



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΚΑΙ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ
ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΜΕΘΟΔΟΥ ΠΡΟΒΛΕΨΗΣ Θ
ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

ΤΣΙΑΦΑ Δ. ΕΙΡΗΝΗ

Επιβλέπων: Βασίλειος Ασημακόπουλος
Καθηγητής, Ε.Μ.Π.

Υπεύθυνος: Κωνσταντίνος Νικολόπουλος
Επίκουρος Καθηγητής, Manchester Business School

Αθήνα, Οκτώβριος 2008

ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΚΑΙ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ
ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΜΕΘΟΔΟΥ ΠΡΟΒΛΕΨΗΣ Θ ΜΕ
ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

ΤΣΙΑΦΑ Δ. ΕΙΡΗΝΗ

Επιβλέπων: Βασίλειος Ασημακόπουλος
Καθηγητής, Ε.Μ.Π.

Υπεύθυνος: Κωνσταντίνος Νικολόπουλος
Επίκουρος Καθηγητής, Manchester Business School

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 15/10/2008.

.....
Βασίλειος Ασημακόπουλος
Καθηγητής Ε.Μ.Π.

.....
Ιωάννης Ψαρράς
Καθηγητής Ε.Μ.Π.

.....
Δημήτριος Ασκούνης
Επίκουρος Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2008

.....
ΤΣΙΑΦΑ Δ. ΕΙΡΗΝΗ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών
Ε.Μ.Π.

Copyright © Τσιάφα Δ. Ειρήνη , Οκτώβριος 2008.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ' ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τους συγγραφείς.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τους συγγραφείς και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

ΠΡΟΛΟΓΟΣ

Η διπλωματική αυτή εργασία εκπονήθηκε στα πλαίσια των ερευνητικών δραστηριοτήτων της **Μονάδας Συστημάτων Πρόβλεψης και Προοπτικής** κατά το ακαδημαϊκό έτος 2007-2008. Η μονάδα υπάγεται στον Τομέα Ηλεκτρικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων, της Σχολής Ηλεκτρολόγων Μηχανικών & Μηχανικών Η/Υ, του Εθνικού Μετσόβιου Πολυτεχνείου.

Θα ήθελα να ευχαριστήσω τον καθηγητή κ. Βασίλειο Ασημακόπουλο για την ευκαιρία που μου έδωσε, να ασχοληθώ σε βάθος με το αντικείμενο των προβλέψεων και την συμπαράστασή του σε κάθε δυσκολία που προέκυψε, καθώς και τον Καθηγητή κ. Ιωάννη Ψαρρά και τον Επ. Καθηγητή κ. Δημήτριο Ασκούνη για την τιμή που μου έκαναν να συμμετάσχουν στην επιτροπή εξέτασης της εργασίας.

Θα ήθελα ιδιαιτέρως να ευχαριστήσω τον Επ. Καθηγητή κ. Κωνσταντίνο Νικολόπουλο και το συνεργάτη στη μονάδα, κ. Νικόλαο Μπουγιούκο, για την πολύτιμη βοήθειά τους σε κάθε φάση της εκπόνησης αυτού του έργου καθώς και για την καθοδήγησή τους και τις συμβουλές τους, που οδήγησαν στην ολοκλήρωση της εργασίας.

Τέλος, ευχαριστώ θερμά την καλή φίλη Ε.Μαυροδοπούλου για το ενδιαφέρον και τη βοήθειά της καθώς και τα υπόλοιπα μέλη του εργαστηρίου και κυρίως τον υπ.Διδάκτορα Φ.Πετρόπουλο, τον Α.Ράπτη και την Κ.Ζομπανάκη για την βοήθεια και την υποστήριξή τους.

ΠΕΡΙΛΗΨΗ

Οι διάφορες μέθοδοι πρόβλεψης επιλέγονται και εφαρμόζονται ανάλογα με συγκεκριμένες παραμέτρους όπως το αντικείμενο της πρόβλεψης, τον χρονικό ορίζοντα της πρόβλεψης, τα ήδη υπάρχοντα δεδομένα καθώς και το κόστος για την παραγωγή των προβλέψεων. Στην πραγματικότητα όμως, η αληθινή αξία μιας μεθόδου αποτιμάται όταν εφαρμόζεται σε πραγματικές καταστάσεις. Μια μέθοδος πρόβλεψης χρονοσειρών λοιπόν, οφείλει να έχει στατιστική πληρότητα και συγχρόνως να παρέχει ικανοποιητικά πρακτικά αποτελέσματα.

Την ανάγκη της μέτρησης της απόδοσης των διάφορων μεθόδων πρόβλεψης έρχονται να καλύψουν διαγωνισμοί πρόβλεψης στους οποίους μετράται η αποτελεσματικότητα των μεθόδων που συμμετέχουν μέσα από την εφαρμογή τους σε ένα εκτενές σύνολο χρονοσειρών διαφορετικού μεγέθους και περιεχομένου.

Στον μεγαλύτερο διαγωνισμό προβλέψεων που έχει διοργανωθεί ως τώρα τον Μ3 (1999) παρουσιάστηκε από τους Β.Ασημακόπουλο και Κ.Νικολοπόπουλο μια νέα μέθοδος, η μέθοδος Θ. Η μέθοδος Θ αποτελεί μια διαφορετική προσέγγιση της αποσύνθεσης. Πρέπει να σημειωθεί ότι η μέθοδος Θ πρώτευσε ανάμεσα στις 24 μεθόδους που διαγωνίστηκαν στον Μ3. Από τότε έχουν γίνει αρκετές μελέτες πάνω στην μέθοδο Θ και έχουν αναζητηθεί τρόποι βελτιστοποίησης της. Με αφορμή τον διαγωνισμό προβλέψεων NN3 (2007) που ως στόχο είχε να αξιολογηθούν μέθοδοι που χρησιμοποιούν Νευρωνικά δίκτυα ή άλλες μεθόδους τεχνητής νοημοσύνης στην πρόβλεψη χρονοσειρών, έγινε προσπάθεια βελτιστοποίησης της μεθόδου Θ με την χρήση Νευρωνικών Δικτύων.

Αυτή η προσπάθεια οδήγησε στην μέθοδο Theta AI η οποία τροποποιεί την μέθοδο Θ ώστε αυτή να επιλέγει τα βάρη της συνεισφοράς των γραμμών Θ με την χρήση ενός νευρωνικού δικτύου. Η μέθοδος Theta AI έδωσε ικανοποιητικά αποτελέσματα αφού διακρίθηκε μεταξύ των άλλων μεθόδων(30) και μάλιστα στο ένα από τα δύο σύνολα των χρονοσειρών του διαγωνισμού έδωσε τις καλύτερες προβλέψεις. Τα αποτελέσματα της παρούσας εργασίας όσον αφορά την μέθοδο Theta AI και τις βελτιώσεις της παρουσιάστηκαν στο 28th International Symposium on Forecasting (ISF) που πραγματοποιήθηκε τον Ιούνιο του 2008 στην Νίκαια της Γαλλίας.

Λέξεις Κλειδιά:

Πρόβλεψη Χρονοσειρών, Μέθοδος Θ, Νευρωνικά Δίκτυα, Τεχνητή Νοημοσύνη, Διαγωνισμοί Προβλέψεων.

ABSTRACT

The various forecasting methods are selected and applied depending on specific parameters as the object of forecasting, the time horizon of forecasting, the already existing data as well as the cost on the production of forecasts. However, the actual value of a forecasting method is measured when it is applied in real situations. Therefore, it is very important for a timeseries forecasting method to have statistical plenitude and to provide satisfactory practical results.

The forecasting competitions were originated in order to measure and compare the attribution of various forecasting methods. The effectiveness of methods, which participate through their application in an extensive amount of timeseries with different size and contents, is evaluated.

In the biggest forecasting competition that has been organized until now M3 (1999), a new method was presented by V.Assimakopoulos and K.Nikolopoulos, Theta method. The Theta method constitutes a different approach of decomposition. It must be emphasized that the Theta method was first between the 24 methods that participated in the M3. After that, a lot of study has been conducted in Theta method and ways for optimization. In the NN3 (2007) forecasting competition, whose objective was to evaluate methods that use Neural Networks or other methods of artificial intelligence in timeseries forecasting, there was a perspective of optimization of Theta method with the use of artificial neural networks.

This effort led to the Theta AI method which modifies Theta method in order to select the weights of the Theta lines with the use of neural networks. Theta AI method gave satisfactory results and produced the most accurate forecasts in the reduced dataset. The results of the present work with regard to the method Theta AI and some improvements were presented in the 28th International Symposium on Forecasting (ISF) that was held in June 2008 in Nice, France.

Keywords:

Time Series Forecasting, Theta Model, Neural Networks, Artificial Intelligence, Forecasting Competitions

ΠΕΡΙΕΧΟΜΕΝΑ

1 ΓΕΝΙΚΑ ΠΕΡΙ ΠΡΟΒΛΕΨΕΩΝ.....	19
1.1 ΠΡΟΒΛΕΨΗ.....	21
1.2 ΤΙ ΜΠΟΡΕΙ ΝΑ ΠΡΟΒΛΕΨΕΙ ΚΑΝΕΙΣ ΚΑΙ ΤΙ ΟΧΙ.....	23
2 ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΕΩΝ	25
2.1 ΚΑΤΗΓΟΡΙΕΣ ΤΕΧΝΙΚΩΝ ΠΡΟΒΛΕΨΕΩΝ	27
2.1.1 Ποσοτικές μέθοδοι.....	27
2.1.1.1 Μέθοδοι Χρονοσειρών.....	28
2.1.1.1.1 Μέθοδοι Αποσύνθεσης.....	29
2.1.1.1.2 Μέθοδοι εξομάλυνσης.....	32
2.1.1.1.3 Αυτοπαλινδρομικές Μέθοδοι Κινητού Μέσου Όρου (ARIMA).....	42
2.1.1.2 Αιτιοκρατικές Μέθοδοι.....	43
2.1.1.2.1 Μέθοδοι Παλινδρόμησης.....	44
2.1.1.2.2 Οικονομετρικές μέθοδοι.....	46
2.1.2 Κριτικές Μέθοδοι.....	47
2.1.3 Τεχνολογικές μέθοδοι.....	48
2.2 ΜΕΘΟΔΟΣ ΝΑΙΒΕ.....	50
2.3 ΠΟΙΟΤΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΧΡΟΝΟΣΕΙΡΩΝ	50
2.4 ΒΑΣΙΚΑ ΒΗΜΑΤΑ ΣΕ ΜΙΑ ΔΙΑΔΙΚΑΣΙΑ ΠΡΟΒΛΕΨΗΣ.....	53
2.4.1 Παράγοντες στην επιλογή της καλύτερης μεθόδου πρόβλεψης.....	55
2.5 ΣΥΝΔΥΑΖΟΝΤΑΣ ΠΡΟΒΛΕΨΕΙΣ.....	56
2.6 ΣΤΑΤΙΣΤΙΚΟΙ ΔΕΙΚΤΕΣ	58
2.7 ΔΕΙΚΤΕΣ ΣΦΑΛΜΑΤΩΝ.....	59
3 Η ΜΕΘΟΔΟΣ Θ.....	61
3.1 ΓΕΝΙΚΑ.....	65
3.2 ΤΟ ΜΟΝΤΕΛΟ Θ	67
3.3 ΓΕΝΙΚΗ ΔΙΑΤΥΠΩΣΗ.....	69
3.4 ΒΗΜΑΤΑ ΔΙΑΔΙΚΑΣΙΑΣ ΠΑΡΑΓΩΓΗΣ ΠΡΟΒΛΕΨΕΩΝ ΜΕ ΤΗ ΜΕΘΟΔΟ Θ	70
3.5 ΑΞΙΟΛΟΓΗΣΗ ΜΕΘΟΔΟΥ Θ	71
3.6 ΕΝΑΣ ΕΝΑΛΛΑΚΤΙΚΟΣ ΤΡΟΠΟΣ ΠΑΡΑΓΩΓΗΣ ΤΗΣ ΓΡΑΜΜΗΣ $L(\Theta=2)$	72
3.7 ΣΗΜΕΙΑΚΕΣ ΠΡΟΒΛΕΨΕΙΣ	73
3.8 ΣΤΟΧΑΣΤΙΚΟ ΜΟΝΤΕΛΟ	75
4 ΔΙΑΓΩΝΙΣΜΟΙ ΠΡΟΒΛΕΨΕΩΝ.....	79
4.1 ΕΙΣΑΓΩΓΗ.....	81
4.2 ΓΕΝΙΚΕΣ ΠΑΡΑΤΗΡΗΣΕΙΣ ΓΙΑ ΤΟΥΣ ΔΙΑΓΩΝΙΣΜΟΥΣ	81
4.2.1 Επίδραση του τύπου των χρονοσειρών.....	81
4.2.2 Επίδραση του ορίζοντα πρόβλεψης.....	82
4.2.3 Επίδραση της εποχιακότητας.....	83
4.2.4 Επίδραση του συνδυασμού των προβλέψεων	83
4.3 Η ΙΣΤΟΡΙΑ ΤΩΝ ΜΕΛΕΤΩΝ ΑΚΡΙΒΕΙΑΣ ΚΑΙ ΔΙΑΓΩΝΙΣΜΩΝ ΠΡΟΒΛΕΨΗΣ ...	84
4.4 ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΤΩΝ ΔΙΑΓΩΝΙΣΜΩΝ-Μ	88
4.4.1 εμπειρικό τεστ	88
4.4.2 Πολλαπλή υπόθεση.....	88

4.4.3 Μεγάλα δείγματα.....	89
4.4.4 Ανεξάρτητη αποτίμηση σε μια κοινή βάση δεδομένων	89
4.4.5 Πλήρη αποκάλυψη των δεδομένων & των αποτελεσμάτων.....	89
4.5 Ο ΔΙΑΓΩΝΙΣΜΟΣ-M3	90
4.5.1 Αποτελέσματα διαγωνισμού M3	93
4.6 Ο ΔΙΑΓΩΝΙΣΜΟΣ NN3.....	98
4.6.1 Μέθοδοι	98
4.6.2 Κίνητρα.....	99
4.6.3 Δεδομένα NN3	101
4.6.4 Αποτελέσματα NN3	101
5 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	105
5.1 ΕΙΣΑΓΩΓΗ.....	107
5.2 ΕΜΠΝΕΥΣΗ ΑΠΟ ΤΗ ΒΙΟΛΟΓΙΑ	108
5.3 ΙΣΤΟΡΙΑ	110
5.4 ΙΔΙΑΙΤΕΡΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	111
5.4.1 Πλεονεκτήματα-Μειονεκτήματα νευρωνικών δικτύων.....	114
5.5 ΔΟΜΗ & ΛΕΙΤΟΥΡΓΙΑ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ	114
5.6 ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΠΡΟΒΛΕΨΕΙΣ	121
5.8 ΣΧΕΤΙΚΗ ΕΠΙΔΟΣΗ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΠΡΟΒΛΕΨΕΙΣ	124
5.8 ΒΗΜΑΤΑ ΣΧΕΔΙΑΣΗΣ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ	127
5.8.1 ΒΗΜΑ 1: Επιλογή μεταβλητών	127
5.8.2 ΒΗΜΑ 2: Συλλογή δεδομένων	128
5.8.3 ΒΗΜΑ 3: Προεπεξεργασία δεδομένων	129
5.8.4 ΒΗΜΑ 4: Σύνολα εκπαίδευσης, δοκιμής και αξιολόγησης (training, test, validation sets).....	131
5.8.5 ΒΗΜΑ 5: Παραδείγματα νευρωνικών δικτύων	132
5.8.5.1 Αριθμός κρυμμένων επιπέδων.....	133
5.8.5.2 Αριθμός κρυμμένων νευρώνων	134
5.8.5.3 Αριθμός νευρώνων εξόδου.....	136
5.8.5.4 Συναρτήσεις μεταφοράς	136
5.8.6 ΒΗΜΑ 6: Κριτήρια αξιολόγησης.....	137
5.8.7 ΒΗΜΑ 7: Τελική προσομοίωση νευρωνικών δικτύων	138
5.8.7.1 Αριθμός επαναλήψεων	138
5.8.7.2 Ρυθμός εκμάθησης και ταχύτητα.....	141
5.8.8 ΒΗΜΑ 8: Υλοποίηση.....	142
6 ΘΗΤΑ ΑΙ	145
6.1 ΠΕΡΙΓΡΑΦΗ ΤΗΣ ΔΙΑΔΙΚΑΣΙΑΣ ΘΗΤΑ ΑΙ	148
6.2. ΕΦΑΡΜΟΓΗ ΤΗΣ ΜΕΘΟΔΟΥ ΣΤΟΝ ΔΙΑΓΩΝΙΣΜΟ NN3.....	150
6.3 ΑΠΟΤΕΛΕΣΜΑΤΑ ΤΗΣ ΘΗΤΑ ΑΙ ΣΤΟΝ ΔΙΑΓΩΝΙΣΜΟ NN3.....	150
6.5 ΕΡΓΑΛΕΙΑ ΠΟΥ ΧΡΗΣΙΜΟΠΟΙΗΘΗΚΑΝ.....	151
6.5.1 Πυθία.....	151
6.5.1 Alyuda Forecaster XL.....	152
6.5.2 Alyuda Forecaster	154
12 ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΜΕΘΟΔΟΥ ΠΡΟΒΛΕΨΗΣ Θ ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	

6.5.3 <i>Alyuda NeuroFusion</i>	156
6.5.4 <i>Alyuda NeuroIntelligence</i>	156
7 ΕΠΙΛΟΓΟΣ	163
7.1 ΣΥΜΠΕΡΑΣΜΑΤΑ.....	165
7.2 ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ.....	165
8 ΒΙΒΛΙΟΓΡΑΦΙΑ	167

ΕΥΡΕΤΗΡΙΟ ΠΙΝΑΚΩΝ

Πίνακας 4.1	Χρονοσειρές Διαγωνισμού Μ3 ανά κατηγορίες.....	91
Πίνακας 4.2	Οι 24 μέθοδοι που συμμετείχαν στον Διαγωνισμό Μ3 χωρισμένες σε 6 κατηγορίες.....	92
Πίνακας 4.3	Σύγκριση της επίδοσης των διάφορων μεθόδων πρόβλεψης με την Naive2.....	93
Πίνακας 4.4	Average Symmetric MAPE για όλα τα δεδομένα.....	95
Πίνακας 4.5	Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα, για όλα τα δεδομένα.....	95
Πίνακας 4.6	Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το symmetric MAPE.....	96
Πίνακας 4.7	Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το median APE.....	96
Πίνακας 4.8	Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το median RAE.....	97
Πίνακας 4.9	Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση τα εποχιακά/μη εποχιακά δεδομένα.....	97
Πίνακας 4.10	Αποτελέσματα NN3 στο σύνολο των δεδομένων (A:111 χρονοσειρές).....	103
Πίνακας 4.11	Αποτελέσματα NN3 στο υποσύνολο των δεδομένων (B:11 χρονοσειρές).....	104
Πίνακας 5.1	Γενική δομή ενός Νευρωνικού Δικτύου.....	108
Πίνακας 5.2	Τα κυριότερα βήματα στην εξέλιξη των Νευρωνικών Δικτύων.....	111
Πίνακας 5.3	Πλεονεκτήματα-Μειονεκτήματα Νευρωνικών Δικτύων.....	114
Πίνακας 5.4	Αναγκαίες παράμετροι για τον σχεδιασμό ενός BP Νευρωνικού Δικτύου.....	121

Πίνακας 5.5 Μελέτες σύγκρισης των Νευρωνικών Δικτύων με τις παραδοσιακές στατιστικές μεθόδους.....	125-126
Πίνακας 5.6 Βήματα σχεδίασης ενός Νευρωνικού Δικτύου.....	127
Πίνακας 6.1 Αποτελέσματα με τη χρήση του Forecaster XL.....	147
Πίνακας 6.2 Αποτελέσματα για το πλήρες σύνολο των 111 χρονοσειρών του διαγωνισμού.....	150
Πίνακας 6.3 Αποτελέσματα για το υποσύνολο των 11 χρονοσειρών.....	150
Πίνακας 6.4 Αποτελέσματα με τη χρήση SES για την πρόβλεψη στην $L(\theta=2)$	151

ΕΥΡΕΤΗΡΙΟ ΣΧΗΜΑΤΩΝ

Σχήμα 2.1	Κατηγορίες τεχνικών προβλέψεων.....	27
Σχήμα 2.2	Μοντέλο χρονοσειρών.....	28
Σχήμα 2.3	Τύποι μοντέλων εξομάλυνσης.....	33
Σχήμα 2.4	Αιτιοκρατικό μοντέλο.....	43
Σχήμα 2.5	Τυχαία χρονοσειρά.....	51
Σχήμα 2.6	Ποιοτικά χαρακτηριστικά χρονοσειράς.....	51
Σχήμα 3.1	Χρονοσειρά 200 από το Διαγωνισμό M3-εξομάλυνση.....	67
Σχήμα 3.2	Χρονοσειρά 200 από τον Διαγωνισμό M3-διεύρυνση.....	68
Σχήμα 3.3	Οι δύο γραμμές $L(\theta=0)$ και $L(\theta=2)$ και η τελική πρόβλεψη του μοντέλου.....	70
Σχήμα 5.1	Μετάβαση από τα βιολογικά ΝΔ στα τεχνητά ΝΔ.....	109
Σχήμα 5.2	MLP με δύο κρυμμένα επίπεδα.....	116
Σχήμα 5.3	Νευρωνικό Δίκτυο Backpropagation (BP).....	120
Σχήμα 5.4	Λογαριθμικός μετασχηματισμός σε μηνιαία δεδομένα.....	130
Σχήμα 5.5	Πιθανά σφάλματα training set και test set.....	139
Σχήμα 6.1	Αρχιτεκτονική ΝΔ κατάλληλο για πρόβλεψη χρονοσειρών.....	147
Σχήμα 6.2	Πυθία.....	152
Σχήμα 6.3	Alyuda Forecaster XL (1).....	153
Σχήμα 6.4	Alyuda Forecaster XL (2).....	153
Σχήμα 6.5	Alyuda Forecaster (1).....	154
Σχήμα 6.6	Alyuda Forecaster (2).....	155
Σχήμα 6.7	Alyuda Forecaster (3).....	155
Σχήμα 6.8	Analyze-Partition-Preprocess (1).....	157
Σχήμα 6.9	Analyze-Partition-Preprocess (2).....	157
Σχήμα 6.10	Design Architecture-Search Architecture-Train (1).....	158

Σχήμα 6.11 Design Architecture-Search Architecture-Train (2).....	158
Σχήμα 6.12 Design Architecture-Search Architecture-Train (3).....	159
Σχήμα 6.13 Design Architecture-Search Architecture-Train (4).....	159
Σχήμα 6.14 Test.....	160
Σχήμα 6.15 Query.....	161

1|| ΓΕΝΙΚΑ ΠΕΡΙ ΠΡΟΒΛΕΨΕΩΝ

1.1 ΠΡΟΒΛΕΨΗ

«Πρόβλεψη», μια λέξη που ακούγεται όλο και πιο συχνά στη σημερινή εποχή. Κατά ορισμό, πρόβλεψη είναι η διαδικασία της εκτίμησης ενός μεγέθους σε άγνωστες καταστάσεις. Όλοι οι άνθρωποι από διαφορετική σκοπιά και για διαφορετικούς λόγους ο καθένας αναζητούν μια πρόβλεψη. Μια εκτίμηση που θα τους βοηθήσει να λάβουν μια απόφαση με μικρότερο ρίσκο. Μικρότερο ρίσκο στην δουλειά τους, σε μία επικείμενη αγορά, στον προγραμματισμό των διακοπών τους, στην επιχείρησή τους, στη ζωή τους.

Οι ραγδαίες αλλαγές σε όλους τους τομείς της καθημερινής ζωής και η αβεβαιότητα για την εξέλιξη των καταστάσεων στο μέλλον που πηγάζει από αυτές έχουν κεντρίσει το ενδιαφέρον τόσο του επιστημονικού-ακαδημαϊκού κόσμου όσο και του επιχειρησιακού κόσμου. Από την πλευρά των ακαδημαϊκών έχουν δημιουργηθεί πολλές διαφορετικές μέθοδοι πρόβλεψης, κάποιες εξ ολοκλήρου βασισμένες σε θεωρητικό υπόβαθρο και κάποιες άλλες βασισμένες περισσότερο στα διαθέσιμα τεχνολογικά μέσα και στις δυνατότητες που αυτά διαθέτουν (π.χ. νευρωνικά δίκτυα). Οι διάφορες μέθοδοι επιλέγονται και εφαρμόζονται ανάλογα με συγκεκριμένες παραμέτρους όπως είναι:

- το αντικείμενο της πρόβλεψης,
- ο χρονικός ορίζοντας της πρόβλεψης,
- τα ήδη υπάρχοντα δεδομένα και το πρότυπο συμπεριφοράς αυτών,
- το κόστος για την παραγωγή των προβλέψεων,
- η ευκολία χρήσης της επιλεγμένης μεθόδου πρόβλεψης καθώς και
- η αποδεδειγμένη αξιοπιστία της μεθόδου.

Στην πραγματικότητα όμως η αληθινή αξία μιας μεθόδου αποτιμάται όταν εφαρμόζεται σε πραγματικές καταστάσεις. Έτσι η ολοκληρωμένη εικόνα για μια μέθοδο δημιουργείται μόνο όταν εφαρμοστεί η θεωρία στην πράξη. Μια συνεργασία λοιπόν ακαδημαϊκού και επιχειρησιακού κόσμου μπορεί να επιφέρει εύλογα αποτελέσματα. Και αυτό μπορεί να το καταλάβει πολύ απλά οποιοσδήποτε σκεπτόμενος πόσο καλύτερα μοντέλα πρόβλεψης μπορούν να προκύψουν αν αυτά σχεδιασθούν βάσει των ιδιαίτερων αναγκών της εκάστοτε επιχείρησης.

Από την πλευρά του επιχειρησιακού περιβάλλοντος είναι ολοφάνερη η σημαντικότητα της πρόβλεψης αφού μια επιχείρηση βρίσκεται καθημερινά στην ανάγκη για λήψη μιας απόφασης αντιμετωπίζοντας όσο το δυνατόν περισσότερο την αβεβαιότητα του μέλλοντος. Μελετώντας επιφανειακά την δομή μιας επιχείρησης μπορούμε να τονίσουμε ότι η πρόβλεψη διαδραματίζει πρωτεύοντα ρόλο σε όποια δραστηριότητα λήψης αποφάσεων, καθορισμού, σχεδιασμού και υλοποίησης στρατηγικής, χρονικού προγραμματισμού καθώς και σχεδιασμού πολιτικής λειτουργίας της επιχείρησης. Είναι σημαντικό να τονίσουμε ότι έστω και μία πολύ μικρή βελτίωση στην ακρίβεια των προβλέψεων μπορεί να αποφέρει τεράστια ποσά κέρδους σε μία επιχείρηση. Για αυτό το λόγο οι διάφορες υπηρεσίες πρόβλεψης και τα διάφορα προϊόντα για την παραγωγή προβλέψεων που γενικά κυκλοφορούν στην αγορά γνωρίζουν μεγάλη ζήτηση.

Για να μπορέσει όμως κάποιος να χρησιμοποιήσει προς όφελός του τις προβλέψεις πρέπει να μπορεί να ξεχωρίσει την πιο κερδοφόρα επιλογή. Και αυτό είναι απόρροια της πείρας. Ας θεωρήσουμε ένα διοικητικό στέλεχος μιας μεγάλης επιχείρησης. Αυτό το άτομο πρέπει να διαθέτει την κατάλληλη εμπειρία στις καταστάσεις που έχει να αντιμετωπίσει και οι αποφάσεις του να μην επηρεάζονται από προσωπικά ενδιαφέροντα, φιλοδοξίες, σκοπιμότητες και μονόπλευρη εξέταση του περιβάλλοντος και των εναλλακτικών επιλογών. Για να επιτευχθεί ο εκάστοτε στόχος πρέπει οι αποφάσεις του να είναι όσο το δυνατόν αντικειμενικές και να μην βασίζεται μόνο στα πειραματικά ή μόνο στα θεωρητικά αποτελέσματα αλλά να έχει την ικανότητα να συγκρίνει και να συνδυάζει τα αποτελέσματα των δύο.

Είναι φυσικό ότι κάποια πειραματικά αποτελέσματα που αποκλίνουν τελείως από τα αντίστοιχα θεωρητικά δεν έχουν κάποια βάση και λόγω της αβεβαιότητας που τα διακρίνει δεν είναι καθόλου αξιόπιστα. Φυσικά το ίδιο ισχύει και για τη θεωρία. Όταν η θεωρία δεν τεκμηριώνεται από πειράματα σε πραγματικά δεδομένα παραμένει στο θεωρητικό επίπεδο και δεν έχει κανένα ενδιαφέρον για μελλοντική χρήση. Κανείς δεν ενδιαφέρεται για θεωρητικά μοντέλα όταν αυτά δεν μπορούν να τεκμηριωθούν και να χρησιμοποιηθούν πρακτικά. Όλα τα παραπάνω είναι κάποιοι σημαντικοί λόγοι

οι οποίοι έχουν καταστήσει έναν σύμβουλο προβλέψεων απαραίτητο στέλεχος σε κάθε επιχείρηση.

Αν εμβαθύνουμε λίγο στον τομέα προβλέψεις και αποτελέσματα αυτών θα παρατηρήσουμε ότι υπάρχει μεγάλη δυσαρέσκεια σχετικά με τα πολύ μεγάλα σε αρκετές περιπτώσεις σφάλματα όπως και την αδυναμία των διάφορων μεθόδων να προβλέψουν και να προειδοποιήσουν έγκαιρα για επερχόμενες αλλαγές και ανωμαλίες. Αλλά θα ήταν αναγκαίες οι προβλέψεις αν όλα κυλούσαν ομαλά και χωρίς καμία αμφιβολία για το τι ακολουθεί; Φυσικά και όχι! Δεν θα υπήρχαν. Στην πραγματικότητα όμως το περιβάλλον στο οποίο ζούμε χαρακτηρίζεται από συνεχείς μεταβολές, εξελίξεις, μεγάλες διακυμάνσεις και απρόσμενες καταστάσεις, συνθήκες που αυξάνουν την ανάγκη για προβλέψεις. Ο κύριος λόγος που υπάρχει αυτή η αιωρούμενη δυσανασχέτηση και οι δυσμενείς κριτικές για τις προβλέψεις είναι ότι πολλοί πιστεύουν ότι μπορούν να προβλεφθούν τα πάντα. Αυτό όμως καταλήγει να είναι ένας μύθος. Η ύπαρξη σφαλμάτων είναι αναπόφευκτη. Για αυτό το λόγο και συνήθως υπάρχουν αποκλίσεις μεταξύ προβλέψεων και πραγματικών αποτελεσμάτων. Το μόνο που μπορεί να γίνει για να είναι πιο ωφέλιμα τα αποτελέσματα είναι να γίνεται, όσο είναι εφικτό φυσικά, ρεαλιστική εκτίμηση των παραμέτρων.

1.2 ΤΙ ΜΠΟΡΕΙ ΝΑ ΠΡΟΒΛΕΨΕΙ ΚΑΝΕΙΣ ΚΑΙ ΤΙ ΟΧΙ

Ένα ερώτημα αναμφισβήτητα ενδιαφέρον και με μεγάλες προεκτάσεις. Τελικά υπάρχουν τομείς και δεδομένα όπου παράγονται πάντα αξιόπιστες προβλέψεις; Με λίγη σκέψη καταλήγουμε ότι αυτό είναι κάτι πολύ δύσκολο να επιτευχθεί. Ας αναφέρουμε περιληπτικά κάποιους τομείς της καθημερινότητας μας οι οποίοι συνήθως αναλύονται με προβλέψεις:

- ✓ Πρόγνωση μετεωρολογικών συνθηκών
- ✓ Πρόβλεψη κλιματικών αλλαγών και φαινομένων (ψύξη/ θέρμανση πλανήτη)
- ✓ Πρόβλεψη κινδύνου πυρκαγιάς
- ✓ Προγνωστικά αγώνων ποδοσφαίρου, μπάσκετ, διεθνών διοργανώσεων, Ολυμπιακών αγώνων
- ✓ Πρόβλεψη σεισμών

- ✓ Αστρολογικές προβλέψεις
- ✓ Πρόβλεψη πορείας οικονομικών μεγεθών
- ✓ Πρόβλεψη πτώσης/ ανόδου τιμής πετρελαίου
- ✓ Πρόβλεψη συνολικής παραγωγής ενέργειας σε μία εγκατάσταση
- ✓ Πρόβλεψη θνησιμότητας πληθυσμού σε μια χώρα
- ✓ Πρόβλεψη της κυκλοφορίας στην εθνική οδό ή σε άλλες τοπικές οδούς
- ✓ Πρόβλεψη απόδοσης εργαζομένων σε μια εταιρεία/ μαθητών σε ένα σχολείο
- ✓ Πρόβλεψη ζήτησης ενός συγκεκριμένου είδους κατανάλωσης

Για παράδειγμα συμβάλλοντας στην επιτυχή πρόβλεψη των σεισμών, επιστήμονες έχουν κατασκευάσει ένα διαστημικό σταθμό όπου μελετώντας τα φορτισμένα σωματίδια στο διάστημα προσπαθούν να εκτιμήσουν το μέρος που θα γίνει ένας επικείμενος σεισμός, την ακριβή μέρα και ώρα καθώς και το μέγεθος του σεισμού. Αλλά είναι πάντα αληθείς οι προβλέψεις τους; Πόσες είναι οι περιπτώσεις όπου έχουμε ακούσει για κάποιο επικείμενο σεισμό σε μία περιοχή με μόνο αποτέλεσμα να τρομοκρατείται ο κόσμος και στο τέλος να μην συμβαίνει τίποτα;

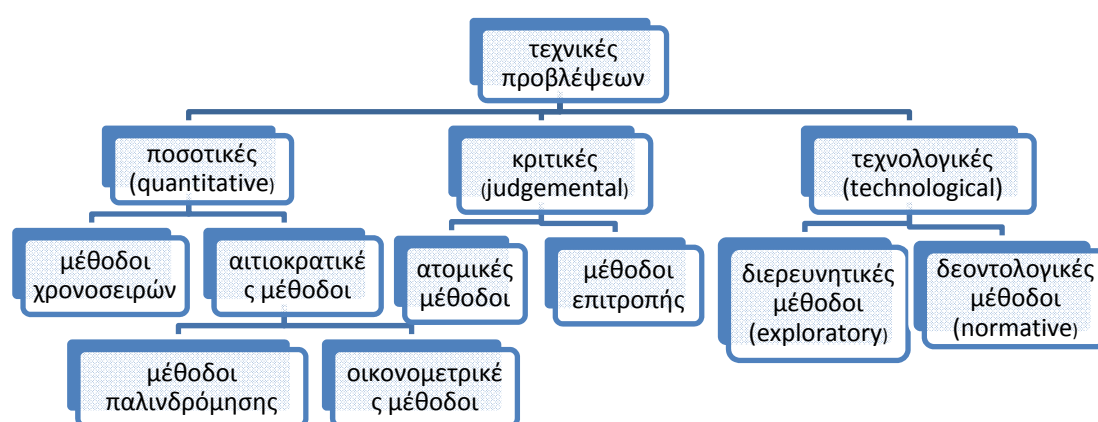
Ο κωμικός Josh Billing σε ένα θέμα σχετικό με τις προβλέψεις είχε πει: « Μην προβλέπεις. Αν η πρόβλεψή σου αποδειχθεί λάθος, κανείς δεν θα την ξεχάσει. Αν αποδειχθεί σωστή, κανείς δεν θα την θυμάται.» Μπορούμε όμως να ακολουθήσουμε αυτή τη λογική; Η αλήθεια είναι ότι οι προβλέψεις είναι αναγκαίες στη ζωή μας. Μας βοηθούν να είμαστε κατάλληλα προετοιμασμένοι για κάποια επικείμενα γεγονότα και να παίρνουμε σωστότερες αποφάσεις, έστω και αν πάντα υπήρχαν και θα υπάρχουν οι μεγάλες αποκλίσεις που θα ανατρέπουν όλη την προετοιμασία μας.

Τελικά όμως μπορούμε να προβλέψουμε, μέχρι ένα βαθμό τουλάχιστον, τα πάντα; Ποιος μπορεί να προβλέψει αν θα είναι ευτυχισμένος στη ζωή του; Ποιος μπορεί να προβλέψει πότε ακριβώς θα πεθάνει; Κανείς! Μπορεί να προβλεφθεί ένα σοβαρό αυτοκινητιστικό δυστύχημα ή μία σύγκρουση αεροπλάνου; Ποιος μπορεί να ξέρει πόσα θύματα θα έχει ένα τέτοια ατύχημα; Η απάντηση είναι η ίδια. Βλέπουμε λοιπόν ότι υπάρχουν πολλά σημαντικά θέματα στη ζωή ενός ανθρώπου στα οποία δεν μπορεί να κάνει κανείς εκτίμηση.

2|| ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΕΩΝ

2.1 ΚΑΤΗΓΟΡΙΕΣ ΤΕΧΝΙΚΩΝ ΠΡΟΒΛΕΨΕΩΝ

Μια πρόβλεψη μπορεί να αναφέρεται στην εκτίμηση χρονοσειρών, δεδομένα από αντιπροσωπευτικό δείγμα ή μακροχρόνια δεδομένα. Οι τεχνικές προβλέψεων που έχουν αναπτυχθεί μέχρι σήμερα εντάσσονται σε τρεις εκτενείς κατηγορίες οι οποίες φαίνονται σχηματικά παρακάτω:



Σχήμα 2.1 Κατηγορίες τεχνικών προβλέψεων

2.1.1 Ποσοτικές μέθοδοι

Οι ποσοτικές μέθοδοι εφαρμόζονται όταν υπάρχει διαθέσιμη πληροφορία για το παρελθόν και θεωρείται ότι το πρότυπο συμπεριφοράς θα διατηρηθεί αμετάβλητο και στο μέλλον. Απαιτείται δε η ποσοτικοποίηση της πληροφορίας. Τα μοντέλα που αφορούν τις ποσοτικές μεθόδους πρόβλεψης διακρίνονται σε δύο: το **μοντέλο χρονοσειρών** (time series model) και το **αιτιοκρατικό ή επεξηγηματικό μοντέλο** (causal relationship or explanatory model). Μελετώντας τις ιδιότητες και τα χαρακτηριστικά των μοντέλων αυτών γίνεται ευκολότερη η κατανόηση των βασικών υποθέσεων πάνω στις οποίες στηρίζεται κάθε ποσοτική μέθοδος, ενώ ταυτόχρονα

εντοπίζονται τα πλεονεκτήματα και τα μειονεκτήματα της εφαρμογής της σε συγκεκριμένες καταστάσεις.

2.1.1.1 Μέθοδοι Χρονοσειρών

Οι μέθοδοι χρονοσειρών αποτελούν μαθηματικά μοντέλα βασισμένα στη στατιστική. Στόχος είναι η ανίχνευση κάποιου προτύπου συμπεριφοράς των ιστορικών δεδομένων και η επέκτασή του στο μέλλον. Η εφαρμογή του μοντέλου είναι δυνατή μόνο όταν υπάρχουν ιστορικά δεδομένα του υπό εξέταση μεγέθους σε προηγούμενες και σταθερές χρονικές περιόδους (π.χ. ημέρες, μήνες, έτη κ.λπ.). Βασίζεται στην υπόθεση ότι η μεταβολή της τιμής του μεγέθους ακολουθεί ένα συγκεκριμένο πρότυπο που επαναλαμβάνεται στο χρόνο και παραμένει σταθερό. Έτσι με την αναγνώριση αυτού του προτύπου και την προέκτασή του στο μέλλον προκύπτουν οι προβλέψεις. Κατά συνέπεια, η προέκταση αυτή οδηγεί σε προβλέψεις που βασίζονται στην ιστορία της χρονοσειράς και θεωρούνται ικανοποιητικές στο βαθμό που η εξέλιξή της γίνει υπό το καθεστώς των σημερινών συνθηκών. Αυτό σε μερικές περιπτώσεις όπου εμφανίζονται μη αναμενόμενα γεγονότα οδηγεί σε λανθασμένες προβλέψεις και έτσι το μοντέλο χαρακτηρίζεται ως ανεπαρκές. Ας σημειώσουμε ότι οι χρονοσειρές στα μοντέλα αυτά θεωρείται ότι αντιπροσωπεύουν στοχαστικές διαδικασίες.

Σχηματικά η μορφή του μοντέλου φαίνεται παρακάτω:



Σχήμα 2.2 Μοντέλο χρονοσειρών

Είσοδος του συστήματος είναι τα προηγούμενα ιστορικά δεδομένα X_i , όπου ο δείκτης i αναφέρεται στην χρονική περίοδο. Το i παίρνει τιμές από το 1 μέχρι το t . Έξοδος του συστήματος είναι η πρόβλεψη που πραγματοποιείται την χρονική περίοδο t για την επόμενη χρονική περίοδο $t+1$, και συμβολίζεται με $y = \hat{X}_t$.

Η σχέση που περιγράφει το σύστημα είναι γραμμική και έχει την μορφή:

$$y = f(X_1, X_2, \dots, X_{t-1})$$

Στην πραγματικότητα το μοντέλο των χρονοσειρών θεωρείται σαν «μαύρο κουτί» αφού μη έχοντας την δυνατότητα να συσχετίσει το υπό πρόβλεψη μέγεθος με τους παράγοντες που επηρεάζουν την τιμή του, παρέχει πληροφορίες για το τι πρόκειται να συμβεί χωρίς ταυτόχρονα να μας επιτρέπει να κατανοήσουμε το γιατί θα συμβεί.

Όταν μιλάμε για πρόβλεψη μιλάμε συνήθως για μοντέλα χρονοσειρών. Οι βασικοί λόγοι που δικαιολογούν την τόσο μεγάλη απήχηση των μοντέλων είναι οι εξής:

- ✓ Δεν υπάρχει πάντα η δυνατότητα να συσχετίσουμε ένα μεταβαλλόμενο μέγεθος με κάποιους παράγοντες και πολύ περισσότερο να προσδιορίσουμε τον τρόπο αλληλεπίδρασής τους.
- ✓ Σε πολλές περιπτώσεις ενδιαφερόμαστε να προσδιορίσουμε μόνο το τι θα συμβεί και όχι το γιατί.
- ✓ Το κόστος που απαιτείται στην πρώτη περίπτωση είναι πολύ μικρότερο από εκείνο που απαιτείται στη δεύτερη.

Οι μέθοδοι που περιγράφονται με το μοντέλο των χρονοσειρών είναι η αποσύνθεση (decomposition), η εξομάλυνση (smoothing) και οι αυτοπαλινδρομικές μέθοδοι κινητού μέσου όρου (Autoregressive/Integrated/ Moving Average-ARIMA). Οι διαφορές μεταξύ αυτών των μεθόδων εντοπίζονται στη μορφή του συναρτησιακού τύπου που περιγράφει το σύστημα.

2.1.1.1.1 Μέθοδοι Αποσύνθεσης

Οι μέθοδοι αποσύνθεσης εφαρμόζουν απλές μαθηματικές σχέσεις με σκοπό την απομόνωση των τεσσάρων βασικών συνιστωσών των χρονοσειρών: εποχιακότητα, κύκλος, τάση και τυχαιότητα. Το χαρακτηριστικό που αντιπροσωπεύει την γενική εικόνα της χρονοσειράς είναι η τάση, η οποία μπορεί να είναι ανοδική, πτωτική ή μηδενική. Ο κύκλος αντιπροσωπεύει τις ανόδους και τις πτώσεις λόγω ειδικών οικονομικών συνθηκών και συχνά ακολουθεί μια κυματοειδή γραμμή που

κινείται μεταξύ της υψηλότερης και της χαμηλότερης τιμής. Η εποχιακότητα αντιπροσωπεύει τις περιοδικές διακυμάνσεις που έχουν σταθερό μήκος. Η διαφορά της εποχιακότητας από την κυκλικότητα είναι ότι ενώ η εποχιακότητα επαναλαμβάνεται σε σταθερά διαστήματα όπως ο χρόνος, ο μήνας, η εβδομάδα, η κυκλικότητα έχει μεγαλύτερη διάρκεια που διαφέρει από κύκλο σε κύκλο.

Κάνοντας απαλοιφή της εποχιακότητας και της τυχαιότητας καταλήγουμε στην καμπύλη τάσης-κύκλου, η οποία είναι ιδιαίτερα σημαντική για την πρόβλεψη επιχειρησιακών δεδομένων. Ο πιο σημαντικός λόγος που οι μέθοδοι αποσύνθεσης είναι ευρέως διαδεδομένες στο χώρο των επιχειρήσεων είναι ότι κάθε χρήστης-στέλεχος επιχείρησης έχει την δυνατότητα να συμβάλλει στον σχηματισμό των προβλέψεων ενσωματώνοντας την δική του γνώμη και διαίσθηση.

Η μαθηματική διατύπωση της αποσύνθεσης είναι η εξής:

$$X_t = f(S_t, T_t, C_t, R_t)$$

όπου:

X_t = παρατήρηση κατά την χρονική περίοδο t

S_t = συνιστώσα εποχιακότητας

T_t = συνιστώσα τάσης

C_t = συνιστώσα κύκλου

R_t = συνιστώσα τυχαιότητας

Οι πιο απλές συναρτησιακές μορφές είναι η πολλαπλασιαστική με αντίστοιχη διατύπωση:

$$X_t = T_t \cdot S_t \cdot C_t \cdot R_t$$

και η προσθετική με μορφή:

$$X_t = T_t + S_t + C_t + R_t$$

Παρακάτω αναφέρονται ονομαστικά τα τεχνικά χαρακτηριστικά της διαδικασίας αποσύνθεσης:

- ✓ Ασυνέχειες (Outliers)
- ✓ Αλλαγές προτύπου (Break in series)
- ✓ Κανονικοποίηση (Streamlining)
- ✓ Ημερήσια και εβδομαδιαία δεδομένα (Daily and weekly data)
- ✓ Ημερολογιακές επιδράσεις (Calendar effects)
- ✓ Μετασχηματισμοί (Transformation)
- ✓ Αναδρομικές μέθοδοι αποσύνθεσης (Concurrent adjustment in practice)

Από τη βιβλιογραφία αντλούμε τις κυριότερες μεθόδους αποσύνθεσης (F.A.G de Butter):

- Fixed Additive method, Σταθερή προσθετική Μέθοδος,
- Fixed Multiplicative Method, Σταθερή πολλαπλασιαστική μέθοδος ή Κλασσική Μέθοδος Αποσύνθεσης,
- Moving Additive Method, Κινητή προσθετική μέθοδος,
- Moving Multiplicative Method, Κινητή πολλαπλασιαστική μέθοδος,
- Zaycoff's method,
- Μέθοδος Census X-II,
- CPB Method,
- KVF Method,
- SABL Method,

με πιο δημοφιλείς την κλασσική μέθοδο αποσύνθεσης και την μέθοδο Census II. Αναλυτική περιγραφή των μεθόδων αυτών μπορεί να βρει κανείς στις σημειώσεις του μαθήματος «ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΕΩΝ» του 9^{ου} εξαμήνου της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών υπολογιστών.

2.1.1.1.2 Μέθοδοι εξομάλυνσης

Οι μέθοδοι εξομάλυνσης έχουν σχεδιαστεί με στόχο να εφαρμόζονται εύκολα και να παρέχουν ικανοποιητικές προβλέψεις στον βραχυπρόθεσμο ορίζοντα. Στις μεθόδους αυτές γίνεται χρήση των ιστορικών δεδομένων για τον προσδιορισμό μιας «εξομαλυμένης» (smoothed) τιμής για τις χρονοσειρές. Έπειτα η «εξομαλυμένη» αυτή τιμή προεκτείνεται ώστε να αποτελέσει πρόβλεψη για τη μελλοντική τιμή της χρονοσειράς.

