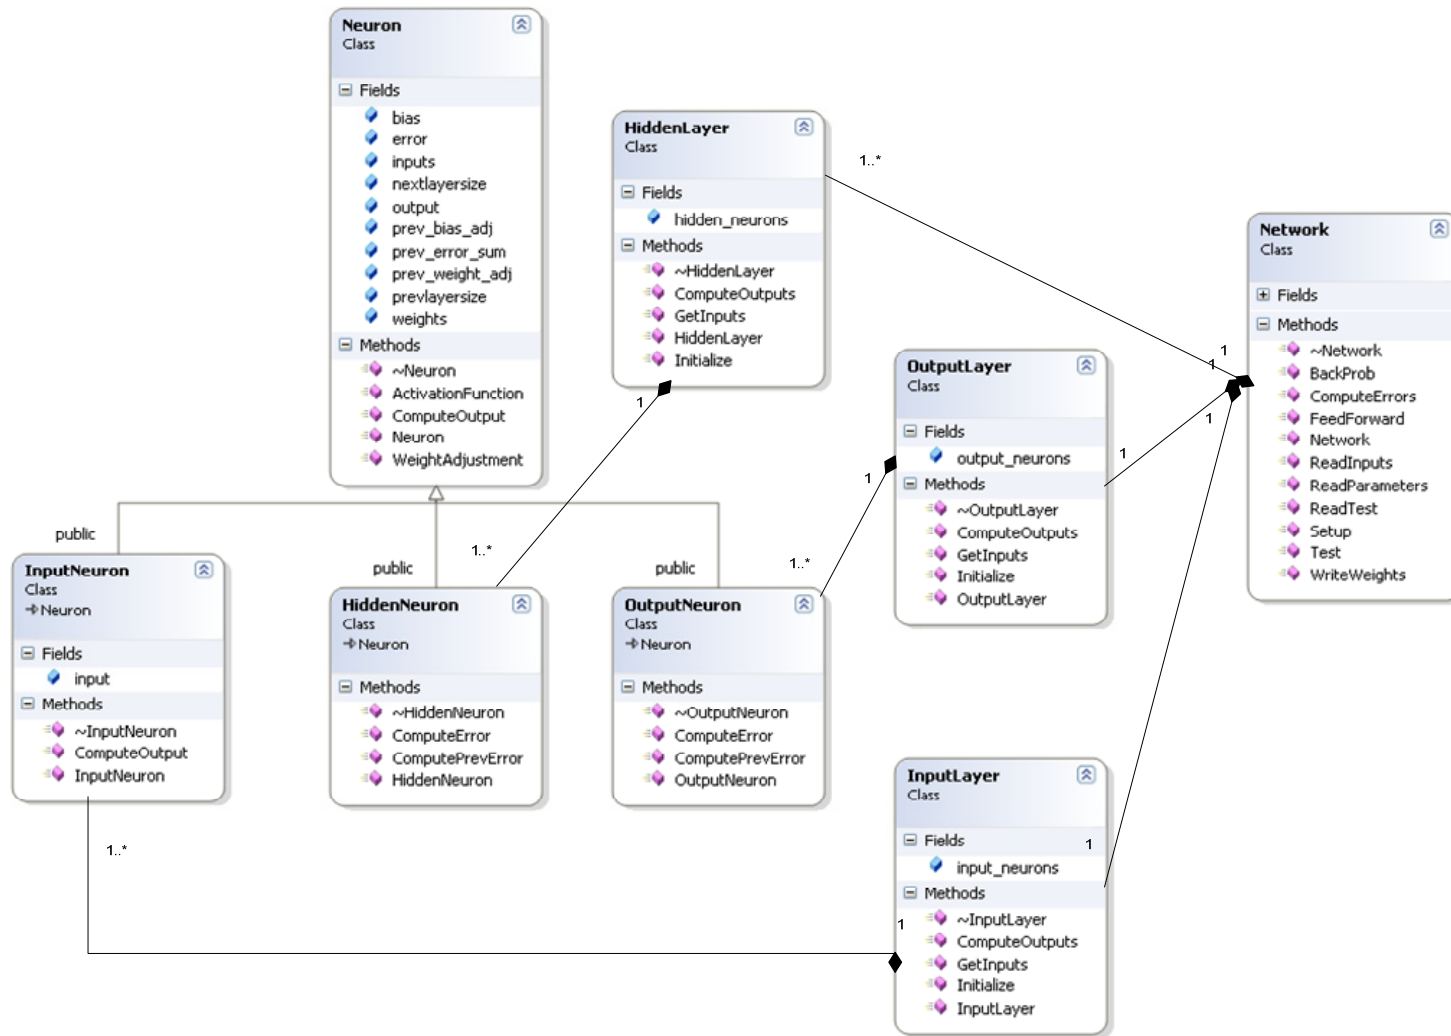
Σχήμα 3.1: Διάγραμμα ροής δεδομένων για τον αλγόριθμο backpropagation.

Στο στατικό δίκτυο, το επίπεδο εισόδου θα έχει σταθερό μέγεθος. Όπως αναφέραμε και πιο πάνω οι εισοδοί σε αυτό το δίκτυο θα είναι ο μήνας στον οποίο βρισκόμαστε, η θερμοκρασία, η ταχύτητα των ανέμων, μια μέση τιμή της ζήτησης του φυσικού αερίου άλλων χρόνων για την ίδια μέρα και ώρα καθώς και μία τιμή που να επιδεικνύει αν η μέρα που εξετάζουμε είναι καθημερινή ή αργία. Για την κωδικοποίηση του μήνα, θα χρησιμοποιήσουμε δυαδική κωδικοποίηση, οπότε θα χρειαστούμε τέσσερις εισόδους για να την αναπαραστήσουμε. Για την θερμοκρασία, την ταχύτητα των ανέμων και την μέση τιμή της ζήτησης των προηγούμενων χρόνων θα χρειαστούμε από μία ακόμα είσοδο. Τέλος για την ένδειξη του κατά πόσον η μέρα υπό εξέταση είναι καθημερινή ή αργία, θα χρειαστούμε ακόμα μια είσοδο. Οπότε θα χρειαστούμε σύνολο 8 εισόδους.

Το επίπεδο εισόδου για το δίκτυο που θα χρησιμοποιεί την τεχνική του κινητού παραθύρου στο χρόνο θα έχει μέγεθος όσο και το μέγεθος του παραθύρου. Δηλαδή, οι εισοδοί στο δίκτυο μας θα είναι τόσες όσο και το μέγεθος του παραθύρου. Το δίκτυο μας πρέπει να σχεδιαστεί με τέτοιο τρόπο ώστε να μπορούμε εύκολα με την αλλαγή κάποιας παραμέτρου, να μεταβάλλουμε το μέγεθος του παραθύρου πριν από την κάθε εκπαίδευση.

Τα κρυφά επίπεδα στα δίκτυα μας θα έχουν περισσότερους νευρώνες από όσους θα έχει το επίπεδο εισόδου. Κατά τον πειραματισμό μας θα μεταβάλλουμε το μέγεθος των επιπέδων αυτών στην προσπάθεια μας για επίτευξη καλύτερων αποτελεσμάτων, και θα προσπαθήσουμε να καταλήξουμε σε ένα μέγεθος με το οποίο θα παίρνουμε τα καλύτερα αποτελέσματα.

Το επίπεδο εξόδου και στα δύο δίκτυα θα έχει μέγεθος ένα, αφού η προσπάθεια μας γίνεται για μια πρόβλεψη της ζήτησης του φυσικού αερίου για κάποια συγκεκριμένη μέρα και ώρα. Οπότε η ζήτηση αυτή θα μας δίνετε σε μια τιμή, άρα και μία έξοδο.



Σχήμα 3.2: Διάγραμμα UML για τα δίκτυα μας.

## 3.2 Υλοποίηση

Η υλοποίηση και για τα δύο δίκτυα μας θα είναι παρόμοια με τις κυριότερες διαφορές να παρατηρούνται στον τρόπο επεξεργασίας των εισόδων. Τα δίκτυα μας όπως αναφέραμε και στον σχεδιασμό, θα αποτελούνται από τρία ή τέσσερα επίπεδα νευρώνων. Ένα επίπεδο για την είσοδο όπου οι νευρώνες του δεν θα είναι ενεργοί, ένα ή δύο κρυφά επίπεδα και ένα επίπεδο για την έξοδο. Το κάθε επίπεδο θα αποτελείται από νευρώνες, όπου η είσοδος του κάθε νευρώνα θα είναι συνδεδεμένη με την έξοδο όλων των νευρώνων που βρίσκονται στο επίπεδο πριν από το δικό του και η έξοδος του θα δίνεται στο επόμενο επίπεδο. Εξαιρέση σε αυτό θα είναι οι νευρώνες εισόδου, όπου σε αυτή την περίπτωση οι εισοδοί θα είναι και οι εισοδοί στο δίκτυο, και οι νευρώνες εξόδου, όπου η έξοδος θα είναι και η έξοδος του δικτύου. Στο σχήμα 3.2 βλέπουμε το διάγραμμα UML για τα δίκτυα μας.

### 3.2.1 Περιγραφή των κλάσεων

Η υλοποίηση των κλάσεων των δικτύων μπορεί να βρεθεί στα παραρτήματα Α και Β. Στο παράρτημα Α υπάρχει η υλοποίηση της τεχνικής του κινητού παραθύρου, και στο παράρτημα Β η υλοποίηση της στατικής μεθόδου.

Η κλάση `Neuron` αναπαριστά ένα νευρώνα στο δίκτυο μας. Περιέχει όλες τις μεταβλητές που πρέπει να περιέχει ένας νευρώνας, όπως τις εισόδους του, τα βάρη για την κάθε είσοδο και την τιμή του `bias`. Επίσης περιέχει και μερικές επιπλέον μεταβλητές που βοηθούν στον υπολογισμό των λαθών και την διόρθωση των βαρών, όπως μια δομή που να κρατάει τα βάρη που υπάρχουν στις συνδέσεις του με τους νευρώνες του προηγούμενου επιπέδου. Η κλάση αυτή περιέχει μια μέθοδο για υπολογισμό τις εξόδου βάση των εισόδων και των βαρών, μια μέθοδο για μοντελοποίηση της συναρτήσεως ενεργοποίησης καθώς και μια μέθοδο για αλλαγές στα βάρη του βάσης του λάθους.

Η κλάση `InputNeuron` αναπαριστά έναν νευρώνα του επιπέδου εισόδου στο δίκτυο μας. Αυτή η κλάση κληρονομεί τα βασικά χαρακτηριστικά και λειτουργίες που πρέπει να έχει ένας νευρώνας από την κλάση `Neuron`. Σε αυτήν την κλάση η είσοδος είναι

διαφορετική, διότι την είσοδο του ένας νευρώνας στο επίπεδο εισόδου την παίρνει απευθείας από το δίκτυο. Επίσης η μέθοδος για υπολογισμό της εξόδου είναι διαφορετική, μια και η έξοδος των νευρώνων στο επίπεδο εισόδου είναι η ίδια με την είσοδο. Οι νευρώνες σε αυτό το επίπεδο απλά μεταφέρουν την είσοδο μέσα στο δίκτυο.

Η κλάση HiddenNeuron αναπαριστά έναν νευρώνα του κρυφού επιπέδου στο δίκτυο μας. Αυτή η κλάση επίσης κληρονομεί τα βασικά χαρακτηριστικά και λειτουργίες που πρέπει να έχει ένας νευρώνας από την κλάση Neuron. Σε αυτή την κλάση, με την μέθοδο υπολογισμού του λάθους, εκτελούμε τον ανάλογο τύπο για την εύρεση της τιμής του λάθους, που βασίζεται και στην τιμή της εξόδου του ίδιου του νευρώνα, αλλά και στην τιμή του λάθους που έρχεται από το επόμενο επίπεδο του δικτύου μας.

