



**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
ΤΜΗΜΑ ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**

ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**ΘΕΜΑ : ΤΕΧΝΙΚΕΣ ΒΡΑΧΥΠΡΟΘΕΣΜΗΣ ΠΡΟΒΛΕΨΗΣ
ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ**



**Μαρκουλάκης Στυλιανός Α.Μ. : 2003030002
e-mail:smarkoul1@yahoo.gr**

Επιβλέπων Καθηγητής : Σταυρακάκης Γεώργιος

Χανιά, Σεπτέμβριος 2004

ΚΕΦΑΛΑΙΟ 1

ΕΙΣΑΓΩΓΗ

1.1 ΥΠΟΒΑΘΡΟ

Η συνεχής παρακολούθηση του φορτίου από την παραγωγή του συστήματος είναι μία βασική απαίτηση της λειτουργίας των συστημάτων ηλεκτρικής ενέργειας.

Για τον έλεγχο και την οικονομική λειτουργία του συστήματος, η παρακολούθηση του φορτίου από την παραγωγή, πρέπει να γίνεται συνεχώς και σε ένα μεγάλο φάσμα χρονικών διαστημάτων. Σε διάστημα δευτερολέπτων, όπου οι διακυμάνσεις του φορτίου είναι σχετικά μικρές και τυχαίες, ο Αυτόματος Έλεγχος Παραγωγής (ΑΕΠ)* φροντίζει ώστε η παραγωγή του συστήματος να αντισταθμίζει τη ζήτηση του φορτίου. Σε διαστήματα μερικών λεπτών, όπου οι διακυμάνσεις του φορτίου είναι μεγαλύτερες, η Οικονομική Κατανομή Φορτίου* φροντίζει για την κατανομή του συνολικού φορτίου του συστήματος στις ήδη ενταγμένες στο δίκτυο μονάδες κατά τον πλέον οικονομικό τρόπο. Σε διαστήματα μερικών ωρών ή και ημερών, οι διακυμάνσεις του φορτίου είναι ακόμη μεγαλύτερες. Η κάλυψη του φορτίου για τέτοια χρονικά διαστήματα απαιτεί την εκκίνηση ή την κράτηση μονάδων παραγωγής ή ανταλλαγή ισχύος με τα γειτονικά συστήματα ηλεκτρικής ενέργειας.

Λειτουργίες βραχυπρόθεσμου προγραμματισμού της παραγωγής, όπως η Οικονομική Ένταξη Μονάδων Παραγωγής*, η Υδροθερμική Συνεργασία* και οι Οικονομικές Ανταλλαγές Ισχύος*, φροντίζουν για την κάλυψη του φορτίου για χρονικά διαστήματα που κυμαίνονται από τις λίγες επόμενες ώρες έως και την επόμενη εβδομάδα. Για χρονικές περιόδους μηνών έως και πέντε χρόνων γίνεται προγραμματισμός καυσίμων, χρήσης υδάτινων πόρων, συντήρησης των μονάδων κατά τρόπο που να εξασφαλίζεται η αξιόπιστη κάλυψη του φορτίου με τις ήδη εγκατεστημένες στο δίκτυο μονάδες. Τέλος, για μεγάλα χρονικά διαστήματα, μέχρι και τα 25 επόμενα χρόνια, γίνεται προγραμματισμός ένταξης (εγκατάστασης) νέων μονάδων στο σύστημα, ώστε να καλυφθεί ενδεχόμενη αύξηση του φορτίου του συστήματος [1].

* Οι λειτουργίες : Αυτόματος Έλεγχος Παραγωγής (ΑΕΠ), Οικονομική Κατανομή Φορτίου, Οικονομική Ένταξη Μονάδων Παραγωγής, Υδροθερμική Συνεργασία και Οικονομικές Ανταλλαγές Ισχύος, που αναφέρονται παραπάνω και σχετίζονται με τον προγραμματισμό και τον έλεγχο της παραγωγής ηλεκτρικής ενέργειας, είναι βασικές λειτουργίες του υποσυστήματος παραγωγής, το οποίο υπάγεται στη λειτουργία της Ενεργειακής Διαχείρισης του Λογισμικού Εφαρμογών των Συστημάτων Ελέγχου Ενέργειας στη χώρα μας.

Η πρόβλεψη φορτίου είναι, λοιπόν, μία από τις βασικές λειτουργίες στα συστήματα ηλεκτρικής ενέργειας. Το κίνητρο για ακριβείς προβλέψεις βρίσκεται στη φύση του ηλεκτρισμού ως ένα αγαθό και εμπορικό είδος. Ο ηλεκτρισμός δεν μπορεί να αποθηκευθεί, κάτι το οποίο σημαίνει ότι για μια ηλεκτρική χρήση η εκτίμηση της μελλοντικής απαίτησης είναι απαραίτητη για τη διαχείριση της παραγωγής και αγοράς με έναν οικονομικό τρόπο. Στην Ελλάδα η αγορά ενέργειας έχει πρόσφατα ανοίξει, γεγονός που αυξάνει τον ανταγωνισμό.

Βλέπουμε, επομένως, πόσο σημαντική είναι η πρόβλεψη του ηλεκτρικού φορτίου, δηλαδή της ζήτησης ηλεκτρικής ενέργειας, για διάφορους χρονικούς ορίζοντες, για τη σωστή και καλύτερη τεχνοοικονομικά διαχείριση και λειτουργία ενός συστήματος ηλεκτρικής ενέργειας. Υπάρχει, επομένως, η ανάγκη για μία κατά το δυνατόν αξιόπιστη και - με μικρές αποκλίσεις από την πραγματικότητα - πρόβλεψη του φορτίου, με στόχο τα αποτελέσματα αυτής να είναι τα καλύτερα δυνατά ούτως ώστε να μπορούν να χρησιμοποιηθούν για το σχεδιασμό των απαραίτητων ενεργειών που αφορούν τα συστήματα ηλεκτρικής ενέργειας.

Οι μέθοδοι πρόβλεψης φορτίου μπορούν να χωριστούν σε πολύ βραχυπρόθεσμα, βραχυπρόθεσμα, μεσοπρόθεσμα και μακροπρόθεσμα μοντέλα ανάλογα με το χρονικό διάστημα [2]. Σε πολύ βραχυπρόθεσμες προβλέψεις φορτίου ο προβλεπόμενος χρόνος μπορεί να είναι ακόμη και μερικά λεπτά, ενώ σε μακροπρόθεσμες προβλέψεις μπορεί να είναι από μερικά χρόνια έως και μερικές δεκαετίες.

Είδος Πρόβλεψης	Χρονικός Ορίζοντας	Λειτουργίες για τις οποίες χρειάζεται
Πολύ βραχυπρόθεσμη	μερικά sec - μερικά min	Αυτόματος Έλεγχος Παραγωγής Οικονομική Κατανομή Φορτίου
Βραχυπρόθεσμη	μερικές h - 1 εβδομάδα	Ένταξη Μονάδων Υδροθερμική Συνεργασία Ανταλλαγές Ισχύος
Μεσοπρόθεσμη	μερικοί μήνες - 5 έτη	Προγραμματισμός Καυσίμων Χρήση Υδάτινων Πόρων Προγραμματισμός Συντήρησης
Μακροπρόθεσμη	10 - 25 έτη	Προγραμματισμός Ένταξης Νέων Μονάδων

Πίνακας 1.1 Χαρακτηρισμός προβλέψεων φορτίου ανάλογα με το χρονικό ορίζοντα.

Οι προβλέψεις του φορτίου ανάλογα με το χρονικό ορίζοντα πρόβλεψης χαρακτηρίζονται όπως φαίνεται στον πίνακα 1.1 [1].

Αυτή η μελέτη θα επικεντρωθεί σε βραχυπρόθεσμες προβλέψεις φορτίου, όπου ο προβλεπόμενος χρόνος θα αφορά την επόμενη ώρα κάθε φορά .

Η βραχυπρόθεσμη πρόβλεψη φορτίου (short-term load forecasting, STLF) αποτελεί ένα ευρέως διαδεδομένο θέμα στη βιβλιογραφία των συστημάτων ηλεκτρικής ενέργειας (ΣΗΕ). Ένας λόγος είναι ότι πρόσφατες επιστημονικές καινοτομίες μας έχουν φέρει πιο κοντά στη λύση του προβλήματος. Η ανάπτυξη της τεχνολογίας των ηλεκτρονικών υπολογιστών έχει αυξήσει τις δυνατότητες για αυτές και άλλες μεθόδους που λειτουργούν σε περιβάλλον πραγματικού χρόνου. Ένας ακόμη λόγος μπορεί να είναι ότι υπάρχει μία διεθνής τάση αύξησης του ανταγωνισμού στις ηλεκτρικές αγορές [3].

Ακόμη κι αν πολλές μέθοδοι πρόβλεψης έχουν ελεγχθεί και αποδειχθεί επιτυχείς, καμία δεν έχει κατορθώσει να καθιερωθεί σαν μια ευρέως εφαρμοζόμενη μέθοδος. Ο λόγος είναι ότι οι συνθήκες και οι απαιτήσεις της κάθε μεθόδου έχουν σημαντική επίδραση στην επιλογή της κατάλληλης μεθόδου. Τα αποτελέσματα που έχουν παρουσιασθεί σε σχετική βιβλιογραφία συνήθως δεν είναι άμεσα συγκρίσιμα μεταξύ τους.

Μια μειονότητα των πρόσφατων προσεγγίσεων βασίζεται στις τεχνικές νευρωνικών δικτύων. Πολλές έρευνες έχουν επιφέρει ικανοποιητικά αποτελέσματα. Η ελκυστικότητα των μεθόδων βρίσκεται στη δυνατότητα την οποία έχουν τα νευρωνικά δίκτυα να είναι σε θέση να μάθουν ιδιότητες του φορτίου, που διαφορετικά θα απαιτούσε προσεκτική ανάλυση για να εντοπιστούν. Εξίσου ενδιαφέρουσες αποτελούν και οι τεχνικές πρόβλεψης που στηρίζονται στη χρήση της ασαφούς λογικής για την ανάπτυξη αυτόνομων συστημάτων πρόβλεψης φορτίου (νευρωασαφή δίκτυα), αλλά και στην ενσωμάτωση ή το συνδυασμό της ασαφούς λογικής σε κλασσικά νευρωνικά δίκτυα.

Παρόλα αυτά, η ανάπτυξη των μεθόδων δεν έχει ολοκληρωθεί και η έλλειψη συγκρίσιμων αποτελεσμάτων σε παραλλαγές διαφορετικού είδους μοντέλων αποτελεί ένα πρόβλημα. Συνεπώς, για να κάνουμε χρήση των τεχνικών αυτών σε πραγματικές εφαρμογές μια συγκριτική ανάλυση των ιδιοτήτων των διαφόρων τύπων μοντέλων δείχνει να είναι απαραίτητη.

1.2 ΣΚΟΠΟΣ ΤΗΣ ΜΕΛΕΤΗΣ

Αυτή η μελέτη ερευνά την εφαρμοσιμότητα του φίλτρου KALMAN καθώς επίσης και του νευρωνασαφούς δικτύου ANFIS (adaptive neural fuzzy inference system) στην βραχυπρόθεσμη πρόβλεψη φορτίου. Σε κάθε περίπτωση, είναι δυνατή η πρόβλεψη φορτίου για μια ολόκληρη μέρα κάθε φορά και η πρόβλεψη φορτίου για μία ή περισσότερες ώρες. Η προσέγγιση που ακολουθήθηκε σε αυτή την περίπτωση έχει ως εξής: Αναφορικά με το δίκτυο ANFIS, θεωρώντας ότι το μέσο ωριαίο φορτίο κατά τη διάρκεια μιας χρονιάς διαιρείται σε 24 διακριτές χρονοσειρές (με την κάθε μια να αφορά το φορτίο για μια συγκεκριμένη ώρα της ημέρας κατά τη διάρκεια του έτους), σχηματίζονται τα αντίστοιχα 24 μοντέλα (διακριτά μεταξύ τους) με στόχο την πρόβλεψη του μέσου ωριαίου ηλεκτρικού φορτίου από το καθένα χωριστά. Η παρούσα μελέτη περιορίζεται στα μοντέλα εκείνα που προβλέπουν το φορτίο για τις ώρες 02:00 και 14:00 της κάθε ημέρας. Όσον αφορά το φίλτρο KALMAN, λόγω της ιδιομορφίας του σε σχέση με τα προαναφερθέντα - όπως αυτό προτείνεται στην βιβλιογραφία [31] – δηλαδή, χρήση ενός συνόλου από διαδοχικές ημέρες ως σύνολα εκπαίδευσης και όχι διαχωρισμός σε 24 διακριτά σύνολα εκπαίδευσης και άρα 24 διακριτά μοντέλα, γίνεται πρόβλεψη μονάχα για τις ώρες 02:00 και 14:00 κάθε ημέρας ούτως ώστε να υπάρχει ένα κοινό μέτρο σύγκρισης. Σε κάθε περίπτωση, ο έλεγχος πραγματοποιείται μέσω της σύγκρισης με τα πραγματικά στοιχεία φορτίου της ηλεκτρικής κατανάλωσης. Ο σκοπός είναι να μπορέσουμε να εισηγηθούμε την επιλογή της καταλληλότερης δομής του μοντέλου.