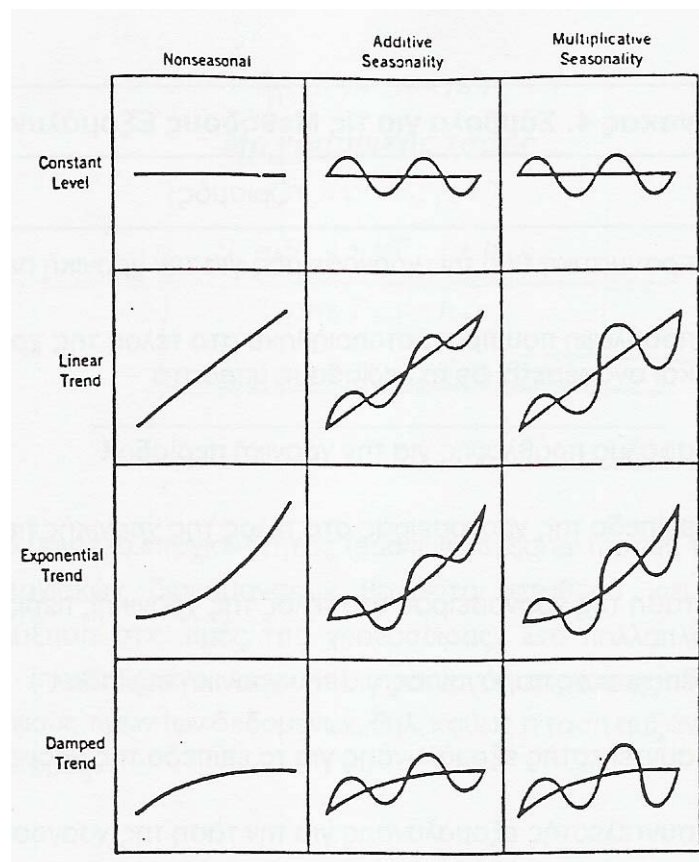
Η βασική ιδέα των μεθόδων εξομάλυνσης είναι ότι υπάρχει ένα λανθάνον πρότυπο συμπεριφοράς το οποίο ακολουθούν οι τιμές των μεταβλητών πρόβλεψης και ότι οι ιστορικές παρατηρήσεις της κάθε μεταβλητής αντιπροσωπεύουν αυτό το πρότυπο καθώς και τυχαίες διακυμάνσεις. Σκοπός αυτών των μεθόδων πρόβλεψης είναι να διακρίνουν ανάμεσα στις τυχαίες αποκλίσεις και στο βασικό πρότυπο, εξομαλύνοντας τα ιστορικά δεδομένα. Αυτό ισοδυναμεί με ελαχιστοποίηση της τυχαιότητας που υπάρχει στην ιστορική ακολουθία και έχει σαν αποτέλεσμα η πρόβλεψη να βασίζεται στο εξομαλυμένο πρότυπο συμπεριφοράς των δεδομένων.

Δύο από τις σημαντικότερες κατηγορίες μεθόδων πρόβλεψης είναι οι μέθοδοι κινητού μέσου όρου και οι μέθοδοι εκθετικής εξομάλυνσης. Η πρώτη βασίζεται στον κοινό ορισμό του μέσου όρου και χρησιμοποιεί ένα σταθερό αριθμό δεδομένων (εμπεριέχοντας πάντα τις πιο πρόσφατες παρατηρήσεις της χρονοσειράς) τα οποία συμμετέχουν στον υπολογισμό του μέσου όρου με ίσα βάρη. Συγκεκριμένα, καθώς μια νέα παρατήρηση γίνεται διαθέσιμη, ένας νέος μέσος όρος υπολογίζεται, στον οποίο παραλείπεται η πιο παλιά παρατήρηση προκειμένου να συμπεριληφθεί η πιο πρόσφατη. Ο κινητός αυτός μέσος όρος θα αποτελέσει και την πρόβλεψη για την επόμενη περίοδο. Η δεύτερη κατηγορία μεθόδων εξομάλυνσης, αντίθετα με την μέθοδο κινητού μέσου όρου, αποδίδει άνισα βάρη στα ιστορικά δεδομένα. Η βασική αρχή των μεθόδων εκθετικής εξομάλυνσης είναι ότι όσο πιο πρόσφατα είναι τα δεδομένα τόσο περισσότερη πληροφορία περιέχουν. Για τον λόγο αυτό μεγαλύτερη βαρύτητα αποδίδεται στα πρόσφατα δεδομένα η οποία και φθίνει εκθετικά καθώς αναφερόμαστε σε δεδομένα που αντιστοιχούν σε παλιότερες χρονικές περιόδους. Τα

μοντέλα που προκύπτουν από τις μεθόδους εκθετικής εξομάλυνσης κατηγοριοποιούνται ανάλογα με την γενική μορφή της γραφικής παράστασης των ιστορικών δεδομένων με οριζόντιο άξονα τον χρόνο. Έτσι 4 μοντέλα τάσης (σταθερού επιπέδου, γραμμικής τάσης, εκθετικής τάσης και φθίνουσας τάσης) συνδυάζονται με 3 εποχιακά μοντέλα (μη εποχιακό, προσθετικό εποχιακό και πολλαπλασιαστικό εποχιακό) δίνοντας 12 βασικές κατηγορίες.

Λόγω της σημαντικότητας των μεθόδων εκθετικής εξομάλυνσης και της ιδιαίτερης χρησιμότητάς τους, θα επεκταθούμε λίγο περισσότερο στην ανάλυση και κατανόηση των μοντέλων. Αρχικά αναπτύσσουμε την θεωρητική πλευρά των μοντέλων εξομάλυνσης που αναφέρθηκαν και στη συνέχεια αναλύουμε διεξοδικά το μοντέλο σταθερού επιπέδου, το μοντέλο γραμμικής τάσης (Holt) και τέλος την συλλογιστική των μοντέλων μη γραμμικής τάσης.

Στο σχήμα παριστάνονται οι δώδεκα βασικές κατηγορίες των μοντέλων εξομάλυνσης:



Σχήμα 2.3 Τύποι μοντέλων εξομάλυνσης

Τα μοντέλα σταθερού επιπέδου (constant level) αποτελούν την πιο απλή παραδοχή. Το πιο σημαντικό στοιχείο είναι ότι υποθέτουν απουσία τάσης από τα δεδομένα. Δηλαδή, οι χρονοσειρές θεωρείται ότι έχουν ένα σχετικά σταθερό μέσο όρο και η πρόβλεψη προκύπτει από την προέκταση μιας οριζόντιας ευθείας γραμμής. Τα μοντέλα σταθερού επιπέδου χρησιμοποιούνται ευρέως για προβλέψεις ενός βήματος (one-step-ahead forecasting) ή όταν οι χρονοσειρές χαρακτηρίζονται από αυξημένο θόρυβο ή τυχαιότητα. Το μοντέλο γραμμικής τάσης (linear trend) είναι το πιο δημοφιλές μοντέλο και οι προβλέψεις του προκύπτουν απλά με την προέκταση μιας ευθείας γραμμής για οποιαδήποτε χρονική περίοδο στο μέλλον. Το μοντέλο εκθετικής τάσης (exponential trend) είναι προτιμότερο σε περιπτώσεις όπου παρατηρείται συνεχόμενη αύξηση στα ιστορικά δεδομένα που χρησιμοποιούνται για την πρόβλεψη. Για παράδειγμα, στην αρχή του κύκλου ζωής ενός προϊόντος όπου παρατηρείται συνεχόμενη αύξηση του ποσοστού των πωλήσεων είναι προτιμότερη η χρήση του μοντέλου εκθετικής τάσης. Αξίζει να σημειώσουμε ότι σε διάφορες εμπειρικές μελέτες, τα μοντέλα γραμμικής και εκθετικής τάσης αποδείχθηκαν υπεραισιόδοξα και οδηγούσαν σε ιδιαίτερα υψηλές τιμές προβλέψεων καθώς επιμηκυνόταν ο χρονικός ορίζοντας. Τέλος το μοντέλο της φθίνουσας τάσης (damped trend) αποτελεί την καλύτερη παραδοχή σε περιπτώσεις μακροπρόθεσμων προβλέψεων. Σύμφωνα με το μοντέλο αυτό μειώνεται βαθμιαία το μέγεθος κατά το οποίο αυξάνονται οι τιμές της χρονοσειράς κάθε χρονική περίοδο.

❖ Το μοντέλο σταθερού επιπέδου

Το μοντέλο σταθερού επιπέδου αναφέρεται και ως απλή εκθετική εξομάλυνση και περιγράφεται από τις εξισώσεις:

$$e_t = X_t - \hat{X}_{t-1} \quad (1)$$

$$S_t = S_{t-1} + h_1 e_t$$

$$\hat{X}_t(m) = S_t$$

Η εξίσωση (1) υπολογίζει το σφάλμα πρόβλεψης e_t το οποίο ορίζεται σαν η διαφορά της πραγματικής τιμής της χρονοσειράς και της πρόβλεψης. Ο δείκτης t αντιπροσωπεύει τη χρονική περίοδο. Το S_t είναι το επίπεδο της χρονοσειράς στο τέλος της χρονικής περιόδου t και είναι ίσο με το άθροισμα του επιπέδου της προηγούμενης χρονικής περιόδου $t-1$ και κάποιου ποσοστού του σφάλματος πρόβλεψης. Το ποσοστό αυτό καθορίζεται από τον συντελεστή h_1 ο οποίος ορίζεται ως ο συντελεστής εξομάλυνσης και το πεδίο τιμών του είναι από 0 έως 1. Το $\widehat{X}_t(m)$ είναι η πρόβλεψη που πραγματοποιείται στο τέλος της χρονικής περιόδου t και αναφέρεται σε m περιόδους μπροστά. Από τη στιγμή που μελετάμε το μοντέλο σταθερού επιπέδου, η πρόβλεψη είναι ίση με το S_t για κάθε χρονική περίοδο.

Η συμπεριφορά του μοντέλου σταθερού επιπέδου πλησιάζει αρκετά αυτή του αυτόματου πιλότου ή του θερμοστάτη. Για κάθε τιμή της χρονοσειράς υπολογίζεται το σφάλμα πρόβλεψης. Αν το σφάλμα είναι θετικό τότε η πρόβλεψη για την επόμενη χρονική περίοδο αυξάνεται. Αντίθετα, αν το σφάλμα είναι αρνητικό τότε η πρόβλεψη για την επόμενη χρονική περίοδο μειώνεται. Με αυτόν τον τρόπο, τα σφάλματα χρησιμοποιούνται για να καθοδηγήσουν τις προβλέψεις προς το πραγματικό επίπεδο της χρονοσειράς.

Πρέπει να επιλέγουμε προσεκτικά την αρχική τιμή επιπέδου και την τιμή του συντελεστή εξομάλυνσης. Κι αυτό γιατί αν η πρώτη πρόβλεψη δεν είναι αντιπροσωπευτική των δεδομένων θα έχει παραποιητική δράση στις τιμές των επόμενων προβλέψεων. Επιπλέον η πρώτη πρόβλεψη επηρεάζει την επιλογή του συντελεστή εξομάλυνσης. Συνήθως λοιπόν η πρώτη πρόβλεψη τίθεται ίση με τον μέσο όρο των δεδομένων. Εξαιρούνται φυσικά συγκεκριμένες περιπτώσεις όπου βάσει των δεδομένων που έχουμε, αν χρησιμοποιήσουμε ως πρώτη πρόβλεψη των δεδομένων τότε θα χρειαστεί πολύ μεγάλος δείκτης εξομάλυνσης (περίπου ίσος με 1) για να μπορέσουν οι επόμενες προβλέψεις να προσεγγίσουν το επίπεδο των πραγματικών τιμών.

Όσον αφορά τώρα την τιμή του συντελεστή εξομάλυνσης, ελέγχονται κάποιες δοκιμαστικές τιμές. Το κριτήριο επιλογής είναι στις περισσότερες περιπτώσεις η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (MSE) αν και θα μπορούσαν να χρησιμοποιηθούν και άλλα είδη σφάλματος όπως το απόλυτο ή το ποσοστιαίο σφάλμα. Ένας αποτελεσματικός αλγόριθμος για να επιτευχθεί η βέλτιστη επιλογή του

συντελεστή εξομάλυνσης είναι ο ακόλουθος: Αρχικά υπολογίζουμε την τιμή του σφάλματος για 2 τιμές του συντελεστή εξομάλυνσης, τις τιμές $h_1 = 0.33$ και $h_1 = 0.67$ επιλέγοντας την καλύτερη από τις 2. Έπειτα υπολογίζεται το σφάλμα για το διάστημα τιμών ± 0.17 γύρω από το βέλτιστο h_1 . Και πάλι επιλέγεται το βέλτιστο h_1 . Αυτή η διαδικασία εκτελείται επαναληπτικά εξετάζοντας μικρότερα διαστήματα (± 0.08 , ± 0.04 , ± 0.02 , ± 0.015 , ± 0.0005) μέχρι το σημείο που η μεταβολή του σφάλματος γίνει μικρότερη από 1%.

Για να μπορούν οι προβλέψεις να ανταποκριθούν σε μελλοντικές αλλαγές του περιβάλλοντος της χρονοσειράς, θα πρέπει να οριστεί ένα ελάχιστο όριο στην τιμή του συντελεστή εξομάλυνσης το οποίο θα είναι από $h_1=0.1$ και πάνω. Αυτό γιατί όπως φαίνεται από το μοντέλο εξισώσεων της απλής εκθετικής εξομάλυνσης, αν ο συντελεστής εξομάλυνσης λάβει την τιμή 0, τότε η αρχική πρόβλεψη θα μείνει σταθερή για όλες τις χρονικές περιόδους,

Ο βέλτιστος συντελεστής εξομάλυνσης καθορίζεται από την αλληλεξάρτηση 2 παραγόντων. Ο πρώτος παράγοντας είναι το ποσοστό θορύβου στη χρονοσειρά. Όσο περισσότερος θόρυβος υπάρχει στα δεδομένα της χρονοσειράς, τόσο μικρότερη πρέπει να είναι η τιμή του συντελεστή εξομάλυνσης για να αποφύγουμε την υπερβολική αντίδραση στον θόρυβο. Ο δεύτερος παράγοντας είναι η σταθερότητα του μέσου όρου της χρονοσειράς. Αν ο μέσος όρος μεταβάλλεται, ο συντελεστής εξομάλυνσης θα πρέπει να είναι μεγάλος ώστε οι προβλέψεις να παρακολουθούν τις μεταβολές που παρουσιάζουν τα δεδομένα. Αντίθετα, αν ο μέσος όρος είναι σχετικά σταθερός, η τιμή του συντελεστή εξομάλυνσης θα είναι μικρή. Η μέγιστη τιμή που λαμβάνει ο συντελεστής εξομάλυνσης είναι $h_1=1.0$, το οποίο σημαίνει ότι η πρόβλεψη είναι ίση με την τελευταία τιμή της χρονοσειράς.

Γενικά πάντως η τιμή του συντελεστή εξομάλυνσης επηρεάζει και τα βάρη που αποδίδονται στα δεδομένα της χρονοσειράς ανάλογα με τη χρονική τους θέση. Κάθε τιμή της χρονοσειράς έχει ένα βάρος η τιμή του οποίου δεν παραμένει σταθερή. Τα βάρη ελαττώνονται με εκθετικό τρόπο καθώς τα δεδομένα παλιώνουν. Αυτό παρατηρείται και από την ακόλουθη εξίσωση που μας δίνει το S_t :

$$S_t = h_1 X_t + h_1(1 - h_1)X_{t-1} + h_1(1 - h_1)^2 X_{t-2} + h_1(1 - h_1)^3 X_{t-3} \\ + h_1(1 - h_1)^4 X_{t-4} + \dots + h_1(1 - h_1)^k X_{t-k}$$

❖ Το μοντέλο σταθερής τάσης (Holt)

Το μοντέλο εξομάλυνσης γραμμικής τάσης είναι μια επέκταση του μοντέλου παλινδρόμησης όπου ο χρόνος αποτελεί την ανεξάρτητη μεταβλητή. Στο μοντέλο παλινδρόμησης, όπως θα δούμε και παρακάτω, η εξίσωση παλινδρόμησης είναι $X = a + b t$ όπου a είναι το αρχικό σημείο της γραμμής και b η κλίση της τα οποία διατηρούνται πάντα σταθερά σε όλο το μήκος της χρονοσειράς. Οι τιμές των παραμέτρων a και b προκύπτουν από το μέσο όρο των δεδομένων.

Αντίθετα στο μοντέλο εξομάλυνσης γραμμικής τάσης, το αρχικό σημείο και η κλίση δεν παραμένουν σταθερά αλλά μεταβάλλονται σε κάθε χρονική περίοδο ενώ συγχρόνως τα πιο πρόσφατα δεδομένα αποκτούν και μεγαλύτερη βαρύτητα. Εμπειρικές μελέτες έχουν δείξει ότι οι εξομαλυμένες τιμές του αρχικού σημείου και της κλίσης είναι πολύ πιο ακριβείς από τις αντίστοιχες τιμές που υπολογίζονται από την εφαρμογή της απλής γραμμικής παλινδρόμησης.

Το μαθηματικό μοντέλο εξομάλυνσης γραμμικής τάσης περιγράφεται από τις ακόλουθες εξισώσεις:

$$e_t = X_t - \hat{X}_{t-1} \quad (1)$$

$$S_t = S_{t-1} + T_{t-1} + h_1 e_t$$

$$T_t = T_{t-1} + h_2 e_t$$

$$\hat{X}_t(m) = S_t + mT_t$$

Αρχικά υπολογίζεται το σφάλμα πρόβλεψης e_t το οποίο ορίζεται σαν η διαφορά της πραγματικής τιμής της χρονοσειράς και της πρόβλεψης της χρονικής περιόδου $t-1$ για ορίζοντα 1 περιόδου. Το S_t είναι το επίπεδο της χρονοσειράς στο

τέλος της χρονικής περιόδου t και είναι ίσο με το άθροισμα του επιπέδου της χρονικής περιόδου $t-1$, της τάσης για την χρονική περίοδο $t-1$ και ενός ποσοστού του σφάλματος πρόβλεψης. Το ποσοστό αυτό καθορίζεται από τον συντελεστή h_1 ο οποίος ορίζεται ως ο συντελεστής εξομάλυνσης του επιπέδου και το πεδίο τιμών του είναι από 0 έως 1. Η τάση T_t είναι η τάση της χρονοσειράς για την χρονική περίοδο t (εξομαλυμένη τάση) και είναι ίση με το άθροισμα της τάσης της χρονικής περιόδου $t-1$ και ενός ποσοστού του σφάλματος πρόβλεψης. Το ποσοστό αυτό καθορίζεται από τον συντελεστή h_2 ο οποίος ορίζεται ως ο συντελεστής εξομάλυνσης της τάσης και το πεδίο τιμών του είναι επίσης από 0 έως 1. Η ποσότητα $\widehat{X}_t(m)$ είναι η πρόβλεψη που πραγματοποιείται στο τέλος της περιόδου t και αναφέρεται σε m περιόδους μπροστά. Η πρόβλεψη είναι ίση με το άθροισμα του επιπέδου S_t και της τάσης T_t πολλαπλασιασμένης με τον αριθμό m των περιόδων του ορίζοντα πρόβλεψης. Η αρχικοποίηση του μοντέλου γραμμικής τάσης μπορεί να γίνει με εφαρμογή γραμμικής παλινδρόμησης στα δεδομένα μας. Συγκεκριμένα οι αρχικές τιμές του επιπέδου και της τάσης, λαμβάνουν τις τιμές του αρχικού σημείου και της κλίσης της ευθείας γραμμικής παλινδρόμησης.

Όσον αφορά τώρα τις τιμές των συντελεστών εξομάλυνσης, ελέγχονται κάποιες δοκιμαστικές τιμές. Το κριτήριο επιλογής είναι στις περισσότερες περιπτώσεις η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (MSE) αν και θα μπορούσαν να χρησιμοποιηθούν και άλλα είδη σφάλματος όπως το απόλυτο ή το ποσοστιαίο σφάλμα. Ένας αποτελεσματικός αλγόριθμος για να επιλεγούν οι βέλτιστες τιμές των συντελεστών εξομάλυνσης επιπέδου και τάσης είναι ο ακόλουθος: αρχικά υπολογίζουμε την τιμή του σφάλματος για 4 συνδυασμούς ($h_1=0.33, 0.67$) και ($h_2=0.33, 0.67$) επιλέγοντας τον καλύτερο. Έπειτα υπολογίζεται το σφάλμα για το διάστημα τιμών ± 0.17 γύρω από τα βέλτιστα h_1, h_2 που έχουμε επιλέξει. Και πάλι επιλέγεται ο βέλτιστος συνδυασμός h_1 και h_2 . Αυτή η διαδικασία εκτελείται επαναληπτικά μέχρι το σημείο που η μεταβολή του σφάλματος γίνει μικρότερη από 1%, μειώνοντας σταδιακά και τα αντίστοιχα διαστήματα (σε $\pm 0.08, \pm 0.04, \pm 0.02$). Συνήθως η βέλτιστη τιμή του συντελεστή τάσης h_2 είναι μικρότερη από την τιμή του συντελεστή επιπέδου h_1 αφού η τιμή της τάσης για κάθε περίοδο είναι συνήθως πολύ μικρότερη από την τιμή του επιπέδου. Αν προστεθεί το ίδιο

ποσοστό σφάλματος και στο επίπεδο και στην τάση τότε οι προβλέψεις που θα προκύψουν θα είναι μάλλον ασταθείς. Τα προτεινόμενα κατώτατα όρια των συντελεστών εξομάλυνσης είναι μεταξύ $h_1=0.1$ και $h_2=0.01$.

❖ Μοντέλα μη γραμμικής τάσης

Το μοντέλο γραμμικής τάσης μπορεί να μεταβληθεί κατάλληλα ώστε να προσαρμόζεται και σε μη γραμμικές τάσεις. Αυτό επιτυγχάνεται με τη χρήση μιας παραμέτρου που ελέγχει το ρυθμό αύξησης των τιμών των προβλέψεων. Αυτή ονομάζεται παράμετρος διόρθωσης της τάσης και συμβολίζεται με φ . Οι εξισώσεις που περιγράφουν το μοντέλο μη γραμμικής τάσης είναι οι ακόλουθες:

$$e_t = X_t - \hat{X}_{t-1} \quad (1)$$

$$S_t = S_{t-1} + \varphi T_{t-1} + h_1 e_t$$

$$T_t = \varphi T_{t-1} + h_2 e_t$$

$$\hat{X}_t(m) = S_t + \sum_{t-1}^m \varphi^t T_t$$

Αρχικά υπολογίζεται το σφάλμα πρόβλεψης e_t το οποίο ορίζεται σαν η διαφορά της πραγματικής τιμής της χρονοσειράς και της πρόβλεψης της χρονικής περιόδου $t-1$ για ορίζοντα μιας περιόδου. Το S_t είναι το επίπεδο της χρονοσειράς στο τέλος της χρονικής περιόδου t και είναι ίσο με το άθροισμα του επιπέδου της χρονικής περιόδου $t-1$, της τάσης για την χρονική περίοδο $t-1$ πολλαπλασιασμένης με την παράμετρο φ και ενός ποσοστού του σφάλματος πρόβλεψης. Το ποσοστό αυτό καθορίζεται από τον συντελεστή h_1 ο οποίος ορίζεται ως ο συντελεστής εξομάλυνσης του επιπέδου και το πεδίο τιμών του είναι από 0 έως 1. Η τάση T_t είναι η τάση της χρονοσειράς για την χρονική περίοδο t και είναι ίση με το άθροισμα της τάσης της χρονικής περιόδου $t-1$ πολλαπλασιασμένης με την παράμετρο φ και ενός ποσοστού του σφάλματος πρόβλεψης. Το ποσοστό αυτό καθορίζεται από τον συντελεστή h_2 ο οποίος ορίζεται ως ο συντελεστής εξομάλυνσης της τάσης και το πεδίο τιμών του είναι επίσης από 0 έως 1. Η ποσότητα $\hat{X}_t(m)$ είναι η πρόβλεψη που πραγματοποιείται στο τέλος της περιόδου t και αναφέρεται σε m περιόδους μπροστά. Η πρόβλεψη είναι

ίση με το άθροισμα του επιπέδου S_i και της τάσης T_i πολλαπλασιασμένης με την παράμετρο φ υψωμένη στον αριθμό m των περιόδων του ορίζοντα πρόβλεψης.

Αν η τιμή του συντελεστή φ είναι μεγαλύτερη του 1, τότε προκύπτει εκθετική τάση και το μέγεθος κατά το οποίο αυξάνει η τιμή των προβλέψεων, μεγαλώνει κάθε χρονική περίοδο. Αν η τιμή του συντελεστή φ είναι μικρότερη του 1, τότε προκύπτει φθίνουσα τάση και το μέγεθος κατά το οποίο αυξάνει η τιμή των προβλέψεων, μικραίνει κάθε χρονική περίοδο.

Η αρχικοποίηση του μοντέλου μη γραμμικής τάσης μπορεί να γίνει με εφαρμογή γραμμικής παλινδρόμησης στα δεδομένα μας. Συγκεκριμένα οι αρχικές τιμές του επιπέδου και της τάσης λαμβάνουν τις τιμές του αρχικού σημείου και της κλίσης της ευθείας γραμμικής παλινδρόμησης.

Όσον αφορά τώρα τις τιμές των συντελεστών εξομάλυνσης και της παραμέτρου διόρθωσης της τάσης, ελέγχονται κάποιες δοκιμαστικές τιμές. Το κριτήριο επιλογής είναι στις περισσότερες περιπτώσεις, η ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (MSE) αν και θα μπορούσαν να χρησιμοποιηθούν και άλλα είδη σφάλματος όπως το απόλυτο ή το ποσοστιαίο σφάλμα. Ένας αποτελεσματικός αλγόριθμος για να επιλεγούν οι βέλτιστες τιμές των συντελεστών εξομάλυνσης επιπέδου, τάσης και της παραμέτρου διόρθωσης της τάσης είναι ο ακόλουθος: Αρχικά υπολογίζουμε την τιμή του σφάλματος για 20 συνδυασμούς ($h_1=0.33, 0.67$) και ($h_1=0.33, 0.67$) και ($\varphi=0.33, 0.67, 1.00, 1.33, 1.67$) επιλέγοντας τον καλύτερο. Έπειτα υπολογίζεται το σφάλμα για το διάστημα τιμών ± 0.17 γύρω από τα βέλτιστα h_1, h_2 και φ που έχουμε επιλέξει. Και πάλι επιλέγεται ο βέλτιστος συνδυασμός h_1, h_2 και φ . Αυτή η διαδικασία εκτελείται επαναληπτικά μέχρι το σημείο που η μεταβολή του σφάλματος γίνει μικρότερη από 1%, μειώνοντας σταδιακά και τα αντίστοιχα διαστήματα (σε $\pm 0.08, \pm 0.04, \pm 0.02$).

Αρκετές φορές οι προβλέψεις που προκύπτουν από το μοντέλο μη γραμμικής τάσης είναι σχεδόν ίδιες με αυτές του μοντέλου απλής εκθετικής εξομάλυνσης ή του μοντέλου γραμμικής τάσης. Για παράδειγμα αν στα δεδομένα μας δεν υπάρχει τάση και εφαρμόσουμε σε αυτά το μοντέλο μη γραμμικής τάσης και το μοντέλο σταθερού

επιπέδου, οι προβλέψεις που θα παραχθούν θα είναι κατά προσέγγιση ίσες. Αυτό γιατί η τιμή της παραμέτρου διόρθωσης της τάσης φ που θα προκύψει με την προαναφερόμενη διαδικασία εύρεσης της, θα είναι πολύ κοντά στο 0. Αν θέσουμε $\varphi = 0$, στις εξισώσεις που περιγράφουν το μοντέλο μη γραμμικής τάσης, τότε προκύπτει το μοντέλο σταθερού επιπέδου και συνεπώς οι προβλέψεις είναι ακριβώς οι ίδιες.

Από την παραπάνω διαπίστωση καταλαβαίνουμε ότι μπορούμε να χρησιμοποιήσουμε το μοντέλο μη γραμμικής τάσης σαν ένα αυτόματο σύστημα πρόβλεψης για κάθε τύπο μη εποχιακής χρονοσειράς. Έτσι θα έχουμε την εξής αντιστοίχιση για καθένα από τα παρακάτω 4 μοντέλα εξομάλυνσης:

- $\varphi=0 \rightarrow$ σταθερό επίπεδο
- $\varphi<1 \rightarrow$ φθίνουσα τάση
- $\varphi=1 \rightarrow$ γραμμική τάση
- $\varphi>1 \rightarrow$ εκθετική τάση

Η χρησιμοποίηση μοντέλου εκθετικής τάσης σε ένα αυτόματο σύστημα πρόβλεψης εγκυμονεί κινδύνους. Έτσι το μοντέλο αυτό μπορεί να αποκλειστεί περιορίζοντας το πεδίο τιμών της παραμέτρου διόρθωσης της τάσης φ στο διάστημα $[0, 1]$ και ο προαναφερθείς αλγόριθμος αρχικοποίησης των συντελεστών θα εξετάσει αρχικά για την παράμετρο φ μόνο για τις τιμές 0.33 και 0.67.

Η ακρίβεια των προβλέψεων του μοντέλου μη γραμμικής τάσης είναι σημαντικά μεγαλύτερη από τις αντίστοιχες του μοντέλου γραμμικής τάσης. Γενικά το μοντέλο μη γραμμικής τάσης δίνει ικανοποιητικά αποτελέσματα σε περιπτώσεις όπου είναι αδύνατη η εύρεση κάποιου συγκεκριμένου μοντέλου για την παραγωγή προβλέψεων κάποιας χρονοσειράς.

Συστηματικές έρευνες έχουν δείξει ότι όσο πιο μακρινός είναι ο ορίζοντας πρόβλεψης, τόσο πιο πολύ πλεονεκτεί το μοντέλο μη γραμμικής τάσης σε ακρίβεια έναντι των άλλων μοντέλων.

2.1.1.1.3 Αυτοπαλινδρομικές Μέθοδοι Κινητού Μέσου Όρου (ARIMA)

Τα ολοκληρωμένα αυτοπαλινδρομικά μοντέλα κινητών μέσων όρων είναι στοχαστικά μαθηματικά μοντέλα με τα οποία προσπαθούμε να περιγράψουμε τη διαχρονική εξέλιξη κάποιου φυσικού μεγέθους. Δεδομένου ότι για την πλειοψηφία των φυσικών μεγεθών είναι αδύνατη η πλήρης γνώση και καταγραφή όλων των παραγόντων που επηρεάζουν την εξέλιξή τους στο χρόνο, είναι πολύ δύσκολη η διαχρονική περιγραφή του μεγέθους από ένα ντετερμινιστικό μοντέλο. Από την άλλη πλευρά, η εξάρτηση τέτοιων μεγεθών από μη ντετερμινιστικούς παράγοντες καθιστά δυνατή την περιγραφή της διαχρονικής τους εξέλιξης από ένα στοχαστικό μοντέλο, με το οποίο θα μπορεί να υπολογιστεί η πιθανότητα με την οποία η τιμή του μεγέθους βρίσκεται σε κάποιο διάστημα.

Τα στοχαστικά μοντέλα περιέχουν τον τυχαίο παράγοντα, τις τιμές του μεγέθους σε προηγούμενες χρονικές στιγμές και ίσως κάποιους άλλους στοχαστικούς παράγοντες. Το μοντέλο που προκύπτει είναι ένας συνδυασμός των παραπάνω ποσοτήτων.

Τα μοντέλα ARIMA χρησιμοποιούνται ευρύτατα γιατί βρίσκουν εφαρμογή στη μελέτη πολλών μεγεθών και φαίνεται να δίνουν μια καλή εικόνα της διαχρονικής συμπεριφοράς τους καθώς και ικανοποιητικά αποτελέσματα στην πρόβλεψη των μελλοντικών τιμών του μεγέθους. Βέβαια έχει παρατηρηθεί ότι είναι ιδανικά για βραχυπρόθεσμες προβλέψεις ενώ στις μακροπρόθεσμες προβλέψεις παρουσιάζουν μεγάλες αποκλίσεις. Αυτό συμβαίνει γιατί τα ARIMA δίνουν μεγαλύτερη έμφαση στις παρατηρήσεις του πρόσφατου παρελθόντος από ότι σε αυτές του μακρινού παρελθόντος. Είναι σημαντικό να τονίσουμε ότι τα μοντέλα αυτά εφαρμόζονται αποκλειστικά σε διακριτές χρονοσειρές, οι παρατηρήσεις των οποίων έχουν ληφθεί σε χρονικές στιγμές που απέχουν μεταξύ τους ίσα χρονικά διαστήματα.

Η εκτεταμένη ανάπτυξη και μελέτη των μοντέλων ARIMA είναι πλέον συνυφασμένη με τα ονόματα των Box και Jenkins οι οποίοι πρότειναν μια οικογένεια αλγεβρικών μοντέλων πρόβλεψης, από τα οποία μπορεί κανείς να διαλέξει το καταλληλότερο για την πρόβλεψη μιας συγκεκριμένης χρονοσειράς. Η μέθοδος Box-

Jenkins οδηγεί στην ανάπτυξη ενός μοντέλου παρέμβασης, όπου παρέμβαση θεωρείται ένα σημαντικό γεγονός όπως νέοι νόμοι, πόλεμοι, φυσικές καταστροφές, οικονομικά γεγονότα κλπ. Ενδεικτικά αναφέρουμε δύο παραδείγματα εφαρμογής της μεθόδου αυτής:

- ✓ Η ανακάλυψη των ολοκληρωμένων κυκλωμάτων που οδήγησε σε νέα αναπτυξιακά κύματα πολλούς τεχνολογικούς και παραγωγικούς κλάδους.
- ✓ Η δημιουργία της Ευρωπαϊκής Ένωσης που επηρέασε τον διεθνή ανταγωνισμό, το ελεύθερο εμπόριο και την κινητικότητα των εργαζομένων.

2.1.1.2 Αιτιοκρατικές Μέθοδοι

Βασική υπόθεση στο μοντέλο αυτό είναι ότι υπάρχει μια σταθερή σχέση μεταξύ της μεταβλητής πρόβλεψης (εξαρτημένη μεταβλητή) και ορισμένων παραμέτρων (ανεξάρτητες μεταβλητές) που το επηρεάζουν. Αυτή η σχέση μπορεί κάλλιστα να χαρακτηρισθεί ως σχέση αιτίου-αιτιατού. Αυτή η σχέση μπορεί να παρασταθεί σχηματικά ως εξής:



Σχήμα 2.4 Αιτιοκρατικό μοντέλο

Το i παίρνει τιμές από 1 μέχρι και n , και αντιπροσωπεύει τις n παραμέτρους από τις οποίες εξαρτάται η μεταβολή του μεγέθους που μας ενδιαφέρει. Η έξοδος είναι η προβλεπόμενη τιμή της εξαρτημένης μεταβλητής. Το σύστημα περιγράφεται από την παρακάτω μαθηματική συνάρτηση:

$$y = f(X_1, X_2, \dots, X_n)$$

Το πιο σημαντικό πλεονέκτημα των αιτιοκρατικών μεθόδων είναι ότι προσφέρουν στον χρήστη την δυνατότητα να προβλέψει την μελλοντική τιμή κάποιου μεγέθους, για διάφορους συνδυασμούς των μεταβλητών εισόδου. Έτσι έχοντας στην

διάθεσή του διάφορα εναλλακτικά σενάρια μπορεί να καταλήξει ευκολότερα στην επιλογή της βέλτιστης επιλογής.

Τα αιτιοκρατικά μοντέλα όμως χαρακτηρίζονται και από μερικά σοβαρά μειονεκτήματα. Ένα σοβαρό μειονέκτημα είναι ότι απαιτούν πολύ περισσότερα δεδομένα σε σχέση με τις μεθόδους των χρονοσειρών, αφού χρειάζονται πληροφορίες όχι μόνο για την μεταβλητή πρόβλεψης αλλά και για ένα πλήθος ανεξάρτητων μεταβλητών. Επιπλέον τα μοντέλα αυτά παρουσιάζουν μεγάλη “ευαισθησία” σε πιθανές αλλαγές των φυσικών νόμων που συνδέουν τις ανεξάρτητες μεταβλητές με το υπό εξέταση μέγεθος. Τέλος, είναι πολλές οι περιπτώσεις όπου για την παραγωγή ολοκληρωμένων προβλέψεων από ένα τέτοιο μοντέλο απαιτείται προηγουμένως η εκτίμηση, με βάση κάποια άλλη μέθοδο πρόβλεψης, της μελλοντικής τιμής ορισμένων μεταβλητών εισόδου. Αυτό συνεπάγεται την άμεση αύξηση των απαιτούμενων υπολογισμών όπως και του συνολικού κόστους της όλης εφαρμογής.

Στις αιτιοκρατικές μεθόδους ανήκουν οι μέθοδοι παλινδρόμησης (απλή γραμμική παλινδρόμηση, πολλαπλή γραμμική παλινδρόμηση) και οι οικονομετρικές μέθοδοι.

2.1.1.2.1 Μέθοδοι Παλινδρόμησης

❖ Απλή γραμμική παλινδρόμηση

Βασική υπόθεση στην συγκεκριμένη μέθοδο είναι η ύπαρξη γραμμικής σχέσης ανάμεσα στην μεταβλητή πρόβλεψης (εξαρτημένη μεταβλητή, Y) και σε μια άλλη μεταβλητή (ανεξάρτητη μεταβλητή, X). Θεωρείται ότι η ανεξάρτητη μεταβλητή καθορίζεται από εξωγενείς παράγοντες. Η ζητούμενη εξίσωση σε αυτή τη μέθοδο είναι η έκφραση της σχέσης μεταξύ εξαρτημένης και ανεξάρτητης μεταβλητής σύμφωνα με τη σχέση:

$$\hat{Y}_i = a + b X_i$$

Όπου οι σταθερές a , b υπολογίζονται, εφαρμόζοντας την μέθοδο των ελαχίστων τετραγώνων, από τις παρακάτω εξισώσεις:

$$b = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

$$a = \bar{Y} - b\bar{X}$$

Όπου $\bar{Y} = \frac{\sum Y}{n}$, $\bar{X} = \frac{\sum X}{n}$ και n ο αριθμός των παρατηρήσεων.

Με βάση την εξίσωση παλινδρόμησης υπολογίζονται κάποιοι στατιστικοί δείκτες (F-test, t-test) οι οποίοι επιτρέπουν την εκτίμηση:

- Της πιθανότητας οι μελλοντικές τιμές της εξαρτημένης μεταβλητής να διαφέρουν από τις προβλεπόμενες κατά συγκεκριμένη ποσότητα,
- Της αξιοπιστίας του υπολογισμού της ευθείας παλινδρόμησης και
- Της ακρίβειας των συντελεστών a και b .

Εάν παρατηρηθεί από την γραφική παράσταση των τιμών των ζευγών (X , Y) ότι οι μεταβλητές X και Y δεν συνδέονται με γραμμική συνάρτηση αλλά η συνάρτηση αυτή είναι γραμμική ως προς τις παραμέτρους (π.χ. πολυονυμική συνάρτηση κ.λπ.) τότε η μέθοδος της απλής γραμμικής παλινδρόμησης μπορεί να εφαρμοστεί και σε αυτή την περίπτωση.

❖ Πολλαπλή γραμμική παλινδρόμηση

Στην πολλαπλή παλινδρόμηση υπάρχει μια εξαρτημένη μεταβλητή-μεταβλητή πρόβλεψης και δύο ή περισσότερες ανεξάρτητες μεταβλητές.

Η γενική μορφή της πολλαπλής γραμμικής παλινδρόμησης είναι:

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_kX_k + \varepsilon$$

όπου:

$b_0, b_1, b_2, \dots, b_k$: είναι σταθερές παράμετροι

X_1, X_2, \dots, X_k : είναι μεταβλητές υπολογισμένες χωρίς σφάλμα

ε : είναι τυχαία μεταβλητή κανονικά κατανομημένη γύρω από το μηδέν με διασπορά V_ε

Η εξίσωση της πολλαπλής γραμμικής παλινδρόμησης είναι γραμμική ως προς τους συντελεστές. Ο εκθέτης κάθε συντελεστή b ισούται με τη μονάδα-γεγονός που εξασφαλίζει τη γραμμικότητα και οι τιμές των συντελεστών αυτών μπορούν να προκύψουν με εφαρμογή της μεθόδου των ελαχίστων τετραγώνων. Στην ουσία ο στόχος είναι ο υπολογισμός των αγνώστων παραμέτρων του μοντέλου: $b_0, b_1, b_2, \dots, b_k$ και V_ε .

Βασικό πλεονέκτημα αυτής της μεθόδου είναι ότι μπορούν να θεωρηθούν και να διερευνηθούν ένας σημαντικός αριθμός διαφορετικών σχέσεων.

2.1.1.2.2 Οικονομετρικές μέθοδοι

Μια οικονομετρική μέθοδος προσδιορίζει τη σχέση μεταξύ μιας ή περισσοτέρων ενδογενών ή εξωγενών μεταβλητών με χρήση τεχνικών ελαχίστων τετραγώνων και οικονομετρικών μεθόδων που βασίζονται στην επίλυση πολλών ταυτόχρονα σχετικών εξισώσεων. Οδηγεί στην ανάπτυξη οικονομικών μοντέλων που αναπαριστούν τη σχέση μεταξύ εισροών και εκροών σε βιομηχανικούς κλάδους με τη χρήση πινάκων επίδρασης.

Οι οικονομετρικές μέθοδοι περιλαμβάνουν όλες τις ποσοτικές διαδικασίες που βασίζονται σε αιτιοκρατικές σχέσεις. Τα βασικά βήματα που ακολουθούνται στην εφαρμογή μιας οικονομετρικής μεθόδου είναι η ανάπτυξη του *a priori* μοντέλου, η επιλογή των δεδομένων, η ανάλυση των δεδομένων και η εκ νέου προσαρμογή του μοντέλου.

Τρεις είναι οι βασικές συνθήκες που ευνοούν τη χρήση οικονομετρικών μεθόδων. Η πρώτη είναι η ύπαρξη επαρκούς πληροφορίας για τις αιτιοκρατικές σχέσεις. Η πληροφορία αυτή μπορεί να προέρχεται είτε από υποκειμενικές πηγές είτε από την ανάλυση των δεδομένων. Η δεύτερη συνθήκη είναι ότι οι μεταβολές των αιτιοκρατικών μεταβλητών πρέπει να είναι μεγάλες για να μπορούν να εφαρμοστούν οι οικονομετρικές μέθοδοι. Όμως για μεγάλες μεταβολές δεν είναι και τόσο

απαραίτητο να χρησιμοποιηθούν οικονομετρικές μέθοδοι. Η τρίτη συνθήκη είναι η δυνατότητα να προβλεφθεί με ακρίβεια η κατεύθυνση των μεταβολών στις αιτιοκρατικές μεταβλητές, και να εκτιμηθεί η βαρύτητα των μεταβολών αυτών.

Με μία σύντομη σύγκριση των οικονομετρικών μεθόδων με την μέθοδο της πολλαπλής παλινδρόμησης μπορούμε να πούμε ότι η μέθοδος της πολλαπλής παλινδρόμησης αποτελεί ειδική περίπτωση των οικονομετρικών μεθόδων. Οι πιο σημαντικές διαφορές αναφέρονται συνοπτικά παρακάτω:

- Στις οικονομετρικές μεθόδους η επιλογή των αιτιοκρατικών μεταβλητών, των συντελεστών και της μορφής της εξίσωσης πάνω στην οποία θα βασιστούν οι μελλοντικές προβλέψεις προαποφασίζονται από τον εμπειρογνώμονα με βάση την κρίση, την εμπειρία και τις προσωπικές του εκτιμήσεις. Αντιθέτως η μέθοδος της πολλαπλής παλινδρόμησης προεπιλέγει μόνο την μορφή της εξίσωσης που πρόκειται να χρησιμοποιηθεί. Οι ανεξάρτητες μεταβλητές καθώς και οι αντίστοιχοι συντελεστές προκύπτουν μετά από διαδοχικά τρεξίματα της εξίσωσης και προσδιορίζονται με βάση αντικειμενικές μεθόδους.
- Η μορφή της εξίσωσης στην πολλαπλή παλινδρόμηση είναι περίπου συγκεκριμένη, ενώ στις οικονομετρικές μεθόδους υπάρχει μεγαλύτερη δυνατότητα διαφοροποίησης.
- Στις οικονομετρικές μεθόδους ο έλεγχος της σημαντικότητας των ανεξάρτητων μεταβλητών γίνεται με διάφορους αντικειμενικούς τρόπους. Αντιθέτως, κατά την εφαρμογή της πολλαπλής παλινδρόμησης χρησιμοποιούνται μόνο συγκεκριμένες στατιστικές μέθοδοι.
- Τέλος ανάλογα με τη φύση της εκάστοτε εφαρμογής, οι οικονομετρικές μέθοδοι θεωρούνται καταλληλότερες για περιπτώσεις όπου εκτιμάται ότι οι επερχόμενες μεταβολές των ανεξάρτητων μεταβλητών θα είναι μεγάλης κλίμακας και σε περιπτώσεις όπου τα διαθέσιμα ιστορικά δεδομένα είναι λίγα.

2.1.2 Κριτικές Μέθοδοι

Οι κριτικές μέθοδοι χρησιμοποιούν δεδομένα που αποτελούν κυρίως αποτέλεσμα διαισθητικής κρίσης, προσωπικής γνώμης και εκτίμησης πιθανοτήτων.

Δεν έχουν τις ίδιες απαιτήσεις με τις ποσοτικές μεθόδους πρόβλεψης. Βασίζονται στην εμπειρία, την γνώση επί του αντικειμένου και την κριτική ικανότητα των ατόμων που ασχολούνται με την πρόβλεψη. Πλεονεκτούν έναντι των ποσοτικών ως προς την δυνατότητα ενσωμάτωσης και επεξεργασίας των δεδομένων που αφορούν εξωτερικούς παράγοντες και τις ιδιαίτερες συνθήκες που επηρέασαν ή πρόκειται να επηρεάσουν τη χρονοσειρά.

Στις κριτικές μεθόδους η πρόβλεψη μπορεί να βασίζεται είτε στις γνώσεις και την κρίση ενός ατόμου (ατομικές μέθοδοι) είτε να προκύπτει από την ανταλλαγή και το συνδυασμό απόψεων των μελών κάποιας συγκεκριμένης ομάδας (μέθοδοι επιτροπής).

2.1.3 Τεχνολογικές μέθοδοι

Οι μέθοδοι αυτές βασίζονται στις υποκειμενικές απόψεις και κρίσεις ειδικών σχετικά με μελλοντικές τάσεις και τεχνολογικές αλλαγές όπως η ζήτηση νέων προϊόντων, η χρήση νέων τεχνολογιών, η εφαρμογή νέων ανταγωνιστικών πολιτικών. Χρησιμοποιούνται συνήθως για μακροπρόθεσμες προβλέψεις σε περιπτώσεις που δεν υπάρχουν επαρκή αντικειμενικά δεδομένα για πρότυπα ή σχέσεις στο παρελθόν.

Οι τεχνολογικές μέθοδοι προβλέψεων μπορούν να ταξινομηθούν, βάση του χρόνου των δεδομένων σε δύο γενικές κατηγορίες: τις διερευνητικές (exploratory) και τις δεοντολογικές (normative).

- ✓ Διερευνητικές: Οι τεχνικές εκείνες που βασίζονται σε μια επέκταση των δεδομένων του παρελθόντος, δια μέσου του παρόντος, στο μέλλον (Delphi, S-καμπύλες, αναλογίες και μορφολογική έρευνα)
- ✓ Δεοντολογικές: Οι τεχνικές εκείνες στις οποίες μια επιθυμητή ή πιθανή κατάσταση γεγονότων προβάλλεται στο μέλλον. Συγκεκριμένα προσδιορίζεται μια αναδρομική σειρά βημάτων που εκτιμάται ότι θα οδηγήσουν στη τρέχουσα κατάσταση και αξιολογείται η πιθανότητα πραγματοποίησής τους (μήτρες αποφάσεων, δέντρα συσχετίσεων, ανάλυση συστημάτων).