Η κλάση OutputNeuron αναπαριστά έναν νευρώνα του επιπέδου εξόδου στο δίκτυο μας. Αυτή η κλάση επίσης κληρονομεί τα βασικά χαρακτηριστικά και λειτουργίες που πρέπει να έχει ένας νευρώνας από την κλάση Neuron. Σε αυτή την κλάση υπολογίζουμε την τιμή του λάθους με την μέθοδο για υπολογισμό του λάθους, που βασίζεται μόνο στην έξοδο του ίδιου του νευρώνα και της επιθυμητής εξόδου.

Οι κλάσεις InputLayer, HiddenLayer και OutputLayer αναπαριστούν τα διαφορετικά επίπεδα που υπάρχουν στο δίκτυο μας. Περιέχουν μία δομή (vector) όπου έχουν αποθηκευμένους όλους τους νευρώνες που ανήκουν σε αυτό το επίπεδο. Είναι εξοπλισμένες με μέθοδο για αρχικοποίηση των νευρώνων τους, την μέθοδο για ανάκτηση των εισόδων των νευρώνων τους, καθώς και μέθοδο για τον υπολογισμό των λαθών για τον κάθε νευρώνα. Η αρχικοποίηση των νευρώνων τους γίνεται αρχικοποιώντας τα βάρη τους καθώς και το bias τους με μικρές τυχαίες τιμές. Η ανάκτηση των εισόδων των νευρώνων γίνεται διαφορετικά για στην κλάση InputLayer μια και σε αυτήν την περίπτωση η είσοδος στους νευρώνες δίνεται από το ίδιο το πρόγραμμα. Στις κλάσεις HiddenLayer και OutputLayer όμως, η ανάκτηση των εισόδων των νευρώνων τους γίνεται δίνοντας στον κάθε νευρώνα τις εξόδους όλων των νευρώνων του προηγούμενου επιπέδου, πολλαπλασιασμένες επί τα βάρη που υπάρχουν στις συνδέσεις τους. Όπως αναφέραμε πιο πάνω ο κάθε νευρώνας περιέχει μια δομή που κρατάει όλα τα βάρη που έχει στις συνδέσεις του με τους νευρώνες του προηγούμενου επιπέδου. Οπότε η μέθοδος αυτή των επιπέδων είναι υπεύθυνη να πάρει

τις εξόδους των νευρώνων του προηγούμενου επιπέδου και να τις περάσει στους δικούς της νευρώνες. Τέλος ο υπολογισμός των εξόδων των νευρώνων στο κάθε επίπεδο γίνεται καλώντας την μέθοδο για υπολογισμό της εξόδου στον κάθε νευρώνα που υπάρχει στο επίπεδο.

Η κλάση Network αναπαριστά ολόκληρο το δίκτυο. Περιέχει ένα επίπεδο εισόδου, ένα ή δύο κρυφά επίπεδα, ανάλογα με την αρχικοποίηση μας και ένα επίπεδο εξόδου. Ακόμα περιέχει δομές (vectors) όπου αποθηκεύει τα δεδομένα της εκπαίδευσης (training data), που θα χρησιμοποιηθούν και σαν είσοδος για την εκπαίδευση στο δίκτυο μας αλλά και σαν επιθυμητή έξοδος για τον υπολογισμό του λάθους κατά την εκπαίδευση, και τα δεδομένα επαλήθευσης (testing data), που θα χρησιμοποιηθούν κατά την φάση της επαλήθευσης (testing) που γίνεται μετά την εκπαίδευση για αξιολόγηση της απόδοσης του δικτύου μας. Η κλάση αυτή περιέχει πολλές μεθόδους για αρχικοποίηση του δικτύου, εκτέλεση του αλγορίθμου backpropagation και καταγραφή των αποτελεσμάτων. Η μέθοδος ReadParameters διαβάζει από το αρχείο των παραμέτρων, τις παραμέτρους για το δίκτυο, όπως learning rate, momentum, το πλήθος των κρυφών νευρώνων και επιπέδων καθώς και τον αριθμό των εποχών της εκπαίδευσης. Η μέθοδος ReadInputs και ReadTest διαβάζουν τα δεδομένα εκπαίδευσης και δεδομένα επαλήθευσης αντίστοιχα από αρχεία, τα οποία έχουμε πρώτα περάσει από ένα parser πρόγραμμα για να κάνουμε την ανάγνωση και την καταχώρηση στο κύριο πρόγραμμα πιο εύκολη. Η μέθοδος Setup καλεί τις τρεις πιο πάνω μεθόδους για διάβασμα των παραμέτρων και δεδομένων, δημιουργεί τα επίπεδα εισόδου, κρυφά και εξόδου και τα καλεί τις αρχικοποιήσεις τους ώστε να αρχικοποιηθούν όλοι οι νευρώνες με τυχαίες τιμές στα βάρη και στο bias τους. Η μέθοδος FeedForward εκτελεί το εμπρόσθιο πέρασμα του αλγορίθμου backpropagation. Ξεκινά δίνοντας στο επίπεδο εισόδου τις εισόδους από τα δεδομένα εκπαίδευσης και καλεί την μέθοδο στο επίπεδο εισόδου για να υπολογίσει τις εξόδους του, που στην περίπτωση του επιπέδου αυτού είναι οι ίδιες με τις εισόδους. Μετά καλεί την μέθοδο στο κρυφό επίπεδο για να πάρει τις εισόδους του, από τις εξόδους του προηγούμενου επιπέδου, του επιπέδου εισόδου, και αφού αυτό τελειώσει, καλεί την μέθοδο του κρυφού επιπέδου για να υπολογίσει τις εξόδους για τους νευρώνες του. Στην συνέχεια, αν υπάρχει και δεύτερο κρυφό επίπεδο, εκτελείται η πιο πάνω διαδικασία ξανά για αυτό το επίπεδο, αν όχι τότε προχωράει στο επίπεδο εξόδου. Παρόμοια και για το επίπεδο εξόδου η κλάση αυτή δίνει στο επίπεδο



εξόδου τις εισόδους από το προηγούμενο κρυφό επίπεδο, και καλεί την μέθοδο του επιπέδου εξόδου για υπολογισμό της εξόδου των νευρώνων του (στο συγκεκριμένο πρόβλημα το επίπεδο εξόδου περιέχει μόνο έναν νευρώνα, μια και η έξοδος που θέλουμε να προβλέπει το δίκτυο είναι μόνο μία τιμή, η τιμή της ζήτησης του φυσικού αερίου για την χρονική στιγμή που εξετάζουμε). Η μέθοδος `ComputeErrors` εκτελεί τους υπολογισμούς για εύρεση των λαθών. Στην αρχή γίνεται ο υπολογισμός του λάθους για το επίπεδο εξόδου, μια και για την εύρεση του απαιτείται μόνο η έξοδος του νευρώνα ή των νευρώνων εξόδου, και η επιθυμητή έξοδος. Μετά υπολογίζεται το λάθος για τους νευρώνες στο ή στα κρυφά επίπεδα, μια και για την εύρεση του χρειάζεται και το λάθος από το επόμενο επίπεδο, δηλαδή του επιπέδου εξόδου. Η μέθοδος `BackProp` υπολογίζει σε κάθε νευρώνα όλων των επιπέδων την αλλαγή που πρέπει να γίνει στα βάρη τους, ξεκινώντας από το επίπεδο εξόδου προχωρώντας προς τα πίσω μέχρι το επίπεδο εισόδου. Τέλος με την μέθοδο `WriteWeights` το πρόγραμμα γράφει σε ένα αρχείο τις τελικές τιμές που έχουν τα βάρη όλων των συνδέσεων στο δίκτυο μετά το τέλος της εκπαίδευσης.

### 3.2.2 Περιγραφή ροής δεδομένων

Το πρόγραμμα μας μόλις ξεκινήσει διαβάζει τα αρχεία εισόδου για τα δεδομένα εκπαίδευσης, δεδομένα επαλήθευσης και το αρχείο των παραμέτρων. Το αρχείο των παραμέτρων περιέχει τις αρχικές τιμές για το πλήθος των εισόδων, το πλήθος των νευρώνων στα κρυφά επίπεδα, αν υπάρχει δεύτερο κρυφό επίπεδο, τις αρχικές τιμές του ρυθμού μάθησης και ορμής και τον αριθμό των εποχών. Έπειτα το δίκτυο αρχικοποιείται, δημιουργώντας τα επίπεδα εισόδου, κρυφά και εξόδου και δίνοντας στα βάρη και στα `bias` των νευρώνων τους μικρές τυχαίες τιμές. Μετά το δίκτυο μας διαβάζει από την είσοδο τα αρχεία δεδομένων εκπαίδευσης, επαλήθευσης καθώς και το αρχείο με τις διάφορες παραμέτρους όπως `learning rate`, `momentum`, αριθμό νευρώνων στα κρυφά επίπεδα και τον αριθμό των εποχών εκπαίδευσης. Έπειτα το δίκτυο εκτελεί την εμπρόσθια φάση του αλγορίθμου υπολογίζοντας τις εξόδους για όλους τους νευρώνες. Μετά από την εύρεση των εξόδων υπολογίζονται οι τιμές του λάθους για κάθε νευρώνα και βάση αυτών ακολουθεί η διόρθωση των βαρών. Με το τέλος αυτής της διαδικασίας υπολογίζεται το ολικό λάθος για την τρέχουσα εκπαίδευση και η μάθηση συνεχίζεται με τις επόμενες τιμές στο αρχείο των δεδομένων εκπαίδευσης.

Συνεχίζουμε να επαναλαμβάνουμε αυτά τα βήματα μέχρι να τελειώσει ο αριθμός των επαναλήψεων που ορίζει ο χρήστης στο αρχείο παραμέτρων.

### 3.2.3 Διαφορές στις τεχνικές

Οι κύριες διαφορές στην υλοποίηση του δικτύου με την τεχνική του κινητού παραθύρου στον χρόνο και του στατικού δικτύου βρίσκονται στον τρόπο επεξεργασίας των δεδομένων εισόδου. Στην μέθοδο του κινητού παραθύρου στον χρόνο έχουμε ένα παράθυρο στα δεδομένα ζήτησης και δίνουμε σαν είσοδο τόσα δεδομένα όσα και το μέγεθος του παραθύρου, προσπαθώντας να υπολογίσουμε την ζήτηση για την χρονική στιγμή αμέσως μετά το παράθυρο. Μετά από κάθε πρόβλεψη, πρέπει να προχωρούμε το παράθυρο μέσα στα δεδομένα της ζήτησης κατά μία τιμή, ενώ στο στατικό δίκτυο απλά προχωράμε στην επόμενη γραμμή στο αρχείο εισόδου. Επίσης την μέθοδο του κινητού παραθύρου στον χρόνο δεν υπάρχουν ξεχωριστά δεδομένα για εκπαίδευση και ξεχωριστά για επαλήθευση. Σε αυτή την τεχνική τα δεδομένα εκπαίδευσης χρησιμοποιούνται και για μάθηση και για επαλήθευση. Η διαδικασία της επαλήθευσης όμως διαφέρει επίσης. Στο στατικό δίκτυο η επαλήθευση γίνεται μετά το τέλος της εκπαίδευσης, όπου δείχνουμε στο πλέον εκπαιδευμένο δίκτυο μας τα δεδομένα επαλήθευσης, παίρνουμε την έξοδο που θα μας δώσει, και βάση αυτού υπολογίζουμε την απόδοση του δικτύου, χρησιμοποιώντας τεχνικές όπως το μέσο απόλυτο σφάλμα. Στην μέθοδο του κινητού παραθύρου στον χρόνο όμως η απόδοση του δικτύου υπολογίζεται σε κάθε υπολογισμό πρόβλεψης της ζήτησης του δικτύου κατά την φάση της εκπαίδευσης. Αυτό συμβαίνει διότι το δίκτυο με αυτή την τεχνική μαθαίνει να συσχετίζει τα δεδομένα καθώς προχωράει ο χρόνος. Οπότε η πιο κατάλληλη στιγμή για την εύρεση της απόδοσης στην πρόβλεψη της ζήτησης για μια συγκεκριμένη χρονική στιγμή είναι σε αυτή την ίδια την χρονική στιγμή.