Αυτή η μελέτη δεν ασχολείται με προβλέψεις σε ειδικές ημέρες, όπως είναι οι θρησκευτικές και οι νόμιμες αργίες. Οι ειδικές ημέρες έχουν διαφορετικό προφίλ κατανάλωσης από τις συνηθισμένες ημέρες, γεγονός που κάνει την πρόβλεψη για αυτές πολύ δύσκολη. Συχνά ωστόσο, όταν τίθεται σε εφαρμογή μια πραγματική εφαρμογή, ζητείται να βρεθεί ένας τρόπος ώστε να λάβουμε υπόψη και αυτές τις ημέρες. Η πιο κοινή προσέγγιση - αλλά όχι απαραίτητα η καλύτερη - είναι να τις αντιμετωπίσουμε σαν να είναι Κυριακές.

1.3 ΔΟΜΗ ΤΗΣ ΜΕΛΕΤΗΣ

Το δεύτερο κεφάλαιο επικεντρώνεται στο αντικείμενο της πρόβλεψης φορτίου γενικά. Πρώτα αναφέρονται οι ιδιότητες της καμπύλης φορτίου μιας ηλεκτρικής χρήσης και διάφοροι παράγοντες που επηρεάζουν το φορτίο. Έπειτα μελετούνται δυνατές προσεγγίσεις του προβλήματος. Οι πιο δημοφιλείς συμβατικές μέθοδοι παρουσιάζονται εν συντομία.

Το τρίτο κεφάλαιο αναφέρεται σε διάφορα μοντέλα πρόβλεψης νευρωνικών δικτύων αλλά και του μοντέλου AR - μοντέλο αυτοπαλινδρόμησης (autoregressive) -, όπως αυτά παρουσιάζονται μέσα από τη μελέτη των Κ.Καλαϊτζάκη, Γ.Σταυρακάκη και Ε.Αναγνωστάκη με τίτλο “Short term load forecasting based on artificial neural networks parallel implementation” [43]. Έτσι γίνεται μια συνοπτική παρουσίαση των διαφόρων μεθόδων πρόβλεψης που αναφέρονται, τα αποτελέσματα των οποίων θα χρησιμοποιηθούν ως μέτρο σύγκρισης για τα δύο επιπρόσθετα μοντέλα που πραγματεύεται η παρούσα μελέτη (δηλαδή, το φίλτρο KALMAN και δίκτυο ANFIS).

Στο τέταρτο κεφάλαιο, γίνεται μια αναλυτική περιγραφή, από μαθηματικής άποψης, του φίλτρου KALMAN και ακολούθως, παρουσίαση της συγκεκριμένης διαδικασίας που ακολουθήθηκε (όπως παρουσιάζεται μέσα από συγκεκριμένη μελέτη) με στόχο την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου.

Το πέμπτο κεφάλαιο ξεκινάει με μια εισαγωγή στο πεδίο που αφορά την ασαφή λογική (βασικές έννοιες, ορισμοί, εισαγωγή σε διάφορα νευρωσασαφή μοντέλα), και ακολουθεί μια παρουσίαση κάποιων εφαρμογών από διάφορα μοντέλα που ενσωματώνουν την ασαφή λογική. Στη συνέχεια περιγράφεται το νευρωσασαφές δίκτυο ANFIS (δομή, εκπαίδευση) και η συνεπακόλουθη εφαρμογή του στην πρόβλεψη του φορτίου.

Το έκτο κεφάλαιο παρουσιάζει τα αποτελέσματα των δοκιμών (σφάλματα, γραφικές παραστάσεις) που αφορούν τα μοντέλα KALMAN και ANFIS, με τελικό στόχο τη σύγκριση των σφαλμάτων από το σύνολο των μοντέλων (KALMAN, ANFIS και μοντέλα της μελέτης που παρουσιάζεται στο τρίτο κεφάλαιο).

Τέλος, στο έβδομο κεφάλαιο, παρουσιάζονται γενικά συμπεράσματα και παρατηρήσεις που προέκυψαν από τη μελέτη αυτή.

ΚΕΦΑΛΑΙΟ 2

ΠΡΟΒΛΕΨΗ ΦΟΡΤΙΟΥ

2.1 ΠΑΡΑΓΟΝΤΕΣ ΠΟΥ ΕΠΗΡΕΑΖΟΥΝ ΤΟ ΦΟΡΤΙΟ

Γενικά, το φορτίο μια ηλεκτρικής χρήσης απαρτίζεται από πολύ διαφορετικές καταναλωτικές μονάδες. Ένα μεγάλο μέρος του ηλεκτρισμού καταναλώνεται σε βιομηχανικές δραστηριότητες. Ένα άλλο μέρος φυσικά χρησιμοποιείται από ιδιώτες με σκοπό τη θέρμανση, το φωτισμό, το μαγείρεμα κ.ά. Επίσης, πολλές κοινωφελείς υπηρεσίες απαιτούν ηλεκτρισμό, π.χ. ο φωτισμός των δρόμων, ο ηλεκτρικός σιδηρόδρομος κ.ά.

Οι παράγοντες που επηρεάζουν το φορτίο εξαρτώνται από τις επιμέρους μονάδες κατανάλωσης. Το βιομηχανικό φορτίο συνήθως καθορίζεται περισσότερο από το επίπεδο της παραγωγής. Το φορτίο είναι συνήθως αρκετά σταθερό και είναι δυνατό να εκτιμηθεί η εξάρτηση του σε διαφορετικά επίπεδα παραγωγής. Παρ' όλα αυτά, από την σκοπιά της πώλησης ενέργειας, η βιομηχανική χρήση συχνά προσθέτει αβεβαιότητα στις προβλέψεις. Το πρόβλημα είναι η πιθανότητα απροσδόκητων συμβάντων, όπως μηχανικές βλάβες ή απεργίες, οι οποίες μπορούν να προκαλέσουν μεγάλες απρόβλεπτες διακυμάνσεις στο επίπεδο φορτίου. Στην περίπτωση των ιδιωτών, οι παράγοντες που επηρεάζουν το φορτίο είναι πολύ πιο δύσκολο να καθοριστούν. Κάθε άνθρωπος συμπεριφέρεται με τον δικό του ιδιαίτερο τρόπο και η ανθρώπινη ψυχολογία σχετίζεται με κάθε καταναλωτική απόφαση. Πολλοί κοινωνικοί παράγοντες αλλά και παράγοντες συμπεριφοράς μπορούν να παρατηρηθούν. Για παράδειγμα μεγάλα γεγονότα, αργίες ακόμη και τηλεοπτικά προγράμματα επηρεάζουν το φορτίο [2,4,5]. Ο καιρός είναι ο πιο σημαντικός παράγοντας κι αυτό εξαιτίας της ηλεκτρικής θέρμανσης των σπιτιών, η οποία γίνεται πιο έντονη όσο μειώνεται η θερμοκρασία [6].

Γενικά, θα λέγαμε ότι οι παράγοντες οι οποίοι επηρεάζουν το ηλεκτρικό φορτίο μπορούν να χωριστούν σε τέσσερις κατηγορίες :

- (α) Οικονομικοί
- (β) Χρονικοί
- (γ) Καιρικοί
- (δ) Τυχαίοι

Για τη δημιουργία ενός μοντέλου που περιγράφει το φορτίο θα πρέπει να γίνει κατανοητή η επίδραση όλων των παραγόντων στη διαμόρφωση της ζήτησης. Ακολουθεί μία σύντομη περιγραφή της επίδρασης των ως

άνω παραγόντων στη διαμόρφωση της ζήτησης της ηλεκτρικής ενέργειας.

(α) Οικονομικοί Παράγοντες

Το οικονομικό περιβάλλον εντός του οποίου λειτουργεί μία ηλεκτρική εταιρεία επιδρά αναμφίβολα στη διαμόρφωση της ηλεκτρικής ζήτησης. Δημογραφικοί παράγοντες, επίπεδα βιομηχανικής δραστηριότητας, ανάπτυξη ή και κορεσμός της αγοράς νέων ηλεκτρικών συσκευών, αλλαγές στον αγροτικό τομέα, κρατικές παρεμβάσεις και γενικά η οικονομική δραστηριότητα, έχουν μεγάλη επίδραση στο ρυθμό αύξησης ή μείωσης του φορτίου του συστήματος. Αλλαγές στην τιμολογιακή πολιτική της επιχείρησης, καθώς και προγράμματα εξοικονόμησης ενέργειας και διαχείρισης της ζήτησης επιδρούν επίσης στη διαμόρφωση της ζήτησης. Τυπικά, οι οικονομικοί παράγοντες έχουν χρονικές σταθερές σημαντικά μεγαλύτερες από μία εβδομάδα και δεν επηρεάζουν βραχυπρόθεσμα τη ζήτηση.



(β) Χρονικοί Παράγοντες

Τρεις βασικοί χρονικοί παράγοντες - εποχιακές μεταβολές, εβδομαδιαίος/ημερήσιος κύκλος και εθνικές και θρησκευτικές εορτές/αργίες - επηρεάζουν σημαντικά το ηλεκτρικό φορτίο. Οι εποχιακές μεταβολές επιδρούν στη μορφή της καμπύλης φορτίου. Στο σχήμα 1.1 δίνεται μία τυπική ημερήσια καμπύλη φορτίου χειμώνα και μία θέρους του εθνικού διασυνδεδεμένου συστήματος. Με απλή εποπτεία, παρατηρούμε τις διαφορές στην ώρα εμφάνισης της βραδινής αιχμής, καθώς και την τρίτη αιχμή που εμφανίζεται το χειμώνα λόγω της θερμοσυσσώρευσης. Ορισμένες μεταβολές στην καμπύλη φόρτισης γίνονται σταδιακά με την αλλαγή διαφόρων εποχιακών μεταβλητών, όπως η θερμοκρασία και οι ώρες ηλιοφάνειας. Άλλες εποχιακές μεταβολές δημιουργούν απότομες αλλαγές στην καμπύλη φόρτισης. Τέτοιες αλλαγές είναι η αλλαγή ώρας (Χειμερινή - Θερινή) (σε αυτήν την περίπτωση παρατηρείται μετατόπιση της καμπύλης φορτίου), η έναρξη της σχολικής χρονιάς, η πιθανή εποχιακή μεταβολή στις χρονικές ζώνες φθηνού τιμολογίου κ.ά.

Η εβδομαδιαία/ημερήσια περιοδικότητα του φορτίου είναι αποτέλεσμα της περιοδικότητας του κύκλου εργασίας - ανάπαυσης του πληθυσμού. Υπάρχουν προκαθορισμένες μορφές καμπυλών φορτίου για μία «τυπική» εβδομάδα κάθε εποχής. Το Σαββατοκύριακο η ζήτηση είναι μειωμένη και το επίπεδο της ζήτησης, καθώς και η μορφή της καμπύλης φορτίου, της Δευτέρας και της Παρασκευής είναι κάπως διαφορετική από τις υπόλοιπες εργάσιμες μέρες λόγω γειτνίασης με το Σαββατοκύριακο. Η

Τρίτη, η Τετάρτη και η Πέμπτη έχουν συνήθως παρόμοιες καμπύλες φορτίου «εργάσιμης μέρας».