Αναφέρονται κάποια παραδείγματα τεχνολογικών μεθόδων πρόβλεψης:

- Μέθοδος DELPHI
- Μέθοδος Δένδρων Συναφείας
- Μέθοδος Ποσοτικοποιημένων Ιστορικών Αναλογιών
- Μέθοδος Ανάλυσης Επιπτώσεων Τάσεων
- Μέθοδος Καμπυλών Ανάπτυξης και Καμπυλών Αντικατάστασης
- Μέθοδος Σεναρίων

Η πιο συνήθης μέθοδος είναι χωρίς καμία αμφιβολία η μέθοδος DELPHI. Είναι μια επαναληπτική διαδικασία στην οποία εμπειρογνώμονες απαντούν σε ερωτηματολόγια τα οποία ταξινομούνται και τροποποιούνται αρκετές φορές μέχρι να φθάσουν σε συγκλίνουσες απόψεις και συμπεράσματα. Σκοπός της μεθόδου είναι να επιτύχει ομοφωνία μεταξύ των εμπειρογνομόνων και να προσδιορίσει ανταγωνιστικές απόψεις σχετικά με εναλλακτικές μελλοντικές εξελίξεις. Είναι αποτελεσματική μέθοδος επειδή η δομημένη και ανεξάρτητη καταγραφή των απόψεων των εμπειρογνομόνων οδηγεί σε σχετικά αμερόληπτες εκτιμήσεις εναλλακτικών μελλοντικών γεγονότων. Επιπροσθέτως, εκτός από τα πλεονεκτήματα μιας αυθεντικής αντικειμενοστραφούς γλώσσας, έχει και άλλα όπως το γεγονός ότι βασίζεται σε φόρμες, ο πολύ γρήγορος μεταγλωττιστής της, η πολύ καλή υποστήριξη σε εφαρμογές Βάσεων Δεδομένων, η συγγένειά της με τον προγραμματισμό των Windows και το προηγμένο χαρακτηριστικό της χρήσης 'components'.

Τυπικά βήματα της μεθόδου είναι:

- 1) Επιλογή της ομάδας των ανεξαρτήτων εμπειρογνομόνων .
- 2) Ερωτηματολόγια ή εναλλακτικά σενάρια σχετικά με τις εξελίξεις σε έναν κλάδο υποβάλλονται στους εμπειρογνώμονες.
- 3) Οι απαντήσεις του πρώτου κύκλου απαντήσεων μπορεί να διαφέρουν πολύ λόγω της διαφορετικής οπτικής μεταξύ τους.
- 4) Μέσω διαδοχικής ενημέρωσης των εμπειρογνομόνων με τις απαντήσεις των άλλων, η άποψη της ομάδας εξελίσσεται προς συγκλίνουσα κατεύθυνση.

5) Αν υπάρχουν σημαντικές αποκλίσεις μεταξύ των απόψεων μιας μειοψηφίας εμπειρογνομόνων και της πλειοψηφίας, μελετώνται προσεκτικά οι διαφορές και οι αιτίες τους.

2.2 ΜΕΘΟΔΟΣ NAIVE

Η «αφελής» μέθοδος είναι η πιο απλή μέθοδος και αποτελεί σημείο αναφοράς για όλες τις άλλες μεθόδους πρόβλεψης. Κάθε μέθοδος για να θεωρηθεί αποτελεσματική πρέπει να δίνει αποτελέσματα πιο ακριβή από τα αποτελέσματα της Naive. Η μέθοδος αυτή δίνει ως πρόβλεψη για κάθε ορίζοντα την τελευταία γνωστή παρατήρηση. Έχει καλές επιδόσεις για πρόβλεψη 1 περιόδου μπροστά σε αποεποχικοποιημένες χρονοσειρές καθώς η αναμενόμενη τιμή της πρόβλεψης δεν διαφέρει σημαντικά από την τελευταία παρατήρηση που έχουμε στην διάθεση μας. Η μέθοδος περιγράφεται από την ακόλουθη εξίσωση:

$$F_t = X_{t-1}$$

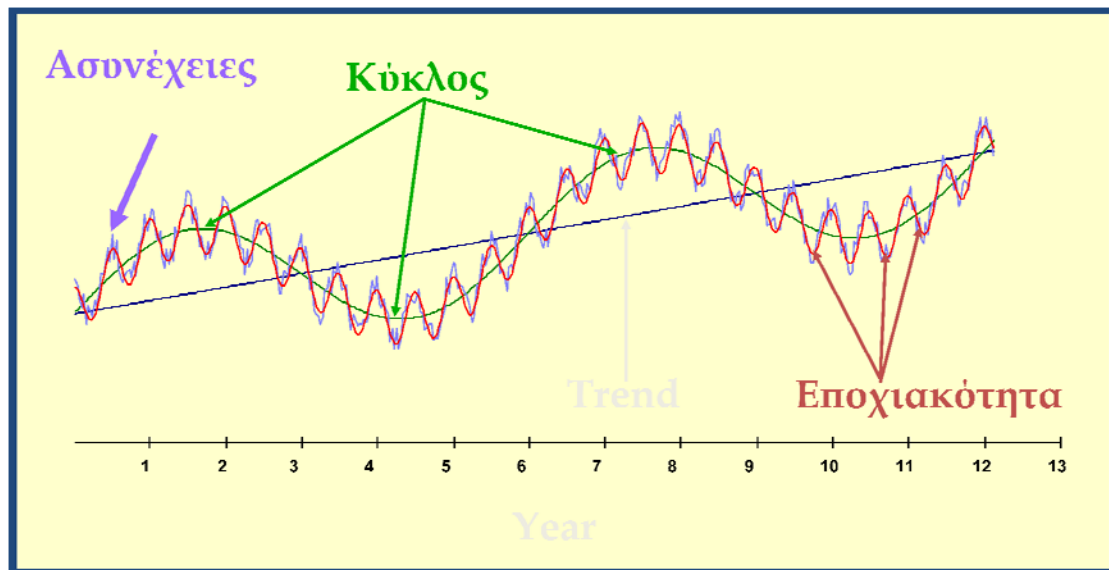
όπου:

F_t : η πρόβλεψη για την περίοδο t

X_{t-1} : η παρατήρηση την χρονική περίοδο t-1

2.3 ΠΟΙΟΤΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΧΡΟΝΟΣΕΙΡΩΝ

Η συστηματική μελέτη μιας χρονοσειράς ξεκινάει με την επισκόπηση του γραφήματος της στο πεδίο του χρόνου. Για παράδειγμα ας θεωρήσουμε το γράφημα που φαίνεται παρακάτω:



Σχήμα 2.5 Τυχαία χρονοσειρά

Παρατηρούμε ότι τα βασικά ποιοτικά χαρακτηριστικά της χρονοσειράς προκύπτουν κατευθείαν από το διάγραμμα και είναι: η τάση, η κυκλικότητα, η εποχιακότητα και οι ασυνέχειες. Αν αποσυνθέσουμε την συγκεκριμένη χρονοσειρά στα τέσσερα αυτά συστατικά της προκύπτουν τα παρακάτω τέσσερα διαγράμματα:

Σχήμα 2.6 Ποιοτικά χαρακτηριστικά χρονοσειράς

Για την καλύτερη κατανόηση των χαρακτηριστικών αυτών αναλύουμε ξεχωριστά το καθένα:

Η **τάση** ορίζεται γενικά σαν μια μακροπρόθεσμη μεταβολή του μέσου επιπέδου των τιμών της χρονοσειράς. Ουσιαστικά παρουσιάζει την γενική εικόνα της χρονοσειράς και μπορεί να είναι ανοδική, πτωτική ή σταθερή. Συχνά η τάση μπορεί να εκτιμηθεί κατά προσέγγιση με μια ευθεία γραμμή ή μια εκθετική καμπύλη, χωρίς να αποκλείονται και άλλες οικογένειες καμπυλών. Για να εξαχθούν ασφαλή συμπεράσματα για το αν μια χρονοσειρά παρουσιάζει ή όχι τάση θα πρέπει να έχουμε στην διάθεση μας ικανό αριθμό παρατηρήσεων και να εκτιμήσουμε ένα κατάλληλο μήκος περιόδου στο οποίο θα αναζητήσουμε την ύπαρξη τάσης. Αυτό γιατί αν μια χρονοσειρά παρουσιάζει κυκλικές διακυμάνσεις για κάποιο χρονικό διάστημα και το πλήθος των παρατηρήσεων που έχουμε στην διάθεση μας είναι μικρότερο από αυτόν τον αριθμό, τότε θα λάβουμε την υπάρχουσα κυκλικότητα της χρονοσειράς ως τάση και θα οδηγηθούμε σε λανθασμένα συμπεράσματα.

Η **κυκλικότητα** αντιπροσωπεύει μια κυματοειδή μεταβολή που οφείλεται σε ειδικές εξωγενείς συνθήκες και εμφανίζεται κατά περιόδους. Οι περίοδοι αυτοί συνήθως δεν είναι σταθερές και το μήκος τους είναι μεγαλύτερο του έτους. Είναι πολύ συχνό φαινόμενο ιδιαίτερα σε οικονομικά μεγέθη όπως στο Ακαθάριστο Εθνικό Προϊόν, στους δείκτες βιομηχανικής παραγωγής και στις τιμές των μετοχών. Συχνά χαρακτηρίζεται και ως «επιχειρηματικός κύκλος» εφόσον είναι αποτέλεσμα των διαδοχικών ανόδων-καθόδων των οικονομικών συνθηκών γενικότερα.

Η **εποχιακότητα** είναι μια περιοδική διακύμανση η οποία έχει σταθερό και μικρότερο του έτους μήκος. Η διακύμανση αυτή είναι άμεσα κατανοητή και προβλέψιμη γιατί επαναλαμβάνεται με τον ίδιο ακριβώς τρόπο. Συναντάται σε χρονοσειρές όπως για παράδειγμα της κατανάλωσης του πετρελαίου θέρμανσης και της διέλευσης των τροχοφόρων οχημάτων από κομβικά σημεία στο οδικό σύστημα κάποιας χώρας (π.χ. διόδια). Από τη στιγμή που οι αλλαγές στη χρονοσειρά είναι άμεσα παρατηρήσιμες και αναμενόμενες κατά κάποιο τρόπο, είναι εύκολο να απομονωθούν καταλήγοντας έτσι στα αποεποχικοποιημένα δεδομένα.

Οι **ασυνέχειες** είναι εκείνες οι παρατηρήσεις που εμφανίζονται στο γράφημα της χρονοσειράς ως απότομες αλλαγές στο πρότυπο συμπεριφοράς της και δεν θα μπορούσαν να είχαν προβλεφθεί από την ιστορία της. Οι ασυνέχειες μπορεί να είναι

παροδικές ή μόνιμες. Στην πρώτη περίπτωση κάνουμε λόγο για outliers, και η επίδρασή τους στη χρονοσειρά έχει μικρή χρονική διάρκεια. Η ερμηνεία τέτοιου είδους ασυνεχειών κρύβει πολλές παγίδες και για αυτό πρέπει το άτομο που έχει αυτή την αρμοδιότητα να διαθέτει την απαραίτητη γνώση, εμπειρία, κριτική ικανότητα και κοινή λογική. Ένα outlier μπορεί να αντιπροσωπεύει μια ασυνήθιστη παρατήρηση που οφείλεται σε κάποιο εξαιρετικό και απρόβλεπτο γεγονός όπως, μια μεγάλη απεργία των εργαζομένων σε μια βιομηχανία ή μια μεγάλη αθλητική διοργάνωση σε μια χώρα(π.χ. Ολυμπιακοί Αγώνες). Στην περίπτωση όπου οι ασυνέχειες αποκτούν μόνιμο χαρακτήρα κάνουμε λόγο για level-shifts. Τα level-shifts είναι απότομες αλλαγές στο μέσο επίπεδο των τιμών της χρονοσειράς. Τέτοιες αλλαγές μπορούν να συμβούν για παράδειγμα, στην οικονομική κατάσταση μιας περιοχής έπειτα από μια μεγάλη οικολογική καταστροφή.

Τέλος υπάρχουν και οι μη κανονικές διακυμάνσεις οι οποίες εκφράζουν μια τυχαία μεταβλητή. Αυτή η μεταβλητή απεικονίζει τον τυχαίο παράγοντα μιας στοχαστικής διαδικασίας που προκύπτει αν από τη δεδομένη χρονοσειρά έχουν αφαιρεθεί όλα τα υπόλοιπα στοιχεία της χρονοσειράς.

2.4 ΒΑΣΙΚΑ ΒΗΜΑΤΑ ΣΕ ΜΙΑ ΔΙΑΔΙΚΑΣΙΑ ΠΡΟΒΛΕΨΗΣ

1. Καθορισμός προβλήματος(problem definition)

Όσο παράξενο και να ακούγεται τις περισσότερες φορές αυτό είναι το πιο δύσκολο κομμάτι στη διαδικασία της πρόβλεψης. Αρχικά θα πρέπει να γίνει απολύτως σαφές ποιοί θα χρησιμοποιήσουν τις προβλέψεις και με ποιο τρόπο θα γίνει αυτό. Επίσης πρέπει να προσδιορισθεί από την αρχή το ποιος θα συλλέξει τα στοιχεία, ποιος θα συντηρεί τις βάσεις δεδομένων και ποιος θα χρησιμοποιήσει τις προβλέψεις για τον μελλοντικό σχεδιασμό.

2. Συγκέντρωση πληροφοριών (Gathering information)

Οι απαραίτητες πληροφορίες που πρέπει να συλλεχθούν πριν ξεκινήσει η διαδικασία της πρόβλεψης είναι τα αριθμητικά δεδομένα και η κρίση, η εμπειρία και

η πείρα του προσωπικού που ασχολούνταν με αυτή την αγορά το πρόσφατο χρονικό διάστημα.

3. Προκαταρκτική ανάλυση (Exploratory Analysis)

Πρέπει αρχικά να κατασκευάσουμε την γραφική παράσταση των ιστορικών δεδομένων. Από αυτή τη βασική γραφική παράσταση μπορούμε εύκολα να υπολογίσουμε κάποιους βασικούς στατιστικούς δείκτες όπως η μέση τιμή, η τυπική απόκλιση, το ελάχιστο και το μέγιστο των δεδομένων, την γραμμική τάση κ.λπ. Από αυτούς τους δείκτες μπορούμε να αποκομίσουμε σημαντικά στοιχεία για κάποια δευτερεύοντα χαρακτηριστικά της χρονοσειράς. Σκοπός αυτής της διαδικασίας είναι να εμβαθύνουμε λίγο στα δεδομένα και να αναγνωρίσουμε το πρότυπο συμπεριφοράς των δεδομένων. Τα πρότυπα αυτά είναι τέσσερα και συγκεκριμένα: το σταθερό πρότυπο, το πρότυπο της τάσης, το εποχιακό και το κυκλικό πρότυπο. Επειδή η ικανότητα των διαφόρων μεθόδων να παράγουν αξιόπιστες προβλέψεις για διαφορετικά πρότυπα δεδομένων ποικίλλει, είναι σημαντικό η μέθοδος που θα επιλεγεί να είναι κατάλληλη για το συγκεκριμένο πρότυπο. Γνωρίζοντας καλύτερα τα δεδομένα μπορούμε ευκολότερα να οδηγηθούμε σε μια οικογένεια μοντέλων πρόβλεψης που λογικά θα μας δώσουν ικανοποιητικές προβλέψεις.

4. Επιλογή & Προσαρμογή Μοντέλου (Choosing & Fitting models)

Στο σημείο αυτό καθορίζουμε τις τιμές των διαφόρων παραμέτρων των μοντέλων πρόβλεψης που έχουν επιλεγεί στο προηγούμενο βήμα.

5. Χρήση και αποτίμηση του μοντέλου πρόβλεψης (Using and Evaluating a forecasting model)

Στο τελικό στάδιο αφού ένα μοντέλο έχει επιλεγεί υποκειμενικά και οι παράμετροί του έχουν καθοριστεί στο προηγούμενο στάδιο, χρησιμοποιείται το μοντέλο αυτό ώστε να παραχθούν προβλέψεις. Το κατά πόσο το μοντέλο και οι

προβλέψεις είναι ικανοποιητικές κρίνονται μόνο από το χρόνο και αν είναι απαραίτητο κάποια βήματα από τη διαδικασία της πρόβλεψης επαναλαμβάνονται.

2.4.1 Παράγοντες στην επιλογή της καλύτερης μεθόδου πρόβλεψης

Εστιάζοντας λίγο την προσοχή μας στο τρίτο και στο τέταρτο βήμα της διαδικασίας πρόβλεψης που αναφέρθηκαν παραπάνω, θα πρέπει να τονίσουμε ότι εκτός από τα στοιχεία που αποκομίζουμε από τη γραφική παράσταση των δεδομένων (πρότυπο συμπεριφοράς των δεδομένων), υπάρχουν και κάποιοι άλλοι πολλοί σημαντικοί παράγοντες οι οποίοι πρέπει να ληφθούν σοβαρά υπόψη, μιας και αντικατοπτρίζουν τις δυνατότητες και την εφαρμοσιμότητα των διαθέσιμων μεθόδων.

Βασικό κριτήριο επιλογής μιας μεθόδου πρόβλεψης αποτελεί ο χρονικός ορίζοντας, δηλαδή το χρονικό διάστημα στο οποίο θα αναφέρεται η πρόβλεψη στο μέλλον. Γενικά οι ποιοτικές μέθοδοι χρησιμοποιούνται περισσότερο στις περιπτώσεις μακροπρόθεσμων προβλέψεων, ενώ οι ποσοτικές μέθοδοι για μεσοπρόθεσμες και βραχυπρόθεσμες προβλέψεις. Επίσης σημαντικός είναι και ο αριθμός των περιόδων για τις οποίες απαιτείται η πρόβλεψη. Ορισμένες τεχνικές είναι κατάλληλες για προβλέψεις που αντιστοιχούν σε μια ή δύο περιόδους μετά από την πιο πρόσφατη παρατήρηση, ενώ άλλες σε περισσότερες. Υπάρχουν επίσης τεχνικές που συνδυάζουν ορίζοντες πρόβλεψης με διαφορετικά μήκη.

Ένας ακόμα σημαντικός παράγοντας είναι το κόστος μιας μεθόδου πρόβλεψης το οποίο καθορίζεται από τον όγκο των δεδομένων που απαιτεί η μέθοδος και από την πολυπλοκότητα της εφαρμογής της.

Πρέπει επιπλέον να είναι γνωστή η αξιοπιστία του μοντέλου πρόβλεψης. Είναι φυσικό ότι σε κάθε πρόβλεψη απαιτείται και ένα ξεχωριστό επίπεδο λεπτομέρειας. Σε ορισμένες περιπτώσεις ένα ποσοστό ακρίβειας $\pm 10\%$ θεωρείται ικανοποιητικό, ενώ σε άλλες έστω και μια διακύμανση της τάξης του $\pm 5\%$ μπορεί να αποδειχτεί καταστροφική.

Τέλος είναι εύλογο να υπάρχει μια εικόνα για την δυσκολία εφαρμογής της μεθόδου. Έχει αποδειχτεί στην πράξη ότι προτιμούνται μέθοδοι που είναι κατανοητές και εύκολες στην εφαρμογή τους.

2.5 ΣΥΝΔΥΑΖΟΝΤΑΣ ΠΡΟΒΛΕΨΕΙΣ

Σε πολλές περιπτώσεις όπου η επιλογή της κατάλληλης μεθόδου προβλέψεων δεν είναι εύκολη, έχει αποδειχθεί προτιμότερος ο συνδυασμός των προβλέψεων που προκύπτουν από την εφαρμογή διαφορετικών μεθόδων. Με τον τρόπο αυτό αυξάνεται η ακρίβεια των προβλέψεων καθώς ελαττώνεται σημαντικά το διάστημα διακύμανσης των σφαλμάτων.

Διαφορετικές μέθοδοι πρόβλεψης τείνουν να παράγουν διαφορετικά αποτελέσματα όταν εφαρμόζονται στις ίδιες χρονοσειρές. Επομένως η πρόβλεψη μιας δεδομένης μεθόδου μπορεί να παρέχει κάποια χρήσιμη πληροφορία που δεν εμπεριέχεται στις προβλέψεις των άλλων μεθόδων. Στο βαθμό που θα θέλαμε να βασίσουμε τις προβλέψεις σε όλη την διαθέσιμη πληροφορία που μπορούμε να συγκεντρώσουμε, φαίνεται λογικό να συσσωρεύσουμε την πληροφορία που παρέχεται από διαφορετικές μεθόδους πρόβλεψης συνδυάζοντας τις παραγόμενες προβλέψεις.

Υποθέτοντας σταθερότητα των προτύπων συμπεριφοράς των δεδομένων, το βέλτιστο θεωρητικό μοντέλο θα έπρεπε να παράγει τις πιο ακριβείς προβλέψεις. Από την στιγμή όμως που τα πρότυπα αυτά μεταβάλλονται στην πράξη, ο συνδυασμός προβλέψεων από διάφορα μοντέλα, παράγει έναν μέσο όρο που προσεγγίζει περισσότερο την πραγματικότητα από το θεωρητικά πιο σωστό μοντέλο.

Η χρήση συνδυασμού προβλέψεων ισοδυναμεί με την παραδοχή ότι είναι αδύνατον να βρεθεί κάποιο μοντέλο που να προσδιορίζει με βέλτιστο τρόπο τη συμπεριφορά των ιστορικών δεδομένων. Όμως η μελέτη των διαφόρων τεχνικών συνδυασμού των προβλέψεων μπορεί τελικά να οδηγήσει στον προσδιορισμό πιο κατάλληλων προτύπων συμπεριφοράς και επομένως στη δημιουργία καλύτερων ατομικών μοντέλων. Αν ο συνδυασμός διαφορετικών μοντέλων παράγει πιο ακριβείς προβλέψεις, είναι θεωρητικά δυνατή η κατασκευή ενός μοντέλου το οποίο να κάνει βέλτιστη χρήση των διαφορετικών μορφών πληροφορίας που εμπεριέχονται στις προβλέψεις των μοντέλων αυτών.

Έχουμε τον υπολογισμό του μέσου όρου των προβλέψεων που προκύπτουν από διάφορες μεθόδους πρόβλεψης και τον υπολογισμό του μέσου όρου με χρήση συντελεστών βαρύτητας, οι οποίοι εξαρτώνται από την σχετική ακρίβεια της κάθε μεθόδου και από την συνδιακύμανση των σφαλμάτων πρόβλεψης.

Τα αποτελέσματα από έρευνες και μελέτες που έχουν γίνει μέχρι σήμερα αποδεικνύουν ότι ο συνδυασμός προβλέψεων αποτελεί μια πολύ ισχυρή στρατηγική για την μείωση των σφαλμάτων πρόβλεψης. Δεν έχουν διερευνηθεί σε όλη τους την έκταση το πόσες και ποιες μέθοδοι πρόβλεψης πρέπει να συνδυαστούν για να παράγουν την τελική πρόβλεψη καθώς και την επιλογή των συντελεστών βαρύτητας. Συχνά επικρατεί η άποψη της επιλογής μεθόδων που να διαφέρουν σημαντικά ως προς την ερμηνεία των δεδομένων και ως προς τον τρόπο επεξεργασίας τους. Μια εναλλακτική άποψη είναι η χρήση μεθόδων που θεωρούνται πιο κατάλληλες για την συγκεκριμένη μορφή των δεδομένων.

Όσον αφορά τους συντελεστές βαρύτητας έχει αποδειχθεί ότι σε αρκετές περιπτώσεις ο υπολογισμός του απλού μέσου όρου των προβλέψεων οδηγεί σε αποτελέσματα το ίδιο ικανοποιητικά με αυτά πιο πολύπλοκων τεχνικών συνδυασμού. Σε περιπτώσεις όμως που μια μέθοδος δίνει πιο ακριβή αποτελέσματα από κάποια άλλη, είναι προφανές ότι ο μέσος όρος των προβλέψεων δεν θα είναι ικανοποιητικός. Το μέτρο της σχετικής ακρίβειας κάθε μεθόδου σε μια συγκεκριμένη περίπτωση θα μπορούσε να χρησιμοποιηθεί για την επιλογή των συντελεστών βαρύτητας. Επιπλέον το μέγεθος της ανομοιότητας των μεθόδων αποτελεί εξίσου σημαντική ένδειξη.

2.6 ΣΤΑΤΙΣΤΙΚΟΙ ΔΕΙΚΤΕΣ

Για την καλύτερη παρατήρηση και κατανόηση των πειραμάτων και των αποτελεσμάτων της διπλωματικής κρίνεται απαραίτητη η αναφορά σε ορισμένες βασικές στατιστικές έννοιες που χρησιμοποιούνται ευρέως στην ανάλυση των χρονοσειρών:

➤ Μέση τιμή (mean) : $\bar{Y} = \frac{1}{n} \sum Y_i$

Όπου n το πλήθος των παρατηρήσεων του δείγματος και $\sum Y_i$ το άθροισμα των παρατηρήσεων.

➤ Διάμεσος (median) : → η μεσαία παρατήρηση αν (n) περιττός και

→ ο μέσος των δύο μεσαίων παρατηρήσεων αν (n) άρτιος

➤ Mean Absolute Deviation: $MAD = \frac{1}{n} \sum |Y_i - \bar{Y}|$

➤ Mean Square Deviation: $MSD = \frac{1}{n} \sum (Y_i - \bar{Y})^2$

➤ Διακύμανση (Variance) : $S^2 = \frac{1}{n-1} \sum (Y_i - \bar{Y})^2$

➤ Τυπική Απόκλιση (Standard Deviation): $S = \sqrt{S^2}$

➤ Συνδιακύμανση (Covariance): $COV_{xy} = \frac{1}{n-1} \sum (X_i - \bar{X})(Y_i - \bar{Y})$

➤ Συσχέτιση (Correlation) : $r_{xy} = \frac{COV_{xy}}{S_x S_y}$, $+1 \geq r_{xy} \geq -1$

➤ Αυτοδιακύμανση (Autocovariance) : $C_k = \frac{1}{n} \sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})$

➤ Αυτοσυσχέτιση (Autocorrelation) : $r_k = \frac{C_k}{\sum_1^n (Y_i - \bar{Y})^2}$

2.7 ΔΕΙΚΤΕΣ ΣΦΑΛΜΑΤΩΝ

Για να μετρήσουμε την ακρίβεια των προβλέψεων που εξάγονται από κάποιο μοντέλο, απαιτείται ο υπολογισμός δεικτών σφάλματος. Ενδεικτικά παρατίθενται κάποιοι τύποι υπολογισμού συγκεκριμένων δεικτών σφάλματος:

- Το σφάλμα της πρόβλεψης ορίζεται ως η διαφορά μεταξύ της πραγματικής τιμής και της τιμής της πρόβλεψης για την αντίστοιχη χρονική περίοδο:

$$e_t = Act - F$$

- Μέσο σφάλμα: $ME = \frac{1}{n} \sum_{t=1}^n e_t$

Αποτελεί συστηματικό σφάλμα δείγματος.

- Μέσο Απόλυτο Σφάλμα: $MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$

- Μέσο Τετραγωνικό Σφάλμα: $MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$

Μετρά την διασπορά των σφαλμάτων πρόβλεψης. Τα μεγάλα σφάλματα αποκτούν μεγαλύτερο βάρος από την περίπτωση που χρησιμοποιείται η Μέση Απόλυτη Απόκλιση (MAD).

- Μέσο Ποσοστιαίο Σφάλμα: $MPE = \frac{1}{n} \sum_{t=1}^n PE_t = \frac{1}{n} \sum_{t=1}^n \left(\frac{Act-F}{Act} \right) 100$

- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα: $MAPE = \frac{\sum_{i=1}^n APE}{n}$, όπου $APE = \left| \frac{F-Act}{Act} \right|$

Μετρά την διασπορά των σφαλμάτων πρόβλεψης αναφορικά με το επίπεδο της ζήτησης.

- Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα:

$$SMAPE = \frac{\sum_{i=1}^n \left| \frac{F_i - Act_i}{\frac{F_i + Act_i}{2}} \right|}{n} \cdot 100$$

Οι δείκτες σφάλματος μετρούν την προσαρμογή του μοντέλου στα ιστορικά δεδομένα. Βέβαια πρέπει να σημειωθεί ότι ένας μηδενικός δείκτης σφάλματος δεν σημαίνει πάντα και καλό μοντέλο πρόβλεψης αφού σε πολλές τέτοιες περιπτώσεις παρατηρείται το πρόβλημα της υπερπροσαρμογής.

Στην παρούσα διπλωματική, για την μελέτη και την αξιολόγηση των προβλέψεων χρησιμοποιήθηκε το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (MAPE) καθώς και το Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (SMAPE).

3|| Η ΜΕΘΟΔΟΣ Θ

Σκοπός της παρούσας διπλωματικής εργασίας είναι η βελτιστοποίηση της μεθόδου Θ υπό την έννοια της ελαχιστοποίησης του σφάλματος πρόβλεψης με χρήση Νευρωνικών Δικτύων. Η μέθοδος Θ είναι μια νέα μέθοδος πρόβλεψης η οποία χρησιμοποιήθηκε για παραγωγή προβλέψεων στον διαγωνισμό M3 που διοργανώθηκε το 2000 από τους S.Makridakis και M.Hibon και κατέλαβε την πρώτη θέση ανάμεσα σε 24 άλλες μεθόδους πρόβλεψης που συμμετείχαν στον διαγωνισμό.

3.1 ΓΕΝΙΚΑ

Η μέθοδος Θ (Assimakopoulos et.al.1999, 2000) αποτελεί μια διαφορετική προσέγγιση της αποσύνθεσης με στόχο την παραγωγή καλύτερων προβλέψεων. Είναι μια νέα μονοδιάστατη μέθοδος πρόβλεψης η οποία βασίζεται στην ιδέα της μετατροπής των τοπικών καμπυλοτήτων μιας χρονοσειράς μέσω του συντελεστή θ , ο οποίος εφαρμόζεται απευθείας (πολλαπλασιαστικά) στις διαφορές δεύτερης τάξης των δεδομένων. Η χρονοσειρά που προκύπτει διατηρεί τη μέση τιμή και την κλίση των αρχικών δεδομένων αλλά όχι τις τοπικές καμπυλότητες. Οι καινούριες χρονοσειρές που παράγονται ονομάζονται γραμμές Θ (Theta Lines). Βασικό ποιοτικό χαρακτηριστικό των γραμμών Θ είναι η καλύτερη προσέγγιση της μακροπρόθεσμης συμπεριφοράς των δεδομένων ή η ανάδειξη των βραχυπρόθεσμων χαρακτηριστικών, ανάλογα με τη τιμή του συντελεστή θ ($\theta < 1$, $\theta > 1$ αντίστοιχα).

Η προτεινόμενη μέθοδος αποσυνθέτει την αρχική χρονοσειρά σε δύο ή περισσότερες γραμμές Θ . Αυτές οι γραμμές μελετώνται και προεκτείνονται ξεχωριστά στο μέλλον και οι αντίστοιχες παραγόμενες προβλέψεις συνδυάζονται με ίσα βάρη. Ο απλός συνδυασμός δυο γραμμών Θ , $\Theta=0$ (ευθεία γραμμή) και $\Theta=2$ (διπλασιασμός τοπικών καμπυλοτήτων) υιοθετήθηκε με σκοπό να παραχθούν προβλέψεις για τις 3003 χρονοσειρές του διαγωνισμού M3. Τα αποτελέσματα της μεθόδου ήταν πολύ ικανοποιητικά, ιδιαίτερα για τις μηνιαίες χρονοσειρές και τα μικροοικονομικά δεδομένα.

Στο παρελθόν είχαν γίνει πολλές προσπάθειες για παραγωγή προβλέψεων βασισμένες καθαρά στην κλασική αποσύνθεση (Makridakis et.al. ,1984). Τα βασικά χαρακτηριστικά που συνήθως διακρίνονται και απομονώνονται είναι οι συνιστώσες τάσης, κύκλου, εποχιακότητας και τυχαιότητας. Η κάθε συνιστώσα προεκτείνεται ξεχωριστά στο μέλλον και οι παραγόμενες προβλέψεις συνδυάζονται με ίσα βάρη συνθέτοντας έτσι την τελική πρόβλεψη για την υπό εξέταση χρονοσειρά. Αυτή η προσέγγιση όμως δεν συνίσταται συχνά και αυτό κυρίως γιατί εντοπίζονται δυσκολίες στην επιτυχή απομόνωση του συντελεστή σφάλματος όπως και στην παραγωγή ικανών προβλέψεων στη γραμμική τάσης-κύκλου. Ίσως η μόνη τεχνική που έχει βρεθεί να παράγει ικανοποιητικές προβλέψεις είναι η εφαρμογή της μεθόδου εκθετικής εξομάλυνσης γραμμικής τάσης (Holt) και της μεθόδου εκθετικής

εξομάλυνσης φθίνουσας τάσης σε αποεποχικοποιημένα δεδομένα. Τα τελικά αποτελέσματα προκύπτουν με επαναεποχικοποίηση των παραγόμενων προβλέψεων.

Η μέθοδος Θ προτείνει μια διαφορετική προσέγγιση της αποσύνθεσης: την αποσύνθεση των αποεποχικοποιημένων δεδομένων σε συνιστώσες βραχυπρόθεσμης και μακροπρόθεσμης τάσης. Η πρόκληση για τη μέθοδο αυτή ήταν η αύξηση του βαθμού της αξιοποίησης των χρήσιμων πληροφοριών που προκύπτουν από τα δεδομένα, πριν την εφαρμογή μιας μεθόδου πρόβλεψης. Διαισθητικά, τέτοιες πληροφορίες έχουν βραχυπρόθεσμες και μακροπρόθεσμες συνιστώσες. Αυτές οι συνιστώσες αναδεικνύονται με τη μέθοδο Θ και εξετάζονται ξεχωριστά. Ουσιαστικά η μέθοδος Θ λειτουργεί σαν ένας μεγεθυντικός φακός μέσα από τον οποίο οι διακυμάνσεις των χρονοσειρών μικραίνουν ή μεγεθύνονται ανάλογα. Ο συνδυασμός των προβλέψεων των συνιστωσών γίνεται πιο αποτελεσματικός.

Ο συνδυασμός προβλέψεων κάτω από συγκεκριμένες προϋποθέσεις βελτιώνει την ακρίβεια των προβλέψεων (Clemen, 1989). Ο λόγος βρίσκεται στη στάθμιση των σφαλμάτων που προκύπτουν από κάθε μέθοδο πρόβλεψης ξεχωριστά. Αυτά τα σφάλματα οφείλονται στην αστάθεια των προτύπων των χρονοσειρών, στην ελαχιστοποίηση των διαδικασιών για την επιλογή του καλύτερου μοντέλου ή ακόμα και σε λάθη μετρήσεων (Makridakis, Wheelright & Hyndman, 1998). Πάνω από όλα όμως τα σφάλματα είναι συνδεδεμένα με την φύση του εκάστοτε επιλεγμένου μοντέλου. Κάθε μοντέλο ή συναρτησιακή σχέση εκθέτει την δική του λογική στα δεδομένα με ένα περισσότερο ή λιγότερο ευέλικτο τρόπο και με αυτή την ίδια λογική προεκτείνει τα δεδομένα στο μέλλον. Αν υπάρχει μια ποσότητα χρήσιμων πληροφοριών μέσα σε μία χρονοσειρά, τότε υπάρχει και ένας αντίστοιχος βαθμός αξιοποίησης αυτής της πληροφορίας σε κάθε μέθοδο πρόβλεψης που εφαρμόζεται. Από αυτή την άποψη η μέθοδος Θ μπορεί να θεωρηθεί ως μια εναλλακτική μέθοδο αποσύνθεσης ή/και ως μια επέκταση της ιδέας των γραμμικών συνδυασμών παραγόμενων προβλέψεων.

3.2 TO MONTEΛO Θ

Το μοντέλο Θ είναι βασισμένο στην ιδέα της μεταβολής των τοπικών καμπυλοτήτων μιας χρονοσειράς. Αυτή η μεταβολή επιτυγχάνεται από ένα συντελεστή, καλούμενος συντελεστής θ , ο οποίος εφαρμόζεται στις δευτερες διαφορές των δεδομένων, σύμφωνα με την ακόλουθη σχέση:

$$X_{new}''(\theta) = \theta \cdot X_{data}''$$

Όπου: $X_{data}'' = X_t - 2X_{t-1} + X_{t-2}$, σε χρόνο t .

Αν οι τοπικές καμπυλότητες μειώνονται σταδιακά τότε η χρονοσειρά εξομαλύνεται, όπως φαίνεται στο παρακάτω σχήμα. Η χρονοσειρά αυτή έχει ληφθεί από τα δεδομένα του διαγωνισμού M3.




Fig. 1. M3-Comp. Series 200, the Theta-model deflation.

Σχήμα 3.1 Χρονοσειρά 200 από το Διαγωνισμό M3-εξομάλυνση

Όσο μικρότερη είναι η τιμή του συντελεστή θ , τόσο μεγαλύτερη είναι η μείωση των τοπικών καμπυλοτήτων (εξομάλυνση). Στην ακραία περίπτωση όπου $\theta=0$, η χρονοσειρά μετατρέπεται στην ευθεία γραμμή παλινδρόμησης. Η διαρκής μείωση των διακυμάνσεων μικραίνει τις απόλυτες διαφορές μεταξύ διαδοχικών παρατηρήσεων κάτι που έχει σαν αποτέλεσμα, από ποιοτικής άποψης, την εμφάνιση τάσης στα δεδομένα της νέας χρονοσειράς.

Σημειώνουμε ότι ο συντελεστής θ μπορεί να πάρει και αρνητικές τιμές οι οποίες αντιστρέφουν τις τοπικές καμπυλότητες. Για $\theta=-1$ έχουμε ολική αναστροφή των τοπικών καμπυλοτήτων (φαινόμενο “καθρέπτη”).

Αντίστοιχα, εάν οι τοπικές καμπυλότητες αυξηθούν ($\theta>1$) τότε η χρονοσειρά διευρύνεται όπως φαίνεται στο σχήμα 2:




Fig. 2. M3-Comp. Series 200, the Theta-model dilation.

Σχήμα 3.2 Χρονοσειρά 200 από το Διαγωνισμό M3-διεύρυνση

Όπως παρατηρούμε και στο σχήμα, όσο μεγαλύτερος είναι ο βαθμός της διεύρυνσης, τόσο μεγαλύτερη είναι και η μεγέθυνση της βραχυπρόθεσμης συμπεριφοράς.

Ακολουθώντας αυτή την διαδικασία, έχουν κατασκευασθεί ένα σύνολο από νέες χρονοσειρές, τις λεγόμενες γραμμές Θ . Αυτές οι γραμμές είναι δυνατόν να κατασκευασθούν με πολλούς τρόπους. Εάν επιλεγεί να κατασκευασθούν σύμφωνα με τη θεωρία των ελαχίστων τετραγώνων (Makridakis, 1998 p.54-62) τότε οι γραμμές Θ διατηρούν την μέση τιμή και την κλίση παλινδρόμησης της αρχικής χρονοσειράς.

3.3 ΓΕΝΙΚΗ ΔΙΑΤΥΠΩΣΗ

Η αρχική χρονοσειρά αποσυντίθεται σε δύο ή περισσότερες γραμμές Θ . Κάθε μια από τις γραμμές Θ προεκτείνεται στο μέλλον ξεχωριστά και οι προβλέψεις απλά συνδυάζονται με ίσα βάρη. Οποιαδήποτε μέθοδος πρόβλεψης μπορεί να χρησιμοποιηθεί για να παραχθούν προβλέψεις για την κάθε γραμμή Θ , ανάλογα φυσικά με την ήδη υπάρχουσα εμπειρία για την δεδομένη χρονοσειρά (Fildes, Hibon, Makridakis & Meade, 1998). Ένας διαφορετικός συνδυασμός των γραμμών Θ μπορεί να εφαρμοστεί για κάθε ορίζοντα πρόβλεψης.


Ας θεωρήσουμε μια από τις πιο απλές περιπτώσεις όπου η αρχική χρονοσειρά αποσυντίθεται σε δύο γραμμές Θ , για τιμές του συντελεστή θ , $\theta=0$ και $\theta=2$:

$$\text{Data} = \frac{1}{2} (L(\theta=0) + (L(\theta=2)))$$

Όπου $L(\theta=a)$ είναι η γραμμή Θ για τιμή του συντελεστή θ ίση με a .

Η πρώτη γραμμή Θ ($\theta=0$) είναι η ευθεία της απλής γραμμικής παλινδρόμησης των δεδομένων και η δεύτερη έχει δεύτερες διαφορές διπλάσιες της αρχικής χρονοσειράς. Αυτή είναι η περίπτωση όπου δύο γραμμές Θ , με τιμές παραμέτρου θ συμμετρικές ως προς τη μονάδα, συνθέτονται. Η πρώτη γραμμή ($L(\theta=0)$) περιγράφει την χρονοσειρά μέσα από μια γραμμική τάση. Η δεύτερη ($L(\theta=2)$) έχει διπλασιάσει τις τοπικές καμπυλότητες τονίζοντας έτσι την βραχυπρόθεσμη συμπεριφορά. Η πρώτη γραμμή προεκτείνεται στο μέλλον σύμφωνα με την κλασσική θεωρία παλινδρόμησης. Αντίστοιχα η δεύτερη προεκτείνεται με εκθετική εξομάλυνση σταθερού επιπέδου SES. Ο απλός γραμμικός συνδυασμός των δύο προβλέψεων δίνει την τελική πρόβλεψη για το μοντέλο Θ . Αυτή η διαδικασία απεικονίζεται στο παρακάτω σχήμα:

Figure 1. M3 Competition - N000TYB001-YEARLY/MCRO



Σχήμα 3.3 Οι δύο γραμμές $L(\theta=0)$ και $L(\theta=2)$ και η τελική πρόβλεψη του μοντέλου

3.4 ΒΗΜΑΤΑ ΔΙΑΔΙΚΑΣΙΑΣ ΠΑΡΑΓΩΓΗΣ ΠΡΟΒΛΕΨΕΩΝ ΜΕ ΤΗ ΜΕΘΟΔΟ Θ

➤ *ΒΗΜΑ 0: Τέστ Εποχιακότητας*

Η κάθε χρονοσειρά ελέγχεται για εποχιακή συμπεριφορά με κριτήριο την τιμή του συντελεστή αυτοσυσχέτισης με lag ένα έτος (π.χ. για μηνιαία δεδομένα-12) συγκρινόμενη με την τιμή 1.645 (τιμή της t-κατανομής για πιθανότητα 0.1)*

➤ *ΒΗΜΑ 1: Αποεποχικοποίηση*

Η χρονοσειρά αποεποχικοποιείται με την κλασσική μέθοδο αποσύνθεσης.

➤ BHMA 2: Αποσύνθεση

Κάθε χρονοσειρά αποσυντίθεται σε δύο γραμμές Θ , για τιμές $\theta=0$ και $\theta=2$.

➤ BHMA 3: Πρόβλεψη

Η γραμμή $L(\theta=0)$ προεκτείνεται με απλή γραμμική παλινδρόμηση ενώ η $L(\theta=2)$ με εκθετική εξομάλυνση σταθερού επιπέδου.

➤ BHMA 4: Συνδυασμός

Οι προηγούμενες προβλέψεις συνδυάζονται με ίσα βάρη.

➤ BHMA 5: Εποχικοποίηση

Οι τελικές προβλέψεις εποχικοποιούνται.

3.5 ΑΞΙΟΛΟΓΗΣΗ ΜΕΘΟΔΟΥ Θ

Το δυνατό στοιχείο της μεθόδου έγκειται στην αποσύνθεση των αρχικών δεδομένων. Οι δύο συνιστώσες περιέχουν πληροφορίες, οι οποίες είναι χρήσιμες για την διαδικασία πρόβλεψης αλλά χάνονται ή δεν μπορούν να αναγνωριστούν και να αξιοποιηθούν από τα υπάρχοντα μοντέλα πρόβλεψης όταν αυτά εφαρμόζονται απευθείας στα αρχικά δεδομένα. Ιδιαίτερα στην περίπτωση της γραμμής $L(\theta=0)$ το φαινόμενο αυτό είναι πιο εύκολα αντιληπτό. Η ευθεία γραμμή παλινδρόμησης περιέχει πληροφορίες για την μακροπρόθεσμη τάση της χρονοσειράς η οποία αμελείται όταν η μέθοδος προσαρμόζεται σε πιο πρόσφατες τάσεις. Από την άλλη πλευρά, όταν χρησιμοποιείται μόνο η γραμμική τάση, όλες οι πολύτιμες πληροφορίες των βραχυχρόνιων διακυμάνσεων αγνοούνται.

Χαρακτηριστικό παράδειγμα είναι η επίδοση του μοντέλου Θ στις μηνιαίες χρονοσειρές του διαγωνισμού M3. Τα μηνιαία δεδομένα του διαγωνισμού έχουν χαρακτηριστεί γενικά από σχετικά μεγάλες διακυμάνσεις. Αυτό το γεγονός δεν επιτρέπει στις περισσότερες μεθόδους να αναγνωρίσουν την μακροπρόθεσμη τάση και κατά συνέπεια να την λάβουν σοβαρά υπόψη τους στην παραγωγή προβλέψεων.

Στη περίπτωση του μοντέλου Θ , η μακροπρόθεσμη τάση εξασφαλίζεται από την προέκταση της γραμμής $\theta=0$. Ταυτόχρονα η ύπαρξη και της γραμμής $\theta=2$

λειτουργεί σαν αντίβαρο στην χρησιμοποίηση μόνο της απλής γραμμικής παλινδρόμησης και εξασφαλίζει την αξιοποίηση και της βραχυπρόθεσμης πληροφορίας. Ως αποτέλεσμα το σημείο εκκίνησης των προβλέψεων πετυχαίνει καλύτερη προσέγγιση του σωστού επιπέδου, και μια και η προέκταση είναι οριζόντια εξασφαλίζεται μια συντηρητική μεν σταθερή δε συνέχιση της μακροπρόθεσμης τάσης.

Μια πιο μαθηματική ανάλυση των όσων αναφέραμε παραπάνω παρουσιάζεται στα παραρτήματα Α και Β που βρίσκονται στο ολοκληρωμένο άρθρο που δημοσιεύτηκε στο international journal of forecasting(2000):

“The Theta Model: a decomposition approach to forecasting” V.Assimakopoulos , K.Nikolopoulos.

Στο παράρτημα Α αποδεικνύεται ότι οι γραμμές Θ που κατασκευάζονται σύμφωνα με τη θεωρία των ελαχίστων τετραγώνων διατηρούν την μέση τιμή και την κλίση παλινδρόμησης της αρχικής χρονοσειράς. Στο παράρτημα Β αποδεικνύεται ότι η γραμμή Θ $L(\theta=0)$ είναι η ευθεία της απλής γραμμικής παλινδρόμησης και ότι αν δύο γραμμές παράγονται από συμμετρικούς συντελεστές θ , τότε η μέση τιμή των δύο αυτών γραμμών αναπαράγει τα αρχικά δεδομένα.

3.6 ΕΝΑΣ ΕΝΑΛΛΑΚΤΙΚΟΣ ΤΡΟΠΟΣ ΠΑΡΑΓΩΓΗΣ ΤΗΣ ΓΡΑΜΜΗΣ $L(\theta=2)$

Από τα παραπάνω παραρτήματα παρατηρούμε ότι κάθε γραμμή $L(\theta)$ προκύπτει από την επίλυση ενός γραμμικού συστήματος εξισώσεων του οποίου οι συντελεστές εξαρτώνται από τα δεδομένα της αρχικής χρονοσειράς και την τιμή της παραμέτρου θ .

Για δύο συμμετρικούς συντελεστές θ όμως ισχύει η εξής σχέση:

$$\text{Data} = \frac{1}{2} (L(\theta=1-a) + (L(\theta=1+a))) (1)$$

Έτσι συμπεραίνουμε ότι οι δύο γραμμές θ με συμμετρικούς συντελεστές θ , μπορούν να παραχθούν πιο εύκολα, χωρίς να χρειάζεται η επίλυση του γραμμικού συστήματος.