# Κεφάλαιο 4

## Αποτελέσματα

---

4.1 Αποτελέσματα τεχνικής κινητού παραθύρου στον χρόνο	38
4.1.1 Αλλαγές στους ρυθμούς μάθησης και ορμής	40
4.1.2 Προσθήκη δεύτερου κρυφού επιπέδου	43
4.1.3 Αλλαγές στην δομή του δικτύου	46
4.1.4 Τελικά αποτελέσματα	49
4.2 Αποτελέσματα στατικού δικτύου	52
4.2.1 Αλλαγές στους ρυθμούς μάθησης και ορμής	54
4.2.2 Αλλαγές στην δομή του δικτύου	60
4.2.2.1 Προσθήκη δεύτερου κρυφού επιπέδου	60
4.2.2.2 Αύξηση των νευρώνων του κρυφού επιπέδου	62
4.2.3 Αλλαγές στα δεδομένα εκπαίδευσης και επαλήθευσης	65
4.2.4 Τελικά αποτελέσματα	67

---

Κατά την διάρκεια αυτής της διπλωματικής εργασίας, μετά την υλοποίηση των νευρωνικών δικτύων που αναλύσαμε στο προηγούμενο κεφάλαιο, παράχθηκαν πολλά αποτελέσματα, εκ των οποίων κάποια από αυτά ήταν ικανοποιητικά και άλλα δεν ήταν. Η διαδικασία παραγωγής των αποτελεσμάτων είναι μια πολύ χρονοβόρα διαδικασία και ο χρόνος που αφιερώθηκε για την εξαγωγή τους ήταν μεγάλος. Ο λόγος είναι ότι για την ολοκλήρωση μιας σωστής εκπαίδευσης ενός από τα δίκτυα μας απαιτείται πολύς χρόνος. Συγκεκριμένα αλλαγές στην είσοδο, όπως αύξηση του μεγέθους του παραθύρου στην μέθοδο με το κινητό παράθυρο στο χρόνο, αλλαγές στο πλήθος των νευρώνων στα κρυφά επίπεδα και αλλαγές στον αριθμό των εποχών εκπαίδευσης συνεφέρουν ανάλογα μεγάλες αλλαγές στον χρόνο που απαιτείται για ολοκλήρωση της εκπαίδευσης. Επίσης η ίδια η διαδικασία της εκπαίδευσης είναι πολύ ευαίσθητη στις διάφορες παραμέτρους που θα της δώσουμε. Ακόμα και μια μικρή αλλαγή στις παραμέτρους μπορεί να επηρεάσει σημαντικά, είτε αρνητικά, είτε θετικά τα αποτελέσματα μας.

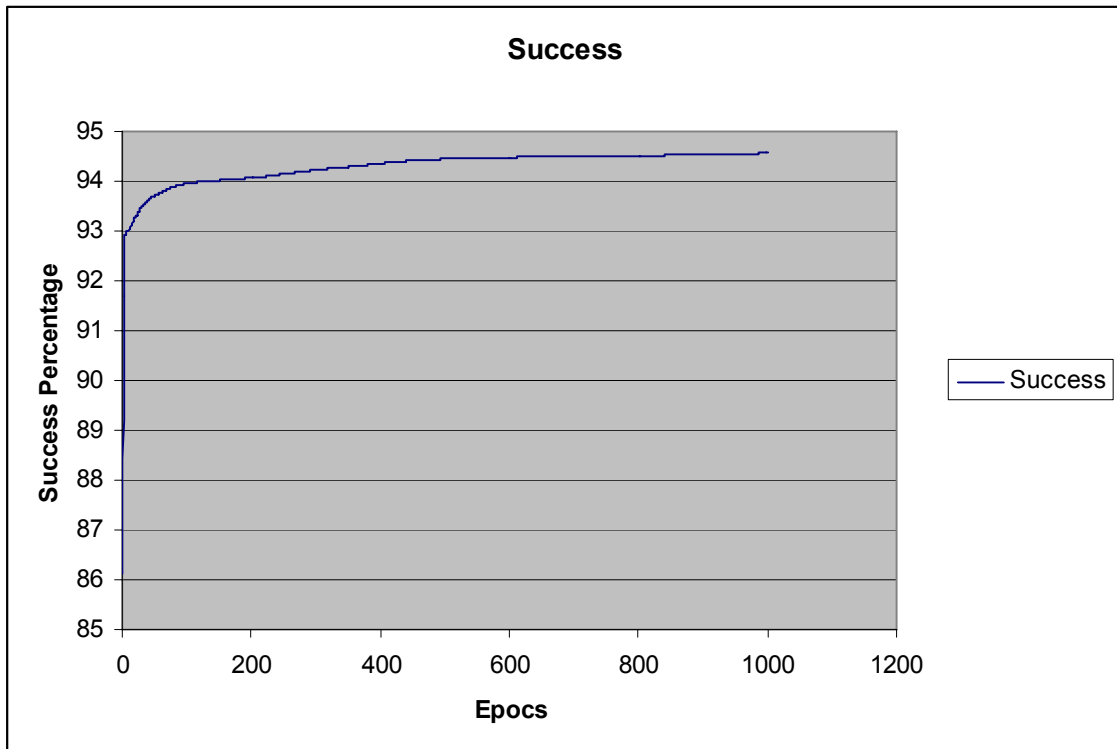
Από όλα τα αποτελέσματα που πάρθηκαν, θα παρουσιάσουμε ένα μικρό αλλά περιεκτικό φάσμα όπου φαίνονται ξεκάθαρα τα αποτελέσματα, η επιτυχία πρόβλεψης, οι τιμές των λαθών και οι επιδράσεις που έχουν οι διάφορες παραμέτροι πάνω στα τελικά αυτά αποτελέσματα.

#### **4.1 Αποτελέσματα τεχνικής κινητού παραθύρου στον χρόνο**

Τα αποτελέσματα που πάρθηκαν χρησιμοποιώντας την τεχνική του κινητού παραθύρου στον χρόνο ήταν αρκετά ικανοποιητικά και πειραματιστήκαμε αρκετά με τις διάφορες παραμέτρους προσπαθώντας να αυξήσουμε την απόδοση του δικτύου. Την απόδοση του δικτύου την υπολογίζουμε σε κάθε πρόβλεψη που κάνει το δίκτυο κατά την διάρκεια της εκπαίδευσης χρησιμοποιώντας την τεχνική του απόλυτου σφάλματος. Λόγω του ότι ο όγκος των δεδομένων είναι τεράστιος, δεν μπορούμε να δείξουμε την απόδοση για κάθε πρόβλεψη κάθε ώρας στα 7 χρόνια των δεδομένων και για τις 1000 εποχές της εκπαίδευσης. Οπότε προσθέτουμε κάθε φορά το ποσοστό της επιτυχίας στην πρόβλεψη κάθε ώρας στο σύνολο δεδομένων των 7 χρόνων και στο τέλος κάθε εποχής βρίσκουμε τον μέσο όρο της επιτυχίας για την εποχή αυτή. Στις περιπτώσεις όπου δείχνουμε μόνο μια τιμή για την επιτυχία του δικτύου, εννοούμε την τελευταία τιμή της

επιτυχίας στην τελευταία εποχή της εκπαίδευσης. Γενικά σε όλες τις εκπαιδεύσεις μας η επιτυχία τείνει να αυξάνεται καθώς περνάει ο χρόνος (σχήμα 4.1).

Για την παραγωγή των τιμών των λαθών της εκπαίδευσης του δικτύου μας χρησιμοποιήσαμε την τεχνική του τετραγωνικού λάθους. Στις επιτυχείς εκπαιδεύσεις το λάθος τείνει να μειώνεται όσο περνά ο χρόνος και το δίκτυο μαθαίνει με αποτέλεσμα τα ποσοστά επιτυχίας του στις προβλέψεις να αυξάνονται.




**Σχήμα 4.1:** Παράδειγμα αποτελεσμάτων επιτυχίας τεχνικής κινητού παραθύρου, με παραμέτρους 0.3 στον ρυθμό μάθησης και ορμής, μέγεθος παραθύρου 7 και αριθμό κρυφών νευρώνων 14.

Σε αυτό το υποκεφάλαιο θα αναλύσουμε τα αποτελέσματα που πάρθηκαν μετά από πειραματισμό στις εκπαιδεύσεις του δικτύου με την τεχνική του κινητού παραθύρου στον χρόνο. Θα αναλύσουμε τις επιδράσεις που έχουν στα αποτελέσματα μας οι αλλαγές στις παραμέτρους του ρυθμού μάθησης, της ορμής και της δομής του δικτύου, δηλαδή το μέγεθος του παραθύρου, ο αριθμός των νευρώνων στο κρυφό επίπεδο και η προσθήκη ενός δεύτερου κρυφού επιπέδου.

#### 4.1.1 Αλλαγές στους ρυθμούς μάθησης και ορμής

Κρατώντας το μέγεθος του παραθύρου, το πλήθος των νευρώνων στο κρυφό επίπεδο και τις τιμές της ορμής σταθερές στις τιμές 7, 14 και 0.3 αντίστοιχα, πειραματιστήκαμε με τις τιμές του ρυθμού μάθησης στην προσπάθεια μας να καταλήξουμε σε μια βέλτιστη τιμή η οποία μας προσφέρει τα καλύτερα αποτελέσματα.


Αρχικά εκπαιδύσαμε το δίκτυο δίνοντας την τιμή 0.3 στην παράμετρο του ρυθμού μάθησης. Ακολούθως εκπαιδύσαμε το δίκτυο δίνοντας τις τιμές 0.5 και 0.7. Σε κάθε περίπτωση αφήσαμε το δίκτυο να εκπαιδευτεί για 1000 εποχές προτού συλλέξουμε τα αποτελέσματα μας. Στο πιο κάτω σχήμα (σχήμα 4.2) βλέπουμε την σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο του ρυθμού μάθησης.



Σχήμα 4.2: Αποτελέσματα επιτυχίας για ρυθμούς μάθησης 0.3, 0.5 και 0.7

Παρατηρούμε πως η επιτυχία του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης είναι πιο υψηλή για την τιμή 0.5 στην παράμετρο του ρυθμού μάθησης.

Στο πιο κάτω σχήμα (σχήμα 4.3) βλέπουμε την σύγκριση των αποτελεσμάτων του σφάλματος του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο του ρυθμού μάθησης.




**Σχήμα 4.3: Αποτελέσματα τιμών λάθους για ρυθμούς μάθησης 0.3, 0.5 και 0.7**

Παρατηρούμε πως το σφάλμα του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης είναι πιο χαμηλό για την τιμή 0.5 στην παράμετρο του ρυθμού μάθησης.

Συμπεραίνοντας από τα αποτελέσματα του πιο πάνω πειραματισμού, η βέλτιστη τιμή για την παράμετρο του ρυθμού μάθησης ώστε το δίκτυο μας να παράγει τα καλύτερα ποσοστά επιτυχίας και το μικρότερο δυνατό σφάλμα είναι η 0.5. Τώρα πρέπει να εξετάσουμε την τιμή που θα δώσουμε στην παράμετρο της ορμής. Κρατήσαμε το μέγεθος του παραθύρου, το πλήθος των νευρώνων στο κρυφό επίπεδο και την τιμή του ρυθμού μάθησης σταθερό στο 7, 14 και 0.5 αντίστοιχα. Πειραματιστήκαμε τώρα με τις τιμές της παραμέτρου της ορμής στην προσπάθεια μας να καταλήξουμε σε μια βέλτιστη τιμή η οποία μας προσφέρει τα καλύτερα αποτελέσματα.