Τέλος, η ζήτηση φορτίου κατά τη διάρκεια των εθνικών ή των θρησκευτικών εορτών είναι σημαντικά χαμηλότερη από τα φυσιολογικά επίπεδα. Σημαντική μείωση της ζήτησης παρατηρείται επιπλέον και κατά τη διάρκεια εορταστικών τριημέρων.



Σχήμα 2.1. Τυπικές καμπύλες φορτίου για μία ημέρα του χειμώνα (Τετάρτη 15/11/2000) και μία ημέρα του καλοκαιριού (Τετάρτη 11/7/2000)

(γ) Καιρικοί Παράγοντες

Οι καιρικές συνθήκες προκαλούν σημαντικές αλλαγές στην καμπύλη φορτίου. Αυτό συμβαίνει διότι η λειτουργία ενός μεγάλου ποσοστού ηλεκτρικών συσκευών (θέρμανση, κλιματισμός, αρδεύσεις) εξαρτάται από τις καιρικές συνθήκες.

Σε πολλά συστήματα, η θερμοκρασία έχει τη σημαντικότερη επίδραση στη διαμόρφωση του φορτίου. Για συστήματα τα οποία καλύπτουν μεγάλη γεωγραφική έκταση χρειάζεται να ληφθούν υπόψη οι θερμοκρασίες σε διάφορες περιοχές για να υπολογιστεί η ακριβής επίδραση στο φορτίο. Άλλοι παράγοντες, όπως υγρασία, βροχόπτωση, άνεμος, νεφώσεις, επηρεάζουν επίσης τη ζήτηση.

(δ) Τυχαίοι Παράγοντες

Σε αυτήν την κατηγορία ανήκουν όλοι οι παράγοντες που επηρεάζουν το φορτίο και δεν ανήκουν σε καμία από τις προηγούμενες κατηγορίες. Η λειτουργία του συστήματος δέχεται συνεχώς διαταραχές οι οποίες οφείλονται στο γεγονός ότι η ζήτηση του φορτίου συνίσταται από ένα μεγάλο αριθμό επί μέρους ζητήσεων των καταναλωτών. Εκτός από τους χιλιάδες μικρούς καταναλωτές, υπάρχουν και μεγάλοι καταναλωτές (χαλυβουργεία κ.ά.) που προκαλούν σχετικά μεγάλες τυχαίες διαταραχές στη ζήτηση φορτίου.

Υπάρχουν επίσης ορισμένα άλλα γεγονότα, όπως μεγάλες απεργίες, εκλογές, ειδικά προγράμματα στην τηλεόραση, τα οποία, αν και είναι εκ των προτέρων γνωστά, είναι αρκετά δύσκολο να εκτιμηθεί η επίδρασή τους στη διαμόρφωση της ζήτησης [1].

Ποιοι, όμως, από όλους αυτούς τους προαναφερθέντες παράγοντες λαμβάνονται υπόψη στη μελέτη μας; Ένα μεγάλο κομμάτι της κατανάλωσης οφείλεται σε ιδιώτες και άλλους μικρούς ηλεκτρικούς καταναλωτές. Μία συνήθης προσέγγιση της πρόβλεψης φορτίου είναι να επικεντρωθούμε στο συνολικό φορτίο. Αυτή είναι και η προσέγγιση που θα κάνουμε στη μελέτη μας. Το γεγονός αυτό μειώνει τον αριθμό των παραγόντων που πρέπει να ληφθούν υπόψη. Οι πιο σημαντικοί είναι [7] :

- Βραχυπρόθεσμα, οι μετεωρολογικές συνθήκες προκαλούν μεγάλες αποκλίσεις στο συνολικό φορτίο. Εκτός της θερμοκρασίας, και η ταχύτητα του ανέμου, τα σύννεφα και η υγρασία ασκούν κάποια επιρροή [8,9,10].
- Μακροπρόθεσμα, οικονομικοί και δημογραφικοί παράγοντες παίζουν τον πιο σημαντικό ρόλο στον καθορισμό της εξέλιξης της ηλεκτρικής ζήτησης.

- Από τη σκοπιά της πρόβλεψης, οι χρονικοί παράγοντες είναι βασικοί. Διάφορες περιοδικές επιδράσεις και επαναλαμβανόμενες καταστάσεις καθώς και νόμιμες και θρησκευτικές αργίες λαμβάνονται υπόψη.


Οι άλλοι παράγοντες που προκαλούν διαταραχές και μπορούν να καταταχθούν σαν τυχαίοι παράγοντες είναι συνήθως μικροί στην περίπτωση των ατομικών καταναλωτών. Παρόλ' αυτά μεγάλα κοινωνικά γεγονότα και δημοφιλή τηλεοπτικά προγράμματα προσθέτουν αβεβαιότητα στις προβλέψεις. Από την άλλη βιομηχανικές μονάδες μπορούν να προκαλέσουν σχετικά μεγάλες διαταραχές.

Μόνο βραχυπρόθεσμες προβλέψεις θα πραγματευθούμε σε αυτή τη μελέτη. Επομένως, οι οικονομικοί και δημογραφικοί παράγοντες δεν θα αναφερθούν. Η απόφαση να συνδυάσουμε όλες τις καταναλωτικές μονάδες σε ένα συνολικό φορτίο σημαίνει ότι η πρόβλεψη θα στηριχθεί κυρίως στην προηγούμενη συμπεριφορά του φορτίου. Οι χρονικοί παράγοντες παίζουν τον καθοριστικό ρόλο στην ανάλυση αυτής της μελέτης. Στην επόμενη ενότητα εξετάζεται η συμπεριφορά του φορτίου στην Κρήτη και γίνεται αναφορά σε ορισμένες βασικές ιδιότητες των χρονοσειρών.


2.2 ΙΔΙΟΤΗΤΕΣ ΤΗΣ ΚΑΜΠΥΛΗΣ ΦΟΡΤΙΟΥ

Στη μελέτη αυτή, η προβλεπόμενη καμπύλη φορτίου αποτελείται από ωριαίες τιμές φορτίου που είναι στην πραγματικότητα μέσες ωριαίες. Αυτό σημαίνει ότι μπορούμε να δούμε τη καμπύλη φορτίου σαν μια χρονοσειρά από πραγματικά νούμερα που το καθένα είναι το μέσο ωριαίο φορτίο. Ωστόσο, το νούμερο που παρατηρούμε περιορίζεται σε 24 την ημέρα. Τα μοντέλα που μελετούμε μπορούν να εφαρμοστούν με μικρές μετατροπές σε περιπτώσεις όπου το διάστημα μεταξύ των παρατηρήσεων είναι μικρότερο.

Η ωριαία απαίτηση ηλεκτρικού φορτίου στο απομονωμένο σύστημα της Κρήτης χρησιμοποιείται σε αυτή τη μελέτη στην περίπτωση ελέγχου. Έτσι, για τα έτη 2000 και 2001, απεικονίζονται στα ακόλουθα σχήματα οι ωριαίες τιμές του ηλεκτρικού φορτίου για το διάστημα 1 Ιανουαρίου – 31 Δεκεμβρίου.




Σχήμα 2.2.1



Σχήμα 2.2.2


Στα παραπάνω διαγράμματα φαίνεται καθαρά η τάση της κάθε εποχής. Παρατηρούμε ότι το φορτίο τους καλοκαιρινούς μήνες είναι μεγαλύτερο. Η διακύμανση αυτή του φορτίου οφείλεται στις διαφορετικές περιβαλλοντικές συνθήκες της Κρήτης για κάθε εποχή.

Τις εργάσιμες ημέρες οι κοινωνικές δραστηριότητες είναι περισσότερες απ' ό,τι το Σάββατο και την Κυριακή και γι' αυτό το λόγο το φορτίο είναι επίσης μεγαλύτερο. Στο σχήμα 2.4 φαίνεται το φορτίο δύο διαδοχικών εβδομάδων του Ιουνίου για το έτος 1995. Το διάγραμμα ξεκινάει με πέντε παρόμοιες καμπύλες οι οποίες είναι οι καμπύλες φορτίου από Δευτέρα έως Παρασκευή. Στη συνέχεια παρουσιάζονται δύο διαφορετικές καμπύλες για το Σάββατο και την Κυριακή. Η εβδομαδιαία αυτή καμπύλη επαναλαμβάνεται.




Σχήμα 2.3. Το φορτίο για την περίοδο 1 – 14 Ιουνίου. Η πρώτη μέρα ήταν Πέμπτη.


Η ημερήσια τάση, από την άλλη πλευρά, είναι αποτέλεσμα της συμπεριφοράς των ανθρώπων κατά τη διάρκεια της ημέρας. Οι περισσότεροι άνθρωποι κοιμούνται το βράδυ και γι' αυτό το φορτίο είναι χαμηλό. Επίσης, κατά τη διάρκεια της ημέρας οι περισσότερες δραστηριότητες εμφανίζονται να είναι κοινές για όλους τους ανθρώπους. Η ημερήσια τάση μεταβάλλεται κατά τη διάρκεια του χρόνου. Στα ακόλουθα σχήματα παρουσιάζονται οι καμπύλες φορτίου διαφόρων Τετάρτων για διαφορετικές περιόδους του χρόνου για το έτος 2000.




Σχήμα 2.4.1



Σχήμα 2.4.2



Σχήμα 2.4.3



Σχήμα 2.4.4

Όπως φαίνεται στο σχήμα 2.3, υπάρχουν διαφορές και μεταξύ των ημερών της ίδιας εποχής. Γι' αυτό το λόγο, στην πρόβλεψη φορτίου, οι ημέρες συχνά χωρίζονται σε διαφορετικούς τύπους ημερών. Κάθε ένας απ' αυτούς έχει τις δικές του χαρακτηριστικές μορφές φορτίου. Φαίνεται ξεκάθαρα ότι τα Σαββατοκύριακα έχουν διαφορετικές καμπύλες φορτίου από τις υπόλοιπες ημέρες. Επίσης, συχνά οι Δευτέρες και /ή οι Παρασκευές διαχωρίζονται από τις υπόλοιπες εργάσιμες ημέρες. Αυτό συμβαίνει γιατί είναι πιθανό τα Σαββατοκύριακα να έχουν επίδραση στα φορτία αυτών των ημερών. Ένα άλλο ζήτημα είναι η κατηγοριοποίηση των ειδικών ημερών (για παράδειγμα, αργίες και θρησκευτικές εορτές). Μερικές φορές μπαίνουν στην ίδια κατηγορία με τις Κυριακές [11,12]. Εν τούτοις, διαφορετικές ειδικές ημέρες έχουν διαφορετικά προφίλ φορτίων.

Σε αυτή την εργασία, δεν ακολουθείται η κατηγοριοποίηση των ημερών, αντιμετωπίζοντας τα δεδομένα του μέσου ωριαίου ηλεκτρικού φορτίου που είναι διαθέσιμα ως μια ενιαία χρονοσειρά.

2.3 ΔΥΝΑΤΕΣ ΠΡΟΣΕΓΓΙΣΕΙΣ

2.3.1 ΤΑΞΙΝΟΜΗΣΗ ΤΩΝ ΜΕΘΟΔΩΝ

Το προβλεπόμενο σύστημα φορτίου είναι μια μη στάσιμη διαδικασία που αποτελείται από χιλιάδες ξεχωριστά στοιχεία. Επομένως, το εύρος των πιθανών προσεγγίσεων πρόβλεψης είναι μεγάλο. Συνήθως, η μόνη δυνατότητα είναι να πάρουμε μια μακροσκοπική εικόνα του προβλήματος και να προσπαθήσουμε να μοντελοποιήσουμε το μελλοντικό φορτίο σαν μια επανάληψη προηγούμενων συμπεριφορών. Αυτό αφήνει ανοικτό το πεδίο για πολύ διαφορετικές λύσεις. Εξαιτίας της φύσης του φορτίου, η μόνη αντικειμενική μέθοδος για να αξιολογήσουμε τις προσεγγίσεις είναι μέσω πειραματικών αποδείξεων.