Αυτό γίνεται ως εξής:

Για $a=1$ από την εξίσωση (1) προκύπτει:

$$\text{Data} = \frac{1}{2} (L(\theta=0) + (L(\theta=2))) \Rightarrow$$

$$\text{Data} = \frac{1}{2} (LRL + (L(\theta=2))) \Rightarrow$$

$$2\text{Data} = LRL + (L(\theta=2)) \Rightarrow$$

$$\underline{L(\theta=2) = 2\text{Data} - LRL} \quad (2)$$

Με αυτό τον τρόπο παράγεται η $L(\theta=2)$ πιο εύκολα αφού η LRL μπορεί να παραχθεί σύμφωνα με την κλασσική θεωρία παλινδρόμησης. Κατά συνέπεια αλλάζουν και τα βήματα της διαδικασίας παραγωγής των προβλέψεων. Αρχικά παράγουμε την ευθεία παλινδρόμησης και την επεκτείνουμε στο μέλλον. Στη συνέχεια παράγουμε την γραμμή $L(\theta=2)$ σύμφωνα με τη σχέση (2) και την προεκτείνουμε στο μέλλον με τη μέθοδο SES. Συνδυάζοντας με ίσα βάρη τις επί μέρους προβλέψεις, παράγουμε τις τελικές προβλέψεις της μεθόδου.

3.7 ΣΗΜΕΙΑΚΕΣ ΠΡΟΒΛΕΨΕΙΣ

Η εξίσωση πρόβλεψης για την απλή εκθετική εξομάλυνση σταθερού επιπέδου SES είναι (Makridakis et al. 1983, eq. 3-19,3-22):

$$F_{t+1} = F_t + a(Y_t - F_t), \text{ or}$$

$$F_{t+1} = aY_t + (1 - a)F_t, (1)$$

Όπου a η παράμετρος εξομάλυνσης.

Εφαρμόζοντας το μοντέλο στην γραμμή $\Theta L(\theta=2)$, προκύπτει:

$$F_{t+1}^{(L(\theta=2))} = a \cdot L(\theta = 2)_t + (1 - a) \cdot F_t^{L(\theta=2)}, (2)$$

Όπου \hat{a} είναι η παράμετρος εξομάλυνσης όπως προκύπτει όταν εφαρμοστεί SES στη γραμμή $L(\theta=2)$.

Από τη θεωρία γραμμικής παλινδρόμησης προκύπτει:

$$F_{t+1}^{(L(\theta=0))} = \hat{a} + \hat{b}t = [\hat{a} + \hat{b}(t-1)] + \hat{b} \Rightarrow$$

$$F_{t+1}^{(L(\theta=0))} = F_t^{(L(\theta=0))} + \hat{b}, (3)$$

Κάνοντας μερικές αντικαταστάσεις και εφαρμόζοντας την ιδιότητα της μεθόδου Θ :

$$\text{Data} = \frac{1}{2} (L(\theta=0) + (L(\theta=2)))$$

η εξίσωση πρόβλεψης για την παραγωγή σημειακών προβλέψεων υπολογίζεται ως ακολούθως:

$$(2) + (3) \Rightarrow F_{t+1}^{(L(\theta=2))} + F_{t+1}^{(L(\theta=0))} = \hat{a} \cdot L(\theta=2)_t + (1-\hat{a}) \cdot F_t^{L(\theta=2)} + F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$F_{t+1}^{(L(\theta=2))} + F_{t+1}^{(L(\theta=0))} = \hat{a} \cdot L(\theta=2)_t + (1-\hat{a}) \cdot F_t^{L(\theta=2)} + F_t^{(L(\theta=0))} - \hat{a} F_t^{(L(\theta=0))} + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$F_{t+1}^{(L(\theta=2))} + F_{t+1}^{(L(\theta=0))} = \hat{a} \cdot L(\theta=2)_t + (1-\hat{a}) \cdot F_t^{L(\theta=2)} + (1-\hat{a}) F_t^{(L(\theta=0))} + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$[F_{t+1}^{(L(\theta=2))} + F_{t+1}^{(L(\theta=0))}] = \hat{a} \cdot L(\theta=2)_t + (1-\hat{a}) [F_t^{L(\theta=2)} + F_t^{(L(\theta=0))}] + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$2F_{t+1} = \hat{a} \cdot L(\theta=2)_t + (1-\hat{a}) 2F_t + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$2F_{t+1} = \hat{a} (2Y_t - F_t^{(L(\theta=0))}) + (1-\hat{a}) 2F_t + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$2F_{t+1} = 2\hat{a} Y_t - \hat{a} F_t^{(L(\theta=0))} + (1-\hat{a}) 2F_t + \hat{a} F_t^{(L(\theta=0))} + \hat{b} \Rightarrow$$

$$2F_{t+1} = 2\hat{a} Y_t + (1-\hat{a}) 2F_t + \hat{b} \Rightarrow$$

$$F_{t+1} = a Y_t + (1 - a) F_t + \frac{\hat{b}}{2}$$

Άρα (Assimakopoulos et.al.2002):

- Η μέθοδος Θ περιέχει όρο τάσης. Ο όρος τάσης είναι σταθερός και ίσος με το μισό της κλίσης παλινδρόμησης (regression slope) της αρχικής χρονοσειράς.
- Η παράμετρος a του μοντέλου υπολογίστηκε μετά από εφαρμογή SES στη γραμμή L($\theta=2$).

3.8 ΣΤΟΧΑΣΤΙΚΟ ΜΟΝΤΕΛΟ

Μπορούμε να αναγνωρίσουμε το λανθάνων στοχαστικό μοντέλο της μεθόδου Θ μέσω μιας ανάλυσης στο χώρο της κατάστασης (Assimakopoulos et.al. 2002):

Έστω:

$$X_t = l_{t-1} + b + e_t, (5)$$

$$l_t = l_{t-1} + b + a e_t, (6)$$

$$\hat{X}_{t+m} = l_n + m b, (7)$$

Όπου: $t=2..n, l_1=X_1, e_1 \sim \text{NID}(0, \sigma^2)$

Θα πρέπει να προσέξουμε ότι η παράμετρος επιπέδου δεν υπολογίζεται με διαδικασία ελαχιστοποίησης του MSE πάνω στην αρχική χρονοσειρά αλλά μέσω διαδικασίας ελαχιστοποίησης πάνω στη γραμμή L($\theta=2$).

Κάνοντας αντικαταστάσεις προκύπτει ότι:

$$(5)-(6) \Rightarrow l_t = X_t + (a - 1)e_t, (8)$$

Και

$$(5) \Rightarrow X_t = X_{t-1} + b + (a - 1)e_{t-1} + e_t, (9)$$

$$\Rightarrow e_t = X_t - X_{t-1} - b - (a - 1)e_{t-1}, (10)$$

Έτσι, η εξίσωση πρόβλεψης (7) μπορεί να ξαναγραφεί ως:

$$(7) \Rightarrow \hat{X}_{t+1} = X_t + b + (a - 1)e_t, (11)$$

Μπορούμε να εκφράσουμε την πρόβλεψη σε συνάρτηση μόνο των ιστορικών δεδομένων, με διαδοχικές αντικαταστάσεις του όρου σφάλματος από την εξίσωση (10):

$$(11) \xrightarrow{\text{διαδοχικά (10)}} \hat{X}_{t+1} = \left\{ \alpha \sum_{i=0}^{n-1} (1-a)^i X_{n-i} + (1-a)^n X_1 \right\} + \frac{b}{a} [1 - (1-a)^n]$$

Έτσι:

$$\hat{X}_{t+1} = \hat{X}_{t+1 [SES(a)]} + \frac{b}{a} [1 - (1-a)^n], (12)$$

Για μακρινότερους ορίζοντες ($m > 1$) η εξίσωση πρόβλεψης γίνεται:

$$\hat{X}_{t+m} = \hat{X}_{t+1} + (m-1)b \Rightarrow$$

$$\hat{X}_{t+m} = \hat{X}_{t+1 [SES(a)]} + b \left[m - 1 + \frac{1 - (1-a)^n}{a} \right], (13)$$

Για να πάρουμε ταυτόσημες προβλέψεις με τη μέθοδο Θ, θέτουμε:

$$\left\{ \begin{array}{l} \alpha \equiv \hat{a} \\ b \equiv \frac{\hat{b}}{2} \end{array} \right\}$$

Όπου b, ο όρος τάσης, σταθερός και ίσος με το μισό της τάσης παλινδρόμησης και η παράμετρος \hat{a} έχει παραχθεί από την γραμμή $L(\theta=2)$.

Έτσι, η εξίσωση πρόβλεψης για την μέθοδο Θ (στην ειδική περίπτωση των δύο γραμμών $L(\theta=0)$ και $L(\theta=2)$) είναι:

$$\hat{X}_{t+m} = \hat{X}_{t+1 [SES(\hat{a})]} + \frac{\hat{b}}{2} \left[m - 1 + \frac{1 - (1-\hat{a})^n}{\hat{a}} \right], (14)$$

Όπου ο πρώτος όρος σε αυτήν την εξίσωση είναι το μοντέλο απλής εκθετικής εξομάλυνσης (SES).

Επιπλέον, μπορούμε να πάρουμε διαστήματα εμπιστοσύνης για προβλέψεις ορίζοντα m (Yar and Chatfield, 1990):

$$\hat{X}_{t+m} [P.1.95\%] = \hat{X}_{t+m} \mp 1.96\sigma\sqrt{1 + (m-1)a^2}, \quad (15)$$

Σε ανάλογα συμπεράσματα καταλήγουμε κάνοντας ανάλυση σύμφωνα με τη μεθοδολογία των μοντέλων ARIMA, αφού η εξίσωση (9) μπορεί να ξαναγραφεί ως:

$$\nabla X_t = b - [1 + (1 - \alpha)B]e_t, \quad (16)$$

που είναι μια διαδικασία ARIMA(0,1,1) με ντετερμινιστικό drift (Box et.al.1994,p.125-126).

4|| ΔΙΑΓΩΝΙΣΜΟΙ ΠΡΟΒΛΕΨΕΩΝ

4.1 ΕΙΣΑΓΩΓΗ

Η ακρίβεια των προβλέψεων είναι, μεταξύ άλλων, σημαντικός παράγοντας για τη μείωση του κόστους και την παροχή καλύτερης εξυπηρέτησης στους καταναλωτές. Παρόλα αυτά, η διαθέσιμη γνώση και εμπειρία για τη βελτίωση της ακρίβειας για συγκεκριμένες καταστάσεις δεν είναι πάντα αξιοποιήσιμη. Η συνέπεια αυτού είναι επίκαιρες και ευκαιριακές απώλειες που μερικές φορές είναι αρκετά σημαντικές. Εμπειρικές έρευνες στον τομέα των προβλέψεων αποσκοπούν στην σύγκριση της ακρίβειας διάφορων μεθόδων πρόβλεψης έτσι ώστε η εφαρμογή του να είναι καθοριστική και όσο το δυνατόν πιο αντικειμενική. Οι διαγωνισμοί προβλέψεων είναι τέτοιες εμπειρικές έρευνες οι οποίες έχουν ως στόχο την σύγκριση της απόδοσης των διάφορων μεθόδων πρόβλεψης μέσα από την εφαρμογή τους σε ένα ,προκαθορισμένο για κάθε διαγωνισμό, εκτενές σύνολο από χρονοσειρές διαφορετικού μεγέθους και περιεχομένου. Κάθε ειδικός μπορεί να συμμετάσχει στο διαγωνισμό και να παράγει προβλέψεις για τις δεδομένες χρονοσειρές με την δική του ξεχωριστή μέθοδο πρόβλεψης. Με το που κατοχυρωθούν οι προβλέψεις από κάθε ειδικό, γίνεται αποτίμηση και σύγκριση αυτών με προβλέψεις άλλων ειδικών όπως και με τα αποτελέσματα κάποιων απλών μεθόδων που χρησιμοποιούνται ως σημεία αναφοράς. Οι διαγωνισμοί προβλέψεων εξασφαλίζουν την αντικειμενικότητα ενώ συγχρόνως εγγυώνται την γνώση των ειδικών.

4.2 ΓΕΝΙΚΕΣ ΠΑΡΑΤΗΡΗΣΕΙΣ ΓΙΑ ΤΟΥΣ ΔΙΑΓΩΝΙΣΜΟΥΣ

4.2.1 Επίδραση του τύπου των χρονοσειρών

Η σχετική ακρίβεια στις προβλέψεις διάφορων μεθόδων επηρεάζεται άμεσα τόσο από την χρονική απόσταση των παρατηρήσεων, δηλαδή τις περιόδους παρατηρήσεων σε 1 ημερολογιακό έτος (μηνιαίες, 3μηνιαίες, ετήσιες, εβδομαδιαίες, ημερήσιες ή ακόμα και τυχαίες χρονικά παρατηρήσεις), από το είδος των χρονοσειρών (βιομηχανικές, δημογραφικές, μακροοικονομικές, μικροοικονομικές ή διάφορων ειδών) καθώς και από την παρουσία ή όχι εποχιακότητας σε αυτές. Για παράδειγμα, κάποιες μέθοδοι μπορεί να συμπεριφέρονται πολύ καλά για μηνιαία

δεδομένα, ενώ στα ετήσια και στα 3μηνιαία δεδομένα να μην είναι και τόσο αποτελεσματικές.

Εξαιτίας του αποτελέσματος αυτού οι συγκρίσεις των δεικτών επίδοσης στους διαγωνισμούς προβλέψεων γίνεται ανά κατηγορία χρονοσειρών ώστε να αναδειχθεί η μέθοδος που υπερτερεί σε μια συγκεκριμένη κατηγορία. Οι παράγοντες οι οποίοι φαίνεται ότι επηρεάζουν την ακρίβεια των προβλέψεων είναι η τάση, η εποχιακότητα και η τυχαιότητα που υπάρχουν στα δεδομένα των χρονοσειρών. Πιστεύεται ότι όσο πιο μεγάλη είναι η τυχαιότητα στα δεδομένα, τόσο λιγότερη σημασία έχει η χρήση στατιστικά πολύπλοκων μεθόδων.

Είναι λοιπόν αναμενόμενο ότι οι μέθοδοι προβλέψεων που δεν λαμβάνουν την τάση υπόψη τους, δεν συμπεριφέρονται καλά σε σχέση με τις άλλες μεθόδους που την λαμβάνουν, σε δεδομένα χρονοσειρών που παρουσιάζουν σημαντική τάση όπως είναι τα ετήσια δεδομένα.

4.2.2 Επίδραση του ορίζοντα πρόβλεψης

Η σχετική ακρίβεια στις προβλέψεις διαφόρων μεθόδων επηρεάζεται άμεσα από τον ορίζοντα πρόβλεψης. Παρατηρείται λοιπόν το φαινόμενο άλλες μέθοδοι να υπερτερούν στις βραχυπρόθεσμες, άλλες στις μεσοπρόθεσμες και άλλες στις μακροπρόθεσμες προβλέψεις. Λόγω αυτού του γεγονότος, οι συγκρίσεις των διαφόρων μεθόδων γίνονται ανά ορίζοντα πρόβλεψης ή ανά ένα σύνολο οριζόντων που αντιπροσωπεύουν τις βραχυπρόθεσμες, μεσοπρόθεσμες και μακροπρόθεσμες παραχθείσες προβλέψεις.

Συνήθως για μικρό ορίζοντα πρόβλεψης (1 και 2 περιόδους μπροστά), στατιστικά και συναρτησιακά απλές μέθοδοι έχουν καλύτερες επιδόσεις ενώ όσο πιο πολύ μεγαλώνει ο ορίζοντας πρόβλεψης οι στατιστικά πολύπλοκες μέθοδοι είναι πιο αποδοτικές από τις απλές μεθόδους. Η εξήγηση είναι απλή αφού στις περισσότερες περιπτώσεις, για μικρό ορίζοντα πρόβλεψης οι τιμές των χρονοσειρών δεν παρουσιάζουν μεγάλες διαφορές από τις τελευταίες παρατηρήσεις.

4.2.3 Επίδραση της εποχιακότητας

Η σχετική ακρίβεια στις προβλέψεις διαφόρων μεθόδων επηρεάζεται άμεσα από το αν οι υπό εξέταση χρονοσειρές είναι εποχιακές ή όχι. Οι δείκτες επίδοσης των χρονοσειρών που δεν παρουσιάζουν εποχιακότητα είναι σε όλες τις περιπτώσεις πολύ καλύτεροι από τους αντίστοιχους δείκτες δεδομένων που παρουσιάζουν εποχιακότητα. Για αυτόν το λόγο, σε όλους τους διαγωνισμούς προβλέψεων πριν την εφαρμογή των διαφόρων μεθόδων στα δεδομένα γίνεται πρώτα ένας έλεγχος της εποχιακότητας και αναλόγως του αποτελέσματος είτε εφαρμόζουμε απευθείας τις μεθόδους στα δεδομένα μας είτε αποεποχικοποιούμε τα δεδομένα με κάποια από τις πολλές μεθόδους αποεποχικοποίησης που υπάρχουν. Κατόπιν προχωρούμε στην παραγωγή προβλέψεων και στον υπολογισμό των δεικτών σφάλματος. Συνήθως χρησιμοποιούμε σε όλες τις περιπτώσεις την ίδια μέθοδο αποεποχικοποίησης, ώστε να μην επηρεαστούν τα αποτελέσματα από το ποια μέθοδο αποεποχικοποίησης χρησιμοποιεί το κάθε μοντέλο. Εναλλακτικά μπορούμε βέβαια να εφαρμόσουμε μια μέθοδο αποεποχικοποίησης σε όλα τα δεδομένα μας θεωρώντας όλες τις χρονοσειρές που χρησιμοποιούμε ως εποχιακές.

4.2.4 Επίδραση του συνδυασμού των προβλέψεων

Ο συνδυασμός των προβλέψεων μπορεί να χρησιμοποιηθεί επικερδώς για την μείωση των δεικτών σφάλματος υπολογίζοντας απλά τον μέσο όρο των εξαγόμενων προβλέψεων των διάφορων μεθόδων. Άλλες μέθοδοι προβλέψεων συνδυάζουν τα αποτελέσματα που προκύπτουν με άνισα βάρη.

Τα αποτελέσματα από εμπειρικές μελέτες αλλά και από τους διαγωνισμούς πρόβλεψης που έχουν γίνει μέχρι σήμερα αποδεικνύουν ότι ο συνδυασμός προβλέψεων αποτελεί μια ισχυρή στρατηγική για την μείωση των σφαλμάτων πρόβλεψης και την παραγωγή ακριβέστερων προβλέψεων.

4.3 Η ΙΣΤΟΡΙΑ ΤΩΝ ΜΕΛΕΤΩΝ ΑΚΡΙΒΕΙΑΣ ΚΑΙ ΔΙΑΓΩΝΙΣΜΩΝ ΠΡΟΒΛΕΨΗΣ

Ταξιδεύοντας πίσω στο χρόνο, το 1969, ο Reid(1969, 1975),ο Newbold και ο Granger(1974) σύγκριναν ένα μεγάλο αριθμό χρονοσειρών για να προσδιορίσουν την ακρίβεια των προβλέψεων τους. Όμως, αυτές οι πρώτες μελέτες ακρίβειας βασίστηκαν σε ένα περιορισμένο αριθμό μεθόδων πρόβλεψης. Οι S.Makridakis και M.Hibon(1979) έκαναν την πρώτη προσπάθεια σύγκρισης ενός μεγάλου αριθμού από τις σημαντικότερες μεθόδους χρονοσειρών επί ενός μεγάλου συνόλου χρονοσειρών. Συνολικά συλλέχθηκαν 111 χρονοσειρές από ένα ευρύ πεδίο από διαθέσιμα δεδομένα, καλύπτοντας μια μεγάλη κλίμακα από πραγματικές καταστάσεις (επιχειρησιακές εταιρίες, βιομηχανίες και μακροδεδομένα). Το μεγαλύτερο συμπέρασμα της μελέτης τους αυτής ήταν ότι απλές μέθοδοι, όπως η εκθετική εξομάλυνση, υπερτερούν των πιο πολύπλοκων μεθόδων. Αυτό το συμπέρασμα ήρθε σε αντίθεση με την γενικά αποδεκτή άποψη της εποχής και δεν έγινε αποδεκτό από την πλειοψηφία των ερευνητών, κυρίως στον τομέα της στατιστικής. Για να απαντήσουν στις κριτικές και για να ενσωματώσουν τις προτάσεις των διάφορων ερευνητών για βελτίωση, ο Makridakis συνέχισε τις εμπειρικές συγκρίσεις των χρονοσειρών διοργανώνοντας τον Διαγωνισμό-M (Makridakis et.al.,1982).

Στον Διαγωνισμό-M ο αριθμός των χρονοσειρών που χρησιμοποιήθηκαν αυξήθηκε σε 1001 χρονοσειρές και ο αριθμός των μεθόδων πρόβλεψης σε 15 (με εννέα ακόμα παραλλαγές αυτών των μεθόδων να συμπεριλαμβάνονται). Επιπρόσθετα, περισσότερα κριτήρια ακρίβειας άρχισαν να χρησιμοποιούνται καθώς τα δεδομένα υποδιαιρούνται σε διάφορες κατηγορίες (micro, macro, βιομηχανικά κ.λπ.) με σκοπό να καθορίσουν γιατί μερικές μέθοδοι υπερτερούσαν από κάποιες άλλες. Παρόλα αυτά, η πιο σημαντική καινοτομία του διαγωνισμού-M ήταν πως ειδικοί ερευνητές ανέλαβαν να τρέξουν τις 1001 χρονοσειρές (ή ένα μικρότερο δείγμα από 111 χρονοσειρές όπου ο όγκος της εργασίας για την εφαρμογή της μεθόδου ήταν πολύ μεγάλος και χρονοβόρος για αν χρησιμοποιήσει και τις 1001 χρονοσειρές). Κάθε ειδικός παρείχε τις δικές του προβλέψεις οι οποίες συγκρίθηκαν με τα πραγματικά δεδομένα που δεν χρησιμοποιήθηκαν για την ανάλυση του μοντέλου

πρόβλεψης. Τα σφάλματα πρόβλεψης που προέκυψαν χρησιμοποιήθηκαν για τον υπολογισμό άλλων σημαντικών μέτρων ακρίβειας (Makridakis et.al.1982).

Τα αποτελέσματα του διαγωνισμού-M ήταν παρόμοια με αυτά της προηγούμενης έρευνας των S.Makridakis και M.Hibon και συνοψίζονται παρακάτω:

(α) Στατιστικά πολύπλοκες ή εξεζητημένες μέθοδοι δεν προσδίδουν απαραίτητα και πιο ακριβείς προβλέψεις από τις πιο απλές.

(β) Η σχετική κατάταξη της απόδοσης των διαφόρων μεθόδων ποικίλει ανάλογα με το κριτήριο ακρίβειας που χρησιμοποιείται.

(γ) Η ακρίβεια μιας μεθόδου που είναι συνδυασμός απλών μεθόδων συνήθως είναι καλύτερη της ακρίβειας των μεθόδων αν αυτές προσαρμοστούν ξεχωριστά.

(δ) Η ακρίβεια των διαφόρων μεθόδων εξαρτάται από την έκταση του ορίζοντα πρόβλεψης που εφαρμόζεται.

Πολλοί ερευνητές είχαν καταλήξει σε παρόμοια συμπεράσματα με τον διαγωνισμό-M με τέσσερις σημαντικούς τρόπους. Πρώτον, οι υπολογισμοί στους οποίους βασίστηκε η μελέτη είχαν επαληθευτεί και η καταλληλότητά τους έγινε ευρέως αποδεκτή. Δεύτερον, νέες μέθοδοι παρουσιάστηκαν και τα αντλούμενα αποτελέσματα βρέθηκαν να συμφωνούν με αυτά του Διαγωνισμού-M (Geurts & Kelly, 1986; Fildes, Hibon, Makridakis & Meade, 1998). Τρίτον, πολλοί ερευνητές (Hill & Fildes, 1984; Lusk & Neves, 1984; Koehler & Murphree, 1988) έχουν χρησιμοποιήσει τα δεδομένα του Διαγωνισμού-M και έχουν κυκλοφορήσει παρόμοια συμπεράσματα. Και τέλος, επιπρόσθετες μελέτες που χρησιμοποιούν νέα δεδομένα χρονοσειρών έχουν συμφωνήσει στα παραπάνω τέσσερα συμπεράσματα (Armstrong & Collopy, 1992,1993;Makridakis et.al.,1993;Fildes et.al.,1998) και έχουν αποδείξει, πάνω από κάθε λογική αμφιβολία, την εγκυρότητα αυτών των τεσσάρων αποτελεσμάτων. Όμως, υπήρχαν ακόμα συναισθηματικές εντάσεις ως προς την ακρίβεια των εμπειρικών μελετών (Newbold, 1983) και κριτικές για όλων των ειδών των εμπειρικών εργασιών.

Ο Διαγωνισμός-M2 (Makridakis et.al.,1993) ήταν μια απόπειρα για μελέτη της ακρίβειας των διάφορων μεθόδων πρόβλεψης και την καλύτερη κατανόηση των παραγόντων που επηρεάζουν την ακρίβεια πρόβλεψης. Και πάλι, όπως και στο

Διαγωνισμός-M, δημοσιεύτηκε στο International Journal of Forecasting μια πρόκληση για συμμετοχή στον Διαγωνισμό-M2, έγιναν ανακοινώσεις κατά τη διάρκεια του international Symposium of Forecasting (ISF) και μια ειδική γραπτή πρόσκληση απεστάλη σε όλους τους γνωστούς ερευνητές των ποικίλων μεθόδων χρονοσειρών. Ο Διαγωνισμός-M2 οργανώθηκε σε συνεργασία με τέσσερις εταιρείες και περιλάμβανε έξι μακροοικονομικές χρονοσειρές. Σχεδιάστηκε και εφαρμόστηκε σε μία βάση πραγματικού χρόνου (real-time basis). Αυτό σήμαινε πως οι εταιρείες όχι μόνο παρείχαν στους συμμετέχοντες ερευνητές πραγματικά δεδομένα, σχετικά με το παρελθόν και το παρόν, αλλά επίσης δεσμεύτηκαν να απαντήσουν στις ερωτήσεις τους σχετικά με τέτοια δεδομένα, τους παράγοντες που επηρέασαν τις επιχειρήσεις τους και τις μεταβλητές που χρειάστηκε να λάβουν υπόψη τους για να πάρουν τις προβλέψεις των σειρών που δόθηκαν στους συμμετέχοντες. Τα μακροοικονομικά δεδομένα ήταν από τις Ηνωμένες Πολιτείες της Αμερικής , των οποίων η οικονομική κατάσταση ήταν γνωστή εκείνη την περίοδο στους συμμετέχοντες. Ο διαγωνισμός διήρκησε δύο χρόνια και οι συμμετέχοντες ειδικοί ερευνητές έπρεπε να παράγουν προβλέψεις για τους επόμενους 15 μήνες, όπως συνηθίζεται όταν οι προβλέψεις στις επιχειρησιακές εταιρείες γίνονται για τον προϋπολογισμό του επόμενου έτους, ορισμένες φορές τον Σεπτέμβρη ή τον Οκτώβρη. Τον πρώτο χρόνο, εκτός από τα δεδομένα, δόθηκαν στους συμμετέχοντες επίσης συμπληρωματικές πληροφορίες σχετικά με τη βιομηχανία ή την εταιρεία από την οποία προερχόταν η χρονοσειρά. Καθώς ο διαγωνισμός εφαρμόστηκε σε βάση πραγματικού χρόνου η πραγματική κατάσταση της οικονομίας ήταν γνωστή στους συμμετέχοντες, που μπορούσαν επίσης να βρουν, από δημοσιευμένες πηγές, πρόσθετες πληροφορίες, αν το επιθυμούσε.

Ένα χρόνο αργότερα οι πραγματικές τιμές για τους τελευταίους μήνες δόθηκαν στους συμμετέχοντες για να μπορέσουν να αξιολογήσουν την ακρίβεια των προβλέψεων που είχαν κάνει ένα χρόνο πριν. Επιπρόσθετα, δόθηκαν στους ειδικούς πρόσθετες πληροφορίες, που αφορούσαν τον επερχόμενο χρόνο, σχετικά με την βιομηχανία ή τη εταιρεία. Μπορούσαν επίσης να επικοινωνήσουν με ένα πρόσωπο από κάθε εταιρεία αν επιθυμούσαν βοηθητικές υποδείξεις ή διευκρινίσεις σχετικά με τη βιομηχανία / εταιρεία και/ή τα δεδομένα.

Τα αποτελέσματα του Διαγωνισμού-M2 ήταν ουσιαστικά πανομοιότυπα με εκείνα του Διαγωνισμού-M. Στατιστικά οι πολύπλοκες ή εξεζητημένες μέθοδοι δεν έδωσαν ακριβέστερες προβλέψεις από τις πιο απλές. Η σχετική κατάταξη της απόδοσης των διαφόρων μεθόδων ήταν ποικίλη σύμφωνα με το κριτήριο ακρίβειας που χρησιμοποιήθηκε. Η ακρίβεια του συνδυασμού διαφόρων μεθόδων υπερίσχυσε, κατά μέσο όρο, των ανεξάρτητων μεθόδων που χρησιμοποιήθηκαν. Τέλος, η ακρίβεια των διαφόρων μεθόδων ήταν ανάλογη της έκτασης του ορίζοντα των προβλέψεων.

Παρότι τα συμπεράσματα της έρευνας των S.Makridakis και M.Hibon (1979) μπορούσαν να αμφισβητηθούν καθότι βασίζονται στις ικανότητες πρόβλεψης δυο ατόμων, εκείνα του διαγωνισμού-M και του -M2 ήταν υπεράνω τέτοιας κριτικής. Επιπλέον, έγινε κάθε δυνατή προσπάθεια για αν επιτευχθεί ο υψηλότερος δυνατός βαθμός αντικειμενικότητας. Τέτοιες προσπάθειες περιλάμβαναν την εύρεση συμμετεχόντων με βαθιές γνώσεις για να τρέχουν κάθε μέθοδο με τελειότητα και τη διαβεβαίωση ότι η διαδικασία πρόβλεψης ήταν καλά τεκμηριωμένη έτσι ώστε να ήταν δυνατόν να αναπαραχθεί από άλλους ερευνητές και να είναι διαθέσιμη για μετέπειτα εκτενή έρευνα. Τέτοια αναπαραγωγή και εκτενή έρευνα έχει όντως πραγματοποιηθεί. Τα δεδομένα των Διαγωνισμών -M και -M2 έχουν γίνει διαθέσιμα σε περισσότερους από 600 ερευνητές που έχουν μελετήσει κάθε πιθανή πλευρά των μεθόδων (π.χ.Lusk &Neves, 1984) και των υπολογισμών (Simmons, 1986). Επίσης, νέα και διαφορετικά σύνολα δεδομένων (Grambsch & Stahel, 1990;Fildes, 1992; Armstrong &Collory, 1993) επιβεβαιώνουν τα συμπεράσματα του Διαγωνισμού-M με αποτέλεσμα να μπορούν να γενικευθούν σε νέες χρονοσειρές δεδομένων ακόμα και διαφορετικών καταστάσεων και χαρακτηριστικών.

Οι δυνατές εμπειρικές αποδείξεις, όμως, αγνοήθηκαν από θεωρητικούς επιστήμονες στατιστικής που ήταν εχθρικοί απέναντι σε εμπειρικές επαληθεύσεις (Newbold, 1983). Απεναντίας, είχαν συγκεντρώσει τις προσπάθειες τους στο να χτίζουν πιο πολύπλοκα μοντέλα χωρίς να δίνουν καμία προσοχή στη δυνατότητα τέτοιων μοντέλων να προβλέπουν με μεγαλύτερη ακρίβεια δεδομένα της πραγματικής ζωής. Για το λόγο αυτό, οι διαγωνισμοί πρόβλεψης συνεχίστηκαν να εφαρμόζονται.

4.4 ΠΛΕΟΝΕΚΤΗΜΑΤΑ ΤΩΝ ΔΙΑΓΩΝΙΣΜΩΝ-M

Όπως αναφέρθηκε οι διαγωνισμοί-M παρέχουν ένα μοντέλο για διεξαγωγή επιστημονικών ερευνών. Έχουν τουλάχιστον πέντε πολύ σημαντικά πλεονεκτήματα: εμπειρικό τεστ, πολλαπλή υπόθεση, μεγάλου μεγέθους δείγματα, ανεξάρτητη αποτίμηση και πλήρη αποκάλυψη. Αν και αυτά τα στοιχεία μπορεί να θεωρηθούν εμφανή, μελέτες στη επιστήμη της διοίκησης σπάνια περιλαμβάνουν και τα πέντε αυτά στοιχεία. Ακολουθεί η ανάλυση των πέντε αυτών πλεονεκτημάτων.

4.4.1 εμπειρικό τεστ

Το εμπειρικό τεστ είναι απαραίτητο για την δοκιμασία των μεθόδων πρόβλεψης. Παρά την “αντίσταση” των ερευνητών που ασχολήθηκαν με τις μεθόδους των χρονοσειρών, το ενδιαφέρον για εμπειρικές μελέτες έχει αυξηθεί ανάμεσα στους ειδικούς για την παραγωγή προβλέψεων. Σήμερα, τα ειδικά περιοδικά των προβλέψεων δημοσιεύουν συνεχώς εμπειρικές συγκρίσεις. Οι Διαγωνισμοί-M άνοιξαν τον δρόμο για τέτοιου είδους συγκρίσεις.

4.4.2 Πολλαπλή υπόθεση

Οι ακαδημαϊκοί ερευνητές βασίζονται πολύ στην “συνηγορία” (Armstrong, Brodie & Parsons, 2001b). Έχοντας αναπτύξει την μέθοδο που θεωρούν αυτοί ότι είναι η καλύτερη(υπόθεση) μετά ψάχνουν πληροφορίες για να υποστηρίξουν αυτή τη θέση τους. Δεν είναι φυσιολογικό στην επιστήμη της διοίκησης για ένα ερευνητή να εξετάζει ανταγωνιστικές υποθέσεις. Παρόλα αυτά, περίπου 60% των δημοσιευμένων άρθρων στο Journal of Forecasting και στο International Journal of Forecasting εξέταζαν ανταγωνιστικές υποθέσεις. Οι Διαγωνισμοί-M με υποδειγματικό τρόπο παρέμειναν ανοικτοί διαγωνισμοί με την έννοια ότι επέτρεπαν σε όσους ερευνητές έχουν διαφορετικές προσεγγίσεις να συμμετάσχουν.

4.4.3 Μεγάλα δείγματα

Η δοκιμασία (testing) θα πρέπει να γίνεται σε δείγματα μεγάλου μεγέθους. Παρόλα αυτά, πολλές ακαδημαϊκές έρευνες, συμπεριλαμβανομένων αυτών που έχουν να κάνουν με προβλέψεις, δεν χρησιμοποιούν μεγάλα δείγματα. Οι Διαγωνισμοί-M δεν ακολούθησαν αυτή τη λογική. Ο πρώτος διαγωνισμός πρόβλεψης (Makridakis & Hibon, 1979) εξέταζε 111 χρονοσειρές (αρκετά μεγάλος αριθμός συγκριτικά με τα δεδομένα της εποχής) και ο διαγωνισμός-M εξέταζε 1001 χρονοσειρές.

4.4.4 Ανεξάρτητη αποτίμηση σε μια κοινή βάση δεδομένων

Οι μέθοδοι που συμμετείχαν στους διαγωνισμούς εξετάστηκαν σε μια κοινή βάση δεδομένων από ένα ερευνητή ο οποίος εξέταζε την ακρίβεια των προβλέψεων που είχαν παράγει οι συμμετέχοντες με τις διάφορες μεθόδους πρόβλεψης. Αυτή η διαδικασία επαλήθευσης απέφυγε τα προβλήματα που θα ανέκυπταν αν για σύγκριση χρησιμοποιούνταν τα συμπεράσματα παλιότερων ερευνών στις οποίες οι βάσεις δεδομένων ήταν διαφορετικές.

4.4.5 Πλήρη αποκάλυψη των δεδομένων & των αποτελεσμάτων

Η πλήρης αποκάλυψη των αποτελεσμάτων είναι σημαντική γιατί επιτρέπει σε διάφορους ενδιαφερόμενους ερευνητές να διεξάγουν επαναληπτικά πειράματα όπως και προεκτάσεις των μεθόδων. Παρά την ομοφωνία μεταξύ ερευνητών ότι η επανάληψη των πειραμάτων είναι ζωτικής σημασίας για την βελτίωση της επιστημονικής γνώσης, ο αριθμός των δημοσιευμένων τέτοιων πειραμάτων στις επιστήμες της διοίκησης είναι αμελητέος και υπάρχουν ελάχιστες επεκτάσεις. Επιπρόσθετα, το ποσοστό των μελετών στις οποίες τα επαναληπτικά πειράματα υποστήριζαν με τη σειρά τους τα αρχικά συμπεράσματα είναι ιδιαίτερα χαμηλό (Hubbard & Vetter, 1996).

Στο μεγαλύτερο ποσοστό πάντως οι διαγωνισμοί-M αποκάλυψαν τα δεδομένα (forecastingprinciples.com), τις προβλέψεις και κάποιες λεπτομέρειες για τις μεθόδους. Τα επαναληπτικά πειράματα και οι επεκτάσεις των Διαγωνισμών –M επαλήθευσαν τα αρχικά συμπεράσματα.

Ο Διαγωνισμός –M3 δεν παρείχε πλήρη αποκάλυψη δεδομένων σε αυτούς που χρησιμοποιούσαν εμπορικά πακέτα. Αυτό γιατί θεωρήθηκε ότι θα ήταν δύσκολο να καθοριστεί ποιες εφαρμογές των εμπορικών πακέτων θα ήταν χρήσιμες και έτσι θα ήταν αδύνατο από κάποιον να βγάλει μέσω των πακέτων αυτών ολοκληρωμένα συμπεράσματα για τις μεθόδους πρόβλεψης.

4.5 Ο ΔΙΑΓΩΝΙΣΜΟΣ-M3

Ο διαγωνισμός πρόβλεψης –M3 είναι ο μεγαλύτερος διαγωνισμός πρόβλεψης που διοργανώθηκε ποτέ καθώς ζητούμενο ήταν να δοθούν 6 έως 18 προβλέψεις για 3003 διαφορετικές χρονοσειρές οι οποίες προέρχονταν από όλο το φάσμα της οικονομικής δραστηριότητας.

Στόχος της διεξαγωγής του διαγωνισμού ήταν κυρίως να συμπεράνουν αν τα αποτελέσματα των προηγούμενων Διαγωνισμών–M θα μπορούσαν να αντεπεξέλθουν στο νέο, κατά πολύ μεγαλύτερο σύνολο, των 3003 χρονοσειρών.

Οι 3003 χρονοσειρές συλλέχθηκαν έτσι ώστε να συμπεριλάβουν διάφορους τύπους δεδομένων χρονοσειρών (micro, macro, βιομηχανικά κ.λπ.) και διαφορετικά χρονικά διαστήματα ανάμεσα στις παρατηρήσεις (ετήσιες, τριμηνιαίες κ.λπ.). Για να εξασφαλίσουν ότι υπήρχαν αρκετά δεδομένα διαθέσιμα για να διαμορφώσουν ένα επαρκές μοντέλο προβλέψεων, αποφασίστηκε να γίνει ένας ελάχιστος αριθμός παρατηρήσεων για κάθε τύπο δεδομένων. Αυτό το ελάχιστο καθορίστηκε να είναι 14 παρατηρήσεις για τις ετήσιες χρονοσειρές (ο μέσος όρος για τις 645 ετήσιες σειρές είναι 19 παρατηρήσεις), 16 για τριμηνιαίες (ο μέσος όρος για τις 756 τριμηνιαίες χρονοσειρές είναι 44 παρατηρήσεις), 48 για μηνιαίες (ο μέσος όρος για τις 1428 μηνιαίες χρονοσειρές είναι 115 παρατηρήσεις) και 60 για «άλλες» χρονοσειρές (ο μέσος όρος για τις 174 «άλλες» χρονοσειρές είναι 63 παρατηρήσεις). Ο πίνακας 4.1 δείχνει την ταξινόμηση των 3003 χρονοσειρών σύμφωνα με τις δύο μαζικές ταξινομήσεις που περιγράφηκαν. Όλα τα δεδομένα των χρονοσειρών είναι αυστηρά θετικά. Έγινε ένα τεστ σε όλους τους παράγοντες πρόβλεψης: σε περίπτωση κάποιου

αρνητικού παράγοντα, έγινε αντικατάσταση με το μηδέν. Αυτό βοηθάει στο να αποφευχθεί το οποιοδήποτε πρόβλημα στις διάφορες MAPE μετρήσεις.

Είδος /Χρονική περίοδος	Μικρο-οικονομικές	Βιομηχανικές	Μακρο-οικονομικές	Οικονομικές	Δημογραφικές	Άλλες	Σύνολο
Ετήσιες	146	102	83	58	245	11	645
Τριμηνιαίες	204	83	336	76	57	-	756
μηνιαίες	474	334	312	145	111	52	1428
Άλλες	4	-	-	29	-	141	174
Σύνολο	828	519	731	308	413	204	3003

Πίνακας 4.1 Χρονοσειρές διαγωνισμού-M3 ανά κατηγορίες

Όπως και στον Διαγωνισμό-M, ζητήθηκε από τους συμμετέχοντες ειδικούς ερευνητές να δώσουν τις ακόλουθες προβλέψεις πέρα από τα διαθέσιμα δεδομένα που τους είχαν δοθεί: 6 για τις ετήσιες, 8 για τις τριμηνιαίες, 18 για τις μηνιαίες και 8 για την κατηγορία «άλλες». Οι προβλέψεις, επομένως, συγκρίθηκαν από τους συγγραφείς (οι πραγματικές τιμές που αναφέρονταν σε αυτές τις προβλέψεις δεν ήταν διαθέσιμες στους συμμετέχοντες ειδικούς όσο έκαναν τις προβλέψεις τους και επομένως δεν μπορούσαν να εξελίσσουν το μοντέλο πρόβλεψής τους).

Στον διαγωνισμό υπήρξαν 24 διαφορετικές μέθοδοι χωρισμένες σε 6 κατηγορίες. Αυτές ήταν οι μέθοδοι που χρησιμοποιήθηκαν στον Διαγωνισμό –M όπως και 7 νέες από τον τομέα των νευρωνικών δικτύων, των τεχνικών βασισμένων σε κανόνες (RBF), της εκθετικής εξομάλυνσης και της αποσύνθεσης. Κατά την διεξαγωγή του διαγωνισμού, οι διοργανωτές μοίρασαν στους συμμετέχοντες τα δεδομένα από τις 3003 χρονοσειρές έχοντας αποκρύψει τις τελευταίες παρατηρήσεις. Ζητούμενο ήταν να δοθούν προβλέψεις για τις παρατηρήσεις αυτές. Οι διοργανωτές έχοντας τόσο τις προβλέψεις όσο και τα αρχικά κρυμμένα δεδομένα υπολόγισαν τα σφάλματα των μεθόδων με διάφορους δείκτες. Ο διαγωνισμός διήρκεσε περίπου δύο χρόνια (1997-1999).Στον επόμενο πίνακα παρουσιάζονται οι 24 μέθοδοι:

Method	Competitors	Description
<i>Naive/simple</i>		
1. Naive2	M. Hibon	Deseasonalized Naive (Random Walk)
2. Single	M. Hibon	Single Exponential Smoothing
<i>Explicit trend models</i>		
3. Holt	M. Hibon	Automatic Holt's Linear Exponential Smoothing (two parameter model)
4. Robust-Trend	N. Meade	Non-parametric version of Holt's linear model with median based estimate of trend
5. Winter	M. Hibon	Holt-Winter's linear and seasonal exponential smoothing (two or three parameter model)
6. Dampen	M. Hibon	Dampen Trend Exponential Smoothing
7. PP-autocast _a	H. Levenbach	Damped Trend Exponential Smoothing
8. Theta-sm	V. Assimakopoulos	Successive smoothing plus a set of rules for dampening the trend
9. Comb S-H-D	M. Hibon	Combining three methods: Single /Holt / Dampen
<i>Decomposition</i>		
10. Theta	V. Assimakopoulos	Specific decomposition technique, projection and combination of the individual components
<i>ARIMA/ARARMA model</i>		
11. B-J automatic	M. Hibon	Box-Jenkins methodology of 'Business Forecast System'
12. Autobox1 _a	D. Reilly	Robust ARIMA univariate Box-Jenkins with / without Intervention Detection
13. Autobox2 _a		
14. Autobox3 _a		
15. AAM1	G. Melard,	Automatic ARIMA modelling with /without
16. AAM2	J.M. Pasteels	intervention analysis
17. ARARMA	N. Meade	Automated Parzen's methodology with Auto regressive filter
<i>Expert system</i>		
18. ForecastPro _a	R. Goodrich, E. Stellwagen	Selects from among several methods: Exponential Smoothing / Box Jenkins/Poisson and negative binomial models / Croston's Method/Simple Moving Average
19. SmartFcs _a	C. Smart	Automatic Forecasting Expert System which conducts a forecasting tournament among four exponential smoothing and two moving average methods
20. RBF	M. Adya, S. Armstrong, F. Collopy, M. Kennedy	Rule-based forecasting: using three methods — random walk, linear regression and Holt's, to estimate level and trend, involving corrections, simplification, automatic feature identification and re-calibration
21. Flores/Pearce1	B. Flores,	Expert system that chooses among four methods based on the characteristics of the data
22. Flores/Pearce2	S. Pearce	
23. ForecastX _a	J. Galt	Runs tests for seasonality and outliers and selects from among several methods: Exponential

Πίνακας 4.2 Οι 24 μέθοδοι που συμμετείχαν στον M3 χωρισμένες σε 6 κατηγορίες

Πέντε συντελεστές ακρίβειας χρησιμοποιήθηκαν για την ανάλυση της επίδοσης των μεθόδων: symmetric MAPE, Median symmetric APE, Percentage Better και Median RAE. Παρόλα αυτά, η απόλυτη ακρίβεια των διάφορων μεθόδων δεν είναι τόσο σημαντική όσο είναι η επίδοση αυτών των μεθόδων σε σχέση με κάποιες άλλες απλές μεθόδους που θεωρούνται σημεία αναφοράς. Η πιο απλή μέθοδος είναι η Naive2 και ακολουθεί το μοντέλο φθίνουσας τάσης εκθετικής εξομάλυνσης. Όλες οι μέθοδοι πρόβλεψης του διαγωνισμού αποδείχθηκε ότι είναι πιο ακριβής από την Naive2 η οποία απλά αναγνωρίζει την εποχιακότητα στα δεδομένα.

Αυτό επιβεβαιώνεται και από τον παρακάτω πίνακα:

457

Forecasting horizon(s)	1	Average:	Average:	Average:	Average:
		1–4	1–6	1–12	1–18
Theta	2.1%	2.2%	2.1%	2.3%	2.5%
ForecastPro	1.9%	2.0%	1.9%	2.1%	2.3%
ForecastX	1.8%	1.8%	1.8%	2.0%	2.0%
Comb S-H-D	1.6%	1.5%	1.5%	1.8%	2.0%
Dampen	1.7%	1.6%	1.5%	1.8%	1.8%
RBF	0.6%	1.1%	1.3%	1.5%	1.7%
ARARMA	0.8%	0.8%	0.7%	0.7%	0.7%

Πίνακας 4.3 Σύγκριση της επίδοσης των διάφορων μεθόδων πρόβλεψης με την Naive2

4.5.1 Αποτελέσματα διαγωνισμού M3

Ο διαγωνισμός επιβεβαίωσε τα αρχικά αποτελέσματα του Διαγωνισμού-M χρησιμοποιώντας ένα νέο και πολύ μεγαλύτερο σύνολο δεδομένων. Επιπλέον, απέδειξε, για μια ακόμα φορά, ότι οι απλές μέθοδοι είχαν παρόμοια αποτελέσματα, ή και σε αρκετές περιπτώσεις καλύτερα, σε σχέση με τις πιο εξειδικευμένες στατιστικά μεθόδους όπως τα ARIMA και ARARMA μοντέλα. Επιπρόσθετα, ο διαγωνισμός – M3 κατέληξε και σε τρία ακόμη νέα συμπεράσματα με πιο σημαντικό την καταπληκτική επίδοση μιας νέας μεθόδου, της μεθόδου Θ .