Αρχικά εκπαιδεύσαμε το δίκτυο δίνοντας την τιμή 0.3 στην παράμετρο της ορμής. Ακολούθως εκπαιδεύσαμε το δίκτυο δίνοντας τις τιμές 0.5 και 0.7. Σε κάθε περίπτωση

πάλι αφήσαμε το δίκτυο να εκπαιδευτεί για 1000 εποχές προτού συλλέξουμε τα αποτελέσματα μας. Στο πιο κάτω σχήμα (σχήμα 4.4) βλέπουμε την σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο του ρυθμού μάθησης.




**Σχήμα 4.4: Αποτελέσματα επιτυχίας για τιμές στην παράμετρο της ορμής 0.3, 0.5 και 0.7**

Παρατηρούμε πως η επιτυχία του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης είναι πιο υψηλή για την τιμή 0.3 στην παράμετρο της ορμής.

Στο πιο κάτω σχήμα (σχήμα 4.5) βλέπουμε την σύγκριση των αποτελεσμάτων του σφάλματος του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.





**Σχήμα 4.5:** Αποτελέσματα των λαθών για τιμές στην παράμετρο της ορμής 0.3, 0.5 και 0.7


Παρατηρούμε πως το σφάλμα του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης είναι πιο χαμηλό για την τιμή 0.3 στην παράμετρο της ορμής.

Από τους πιο πάνω πειραματισμούς καταλήγουμε πως οι βέλτιστες τιμές για της παραμέτρους του ρυθμού μάθησης και ορμής, είναι 0.5 και 0.3 αντίστοιχα.


#### 4.1.2 Προσθήκη δεύτερου κρυφού επιπέδου

Σε αυτή την υπό-ενότητα θα μελετήσουμε την συνεισφορά που θα έχει η προσθήκη ενός δεύτερου κρυφού επιπέδου στην αρχιτεκτονική του δικτύου μας. Θα κρατήσουμε τις τιμές των παραμέτρων του ρυθμού μάθησης και ορμής σταθερές στις τιμές που καταλήξαμε πιο πάνω ότι είναι οι πιο βέλτιστες. Και πάλι θα αφήσουμε το δίκτυο μας να εκπαιδευτεί για 1000 εποχές προτού συλλέξουμε τα αποτελέσματα μας. Στα σχήματα που ακολουθούν (σχήμα 4.6 και σχήμα 4.7) βλέπουμε την σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης και στο επόμενο σχήμα (σχήμα 4.8 και σχήμα 4.9) την σύγκριση των αποτελεσμάτων


του σφάλματος σε μία αρχιτεκτονική με ένα μόνο κρυφό επίπεδο, και σε μια με δύο κρυφά επίπεδα.




Σχήμα 4.6: Αποτελέσματα της επιτυχίας για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.



Σχήμα 4.7: Αποτελέσματα της επιτυχίας για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.



**Σχήμα 4.8:** Αποτελέσματα του λάθους για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.



**Σχήμα 4.9:** Αποτελέσματα του λάθους για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.


Στις πιο πάνω γραφικές παραστάσεις παρατηρούμε πως και τα δύο δίκτυα παρήγαν πολύ καλά αποτελέσματα, και η διαφορά μεταξύ των αποτελεσμάτων τους είναι μικρή. Παρόλα αυτά παρατηρούμε πως το δίκτυο με την αρχιτεκτονική δύο κρυφών επιπέδων μας προσφέρει καλύτερα αποτελέσματα, και στο ποσοστό της επιτυχίας στην πρόβλεψη του φυσικού αερίου, και στο λάθος εκπαίδευσης. Όμως αξίζει να σημειωθεί πως ο χρόνος εκπαίδευσης αυξάνεται σημαντικά στην αρχιτεκτονική δύο κρυφών επιπέδων. Οπότε για τους επόμενους πειραματισμούς θα χρησιμοποιήσουμε αρχιτεκτονικές ενός κρυφού επιπέδου για εξοικονόμηση χρόνου.

#### **4.1.3 Αλλαγές στην δομή του δικτύου**

Μετά τους πειραματισμούς στις αλλαγές των παραμέτρων του ρυθμού μάθησης και ορμής θα πειραματιστούμε αλλάζοντας την δομή του δικτύου και παρατηρώντας τις αλλαγές που θα συμβούν στα αποτελέσματα των εκπαιδεύσεων. Θα κρατήσουμε τις τιμές των παραμέτρων του ρυθμού μάθησης και ορμής σταθερές στις τιμές που βρήκαμε με τα πειράματα πιο πάνω να είναι οι πιο βέλτιστες. Οι αλλαγές που θα κάνουμε, θα είναι στο μέγεθος του παραθύρου και ταυτόχρονα στον αριθμό των νευρώνων του κρυφού επιπέδου, για να δώσουμε στο δίκτυο μας μια μεγαλύτερη εικόνα για το τι συμβαίνει στα δεδομένα ώστε να μπορέσει να κάνει μια καλύτερη συσχέτιση μεταξύ της εισόδου και της εξόδου. Το μέγεθος του παραθύρου μας δείχνει πόσες ώρες πιο πίσω στον χρόνο το δίκτυο μας μπορεί να βλέπει για να κάνει την πρόβλεψή του. Η αύξηση αυτή στο μέγεθος του παραθύρου και κατά συνέπεια και η αύξηση στον αριθμό των κρυφών νευρώνων, επιφέρει δραματική αύξηση στον χρόνο που απαιτείται για την ολοκλήρωση της εκπαίδευσης του δικτύου. Για αυτό τον λόγο δεν θα υπερβούμε το μέγεθος των 24 ορών για το μέγεθος του παραθύρου.

Όπως αναλύσαμε και προηγουμένως στο κεφάλαιο 3 στην περιγραφή των δεδομένων η γραφική παράσταση της ζήτησης του φυσικού αερίου μέσα σε μια συγκεκριμένη μέρα, είτε αυτή είναι καθημερινή μέρα είτε όχι, στερείται κάποιας συνοχής. Είναι μια μεταβλητή εικόνα που δεν μπορεί να χαρακτηριστεί με συνέπεια, όπως μπορούμε να δούμε και από το σχήμα που ακολουθεί (σχήμα 4.10). Δίνοντας του δικτύου μέγεθος παραθύρου μικρότερου των 24 ορών, του στερούμε την πλήρη εικόνα μιας ολοκληρωμένης μέρας, ενός ολοκληρωμένου μοτίβου. Παρόλα αυτά το δίκτυο είναι


ικανό, και με πιο περιορισμένο παράθυρο να βρει μια συσχέτιση στα δεδομένα και να μας δώσει ένα καλό αποτέλεσμα.



**Σχήμα 4.10:** Η ζήτηση για μια τυπική μέρα στα δεδομένα εισόδου.

Οι τιμές στα μεγέθη του παραθύρου που θα εξετάσουμε στον πειραματισμό μας θα είναι οι 7 ώρες, 12 ώρες και 24 ώρες. Θα συγκρίνουμε τα αποτελέσματα μεταξύ τους και στην επιτυχία του δικτύου στις προβλέψεις και στο λάθος της εκπαίδευσης.

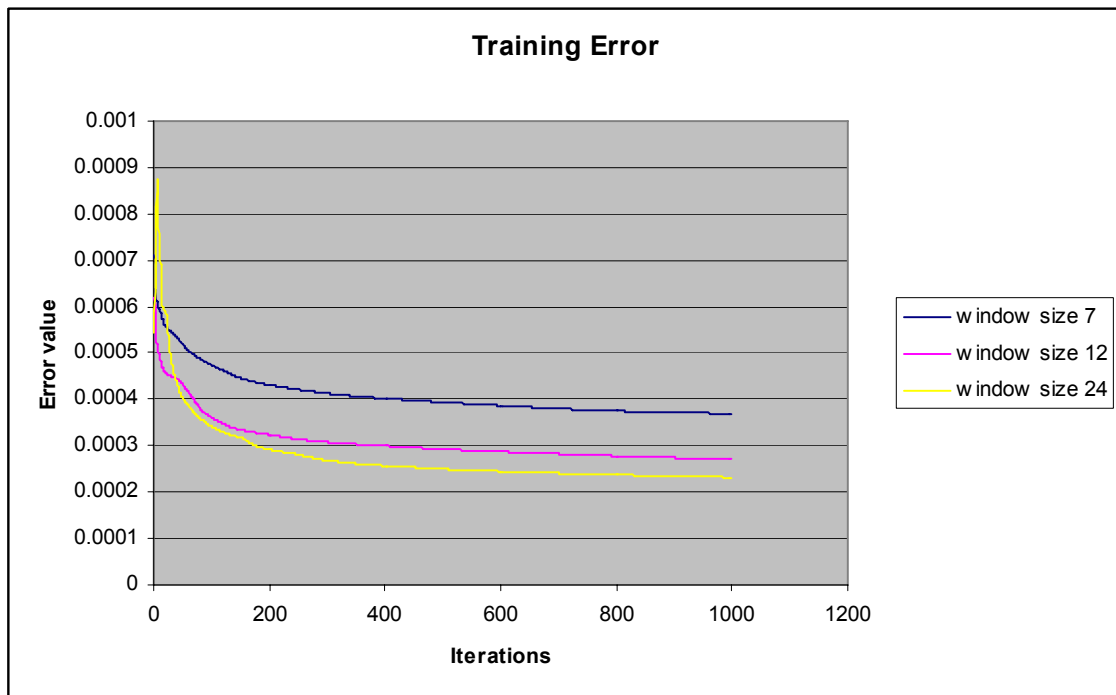
Στην γραφική παράσταση που ακολουθεί (σχήμα 4.11), βλέπουμε την σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τα μεγέθη παραθύρων 7, 12 και 24. Αξίζει να σημειωθεί πως ο χρόνος για εκπαίδευση του δικτύου αυξάνεται δραματικά για μεγάλα μεγέθη παραθύρου.



**Σχήμα 4.11: Αποτελέσματα της επιτυχίας του δικτύου για μεγέθη παραθύρου 7, 12 και 24.**

Παρατηρούμε πως η επιτυχία του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης είναι πιο υψηλή για μέγεθος παραθύρου 24. Το αποτέλεσμα αυτό ήταν αναμενόμενο, διότι όπως περιγράψαμε πιο πάνω, δίνοντας στο δίκτυο παράθυρο μεγέθους 24 ωρών, μιας ολόκληρης μέρας δηλαδή, του δίνουμε μια πιο ολοκληρωμένη εικόνα στο μοτίβο της ζήτησης του φυσικού αερίου μέσα σε μια μέρα.

Στην γραφική παράσταση που ακολουθεί (σχήμα 4.12), βλέπουμε την σύγκριση των αποτελεσμάτων του σφάλματος του δικτύου στην τελευταία πρόβλεψη της εκπαίδευσης για τα μεγέθη παραθύρων 7, 12 και 24.