Υπάρχουν πολλοί τρόποι ταξινόμησης των προσεγγίσεων. Μία δυνατότητα είναι να κατηγοριοποιήσουμε τα μοντέλα σε δύο βασικές κατηγορίες : *time – of – day* (μη δυναμικά μοντέλα) και δυναμικά μοντέλα [7]. Στα *time – of – day* μοντέλα το φορτίο εκφράζεται άμεσα ως μια διακριτή χρονοσειρά αποτελούμενη από τις προβλεπόμενες τιμές για κάθε ώρα της προβλεπόμενης περιόδου. Συχνά το φορτίο μοντελοποιείται σαν άθροισμα μιας σταθερής καμπύλης φορτίου (*standard load curve – SLC*) και ενός υπόλοιπου [13]. Τα δυναμικά μοντέλα, από την άλλη πλευρά, αναγνωρίζουν το γεγονός ότι το φορτίο δεν είναι μόνο συνάρτηση του χρόνου της ημέρας, αλλά επιπλέον και της πιο προσφατής συμπεριφοράς του. Σε αυτά τα μοντέλα, η πρόβλεψη είναι επομένως τυπικά επαναλαμβανόμενη. Η πρόβλεψη για μια συγκεκριμένη ώρα απαιτεί προβλέψεις για τις προηγούμενες ώρες.

Άλλες δυνατές ταξινομήσεις των προσεγγίσεων είναι, για παράδειγμα, οι διαχωρισμοί μεταξύ ντετερμινιστικών – στοχαστικών μοντέλων, συνολικού φορτίου – μοντέλα καταναλωτών και αιχμή φορτίου – μοντέλο μορφής φορτίου [2,8].

Τα ντετερμινιστικά μοντέλα παρέχουν μόνο τις προβλεπόμενες τιμές και όχι μέτρηση για το λάθος πρόβλεψης. Τα στοχαστικά μοντέλα, από την άλλη, παρέχουν την πρόβλεψη ως αποτέλεσμα της στοχαστικής διαδικασίας. Αυτές επιτρέπουν υπολογισμούς στις στατιστικές ιδιότητες του προβλεπόμενου λάθους (που φυσικά στηρίζονται στις προϋποθέσεις βάσει των οποίων υλοποιήθηκε το μοντέλο).

Όλες οι εκτιμήσεις της μελέτης επικεντρώνονται στο συνολικό φορτίο. Προσπάθειες έχουν γίνει επίσης προκειμένου να χωριστούν οι καταναλωτές σε κατηγορίες και να γίνει η πρόβλεψη για κάθε κατηγορία χωριστά [14,15,16]. Η πρόβλεψη για το συνολικό φορτίο γίνεται προσθέτοντας τις προβλέψεις όλων των κατηγοριών. Το πρόβλημα είναι η

πολλή δουλειά που χρειάζεται για να πραγματοποιηθούν επαρκή μοντέλα για κάθε κατηγορία.

Ο διαχωρισμός μεταξύ μοντέλων αιχμής φορτίου και μοντέλων μορφής φορτίου είναι αρκετά θεμελιώδης. Τα μοντέλα αιχμής φορτίου προβλέπουν μόνο το ημερήσιο μέγιστο φορτίο και τα μοντέλα μορφής φορτίου προβλέπουν τιμές φορτίου για όλες τις ώρες (ή μισάωρα). Αυτή η μελέτη επικεντρώνεται στα μοντέλα μορφής φορτίου.

2.3.2 ΜΕΡΙΚΕΣ ΑΠΟ ΤΙΣ ΠΙΟ ΔΗΜΟΦΙΛΕΙΣ ΜΕΘΟΔΟΥΣ

MONTELA Time – of – day

Στην απλούστερη μορφή, το μοντέλο Time – of – day παίρνει το πραγματικό πρότυπο φορτίου της προηγούμενης βδομάδας σαν ένα μοντέλο για να προβλέψει το φορτίο της παρούσας εβδομάδας. Εναλλακτικά, ένας αριθμός από πρότυπα φορτίου αποθηκεύεται για τυπικές εβδομάδες με διαφορετικές καιρικές συνθήκες. Έπειτα, αυτές συνδυάζονται για να δημιουργηθεί πρόβλεψη.

Συνήθως, ένα μοντέλο Time – of – day είναι της μορφής [7] :

$$z(t) = \sum_{i=1}^N a_i f(t)_i + v(t) \quad (2.1)$$

Το φορτίο στο χρόνο t εκφράζεται σαν ένα σταθμικό άθροισμα αναλυτικών συναρτήσεων χρόνου συνήθως ημιτονοειδών με περίοδο από 24 ή 168. Οι συντελεστές a_i είναι βραδέως μεταβαλλόμενες σταθερές, οι οποίες συνήθως υπολογίζονται μέσω μιας γραμμικής απόκλισης ή μίας ομαλής εκθετικής συνάρτησης. Η διαμόρφωση λάθους $v(t)$ θεωρείται ότι είναι λευκός θόρυβος.

Η φασματική αποσύνθεση (**spectral decomposition**) είναι ένα άλλο μοντέλο Time – of – day. Αυτό το μοντέλο έχει βασικά την ίδια μορφή με την εξίσωση (2.1), αλλά οι συναρτήσεις χρόνου $f_i(t)$ αντιπροσωπεύουν τις χαρακτηριστικές συναρτήσεις που αντιστοιχούν στη συνάρτηση αυτοσυσχέτισης της χρονοσειράς του φορτίου. Αυτού του είδους οι συναρτήσεις μπορούν αρχικά να αναπαραστήσουν τα τυχαία φορτία με

μεγαλύτερη ακρίβεια από ότι οι αυθαίρετα επιλεγμένες συναρτήσεις χρόνου.

Τα μοντέλα time – of – day έχουν προταθεί, για παράδειγμα, από τον Sharma (1974) και Thompson (1976). Ένα παράδειγμα της εφαρμοσμένης φασματικής αποσύνθεσης μπορεί να βρεθεί στον Laing (1985).

ΜΟΝΤΕΛΑ ΑΠΟΚΛΙΣΗΣ ΕΞΑΡΤΗΜΕΝΗΣ ΣΤΑΤΙΣΤΙΚΗΣ ΜΕΤΑΒΛΗΤΗΣ

Τα μοντέλα αυτά συνήθως θεωρούν ότι το φορτίο μπορεί να διαιρεθεί σε ένα πρότυπο στοιχείο φορτίου και σε ένα στοιχείο γραμμικά εξαρτημένο από κάποιες επεξηγηματικές μεταβλητές. Αυτό το μοντέλο μπορεί να γραφεί :

$$z(t) = b(t) + \sum_{i=1}^n a_i y_i(t) + \varepsilon(t) \quad (2.2)$$

Το $b(t)$ είναι το πρότυπο φορτίο, $\varepsilon(t)$ είναι ένα στοιχείο λευκού θορύβου και $y_i(t)$ οι ανεξάρτητες επεξηγηματικές μεταβλητές. Οι πιο τυπικές επεξηγηματικές μεταβλητές είναι οι καιρικοί παράγοντες.

Ένα τυπικό μοντέλο απόκλισης έχει χρησιμοποιηθεί από τους Rasanen and Ruusunen (1992). Αυτοί μοντελοποίησαν διαφορετικές κατηγορίες καταναλωτών διαχωρίζοντας τα μοντέλα απόκλισης. Το φορτίο διαχωρίζεται σε ένα στοιχείο ρυθμού και σε ένα στοιχείο που εξαρτάται από τη θερμοκρασία. Το στοιχείο ρυθμού αντιστοιχεί στο στοιχείο μίας συγκεκριμένης ώρας στη μέση θερμοκρασία της περιόδου μας.

Έχουν επίσης προταθεί παραλλαγές πιο πολύπλοκων μοντέλων. Μερικά μοντέλα χρησιμοποιούν προγενέστερες τιμές φορτίου σαν επεξηγηματικές μεταβλητές επιπρόσθετα στις εξωτερικές μεταβλητές [17].

Τα μοντέλα απόκλισης είναι από τις παλαιότερες μεθόδους που έχουν προταθεί για την πρόβλεψη φορτίου. Δεν είναι τόσο ευαίσθητες σε περιστασιακές διαταραχές στις μετρήσεις. Η εύκολη εφαρμογή τους είναι ένα άλλο πλεονέκτημα. Η σειριακή συσχέτιση, η οποία είναι συνήθης όταν χρησιμοποιούνται μοντέλα απόκλισης, μπορεί να προκαλέσει προβλήματα.

ΜΟΝΤΕΛΑ ΣΤΟΧΑΣΤΙΚΩΝ ΧΡΟΝΟΣΕΙΡΩΝ

Αυτή είναι μια πολύ διαδεδομένη κατηγορία μοντέλων δυναμικών προβλέψεων [2,18,19]. Υπάρχουν πολλά καταμετρημένα ονόματα στη σχετική βιβλιογραφία για την κατηγορία αυτή, όπως για παράδειγμα τα μοντέλα ARMA (autoregressive-moving average), μοντέλα ARIMA (integrated autoregressive-moving average), μεθόδους Box-Jenkins, μοντέλα γραμμικών χρονοσειρών κ.ά. Μία γενική θεώρηση των μοντέλων αυτών μπορεί να βρεθεί π.χ. στους Pindyck and Rubinfeld (1991).

Η βασική αρχή είναι ότι η χρονοσειρά του φορτίου πρέπει πρώτα να μετατραπεί σε μια σε μια σταθερή χρονοσειρά με την κατάλληλη διαφοροποίηση. Έπειτα, η εναπομένονσα στατική σειρά μπορεί να φιλτραριστεί μέσα σε λευκό θόρυβο. Τα μοντέλα προϋποθέτουν ότι οι ιδιότητες των χρονοσειρών παραμένουν αναλλοίωτες για την περίοδο που χρησιμοποιείται στο μοντέλο εκτίμησης και όλες οι διαταραχές οφείλονται στο στοιχείο του λευκού θορύβου που περιέχεται στη διαδικασία.

Το βασικό μοντέλο ARIMA γράφεται ως εξής :

$$\phi(B)\nabla^d z(t) = \theta(B)a(t) \quad (2.3)$$

όπου

$z(t)$, $t = 1, \dots, N$ είναι η μοντελοποιημένη χρονοσειρά

$a(t)$, $t = 1, \dots, N$ είναι η ακολουθία λευκού θορύβου

$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$, είναι η AR πολυωνυμική παράμετρος

$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$, είναι η MA πολυωνυμική παράμετρος

B είναι ο “backward shift operator” ($B^n(z(t)) = z(t-n)$)

ϕ_i, θ_i είναι σταθεροί παράμετροι

$\nabla = 1 - B$ είναι ο “backward difference operator”

Το βασικό μοντέλο ARIMA δεν είναι από μόνο του κατάλληλο για να περιγράψει τις χρονοσειρές φορτίου, καθώς οι σειρές φορτίου περιλαμβάνουν εποχιακές διακυμάνσεις. Επομένως, απαιτούνται διαφοροποιήσεις μέσα στην περίοδο των εποχικών διακυμάνσεων (συνήθως 24 και 168). Το μοντέλο που αποκτούμε τότε ονομάζεται εποχιακό ARIMA (SARIMA) και μπορεί να γραφεί [13] :

$$\phi(B)\phi_s(B^S)\nabla^d\nabla_s^D z(t) = \theta(B)\theta_s(B^S)a(t) \quad (2.4)$$

όπου

$$\nabla_S^D = (1 - B^S)^D \quad \text{και}$$

S είναι η περίοδος της εποχιακής μεταβολής

Μία εξωτερική μεταβλητή εισόδου, όπως η θερμοκρασία στην περίπτωση των χρονοσειρών φορτίου, μπορεί να συμπεριληφθεί σε αυτό το μοντέλο. Αυτή η παραλλαγή του μοντέλου ARIMA ονομάζεται ARIMAX μοντέλο και μπορεί γενικά να γραφεί :

$$\phi(B)\nabla^d z(t) = w(B)x(t-b) + \theta(B)a(t) \quad (2.5)$$

όπου $x(t)$ είναι η εξωτερική μεταβλητή στο χρόνο t

$$w(B) = w_0 + w_1 B + w_2 B^2 + w_3 B^3 + \dots$$

Το μοντέλο ARIMA περιλαμβάνει και τα δύο, οι εποχιακές διακυμάνσεις και η εξωτερική μεταβλητή ονομάζεται συχνά μοντέλο SARIMAX.