Η Μονάδα Συστημάτων Πρόβλεψης και Προοπτικής της σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου συμμετείχε στον διαγωνισμό παρουσιάζοντας μια καινούρια μέθοδο πρόβλεψης, την μέθοδο Θ (Theta model). Αυτή η μέθοδος διέπρεψε στον διαγωνισμό καταλαμβάνοντας την πρώτη θέση μεταξύ των συμμετεχόντων. Παρόλο που η μέθοδος είναι αρκετά απλή στη χρήση και δεν βασίζεται στην αυστηρή στατιστική θεωρία, εξήγαγε πολύ ακριβή αποτελέσματα σε διαφορετικούς τύπους χρονοσειρών, διαφορετικούς χρονικούς ορίζοντες πρόβλεψης και σε διαφορετικούς δείκτες ακρίβειας. Η μέθοδος Θ κατάφερε να νικήσει ακόμα και εξειδικευμένες μεθόδους σε διάφορους τομείς προβλέψεων.

Επιπλέον, στον διαγωνισμό έλαβε μέρος ένα από τα κορυφαία πλέον ολοκληρωμένα πακέτα λογισμικού στον χώρο των προβλέψεων, το Forecast Pro. Το Forecast Pro εξήγαγε αρκετά ικανοποιητικά αποτελέσματα. Το λογισμικό αυτό έχει την ικανότητα να αναγνωρίζει την πιο κατάλληλη μέθοδο από ένα σύνολο από πιθανές επιλογές.

Τέλος, από τον διαγωνισμό εξήλθε το συμπέρασμα ότι όσον αφορά ετήσια δεδομένα μια μέθοδος αποδείχθηκε καλύτερη από όλες τις άλλες. Αυτή η μέθοδος είναι η Robust-Trend.

Τα τελικά αποτελέσματα του διαγωνισμού-M3 ανακοινώθηκαν στο 19^ο διεθνές συνέδριο πρόβλεψης τον Ιούνιο του 1999 στην Ουάσιγκτον (ISF1999) τα οποία παρουσιάζονται και στους παρακάτω πίνακες για μια πιο ολοκληρωμένη εικόνα:

Method	Forecasting horizon															[obs	
	1	2	3	4	5	6	8	12	15	18	1 to 4	1 to 6	1 to 8	1 to 12	1 to 15		1 to 18
Naive2	10.5	11.3	13.6	15.1	15.1	15.9	14.5	16	19.3	20.7	12.62	13.57	13.76	14.24	14.81	15.47	3003
Single	9.5	10.6	12.7	14.1	14.3	15	13.3	14.5	18.3	19.4	11.73	12.71	12.84	13.13	13.67	14.32	3003
Holt	9	10.4	12.8	14.5	15.1	15.8	13.9	14.8	18.8	20.2	11.67	12.93	13.11	13.42	13.95	14.6	3003
Dampen	8.8	10	12	13.5	13.7	14.3	12.5	13.9	17.5	18.9	11.05	12.04	12.14	12.44	12.96	13.63	3003
Winter	9.1	10.5	12.9	14.6	15.1	15.9	14	14.6	18.9	20.2	11.77	13.01	13.19	13.48	14.01	14.65	3003
Comb S-H-D	8.9	10	12	13.5	13.7	14.2	12.4	13.6	17.3	18.3	11.1	12.04	12.13	12.4	12.91	13.52	3003
B-J automatic	9.2	10.4	12.2	13.9	14	14.8	13	14.1	17.8	19.3	11.42	12.41	12.54	12.8	13.35	14.01	3003
Autobox1	9.8	11.1	13.1	15.1	16	16.8	14.2	15.4	19.1	20.4	12.3	13.67	13.78	14	14.56	15.23	3003
Autobox2	9.5	10.4	12.2	13.8	13.8	14.9	13.2	15.2	18.2	19.9	11.48	12.44	12.63	13.1	13.7	14.41	3003
Autobox3	9.7	11.2	12.9	14.6	15.8	16.5	14.4	16.1	19.2	21.2	12.08	13.43	13.64	14.01	14.57	15.33	3003
Robust-Trend	10.5	11.2	13.2	14.7	15	15.9	15.1	17.5	22.2	24.3	12.38	13.4	13.73	14.57	15.42	16.3	3003
ARARMA	9.7	10.9	12.6	14.2	14.6	15.6	13.9	15.2	18.5	20.3	11.83	12.92	13.12	13.54	14.09	14.74	3003
Automat ANN	9	10.4	11.8	13.8	13.8	15.5	13.4	14.6	17.3	19.6	11.23	12.38	12.58	12.96	13.48	14.11	3003
Flores/Pearce1	9.2	10.5	12.6	14.5	14.8	15.3	13.8	14.4	19.1	20.8	11.68	12.79	13.03	13.31	13.92	14.7	3003
Flores/Pearce2	10	11	12.8	14.1	14.1	14.7	12.9	14.4	18.2	19.9	11.96	12.77	12.81	13.04	13.61	14.29	3003
PP-autocast	9.1	10	12.1	13.5	13.8	14.7	13.1	14.3	17.7	19.6	11.2	12.21	12.4	12.8	13.34	14.01	3003
ForecastPro	8.6	9.6	11.4	12.9	13.3	14.3	12.6	13.2	16.4	18.3	10.64	11.69	11.86	12.14	12.6	13.19	3003
SmartFcs	9.2	10.3	12	13.5	14	15.1	13	14.9	18	19.4	11.23	12.34	12.49	12.94	13.48	14.13	3003
Theta-sm	9.8	11.3	12.6	13.6	14.3	15	12.7	14	16.2	18.3	11.81	12.76	12.77	13.04	13.4	13.88	3003
Theta	8.4	9.6	11.3	12.5	13.2	14	12	13.2	16.2	18.2	10.44	11.49	11.62	11.95	12.42	13.01	3003
RBF	9.9	10.5	12.4	13.4	13.2	14.2	12.8	14.1	17.3	17.8	11.56	12.28	12.42	12.77	13.25	13.75	3003
ForecastX	8.7	9.8	11.6	13.1	13.2	13.9	12.6	13.9	17.8	18.7	10.82	11.73	11.89	12.22	12.81	13.49	3003
AAM1	9.8	10.6	11.2	12.6	13	13.5	14.1	14.9	18	20.4	11.04	11.76	12.43	13.04	13.77	14.63	2184
AAM2	10	10.7	11.3	12.9	13.2	13.7	14.3	15.1	18.4	20.7	11.21	11.95	12.62	13.21	13.97	14.85	2184

Πίνακας 4.4 Average Symmetric MAPE για όλα τα δεδομένα

Accuracy measure	Micro (828)	Industry (519)	Macro (731)	Finance (308)	Demographic (413)	Other (204)
Symmetric MAPE	Theta	ForecastX/ ForecastPro	RBF/ARARMA	AAM1 / AAM2	ForecastX	Comb S-H-D
Average RANKING	Theta	ForecastPro	Robust-Trend	AAM1 / AAM2	Robust-Trend	Theta
Median APE	Theta	ForecastX	Robust-Trend	Autobox3	RBF	Theta
Median RAE	Theta	Theta	Robust-Trend	Robust-Trend	RBF	Theta
		RBF / Comb S-H-D	ARARMA	ARARMA		Theta
			RBF	Theta		Autobox2
				AAM1 /AAM2		Comb S-H-D

Πίνακας 4.5 Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα για όλα τα δεδομένα

Time interval between observations	Types of time series data						
	Micro (828)	Industry (519)	Macro (731)	Finance (308)	Demographic (413)	Other (204)	Total (3003)
Yearly (645)	Robust-Trend	Theta	Robust-Trend	Autobox2	ForecastX		RBF
	Flores /Pearce2	Comb S-H-D	ARARMA	Single	RBF		ForecastX
Quarterly (756)	SmartFcs	Autobox2		Naive2			Autobox2
	Autobox2						Theta
	Theta	Comb S-H-D	Theta	Theta	Theta/		Robust-Trend
	Comb S-H-D	RBF	Comb S-H-D	PP-autocast	SmartFcs		Theta
Monthly (1428)	ForecastX	ForecastX		ForecastPro	Dampen		Comb S-H-D
		PP-autocast					Dampen
	Theta	ForecastPro	ARARMA	AAM1/	ForecastX	Comb S-H-D	PP-autocast
Other (174)	ForecastPro	ForecastX	RBF	AAM2	SmartFcs	B-J automatic	Theta
					Single	AAM1	ForecastPro
					ForecastPro		
				Dampen/		Theta	ARARMA
Total (3003)				PP-autocast		Autobox2	Theta /
				Automat ANN		Robust-Trend	Autobox2
				ForecastPro		Comb S-H-D	
	Theta	ForecastPro/	RBF/	AAM1	ForecastX		Theta
	ForecastPro	ForecastX	ARARMA	AAM2			ForecastPro
		Theta	Theta/				

Robust-Trend

Πίνακας 4.6 Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το symmetric MAPE

Time interval between successive observations	Types of time series data						
	Micro (828)	Industry (519)	Macro (731)	Finance (308)	Demographic (413)	Other (204)	Total (3003)
Yearly (645)	Robust-Trend	Robust-Trend	Robust-Trend	Single	ForecastX		RBF
	SmartFcs		ForecastPro	Naive2	ForecastPro		Flores / Pearce1
				Autobox2	RBF		PP-autocast
Quarterly (756)					Theta		
	ForecastX	ForecastX	Theta	Theta	ARARMA		Robust-Trend
	Comb S-H-D	Comb S-H-D	RBF	Winter	Robust-Trend		Theta
	Holt	Theta	Flores /Pearce1	SmartFcs			Comb S-H-D
Monthly (1428)		Robust-Trend					ForecastX
	PP-autocast						
	Theta	ForecastPro	Robust-Trend	AAM1 /	Robust-Trend	ARARMA	ForecastPro
Other (174)	ForecastPro	B-J automatic	Holt	AAM2	ARARMA/	AAM2	Theta
		ForecastX	AAM1	Autobox3	RBF		Holt
		Theta		Autobox1			Comb S-H-D
			Automat ANN			ForecastX	ForecastX
						Autobox2	Autobox2

Πίνακας 4.7 Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το median APE

Time interval between successive observations	Types of time series data						
	Micro (828)	Industry (519)	Macro (731)	Finance (308)	Demographic (413)	Other (204)	Total (3003)
Yearly (645)	Robust-Trend SmartFcs / Theta/ Autobox2	Robust-Trend Theta-sm Theta	Robust-Trend ARARMA RBF		RBF Theta		
Quarterly (756)	Holt Theta Comb S-H-D/ Robust-Trend	Comb S-H-D/ Theta / Robust-Trend Holt	Theta/ Comb S-H-D	Theta/ Winter	Theta ARARMA Comb S-H-D		
Monthly (1428)	Theta Theta-sm ForecastPro / Automat ANN		AAM1 / Robust-Trend Holt ARARMA	AAM1/ AAM2	Robust-Trend ARARMA	ARARMA AAM2 AAM1 Theta	
Other (174)							

Πίνακας 4.8 Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση το median RAE

Micro (828)	Industry (519)	Macro (731)	Finance (308)	Demographic (413)	Other (204)	Total (3003)
Seasonal (862)	ForecastPro Theta Dampen Comb S-H-D SmartFcs ForecastX		AAM1/ AAM2 ForecastPro ForecastX			ForecastPro Theta/ ForecastX / Dampen Comb S-H-D
Non-Seasonal (2141)	Theta		AAM1/ AAM2			Theta ForecastPro ForecastX / Comb S-H-D

Πίνακας 4.9 Μέθοδοι που δίνουν τα καλύτερα αποτελέσματα με βάση εποχιακά/μη εποχιακά δεδομένα

4.6 Ο ΔΙΑΓΩΝΙΣΜΟΣ NN3

Κύριος στόχος του διαγωνισμού ήταν η πρόβλεψη ενός συνόλου 11 ή 111 χρονοσειρών όσο το δυνατόν ακριβέστερα, χρησιμοποιώντας μεθόδους από την υπολογιστική νοημοσύνη και μια συνεπή μεθοδολογία. Επιπλέον, μεγάλη ήταν και η αναγκαιότητα για την αξιολόγηση της προόδου στη διαμόρφωση των Νευρωνικών Δικτύων για την πρόβλεψη και τη διάδοση της γνώσης σχετικά με τις εύρεση των καλύτερων πρακτικών. Ο διαγωνισμός διεξήχθη για ακαδημαϊκούς λόγους και υποστηριζόταν από μια επιχορήγηση από τη SAS και το Διεθνές Ίδρυμα Ειδικών στις Προβλέψεις (IPF).

4.6.1 Μέθοδοι

Ο διαγωνισμός NN3 δεν ήταν καθόλου περιοριστικός όσον αφορά τα διάφορα μοντέλα πρόβλεψης που μπορούσαν να χρησιμοποιηθούν. Αντιθέτως, ήταν ανοικτός σε όλες τις μεθόδους υπολογιστικής νοημοσύνης που χρησιμοποιούνται στην οικονομική πρόβλεψη, στη στατιστική πρόβλεψη και στην ανάλυση χρονοσειρών, συμπεριλαμβανομένων των εξής:

- Feed-forward και recurrent Νευρωνικά Δίκτυα.
- Fuzzy προβλέψεις, εξελικτικοί και Γενετικοί Αλγόριθμοι.
- Δέντρα απόφασης οπισθοδρόμησης.
- Υποστήριξη διανυσματικής οπισθοδρόμησης.
- Υβριδικές προσεγγίσεις.

Πρέπει να διευκρινίσουμε επιπλέον ότι οι κανόνες του διαγωνισμού δεν υποχρέωναν κάθε διαγωνιζόμενο να κατασκευάσει ένα συγκεκριμένο ΝΔ με προκαθορισμένη δομή (είσοδοι, ενδιάμεσο επίπεδο, έξοδος) αλλά επέτρεπε την ανάπτυξη μιας διαδικασίας μέσω της οποίας να γίνονται οι κατάλληλες δοκιμές και

να επιλέγεται κάθε φορά το κατάλληλο σύνολο παραμέτρων που θα οδηγήσει στην καλύτερη πρόβλεψη της κάθε χρονοσειράς.

Η αποτίμηση των παραπάνω μεθόδων έγινε με σύγκριση των αποτελεσμάτων τους με τα αντίστοιχα αποτελέσματα των παρακάτω διακεκριμένων στατιστικών μεθόδων πρόβλεψης:

- Naive
- Απλή, γραμμική, εκθετική και φθίνουσα τάση εκθετικής εξομάλυνσης
- Μέθοδοι ARIMA

4.6.2 Κίνητρα

Ο Διαγωνισμός χρηματοδοτήθηκε ως μια ερευνητική επιχορήγηση ονόματι "Αυτόματη Μοντελοποίηση και Πρόβλεψη με τα Νευρωνικά Δίκτυα – Αξιολόγηση Διαγωνισμού πρόβλεψης" από τη SAS και το IIF, για να υποστηρίξει την έρευνα στις αρχές της Πρόβλεψης, από τον S.F. Crone και τον K. Nikolopoulos.

Για πάνω από 15 έτη έρευνας και περισσότερες από 2000 δημοσιεύσεις στα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) στην πρόβλεψη (Crone και Graffelle, 2004), τα ΤΝΔ δεν έχουν καθιερωθεί ακόμα ως έγκυρη και αξιόπιστη μέθοδος πρόβλεψης στο Διαγωνισμό προβλέψεων. Τα αποτελέσματα του Διαγωνισμού M3 (Makridakis και Hibon 2000) είχαν δείξει την κακή απόδοση ΝΔ (Haykin, 1999) στην πρόβλεψη ενός μεγάλου αριθμού εμπειρικών χρονοσειρών. Παρόλο το αρχικό ενδιαφέρον από διάφορες ερευνητικές ομάδες (Hibon, 2005), μόνο οι Balkin και Ord (2000) υπέβαλαν επιτυχώς αποτελέσματα στο διαγωνισμό. Εντούτοις, η προσέγγισή τους ξεπέρασε μόνο λίγες από τις 24 προσεγγίσεις που παρήγαγαν προβλέψεις. Παρά τις αισιόδοξες δημοσιεύσεις που έδειξαν την ανώτερη απόδοση των ΝΔ σε απλές χρονοσειρές (Adya και Collory, 1998, Zhang et Al, 1998) ή ένα μικρό υποσύνολο (Hill et Al, 1996), η απόδοσή τους στην πρόβλεψη μηνιαίων δεδομένων (πίνακας 15, Makridakis και Hibon, 2000) είχε διαφορετικό (χειρότερο) αποτέλεσμα από το αναμενόμενο.

Σημαντικές συζητήσεις μεταξύ ειδικών ερευνητών σε διάφορα διεθνή συνέδρια όπως το European Symposium on Artificial Neural Networks (ESANN

2004), το International Conference on Artificial Intelligence (IC-AI 2005), το International Joint Conference on Neural Networks (IJCNN 2005) και το 2004 International Symposium on Forecasting (ISF), κατέληξαν ότι η κακή επίδοση των Νευρωνικών Δικτύων μπορεί ως ένα σημείο να αποδοθεί στην υβριδική και συχνά αναφερόμενη σε συγκεκριμένο σκοπό διαδικασία μοντελοποίησης για τον προσδιορισμό του μεγάλου βαθμού ελευθερίας, αμφισβητώντας την εγκυρότητα και την αξιοπιστία των εφαρμογών των νευρωνικών δικτύων για ένα μεγάλο σύνολο από χρονοσειρές. Η μοντελοποίηση με ΝΔ μοιάζει πιο πολύ με μια “τέχνη” παρά με επιστημονική προσέγγιση που ακολουθεί συγκεκριμένη μεθοδολογία για την διαδικασία μοντελοποίησης. Κατά συνέπεια, η ανάγκη για συνεχή παρέμβαση του χειριστή του ΝΔ έχει απαγορεύσει την αυτοματοποίηση της λειτουργίας των ΝΔ σε μεγάλη κλίμακα.

Αυτός είναι και ο λόγος που σε διαγωνισμούς προβλέψεων που έχουν γίνει στον τομέα των ΝΔ, όπως για παράδειγμα ο διαγωνισμός του Santa Fe (Weigend, 1994), ο διαγωνισμός EUNITE (Suykens and Vandewalle, 1998) καθώς και ο IJCNN’04 CATS-competition, τα μοντέλα αρκέστηκαν σε εκτίμηση μεμονωμένων χρονοσειρών μη μπορώντας να αξιοποιήσουν τα στοιχεία του ορίζοντα πρόβλεψης που υπήρχαν για το πώς να αυξήσουν την αξιοπιστία της εκτίμησης των μεθόδων πρόβλεψης (Fildes et al., 1998).

Παρόλα αυτά, πρόσφατες δημοσιεύσεις περιγράφουν την ανταγωνιστική συμπεριφορά των ΝΔ σε ένα μεγαλύτερο αριθμό χρονοσειρών (Liao and Fildes, 2005, Zhang and Qi, 2005, Crone, 2005), υποδεικνύοντας την χρησιμότητας της αυξημένης υπολογιστικής δύναμης για την αυτοματοποίηση της παραγωγής προβλέψεων με ΝΔ. Για αυτό το λόγο και ένας διαγωνισμός πρόβλεψης χρησιμοποιώντας ένα αντιπροσωπευτικό αριθμό χρονοσειρών μέσα σε ένα συγκεκριμένο χρονικό πλαίσιο φάνηκε εφικτός.

Κυρίως 2 ουσιαστικές ερευνητικές ερωτήσεις μπορούν να επιλυθούν μέσω της πρόσκλησης εμπειρογνομώνων στην ακαδημαϊκή κοινότητα ΝΔ για να συμμετέχουν σε έναν διαγωνισμό πρόβλεψης όπως ο NN3:

1. Ποια είναι η απόδοση των ΝΔ σε σύγκριση με τις καθιερωμένες μεθόδους πρόβλεψης;
2. Ποιες είναι οι καλύτερες σύγχρονες μεθοδολογίες που χρησιμοποιούνται από τους ερευνητές για να μοντελοποιήσουν τα Νευρωνικά Δίκτυα στην πρόβλεψη μιας χρονοσειράς

4.6.3 Δεδομένα NN3

Ο διαγωνισμός παρείχε 2 σύνολα δεδομένων. Το σύνολο δεδομένων A ήταν ένα πλήρες σύνολο δεδομένων 111 μηνιαίων χρονοσειρών που προέρχονται από ομοιογενή πληθυσμό εμπειρικών, επιχειρησιακών χρονοσειρών. Το σύνολο δεδομένων B ήταν ένα υπόδειγμα 11 χρονοσειρών από τις 111 χρονοσειρές και περιλαμβανόταν επομένως στο μεγαλύτερο σύνολο δεδομένων. Ενθαρρύνθηκαν ιδιαίτερα οι υποβολές για το σύνολο δεδομένων A, με τις 111 χρονοσειρές. Εκείνοι που πρόβλεψαν το πλήρες σύνολο δεδομένων κέρδισαν.

4.6.4 Αποτελέσματα NN3

Προκειμένου να διευκολυνθεί η διεπιστημονική έρευνα και οι υποβολές από τις διάφορες Ακαδημαϊκές Αρχές, τα αποτελέσματα παρουσιάστηκαν σε διάφορες **διασκέψεις** το 2007, στην Ευρώπη, τις ΗΠΑ και την Ασία, σε διαφορετικούς τομείς εφαρμογής των Νευρωνικών Δικτύων, της εφαρμοσμένης μηχανικής, της πληροφορικής, της διοίκησης, της στατιστικής και της λειτουργικής έρευνας. Οι συντάκτες μπορούσαν ωστόσο να επιλέξουν να παρευρεθούν σε 1 ή περισσότερα εργαστήρια διασκέψεων, όπου παρουσιάζονται οι έρευνες. Όλοι εκείνοι που υπέβαλλαν τις προβλέψεις κλήθηκαν να συμμετάσχουν στις συνόδους: **ISF'07 - Νέα Υόρκη 2007** – ‘Διεθνές Συμπόσιο για την πρόβλεψη’, **DMIN'07 - Ορλάντο 2007** – ‘Διεθνής Διάσκεψη σχετικά με την ανάκτηση δεδομένων’, και στο **Las Vegas**. Κάθε εργαστήριο παρείχε το καλύτερο έγγραφο και την καλύτερη υποβολή από το σύνολο δεδομένων για α) σπουδαστές και β) μη-σπουδαστές. Όλες οι υποβολές κλήθηκαν να υποβάλλουν τις εργασίες στις ειδικές Συνόδους και τα πρακτικά των Διασκέψεων. Οι επιτυχέστεροι συντάκτες προσκλήθηκαν για μια κοινή υποβολή στο ιδιαίτερα

επευφημημένο Διεθνές Περιοδικό της Πρόβλεψης (International Journal of Forecasting) και αλλού (ISI SCI, ScienceDirect).

Ακολουθεί μια αναλυτική παρουσίαση των αποτελεσμάτων για τα δύο σύνολα δεδομένων A και B που αναφέρθηκαν προηγουμένως:

Κατάταξη	Συμμετέχοντες	SMAPE
1	Stat. Contender - Wildi	14,84%
2	Stat. Benchmark - Theta Method (Nikolopoulos)	14,89%
3	Illies, Jäger, Kosuchinas, Rincon, Sakenas, Vaskevcius	15,18%
4	Stat. Benchmark - ForecastPro (Stellwagen)	15,44%
5	CI Benchmark - Theta AI (Nikolopoulos)	15,66%
6	Stat. Benchmark - Autobox (Reilly)	15,95%
7	Adeodato, Vasconcelos, Arnaud, Chunha, Monteiro	16,17%
8	Flores, Anaya, Ramirez, Morales	16,31%
9	Chen, Yao	16,55%
10	D'yakonov	16,57%
11	Kamel, Atiya, Gayar, El-Shishiny	16,92%
12	Abou-Nasr	17,54%
13	Theodosiou, Swamy	17,55%
14	CI Benchmark - Naive MLP (Crone)	17,84%
15	de Vos	18,24%
16	Yan	18,58%
17	CI Benchmark - Naive SVR (Crone, Pietsch)	18,60%
18	C49	18,72%
19	Perfileieva, Novak, Pavliska, Dvorak, Stepnicka	18,81%
20	Kurogi, Koyama, Tanaka, Sanuki	19,00%
21	Stat. Contender - Beadle	19,14%
22	Stat. Contender - Lewicke	19,17%
23	Sorjamaa, Lendasse	19,60%
24	Isa	20,00%
25	C28	20,54%
26	Duclos-Gosselin	20,85%
27	Stat. Benchmark - Naive	22,69%
28	Papadaki, Amaxopolous	22,70%
29	Stat. Benchmark - Hazarika	23,72%
30	C17	24,09%

Πίνακας 4.10 Αποτελέσματα NN3 στο σύνολο των δεδομένων (A:111 χρονοσειρές)

Κατάταξη	Συμμετέχοντες	SMAPE
1	CI Benchmark - Theta AI (Nikolopoulos)	13,07%
2	Stat. Benchmark - Autobox (Reily)	13,49%
3	Stat. Benchmark - ForecastPro (Stellwagen)	13,52%
4	Yan	13,68%
5	Stat. Benchmark - Theta (Nikolopoulos)	13,70%
6	Ilies, Jäger, Kosuchinas, Rincon, Sakenas, Vaskevcius	14,26%
7	Chen, Yao	14,46%
8	Yousefi, Miromeni, Lucas	14,49%
9	Ahmed, Atiya, Gayar, El-Shishiny	14,52%
10	Flores, Anaya, Ramirez, Morales	15,00%
11	Adeodato, Vasconcelos, Arnaud, Chunha, Monteiro	15,10%
12	Stat. Contender - Wildi	15,32%
13	Luna, Soares, Ballini	15,35%
14	Theodosiou, Swamy	16,19%
15	Hwang, Song, Kasabov	16,31%
16	Duclos-Gosselin	16,37%
17	Kurogi, Koyama, Tanaka, Sanuki	16,49%
18	White	16,56%
19	Abou-Nasr	16,69%
20	Stat. Contender - Beadle	17,14%
21	Sorjamaa, Lendasse	17,16%
22	Stat. Contender - Njimi, Mélard	17,19%
23	Rabie	17,24%
24	Jimenez, Rebuzzi Vellasco, Tanscheit	17,78%
25	Ruta, Gabrys	17,90%
26	Isa	18,07%
27	CI Benchmark - Naive SVR	18,37%
28	Fillon, Bartoli, Poloni	18,39%
29	CI Benchmark - Naive MLP	18,69%
30	Stat. Contender - Lewicke	19,51%

Πίνακας 4.11 Αποτελέσματα NN3 στο υποσύνολο των δεδομένων (B:11 χρονοσειρές)

5|| ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ



5.1 ΕΙΣΑΓΩΓΗ

Πρόσφατες ερευνητικές διαδικασίες στα Νευρωνικά Δίκτυα (ANNs) έχουν αποδείξει ότι τα ΝΔ έχουν ισχυρές ικανότητες αναγνώρισης και ταξινόμησης προτύπων. Εμπνευσμένα από τα βιολογικά συστήματα, και ειδικά από την λειτουργία του ανθρώπινου μυαλού, τα ΝΔ είναι ικανά να μάθουν και να γενικευθούν από την “εμπειρία”. Σήμερα τα νευρωνικά δίκτυα χρησιμοποιούνται σε ένα μεγάλο αριθμό εργασιών που καλύπτουν διάφορα πεδία όπως επιχειρήσεις, βιομηχανίες και επιστήμες (Widrow et al., 1994). Μια από τις σημαντικότερες περιοχές εφαρμογής των ΝΔ είναι και οι προβλέψεις (Sharda, 1994).

Τυπικά παραθέτουμε δύο ορισμούς που έχουν δοθεί για τα ΝΔ:

- *Haykin98*: Μια μηχανή που έχει σχεδιαστεί με σκοπό να μοντελοποιήσει τον τρόπο με τον οποίο το ανθρώπινο μυαλό λειτουργεί σε μια συγκεκριμένη εργασία. Το δίκτυο προσαρμόζεται και εκτελείται σε κατάλληλο λογισμικό ηλεκτρονικού υπολογιστή.
- *Zell97*: Μια κλάση στατιστικών μεθόδων για επεξεργασία πληροφοριών. Αυτές αποτελούνται από ένα μεγάλο αριθμό από απλές μονάδες επεξεργασίας (νευρώνες), οι οποίες ανταλλάσσουν πληροφορίες μέσω απευθείας συνδέσεων.

Στο παρακάτω σχήμα φαίνεται παραστατικά η γενική δομή ενός νευρωνικού δικτύου:

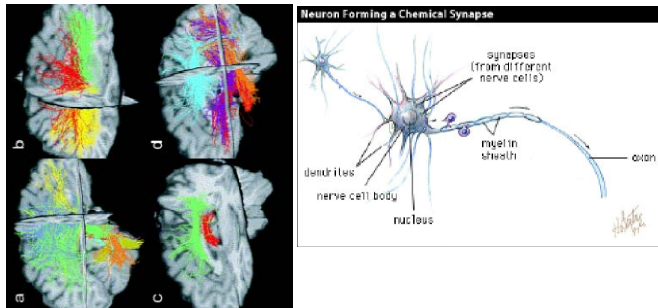


Πίνακας 5.1 Γενική δομή ενός Νευρωνικού Δικτύου

5.2 ΕΜΠΝΕΥΣΗ ΑΠΟ ΤΗ ΒΙΟΛΟΓΙΑ


Τα Νευρωνικά Δίκτυα σαν ιδέα παρουσιάστηκαν για πρώτη φορά σε εμπειρικές έρευνες των McCulloch και Pitts το 1943. Αποτελούν μαθηματικά μοντέλα τα οποία εμπνεύστηκαν από την λειτουργία των βιολογικών νευρώνων. Θέλησαν να αντιγράψουν τα νευρικά συστήματα των ανθρώπων όπως και άλλων ζώων και εντόμων (π.χ. νυχτερίδα) λόγω των πολλών και ξεχωριστών ικανοτήτων που διαθέτουν. Δεν είναι εξάλλου τυχαία η έκφραση που χρησιμοποιείται συχνά ότι ο ανθρώπινος νους είναι το πιο έξυπνο και πολύπλοκο computer που υπάρχει μέχρι

στιγμής. Σχηματικά παρακάτω παρουσιάζεται η μετάβαση από τα φυσικά νευρωνικά δίκτυα στα αντίστοιχα τεχνητά:

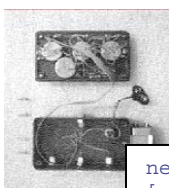
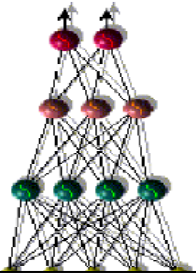
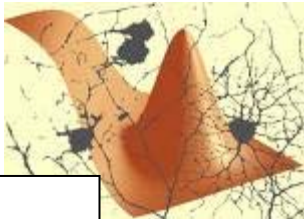


ΒΙΟΛΟΓΙΚΑ ΝΕΥΡΩΝΙΚΑ

ΔΙΚΤΥΑ



ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

```

neural_net = eval(net_name);
[num_rows, ins] =
size(neural_net.iw{1});
[outs,num_cols] =
size(neural_net.lw{neural_net.num
Layers,
neural_net.numLayers-1});
if
(strcmp(neural_net.adaptFcn, ''))
net_type = 'RBF';
else net_type = 'MLP';
end
    
```

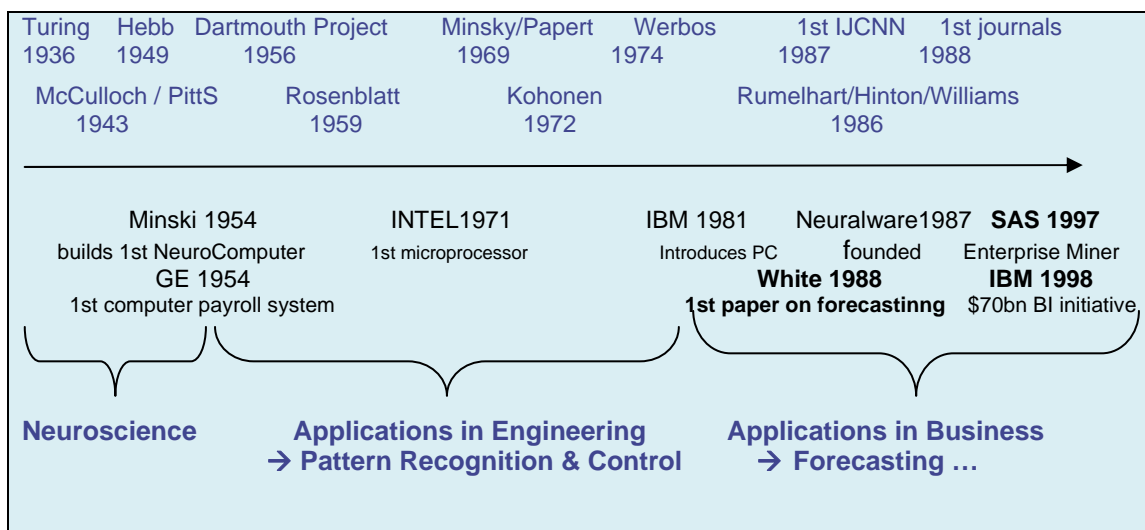


Σχήμα 5.1 Μετάβαση από τα βιολογικά ΝΔ στα τεχνητά ΝΔ

5.3 ΙΣΤΟΡΙΑ

Η πρώτη απόπειρα εφαρμογής των ΝΔ σε πραγματικά δεδομένα έγινε το 1964. Ο Hu(1964) στην έρευνά του χρησιμοποιεί το προσαρμοζόμενο γραμμικό μοντέλο του Widrow για την πρόβλεψη των καιρικών συνθηκών. Εξαιτίας της τότε έλλειψης training αλγορίθμου για πολυστρωματικά δίκτυα, η έρευνα ήταν αρκετά περιορισμένη. Μεγάλη εξέλιξη στην χρησιμοποίηση των ΝΔ για την παραγωγή προβλέψεων πραγματοποιήθηκε με την ανάπτυξη του αλγορίθμου backpropagation (Rumelhart et al., 1986b). Ο Werbos (1974),(1988) πρώτος εφάρμοσε τον αλγόριθμο backpropagation και βρήκε ότι τα ΝΔ που χρησιμοποίησαν τον αλγόριθμο αυτό είχαν καλύτερα αποτελέσματα από τις παραδοσιακές στατιστικές μεθόδους όπως η απλή γραμμική παλινδρόμηση και οι προσεγγίσεις των Box-Jenkins. Οι Lapedes και Farber (1987) διεξήγαγαν μια εμπειρική μελέτη και κατέληξαν ότι τα ΝΔ μπορούν να χρησιμοποιηθούν για την μοντελοποίηση και την πρόβλεψη μη γραμμικών χρονοσειρών. Οι Weigend et al.(1990), Cottrell et al.(1995) έφεραν στην επιφάνεια το θέμα της αρχιτεκτονικής του δικτύου όταν χρησιμοποιείται για πρόβλεψη πραγματικών χρονοσειρών. Οι Tang et al.(1991), Sharda, Patil (1992) και Tang, Fishwick(1993) , μεταξύ άλλων, παρουσίασαν αποτελέσματα από διάφορες συγκρίσεις προβλέψεων μεταξύ μεθόδου Box-Jenkins και μοντέλων ΝΔ. Σε ένα διαγωνισμό προβλέψεων που διοργανώθηκε το 1993 από τους Weigend και Gershenfeld σε συνεργασία με το Santa Fe Institute, οι νικητές σε κάθε σύνολο δεδομένων χρησιμοποίησαν νευρωνικά δίκτυα (Gershenfeld και Weigend,1993).

Αξιοσημείωτες είναι οι ερευνητικές προσπάθειες στον τομέα των προβλέψεων με χρήση Νευρωνικών Δικτύων. Οι Marquez et al.(1992) και Hill et al.(1994) επαναλαμβάνοντας την ήδη υπάρχουσα γνώση για τα ΝΔ, σύγκριναν τα ΝΔ με στατιστικά μοντέλα των μεθόδων χρονοσειρών και των μεθόδων παλινδρόμησης. Ακολουθεί ένας πίνακας με τα κυριότερα βήματα στην εξέλιξη και εφαρμογή των ΝΔ. Τα ΝΔ συνεχίζουν να εξελίσσονται με στόχο να πετυχαίνουν μεγαλύτερη ακρίβεια.



Πίνακας 5.2 Τα κυριότερα βήματα στην εξέλιξη των νευρωνικών δικτύων

5.4 ΙΔΙΑΙΤΕΡΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Τα νευρωνικά δίκτυα αποτελούν ένα νέο και παράλληλα αρκετά ελκυστικό εργαλείο τόσο για τους ερευνητές όσο και για τους εκπαιδευόμενους στον τομέα των προβλέψεων. Αρκετά είναι τα ιδιαίτερα χαρακτηριστικά των νευρωνικών δικτύων που τα ξεχωρίζουν από τις υπόλοιπες μεθόδους πρόβλεψης.

Αρχικά, αντίθετα με τις κλασσικές μεθόδους πρόβλεψης, τα νευρωνικά δίκτυα είναι μοντέλα που προσαρμόζονται εύκολα στα δεδομένα σε περιπτώσεις όπου υπάρχουν λίγες a priori υποθέσεις για τα μοντέλα των προβλημάτων που εξετάζονται. ‘Μαθαίνουν’ από τα παραδείγματα και συλλαμβάνουν τις λογικές λειτουργικές σχέσεις μεταξύ των στοιχείων ακόμα και αν οι ελλοχεύουσες σχέσεις είναι άγνωστες ή δύσκολες να περιγραφούν. Κατά συνέπεια τα ΝΔ είναι κατάλληλα για προβλήματα των οποίων οι λύσεις απαιτούν γνώση που είναι δύσκολο να διευκρινιστεί αλλά για τα οποία υπάρχουν αρκετά στοιχεία και παρατηρήσεις. Από αυτή την άποψη μπορούν να αντιμετωπιστούν ως μια από τις διάφορες μη γραμμικές και μη παραμετρικές στατιστικές μεθόδους (White, 1989; Ripley, 1993; Cheng and Titterington,

1994). Αυτή η προσέγγιση μοντελοποίησης με τη δυνατότητα να μάθει από την εμπειρία είναι πολύ χρήσιμη για πολλά πρακτικά προβλήματα δεδομένου ότι είναι συχνά ευκολότερο να υπάρξουν στοιχεία από το να υπάρχουν καλές θεωρητικές εικασίες για τους ελλοχεύοντες νόμους που κυβερνούν τα συστήματα από τα οποία τα στοιχεία παράγονται. Το πρόβλημα με αυτή την προσέγγιση μοντελοποίησης είναι ότι οι ελλοχεύοντες κανόνες δεν είναι πάντα εμφανείς και οι παρατηρήσεις καλύπτονται συχνά από θόρυβο. Εντούτοις παρέχει ένα πρακτικό και, σε μερικές καταστάσεις τον μόνο εφικτό τρόπο για να λυθούν πραγματικά προβλήματα.

Δεύτερον, τα νευρωνικά δίκτυα μπορούν να γενικευθούν. Αφού μάθουν από το δείγμα που τους παρουσιάζεται, τα ΝΔ μπορούν συχνά να συμπεράνουν ορθά το 'κρυφό' μέρος ενός πληθυσμού ακόμα και αν τα στοιχεία των δειγμάτων περιέχουν θορυβώδεις πληροφορίες. Δεδομένου ότι η πρόβλεψη εκτελείται μέσω της πρόβλεψης της μελλοντικής συμπεριφοράς (το 'κρυφό' μέρος) από τα παραδείγματα της προηγούμενης συμπεριφοράς, είναι σε γενικές γραμμές ένας ιδανικός τομέας εφαρμογής για τα νευρωνικά δίκτυα. Αξίζει να αναφέρουμε ότι πολλές είναι οι περιπτώσεις όπου μια μοναδική αρχιτεκτονική μοντέλου χρησιμοποιείται σε πολλές διαφορετικές εφαρμογές.

Τρίτον, τα νευρωνικά δίκτυα είναι καθολικά λειτουργικά προσεγγιστικά εργαλεία. Έχει αποδειχθεί ότι ένα δίκτυο μπορεί να προσεγγίσει οποιαδήποτε συνεχή λειτουργία σε οποιαδήποτε επιθυμητή ακρίβεια (Irie and Miyake, 1988; Hornik et al., 1989; Cybenko, 1989; Funahashi, 1989; Hornik, 1991, 1993). Τα ΝΔ έχουν πιο γενικές και ελαστικές λειτουργικές μορφές σχετικά με αυτές στις οποίες μπορούν να εξεταστούν ικανοποιητικά οι παραδοσιακές στατιστικές μέθοδοι. Συγκεκριμένα έχουν ελαστικότητα στις μεταβλητές εισόδου και στις μεταβλητές εξόδου κάτι που σημαίνει ότι παρέχουν και ευέλικτη κωδικοποίηση αυτών. Οποιοδήποτε μοντέλο πρόβλεψης υποθέτει ότι υπάρχει μία κρυμμένη (γνωστή η άγνωστη) σχέση μεταξύ των εισόδων (οι προηγούμενες τιμές των χρονοσειρών ή/και άλλων σχετικών μεταβλητών) και των εξόδων (οι μελλοντικές τιμές). Συχνά, τα παραδοσιακά στατιστικά μοντέλα πρόβλεψης έχουν περιορισμούς στον υπολογισμό της ελλοχεύουσας λειτουργίας

λόγω της πολυπλοκότητας του πραγματικού συστήματος. Τα ΝΔ είναι μια καλή εναλλακτική μέθοδος για να προσδιοριστεί αυτή η λειτουργία.

Τέλος, τα νευρωνικά δίκτυα είναι μη γραμμικά. Οι προβλέψεις είναι από καιρό ο κύριος τομέας απασχόλησης των γραμμικών στατιστικών μεθόδων. Οι παραδοσιακές προσεγγίσεις στην πρόβλεψη χρονοσειράς, όπως η Box-Jenkins ή η μέθοδος ARIMA (Box and Jenkins, 1976; Pankratz, 1983), υποθέτουν ότι οι χρονοσειρές που εξετάζονται παράγονται από γραμμικές διαδικασίες. Τα γραμμικά μοντέλα έχουν πλεονεκτήματα υπό την έννοια ότι μπορούν να γίνουν κατανοητά και να αναλυθούν με μεγάλη λεπτομέρεια και επίσης μπορούν εύκολα να εφαρμοστούν. Εντούτοις, μπορούν να είναι συνολικά ακατάλληλα εάν ο ελλοχεύων μηχανισμός είναι μη γραμμικός. Είναι αδικαιολόγητο να υποτεθεί *a priori* ότι μια ιδιαίτερη πραγματοποίηση μιας δεδομένης χρονοσειράς παράγεται με μια γραμμική διαδικασία. Στην πραγματικότητα, τα πραγματικά συστήματα είναι συνήθως μη γραμμικά (Granger and Terasvirta, 1993).

Κατά τη διάρκεια της τελευταίας δεκαετίας, διάφορα μη γραμμικά μοντέλα χρονοσειρών όπως το διαγραμμικό μοντέλο (Granger and Anderson, 1978), το οριακό αυτοπαλινδρομικό μοντέλο (TAR-Tong and Lim, 1980), και το αυτοπαλινδρομικό ARCH μοντέλο (Engle, 1982) έχουν αναπτυχθεί. Εντούτοις, αυτά τα μη γραμμικά μοντέλα είναι ακόμα περιορισμένα δεδομένου ότι μια ρητή σχέση για τη σειρά στοιχείων προσιτή πρέπει να υποτεθεί με αρκετή γνώση του ελλοχεύοντος νόμου. Στην πραγματικότητα, η διατύπωση ενός μη γραμμικού προτύπου σε ένα ιδιαίτερο σύνολο στοιχείων είναι ένας πολύ δύσκολος στόχος δεδομένου ότι υπάρχουν πάρα πολλά πιθανά μη γραμμικά πρότυπα και ένα συγκεκριμένο γραμμικό πρότυπο μπορεί να μη είναι αρκετά γενικό να συλλάβει όλα τα σημαντικά χαρακτηριστικά γνωρίσματα. Τα τεχνητά νευρωνικά δίκτυα, που είναι μη γραμμικές προσεγγίσεις οδηγούμενες από τα δεδομένα, σε αντίθεση με τις παραπάνω μεθόδους, είναι ικανά για μη γραμμική μοντελοποίηση χωρίς *a priori* γνώση μεταξύ των μεταβλητών εισόδου-εξόδου. Για αυτό το λόγο παρέχουν ένα πιο γενικό και ευέλικτο τρόπο παραγωγής προβλέψεων.

5.4.1 Πλεονεκτήματα-Μειονεκτήματα νευρωνικών δικτύων

Στον παρακάτω πίνακα έχουμε συγκεντρώσει τα βασικά πλεονεκτήματα και μειονεκτήματα των νευρωνικών δικτύων.

ΠΛΕΟΝΕΚΤΗΜΑΤΑ	ΜΕΙΟΝΕΚΤΗΜΑΤΑ
<ul style="list-style-type: none">-Τα ΝΔ μπορούν να προβλέψουν κάθε μοντέλο χρονοσειράς (t+1)-χωρίς προεπεξεργασία- χωρίς να χρειάζεται επιλογή συγκεκριμένου μοντέλου.-Τα ΝΔ προσφέρουν πολλούς βαθμούς ελευθερίας στην μοντελοποίηση.-ελευθερία στην πρόβλεψη με ένα μόνο μοντέλο-Ολοκληρωμένο σύνολο μοντέλων-γραμμικά μοντέλα-μη γραμμικά μοντέλα-Αυτοπαλινδρομικά μοντέλα-μοντέλα απλής και πολλαπλής γραμμικής παλινδρόμησης-μοντέλα με πολλές περιόδους πρόβλεψη μπροστά (μεγάλο ορίζοντα πρόβλεψης)-...	<ul style="list-style-type: none">- Τα ΝΔ προσφέρουν πολλούς βαθμούς ελευθερίας στην μοντελοποίηση.- Η εμπειρία είναι απαραίτητη!- Η έρευνα που γίνεται δεν είναι πάντα ακέραια- Η εξήγηση και μετάφραση των βαρών στα ΝΔ είναι αδύνατη λόγω της μη γραμμικότητας.- Η επίδραση των γεγονότων δεν μπορεί να αφαιρεθεί απευθείας.