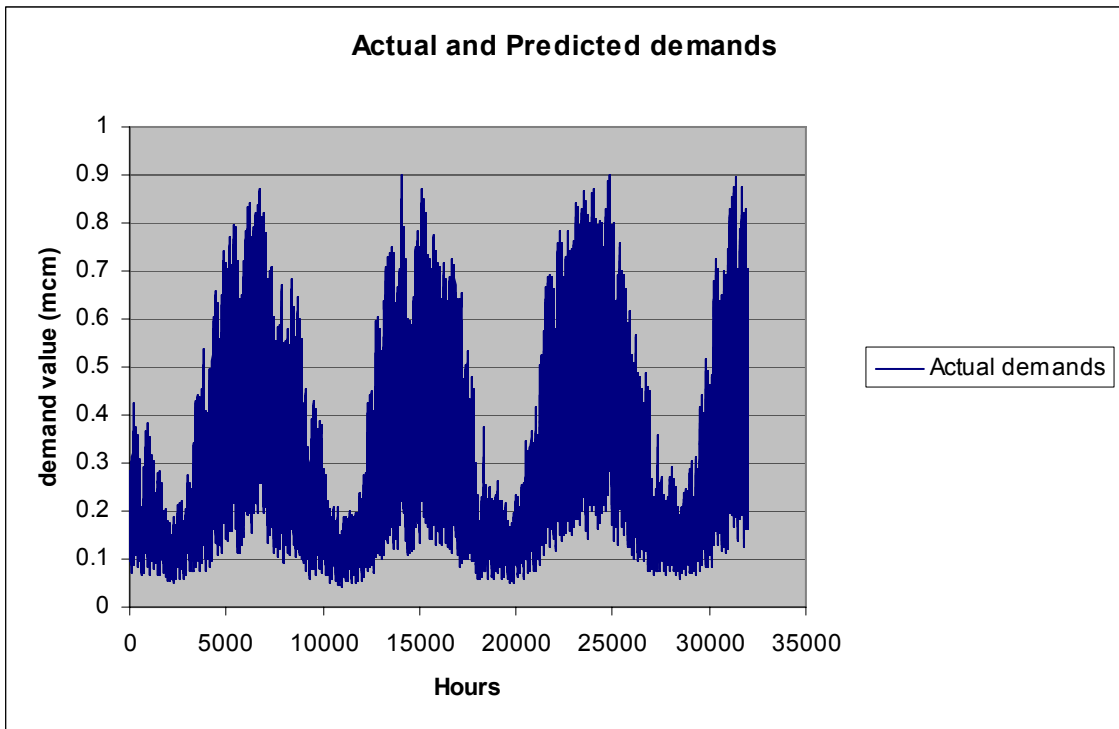


**Σχήμα 4.12:** Αποτελέσματα λαθών του δικτύου για μεγέθη παραθύρου 7, 12 και 24.


Παρατηρούμε πως το σφάλμα του δικτύου στην είναι πιο χαμηλό επίσης για το μέγεθος παραθύρου 24.

#### 4.1.4 Τελικά αποτελέσματα

Συλλέγοντας όλα τα αποτελέσματα από τους πιο πάνω πειραματισμούς, καταλήξαμε στην πιο βέλτιστη οργάνωση για το δίκτυο μας. Για την παράμετρο του ρυθμού μάθησης δώσαμε την τιμή 0.5 και για την παράμετρο της ορμής την τιμή 0.3. Δώσαμε την τιμή 24 για το μέγεθος παραθύρου και την τιμή 30 για τον αριθμό των κρυφών νευρώνων στο κρυφό επίπεδο. Βάση αυτών των παραμέτρων εκπαιδεύσαμε το δίκτυο μας για 1000 εποχές και συλλέξαμε τα αποτελέσματα. Το τελικό ποσοστό επιτυχίας που επιτεύχθηκε ήταν το 95.9041%. Στο σχήματα που ακολουθούν βλέπουμε το πόσο κοντά στις πραγματικές τιμές ζήτησης ήταν οι προβλέψεις του δικτύου μας. Στο σχήμα 4.13 βλέπουμε τις πραγματικές τιμές της ζήτησης, στο σχήμα 4.14 τις προβλεπόμενες τιμές που πήραμε από την έξοδο του δικτύου μας, και στο σχήμα 4.15 έχουμε βάλει αυτές τις γραφικές παραστάσεις την μία πάνω στην άλλη για σύγκριση.




Σχήμα 4.13: Οι πραγματικές τιμές ζήτησης φυσικού αερίου.




Σχήμα 4.14: Αποτελέσματα προβλέψεων του τελικού δικτύου.






**Σχήμα 4.15:** Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών.

Στα σχήματα 4.16 και 4.17 βλέπουμε την σύγκριση αποτελεσμάτων προβλέψεων του τελικού δικτύου έναντι των πραγματικών τιμών για ένα μικρότερο ποσό ωρών.



**Σχήμα 4.16:** Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών για 48 ώρες σε καλοκαιρινή περίοδο.



**Σχήμα 4.17:** Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών για 48 ώρες σε χειμερινή περίοδο.

Βλέπουμε πως οι τελικές προβλέψεις του δικτύου είναι πολύ ακριβής. Το δίκτυο μας μαθαίνει πολύ καλά την συσχέτιση των δεδομένων στον χρόνο, ιδικά με μέγεθος παραθύρου 24, όπου το δίκτυο έχει μια καλή εικόνα για το μοτίβο στην ζήτηση που επικρατεί κατά την διάρκεια μιας μέρας. Αυτή η τεχνική είναι και η πιο ιδανική για να μάθουμε στο δίκτυο και την αύξηση στον πληθυσμό των χρηστών που επιφέρουν μια γενική αύξηση στις τιμές της ζήτησης κάθε χρόνο.

#### **4.2 Αποτελέσματα στατικού δικτύου**


Τα αποτελέσματα που πάρθηκαν χρησιμοποιώντας το στατικό δίκτυο ήταν επίσης αρκετά ικανοποιητικά και πειραματιστήκαμε και εδώ αρκετά με τις διάφορες παραμέτρους προσπαθώντας να αυξήσουμε την απόδοση του δικτύου. Την απόδοση του δικτύου την υπολογίζουμε στο τέλος κάθε εποχής της εκπαίδευσης, όπου κάνουμε ακόμα ένα εμπρόσθιο πέρασμα (feed forward) χρησιμοποιώντας όμως τώρα τα δεδομένα επαλήθευσης, τα οποία είναι διαφορετικά από τα δεδομένα εκπαίδευσης. Σε

αυτό το σημείο εφαρμόζουμε και πάλι την τεχνική του απολύτου σφάλματος για την εύρεση του ποσοστού του λάθους και έπειτα το ποσοστό επιτυχίας.

Για την παραγωγή των τιμών των λαθών της εκπαίδευσης του δικτύου μας χρησιμοποιήσαμε την τεχνική του τετραγωνικού λάθους. Στις επιτυχής εκπαιδεύσεις το λάθος τείνει να μειώνεται όσο περνά ο χρόνος και το δίκτυο μαθαίνει με αποτέλεσμα τα ποσοστά επιτυχίας του στις προβλέψεις να αυξάνονται.

Σε αυτό το υποκεφάλαιο θα αναλύσουμε τα αποτελέσματα που πάρθηκαν μετά από πειραματισμό στις εκπαιδεύσεις στο στατικό δίκτυο. Θα αναλύσουμε τις επιδράσεις που έχουν στα αποτελέσματα μας οι αλλαγές στις παραμέτρους του ρυθμού μάθησης, της ορμής, της δομής του δικτύου, δηλαδή ο αριθμός των νευρώνων στο κρυφό επίπεδο και η προσθήκη ενός δεύτερου κρυφού επιπέδου, καθώς και αλλαγές στα δεδομένα εκπαίδευσης και επαλήθευσης.

Στις πρώτες εκπαιδεύσεις του δικτύου μας ξεκινήσαμε με μέγιστο αριθμό εποχών εκπαίδευσης το 1000. Μετά από μερικές εκπαιδεύσεις όμως, η μορφή των γραφικών παραστάσεων του λάθους εκπαίδευσης και επαλήθευσης ήταν όπως φαίνονται στην πιο κάτω γραφική παράσταση (σχήμα 4.18).



**Σχήμα 4.18:** Το λάθος εκπαίδευσης και επαλήθευσης στις πρώτες εκπαιδεύσεις του στατικού δικτύου.


Βλέποντας τις πιο πάνω γραφικές παραστάσεις παρατηρούμε το κλασσικό πρόβλημα της υπέρ-εκπαίδευσης. Το δίκτυο μας αρχίζει να μαθαίνει «παπαγαλία» τα δεδομένα εκπαίδευσης και χάνει την δυνατότητα να γενικεύει. Αυτό φαίνεται από την άνοδο στο λάθος πάνω στα δεδομένα επαλήθευσης από κάποιο σημείο και μετά. Στην προσπάθεια μας να αποφύγουμε αυτό το πρόβλημα, μειώσαμε τον αριθμό των εποχών εκπαίδευσης.

#### 4.2.1 Αλλαγές στους ρυθμούς μάθησης και ορμής

Κρατώντας τα ίδια δεδομένα εκπαίδευσης και επαλήθευσης, το πλήθος των νευρώνων στο κρυφό επίπεδο στους 16 και την τιμή της ορμής σταθερά στην τιμή 0.7, πειραματιστήκαμε με τις τιμές του ρυθμού μάθησης στην προσπάθεια μας να καταλήξουμε σε μια βέλτιστη τιμή η οποία μας προσφέρει τα καλύτερα αποτελέσματα.

Αρχικά εκπαιδεύσαμε το δίκτυο δίνοντας την τιμή 0.3 στην παράμετρο του ρυθμού μάθησης. Ακολούθως εκπαιδεύσαμε το δίκτυο δίνοντας τις τιμές 0.5 και 0.7. Σε κάθε περίπτωση αφήσαμε το δίκτυο να εκπαιδευτεί για περίπου 300 εποχές προτού συλλέξουμε τα αποτελέσματα μας. Στο πιο κάτω σχήμα (σχήμα 4.19) βλέπουμε την


σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο του ρυθμού μάθησης.




**Σχήμα 4.19: Αποτελέσματα επιτυχίας για ρυθμούς μάθησης 0.3, 0.5 και 0.7.**

Παρατηρούμε πως η επιτυχία του δικτύου μετά την εκπαίδευση είναι πιο ψήλη για την τιμή 0.7 στην παράμετρο του ρυθμού μάθησης.

Στα πιο κάτω σχήματα βλέπουμε την σύγκριση των αποτελεσμάτων του σφάλματος επαλήθευσης του δικτύου (σχήμα 4.20) και του σφάλματος εκπαίδευσης (σχήμα 4.21) για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο του ρυθμού μάθησης.



Σχήμα 4.20: Αποτελέσματα τιμών λάθους επαλήθευσης για ρυθμούς μάθησης 0.3, 0.5 και 0.7.




Σχήμα 4.21: Αποτελέσματα τιμών λάθους εκπαίδευσης για ρυθμούς μάθησης 0.3, 0.5 και 0.7.

Από τις πιο πάνω γραφικές παραστάσεις, παρατηρούμε ότι οι τιμές του λάθους επαλήθευσης στις εκπαιδεύσεις με παράμετρο ρυθμού μάθησης 0.5 και 0.7 είναι πολύ κοντά μεταξύ τους και σαφώς μικρότερες από το λάθος επαλήθευσης στην εκπαίδευση με ρυθμό μάθησης 0.3. Όπως ήταν και αναμενόμενο το λάθος εκπαίδευσης για την εκπαίδευση με ρυθμό μάθησης 0.7 ήταν μικρότερο από το λάθος στις εκπαιδεύσεις με ρυθμούς μάθησης 0.5 και 0.3. Από τα αποτελέσματα αυτά συμπεραίνουμε πως ο ιδανικότερος ρυθμός μάθησης για το δίκτυο μας είναι ο 0.7.