Τα μοντέλα στοχαστικών χρονοσειρών έχουν πολλά ελκυστικά χαρακτηριστικά. Πρώτον, η θεωρία των μοντέλων αυτών είναι αρκετά γνωστή και έπειτα είναι εύκολο να καταλάβουμε πως υλοποιείται η πρόβλεψη. Τα χαρακτηριστικά του μοντέλου είναι εύκολο να υπολογιστούν. Ο υπολογισμός της διαφοράς του λευκού θορύβου επιτρέπει να δημιουργηθεί ένα αίσθημα εμπιστοσύνης για τις προβλέψεις. Η αναγνώριση του μοντέλου είναι σχετικά εύκολη. Επίσης, είναι εφικτή η καθιέρωση των μεθόδων για διαγνωστικούς ελέγχους. Εξ' άλλου, η εκτίμηση των παραμέτρων του μοντέλου είναι σαφής και η πραγματοποίηση δεν είναι δύσκολη.

Μία αδυναμία των στοχαστικών μοντέλων είναι η προσαρμοστικότητα. Στην πραγματικότητα, η συμπεριφορά του φορτίου μπορεί να αλλάξει γρήγορα σε συγκεκριμένα τμήματα του χρόνου. Ενώ στο μοντέλο ARIMA η πρόβλεψη για μια συγκεκριμένη ώρα είναι αρχικά συνάρτηση όλων των προγενέστερων τιμών φορτίων, το μοντέλο δεν μπορεί να προσαρμοστεί στις νέες συνθήκες πολύ γρήγορα, ακόμη και αν οι παράμετροι του μοντέλου υπολογίζονται επαναληπτικά. Ένας παράγοντας ενθύμησης μπορεί να χρησιμοποιηθεί για να δώσει περισσότερο βάρος στη πιο πρόσφατη συμπεριφορά κι έτσι να βελτιώσει την προσαρμοστικότητα του μοντέλου.

Ένα άλλο πρόβλημα είναι ο χειρισμός ανώμαλων συνθηκών φορτίου. Εάν η συμπεριφορά του φορτίου είναι αφύσικη σε μια συγκεκριμένη ημέρα, αυτή η απόκλιση από τις κανονικές συνθήκες θα ανακλαστεί στις μελλοντικές προβλέψεις. Μια δυνατή λύση στο πρόβλημα αυτό είναι να αντικαταστήσουμε τις αφύσικες τιμές φορτίου στο ιστορικό των φορτίων με τις αντίστοιχες τιμές πρόβλεψης.

ΜΟΝΤΕΛΑ ΧΩΡΩΝ ΚΑΤΑΣΤΑΣΗΣ

Στα γραμμικά μοντέλα χώρων κατάστασης, το φορτίο στο χρόνο t μπορεί να γραφεί :

$$z(t) = c^T x(t) \quad (2.6)$$

όπου

$$x(t+1) = Ax(t) + Bu(t) + w(t) \quad (2.7)$$

Το διάνυσμα κατάστασης στο χρόνο t είναι $x(t)$. Η $u(t)$ είναι ένα διάνυσμα εισόδου βασισμένο στη μεταβλητή καιρού και η $w(t)$ ένα διάνυσμα τυχαίων εισόδων λευκού θορύβου. Οι πίνακες A , B και το διάνυσμα c είναι σταθερές που λαμβάνονται.

Υπάρχει ένας αριθμός παραλλαγών του μοντέλου. Κάποια παραδείγματα μπορούν να βρεθούν στα [20,21,22].

Στην πραγματικότητα, το βασικό μοντέλο χώρου κατάστασης μπορεί να μετατραπεί σε μοντέλο ARIMA και αντιστρόφως, και έτσι δεν υπάρχει θεμελιώδης διαφορά ανάμεσα στις ιδιότητες των δύο τύπων μοντέλων. Σύμφωνα με τους Gross και Galiana (1987), ένα πιθανό πλεονέκτημα απέναντι στα μοντέλα ARIMA είναι η δυνατότητα να χρησιμοποιεί προκαταβολικά πληροφορίες στην εκτίμηση παραμέτρων μέσω τεχνικών Bayesian.

ΕΞΕΙΔΙΚΕΥΜΕΝΑ ΣΥΣΤΗΜΑΤΑ

Τα εξειδικευμένα συστήματα είναι μοντέλα που αναφέρονται σε μεθόδους αυτοδιδασχής και είναι συνήθως ικανά να λάβουν υπόψη τόσο ποιοτικούς όσο και ποσοτικούς παράγοντες. Πολλά μοντέλα αυτού του τύπου έχουν προταθεί από τα μέσα της δεκαετίας του 1980. Μία συνηθισμένη προσέγγιση είναι να προσπαθήσουμε να «αντιγράψουμε»

τη λογική ενός ανθρώπινου χειριστή. Η ιδέα είναι να μειώσουμε την αναλογική σκέψη πίσω από τη διαισθητική προβλεψιμότητα σε τυπικά βήματα λογικής [23,24].

Μία δυνατή μέθοδος για να δημιουργήσει ένας ειδικός μία πρόβλεψη, είναι να ερευνήσει τη βάση δεδομένων για μια ημέρα που αντιστοιχεί στην ημέρα που μας ενδιαφέρει σχετικά με τον τύπο ημέρας, τους κοινωνικούς και καιρικούς παράγοντες. Έπειτα, τιμές φορτίου της ίδιας ημέρας λαμβάνονται σαν βάση για την πρόβλεψη. Ένα εξειδικευμένο μοντέλο μπορεί έτσι να γίνει μια αυτοματοποιημένη εκδοχή αυτού του είδους διαδικασίας εύρεσης [25].

Από την άλλη πλευρά, το εξειδικευμένο σύστημα μπορεί να αποτελεί μία πρότυπη βάση καθοριστικών σχέσεων ανάμεσα σε εξωτερικούς παράγοντες και ημερήσιες μορφές φορτίου. Μία διαδεδομένη προσέγγιση είναι να αναπτυχθούν πρότυπα στη βάση ασαφούς λογικής (fuzzy logic) [26,27,28]. Τα ασαφή συστήματα που αναπτύσσονται κατά αυτόν τον τρόπο έχουν ως στόχο την μετατροπή μιας ακριβούς πληροφορίας σε συμβολική πληροφορία, χρησιμοποιώντας γλωσσολογικά σύνολα (linguistic sets), σε μια διαδικασία που ονομάζεται ασαφοποίηση. Η ασαφοποίηση «συλλαμβάνει» την απροσδιοριστία που είναι επικρατούσα σε όλες τις ανθρώπινες διαδικασίες λήψης αποφάσεων. Τα ασαφή σύνολα προσδιορίζονται με όρους όπως «χαμηλό», «κανονικό», «υψηλό» προσομοιώνοντας έτσι τον ανθρώπινο τρόπο σκέψης, που λειτουργεί περισσότερο με σύμβολα παρά με ακριβείς τιμές. Έτσι απαιτείται σε μικρότερο βαθμό εξειδικευμένη γνώση (expert knowledge) επάνω στο αντικείμενο της εκάστοτε διαδικασίας που η ασαφής λογική χρησιμοποιείται. [29]

Η προσέγγιση, σχετικά με μεθόδους αυτοδιδασχίας προς εντοπισμό λύσεων, κάνει τα εξειδικευμένα συστήματα ελκυστικά για τους χειριστές συστημάτων. Το σύστημα μπορεί να παρέχει στο χρήστη τη γραμμή της λογικής ακολουθούμενη από το μοντέλο [30].

ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Τα τελευταία χρόνια έχει αναπτυχθεί ένα πολύ μεγάλο ενδιαφέρον σχετικά με την εφαρμογή της τεχνητής νοημοσύνης στη διαδικασία της βιομηχανίας. Κύριο πλεονέκτημα τους αποτελεί το γεγονός ότι δεν απαιτείται περίπλοκη μαθηματική σχηματοποίηση ή ποσοτική συσχέτιση μεταξύ των εισόδων και εξόδων ενός συστήματος. Επίσης, δεν είναι απαραίτητα τα δεδομένα πολλών ετών. Έτσι, η ικανοποιητική απόδοση της τεχνητής νοημοσύνης έχει οδηγήσει σε επιτυχείς εφαρμογές σχετικά

με την βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Σαν αποτέλεσμα, η αναγνώριση προτύπων [32], τα συστήματα εξπέρ (expert systems) [33,34] και τα νευρωνικά δίκτυα (neural networks) [35-42], έχουν προταθεί για την πρόβλεψη του ηλεκτρικού φορτίου. Πιο δημοφιλή όλων, είναι αναμφίβολα τα τεχνητά νευρωνικά δίκτυα (artificial neural network-ANN). Τα νευρωνικά δίκτυα αναφέρονται σε μία κατηγορία μοντέλων τα οποία είναι εμπνευσμένα από τα βιολογικά νευρικά συστήματα. Τα μοντέλα αποτελούνται από πολλά προγραμματιζόμενα στοιχεία που συνήθως ονομάζονται νευρώνες και λειτουργούν παράλληλα. Τα στοιχεία συνδέονται με συνδετικά βάρη, κάτι το οποίο τους επιτρέπει να προσαρμόζονται μέσω μιας διαδικασίας εκμάθησης. Τα νευρωνικά δίκτυα μπορούν να ερμηνευθούν ως προσαρμόσιμες μηχανές που μπορούν να αποθηκεύσουν γνώση μέσω της διαδικασίας εκμάθησης. Η έρευνα πάνω στο πεδίο αυτό έχει μια ιστορία αρκετών δεκαετιών, αλλά, μετά από μία μείωση του ενδιαφέροντος στη δεκαετία του 1970, μία μαζική ανάπτυξη ξεκίνησε στις αρχές του 1980.

Το κυρίαρχο τους πλεονέκτημα σε σχέση με τα στατιστικά μοντέλα έχει να κάνει με το γεγονός ότι μοντελοποιούν ένα πολυδιάστατο πρόβλημα χωρίς να απαιτούν περίπλοκες υποθέσεις ανάμεσα στις μεταβλητές εισόδου [35,37,39,41,42].

Υπάρχουν πολλών τύπων μοντέλα νευρωνικών δικτύων. Το κοινό χαρακτηριστικό σε αυτά είναι η σχέση με την γενικότερη ιδέα των βιολογικών συστημάτων. Τα μοντέλα μπορούν να κατηγοριοποιηθούν με πολλούς τρόπους. Μία δυνατότητα είναι να ταξινομηθούν με βάση την αρχή εκμάθησης. Ένα νευρωνικό δίκτυο χρησιμοποιεί επιτηρούμενη ή μη επιτηρούμενη εκμάθηση. Στην επιτηρούμενη εκμάθηση το δίκτυο τροφοδοτείται με πρότυπες καταστάσεις και επιθυμητά αποτελέσματα. Τα βάρη του δικτύου έπειτα προσαρμόζονται με σκοπό να μειωθεί η διαφορά μεταξύ των εξόδων του δικτύου και των επιθυμητών εξόδων. Στη μη επιτηρούμενη εκμάθηση, στο δίκτυο δίνονται μόνο σήματα εισόδου και τα βάρη του δικτύου αλλάζουν μέσω ενός προκαθορισμένου μηχανισμού, ο οποίος συνήθως συγκεντρώνει τις πληροφορίες σε συστοιχίες παραπλήσιων πληροφοριών.