Πίνακας 5.3 Πλεονεκτήματα-Μειονεκτήματα νευρωνικών δικτύων

5.5 ΔΟΜΗ & ΛΕΙΤΟΥΡΓΙΑ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

Σε αυτή την ενότητα κάνουμε μια συνοπτική παρουσίαση των τεχνητών νευρωνικών δικτύων. Θα εστιάσουμε την ανάλυσή μας σε μια ιδιαίτερη δομή ΝΔ, τα πολυστρωματικά feedforward δίκτυα, τα οποία αποτελούν το δημοφιλέστερο και ευρέως χρησιμοποιούμενο μοντέλο στον τομέα των προβλέψεων. Για μια γενικότερη εισαγωγή όσον αφορά τα ΝΔ και τις βασικές αρχές τους, μπορεί κάποιος να καταφύγει στην εξής βιβλιογραφία: Wasserman (1989); Hertz et al.(1991); Smith (1993); Rumelhart et al. (1986a),(1986b),(1994),(1995); Lippmann (1987); Hinton (1992); Hammerstorm (1993). Επιπλέον, οι Hush and Horne (1993) σε ένα άρθρο

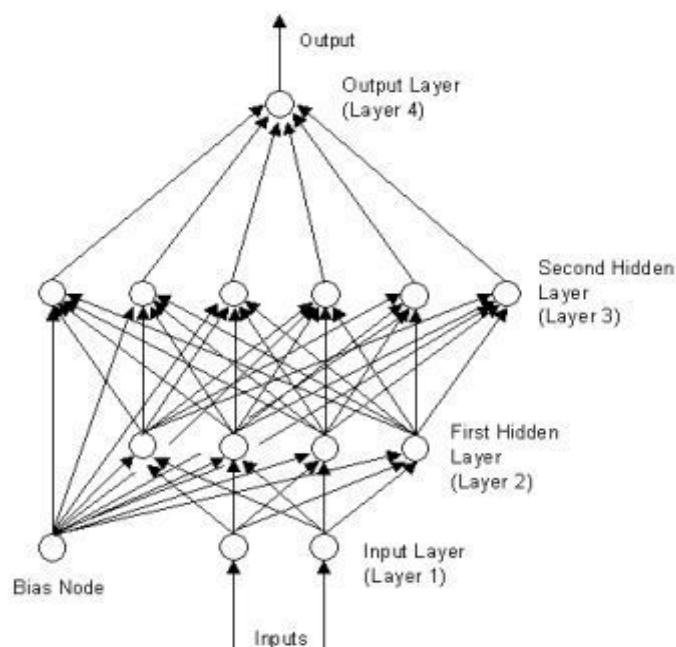
τους συνοψίζουν την θεωρητική πρόοδο που έγινε στον τομέα των ΝΔ μετά το εκπαιδευτικό άρθρο του Lippmann (1987). Οι Masson και Wang δίνουν το 1990 μια λεπτομερή περιγραφή πέντε διαφορετικών μοντέλων. Οι Wilson και Sharda (1992) παρουσίασαν μια περίληψη των εφαρμογών των ΝΔ στον τομέα των επιχειρήσεων. Μια βιβλιογραφία για τις εφαρμογές των ΝΔ στις επιχειρήσεις έδωσε και ο Wong (1995). Οι Kuan και White (1994) συγκεντρώνουν τα μοντέλα των ΝΔ που χρησιμοποιούν οι οικονομολόγοι και καθιερώνουν διάφορα θεωρητικά πλαίσια για την εκμάθηση των ΝΔ. Οι Cheng και Titterington (1994) κάνουν μια λεπτομερή ανάλυση και σύγκριση των παραδειγμάτων των ΝΔ με τις παραδοσιακές στατιστικές μεθόδους.

Τα τεχνητά νευρωνικά δίκτυα αποτελούνται από έναν αριθμό απλών διασυνδεδεμένων στοιχείων επεξεργασίας τα οποία καλούνται νευρώνες ή κόμβοι. Κάθε κόμβος λαμβάνει ένα σήμα εισόδου που είναι οι συνολικές πληροφορίες από άλλους κόμβους ή εξωτερικά ερεθίσματα, το επεξεργάζεται τοπικά μέσω μιας ενεργοποίησης ή μιας συνάρτησης μεταφοράς και παράγει ένα μετασηματοποιημένο σήμα εξόδου το οποίο κατευθύνεται προς έναν άλλο εσωτερικό κόμβο ή ένα κόμβο εξόδου. Αν και κάθε μεμονωμένος νευρώνας λειτουργεί μάλλον αργά και όχι εντελώς σωστά, συλλογικά ένα δίκτυο μπορεί να εκτελέσει έναν εκπληκτικό αριθμό στόχων αρκετά αποτελεσματικά (Reilly and Cooper, 1990). Αυτό το χαρακτηριστικό επεξεργασίας πληροφοριών κάνει το ΝΔ μια ισχυρή υπολογιστική συσκευή ικανή να μάθει από τα παραδείγματα και μετά να γενικευθεί σε άλλες άγνωστες εφαρμογές.

Πολλά διαφορετικά μοντέλα νευρωνικών δικτύων έχουν προταθεί από την δεκαετία του 80' και μετά. Ίσως αυτά με την μεγαλύτερη επίδραση να είναι τα μοντέλα multi layer perceptrons (MLP), τα δίκτυα του Hopfield και τα δίκτυα του Kohonen. Ο Hopfield (1982) προτείνει ένα επαναλαμβανόμενο νευρωνικό δίκτυο που λειτουργεί ως 'συνειρμική' μνήμη. Μια τέτοια μνήμη μπορεί να υπενθυμίζει ένα παράδειγμα από μια μερική ή διαστρεβλωμένη έκδοση. Στα δίκτυα του Kohonen υπάρχει πλήρη συνδεσιμότητα μεταξύ των κόμβων ενώ δεν υπάρχουν επίπεδα. Οι έξοδοι του δικτύου δεν είναι απαραίτητα απόρροια των εξισώσεων των εισόδων. Κυρίως είναι σταθερές καταστάσεις μιας επαναληπτικής διαδικασίας. Οι χαρακτηριστικοί χάρτες του Kohonen (Kohonen 1982) υποκινούνται από την ιδιότητα της οργανωτικής συμπεριφοράς του ανθρώπινου νου.

Τα δίκτυα MLP χρησιμοποιούνται σε ποικίλα προβλήματα και ειδικά στην πρόβλεψη λόγω της έμφυτης ικανότητας για αυθαίρετη σχεδίαση εισόδων-εξόδων. Οι αναγνώστες πρέπει να γνωρίζουν ότι όλοι οι τύποι των νευρωνικών όπως τα δίκτυα με radial-basis λειτουργίες (Park and Sandberg, 1991, 1993; Chng et al.,1996), τα εκτενή πολυονομικά δίκτυα (Shin and Ghosh, 1995) και τα wavelet networks (Zhang and Benveniste, 1992; Delyon et al.,1995) είναι επίσης πολύ χρήσιμα σε μερικές εφαρμογές λόγω της προσεγγιστικής ικανότητάς τους.

Ένα MLP αποτελείται γενικά από διάφορα στρώματα από κόμβους. Το πρώτο ή το χαμηλότερο στρώμα είναι ένα στρώμα εισόδου όπου παραλαμβάνει τις εξωτερικές πληροφορίες. Το τελευταίο ή το υψηλότερο στρώμα είναι ένα στρώμα εξόδου όπου λαμβάνεται η λύση του προβλήματος. Το στρώμα εισόδου και το στρώμα εξόδου χωρίζονται από ένα ή περισσότερα ενδιάμεσα στρώματα αποκαλούμενα κρυμμένα στρώματα. Οι κόμβοι στα παρακείμενα στρώματα συνήθως συνδέονται πλήρως με ακυκλικά τόξα από ένα χαμηλότερο στρώμα σε ένα υψηλότερο στρώμα. Στο σχήμα που ακολουθεί παρουσιάζεται ένα πλήρως συνδεδεμένο feedforward MLP με δύο κρυμμένα επίπεδα:



Σχήμα 5.2 MLP με δύο κρυμμένα επίπεδα

Για ένα επεξηγηματικό ή αιτιοκρατικό πρόβλημα πρόβλεψης, οι εισοδοί σε ένα νευρωνικό δίκτυο είναι συνήθως οι ανεξάρτητες μεταβλητές. Η υπολογιστική σχέση που προκύπτει από το ΝΔ μπορεί να γραφεί ως εξής:

$$y = f(x_1, x_2, \dots, x_p),$$

όπου x_1, x_2, \dots, x_p είναι οι p ανεξάρτητες μεταβλητές και y η εξαρτημένη μεταβλητή. Από αυτή την άποψη, το νευρωνικό δίκτυο είναι λειτουργικά ισοδύναμο με ένα μη γραμμικό μοντέλο παλινδρόμησης. Από τη άλλη πλευρά, για ένα πρόβλημα προέκτασης στο μέλλον ή για ένα πρόβλημα πρόβλεψης χρονοσειρών, οι εισοδοί είναι οι προηγούμενες διαθέσιμες παρατηρήσεις και η έξοδος είναι η μελλοντική τιμή του μεγέθους. Σε αυτό το πρόβλημα, η εξίσωση που προκύπτει από το ΝΔ γράφεται ως εξής:

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-p})$$

όπου y_t είναι η παρατήρηση στον χρόνο t . Έτσι το ΝΔ είναι ισοδύναμο με το μη γραμμικό αυτοπαλινδρομικό μοντέλο που χρησιμοποιείται για την πρόβλεψη προβλημάτων χρονοσειρών. Είναι επίσης εύκολο να ενσωματωθούν οι μεταβλητές πρόβλεψης με τις προηγούμενες παρατηρήσεις σε ένα ΝΔ, το οποίο ανέρχεται σε ένα γενικό μοντέλο λειτουργίας. Για μια ανάλυση της σχέσης μεταξύ ΝΔ και μοντέλων ARMA μπορεί κανείς να απευθυνθεί στο αντίστοιχο σύγγραμμα του Suykens (1996).

Προτού μπορέσει να χρησιμοποιηθεί ένα νευρωνικό δίκτυο για να εκτελέσει μια συγκεκριμένη εργασία, πρέπει πρώτα να εκπαιδευτεί. Βασικά η εκπαίδευση είναι η διαδικασία προσδιορισμού των βαρών των τόξων, τα οποία είναι τα βασικά στοιχεία ενός ΝΔ. Η γνώση που αποκτάται από ένα δίκτυο αποθηκεύεται στα τόξα και τους κόμβους υπό μορφή βαρών τόξων και bias κόμβων. Είναι μέσω των τόξων σύνδεσης ότι ένα ΝΔ μπορεί να πραγματοποιήσει τις σύνθετες μη γραμμικές συνδέσεις από τους κόμβους εισόδου στους κόμβους εξόδου. Μια εκπαίδευση ενός MLP είναι εποπτευόμενη δεδομένου ότι η επιθυμητή απάντηση του δικτύου για κάθε δεδομένη είσοδο είναι πάντα διαθέσιμη.

Τα δεδομένα εισόδου είναι υπό μορφή διανυσμάτων των μεταβλητών εισόδου. Η αντιστοιχία σε κάθε ένα διάνυσμα εισόδου είναι ένας κόμβος εισαγωγής

στο επίπεδο εισόδου του δικτύου. Ως εκ τούτου ο αριθμός των κόμβων εισόδου είναι ίσος με την διάσταση των διανυσμάτων εισαγωγής. Για ένα αιτιοκρατικό πρόβλημα πρόβλεψης, ο αριθμός των κόμβων εισαγωγής είναι καλά ορισμένος και είναι ο αριθμός των ανεξάρτητων μεταβλητών που συνδέονται με το πρόβλημα. Για ένα πρόβλημα πρόβλεψης χρονοσειράς, εντούτοις, ο κατάλληλος αριθμός κόμβων εισόδου δεν είναι εύκολο να καθοριστεί. Ανεξαρτήτως διάστασης, το διάνυσμα εισόδου για ένα πρόβλημα πρόβλεψης χρονοσειράς σχεδόν πάντα αποτελείται από ένα παράθυρο σταθερού μήκους κινούμενο κατά μήκος της χρονοσειράς. Τα συνολικά διαθέσιμα δεδομένα συνήθως διαιρούνται σε ένα σύνολο εκπαίδευσης (training set) και σε ένα σύνολο για τις δοκιμές (testing set). Το training set χρησιμοποιείται για τον υπολογισμό των βαρών των τόξων ενώ το σύνολο δοκιμής χρησιμοποιείται για την μέτρηση της δυνατότητας γενίκευσης του δικτύου.

Η διαδικασία εκπαίδευσης γίνεται συνήθως ως εξής. Πρώτα, τα παραδείγματα του training set εισάγονται στους κόμβους εισόδου του δικτύου. Οι τιμές ενεργοποίησης των κόμβων εισόδου σταθμίζονται και συσσωρεύονται σε κάθε κόμβο στο πρώτο κρυμμένο επίπεδο. Το σύνολο μετασχηματίζεται στη συνέχεια στην αξία ενεργοποίησης του κάθε κόμβου. Αυτό στη συνέχεια γίνεται η είσοδος στο επόμενο επίπεδο, έως ότου τελικά βρεθούν οι τιμές ενεργοποίησης των εξόδων. Ο αλγόριθμος εκπαίδευσης (training algorithm) χρησιμοποιείται για να βρεθούν τα βάρη που ελαχιστοποιούν κάποιο επιλεγμένο μέτρο ακρίβειας όπως για παράδειγμα το μέσο τετραγωνικό σφάλμα (MSE). Ως εκ τούτου η 'εκπαίδευση' των δικτύων είναι στην ουσία ένα μη γραμμικό πρόβλημα ελαχιστοποίησης.

Σε ένα πρόβλημα πρόβλεψης χρονοσειρών, μια μέθοδος εκπαίδευσης αποτελείται από ένα συγκεκριμένο αριθμό προηγούμενων παρατηρήσεων της χρονοσειράς. Ας υποθέσουμε ότι έχουμε N παρατηρήσεις y_1, y_2, \dots, y_N στο training set και χρειαζόμαστε πρόβλεψη για μια περίοδο μπροστά, τότε χρησιμοποιώντας ένα $N\Delta$ με n κόμβους εισόδου, έχουμε $N-n$ μεθόδους εκπαίδευσης. Η πρώτη μέθοδος εκπαίδευσης θα αποτελείται από τις y_1, y_2, \dots, y_n ως εισόδους και την y_{n+1} ως έξοδο. Η δεύτερη μέθοδος εκπαίδευσης θα περιέχει τις y_2, y_3, \dots, y_{n+1} ως εισόδους και την y_{n+2} ως την επιθυμητή έξοδο. Τέλος, η τελευταία μέθοδος εκπαίδευσης θα περιέχει

τις $y_{N-n}, y_{N-n+1}, \dots, y_{N-1}$ ως εισόδους και την y_N ως έξοδο. Αναφέρουμε ότι μια αντικειμενική συνάρτηση βασισμένη στο μέτρο ακρίβειας SSE ή μια συνάρτηση κόστους που πρόκειται να ελαχιστοποιηθεί κατά τη διάρκεια της διαδικασίας εκπαίδευσης εκφράζεται με την παρακάτω σχέση:

$$E = \frac{1}{2} \sum_{i=n+1}^N (y_i - a_i)^2,$$

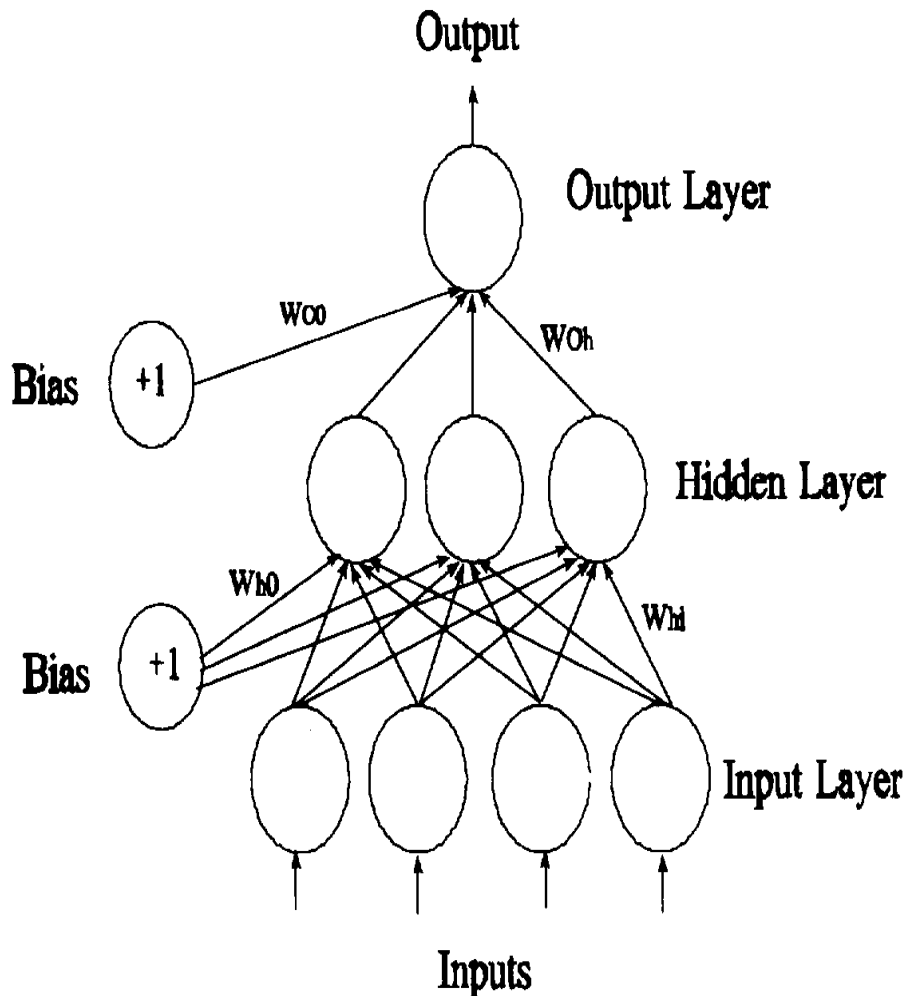
όπου a_i είναι η πραγματική έξοδος του δικτύου και η ποσότητα $\frac{1}{2}$ περιλαμβάνεται για την απλούστευση της έκφρασης των παραγώγων που προέκυψαν από τον αλγόριθμο εκπαίδευσης.

Το νευρωνικό δίκτυο MLP που χρησιμοποιεί τον αλγόριθμο εκπαίδευσης back-propagation (BP) είναι η πιο κοινή τοπολογία δικτύου που χρησιμοποιείται για πρόβλεψη χρονοσειρών. Αποτελείται από έναν αριθμό εισόδων και μονάδων επεξεργασίας που καλούνται όπως αναφέραμε παραπάνω, νευρώνες. Οι νευρώνες σε κάθε επίπεδο είναι πλήρως συνδεδεμένοι με συγκεκριμένα βάρη τα οποία, μαζί με την αρχιτεκτονική του δικτύου, αποτελούν την γνώση ενός 'εκπαιδευμένου' δικτύου. Μαζί με τους νευρώνες επεξεργασίας υπάρχει και ένας νευρώνας συστηματικού σφάλματος (bias) ο οποίος συνδέεται με κάθε νευρώνα επεξεργασίας του κρυμμένου επιπέδου και του επιπέδου εξόδου. Ο νευρώνας συστηματικού σφάλματος έχει τιμή ίση με +1. Ο αριθμός των κρυφών επιπέδων και των νευρώνων σε κάθε επίπεδο ποικίλλει ανάλογα με το μέγεθος και τη φύση των δεδομένων της χρονοσειράς.

Τα δίκτυα BP ανήκουν και αυτά στην κατηγορία των feedforward δικτύων. Ο όρος feedforward αναφέρεται στην κατεύθυνση της ροής πληροφορίας από το επίπεδο εισόδου στο επίπεδο εξόδου. Οι είσοδοι περνούν μέσα στο δίκτυο και είναι αυτές που διαμορφώνουν τις τελικές εξόδους. Η εποπτευόμενη εκμάθηση είναι η διαδικασία σύγκρισης κάθε πρόβλεψης του δικτύου με την ήδη γνωστή σωστή απάντηση και η εκ νέου ρύθμιση των βαρών βασισμένη στο σφάλμα της προκύπτουσας πρόβλεψης και με στόχο την ελαχιστοποίηση της εξίσωσης σφάλματος.

Το δίκτυο BP είναι το πιο κοινό πολυεπίπεδο δίκτυο και υπολογίζεται ότι χρησιμοποιείται περίπου στο 80% των εφαρμογών των ΝΔ στις προβλέψεις. Άλλα δίκτυα λιγότερο χρησιμοποιούμενα στην πρόβλεψη χρονοσειρών είναι τα recurrent

δίκτυα, τα probabilistic δίκτυα και τα fuzzy ΝΔ (ασαφή ΝΔ). Στο σχήμα 5.3 φαίνεται ένα feedforward backpropagation νευρωνικό δίκτυο:



Σχήμα 5.3 Νευρωνικό δίκτυο Back-propagation (BP)

Στον παρακάτω πίνακα αναφέρονται οι παράμετροι που είναι αναγκαίες στον σχεδιασμό ενός ΝΔ που χρησιμοποιεί τον αλγόριθμο back-propagation:

Προεπεξεργασία δεδομένων

συχνότητα των δεδομένων- ημερήσια, εβδομαδιαία, μηνιαία, τριμηνιαία
τύπος δεδομένων- τεχνικά, θεμελιώδη
μέθοδος δειγματοληψίας δεδομένων
μέθοδος ταξινόμησης των δεδομένων- μέγιστο/ελάχιστο, μέση/σταθερή τυπική απόκλιση

Εκπαίδευση(training)

ρυθμός εκπαίδευσης ανά επίπεδο
ταχύτητα
ανεκτικότητα εκπαίδευσης
μέγεθος εποχής
όριο ρυθμού εκπαίδευσης
μέγιστος αριθμός δοκιμών
αριθμός χρόνων για την τυχαιότητα των βαρών
μέγεθος του συνόλου εκπαίδευσης, δοκιμής και αξιολόγησης (training, test and validation sets)

Τοπολογία

αριθμός των νευρώνων εισόδου
αριθμός των κρυμμένων επιπέδων
αριθμός των κρυμμένων νευρώνων σε κάθε επίπεδο
αριθμός των νευρώνων εξόδου
συνάρτηση μεταφοράς για κάθε νευρώνα
συνάρτηση σφάλματος

Πίνακας 5.4 Αναγκαίες παράμετροι για τον σχεδιασμό ενός BP νευρωνικού δικτύου

5.6 ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΠΡΟΒΛΕΨΕΙΣ

Τα προβλήματα πρόβλεψης προκύπτουν σε τόσες πολλές διαφορετικές εφαρμογές και η βιβλιογραφία σχετικά με την πρόβλεψη με χρήση νευρωνικών δικτύων είναι διεσπαρμένη σε τόσους πολλούς διαφορετικούς τομείς που είναι δύσκολο για έναν ερευνητή να γνωρίζει όλες τις εργασίες που έχουν γίνει μέχρι τώρα στον γενικότερο τομέα. Στο σημείο αυτό θα αναφερθούμε λίγο εκτενέστερα στις διάφορες ερευνητικές δραστηριότητες που έχουν γίνει στον τομέα της πρόβλεψης με νευρωνικά δίκτυα. Περισσότερες από 2500 άρθρα που αναφέρονται σε ΝΔ και προβλέψεις έχουν δημοσιευθεί.

Μια από τις πρώτες επιτυχείς εφαρμογές των ΝΔ στις προβλέψεις αναφέρεται από τους Lapedes και Farber (1987), (1988). Χρησιμοποιώντας δύο αιτιοκρατικές χασοτικές χρονοσειρές που παρήχθησαν από τον λογιστικό χάρτη και την εξίσωση Glass-Mackey, σχεδίασαν τα feedforward νευρωνικά δίκτυα τα οποία μπορούν με μεγάλη ακρίβεια να μιμηθούν και να προβλέψουν τέτοια δυναμικά μη γραμμικά συστήματα. Τα αποτελέσματά τους δείχνουν ότι τα ΝΔ μπορούν να χρησιμοποιηθούν με μεγάλη ακρίβεια για την διαμόρφωση και την πρόβλεψη της μη γραμμικής χρονοσειράς.

Ακολουθώντας τους Lapedes και Farber, ένας μεγάλος αριθμός άρθρων αναφέρθηκε στη χρησιμοποίηση των ΝΔ για την ανάλυση και την πρόβλεψη της αιτιοκρατικής χασοτικής χρονοσειράς με ή και χωρίς θόρυβο. Οι χασοτικές χρονοσειρές εμφανίζονται συνήθως στην μηχανική και στις φυσικές επιστήμες δεδομένου ότι τα περισσότερα φυσικά φαινόμενα παράγονται από τα μη γραμμικά χασοτικά συστήματα. Κατά συνέπεια, πολλοί συντάκτες που ασχολήθηκαν με την μοντελοποίηση και πρόβλεψη της χασοτικής χρονοσειράς είναι από τον τομέα της φυσικής. Οι Lowe και Webb (1990) συζητούν για την σχέση μεταξύ των δυναμικών συστημάτων και της λειτουργικής παρεμβολής με ΝΔ. Ο Deppisch (1991) πρότεινε ένα ιεραρχικά εκπαιδευμένο μοντέλο νευρωνικού δικτύου στο οποίο μια δραματική βελτίωση στην ακρίβεια επιτυγχάνεται για την πρόβλεψη δυο χασοτικών συστημάτων. Άλλα έγγραφα που χρησιμοποιούν χασοτικές χρονοσειρές περιλαμβάνουν τα : Jones et al. (1990); Chan and Prager (1994); Rosen (1993); Ginzburg and Horn (1991),(1992); Poli and Jones (1994).

Επιπλέον υπάρχει μια εκτενής βιβλιογραφία στις οικονομικές εφαρμογές των νευρωνικών δικτύων (Trippi and Turban, 1993; Azoff,1994; Refenes, 1995; Gately, 1996). Τα ΝΔ έχουν χρησιμοποιηθεί για την πρόβλεψη της χρεοκοπίας και της πτώχευσης των επιχειρήσεων (Odom and Sharda , 1990; Coleman et al., 1991; Salchenkerger et al.,(1992); Tam and Kiang, 1992; Fletcher and Goss, 1993; Wilson and Sharda,1994), για το ποσοστό συναλλάγματος (Weigend et al.,1992; Refenes, 1993; Borisov and Pavlov, 1995; Kuan and Liu,1995; Wu, 1995; Hann and Steurer, 1996), για τιμές αποθέματος (White, 1988; Kimoto et al., 1990; Schoneburg, 1990;

Bergerson and Wunsch, 1991; Yoon and Swales, 1991; Grudnitski and Osburn, 1993), και για άλλες εφαρμογές (Dutta and Shekhar, 1988; Sen et al., 1992; Wong et al., 1992; Kryzanoski et al., 1993; Chen, 1994; Refenes et al., 1994; Kaastra and Boyd, 1995; Wong and Long, 1995; Chiang et al., 1996; Kohzadi et al., 1996).

Μια άλλη σημαντική εφαρμογή των νευρωνικών δικτύων στις προβλέψεις είναι στην μελέτη κατανάλωσης ηλεκτρικού φορτίου. Η πρόβλεψη φορτίων είναι μια περιοχή που απαιτεί υψηλή ακρίβεια δεδομένου ότι το απόθεμα ηλεκτρικού φορτίου εξαρτάται ιδιαίτερα από την πρόβλεψη της απαίτησης των φορτίων. Οι Park και Sandberg (1991) ανέφεραν ότι απλά ΝΔ με εισόδους τις πληροφορίες της θερμοκρασίας έχουν πολύ καλύτερα αποτελέσματα από την συνήθως χρησιμοποιούμενη παλινδρομική μέθοδο που προέβλεπε συνολική, ωριαία και μέγιστη κατανάλωση φορτίου. Οι Bacha και Meyer συζητούν το γιατί τα ΝΔ είναι κατάλληλα για την πρόβλεψη φορτίων και προτείνουν ένα σύστημα από διαδοχικά υποδίκτυα. Αργότερα χρησιμοποιήθηκε ένα MLP τεσσάρων επιπέδων για την πρόβλεψη του ωριαίου φορτίου ενός συστήματος ενέργειας (Srinivasan et al., 1994). Άλλες μελέτες σε αυτόν τον τομέα περιλαμβάνουν τους: Bakirtzis et al. (1995); Brace et al. (1991); Chen et al. (1991); Dash et al. (1995); El-Sharkawi et al. (1991); Ho et al. (1992); Hsu and Yang (1991a), (1991b); Hwang and Moon (1991); Kiartzis et al. (1995); Lee et al. (1991); Lee and Park (1992); Muller and Mangeas (1993); Pack et al. (1991a,b); Peng et al. (1992); Pelikan et al. (1992); Ricardo et al. (1995).

Πολλά ακόμα προβλήματα προβλέψεων έχουν αντιμετωπισθεί με νευρωνικά δίκτυα. Κάποια από αυτά είναι η αερομεταφερόμενη γύρη (Arizmendi et al., 1993), οι τιμές των προϊόντων (Kohzadi et al., 1996), η θερμοκρασία του περιβάλλοντος (Balestrino et al., 1994), τα φορτία των ελικοπτέρων (Haas et al., 1995), η διεθνής κυκλοφορία επιβατών αερογραμμών (Nam and Schaefer (1995)), διάφοροι μακροοικονομικοί δείκτες (Maasoumi et al., 1994), το επίπεδο όζοντος (Ruiz-Suarez et al., 1995), ο μέσος όρος βαθμολογίας μαθητών (Gorr et al., 1994), η συνολική βιομηχανική παραγωγή (Aiken et al., 1995), η ζήτηση νερού (Lubero, 1991).

5.8 ΣΧΕΤΙΚΗ ΕΠΙΔΟΣΗ ΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΣΤΙΣ ΠΡΟΒΛΕΨΕΙΣ

Για να έχει κάποιος μια πιο ολοκληρωμένη εικόνα σχετικά με την επίδοση των ΝΔ στον τομέα των προβλέψεων πρέπει να συγκριθούν τα αποτελέσματά τους με τα αντίστοιχα αποτελέσματα των κλασσικών στατιστικών μεθόδων. Πολλοί ερευνητές χρησιμοποιούν τα δεδομένα του διαγωνισμού-M για την σύγκριση της απόδοσης των ΝΔ με τα παραδοσιακά στατιστικά μοντέλα. Τα περισσότερα δεδομένα είναι συνήθως από τον επιχειρηματικό κλάδο, την οικονομία και το χρηματιστήριο. Αρκετά σημαντική δουλειά έχουν κάνει οι Kang (1991); Sharda and Patil (1992); Tang et al.(1991); Foster et al.(1992); Tang and Fishwick (1993); Hill et al.(1994), (1996). Στον διαγωνισμό Santa Fe (weigend and Gerschenfeld, 1993) χρησιμοποιούνται έξι μη γραμμικές χρονοσειρές από πολύ διαφορετικούς τομείς όπως η φυσική, η φυσιολογία, η αστροφυσική, το χρηματιστήριο και ακόμη και η μουσική. Όλα τα σύνολα δεδομένων είναι πολύ μεγάλα συγκρινόμενα με τα αντίστοιχα του διαγωνισμού –M όπου όλες οι χρονοσειρές είναι αρκετά μικρές.

Στην βιβλιογραφία υπάρχουν πολλές αναφορές στην επίδοση των νευρωνικών δικτύων σε θέματα προβλέψεων οι οποίες είναι αντικρουόμενες και καταλήγουν σε παράλογα μερικές φορές συμπεράσματα. Ο κύριος λόγος που συμβαίνει αυτό είναι ότι ένας μεγάλος αριθμός παραγόντων, συμπεριλαμβανομένου της αρχιτεκτονικής του δικτύου, της μεθόδου εκπαίδευσης του, και των δεδομένων του αρχικού δείγματος, μπορεί να επηρεάσει την ικανότητα των μοντέλων να παράγουν ορθές και ακριβείς προβλέψεις. Σε κάποιες περιπτώσεις τα ΝΔ καταλήγουν σε χειρότερα αποτελέσματα από τα γραμμικά στατιστικά μοντέλα. Ο λόγος για αυτό μπορεί αν είναι απλά ότι τα δεδομένα είναι γραμμικά χωρίς μεγάλες διακυμάνσεις. Σε αυτή την περίπτωση είναι απόλυτα φυσιολογικό τα γραμμικά μοντέλα να είναι καλύτερα από τα ΝΔ για γραμμικές σχέσεις. Σε άλλες πάλι περιπτώσεις ο λόγος μπορεί να είναι απλά ότι δεν χρησιμοποιήθηκε η κατάλληλη για τα συγκεκριμένα δεδομένα αρχιτεκτονική του δικτύου.

Στον πίνακα 5.5 αναφέρονται οι κυριότερες μελέτες που έχουν γίνει με στόχο τη σύγκριση της επίδοσης των νευρωνικών δικτύων με τα παραδοσιακά στατιστικά μοντέλα.

ΜΕΛΕΤΗ	ΔΕΔΟΜΕΝΑ	ΑΠΟΤΕΛΕΣΜΑΤΑ
Brace et al.(1991)	8 ημερήσιες σειρές ηλεκτρικού φορτίου(ημερ.)	Τα ΝΔ δεν είναι τόσο καλά όσο οι παραδοσιακές μέθοδοι
Caire et al.(1992)	1 σειρά δεδομένων(ημερήσια) ηλεκτρικής κατανάλωσης	Τα ΝΔ είναι ελάχιστα καλύτερα από τα ARIMA για πρόβλεψη 1 περιόδου μπροστά αλλά είναι πολύ πιο αξιόπιστα για μεγαλύτερες περιόδους πρόβλεψης
Chakraborty et al.(1992)	1 χρονοσειρά (μηνιαία) τρισθενούς τιμής	τα ΝΔ είναι καλύτερα από τις στατιστικές μεθόδους κατά μια τουλάχιστον τάξη μεγέθους
Denton (1995)	διάφορα σύνολα δεδομένων Παραγόμενα από υπολογιστή	Σε ιδανικές συνθήκες, τα ΝΔ είναι τόσο καλά όσο το μοντέλο της παλινδρόμησης, κάτω από λιγότερο ιδανικές συνθήκες τα ΝΔ έχουν καλύτερα αποτελέσματα
Duliba (1991)	δεδομένα μεταφοράς (τριμηνιαία)	τα ΝΔ είναι καλύτερα από το γραμμικό μοντέλο παλινδρόμησης για κυκλική παρουσίαση δεδομένων, ενώ χειρότερα για σταθερή παρουσίαση.
Fishwick (1989)	δεδομένα βαλλιστικής τροχιάς	τα ΝΔ είναι χειρότερα από το μοντέλο γραμμικής παλινδρόμησης
Foster et al.(1992)	384 οικονομικές και δημογραφικές χρονοσειρές (τριμηνιαίες και ετήσιες)	τα ΝΔ είναι σημαντικά ανώτερα της γραμμικής παλινδρόμησης και της απλής γραμμικής τάσης εκθετικής εξομάλυνσης
Gorr et al.(1994)	μέσοι όροι βαθμολογίας μαθητών	καμία σημαντική βελτίωση
Hann and Steurer(1996)	εβδομαδιαίο και μηνιαίο ποσοστό συναλλάγματος	Τα ΝΔ έχουν καλύτερα αποτελέσματα για τα εβδομαδιαία δεδομένα ενώ για τα μηνιαία δεδομένα ΝΔ και γραμμικά μοντέλα έχουν σχεδόν τα ίδια αποτελέσματα.
Hill et al.(1994) and Hill et al.(1996)	ένα συστηματικό δείγμα από 111 χρονοσειρές (Μηνιαία, τριμηνιαία και ετήσια)	Τα ΝΔ είναι σημαντικά καλύτερα από τις στατιστικές και τις κριτικές μεθόδους για τα τριμηνιαία και τα μηνιαία δεδομένα, σχεδόν το ίδιο για τα ετήσια. Τα ΝΔ φαίνεται ότι είναι καλύτερα στην πρόβλεψη μηνιαίων και τριμηνιαίων από ότι ετήσιων.

Kang (1991)	50 χρονοσειρές από τον Διαγωνισμό –M	Το καλύτερο ΝΔ είναι πάντα πιο καλό από τη μέθοδο Box-Jenkins, τα ΝΔ έχουν καλύτερα αποτελέσματα καθώς αυξάνεται ο ορίζοντας πρόβλεψης. Τα ΝΔ χρειάζονται λιγότερα δεδομένα για να έχουν παρόμοια αποτελέσματα με τα ARIMA μοντέλα
Kohzadi et al.(1996)	μηνιαίες τιμές σιταριού και ζωντανών βοδιών	Τα ΝΔ είναι αξιοσημείωτα καλύτερα
Lachtermacher and Fuller (1995)	4 σταθερές χρονοσειρές ροής ποταμού και 4 μη σταθερές χρονοσειρές ηλεκτρικού φορτίου (ετήσιες)	για τις σταθερές χρονοσειρές, τα ΝΔ έχουν ελάχιστα καλύτερη γενική επίδοση από τις παραδοσιακές μεθόδους. Για τις μη σταθερές χρονοσειρές, τα ΝΔ είναι καλύτερα από τα ARIMA.
Marquez et al.(1992)	προσομοιωμένα δεδομένα από 3 μοντέλα παλινδρόμησης	Τα ΝΔ έχουν σχεδόν ίδια αποτελέσματα με τα μοντέλα παλινδρόμησης
Nam and Schaefer (1995)	μηνιαία δεδομένα κυκλοφορίας επιβατών αερογραμμών	Τα αποτελέσματα των νευρωνικών δικτύων είναι καλύτερα από αυτά των μεθόδων παλινδρόμησης και εκθετικής εξομάλυνσης.
Refenes (1993)	χρονοσειρές ρυθμού ενός συναλλάγματος (ωριαίες)	Τα ΝΔ είναι πολύ καλύτερα από τα μοντέλα εκθετικής εξομάλυνσης και από τα ARIMA.
Sharda and Patil (1990)and Sharda and Patil (1992)	75 και 111 χρονοσειρές του διαγωνισμού –M (μηνιαίες, τριμηνιαίες και ετήσιες)	Τα αποτελέσματα των ΝΔ είναι συγκρίσιμα με αυτά των μοντέλων Box-Jenkins.
Srinivasan et al.(1994)	1 σύνολο δεδομένων φορτίου	τα ΝΔ είναι καλύτερα από το μοντέλο παλινδρόμησης και τα μοντέλα ARMA
Tang et al.(1991)	3χρονοσειρές επιχειρησιακών δεδομένων (μηνιαία)	Για χρονοσειρές με μεγάλη μνήμη τα ΝΔ και τα μοντέλα ARIMA έχουν σχεδόν τα ίδια αποτελέσματα. Για χρονοσειρές με μικρή μνήμη, τα ΝΔ είναι καλύτερα.
Tang and Fishwick (1993)	14 χρονοσειρές από τον διαγωνισμό –M και 2 πρόσθετες χρονοσειρές επιχειρησιακών δεδομένων (μηνιαία και τριμηνιαία)	Τα ΝΔ είναι καλύτερα από τα TAR μοντέλα και τα διγραμμικά μοντέλα.

Πίνακας 5.5 Μελέτες σύγκρισης των νευρωνικών δικτύων με τις παραδοσιακές στατιστικές μεθόδους

5.8 ΒΗΜΑΤΑ ΣΧΕΔΙΑΣΗΣ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

Στην ενότητα αυτή θα παρουσιάσουμε μια μεθοδολογία σχεδίασης 8 βημάτων η οποία προκύπτει από τον συνδυασμό των βημάτων που έχουν προτείνει οι Deboeck, Masters, Blum, Nelson και Illingworth. Χαρακτηριστικό της διαδικασίας αυτής είναι ότι για τον πλήρη σχεδιασμό ενός δικτύου μπορεί να χρειαστεί η επανάληψη κάποιων βημάτων, ιδιαίτερα μεταξύ επιλογής μεταβλητών και διαδικασίας εκπαίδευσης (training).

Ακολουθεί ένας πίνακας που αναφέρει συνοπτικά τα 8 βήματα της διαδικασίας σχεδίασης. Στη συνέχεια αναλύουμε κάθε βήμα ξεχωριστά για να έχει κάποιος μια πιο ολοκληρωμένη γνώση για την όλη διαδικασία.

Βήμα 1: Επιλογή μεταβλητών.

Βήμα 2: Συλλογή δεδομένων.

Βήμα 3: Προεπεξεργασία δεδομένων.

Βήμα 4: Σύνολα εκπαίδευσης (training set), δοκιμής (test set) και αξιολόγησης (Validation set)

Βήμα 5: Παραδείγματα ΝΔ ανάλογα με:

- τον αριθμό των κρυμμένων επιπέδων
- τον αριθμό των κρυμμένων νευρώνων
- τον αριθμό των νευρώνων εξόδου
- τις συναρτήσεις μεταφοράς

Βήμα 6: Κριτήρια αξιολόγησης

Βήμα 7: Τελική προσομοίωση νευρωνικών δικτύων

Βήμα 8: Υλοποίηση

Πίνακας 5.6 Βήματα σχεδίασης ενός νευρωνικού δικτύου

5.8.1 ΒΗΜΑ 1: Επιλογή μεταβλητών

Η επιτυχία στη σχεδίαση ενός νευρωνικού δικτύου εξαρτάται από τη σαφή κατανόηση του προβλήματος. Κρίσιμος παράγοντας είναι η γνώση των μεταβλητών εισόδου που είναι αναγκαίες για την πρόβλεψη. Το να βρεις τις κατάλληλες μεταβλητές δεν είναι πάντα τόσο εύκολη διαδικασία. Εξάλλου, ένα νευρωνικό δίκτυο έχει τη δυνατότητα να ανιχνεύει τις σύνθετες και μη γραμμικές σχέσεις μεταξύ πολλών διαφορετικών μεταβλητών. Έτσι το ενδιαφέρον σε αυτή τη φάση επικεντρώνεται στους διάφορους δείκτες που μπορούν να προκύψουν από τα αρχικά

δεδομένα. Αυτοί είναι και οι δείκτες που θα διαμορφώσουν τις πραγματικές εισόδους του νευρωνικού δικτύου.

Η απλούστερη μέθοδος νευρωνικού δικτύου χρησιμοποιεί τις αρχικές τιμές της εξαρτώμενης μεταβλητής ή της πρώτης διαφοράς της ως εισόδους. Τέτοια μοντέλα έχουν καταλήξει σε ακριβέστερα συμπεράσματα από τις παραδοσιακές μεθόδους Box-Jenkins σε αρκετές μελέτες. Μια δημοφιλέστερη προσέγγιση είναι να υπολογιστούν οι διάφοροι τεχνικοί δείκτες που είναι βασισμένοι μόνο στις προηγούμενες παρατηρήσεις.

Η συχνότητα των δεδομένων εξαρτάται από τους αντικειμενικούς στόχους του ερευνητή. Υπάρχουν για παράδειγμα τα ημερήσια, τα εβδομαδιαία, τα μηνιαία, τα τριμηνιαία και τα ετήσια δεδομένα. Κάποιος που θέλει να κάνει βραχυπρόθεσμες προβλέψεις θα χρησιμοποιούσε σίγουρα ημερήσια ή εβδομαδιαία δεδομένα. Αντιθέτως κάποιος ερευνητής με μεγαλύτερο ορίζοντα πρόβλεψης θα προτιμούσε τα μηνιαία, τριμηνιαία ακόμα και τα ετήσια δεδομένα για την παραγωγή των απαιτούμενων προβλέψεων ανάλογα με τον τομέα ενασχόλησης του και το μέγεθος προς πρόβλεψη.

5.8.2 ΒΗΜΑ 2: Συλλογή δεδομένων

Ο ερευνητής πρέπει να εξετάσει το κόστος και τη διαθεσιμότητα των επιλεγμένων μεταβλητών του προηγούμενου βήματος, κατά τη συλλογή των δεδομένων. Τα τεχνικά δεδομένα είναι εύκολα διαθέσιμα από πολλούς προμηθευτές σε λογικό κόστος ενώ οι βασικές πληροφορίες είναι δυσκολότερο να αποκτηθούν. Ο χρόνος που ξοδεύεται κατά τη συλλογή των στοιχείων δεν μπορεί να χρησιμοποιηθεί για την προεπεξεργασία, την εκπαίδευση και την αξιολόγηση της επίδοσης των νευρωνικών δικτύων. Ο προμηθευτής πρέπει να έχει τη φήμη της παροχής υψηλής ποιότητας στοιχείων. Εντούτοις, όλα τα στοιχεία πρέπει να ελέγχονται για τυχόν λάθη, εξετάζοντας αλλαγές, αποκλίσεις ή ακόμα απώλειες παρατηρήσεων.


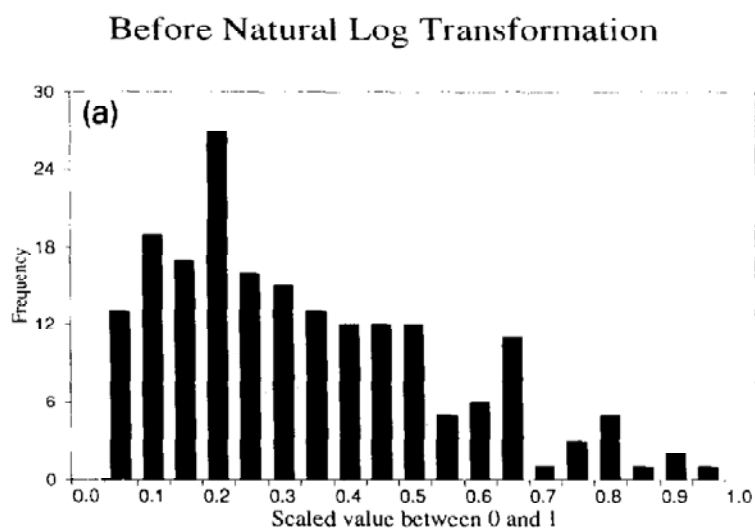
Οι παρατηρήσεις που αρκετές φορές λείπουν, μπορούν να αντιμετωπιστούν με διάφορους τρόπους. Ένας τρόπος είναι να απορριφθούν όλες ή να υποτεθεί ότι

παραμένουν το ίδιο με την παρεμβολή ή τον υπολογισμό του μέσου όρου από τις κοντινές τιμές. Ένας ακόμα συνήθης τρόπος είναι η κωδικοποίηση ενός νευρώνα εισόδου που λαμβάνει την τιμή 1 όταν πρόκειται για missing value και την τιμή 0 στην αντίθετη περίπτωση.

5.8.3 ΒΗΜΑ 3: Προεπεξεργασία δεδομένων

Η προεπεξεργασία δεδομένων αναφέρεται στην ανάλυση και το μετασχηματισμό των μεταβλητών εισόδου και εξόδου με στόχο την ελαχιστοποίηση του θορύβου, την αναγνώριση και ανάδειξη σημαντικών σχέσεων, την ανίχνευση των τάσεων και την εξομάλυνση της διανομής της μεταβλητής για να βοηθήσει στην ουσία το νευρωνικό δίκτυο στην εκμάθηση αυτών. Από τη στιγμή που τα ΝΔ μιμούνται πρότυπα, η παρουσίαση των δεδομένων αποτελεί κρίσιμο παράγοντα στην σχεδίαση ενός επιτυχημένου νευρωνικού δικτύου. Οι μεταβλητές εισόδου και εξόδου για τις οποίες συλλέχθηκαν τα δεδομένα, τροφοδοτούνται σπάνια στο δίκτυο σε ακατέργαστη μορφή. Στην χειρότερη περίπτωση πρέπει τα ακατέργαστα δεδομένα να κλιμακωθούν μεταξύ των ανώτερων και κατώτερων ορίων των συναρτήσεων μεταφοράς (συνήθως μεταξύ 0...1 ή μεταξύ -1...1).

Δύο από τους πιο κοινούς μετασχηματισμούς δεδομένων τόσο στις παραδοσιακές μεθόδους πρόβλεψης όσο και στην πρόβλεψη με νευρωνικά δίκτυα, είναι αρχικά η χρησιμοποίηση των διαφορών μεταξύ των διαφορετικών τιμών που παίρνουν μια μεταβλητή και η επιλογή του φυσικού λογαρίθμου αυτής. Αυτό έχει σαν αποτέλεσμα την αφαίρεση της γραμμικής τάσης από τα δεδομένα. Ο λογαριθμικός μετασχηματισμός είναι χρήσιμος για δεδομένα που μπορούν να πάρουν και μικρές και μεγάλες τιμές και χαρακτηρίζεται από μια εκτεταμένη δεξιά διανομή ουρών. Στα παρακάτω ιστογράμματα φαίνεται καθαρά το αποτέλεσμα του λογαριθμικού μετασχηματισμού εφαρμοσμένο σε μηνιαία δεδομένα όγκου ανταλλαγής για σιτάρι:



Σχήμα 5.4 Λογαριθμικός μετασχηματισμός σε μηνιαία δεδομένα

Επιπρόσθετα ο λογαριθμικός μετασχηματισμός μπορεί να μετατρέπει πολλαπλασιαστικές ή αναλογικές σχέσεις σε προσθετικές κάτι που γενικά απλουστεύει και βελτιώνει την επίδοση ενός νευρωνικού δικτύου.