Κρατώντας τα ίδια δεδομένα εκπαίδευσης και επαλήθευσης όπως και πριν, το πλήθος των νευρώνων στο κρυφό επίπεδο και πάλι στους 16 και την τιμή του ρυθμού μάθησης στο 0.7, πειραματιστήκαμε με τις τιμές στην παράμετρο της ορμής στην προσπάθεια μας να καταλήξουμε σε μια βέλτιστη τιμή η οποία μας προσφέρει τα καλύτερα αποτελέσματα.

Αρχικά εκπαιδεύσαμε το δίκτυο δίνοντας την τιμή 0.3 στην παράμετρο της ορμής. Ακολούθως εκπαιδεύσαμε το δίκτυο δίνοντας τις τιμές 0.5 και 0.7. Σε κάθε περίπτωση αφήσαμε το δίκτυο να εκπαιδευτεί για περίπου 300 εποχές προτού συλλέξουμε τα αποτελέσματα μας. Στο πιο κάτω σχήμα (σχήμα 4.22) βλέπουμε την σύγκριση των αποτελεσμάτων της επιτυχίας του δικτύου για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.




**Σχήμα 4.22:** Αποτελέσματα επιτυχίας για τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.


Παρατηρούμε πως η επιτυχία του δικτύου μετά την εκπαίδευση είναι πιο ψήλη για την τιμή 0.7 στην παράμετρο της ορμής.

Στα πιο κάτω σχήματα βλέπουμε την σύγκριση των αποτελεσμάτων του σφάλματος επαλήθευσης του δικτύου (σχήμα 4.23) και του σφάλματος εκπαίδευσης (σχήμα 4.24) για τις τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.





Σχήμα 4.23: Αποτελέσματα τιμών λάθους επαλήθευσης για τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.



Σχήμα 4.24: Αποτελέσματα τιμών λάθους εκπαίδευσης για τιμές 0.3, 0.5 και 0.7 στην παράμετρο της ορμής.


Από τις πιο πάνω γραφικές παραστάσεις, παρατηρούμε ότι οι τελικές τιμές του λάθους επαλήθευσης στις εκπαιδεύσεις με παράμετρο ορμής 0.3, 0.5 και 0.7 είναι πολύ κοντά μεταξύ τους. Το ίδιο ισχύει και για το λάθος εκπαίδευσης. Το λάθος επαλήθευσης όμως για την εκπαίδευση με παράμετρο ορμής 0.7 ήταν το πιο χαμηλό, αν και η διαφορά ήταν στο έκτο δεκαδικό ψηφίο. Τα αποτελέσματα επιτυχίας όμως για την εκπαίδευση με παράμετρο ορμής 0.7 ήταν ελαφρώς καλύτερα από τα αποτελέσματα των εκπαιδεύσεων με παραμέτρους ορμής 0.3 και 0.5. Από τα αποτελέσματα αυτά συμπεραίνουμε πως η ιδανικότερη τιμή για την παράμετρο της ορμής για το δίκτυο μας είναι η 0.7.

#### **4.2.2 Αλλαγές στην δομή του δικτύου**


Μετά τους πειραματισμούς στις αλλαγές των παραμέτρων του ρυθμού μάθησης και ορμής θα πειραματιστούμε αλλάζοντας την δομή του δικτύου και παρατηρώντας τις αλλαγές που θα συμβούν στα αποτελέσματα των εκπαιδεύσεων. Θα κρατήσουμε τις τιμές των παραμέτρων του ρυθμού μάθησης και ορμής σταθερές στις τιμές που βρήκαμε με τα πειράματα πιο πάνω να είναι οι πιο βέλτιστες. Οι αλλαγές που θα κάνουμε, θα είναι η προσθήκη ενός δεύτερου κρυφού επιπέδου, καθώς και η αλλαγή στον αριθμό των νευρώνων του κρυφού επιπέδου.

##### **4.2.2.1 Προσθήκη δεύτερου κρυφού επιπέδου**


Σε αυτό το υποκεφάλαιο πειραματιστήκαμε με την εισαγωγή ενός δεύτερου κρυφού επιπέδου στην δομή του δικτύου. Κρατήσαμε της τιμές 0.7 στους ρυθμούς μάθησης και ορμής, όπως βρήκαμε πιο πάνω να είναι οι πιο βέλτιστες. Συγκρίναμε τα αποτελέσματα της επιτυχίας του δικτύου, καθώς και τα αποτελέσματα των τιμών των λαθών επαλήθευσης και εκπαίδευσης, για ένα δίκτυο με ένα κρυφό επίπεδο, και ένα δίκτυο με δύο κρυφά επίπεδα. Αξίζει να σημειωθεί πως και σε αυτή την περίπτωση ο χρόνος εκπαίδευσης του δικτύου αυξάνεται όταν προστεθεί ένα επιπλέον κρυφό επίπεδο. Στο πιο κάτω σχήμα (σχήμα 4.25) βλέπουμε την επιτυχία των δύο δικτύων. Στα δύο επόμενα (σχήμα 4.26 και 4.27) βλέπουμε τα λάθη επαλήθευσης και λάθη εκπαίδευσης των δύο δικτύων.



Σχήμα 4.25: Αποτελέσματα της επιτυχίας για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.



Σχήμα 4.26: Αποτελέσματα του λάθους επαλήθευσης για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.




**Σχήμα 4.27:** Αποτελέσματα του λάθους εκπαίδευσης για ένα δίκτυο με ένα κρυφό επίπεδο και ένα δίκτυο με δύο κρυφά επίπεδα.

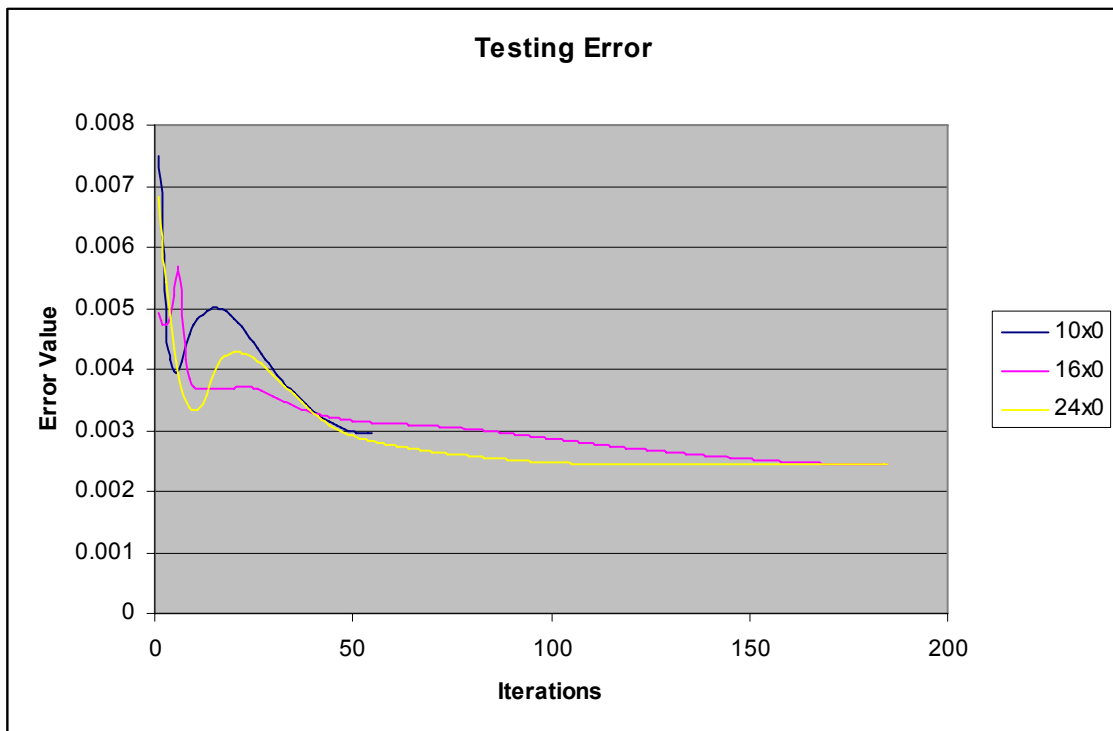
Στις πιο πάνω γραφικές παραστάσεις παρατηρούμε πως και τα δύο δίκτυα παρήγαγαν αρκετά καλά αποτελέσματα, και η διαφορά μεταξύ των αποτελεσμάτων τους είναι μικρή (περίπου 0.03% στην επιτυχία πρόβλεψης). Παρόλα αυτά παρατηρούμε πως το δίκτυο με την αρχιτεκτονική δύο κρυφών επιπέδων είναι αυτό που μας προσφέρει τα ελαφρώς καλύτερα αποτελέσματα, και στο ποσοστό της επιτυχίας στην πρόβλεψη του φυσικού αερίου, και στο λάθος επαλήθευσης. Όμως αξίζει να σημειωθεί και πάλιν πως ο χρόνος εκπαίδευσης αυξάνεται σημαντικά στην αρχιτεκτονική δύο κρυφών επιπέδων. Οπότε, όπως και πριν, για τους επόμενους πειραματισμούς θα χρησιμοποιήσουμε αρχιτεκτονικές ενός κρυφού επιπέδου για εξοικονόμηση χρόνου, εξάλλου μια τόσο μικρή διαφορά στην επιτυχία πρόβλεψης δεν δικαιολογεί τον σημαντικά αυξημένο χρόνο εκπαίδευσης για το δίκτυο με τα δύο κρυφά επίπεδα.

#### 4.2.2.2 Αύξηση των νευρώνων του κρυφού επιπέδου


Τώρα θα πειραματιστούμε με την αλλαγή του αριθμού των νευρώνων στο κρυφό επίπεδο. Κρατήσαμε τις τιμές 0.7 στους ρυθμούς μάθησης και ορμής, όπως βρήκαμε πιο πάνω να είναι οι πιο βέλτιστες. Συγκρίναμε τα αποτελέσματα της επιτυχίας του δικτύου, καθώς και τα αποτελέσματα των τιμών των λαθών επαλήθευσης και εκπαίδευσης, για ένα δίκτυο με 10 νευρώνες στο κρυφό επίπεδο, ένα δίκτυο με 16 και ένα δίκτυο με 24. Στο πιο κάτω σχήμα (σχήμα 4.28) βλέπουμε την επιτυχία των δύο δικτύων. Στα δύο επόμενα (σχήμα 4.29 και 4.30) βλέπουμε τα λάθη επαλήθευσης και λάθη εκπαίδευσης των τριών δικτύων.



Σχήμα 4.28: Αποτελέσματα της επιτυχίας για δίκτυα με αριθμό κρυφών νευρώνων 10, 16 και 24.



Σχήμα 4.29: Αποτελέσματα του λάθους επαλήθευσης για δίκτυα με αριθμό κρυφών νευρώνων 10, 16 και 24.




Σχήμα 4.30: Αποτελέσματα του λάθους εκπαίδευσης για δίκτυα με αριθμό κρυφών νευρώνων 10, 16 και 24.


Από τις πιο πάνω γραφικές παραστάσεις παρατηρούμε πως και τα τρία δίκτυα παρήγαν αρκετά καλά αποτελέσματα αλλά τα αποτελέσματα των δικτύων με αριθμό κρυφών νευρώνων 16 και 24 ήταν σαφώς καλύτερα από τα αποτελέσματα του δικτύου με αριθμό κρυφών νευρώνων 10. Η διαφορά μεταξύ των αποτελεσμάτων των δικτύων με 16 και 24 κρυφούς νευρώνες όμως είναι μικρή (περίπου 0.6% στην επιτυχία πρόβλεψης). Παρόλα αυτά παρατηρούμε πως το δίκτυο με αριθμό κρυφών νευρώνων 16 είναι αυτό που μας προσφέρει τα ελαφρώς καλύτερα αποτελέσματα.