Ο πιο συνηθισμένος τύπος νευρωνικού δικτύου που χρησιμοποιεί επιτηρούμενη εκμάθηση είναι ένα δίκτυο εμπρός προγραμματισμού (feed-forward). Στο δίκτυο δίνεται ένα σήμα εισόδου, το οποίο μεταφέρεται εμπρός διαμέσου του δικτύου. Τελικά, παράγεται ένα σήμα εξόδου. Το δίκτυο μπορεί να παρασταθεί σαν μια χαρτογράφηση μεταξύ της εισόδου και της εξόδου και αυτή η χαρτογράφηση καθορίζεται από τις ελεύθερες παραμέτρους του μοντέλου, που είναι τα συνδετικά βάρη που συνδέουν τους νευρώνες. Ένα αρκετά δημοφιλές μοντέλο αποτελεί το perceptron πολλαπλών στρωμάτων (Multilayer perceptron ή MLP). Η ελκυστικότητα των MLP ερμηνεύεται από την ικανότητα των δικτύων να

μαθαίνουν πολύπλοκες σχέσεις μεταξύ πρότυπων εισόδου και εξόδου, οι οποίες είναι δύσκολο να μοντελοποιηθούν με συμβατικές αλγοριθμικές μεθόδους. Στα μοντέλα, οι είσοδοι του δικτύου είναι συνήθως τωρινές και παλαιότερες τιμές φορτίου και οι έξοδοι είναι μελλοντικές τιμές φορτίου. Το δίκτυο εκπαιδεύεται χρησιμοποιώντας πραγματικά δεδομένα φορτίου από το παρελθόν. Βεβαίως ανάλογα με τη δομή και τον τρόπο εκπαίδευσης τους διακρίνουμε και διάφορα άλλα δίκτυα όπως η Gaussian κωδικοποίηση (Gaussian encoding), τα επαναληπτικά δίκτυα πραγματικού χρόνου (real-time recurrent networks) κ.α.

ΚΕΦΑΛΑΙΟ 3

ΒΡΑΧΥΠΡΟΘΕΣΜΗ ΠΡΟΒΛΕΨΗ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ ΜΕ ΒΑΣΗ ΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 ΕΙΣΑΓΩΓΗ

Στην ενότητα αυτή γίνεται λόγος στις μεθόδους πρόβλεψης του ηλεκτρικού φορτίου, όπως αυτές παρουσιάζονται μέσα από την μελέτη των Κ.Καλαϊτζάκη, Γ.Σταυρακάκη και Ε.Αναγνωστάκη, με τίτλο “Short-term load forecasting based on artificial neural networks parallel implementation”[43]. Ο γενικός σκοπός της βραχυπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου είναι η πρόβλεψη n μέσων ωριαίων τιμών φορτίου προς τα εμπρός, όπου $n \leq 24$. Η προαναφερθείσα μελέτη βασίζεται στην εκπαίδευση, σε κάθε περίπτωση, n διακριτών νευρωνικών δικτύων μιας εξόδου, με στόχο την πρόβλεψη n μέσων ωριαίων τιμών φορτίου. Κάθε νευρωνικό δίκτυο, τροφοδοτείται από το προηγούμενο του, επιτυγχάνοντας έτσι την βήμα με βήμα πρόβλεψη. Με βάση αυτήν τη λογική, το φορτίο για την κάθε ώρα προβλέπεται χρησιμοποιώντας όχι μονάχα την χρονοσειρά του φορτίου της συγκεκριμένης ώρας από τις προηγούμενες ημέρες, αλλά επιπρόσθετα χρησιμοποιώντας και τις προβλεπόμενες τιμές για το φορτίο από προηγούμενα χρονικά διαστήματα της ίδιας ημέρας. Έτσι, με αυτόν τον τρόπο τα αποτελέσματα προκύπτουν καλύτερα από την περίπτωση εκείνη που χρησιμοποιούνταν ένα νευρωνικό δίκτυο 24 εξόδων (προκειμένου για την πρόβλεψη του φορτίου μιας ημέρας). Η συγκεκριμένη μελέτη επιλέγει τον υπολογισμό τιμών για τις χρονοσειρές εκείνες που αφορούν τις ώρες 02:00 και 14:00, με χρονικό ορίζοντα τις 120 ημέρες, χρησιμοποιώντας δεδομένα φορτίου για την εκπαίδευση και δοκιμή των διαφόρων δικτύων από τα έτη 1994 και 1995 του απομονωμένου συστήματος της Κρήτης.

Τονίζεται ότι σε καμία περίπτωση δεν χρησιμοποιήθηκαν μεταβλητές καιρού (θερμοκρασία, υγρασία κ.α.), αλλά μονάχα δεδομένα φορτίου.

3.2 Εκπαίδευση νευρωνικών δικτύων

Το δίκτυο MLP είναι ο πιο δημοφιλής τύπος νευρωνικού δικτύου και τα πιο ευρέως αναφερόμενα μοντέλα νευρωνικών δικτύων βραχυπρόθεσμης πρόβλεψης φορτίου βασίζονται σε αυτά. Η βασική μονάδα (νευρώνιο) του δικτύου είναι ένα perceptron. Αυτή είναι μία υπολογιστι-

κή μονάδα που παράγει την έξοδό της παίρνοντας ένα γραμμικό συνδυασμό των σημάτων εισόδου και μετατρέποντας αυτό από μία συνάρτηση που ονομάζεται συνάρτηση ενεργοποίησης. Η έξοδος του perceptron ως συνάρτηση των σημάτων εισόδων μπορεί να γραφεί κι έτσι :

$$y = \sigma(\sum_i^n w_i x_i - \theta) \quad (3.1)$$

όπου,

y είναι η έξοδος

x_i είναι τα σήματα εισόδου


w_i είναι τα νευρωνικά βάρη

θ είναι ο όρος πόλωσης

σ είναι η συνάρτηση ενεργοποίησης

Πιθανές μορφές της συνάρτησης ενεργοποίησης είναι η γραμμική συνάρτηση, η βηματική συνάρτηση, η λογιστική συνάρτηση και η εφαιπτομενική υπερβολική συνάρτηση.

Το δίκτυο MLP αποτελείται από αρκετά στρώματα νευρωνίων. Κάθε νευρώνιο σε ένα συγκεκριμένο στρώμα συνδέεται με κάθε νευρώνιο του επόμενου στρώματος. Δεν υπάρχουν συνδέσεις ανάδρασης. Ένα MLP δίκτυο τριών στρωμάτων παρουσιάζεται στο σχήμα 3.1.



Σχήμα 3.1. Ένα MLP δίκτυο τριών στρωμάτων

Όταν ένα n -διάστατο διάνυσμα εισόδου τροφοδοτεί το δίκτυο, ένα m -διάστατο διάνυσμα εξόδου παράγεται. Το δίκτυο μπορεί να ερμηνευθεί σαν μια συνάρτηση από το n -διάστατο χώρο εισόδου στο m -διάστατο χώρο εξόδου. Αυτή η συνάρτηση μπορεί να γραφεί με τη μορφή :

$$y = f(x; W) = \sigma(W_n \sigma(W_{n-1} \sigma(\dots \sigma(W_1 x) \dots))) \quad (3.2)$$

όπου,

y είναι το διάνυσμα εξόδου

x είναι το διάνυσμα εισόδου

W_i είναι ένας πίνακας που περιέχει τα νευρώνια βάρους του i-
στου κρυφού στρώματος · τα νευρώνια βάρους θεωρούνται ελεύθεροι
παράμετροι

Το δίκτυο MLP που χρησιμοποιείται συνήθως αποτελείται από 3 στρώματα, ένα στρώμα εισόδου, ένα κρυφό στρώμα κι ένα στρώμα εξόδου. Η συνάρτηση ενεργοποίησης που χρησιμοποιείται στο κρυφό στρώμα είναι συνήθως μη γραμμική (σιγμοειδής ή υπερβολική εφαπτομενική) και η συνάρτηση ενεργοποίησης στο στρώμα εξόδου μπορεί επίσης να είναι είτε μη γραμμική είτε γραμμική.

Τα βάρη του δικτύου ρυθμίζονται από την εκπαίδευση του δικτύου. Ο σκοπός είναι να δίνουμε στο δίκτυο σήματα εισόδου και επιθυμητές εξόδους. Για κάθε σήμα εισόδου, το δίκτυο παράγει ένα σήμα εξόδου και η εκμάθηση στοχεύει στην ελάττωση του αθροίσματος των τετραγωνικών διαφορών μεταξύ των επιθυμητών και των πραγματικών εξόδων. Από εδώ και στο εξής θα ονομάζουμε τη συνάρτηση αυτή άθροισμα των τετραγωνικών λαθών. Η εκμάθηση πραγματοποιείται με επαναλαμβανόμενη τροφοδότηση των πρότυπων εισόδων - εξόδων στο δίκτυο. Μία ολοκληρωμένη παρουσίαση όλης της εκπαίδευσης ονομάζεται εποχή. Η διαδικασία εκμάθησης συνήθως πραγματοποιείται εποχή με εποχή μέχρι τα βάρη να σταθεροποιηθούν και το άθροισμα των τετραγωνικών λαθών να συγκλίνει σε κάποια ελάχιστη τιμή.

Ο πιο συχνά χρησιμοποιούμενος αλγόριθμος εκμάθησης για τα δίκτυα MLP είναι ο αλγόριθμος back-propagation. Αυτή είναι μία ειδική τεχνική για την υλοποίηση της μεθόδου κεκλιμένης καθόδου στο χώρο των βαρών, όπου η κλίση του αθροίσματος των τετραγωνικών λαθών σε σχέση με τα βάρη προσεγγίζεται με ακρίβεια με την «αναπαραγωγή» προς τα πίσω των σημάτων του λάθους στο δίκτυο. Ένας ακόμη καλύτερος αλγόριθμος δημιουργείται χρησιμοποιώντας μια προσέγγιση της μεθόδου του Newton που ονομάζεται Levenberg-Marquardt [50]. Για να εφαρμόσουμε τον αλγόριθμο στην εκπαίδευση του δικτύου, οι παράγωγοι κάθε αθροίσματος τετραγωνικών λαθών σε κάθε δικτυακό βάρος προσεγγίζονται και συλλέγονται σε ένα πίνακα. Αυτός ο πίνακας αναπαριστά τον Ιακωβιανό της ελαχιστοποιημένης συνάρτησης. Η Levenberg-Marquardt προσέγγιση χρησιμοποιείται σε αυτή τη μελέτη για να εκπαιδεύσουμε τα δίκτυα MLP.

Στην ουσία, η εκμάθηση του δικτύου δεν είναι τίποτα άλλο από τον υπολογισμό των παραμέτρων του μοντέλου. Στην περίπτωση ενός μοντέλου MLP η εξάρτηση των παραμέτρων του μοντέλου από την έξοδο είναι πολύ πολύπλοκη σε αντίθεση με τα πολύ κοινά μαθηματικά μοντέλα, π.χ. μοντέλα απόκλισης εξαρτημένης στατιστικής μεταβλητής. Αυτός είναι ο λόγος για τον οποίο η επαναληπτική εκμάθηση απαιτείται στην εκπαίδευση με σκοπό να βρεθούν κατάλληλες τιμές παραμέτρων. Δεν υπάρχει τρόπος να σιγουρευτούμε ότι έχουμε βρει το ολικό ελάχιστο του αθροίσματος του τετραγωνικού λάθους. Από την άλλη, η πολύπλοκη μη γραμμική φύση της εξάρτησης εισόδου - εξόδου δίνει τη δυνατότητα σε ένα απλό δίκτυο να προσαρμοσθεί σε μία πολύ μεγαλύτερη κλίμακα διαφορετικών σχέσεων από ό,τι για παράδειγμα τα μοντέλα απόκλισης. Αυτός είναι ο λόγος για τον οποίο ο όρος εκμάθηση χρησιμοποιείται σχετικά με μοντέλα νευρωνικών δικτύων αυτού του είδους.

Ανάλογες διαδικασίες – τεχνικές χρησιμοποιούνται και για την εκπαίδευση των υπολοίπων νευρωνικών δικτύων, με την λογική όσον αφορά τη διαδικασία της εκπαίδευσης να παραμένει σε γενικές γραμμές η ίδια.

3. 3 Γενίκευση

Η εκπαίδευση στοχεύει στην ελαχιστοποίηση των λαθών των εξόδων του δικτύου σχετικά με τα πρότυπα εισόδου - εξόδου του σετ εκπαίδευσης. Η επιτυχία σε αυτό δεν αποδεικνύει τίποτα σχετικά με την απόδοση του δικτύου μετά την εκπαίδευση. Πιο σημαντική είναι η επιτυχία στη γενίκευση. Ένα δίκτυο λέγεται ότι γενικεύεται καλά όταν μία έξοδος είναι σωστή για μία είσοδο η οποία δεν είχε περιληφθεί στο σετ εκπαίδευσης.