Ένας άλλος δημοφιλής μετασχηματισμός δεδομένων είναι να χρησιμοποιηθούν οι αναλογίες των μεταβλητών εισόδου. Οι αναλογίες δίνουν έμφαση σε σημαντικές σχέσεις ενώ συγχρόνως συντηρούν τους βαθμούς ελευθερίας επειδή λιγότεροι νευρώνες εισόδου χρειάζονται για να κωδικοποιήσουν τις ανεξάρτητες μεταβλητές.

Η εξομάλυνση των δεδομένων εισόδου και εξόδου, με τη χρησιμοποίηση είτε της απλής είτε της εκθετικής εξομάλυνσης, υιοθετείται συχνά. Μερικές φορές βέβαια

είναι προτιμότερο να χρησιμοποιούνται οι κινητοί μέσοι όροι για την εξομάλυνση των ανεξάρτητων μεταβλητών και την πρόβλεψη τάσεων.

Η δειγματοληψία ή το φιλτράρισμα των δεδομένων αναφέρονται στην αφαίρεση κάποιων παρατηρήσεων από τα training και test sets για να δημιουργήσουν μια πιο ομοιόμορφη διανομή. Ο τύπος φιλτραρίσματος που χρησιμοποιείται πρέπει να είναι σύμφωνος με τους αντικειμενικούς στόχους του ερευνητή. Το δίκτυο ελαχιστοποιεί το ποσό των τετραγωνικών σφαλμάτων (ή άλλων εξισώσεων σφαλμάτων) σε όλες τις μεθόδους εκπαίδευσης. Ο ερευνητής πρέπει να είναι ξεκάθαρος, στο τι ακριβώς πρέπει να μάθει το νευρωνικό δίκτυο. Ένα άλλο πλεονέκτημα του φιλτραρίσματος είναι η μείωση των γεγονότων εκπαίδευσης, κάτι που επιτρέπει την εξέταση περισσότερων μεταβλητών εισόδου, την τυχαία επιλογή των βαρών ή/και των κρυμμένων επιπέδων από την περίπτωση εκπαίδευσης μεγάλων συνόλων δεδομένων.

Στην πράξη, η προεπεξεργασία δεδομένων περιλαμβάνει πολλές δοκιμές και σφάλματα. Μια μέθοδος επιλογής των κατάλληλων μεταβλητών εισόδου είναι η δοκιμή διαφόρων συνδυασμών. Αν και μια τέτοια διαδικασία είναι αρκετά χρονοβόρα και απαιτεί μεγάλη υπολογιστική πολυπλοκότητα, αναγνωρίζει τις περιπτώσεις ότι κάποιες μεταβλητές μπορεί να είναι ιδανικές για την πρόβλεψη μόνο όταν συνδυάζονται με άλλες μεταβλητές.

5.8.4 ΒΗΜΑ 4: Σύνολα εκπαίδευσης, δοκιμής και αξιολόγησης (training, test, validation sets)

Η κοινή πρακτική είναι να διαιρεθούν τα δεδομένα της κάθε χρονοσειράς στα τρία παραπάνω σύνολα. Το training set είναι το μεγαλύτερο σύνολο και χρησιμοποιείται από το νευρωνικό δίκτυο για να μάθει τη μορφή που έχουν τα δεδομένα. Συνήθως αποτελεί το 60-80% του συνόλου των δεδομένων. Το test set, που κυμαίνεται μεταξύ 10-30% του συνόλου των δεδομένων, χρησιμοποιείται για να αξιολογήσει τη δυνατότητα γενίκευσης ενός υποθετικά εκπαιδευμένου δικτύου. Ο ερευνητής θα επιλέξει το δίκτυο που αποδίδει καλύτερα στο test set. Ένας τελικός έλεγχος στην απόδοση του εκπαιδευμένου δικτύου γίνεται χρησιμοποιώντας το

validation set, που είναι συνήθως 10% του συνόλου. Το σύνολο επικύρωσης πρέπει να αποτελείται από τις πιο πρόσφατες παρακείμενες παρατηρήσεις.

Το test set μπορεί είτε να επιλεγεί τυχαία από το training set είτε να αποτελείται από ένα σύνολο παρατηρήσεων αμέσως μετά από το training set. Το πλεονέκτημα της τυχαίας επιλογής είναι ότι αποφεύγεται ο κίνδυνος του να χαρακτηριστεί το test set από ένα μόνο είδος των δεδομένων. Αντιθέτως το πλεονέκτημα της χρησιμοποίησης των παρατηρήσεων που ακολουθούν το training set ως test set είναι ότι αυτές είναι οι πιο πρόσφατες παρατηρήσεις που μπορεί αν είναι σημαντικότερες από τα παλαιότερα δεδομένα.

Τα τυχαία επιλεγμένα δεδομένα του test set δεν θα πρέπει να αντικαθιστούνται στο training set γιατί αυτό θα επηρέαζε την ικανότητα γενίκευσης. Επιπλέον μια ντετερμινιστική μέθοδος, όπως το να επιλέγεται κάθε n -οστή παρατήρηση για στοιχείο του test set, δεν προτείνεται για τον απλό λόγο ότι μπορεί να οδηγήσει σε κύκλους των δειγματοληπτημένων δεδομένων.

Προτείνεται ότι τα training set και test set να κλιμακοποιούνται μαζί εφόσον και ο σκοπός του test set είναι ο καθορισμός της ικανότητας γενίκευσης του δικτύου. Εντούτοις, με κανένα τρόπο, δεν πρέπει το validation set να κλιμακοποιείται μαζί είτε με το training test είτε με το test set γιατί κάτι τέτοιο θα οδηγήσει σε με ασφαλή ακεραιότητα του validation set το οποίο αποτελεί και τον τελικό και ανεξάρτητο έλεγχο στο νευρωνικό δίκτυο. Στην πραγματικότητα, ο ερευνητής δεν μπορεί με κανέναν τρόπο να γνωρίζει την ακριβή σειρά των μελλοντικών τιμών, αλλά να κάνει μόνο μια λογική εκτίμηση στη σειρά των training και test sets.

5.9.5 ΒΗΜΑ 5: Παραδείγματα νευρωνικών δικτύων

Υπάρχει ένας άπειρος αριθμός τρόπων να κατασκευαστεί ένα νευρωνικό δίκτυο. Η αρχιτεκτονική του δικτύου, οι ιδιότητες κάθε μεμονωμένου νευρώνα, η λειτουργία μεταφοράς του και το πώς οι είσοδοι συνδυάζονται καθορίζουν το είδος

του νευρωνικού δικτύου. Η αρχιτεκτονική ενός νευρωνικού δικτύου καθορίζει τη δομή του, συμπεριλαμβανομένου του αριθμού των νευρώνων σε κάθε επίπεδο και του αριθμού και του τύπου των διασυνδέσεων.

Ο αριθμός νευρώνων εισόδου είναι μια από τις ευκολότερες παραμέτρους για να επιλέγουν αφού προεπεξεργαστούν οι ανεξάρτητες μεταβλητές, επειδή κάθε ανεξάρτητη μεταβλητή αντιπροσωπεύεται και τον δικό της νευρώνα εισόδου. Παρακάτω θα εξετάσουμε την επιλογή του αριθμού των κρυφών στρώματων, των κρυφών νευρώνων κάθε στρώματος, των νευρώνων εξόδου και των συναρτήσεων μεταφοράς.

5.8.5.1 Αριθμός κρυμμένων επιπέδων

Τα κρυμμένα επίπεδα (στρώματα) παρέχουν στο δίκτυο, τη δυνατότητα να γενικευτεί. Ένα νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο και με ικανοποιητικό αριθμό κρυφών νευρώνων είναι σε θέση να προσεγγίζει οποιαδήποτε λειτουργία. Στην πράξη, τα νευρωνικά δίκτυα με ένα και περιστασιακά δύο κρυμμένα επίπεδα χρησιμοποιούνται ευρέως και έχουν αποδώσει πολύ καλά. Η αύξηση του αριθμού των κρυφών στρώματων αυξάνει επίσης το χρόνο υπολογισμού και τον κίνδυνο ‘overfitting’ που οδηγεί σε κακές προβλέψεις. Το overfitting εμφανίζεται όταν ένα μοντέλο πρόβλεψης έχει πολύ λίγους βαθμούς ελευθερίας. Με άλλα λόγια, όταν έχει σχετικά λίγες παρατηρήσεις σε σχέση με τις παραμέτρους του και επομένως είναι σε θέση να απομνημονεύσει τα μεμονωμένα σημεία παρά να μάθει τη γενική μορφή. Στην περίπτωση των νευρωνικών δικτύων, ο αριθμός των βαρών, που συνδέεται άμεσα με τον αριθμό των κρυμμένων στρώματων και νευρώνων καθώς και το μέγεθος του training set, καθορίζουν την πιθανότητα του overfitting. Όσο μεγαλύτερος ο αριθμός των βαρών σε σχέση με το μέγεθος του training set, τόσο μεγαλύτερη είναι η δυνατότητα του δικτύου να συγκρατήσει την ιδιοσυγκρασία των μεμονωμένων παρατηρήσεων. Αυτό έχει ως συνέπεια, η γενίκευση για το validation set να χάνεται και το μοντέλο να μη χρησιμοποιείται σε μια πραγματική πρόβλεψη.

Επομένως, συνιστάται όλα τα νευρωνικά δίκτυα να αρχίζουν με ένα ή το πολύ δύο κρυμμένα επίπεδα. Εάν ένα νευρωνικό δίκτυο τεσσάρων στρώματων (με δύο κρυφά στρώματα) αποδειχτεί ανεπαρκές αφού έχει εξετάσει πολλαπλούς κρυμμένους

νευρώνες χρησιμοποιώντας έναν λογικό αριθμό τυχαία επιλεγμένων αρχικών βαρών, στη συνέχεια ο ερευνητής πρέπει να τροποποιήσει μερικές φορές τις μεταβλητές εισόδου πριν προσθέσει ένα τρίτο κρυφό επίπεδο. Σύμφωνα με τη θεωρία και όλη την εμπειρική εργασία έως σήμερα, τα δίκτυα με περισσότερα από τέσσερα στρώματα δε βελτιώνουν τα αποτελέσματα.

5.8.5.2 Αριθμός κρυμμένων νευρώνων

Παρά τη σημασία του, δεν υπάρχει κανένας μαγικός τρόπος για την επιλογή του βέλτιστου αριθμού κρυφών νευρώνων. Επομένως, οι ερευνητές ξαναγυρίζουν στον πειραματισμό. Εντούτοις, μερικές εμπειρικές μέθοδοι έχουν εφαρμοστεί. Μια καλή προσέγγιση προκύπτει με εφαρμογή του κανόνα της γεωμετρικής πυραμίδας που προτάθηκε από τον Masters. Σύμφωνα με αυτή, για ένα δίκτυο τριών στρωμάτων με n νευρώνες εισόδου και m νευρώνες εξόδου, το κρυμμένο επίπεδο θα έχει \sqrt{nxm} νευρώνες. Ο πραγματικός αριθμός κρυφών νευρώνων μπορεί ακόμα να κυμανθεί από το $1/2$ ως 2 φορές την τιμή που προκύπτει από τον κανόνα αυτό ανάλογα με τη πολυπλοκότητα του προβλήματος. Οι Baily και Thompson προτείνουν ότι ο αριθμός κρυφών νευρώνων σε ένα νευρικό δίκτυο τριών στρωμάτων πρέπει να είναι το 75% του αριθμού των νευρώνων εισόδου. Ο Katz ισχυρίζεται ότι ένας βέλτιστος αριθμός κρυφών νευρώνων θα βρεθεί μεταξύ του $1/2$ ως 3 φορές του αριθμού των νευρώνων εισόδου. Ο Ersoy προτείνει τον διπλασιασμό του αριθμού των κρυμμένων νευρώνων έως ότου χειροτερεύσει η απόδοση του δικτύου. Ο Klimasauskas προτείνει ότι πρέπει να υπάρξουν τουλάχιστον πέντε φορές περισσότεροι training παράμετροι όπως βάρη, τα οποία θέτουν ένα ανώτερο όριο στον αριθμό κρυφών νευρώνων εισόδου.

Είναι σημαντικό να σημειωθεί ότι οι κανόνες που υπολογίζουν τον αριθμό κρυφών νευρώνων ως πολλαπλάσιο του αριθμού νευρώνων εισόδου, υποθέτουν ότι το training set είναι τουλάχιστον δύο φορές μεγαλύτερο από τον αριθμό των βαρών και κατά προτίμηση τέσσερις ή περισσότερες καθώς αυξάνεται. Εάν αυτό δεν ισχύει, τότε οι εμπειρικές αυτές μέθοδοι μπορούν γρήγορα να οδηγήσουν σε overfitted μοντέλα δεδομένου ότι ο αριθμός κρυφών νευρώνων εξαρτάται άμεσα από τον αριθμό νευρώνων εισόδου (που καθορίζουν στη συνέχεια τον αριθμό των βαρών). Η λύση

είναι είτε να αυξηθεί το μέγεθος του training set είτε ,αν αυτό δεν είναι εφικτό, να τεθεί ένα ανώτερο όριο στον αριθμό των νευρώνων εισόδου έτσι ώστε ο αριθμός βαρών είναι τουλάχιστον ο μισός από τον αριθμό των γεγονότων του training set. Η επιλογή των μεταβλητών εισόδου γίνεται περισσότερο κρίσιμη σε μικρά δίκτυα από τη στιγμή που δεν υπάρχει η πολυτέλεια της παρουσίασης στο δίκτυο ενός μεγάλου αριθμού εισόδων έτσι ώστε να μπορεί τότε αυτό με τη σειρά του να αγνοεί τις μη χρήσιμες εισόδους.

Η επιλογή του σωστού αριθμού κρυφών νευρώνων περιλαμβάνει αρκετό πειραματισμό. Τρεις μέθοδοι που χρησιμοποιούνται συχνά είναι οι: α) fixed, β) constructive, γ) destructive. Στη πρώτη προσέγγιση, μια ομάδα ΝΔ με διαφορετικούς αριθμούς κρυφών νευρώνων εκπαιδεύεται και καθεμία αξιολογείται στο test set, χρησιμοποιώντας έναν λογικό αριθμό τυχαία επιλεγμένων αρχικών βαρών. Η αύξηση στον αριθμό κρυφών νευρώνων μπορεί να είναι ένας, δύο ή περισσότεροι, ανάλογα με τους διαθέσιμους υπολογιστικούς πόρους. Το δίκτυο με το μικρότερο σφάλμα επιλέγεται επειδή είναι σε θέση να γενικεύσει καλύτερα. Αυτή η προσέγγιση είναι χρονοβόρα, αλλά γενικά λειτουργεί πολύ καλά.

Οι constructive και destructive προσεγγίσεις περιλαμβάνουν την αλλαγή του αριθμού των κρυφών νευρώνων κατά τη διάρκεια της εκπαίδευσης παρά την δημιουργία χωριστών δικτύων, καθένα με διαφορετικό αριθμό κρυφών νευρώνων, όπως στην πρώτη προσέγγιση. Πολλά εμπορικά νευρωνικά πακέτα λογισμικού δικτύων δεν υποστηρίζουν αυτές τις μεθόδους. Η constructive προσέγγιση περιλαμβάνει την προσθήκη κρυφών νευρώνων έως ότου αρχίσει η χειροτέρευση του δικτύου. Η destructive προσέγγιση είναι παρόμοια, εκτός από το ότι οι κρυφοί νευρώνες αφαιρούνται κατά τη διάρκεια του training.

Γενικά ο κανόνας είναι να επιλέγεται πάντα το δίκτυο που αποδίδει καλύτερα στο testing set με το λιγότερο αριθμό κρυμμένων νευρώνων. Κατά τις δοκιμές του αριθμού των νευρώνων είναι σημαντικό να κρατηθούν όλες οι άλλες παράμετροι σταθερές. Η αλλαγή οποιασδήποτε παραμέτρου δημιουργεί ουσιαστικά ένα νέο νευρωνικό δίκτυο με διαφορετικό εύρος σφάλματος το οποίο με τη σειρά του επηρεάζει την επιλογή του βέλτιστου αριθμού των κρυφών νευρώνων.

5.8.5.3 Αριθμός νευρώνων εξόδου

Η απόφαση σχετικά με τον αριθμό νευρώνων εξόδου είναι κάπως απλούστερη δεδομένου ότι υπάρχουν συγκεκριμένοι λόγοι να χρησιμοποιείται πάντα ένας μόνο νευρώνας εξόδου. Τα νευρωνικά δίκτυα με πολλές εξόδους, ειδικά εάν αυτές οι εξοδοί χωρίζονται ευρέως, θα παράγουν χειρότερα αποτελέσματα σε σύγκριση με ένα δίκτυο με μια μοναδική έξοδο. Ένα νευρωνικό δίκτυο εκπαιδεύεται με την επιλογή των βαρών έτσι ώστε ο μέσο όρος σφαλμάτων σε όλους τους νευρώνες εξόδου να ελαχιστοποιείται.

5.8.5.4 Συναρτήσεις μεταφοράς

Οι συναρτήσεις μεταφοράς είναι μαθηματικοί τύποι που καθορίζουν την έξοδο ενός νευρώνα επεξεργασίας. Αναφέρονται επίσης ως εξισώσεις μετασχηματισμού, συμπίεσης και ενεργοποίησης. Η πλειοψηφία των περισσότερων μοντέλων νευρωνικών δικτύων χρησιμοποιούν τη Sigmoid (s-shaped) συνάρτηση, αλλά και άλλες όπως την υπερβολική εφαπτομένη, τη βηματική και τη γραμμική. Ο σκοπός της συνάρτησης μεταφοράς είναι να μη φτάσουν οι εξοδοί σε πολύ μεγάλες τιμές, κάτι που μπορεί να παραλύσει τα νευρωνικά δίκτυα και με αυτόν τον τρόπο να εμποδίσει τη διαδικασία εκπαίδευσης.

Οι γραμμικές συναρτήσεις μεταφοράς δεν είναι χρήσιμες στην περίπτωση της μη γραμμικότητας. Οι συναρτήσεις μεταφοράς όπως οι Sigmoid χρησιμοποιούνται συνήθως για χρονοσειρές επειδή είναι μη γραμμικές και συνεχώς διαφοροποιήσιμες, ιδιότητες που είναι επιθυμητές για την εκμάθηση των δικτύων.

Ο Klimasauskas σε σχετική μελέτη τόνισε ότι σε περιπτώσεις όπου ένα δίκτυο πρόκειται να μάθει από την μέση συμπεριφορά, τότε θα πρέπει να χρησιμοποιηθεί μια Sigmoid συνάρτηση μεταφοράς. Σε περιπτώσεις όπου η εκμάθηση του δικτύου περιλαμβάνει αποκλίσεις από τη μέση τιμή, τότε θα πρέπει να χρησιμοποιηθεί η συνάρτηση υπερβολικής εφαπτομένης. Η κλιμακωτή και η βηματική συνάρτηση προτείνονται για δυαδικές μεταβλητές εφόσον η σιγμοειδής συνάρτηση μεταφοράς

πλησιάζει ασυμπτωτικά τα μηδέν και ένα. Σε ένα κλασσικό νευρωνικό δίκτυο που χρησιμοποιεί τον αλγόριθμο back-propagation (BP network), οι νευρώνες εισόδου χρησιμοποιούν συνήθως γραμμικές συναρτήσεις μεταφοράς ενώ όλοι οι άλλοι νευρώνες του δικτύου χρησιμοποιούν σιγμοειδή συνάρτηση.

Τα πραγματικά δεδομένα συνήθως κλιμακώνονται μεταξύ 0 και +1 ή μεταξύ -1 και +1, έτσι είναι και σύμφωνα με την συνάρτηση μεταφοράς που χρησιμοποιείται. Η γραμμική κλιμάκωση και η κλιμάκωση με βάση την μέση σταθερή τυπική απόκλιση είναι οι δύο πιο κοινές μέθοδοι που χρησιμοποιούνται στα νευρωνικά δίκτυα. Στη γραμμική κλιμάκωση όλες οι παρατηρήσεις κλιμακώνονται γραμμικά μεταξύ της ελάχιστης και της μέγιστης τιμής σύμφωνα με την ακόλουθη σχέση:

$$SV = TF_{min} + (TF_{max} - TF_{min}) \times \frac{(D - D_{min})}{(D_{max} - D_{min})}$$

όπου SV είναι η κλιμακωμένη τιμή, TF_{min} και TF_{max} είναι αντίστοιχα η ελάχιστη και η μέγιστη τιμή της συνάρτησης μεταφοράς, D είναι η παρατήρηση και D_{min} , D_{max} είναι αντίστοιχα η ελάχιστη και η μέγιστη τιμή όλων των παρατηρήσεων.

Η απλή γραμμική κλιμάκωση είναι δεκτική στις απότομες αλλαγές με παροδικό χαρακτήρα διότι δεν αλλάζει την ομοιομορφία της διανομής παρά μόνο κλιμακώνει μερικά τις αλλαγές αυτές μέσα στα κατάλληλα όρια της συνάρτησης μεταφοράς.

Τα περισσότερα πακέτα λογισμικού νευρωνικών δικτύων κλιμακώνουν αυτόματα όλες τις μεταβλητές μέσα στο κατάλληλο διάστημα.

5.8.6 ΒΗΜΑ 6: Κριτήρια αξιολόγησης

Η πιο συνήθης συνάρτηση σφάλματος που ελαχιστοποιείται στα νευρωνικά δίκτυα είναι το άθροισμα των τετραγωνικών σφαλμάτων. Άλλες λειτουργίες σφάλματος που προσφέρονται από τους προμηθευτές λογισμικού περιλαμβάνουν τις ελάχιστες απόλυτες αποκλίσεις, τις ασυμμετρικές ελαχίστων τετραγώνων και τις διαφορές ποσοστών. Αυτές οι λειτουργίες σφάλματος μπορούν να μην είναι τα τελικά κριτήρια αξιολόγησης, δεδομένου ότι άλλες μέθοδοι αξιολόγησης της πρόβλεψης, όπως το MAPE, δεν ελαχιστοποιείται στα νευρωνικά δίκτυα.

5.8.7 ΒΗΜΑ 7: Τελική προσομοίωση νευρωνικών δικτύων

Η εκπαίδευση ενός νευρωνικού δικτύου για να μάθει το πρότυπο που πρέπει να ακολουθήσει περιλαμβάνει την επαναληπτική παρουσίασή του με παραδείγματα ήδη γνωστών απαντήσεων. Ο στόχος της εκπαίδευσης είναι να βρεθεί το σύνολο των βαρών μεταξύ των νευρώνων που καθορίζουν το συνολικό ελάχιστο της συνάρτησης σφάλματος. Από τη στιγμή που το μοντέλο δεν είναι overfitted, αυτό το σύνολο των βαρών πρέπει να παρέχει καλή γενίκευση. Το BP νευρωνικό δίκτυο χρησιμοποιεί έναν αλγόριθμο κλιμακωτής καθόδου ο οποίος ρυθμίζει τα βάρη έτσι ώστε να ακολουθούν την πιο απότομη κλίση της επιφάνειας της συνάρτησης σφάλματος. Βέβαια η εύρεση του ολικού ελαχίστου δεν είναι πάντα σίγουρη μιας και η επιφάνεια της συνάρτησης σφάλματος περιέχει πολλά τοπικά ελάχιστα στα οποία μπορεί ο αλγόριθμος να ‘κολλήσει’. Σε αυτή την ενότητα θα συζητήσουμε το πότε πρέπει να σταματάει η εκπαίδευση ενός ΝΔ καθώς και την επιλογή του ρυθμού εκμάθησης και τιμών της ταχύτητας.

5.8.7.1 Αριθμός επαναλήψεων

Υπάρχουν 2 απόψεις σχετικά με το σημείο στο οποίο πρέπει η εκπαίδευση (training) να σταματήσει. Η πρώτη τονίζει τον κίνδυνο παγίδευσης σε ένα τοπικό ελάχιστο και τη δυσκολία του να φτάσουμε σε ένα ολικό ελάχιστο. Ο ερευνητής πρέπει μόνο να σταματήσει όταν δεν υπάρχει πια καμία βελτίωση στη συνάρτηση σφάλματος, βασισμένη σε ένα λογικό αριθμό τυχαία επιλεγμένων αρχικών βαρών. Το σημείο στο οποίο το δίκτυο δεν βελτιώνεται καλείται σύγκλιση. Η δεύτερη άποψη υποστηρίζει μια σειρά από διακοπές train-test. Η εκπαίδευση του δικτύου σταματά μετά από έναν προκαθορισμένο αριθμό επαναλήψεων, εκτιμάται η δυνατότητα του δικτύου να γενικεύσει στο test set και η εκπαίδευση συνεχίζεται. Η γενίκευση είναι η ιδέα ότι ένα μοντέλο βασισμένο σε ένα δείγμα δεδομένων είναι κατάλληλο για την πρόβλεψη του

συνόλου. Το δίκτυο για το οποίο το σφάλμα του test set είναι πολύ χαμηλό, επιλέγεται δεδομένου ότι γενικεύει καλύτερα.

Η επίκριση της διαδικασίας train-test είναι ότι επιπρόσθετες διακοπές θα μπορούσαν να προκαλέσουν μια περαιτέρω πτώση του σφάλματος προτού αυξηθεί ξανά ή ακόμα και να μειωθεί το σφάλμα ασυμπτωτικά. Αυτό φαίνεται καλύτερα στο σχήμα που ακολουθεί όπου παριστάνονται πιθανά σφάλματα των συνόλων εκπαίδευσης και δοκιμής:

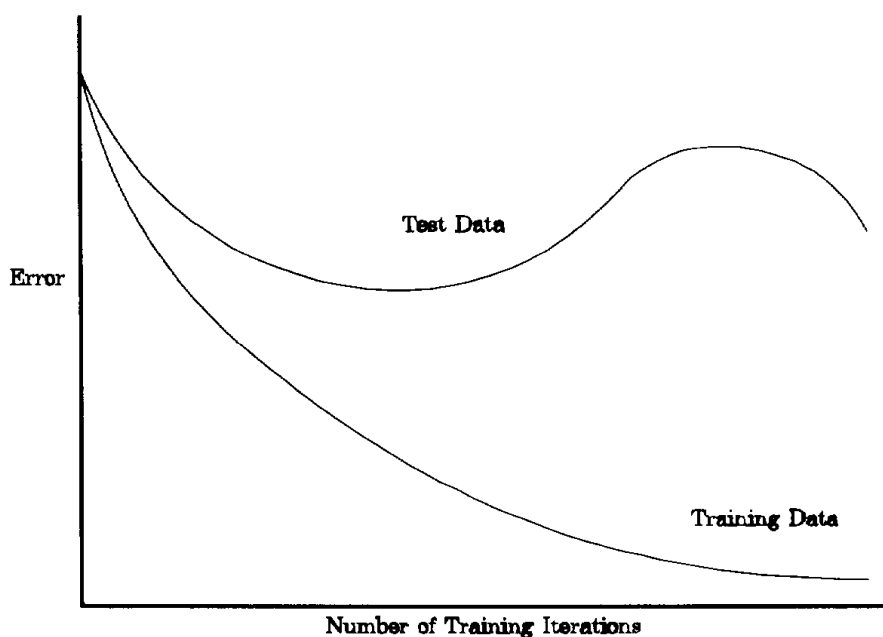


Fig. 5. Possible neural network training and testing set errors.

Σχήμα 5.5 Πιθανά σφάλματα training set και test set

Και οι δυο απόψεις συμφωνούν ότι η γενίκευση είναι ο απότερος στόχος και χρησιμοποιούν testing sets για να αξιολογήσουν έναν μεγάλο αριθμό δικτύων. Το σημείο στο οποίο αυτές οι δύο προσεγγίσεις αρχίζουν να διαχωρίζονται εστιάζεται στην ιδέα του overtraining σε σύγκριση με το overfitting. Η προσέγγιση σύγκλισης δηλώνει ότι δεν υπάρχει κανένα σημείο overtraining παρά μόνο overfitting, το οποίο είναι απλά ένα χαρακτηριστικό ενός δικτύου που έχει πάρα πολλά βάρη. Η λύση είναι να μειωθεί ο αριθμός κρυμμένων νευρώνων (ή των κρυμμένων επιπέδων αν υπάρχουν περισσότερα του ενός) ή/και να αυξηθεί το μέγεθος του training set. Η προσέγγιση του train-test επιχειρεί να διαφυλάξει το δίκτυο από το overfitting σταματώντας την

διαδικασία της εκπαίδευσης (training) βασιζόμενη στην ικανότητα του δικτύου να γενικεύεται.

Το πλεονέκτημα της προσέγγισης σύγκλισης είναι ότι κάποιος μπορεί αν είναι αισιόδοξος ότι το ολικό ελάχιστο έχει επιτευχθεί. Το ίδιο πράγμα για την προσέγγιση train-test είναι δυσκολότερο να υποτεθεί γιατί τα αρχικά βάρη επιλέγονται τυχαία και η μέση συσχέτιση μπορεί να έχει μεγάλη διακύμανση κατά τη διάρκεια της εκπαίδευσης. Ένα άλλο πλεονέκτημα είναι ότι ο ερευνητής έχει δύο λιγότερες παραμέτρους για να ασχολείται, συγκεκριμένα με το σημείο στο οποίο θα σταματήσει η εκπαίδευση και με τη μέθοδο εκτίμησης για το ποιο από τα train-test δίκτυα είναι το ιδανικό. Ένα πλεονέκτημα της προσέγγισης train-test είναι ότι δίκτυα με λιγότερους βαθμούς ελευθερίας μπορούν να εφαρμοστούν με καλύτερη γενίκευση από την προσέγγιση σύγκλισης η οποία θα κατέληγε σε overfitting. Επιπλέον, η προσέγγιση train-test απαιτεί λιγότερο χρόνο εκπαίδευσης (training time).

Ο στόχος της σύγκλισης στην διαδικασία εκπαίδευσης είναι να επιτευχθεί ένα συνολικό ελάχιστο. Αυτό απαιτεί εκπαίδευση για έναν ικανοποιητικό αριθμό επαναλήψεων χρησιμοποιώντας έναν λογικό αριθμό τυχαία επιλεγμένων αρχικών βαρών. Ακόμα και τότε, δεν υπάρχει καμία εγγύηση με ένα BP νευρωνικό δίκτυο ότι θα βρεθεί ένα ολικό ελάχιστο αφού πάντα υπάρχει η πιθανότητα να παγιδευτεί σε ένα τοπικό ελάχιστο.

Μια μέθοδος για να καθορίσει ένα λογικό αριθμό για το μέγιστο αριθμό επαναλήψεων του δικτύου είναι να σχεδιαστεί η μέση συσχέτιση, το άθροισμα των τετραγωνικών σφαλμάτων, ή κάποιο άλλο κατάλληλο μέτρο σφάλματος για κάθε επανάληψη ή σε προκαθορισμένα διαστήματα μέχρι το σημείο όπου η βελτίωση είναι αμελητέα (συνήθως μέχρι ένα μέγιστο 10.000 επαναλήψεων). Κάθε επανάληψη μπορεί να σχεδιαστεί εύκολα εάν το λογισμικό νευρωνικού δικτύου δημιουργεί ένα αρχείο στατιστικών ή εάν αυτό δεν ισχύει, η μέση συσχέτιση μπορεί να καταγραφεί σε διαστήματα των 100 ή 200 από την οθόνη του υπολογιστή. Αφού σχεδιάσει τη μέση συσχέτιση για διάφορα τυχαία επιλεγμένα αρχικά βάρη, ο ερευνητής μπορεί να επιλέξει το μέγιστο αριθμό επαναλήψεων, βασιζόμενων στο σημείο όπου η μέση συσχέτιση σταματά να αυξάνεται γρήγορα και ισιώνει.

Πολλές μελέτες που αναφέρουν τον αριθμό επαναλήψεων του training, αναφέρουν τη σύγκλιση από 85 έως 5.000 επαναλήψεις. Εντούτοις, το εύρος είναι πολύ μεγάλο (έως 50.000 και 191.400 επαναλήψεις) και χρόνοι εκπαίδευσης έως και 60 ώρες έχουν επίσης αναφερθεί. Έχει προταθεί ότι οι ερευνητές είναι καλό να καθορίζουν από την αρχή τον αριθμό των επαναλήψεων που απαιτούνται για αν επιτευχθεί μια αμελητέα βελτίωση για κάθε συγκεκριμένο πρόβλημα και να δοκιμάζουν μεγάλο αριθμό (όσο επιτρέπει η υπολογιστική πολυπλοκότητα φυσικά) τυχαία επιλεγμένων αρχικών βαρών.

5.8.7.2 Ρυθμός εκμάθησης και ταχύτητα

Ένα BP δίκτυο εκπαιδεύεται χρησιμοποιώντας ένα αλγόριθμο καθοδικής κλίσης ο οποίος ακολουθεί το περίγραμμα της επιφάνειας σφάλματος πάντα κατευθυνόμενος προς την πιο απότομη κλίση. Ο αντικειμενικός στόχος της διαδικασίας εκπαίδευσης είναι η ελαχιστοποίηση του συνολικού τετραγωνικού σφάλματος που ορίζεται ως εξής:

$$E = \frac{1}{2} \sum_h^M E_h = \frac{1}{2} \sum_h^M \sum_i^N (t_{hi} - O_{hi})^2$$

όπου E είναι το συνολικό σφάλμα όλων των προτύπων, το E_h αντιπροσωπεύει το σφάλμα του προτύπου h, ο δείκτης h εκτείνεται στο σύνολο των προτύπων εισόδου και το i αναφέρεται στον i-οστό νευρώνα εξόδου. Η μεταβλητή t_{hi} είναι η επιθυμητή έξοδος για τον i-οστό νευρώνα εξόδου όταν εφαρμόζεται το πρότυπο h και O_{hi} είναι η πραγματική έξοδος του i-οστού νευρώνα εξόδου όταν εφαρμόζεται το πρότυπο h. Ο κανόνας εκμάθησης για την ρύθμιση των βαρών μεταξύ των νευρώνων i και j ορίζεται ως εξής:

$$\begin{aligned} \delta_{hi} &= (t_{hi} - O_{hi}) O_{hi} (1 - O_{hi}) \\ \delta_{hi} &= O_{hi} (1 - O_{hi}) \sum_k^N \delta_{hk} w_{jk} \\ \Delta w_{ij}(n+1) &= \varepsilon (\delta_{hi} O_{hj}) \end{aligned}$$

όπου n είναι ο αριθμός της παρουσίασης, δ_{hi} είναι το σήμα σφάλματος του νευρώνα i για το πρότυπο h και ε είναι ο ρυθμός εκμάθησης. Ο ρυθμός εκμάθησης είναι μια σταθερά αναλογικότητας η οποία καθορίζει το μέγεθος των αλλαγών των

βαρών. Η αλλαγή του βάρους ενός νευρώνα είναι αναλογική με την επίδραση του βάρους αυτού του νευρώνα στο σφάλμα.

Τα περισσότερα λογισμικά προγράμματα νευρωνικών δικτύων έχουν προκαθορισμένες τιμές για τον ρυθμό εκμάθησης και την ταχύτητα τα οποία σε γενικές γραμμές δουλεύουν κανονικά. Επιπλέον, πολλά προγράμματα νευρωνικών δικτύων μειώνουν αυτόματα τον ρυθμό εκμάθησης ενώ αυξάνουν τις τιμές της ταχύτητας καθώς επιτυγχάνεται η σύγκλιση.

5.8.8 ΒΗΜΑ 8: Υλοποίηση

Η υλοποίηση παρατίθεται ως το τελευταίο βήμα, αλλά στην πραγματικότητα απαιτεί μια προσεκτική εκτίμηση πριν από τη συλλογή των δεδομένων. Η διαθεσιμότητα των δεδομένων, τα κριτήρια αξιολόγησης, και οι χρόνοι εκπαίδευσης διαμορφώνονται ανάλογα με το περιβάλλον στο οποίο το νευρωνικό δίκτυο θα εφαρμοστεί. Οι περισσότεροι προμηθευτές λογισμικού νευρωνικών δικτύων παρέχουν τα μέσα με τα οποία τα εκπαιδευμένα δίκτυα μπορούν να εφαρμοστούν είτε στο ίδιο το πρόγραμμα νευρωνικού δικτύου είτε ως εκτελέσιμο αρχείο. Αν όχι, ένα εκπαιδευμένο δίκτυο μπορεί να δημιουργηθεί εύκολα σε λογιστικό φύλλο (spreadsheet) με τη γνώση της αρχιτεκτονικής, των συναρτήσεων μεταφοράς, και των βαρών του.


Ένα πλεονέκτημα των νευρωνικών δικτύων είναι η δυνατότητά τους να προσαρμόζονται στις μεταβαλλόμενες συνθήκες μέσω της περιοδικής επανεκπαίδευσης τους. Μόλις επεκταθεί, η απόδοση του νευρωνικού δικτύου θα χειροτερεύσει καθώς περνάει ο χρόνος, εκτός αν πραγματοποιείται επανεκπαίδευση (retraining). Εντούτοις, ακόμη και με την περιοδική επανεκπαίδευση, δεν υπάρχει καμία εγγύηση ότι η απόδοση του δικτύου μπορεί να διατηρηθεί καθώς οι ανεξάρτητες επιλεγμένες μεταβλητές μπορεί να είχαν γίνει λιγότερο σημαντικές.

Έχει προταθεί ότι η συχνότητα της επανεκπαίδευσης για το δίκτυο πρέπει να είναι η ίδια με αυτή που είχε χρησιμοποιηθεί κατά τη διαδικασία της δοκιμής στο τελικό

μοντέλο. Παρόλα αυτά, όταν εξετάζεται ένας μεγάλος αριθμός μοντέλων για να επιλεγεί το τελικό μοντέλο, απαιτείται λιγότερη επανεκπαίδευση για να κρατηθούν οι χρόνοι εκπαίδευσης (training times) σε λογικά πλαίσια. Ένα καλό δίκτυο πρέπει να είναι δυνατό όσο αφορά την συχνότητα επανεκπαίδευσης και συνήθως βελτιώνεται καθώς η επανεκπαίδευση συμβαίνει συχνότερα.

6|| THETA AI

Με αφορμή τον διαγωνισμό NN3 έγινε προσπάθεια από την Μοναδά Προβλέψεων και Προοπτικής να στείλει μια μέθοδο benchmark στον διαγωνισμό NN3. Αρχικά δοκιμάστηκαν αρχιτεκτονικές που βασίζονταν 100% σε Νευρωνικά δίκτυα. Μια τέτοια διάταξη παρουσιάζεται στο ακόλουθο σχήμα.



Σχήμα 6.1 Αρχιτεκτονική ΝΔ κατάλληλο για πρόβλεψη χρονοσειρών

Για τον σκοπό αυτό χρησιμοποιήθηκε το εργαλείο Alyuda Forecaster XL. Τα αποτελέσματα των προβλέψεων παρουσιάζονται στον παρακάτω πίνακα:

	SMAPE	MAPE
111 χρονοσειρές	27,88%	31,39%
11 χρονοσειρές	17,57%	18,19%

Πίνακας 6.1 Αποτελέσματα με τη χρήση του Forecaster XL

Τα αποτελέσματα δεν ήταν ικανοποιητικά και αναπτύχθηκε η μέθοδος THETA AI που στόχο έχει τον συνδυασμό της μεθόδου Θ με την Τεχνητή Νοημοσύνη και ειδικότερα με τα νευρωνικά δίκτυα. Με βάση την κλασική αντιμετώπιση της μεθόδου Θ οι προβλέψεις των γραμμών LRL και $L(\theta=2)$ συνδυάζονται ισοβαρώς. Στην

διαδικασία Theta AI τα βάρη της συμμετοχής των προβλέψεων των γραμμών LRL και $L(\theta=2)$ στην τελική πρόβλεψη θα παράγονται με την χρήση ενός νευρωνικού δικτύου.

6.1 Περιγραφή της διαδικασίας THETA AI

Η διαδικασία THETA AI τροποποιεί την μέθοδο Θ και αποτελείται από τα ακόλουθα βήματα:

Βήμα 1. Αποεποχικοποίηση

Βήμα 2. Δημιουργία Δεδομένων εκπαίδευσης Νευρωνικού Δικτύου

Είσοδοι:

SES(k+1) ή Naive(k+1) για $L(\theta=2)$ περιορισμένη σε k σημεία

LRL(k+1) για την χρονοσειρά περιορισμένη σε k σημεία

Στόχος:

Data(k+1)

Βήμα 3. Δημιουργία Συνόλων εκπαίδευσης, δοκιμής και αξιολόγησης.

Βήμα 4. Εκπαίδευση Νευρωνικού Δικτύου.

Βήμα 5. Παραγωγή Προβλέψεων για τις πλήρεις γραμμές LRL και $L(\theta=2)$.

Βήμα 6. Παραγωγή προβλέψεων από το Νευρωνικό Δίκτυο (είσοδος Βήμα 5).

Βήμα 7. Εποχικοποίηση προβλέψεων.

Αναλυτικότερα:

1. Κατά την αποεποχικοποίηση ελέγχεται αν η χρονοσειρά έχει εποχιακή συνιστώσα. Αν έχει αποεποχικοποιείται. Στα πειράματα μας έγινε χρήση κλασικής αποσύνθεσης (πολλαπλασιαστικό μοντέλο).

2. Στο βήμα αυτό στόχος είναι να δημιουργηθούν τα δεδομένα με τα οποία θα εκπαιδευτεί το Νευρωνικό Δίκτυο που θα καθορίσει τα βάρη με τα οποία θα συνεισφέρουν οι γραμμές $L(\theta=2)$ και LRL στην τελική πρόβλεψη. Για να το πετύχουμε αυτό περιορίζουμε την χρονοσειρά στα k πρώτα της σημεία και εφαρμόζουμε την αποσύνθεση Θ . Οι προβλέψεις των LRL και $L(\theta=2)$ καθώς και το σημείο $k+1$ των δεδομένων αποτελούν αντίστοιχα τα δεδομένα εκπαίδευσης του Νευρωνικού Δικτύου και τα δεδομένο-στόχο.

3. Αφού ολοκληρωθεί η διαδικασία του βήματος 2 για όλα τα δεδομένα καθορίζουμε τα σύνολα εκπαίδευσης, δοκιμής και αξιολόγησης. Τηρούμε χρονολογική σειρά δηλαδή λιγότερο πρόσφατα δεδομένα επιλέγονται στο σύνολο εκπαίδευσης, στο σύνολο δοκιμής επιλέγονται τα πιο πρόσφατα δεδομένα ενώ τα πλέον πρόσφατα αποτελούν το σύνολο έλεγχου. Συνήθως χρησιμοποιείται η αναλογία 70%-15%-15% επί του πλήρους συνόλου για τον καθορισμό των συνόλων εκπαίδευσης, δοκιμής και ελέγχου αντίστοιχα.

4. Με βάση τα παραπάνω δεδομένα το Νευρωνικό Δίκτυο εκπαιδεύεται.

5. Παράγονται οι προβλέψεις των LRL και $L(\theta=2)$ όπως στην μέθοδο Θ .

6. Οι προβλέψεις του βήματος 5 εισάγονται ως είσοδοι στο νευρωνικό δίκτυο και παράγονται οι τελικές προβλέψεις για τα αποεποχικοποιημένα δεδομένα.

7. Οι προβλέψεις του βήματος 6 εποχικοποιούνται με βάση τους εποχιακούς δείκτες της χρονοσειράς που είχαν υπολογιστεί το βήμα 1.

6.2. Εφαρμογή της μεθόδου στον Διαγωνισμό NN3

Οι προβλέψεις για το περιορισμένο σετ χρονοσειρών παράχθηκαν με την χρήση του προγράμματος Alyuda Forecaster και το πρόγραμμα παραγωγής προβλέψεων Πυθία της Μονάδας Προβλέψεων και Προοπτικής. Για το πλήρες σύνολο χρονοσειρών χρησιμοποιήθηκε πάλι το πρόγραμμα παραγωγής προβλέψεων Πυθία και η βιβλιοθήκη προγραμματισμού NeuroFusion. Κατά την παραγωγή προβλέψεων, για να μην είναι τόσο χρονοβόρος η διαδικασία, τροποποιήθηκε το Βήμα 2 της μεθόδου ώστε να χρησιμοποιεί την μέθοδο Naive για την παραγωγή προβλέψεων στην γραμμή $L(\theta=2)$ ενώ ως LRL σε κάθε βήμα η LRL της χρονοσειράς και όχι η LRL της περιορισμένης στο σημείο k χρονοσειράς.

6.3 Αποτελέσματα της Theta AI στον διαγωνισμό NN3

Ακολουθούν αναλυτικά τα αποτελέσματα που δόθηκαν από τους διοργανωτές, για τις μεθόδους Theta και ThetaAI. Στον πρώτο πίνακα αναλύονται αποτελέσματα για το πλήρες σύνολο χρονοσειρών του διαγωνισμού (111) και για στον δεύτερο τα αποτελέσματα στο περιορισμένο σύνολο (11).

	ALL		Short Seasonal		Short Non Saesonal		Long Seasonal		Long Non Seasonal	
	Theta	ThetaAI	Theta	ThetaAI	Theta	ThetaAI	Theta	ThetaAI	Theta	ThetaAI
SMAPE	14,89%	15,66%	14,25%	14,27%	18,89%	22,59%	9,68%	9,53%	17,24%	17,39%
SMdAPE	8,55%	8,60%	9,08%	9,13%	13,27%	14,52%	5,47%	5,31%	8,13%	8,28%

Πίνακας 6.2 Αποτελέσματα για το πλήρες σύνολο των 111 χρονοσειρών του διαγωνισμού

	ALL		SEASONAL		EASY		HARD	
	Theta	Theta AI	Theta	Theta AI	Theta	Theta AI	Theta	Theta AI
MAPE	14,30%	13,57%	14,48%	12,74%	10,40%	10,57%	17,90%	17,95%
MdAPE	8,61%	8,10%	8,17%	6,85%	5,35%	5,34%	11,98%	11,62%
SMAPE	13,70%	13,07%	13,40%	11,90%	10,77%	11,04%	17,14%	17,06%
SMdAPE	8,33%	8,03%	7,85%	6,73%	5,40%	5,33%	11,94%	12,17%

Πίνακας 6.3 Αποτελέσματα για το υποσύνολο των 11 χρονοσειρών

6.4 Βελτίωση της μεθόδου Theta AI

Παρατηρώντας τα αποτελέσματα της Theta AI (ειδικά στο σετ των 11) και λαμβάνοντας υπ' όψιν πως οι παραδοχές της παραγράφου 6.2 επηρεάζουν πιθανότατα αρνητικά την μέθοδο επαναλάβαμε εκτός διαγωνισμού την διαδικασία αλλά πραγματοποιώντας ακριβώς τα βήματα της μεθόδου και χρησιμοποιώντας SES για πρόβλεψη στην γραμμή $L(\theta=2)$ και τα υποσύνολα της. Στην διαδικασία αυτή χρησιμοποιήθηκε το πρόγραμμα παραγωγής προβλέψεων Πυθία και το λογισμικό Alyuda NeuroIntelligence. Τα αποτελέσματα για το σύνολο των χρονοσειρών ήταν τα ακόλουθα:

	Theta AI
MAPE	14.47%
SMAPE	14.57%

Πίνακας 6.4 Αποτελέσματα με τη χρήση SES για την πρόβλεψη στην $L(\theta=2)$

Το αποτελέσματα αυτά μας δίνουν το ερέθισμα πως η διαδικασία Theta AI είναι σε θέση να βελτιώσει τα αποτελέσματα της μεθόδου Theta.