#### **4.2.3 Αλλαγές στα δεδομένα εκπαίδευσης και επαλήθευσης**

Όπως αναφέραμε πιο πριν στο κεφάλαιο 2, τα δεδομένα μας καλύπτουν ένα φάσμα 7 χρόνων, από τις 02/05/1990 μέχρι τις 30/09/1997. Μέχρι τώρα το δίκτυο μας με την στατική μέθοδο το εκπαιδεύαμε με δεδομένα εκπαίδευσης από τις 03/05/1992 μέχρι 30/09/1997 και δεδομένα επαλήθευσης από τις 02/05/1990 μέχρι 02/05/1992 (σύνολο1). Σε αυτό το υποκεφάλαιο θα κάνουμε ένα πειραματισμό, εφαρμόζοντας κάποιες αλλαγές στα δεδομένα εκπαίδευσης και επαλήθευσης στην προσπάθεια μας να βελτιώσουμε τα αποτελέσματα μας. Εκτός από την πιο πάνω οργάνωση στα δεδομένα εισόδου, θα δοκιμάσουμε και ένα σύνολο με δεδομένα εκπαίδευσης από τις 02/05/1990 μέχρι τις 29/09/1995 και δεδομένα επαλήθευσης από τις 30/09/1995 μέχρι τις 30/09/1997 (σύνολο2) και θα συγκρίνουμε τα αποτελέσματα τους. Στο σχήμα 4.31 βλέπουμε την σύγκριση της επιτυχίας των αποτελεσμάτων μεταξύ δύο δικτύων που εκπαιδεύτηκαν με τα διαφορετικά αυτά σύνολα. Στα σχήματα που ακολουθούν (σχήμα 4.32 και 4.33) βλέπουμε την σύγκριση των λαθών επαλήθευσης και εκπαίδευσης για τα δύο αυτά δίκτυα.




Σχήμα 4.31: Αποτελέσματα επιτυχίας για τα δύο δίκτυα εκπαιδευμένα με διαφορετικά σύνολο δεδομένων.



Σχήμα 4.32: Αποτελέσματα λαθών επαλήθευσης για τα δύο δίκτυα εκπαιδευμένα με διαφορετικά σύνολο δεδομένων.






**Σχήμα 4.33:** Αποτελέσματα λαθών εκπαίδευσης για τα δύο δίκτυα εκπαιδευμένα με διαφορετικά σύνολο δεδομένων.

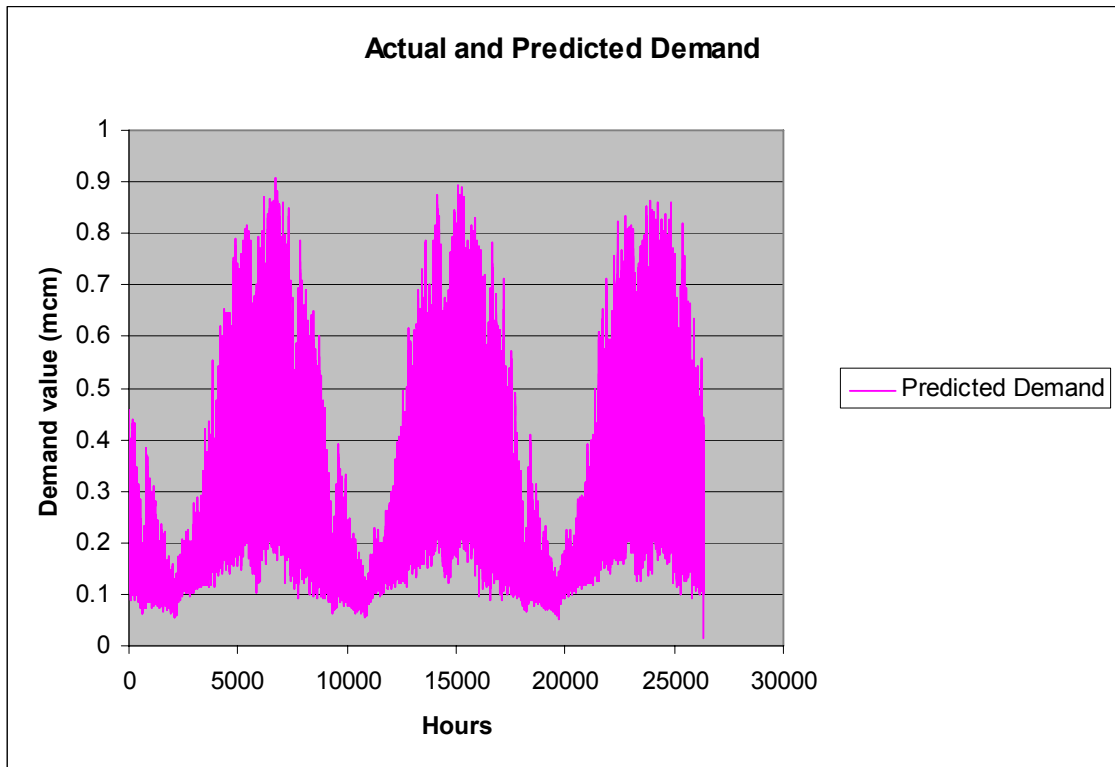
Από τις πιο πάνω γραφικές παραστάσεις παρατηρούμε πως τα αποτελέσματα του δικτύου που εκπαιδεύτηκε με το πρώτο σύνολο δεδομένων, όπου τα δεδομένα εκπαίδευσης ήταν από τις 03/05/1992 μέχρι 30/09/1997 και τα δεδομένα επαλήθευσης από τις 02/05/1990 μέχρι 02/05/1992, ήταν σαφώς καλύτερα από τα αποτελέσματα του δικτύου που εκπαιδεύτηκε με το δεύτερο σύνολο δεδομένων, όπου τα αποτελέσματα εκπαίδευσης ήταν από τις 02/05/1990 μέχρι τις 29/09/1995 και τα δεδομένα επαλήθευσης από τις 30/09/1995 μέχρι τις 30/09/1997. Η διαφορά στην επιτυχία πρόβλεψης των δικτύων ήταν στο 12.268%, το οποίο είναι ένα αρκετά σεβαστό ποσοστό. Ένας από τους λόγους για τους οποίους μπορεί να οφείλεται αυτό είναι στο ότι στα αρχικά δεδομένα για την ζήτηση του φυσικού αερίου οι περισσότερες τιμές που έλειπαν βρίσκονταν στις τελευταίες χρονιές του συνόλου, τις οποίες χρησιμοποιήσαμε για επαλήθευση στο δεύτερο πείραμα.

#### 4.2.4 Τελικά αποτελέσματα

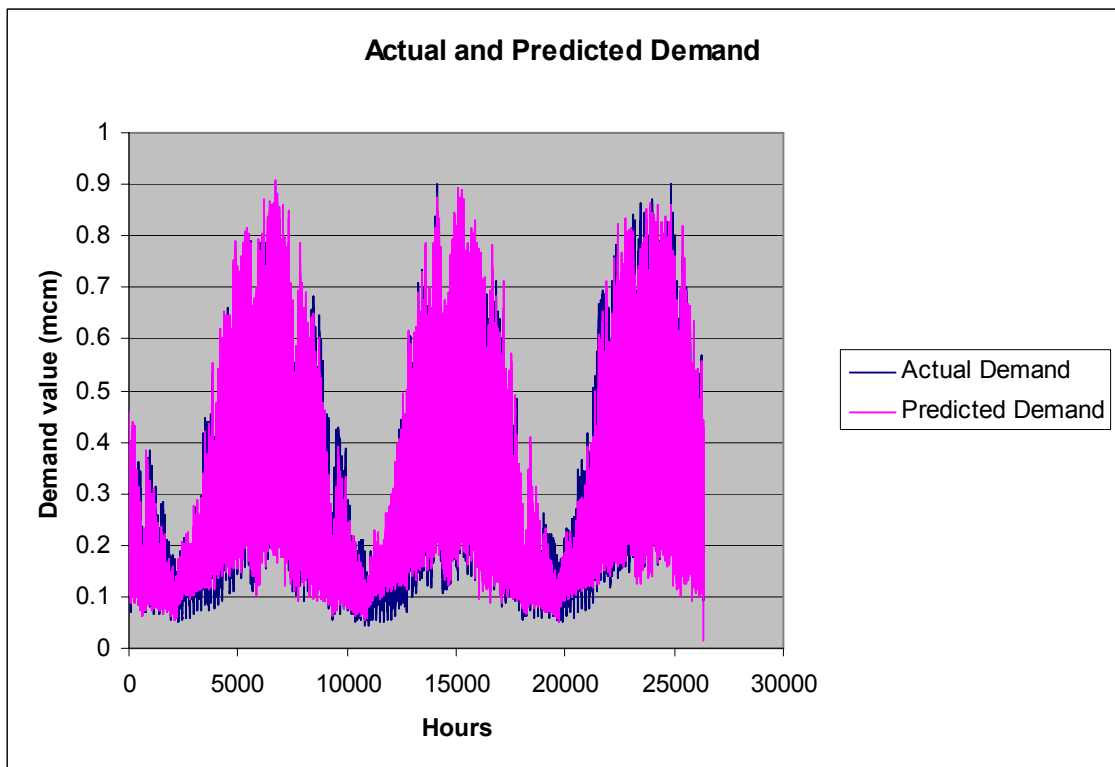
Συλλέγοντας όλα τα αποτελέσματα από τους πιο πάνω πειραματισμούς, καταλήξαμε στην πιο βέλτιστη οργάνωση για το δίκτυο μας. Για την παράμετρο του ρυθμού μάθησης δώσαμε την τιμή 0.7 και για την παράμετρο της ορμής επίσης την τιμή 0.7. Για τον αριθμό των κρυφών νευρώνων στο κρυφό επίπεδο δώσαμε μέγεθος 16. Βάση αυτών των παραμέτρων εκπαιδεύσαμε το δίκτυο μας για περίπου 200 εποχές και συλλέξαμε τα αποτελέσματα. Το τελικό ποσοστό επιτυχίας που επιτεύχθηκε ήταν το 85.9357%. Στο σχήματα που ακολουθούν βλέπουμε το πόσο κοντά στις πραγματικές τιμές ζήτησης ήταν οι προβλέψεις του δικτύου μας. Στο σχήμα 4.34 βλέπουμε τις πραγματικές τιμές της ζήτησης, στο σχήμα 4.35 τις προβλεπόμενες τιμές που πήραμε από την έξοδο του δικτύου μας, και στο σχήμα 4.36 έχουμε βάλει αυτές τις γραφικές παραστάσεις την μία πάνω στην άλλη για σύγκριση. Στα σχήματα 4.37 και 4.38 βλέπουμε και πάλι την σύγκριση αποτελεσμάτων των προβλέψεων του τελικού δικτύου έναντι των πραγματικών τιμών για ένα μικρότερο όμως αριθμό ωρών. Παρατηρώντας τις γραφικές αυτές παραστάσεις μπορούμε να δούμε πως το δίκτυο μας, μας προσφέρει μια αρκετά καλή πρόβλεψη. Βλέπουμε πως η γραφική παράσταση των τιμών πρόβλεψης είναι αρκετά κοντά στη γραφική των πραγματικών τιμών.