Ένα τυπικό πρόβλημα με τα μοντέλα δικτύων είναι η υπερεκπαίδευση που στη σχετική βιβλιογραφία των δικτύων αναφέρεται και ως αποστήθιση. Αυτό σημαίνει ότι το δίκτυο μαθαίνει τα πρότυπα εισόδου-εξόδου του σετ εκπαίδευσης, αλλά την ίδια στιγμή, χωρίς να είναι επιθυμητό κάποιες σχέσεις αποθηκεύονται στα συνδεδετικά βάρη. Επομένως, ακόμη κι αν το δίκτυο παρέχει σωστές εξόδους για τα πρότυπα εισόδων του σετ εκπαίδευσης, η αντίδραση μπορεί να είναι απρόβλεπτη για ελάχιστα διαφορετικά δεδομένα εισόδων.

Η γενίκευση επηρεάζεται από τρεις παράγοντες : το μέγεθος και την αποτελεσματικότητα του σετ εκπαίδευσης, τη δομή του μοντέλου (αρχιτεκτονική δικτύου) και τη φυσική πολυπλοκότητα του προβλήματος [49]. Οι τελευταίοι από αυτούς δεν μπορούν να ελεγχθούν και έτσι τα μέσα για να αποφύγουμε την υπερεκπαίδευση περιορίζονται στον έλεγχο των δύο πρώτων παραγόντων.

Όσο μεγαλύτερο είναι το σετ εκπαίδευσης, τόσο πιο απίθανη είναι η υπερεκπαίδευση. Όπως και να έχει, το σετ εκπαίδευσης πρέπει να περιλαμβάνει μόνο πρότυπα εισόδων-εξόδων που να αντανakλούν σωστά την πραγματική διαδικασία μοντελοποίησης. Άρα, όλα τα λανθασμένα και άσχετα δεδομένα πρέπει να αποκλείονται.

Όσον αφορά την επίδραση της δομής των μοντέλων στη γενίκευση μπορούμε να πούμε ότι : Από τη μία, η επιλογή των μεταβλητών εισόδου είναι πολύ σημαντική. Η περιοχή εισόδου πρέπει να μειωθεί σε ένα λογικό μέγεθος σε σχέση με το μέγεθος του σετ εκπαίδευσης. Αν η διάσταση της περιοχής εισόδου είναι μεγάλη, τότε το σετ των παρατηρήσεων μπορεί να είναι πολύ αραιό για μία κατάλληλη γενίκευση. Επομένως, καμία μη απαραίτητη μεταβλητή εισόδου δεν πρέπει να περιλαμβάνεται, επειδή το δίκτυο μπορεί να μάθει να εξαρτάται από αυτές, ενώ στην πραγματικότητα δεν υπάρχουν στην πραγματική διαδικασία. Από την άλλη, όλοι οι παράγοντες οι οποίοι έχουν μία ξεκάθαρη επιρροή στην έξοδο πρέπει να περιλαμβάνονται.

Όσο μεγαλύτερος είναι ο αριθμός των ελεύθερων παραμέτρων του μοντέλου, τόσο πιο πιθανή είναι η υπερεκπαίδευση. Τότε μιλάμε για «υπερπαραμετροποίηση». Κάθε κρυμμένο στρώμα νευρωνίων έχει ένα συγκεκριμένο αριθμό ελεύθερων παραμέτρων και για αυτό, προκειμένου να αποφύγουμε την υπερπαραμετροποίηση, ο αριθμός των κρυμμένων στρωμάτων νευρωνίων δεν πρέπει να είναι πολύ μεγάλος.

Έστω

H = ο αριθμός των κρυμμένων στρωμάτων νευρωνίων

N = το μέγεθος του στρώματος εισόδου

M = το μέγεθος του στρώματος εξόδου

T = το μέγεθος του σετ εκπαίδευσης

Ο αριθμός των ελεύθερων παραμέτρων είναι αυστηρά $W=H(N+M)$. Αυτό πρέπει να είναι μικρότερο από το μέγεθος του σετ εκπαίδευσης, κατά προτίμηση περίπου ίσο με $T/5$. Έτσι, το μέγεθος του κρυμμένου στρώματος θα είναι κατ' εκτίμηση :

$$H \approx \frac{T}{5(N+M)} \quad (3.3)$$

Με σκοπό να είμαστε σίγουροι για μία κατάλληλη γενίκευση, το δικτυακό μοντέλο, όπως και κάθε άλλο μαθηματικό μοντέλο, πρέπει να είναι τεκμηριωμένο. Αυτό είναι ένα βήμα για την αναγνώριση του συστήματος, που πρέπει να ακολουθήσει την επιλογή της δομής του μοντέλου, και τον υπολογισμό των παραμέτρων. Η τεκμηρίωση ενός μοντέλου νευρωνικού δικτύου μπορεί να πραγματοποιηθεί με βάση μία

αρχή ενός πολύ σημαντικού εργαλείου της στατιστικής, γνωστό ως διασταυρούμενη τεκμηρίωση (cross-validation). Αυτό σημαίνει ότι ένα σετ δεδομένων που δεν έχει χρησιμοποιηθεί στον υπολογισμό των παραμέτρων (δηλαδή εκπαίδευση του δικτύου), χρησιμοποιείται για την εκτίμηση της απόδοσης του μοντέλου.

3.4 ΤΕΧΝΙΚΕΣ ΠΡΟΒΛΕΨΕΙΣ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ

Στις ενότητες που ακολουθούν παρουσιάζονται τα διάφορα μοντέλα πρόβλεψης ηλεκτρικού φορτίου που εφαρμόζονται στη μελέτη [43].

3.4.1 Η μέθοδος αναδρομής (autoregressive method)

Η συγκεκριμένη στατιστική μέθοδος αν και δεν χρησιμοποιείται πλέον ευρέως, ωστόσο παρουσιάζεται για λόγους σύγκρισης με τις υπόλοιπες μεθόδους. Έτσι, το μοντέλο του οποίου τις μελλοντικές τιμές θέλουμε να προβλέψουμε παριστάνεται από την εξίσωση $y_t = a_0 + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + b_t$, όπου $y_t, y_{t-1}, \dots, y_{t-p}$ είναι η παρούσα και οι παρελθοντικές τιμές του φορτίου αντίστοιχα, a_1, \dots, a_p οι άγνωστοι συντελεστές βάρους αυτών των τιμών, a_0 ένας σταθερός όρος και b_t τυχαίος θόρυβος. Ο υπολογισμός των συντελεστών αυτών επιτυγχάνεται με τη χρήση της αναδρομικής μεθόδου ελαχίστων τετραγώνων, σε συνδυασμό με τον αλγόριθμο αποσύνθεσης U-D για αριθμητικούς υπολογισμούς και ακριβής βελτιστοποίηση. Η τάξη p του μοντέλου υπολογίζεται χρησιμοποιώντας το κριτήριο Akaike [41,44-45]. Τελικά με βάση τα διαθέσιμα δεδομένα η τιμή του p βρίσκεται ίση με 4.

3.4.2 Προχωρημένοι αλγόριθμοι ανάστροφης διάδοσης (back-propagation) για MLP δίκτυα.

Τα MLP νευρωνικά δίκτυα που εκπαιδεύονται με βάση τον κλασικό αλγόριθμο ανάστροφης διάδοσης (BP), θεωρούνται ως η πιο συνηθισμένη προσέγγιση για περίπλοκες αντιστοιχίσεις εισόδου – εξόδου ενός δικτύου, αποτελώντας ουσιαστικά μια μη γραμμική συνάρτηση αντιστοίχισης. Ο γενικευμένος κανόνας δέλτα χρησιμοποιείται για τη ρύθμιση των βαρών των τροφοδοτούμενων προς τα εμπρός δικτύων (feed-forward networks) ελαχιστοποιώντας έτσι μια προκαθορισμένη συνάρτηση κόστους σφάλματος. Οι τιμές των βαρών

αυτών ρυθμίζονται με βάση τον κανόνα: $w_{jk}^p(t+1) = w_{jk}^p(t) + m\delta_k^p y_j^p + \alpha \Delta w_{jk}^p(t)$, όπου m η παράμετρος του ρυθμού εκμάθησης, α ο όρος momentum (κυμαινόμενος μεταξύ 0 και 1) και d η αρνητική κλίση του συνολικού τετραγωνικού σφάλματος σε σχέση με την έξοδο του νευρωνίου.

Ωστόσο, οι κλασικοί αλγόριθμοι BP αντιμετωπίζουν το σημαντικό πρόβλημα της αργής σύγκλισης. Για το σκοπό αυτό χρησιμοποιείται μια τεχνική αυτοδιδασχής που ονομάζεται νευρωνικό δίκτυο ανάστροφης διάδοσης με προσαρμοζόμενο ρυθμό εκμάθησης (adaptive learning rate backpropagation neural network ή ALRBP). Το ALRBP συσχετίζει το ρυθμό εκμάθησης με το συνολικό σφάλμα E , επιτυγχάνοντας έτσι την επιτάχυνση της διαδικασίας εκμάθησης. Ο κανόνας ανανέωσης των βαρών σε αυτήν την περίπτωση θα δίνεται από τη σχέση :

$$w_{ij}^p(t+1) = w_{ij}^p(t) - \frac{q(E) \frac{\partial E}{\partial w_{ij}^p}}{\left\| \frac{\partial E}{\partial w_{ij}^p} \right\|^2} \quad \text{Όπου } q(E) \text{ είναι μια συνάρτηση του σφάλματος } E$$

που δίνεται από τη σχέση: $q(E) = \begin{cases} m \\ mE \\ m \tan h\left(\frac{E}{E_0}\right) \end{cases}$, όπου οι m και E_0

αποτελούν σταθερούς μη αρνητικούς αριθμούς που αντιπροσωπεύουν το ρυθμό εκμάθησης και τον παράγοντα κανονικοποίησης του σφάλματος αντίστοιχα. Κύριο πλεονέκτημα του συγκεκριμένου αλγορίθμου αποτελεί το γεγονός της εξάρτησης του ρυθμού εκμάθησης από την ακαριαία τιμή του συνολικού τετραγωνικού σφάλματος E .

Αρκετά σημαντικό ρόλο στην ακρίβεια πρόβλεψης ενός νευρωνικού μοντέλου διαδραματίζει και η μέθοδος κωδικοποίησης των δεδομένων.

Με τη συμβατική μέθοδο τα δεδομένα αντιπροσωπεύονται χρησιμοποιώντας ένα μονάχα κόμβο στα στρώματα εισόδου ή εξόδου. Μια εναλλακτική απεικόνιση των δεδομένων ονομάζεται *Gaussian κωδικοποίηση*. Στην περίπτωση αυτή κάθε δεδομένο αντιπροσωπεύεται ως η μέση τιμή ενός κυλιόμενου Gaussian προτύπου διέγερσης, σε αρκετούς κόμβους στην είσοδο και έξοδο του δικτύου. Αναλυτικότερα, κάθε μεταβλητή του δικτύου $x \in [x_{\min}, x_{\max}]$ αντιστοιχίζεται σε ένα κυλιόμενο Gaussian πρότυπο N κόμβων, που περιλαμβάνει επιπρόσθετους κόμβους σε κάθε πλευρά του εύρους κάθε μεταβλητής. Το επίπεδο ενεργοποίησης κάθε κόμβου βρίσκεται στο διάστημα $[0.1, 0.9]$. Σε κάθε κόμβο αντιστοιχίζεται μια τιμή a_i , γραμμικά διευθετημένη κατά απόσταση δ έτσι ώστε να περιλάβει ολόκληρο το διάστημα του x , με το κέντρο του Gaussian προτύπου διέγερσης να αντιστοιχεί στην κωδικοποιημένη τιμή. Για μια συγκεκριμένη τιμή του x η διέγερση κάθε

κόμβου καθορίζεται από μια συνάρτηση $\psi_i(x) = \frac{\int_{\alpha_i-\delta/2}^{\alpha_i+\delta/2} a\phi(\alpha-x)da}{a_i}$ που

ικανοποιεί την απαίτηση

$$\sum_{i=1}^N a_i \psi_i(x) = \int a\phi(\alpha-x) d\alpha = \bar{a} = x$$

,όπου $\Phi(\alpha)$ η κανονικοποιημένη πυκνότητα πιθανότητας μιας Gaussian κατανομής. Η τεχνική αυτή προσομοιάζει με εκείνη της ασαφοποίησης δεδομένων (data-fuzzification). Η τελική (αποκωδικοποιημένη πλέον)

έξοδος του δικτύου θα δίνεται από τη σχέση $x = \frac{\sum_{i=1}^N a_i \psi_i(x)}{\sum_{i=1}^N \psi_i(x)}$. Μέσα και από

τις ανάλογες δοκιμές τελικά, αποδεικνύεται ότι η ακρίβεια στην πρόβλεψη είναι καλύτερη από ότι στην περίπτωση των συμβατικών δικτύων.