6.5 Εργαλεία που χρησιμοποιήθηκαν

Τα εργαλεία που χρησιμοποιήθηκαν κατά τις διαδικασίες που περιγράφονται παραπάνω είναι τα ακόλουθα:

6.5.1 Πυθία

Το σύστημα Πυθία είναι σχεδιασμένο από την Μονάδα Προβλέψεων και Προοπτικής κάτω από την εποπτεία του καθ. Σπ. Μακρυδάκη. Σε αυτό υλοποιούνται όλες οι γνωστές μέθοδοι πρόβλεψης αλλά και τμήματα που σχετίζονται με μακροχρόνια πρόβλεψη, πρόβλεψη αποθήκης και δυνατότητα παραγωγής παλινδρομικών μοντέλων. Το σύστημα χρησιμοποιήθηκε για την παραγωγή προβλέψεων με μέθοδο SES (Εκθ. Εξομάλυνση σταθερού επιπέδου) και απλή γραμμική παλινδρόμηση καθώς και για την παραγωγή των εποχιακών δεικτών με

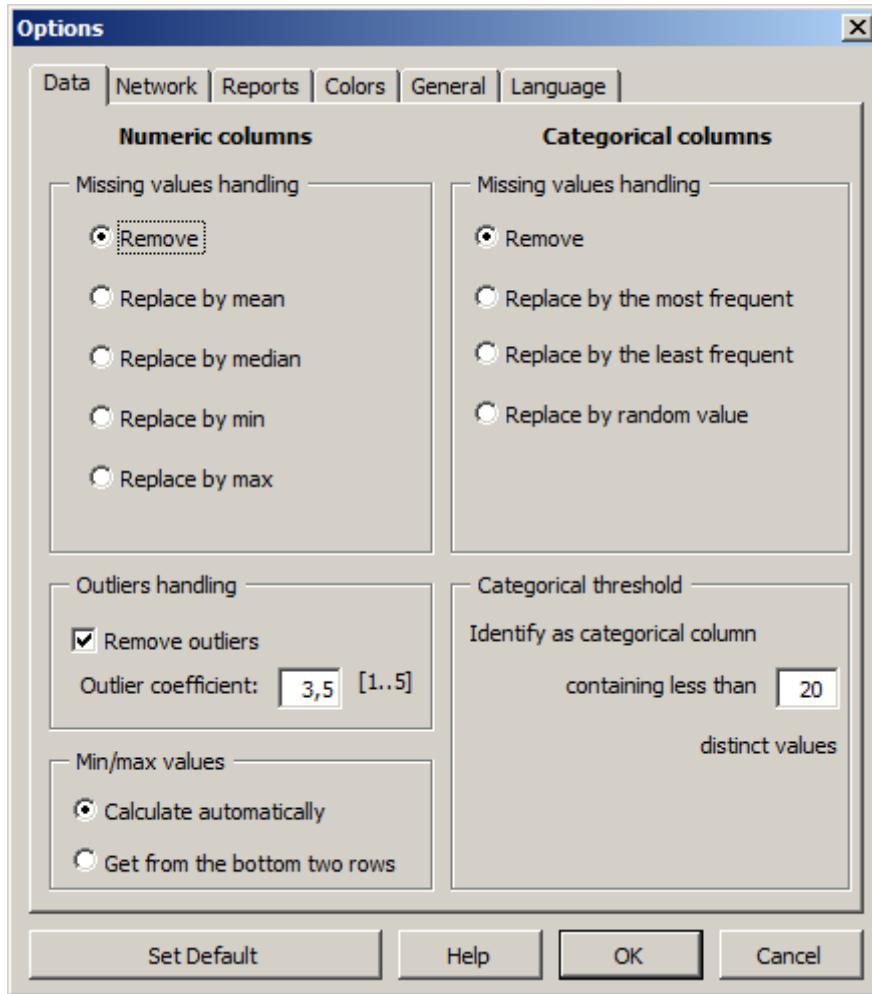
μέθοδο αποσύνθεσης που χρησιμεύουν στην αποεποχικοποίηση και εποχικοποίηση των χρονοσειρών.



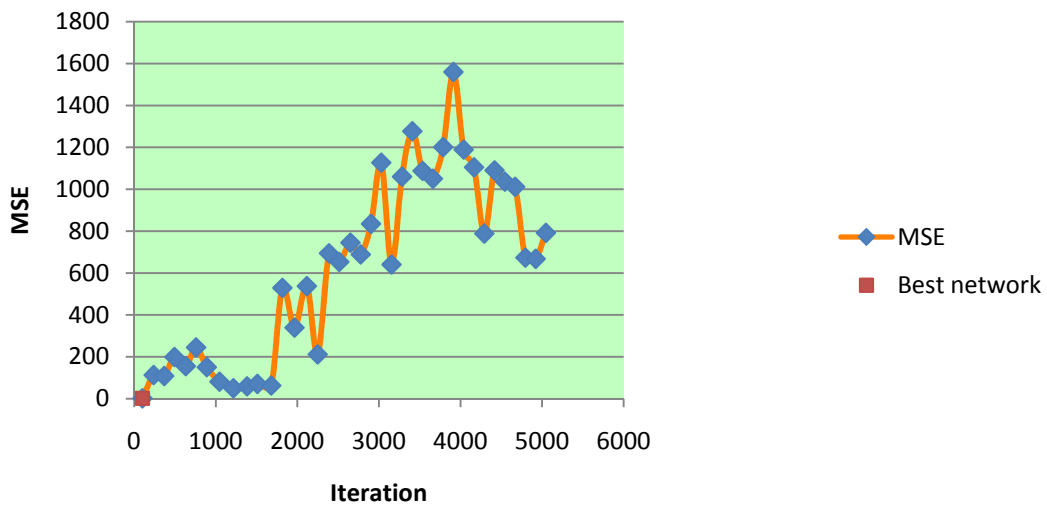
Σχήμα 6.2 Πυθία

6.5.1 Alyuda Forecaster XL

Το Alyuda Forecaster XL είναι ένα add on στο λογισμικό MS Excel και χρησιμοποιήθηκε για την παραγωγή προβλέψεων με νευρωνικά δίκτυα ακολουθώντας μεθοδολογία που βασίζεται καθαρά στη θεωρία νευρωνικών δικτύων. Μπορεί να λύσει προβλήματα πρόβλεψης και κατηγοριοποίησης. Η αποτελεσματικότητά του στην πρόβλεψη χρονοσειρών δεν μπορεί να συγκριθεί με αυτήν των κλασικών μεθόδων πρόβλεψης χρονοσειρών καθώς τα σφάλματα που έδωσε είναι κατά πολύ μεγαλύτερα.



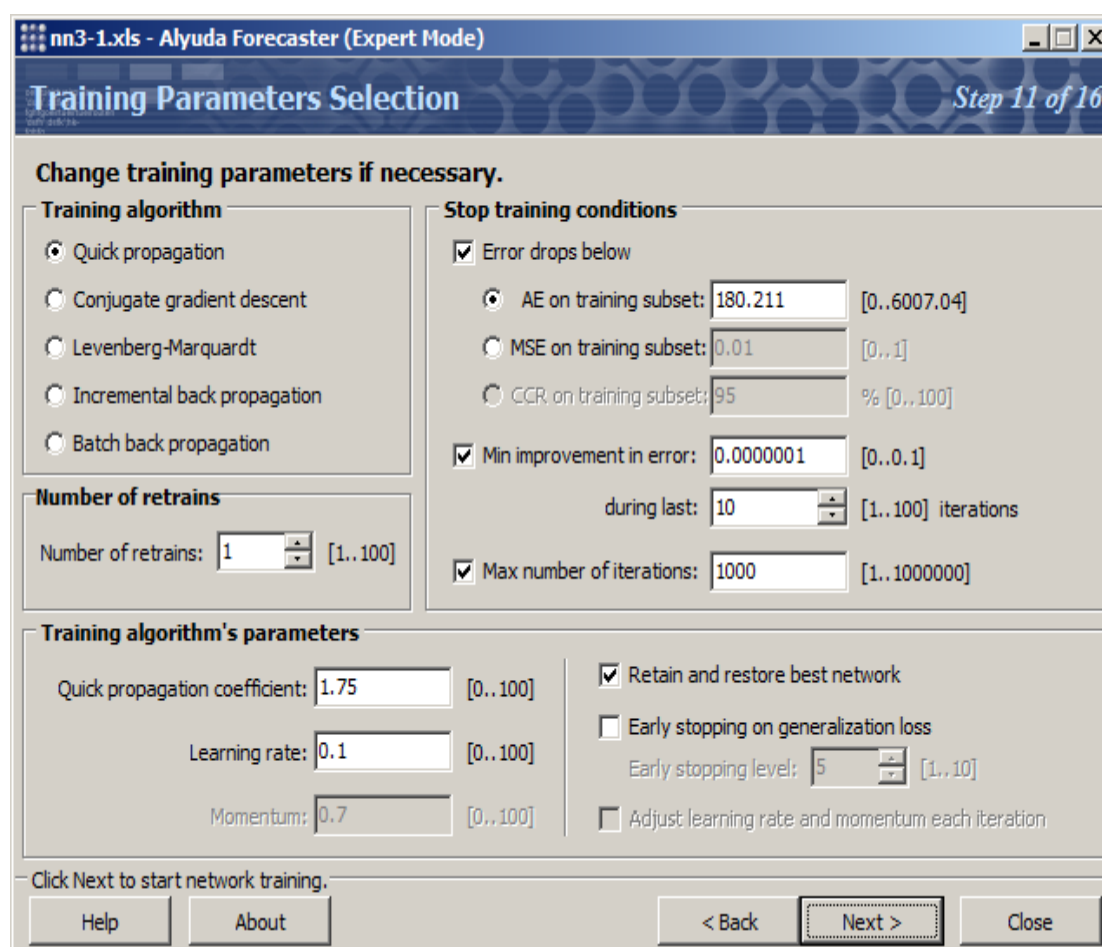
Σχήμα 6.3 Alyuda Forecaster XL



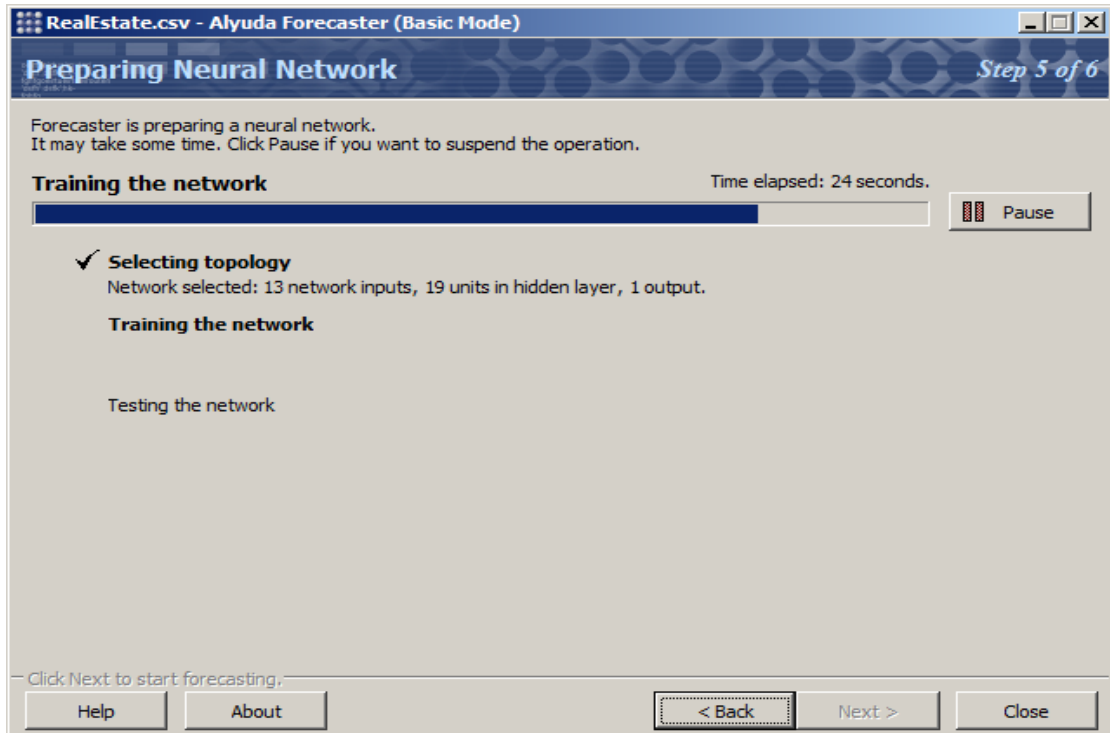
Σχήμα 6.4 Alyuda Forecaster XL-results

6.5.2 Alyuda Forecaster

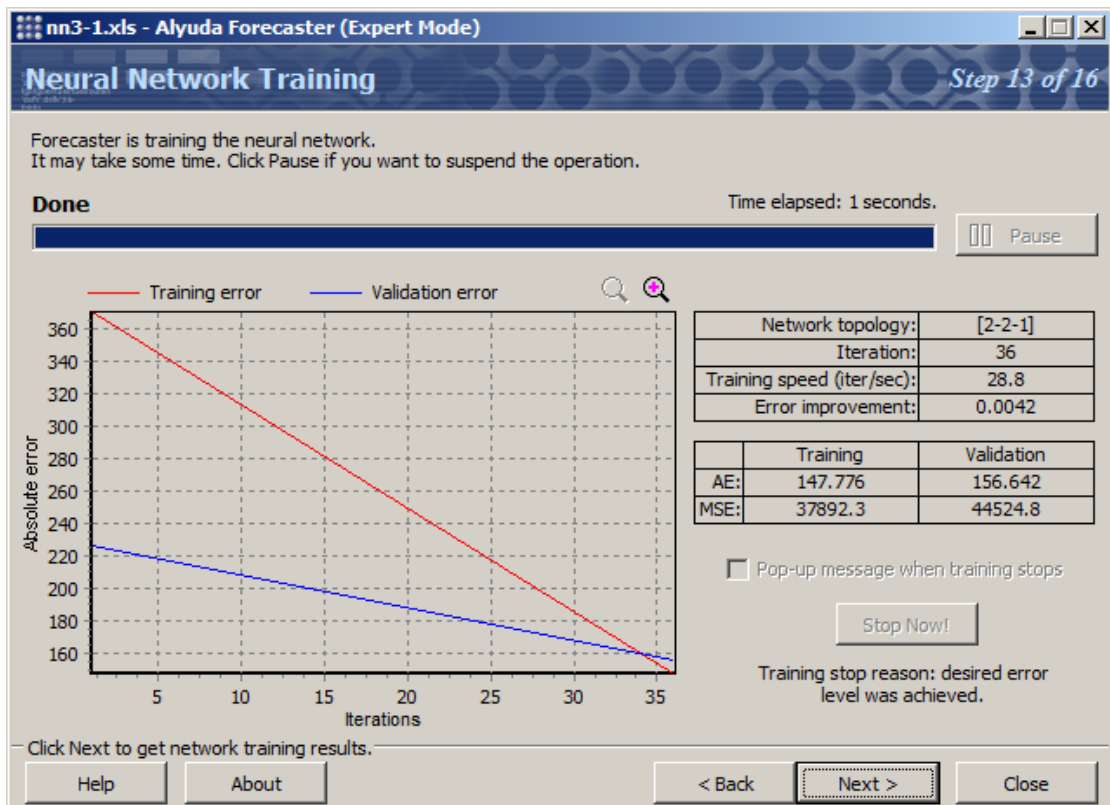
Το λογισμικό Alyuda Forecaster δίνει λύσης σε προβλήματα πρόβλεψης και κατηγοριοποίησης με την χρήση νευρωνικών δικτύων. Χρησιμοποιήθηκε για την παραγωγή προβλέψεων για το περιορισμένο σύνολο του διαγωνισμού NN3. Σαν είσοδο και δεδομένα εκπαίδευσης εισήχθησαν δεδομένα που είχαν προκύψει από το σύστημα Πυθία. Παρέχει αυτοματισμούς σε ότι αφορά την επιλογή της τοπολογίας του νευρωνικού δικτύου που θα χρησιμοποιηθεί και υλοποιεί του πιο γνωστούς αλγόριθμους εκπαίδευσης νευρωνικών δικτύων.



Σχήμα 6.5 Alyuda Forecaster (1)



Σχήμα 6.6 Alyuda Forecaster (2)



Σχήμα 6.7 Alyuda Forecaster

6.5.3 Alyuda NeuroFusion

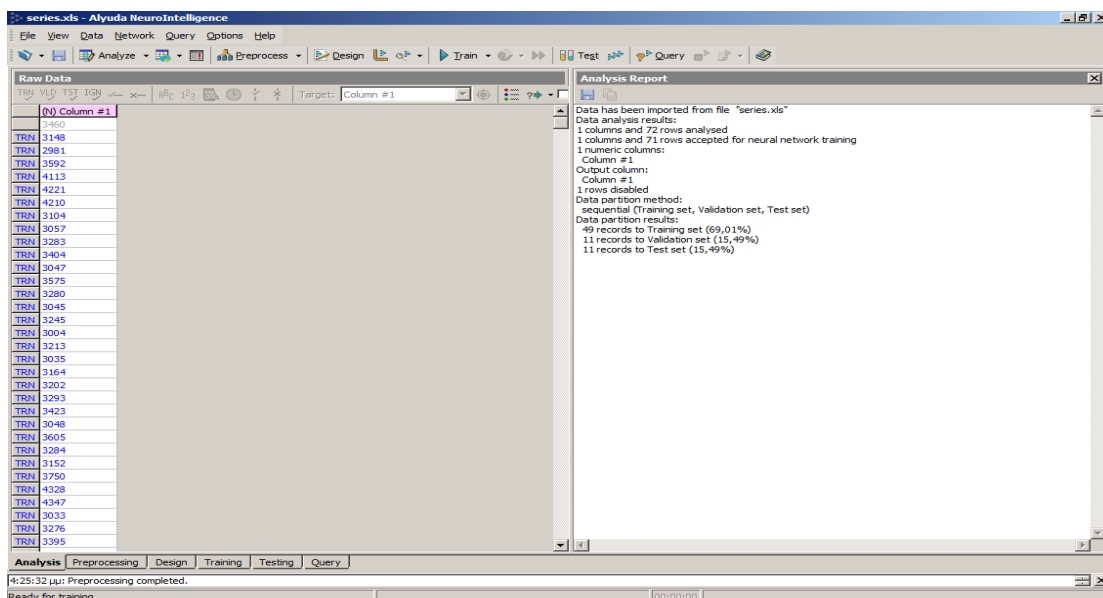
Το Alyuda NeuroFusion είναι μια βιβλιοθήκη ρουτινών που επιτρέπουν την χρήση νευρωνικών δικτύων μέσω κώδικα. Χρησιμοποιήθηκε για την παραγωγή των προβλέψεων του πλήρους σετ του διαγωνισμού NN3. Από την Μονάδα αναπτύχθηκε ειδικό λογισμικό που είχε ως είσοδο δεδομένα από το σύστημα Πυθία. Η βιβλιοθήκη έχει κάποια μειονεκτήματα ως προς την χρήση της σε νευρωνικά δίκτυα για χρονοσειρές με κυριότερο το γεγονός πως επιλέγει τυχαίο training , validation και test set που στην περίπτωση των χρονοσειρών δεν ενδείκνυται αφού τα πιο πρόσφατα δεδομένα είναι μεγαλύτερης βαρύτητας. Χρησιμοποιήθηκε όμως λόγω του ότι η χρήση της επιτάχυνε σημαντικά την διαδικασία σε σχέση με την παραγωγή προβλέψεων μέσω ενός λογισμικού που επεξεργάζεται μια προς μια τις χρονοσειρές και δεν έχει δυνατότητα μαζικής επεξεργασίας. Τα μειονεκτήματα του είναι και ένας λόγος που επαναλήφθηκε το πείραμα για βελτιστοποίησης.

6.5.4 Alyuda NeuroIntelligence

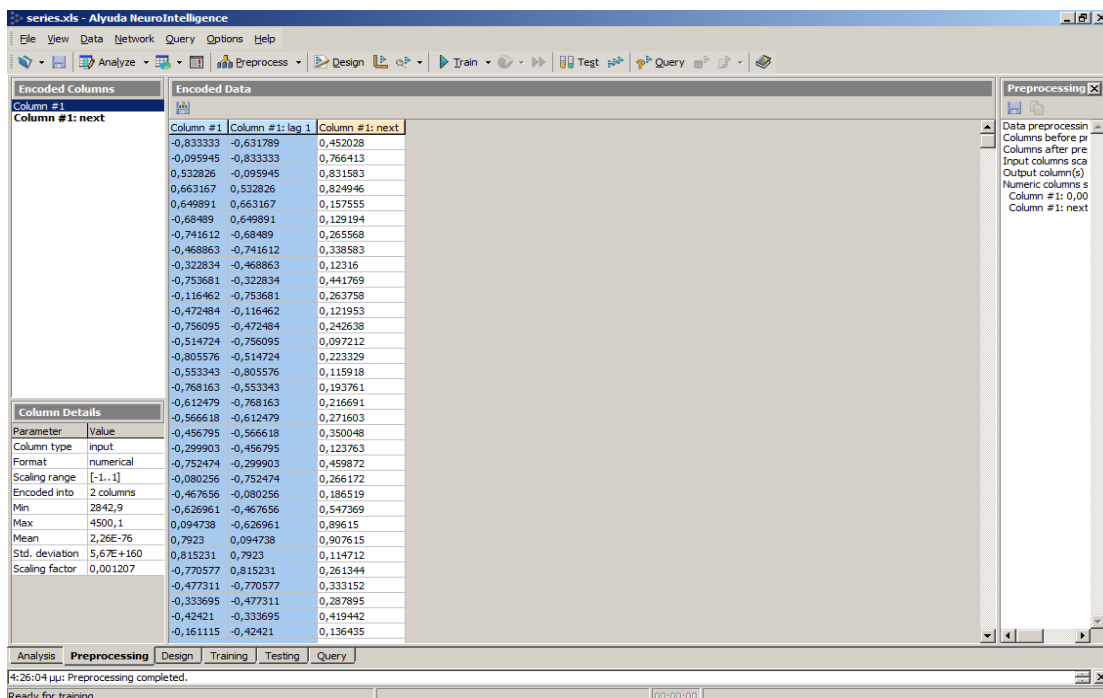
Το Alyuda NeuroIntelligence είναι ένα λογισμικό το οποίο επιτρέπει όπως και το Alyuda Forecaster την χρήση νευρωνικών δικτύων για πρόβλεψη και κατηγοριοποίηση. Ουσιαστικά αποτελεί ένα υπερσύνολο του Alyuda Forecaster αφού έχει πιο πολλές δυνατότητες και επιδέχεται μεγαλύτερη παραμετροποίηση. Χρησιμοποιήθηκε κατά την βελτιστοποίηση της μεθόδου Theta AI. Και σε αυτό το στάδιο οι είσοδοι και το σύνολα εκπαίδευσης, δοκιμής και ελέγχου προήλθαν από το σύστημα Πυθία. Για κάθε μια από της 111 χρονοσειρές του πλήρους σετ ακολουθήθηκαν τα βήματα της μεθόδου. Στο Πυθία έγιναν οι αποεποχικοποιήσεις και οι προβλέψεις για τις χρονοσειρές (τις περιορισμένες μέχρι το σημείο k αλλά τις ολόκληρες). Στη συνέχεια συνθέτονταν ένα αρχείο MS EXCEL που διάβαζε το Alyuda NeuroIntelligence και κατά τα βήματα της εκπαίδευσης του Νευρωνικού Δικτύου τα ακόλουθα υπο-βήματα:

Στάδιο: Analyze – Partition- Preprocess

Κατά την φάση αυτή επιλέγονται στοιχεία όπως ποια θα είναι τα σύνολα εκπαίδευσης, δοκιμής και ελέγχου και γίνεται η επεξεργασία των συνόλων και ο καθαρισμός τους από outliers κλπ.



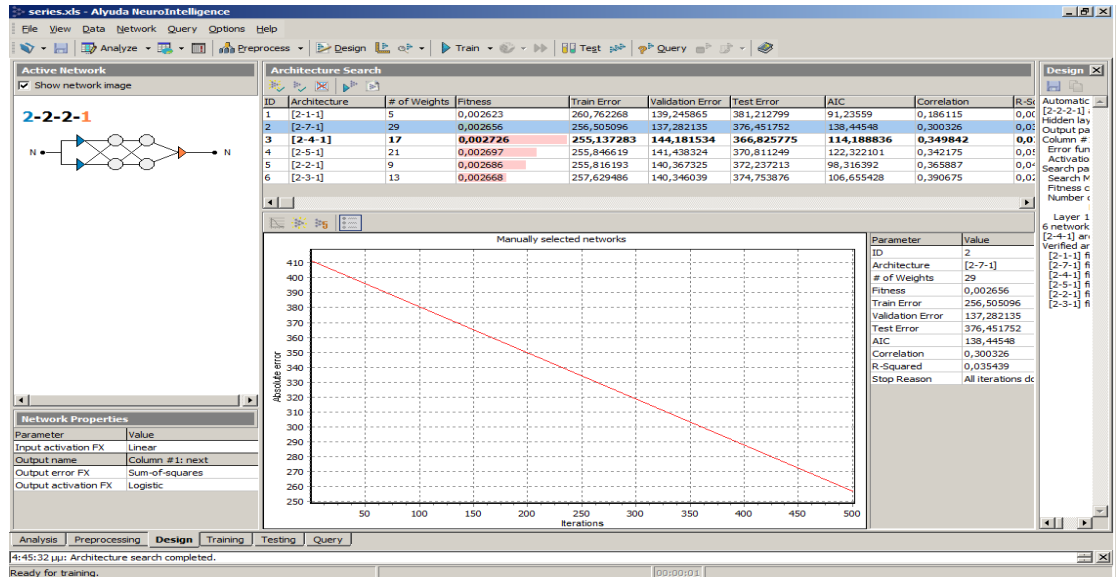
Σχήμα 6.8 Analyze – Partition- Preprocess (1)



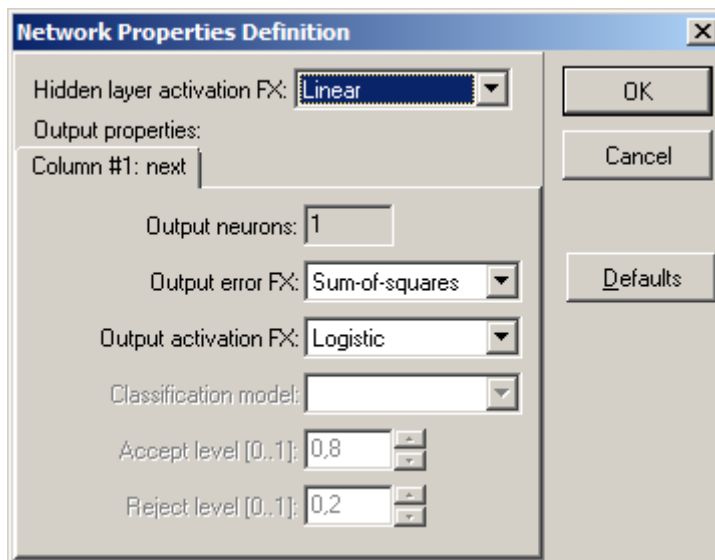
Σχήμα 6.9 Analyze – Partition- Preprocess (2)

Design Architecture - Search Architecture- Train

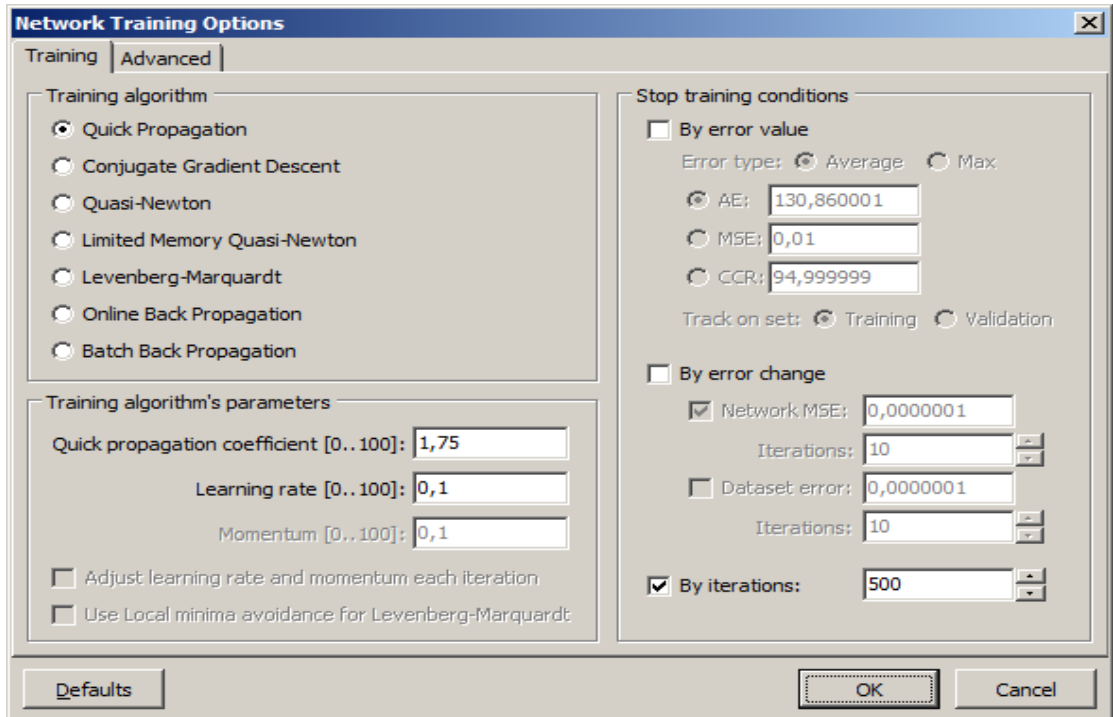
Κατά την φάση αυτή μπορεί να καθοριστεί η δομή του νευρωνικού δικτύου καθώς και να εκπαιδευτεί αυτό με διάφορους τρόπους και παραμέτρους που μπορούμε να επιλέξουμε. Τελικά επιλέγουμε το νευρωνικό δίκτυο που επιθυμούμε ή το σύστημα επιλέγει το καταλληλότερο.



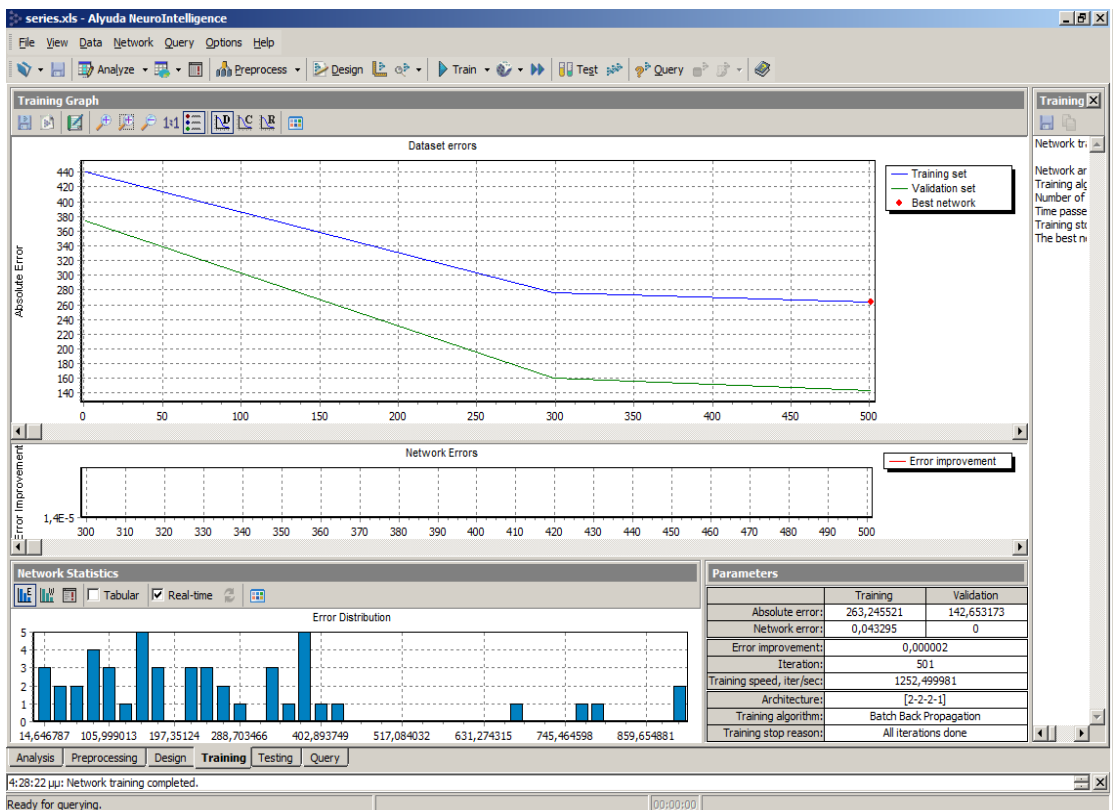
Σχήμα 6.10 Design Architecture - Search Architecture- Train (1)



Σχήμα 6.11 Design Architecture - Search Architecture- Train (2)



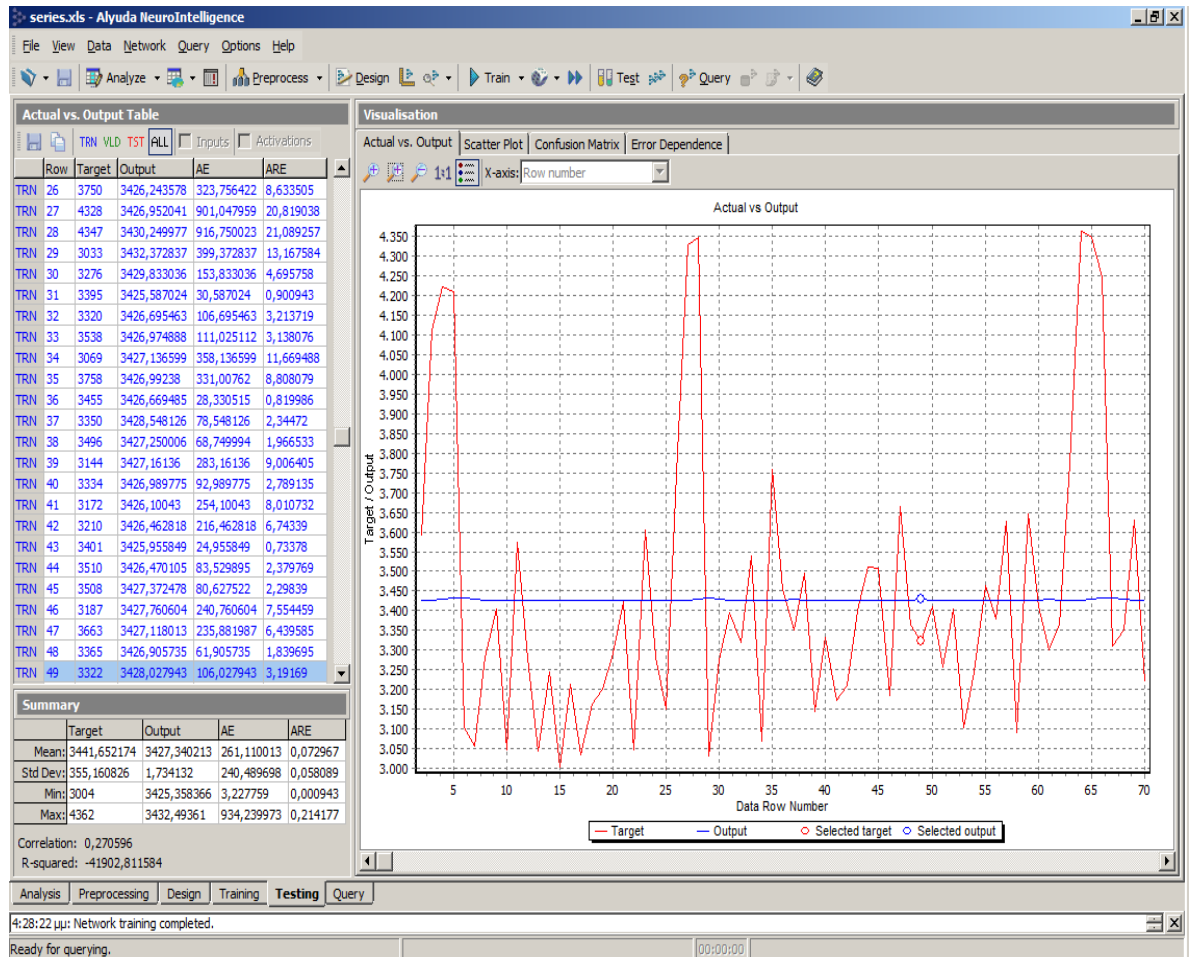
Σχήμα 6.12 Design Architecture - Search Architecture- Train (3)



Σχήμα 6.13 Design Architecture - Search Architecture- Train (4)

Test

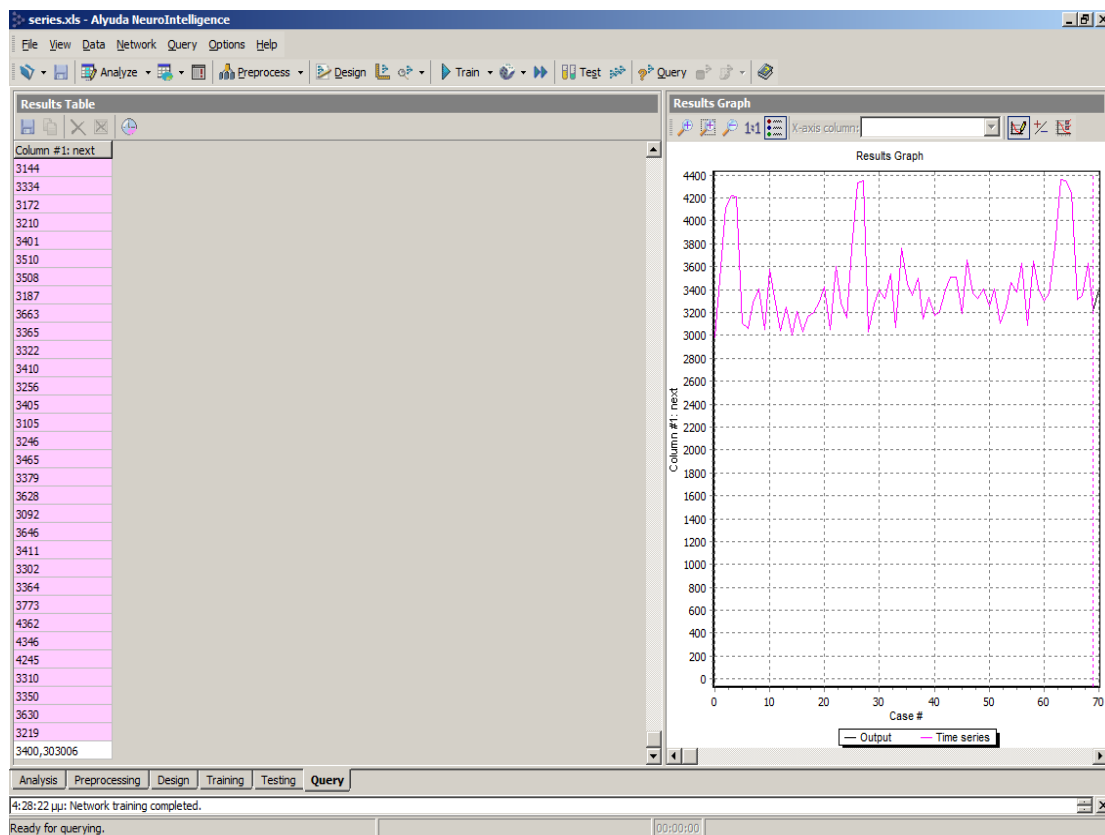
Αφού επιλεγεί το νευρωνικό μπορούμε να δούμε την «απόδοση» του σε όλα τα σύνολα και να κρίνουμε αν αυτό είναι κατάλληλο για τον σκοπό μας.



Σχήμα 6.14 Test

Query

Στο επιλεγμένο νευρωνικό δίκτυο εισάγουμε τις τιμές εισόδου και λαμβάνουμε τις αποεποχικοποιημένες προβλέψεις.



Σχήμα 6.15 Query

Αυτές οι προβλέψεις εποχικοποιούνται πάλι και έτσι παίρνουμε τις τελικές προβλέψεις.

7|| ΕΠΙΛΟΓΟΣ

7.1 Συμπεράσματα

Από τα αποτελέσματα της εργασίας αλλά και από την διαδικασία που χρειάστηκε να ακολουθηθεί βγάζουμε τα ακόλουθα συμπεράσματα.

- Η επεξεργασία και η γενικότερη ενασχόληση με τα Νευρωνικά Δίκτυα είναι μια αρκετά **χρονοβόρο διαδικασία**, η οποία ξεκινά από την συλλογή των πολυάριθμων δεδομένων έως και την εξαγωγή κάποιου συμπεράσματος. Δεν ενδείκνυται για μαζική παραγωγή προβλέψεων.
- Τεχνικές τεχνητής νοημοσύνης μπορούν να βελτιώσουν την απόδοση κλασικών μεθόδων πρόβλεψης έστω και οριακά.
- Μειονέκτημα είναι ότι η μέθοδος επειδή στηρίζεται σε νευρωνικά δίκτυα δεν αναπαράγει ακριβώς τα ίδια αποτελέσματα

7.2 Μελλοντικές Επεκτάσεις

Για καλύτερη τεκμηρίωση, βελτίωση των αποτελεσμάτων της Theta AI αλλά και συναφή έρευνα προτείνεται:

- Πραγματοποίηση πειραμάτων σε μεγαλύτερα σύνολα χρονοσειρών (π.χ. M3).
- Τροποποίηση της διαδικασίας Theta AI ώστε να λαμβάνει υπόψη της τον ορίζοντα πρόβλεψης.
- Χρήση περισσότερων γραμμών Θ στη διαδικασία.
- Χρήση άλλων τεχνικών τεχνητής νοημοσύνης (π.χ. ασαφής λογική, δέντρα αποφάσεων κτλ)

8|| ΒΙΒΛΙΟΓΡΑΦΙΑ

1. Zhang, G., B.E. Patuwo & M. Y. Hu (1998) "Forecasting with artificial neural networks: The state of the art," *International Journal of Forecasting*, 14, 35-62
2. Tim Hill; Marcus O'Connor; William Remus, 1996. Neural Network Models for Time Series Forecasts *Management Science*, Vol. 42, No. 7. (Jul., 1996), pp. 1082-1092
3. V. Assimakopoulos, K. Nikolopoulos, 2000. The Theta model: a decomposition approach to forecasting *International Journal of Forecasting*, 16, 521-530.
4. Rob J. Hyndman, Baki Bihah, 2001. Unmasking the Theta Model. working paper ISSN 1440-771x ISBN 0 7326 1085 0.
5. Spyros Makridakis, Steven C. Wheelwright, Rob J. Hyndman, 1998. Forecasting: Methods and Applications 3rd edition, John Wiley & Sons, New York
6. G. Peter Zhang, 2004. Neural Networks in Business Forecasting *IRM Press*
7. Makridakis, S., Hibon, M., 2000. The M3-Competition: Results, conclusions and implications. *International Journal of Forecasting*, 16, 451-476.
8. J. Scott Armstrong, Monica Adya, Fred Collopy. Principles of Forecasting NN: Rule-based forecasting: Using Judgement in time-series extrapolation
9. William Remus, Marcus O'Connor. Principles of Forecasting NN: Neural Networks for time-series forecasting
10. Refenes, A.N., Azema-Barac, M., 1994. Neural networks applications in financial asset management. *Neural Computing and Applications* 2, 13-39.
11. Kaastra, I., Boyd, M., 1996. Designing a neural network for forecasting financial and economic time series. *Neurocomputing* 10, 215-236.
12. Makridakis, S., 1993. Accuracy measures: theoretical and practical concerns, *International Journal of Forecasting*, 9, 527-529.
13. Nikolopoulos, K., 2002. *Business Forecasting Methodology and Information System*. Thesis (PhD). National Technical University of Athens.
14. Fildes, R., Makridakis, S., 1988. Loss functions and forecasting. *International Journal of Forecasting*, 4, 545-550.
15. Mahmoud, E., 1984. Accuracy in forecasting: A survey. *Journal of Forecasting*, 3, 139-159.
16. Makridakis, S., 1986. The art and science of forecasting: An assessment and future directions, *International Journal of Forecasting*, 2, 15-39.
17. Ord, K., 2001. Commentaries on the M3-Competition. An introduction, some comments and a scorecard, *International Journal of Forecasting*, 17, 537-584.
18. Stekler, H.O. 2001. The M3-competition: The need for formal statistical tests. *International Journal of Forecasting*, 17, 576-577.
19. Julian Faraday; Chris Chatfield, 1998. Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data *Applied Statistics*, Volume 47, Issue 2, 231-250.
20. Sandy D. Balkin, J. Keith Ord, 2000. Automatic neural network modeling for univariate time series *International Journal of Forecasting* 16, 509-515.

21. Monica Adya, Fred Collopy, 1998. How effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation. *Journal of Forecasting* 17, 481-495.
22. Jonathon Shlens, 1999. Time Series Prediction with Artificial Neural Networks *Computer & Industrial Engineering* 54, 903-917.
23. J. Scott Armstrong, 2001. Combining Forecasts. *Principles of forecasting: A handbook for researchers and practitioners*, Kluwer Academic Publishers.
24. J. Scott Armstrong, 1981. How experts are the experts? *Inc.*, December 1981, 15-16.
25. J. Scott Armstrong, 2006. How to make Better Forecasts and Decisions: Avoid Face-to Face meetings. *Foresight: The International Journal of Applied Forecasting*, June 2006.
26. J. Scott Armstrong, Robert Fildes, 2006. Making Progress in Forecasting. *International Journal of Forecasting*
27. J. Scott Armstrong, 2001. Should we redesign Forecasting competitions? *International Journal of Forecasting*, 17, 2001, 542-545.
28. Wei Cheng, Lorry Wagner, Chien-Hua Lin, 1996. Forecasting the 30-year U.S Treasury Bond with a system of Neural Networks. *NeuroVeSt Journal*, January/February 1996.
29. B. Cannas, A. Fanni, G. Tronci, M.K Zedda, 2005. River flow forecasting using neural networks and wavelet analysis. *Geophysical Research Abstracts*, Vol.7, 08651.
30. Rob Law, Hung Hom. Room occupancy rate forecasting: a neural network approach. *International Journal of Hospitality Management*, Vol.10, No.6, 234-239.
31. Mehdi Khashei, Seyed Reza Hejazi, Mehdi Bijari, 2008. A new hybrid artificial neural networks and fuzzy regression model for time-series forecasting. *Fuzzy Sets and Systems* 159, 769-786.
32. R.E Abdel-Aal , 2008. Univariate modeling and forecasting of monthly energy demand time series using ubductive and neural networks. *Computers & Industrial Engineering* 54, 903-917.
33. Ken Black, Daved Eldredge. Ch.14 Forecasting & Time Series. *Business and Economic Statistics using Microsoft Excel*.
34. Sven F.Crone, 2005. Forecasting with Artificial Neural Networks *EVIC 2005 Tutorial* Santiago de Chile, 15 December 2005.
35. Steve Dorling, Gavin Cawley, Jaakko Kukkonen, Ari Karppinen, 2003. Air Quality Forecasting Usind Neural Network Approaches. *Air Quality Forecasting Meeting*, Culham, 15th April 2003.
36. www.neural-forecasting-competition.com/NN3/index.htm
37. Ασημακόπουλος, Β., 2005. Μέθοδοι Προβλέψεων. Αθήνα: Πανεπιστημιακές Εκδόσεις ΕΜΠ.
38. Οικονόμου, Μ., 2000. *Συγκριτική επίδοση μεθόδων πρόβλεψης: Διαγωνισμός M1 και μέθοδος Theta*. Διπλωματική Εργασία. Εθνικό Μετσόβιο Πολυτεχνείο.
39. Πετρόπουλος, Φ., 2007. Βελτιστοποίηση μεθόδου πρόβλεψης Θ και εφαρμογή επί των μηνιαίων δεδομένων των διαγωνισμών M3 και T.

40. Γιαννέλος, Κ., 2004. Πληροφοριακό σύστημα υποστήριξης κριτικών επεμβάσεων σε στατιστικές προβλέψεις
41. Δημόπουλος, Σ., 2008. Πρόβλεψη χρονοσειρών με τη χρήση νευρωνικών δικτύων- εφαρμογή στον τομέα του τουρισμού.

.....
ΤΣΙΑΦΑ Δ. ΕΙΡΗΝΗ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.
© 2008 – All rights reserved