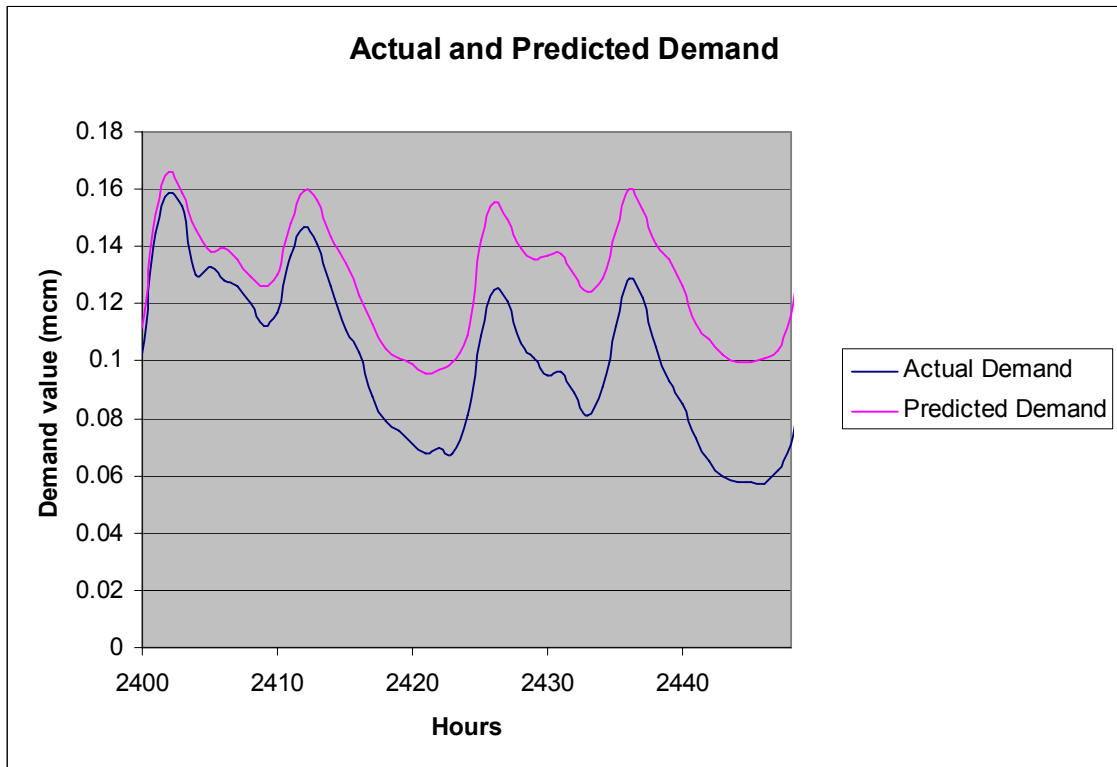
Σχήμα 4.34: Οι πραγματικές τιμές ζήτησης.




Σχήμα 4.35: Αποτελέσματα προβλέψεων του τελικού δικτύου.



Σχήμα 4.36: Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών.



Σχήμα 4.37: Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών για 48 ώρες σε μια καλοκαιρινή προς φθινοπωρινή περίοδο.



Σχήμα 4.38: Σύγκριση αποτελεσμάτων πρόβλεψης και πραγματικών τιμών για 48 ώρες σε χειμερινή περίοδο.

Παρατηρούμε ότι οι προβλέψεις του δικτύου μας είναι αρκετά κοντά στις πραγματικές τιμές της ζήτησης του φυσικού αερίου. Μπορούμε επίσης να δούμε πως η μεγαλύτερη απόκλιση από τις πραγματικές τιμές παρατηρείται στους φθινοπωρινούς μήνες (σχήμα 4.37).

## **Κεφάλαιο 5**

### **Συμπεράσματα**

---

5.1 Συμπεράσματα	73
5.2 Μελλοντική εργασία	74

---

## 5.1 Συμπεράσματα

Η πρόβλεψη της ζήτησης του φυσικού αερίου για θέρμανση είναι ένα πρόβλημα του οποίου η επίλυση θα βοηθήσει πολύ τις εταιρίες διανομής του. Η κίνηση του φυσικού αερίου στις διασωληνώσεις είναι πολύ αργή, οπότε οι εταιρίες πρέπει να γνωρίζουν από αρκετά πιο πριν τις ποσότητες του φυσικού αερίου που θα χρειαστούν για κάποιο συγκεκριμένο χρονικό διάστημα, ώστε να το διοχετεύσουν στο σύστημα έγκαιρα. Η αποτυχία μιας καλής πρόβλεψης μπορεί να επιφέρει προβλήματα στην εταιρία, όπως ζημιές λόγω υπέρ – αγοράς αερίου, ή μη ευχαριστημένους πελάτες λόγω έλλειψης αερίου στο σύστημα.

Στόχος αυτής της διπλωματικής εργασίας ήταν η υλοποίηση ενός συστήματος βασισμένο σε νευρωνικά δίκτυα που να μπορεί να παράγει μια τέτοια πρόβλεψη. Για την επίλυση αυτού του προβλήματος προμηθευτήκαμε δεδομένα από μια μεγάλη εταιρία. Τα δεδομένα αυτά περιέχουν την ζήτηση του φυσικού αερίου για κάθε μέρα και κάθε ώρα για ένα φάσμα 7 χρόνων. Παράλληλα προμηθευτήκαμε και δεδομένα θερμοκρασιών και ταχυτήτων ανέμων που καλύπτουν αυτό το φάσμα. Βασισμένοι σε αυτά τα δεδομένα καταλήξαμε στην προσέγγιση αυτού του προβλήματος με δύο τεχνικές. Την τεχνική του κινητού παραθύρου στον χρόνο, όπου εκμεταλλευτήκαμε την χρονική συσχέτιση στα δεδομένα της ζήτησης του φυσικού αερίου, και με ένα στατικό δίκτυο, όπου χρησιμοποιήσαμε τα δεδομένα θερμοκρασίας και ταχύτητας ανέμων στην πρόβλεψη μαζί με εισόδους για τον τρέχον μήνα, ένα μέσο όρο της ζήτησης στα προηγούμενα χρόνια καθώς και μια είσοδο για ένδειξη αγρίας ή καθημερινής μέρας.

Όσο αφορά τα νευρωνικά δίκτυα δεν υπάρχει ένας χρυσός κανόνας που να μπορεί κάποιος να ακολουθήσει για να πάρει τα καλύτερα αποτελέσματα. Κάθε πρόβλημα είναι διαφορετικό και χρειάζεται διαφορετική προσέγγιση. Ο μόνος τρόπος για εύρεση των κατάλληλων τιμών για την αρχιτεκτονική του δικτύου, των παραμέτρων του και τις εισόδους, χρειάζεται πειραματισμός. Σε αυτήν την εργασία πειραματιστήκαμε αρκετά, μεταβάλλοντας όλες τις παραμέτρους και τις δομές των δικτύων στην συνεχή μας προσπάθεια για καλύτερευση των αποτελεσμάτων μας.

Σύμφωνα με τα αποτελέσματα που συλλέξαμε και οι δύο προσεγγίσεις είχαν πολύ καλά αποτελέσματα στην πρόβλεψη. Η προσέγγιση με την τεχνική του κινητού παραθύρου στον χρόνο όμως αποδείχτηκε η πιο κατάλληλη για την επίλυση αυτού του προβλήματος. Χρησιμοποιώντας την τεχνική αυτή φτάσαμε την επιτυχία του δικτύου μας στην πρόβλεψη της ζήτησης του φυσικού αερίου στο 95.9041% έναντι του 85.9357% που πετύχαμε με το στατικό δίκτυο.

Με την εκπλήρωση αυτής της διπλωματικής εργασίας μπορούμε να αποδείξουμε πως τα τεχνητά νευρωνικά δίκτυα έχουν αποδειχθεί ως αποτελεσματικά εργαλεία για την επίλυση προβλημάτων πρόβλεψης, δίνοντας μας πολύ καλά αποτελέσματα.

## **5.2 Μελλοντική εργασία**

Σαν μελλοντική εργασία, όσο αφορά την μέθοδο με το κινητό παράθυρο στον χρόνο, θα μπορούσε να δοκιμαστεί ένα αρκετά πιο μεγάλο μέγεθος παραθύρου, πράγμα που θα κάνει την εκπαίδευση του δικτύου πολύ πιο αργή, και να συγκριθούν τα αποτελέσματα με το μέγεθος παραθύρου που βρέθηκε εδώ να είναι το κατάλληλο.

Όσο αφορά την μέθοδο του στατικού δικτύου, θα μπορούσαν να δοκιμαστούν εκπαιδεύσεις του δικτύου με μια πιο τυχαία κατανομή των δεδομένων σε δεδομένα εκπαίδευσης και επαλήθευσης. Επίσης θα μπορούσε να δοκιμαστεί και κάποια διαφορετική προσέγγιση στις εισόδους του δικτύου, αλλάζοντας εντελώς πλέον και την δομή του, και να συγκριθούν τα αποτελέσματα αυτά με τα αποτελέσματα που είχαμε σε αυτή την εργασία. Για παράδειγμα θα μπορούσε να κωδικοποιηθεί η τρέχουσα εποχή, όχι με την χρήση του τρέχον μήνα, αλλά με κάποια άλλη είσοδο που να μας δείχνει την εποχή. Θα μπορούσε επίσης να αφαιρεθεί εντελώς η είσοδος του μέσου όρου της ζήτησης σε άλλες χρονιές και να συγκριθούν τα αποτελέσματα. Ακόμα θα μπορούσαν να αφαιρεθούν εντελώς από τα δεδομένα εισόδου οι μέρες που είναι αργίες και να εκπαιδευτεί το δίκτυο μόνο στις καθημερινές μέρες, ώστε να μειώσουμε το λάθος που προκύπτει από την διαφορά που υπάρχει στην ζήτηση του φυσικού ανάμεσα στις καθημερινές μέρες και τις αργίες. Ανάλογα θα μπορούμε να αφαιρέσουμε τις καθημερινές μέρες και να εκπαιδεύσουμε το δίκτυο μόνο με τις αργίες. Θα μπορούσαμε



μετά να έχουμε ένα πρόγραμμα που να βλέπει αν η μέρα είναι αργία η καθημερινή και να ζητάει από το ανάλογο δίκτυο να κάνει την πρόβλεψη για την ζήτηση.

Τέλος για την επίλυση αυτού του προβλήματος θα μπορούσαν να χρησιμοποιηθούν και άλλες τεχνικές, ακόμα και δίκτυα διαφορετικών αρχιτεκτονικών, όπως νευρωνικά δίκτυα με ανατροφοδότηση (recurrent neural networks – RNNs), νευρωνικά δίκτυα καθυστέρησης χρόνου (time delay neural networks – TDNNs), και δίκτυα συναρτήσεων αξονικών βάσεων (radial basis function networks – RBFs).

## Βιβλιογραφία

- [1] Amarpal S.Babbar, “Neural Networks: For Gas Demand Forecasting”, Msc Computing Science Project Report, Department of Computer Science, Birkbeck College, University of London, 1997-1998.
- [2] Leonard J. Tashman “Out-of-sample tests of forecasting accuracy: an analysis and review”, International Journal of Forecasting, Vol. 16, p437-p450, 2000.
- [3] Monica Adya and Fred Collopy, “How effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation”, Journal of Forecasting, Vol. 17, p481 – p495, 1998.
- [4] Nguyen Hoang Viet and Jacek Mandziuk, “Neural and Fuzzy Neural Networks for natural gas consumption prediction”, IEEE XIII Workshop on Neural Networks for Signal Processing, 2003.
- [5] Petr Musilek, Emil Pelikan, Tomas Brabec and Milan Simunek, “Recurrent Neural Network Based Gating for Natural Gas Load Prediction System”, International Joint Conference on Neural Networks, July 16-21 2006.
- [6] Zhang, R.L.; Walton, D.J.; Hoskins, W.D. “Prediction of Natural Gas Consumption”, Electrical and Computer Engineering, Volume , Issue , 14-17 Sep 1993 Page(s):1156 - 1160 vol.2, 1993.
- [7] Διαλέξεις μαθήματος ΕΠΛ442 «Πληροφοριακά συστήματα μάθησης», Δρ. Χρίστος Χριστοδούλου, Πανεπιστήμιο Κύπρου.