3.4.3 Δίκτυα τυχαίας ενεργοποίησης βαρών (Random activation weight networks ή RAWN) και εκπαιδευόμενα RAWN με κινούμενο παράθυρο αναδρομής (moving window regression trained RAWN ή MWRAWN).

Μια γενική συνάρτηση προσέγγισης μπορεί να επιτευχθεί με τα feed-forward νευρωνικά δίκτυα που αποτελούνται από ένα μονάχα κρυφό στρώμα μη γραμμικών νευρωνίων. Η πρωταρχική ιδέα πίσω από τα δίκτυα RAWN είναι ότι δεν απαιτείται η εκπαίδευση των βαρών μεταξύ του στρώματος εισόδου και του κρυφού στρώματος. Θεωρώντας ως τυχαίες τις αρχικές τιμές των βαρών ενεργοποίησης, η διαδικασία εκτίμησης των παραμέτρων μπορεί να θεωρηθεί ως γραμμικού τύπου, και έτσι είναι δυνατό να χρησιμοποιηθεί ένας γραμμικός εκτιμητής ελαχίστων τετραγώνων. Οι εξισώσεις του συγκεκριμένου δικτύου μπορούν να γραφτούν με την μορφή πινάκων :

$$\begin{aligned} Z &= XW^h & [N_e \times N_h] \\ U &= f(Z) = \alpha \tan h(bZ) & [N_e \times N_h] \\ Y_n &= UW^o & [N_e \times N_o] \end{aligned}, \text{ όπου } W^h \text{ είναι ο πίνακας βαρών μεταξύ}$$

εισόδου και κρυφού στρώματος, U ο πίνακας εξόδου του κρυφού στρώματος, W^o ο πίνακας βαρών μεταξύ κρυφού στρώματος και στρώματος εξόδου, και a και b το πλάτος και η φάση της συνάρτησης ενεργοποίησης αντίστοιχα. Θεωρώντας επίσης ως Y_d τα δεδομένα εξόδου στο σύνολο εκπαίδευσης, ο πίνακας Y_d θα δίνεται από τη σχέση:

$Y_d = UW^o + e$, όπου e ο παράγοντας του σφάλματος. Αφού προσδιοριστούν αρχικά τα βάρη του πίνακα W^h , ακολουθεί ο υπολογισμός των βαρών του πίνακα W^o , ελαχιστοποιώντας τη διαφορά ανάμεσα στην έξοδο του νευρωνικού δικτύου $Y(=UW^h)$ και τις επιθυμητές τιμές εξόδου Y_d . Αυτό βέβαια αποτελεί ένα κανονικό πρόβλημα τύπου ελαχίστων τετραγώνων. Δεδομένου ότι ο πίνακας U είναι *full rank* (δηλαδή έχει ένα βαθμό του N_h), η λύση των ελαχίστων τετραγώνων προκύπτει: $\bar{W}^o = (U^T U)^{-1} U^T Y_d$. Με άλλα λόγια, ο πίνακας U πρέπει να έχει N_h γραμμικές ανεξάρτητες στήλες. Σε αντίθετη περίπτωση δεν θα υπάρχει λύση για την προηγούμενη εξίσωση. Εάν ο πίνακας U μπορούσε να δοθεί από τον Z ως ένας μετασχηματισμός γραμμικής συνάρτησης, τότε ο U θα είχε το βαθμό του Z . Όμως, ο Z (ως το εξωτερικό γινόμενο XW^h) αποτελείται από γραμμικά εξαρτημένες στήλες και άρα ο U δεν θα μπορούσε να είναι *full rank*. Στην περίπτωση ωστόσο μιας μη γραμμικής εξίσωσης, ο πίνακας U είναι *full rank*, μιας και οι εξαρτημένες στήλες του Z μετασχηματίζονται με ένα μη γραμμικό τρόπο, εξασφαλίζοντας ότι δεν υπάρχουν δύο στήλες του πίνακα που να είναι ακριβώς οι ίδιες. Το τελευταίο επιτυγχάνεται δίνοντας τυχαίες τιμές στα βάρη ενεργοποίησης W^h . Με τη χρήση επαναληπτικών μεθόδων υπολογίζονται οι τελικές τιμές των βαρών.

Για ακριβείς και γρήγορους υπολογισμούς εφαρμόζεται στα προηγούμενα μια μέθοδος αναδρομής κινούμενου παραθύρου. Έτσι,

θεωρώντας $U = \begin{bmatrix} u_1(1) & \cdots & u_m(1) \\ \vdots & & \vdots \\ u_1(k) & \cdots & u_m(k) \end{bmatrix} = \begin{bmatrix} u^T(1) \\ \vdots \\ u^T(k) \end{bmatrix}$ και $Y_d = [y_d(1) \dots y_d(k)]^T$, στην περίπτωση ενός κινούμενου παραθύρου μήκους n_w χρησιμοποιούνται οι ακόλουθες σχέσεις:

Όπως αποδεικνύεται μέσα από το παράρτημα της αναφοράς [48], ένα κινούμενο παράθυρο ελαχίστων τετραγώνων μπορεί να εξαχθεί από τις

$$\bar{W}^o(k+1) = \bar{W}^o(k) - P(k+1) \times [\Gamma(k+1)\bar{W}^o(k) - \delta(k+1)]$$

,όπου $P^{-1}(k+1) = (U_{k+1}^T U_{k+1})^{-1} = P^{-1}(k) + \Gamma(k+1)$, ο πίνακας συμμεταβλητότητας της εκτίμησης $\bar{W}^o(k+1)$, ενώ οι ποσότητες δ και Γ καθορίζονται ως:

$$\begin{aligned} \delta(k+1) &= u(k+1)y(k+1) \\ &\quad - u(k-n_w+1)y(k-n_w+1) \\ \Gamma(k+1) &= u(k+1)u^T(k+1) \\ &\quad - u(k-n_w+1)u^T(k-n_w+1) \end{aligned}$$

Βασικό πλεονέκτημα της συγκεκριμένης μεθόδου αποτελεί το γεγονός ότι η τιμή $\hat{W}^0(t)$ εκτιμάται χρησιμοποιώντας την πληροφορία που ανακλύπεται από τα τελευταία n_w δείγματα. Κατ' αυτόν τον τρόπο επιτυγχάνεται μια άυξηση στην ταχύτητα εκπαίδευσης του δικτύου, ανάλογη του μήκους του παραθύρου. Τέλος, αρκετά σημαντικό ρόλο παίζει η επιλογή των βαρών ενεργοποίησης W^h . Για το σκοπό αυτό επιλέγεται ένας πίνακας W^h που προκύπτει μέσα από μια τυχαία παραγόμενη κανονική κατανομή με μέση τιμή 0 και τυπική απόκλιση ίση με τη μονάδα. Έτσι, η κανονικοποιημένη

τιμή για τον W^h θα δίνεται τελικά από την εξίσωση:
$$W^h = \sqrt{\frac{a}{\max_k \sum_{\ell=1}^{N_\ell+1} x_\ell^2(k)}} N(0, 1)$$

3.4.4 Δίκτυα με συναρτήσεις radial basis (radial basis function networks ή RBFN's)

Ένα δίκτυο RBFN σχεδιάζεται ώστε να πραγματοποιεί μια αντιστοίχιση εισόδου – εξόδου, εκπαιδευόμενο με ένα σύνολο από p δείγματα (x_k, d_k) , $k=1, 2, \dots, p$. Το συγκεκριμένο υβριδικό δίκτυο ακολουθεί μια συνδυαζόμενη τεχνική επιτηρούμενης και μη επιτηρούμενης εκπαίδευσης. Οι κρυφοί κόμβοι του δικτύου ακολουθούν μια κανονικοποιημένη Gaussian συνάρτηση ενεργοποίησης:

$$z_q = g_q(\mathbf{x}) \doteq \frac{R_q(\mathbf{x})}{\sum_{k=1}^{\ell} R_k(\mathbf{x})} = \frac{\exp[-|\mathbf{x} - m_q|^2 / 2\sigma_q^2]}{\sum_{k=1}^{\ell} \exp[-|\mathbf{x} - m_k|^2 / 2\sigma_k^2]}$$

Με αυτόν τον τρόπο ο κρυφός κόμβος q δίνει μια μέγιστη απόκριση στα διανύσματα εισόδου x τα οποία είναι κοντύτερα προς την τιμή m_q . Κάθε κρυφός κόμβος q έχει το δικό του δεκτικό πεδίο $R_q(\mathbf{x})$ στο χώρο εισόδου, που είναι μια περιοχή με κέντρο την τιμή m_q με μέγεθος ανάλογο προς το σ_q , όπου τα m_q και σ_q^2 είναι η μέση τιμή και η διασπορά της q Gaussian συνάρτησης αντίστοιχα. Οι Gaussian συναρτήσεις αποτελούν βέβαια ένα συγκεκριμένο παράδειγμα των συναρτήσεων radial basis. Η τελική έξοδος του δικτύου θα είναι απλά το ζυγισμένο

άθροισμα των εξόδων των κρυφών κόμβων: $y_i = \alpha_i \left(\sum_{q=1}^{\ell} w_{iq} z_q + \theta_i \right)$, όπου $\alpha_i(\cdot)$ είναι η έξοδος της συνάρτησης ενεργοποίησης και θ_i η τιμή κατωφλίου. Στην μελέτη των Κ.Καλαϊτζάκη, Γ.Σταυρακάκη και Ε.Αναγνωστάκη επιλέγεται όχι ένα σταθερό και εκ των προτέρων ορισμένο κέντρο για κάθε μια από τις συναρτήσεις radial basis, αλλά με τη χρήση της μεθόδου των ορθογωνίων ελαχίστων τετραγώνων και τον αντίστοιχο αλγόριθμο

εκπαίδευσης επιλέγονται διαδοχικά κατάλληλα RBF κέντρα ένα προς ένα από τα σημεία του σετ εκπαίδευσης μέχρις ότου επιτευχθεί το βέλτιστο δίκτυο. Με τη χρήση της συγκεκριμένης μεθόδου παράγεται τελικά ένα δίκτυο RBF αρκετά μικρότερο από ότι ένα τυχαία επιλεγόμενο RBF δίκτυο [46,47]. Ο χρόνος εκπαίδευσης ενός RBF δικτύου προκύπτει αρκετά μικρότερος από εκείνον ενός συμβατικό νευρωνικού δικτύου ανάστροφης διάδοσης.

Ένα σημαντικό μειονέκτημα της παραπάνω μεθόδου σχετίζεται με το μέγεθος διάστασης του χώρου εισόδου. Για μεγάλο αριθμό από μονάδες εισόδου, ο αριθμός των απαιτούμενων συναρτήσεων radial basis μπορεί να γίνει δραματικά μεγάλος. Κατά συνέπεια, η συνεπακόλουθη ύπαρξη πολλών κέντρων (των αντίστοιχων RB συναρτήσεων) οδηγεί σε ένα επίσης μεγάλο αριθμό παραμέτρων προς υπολογισμό, με αποτέλεσμα το δίκτυο να είναι τελικά υπερευαίσθητο στις λεπτομέρειες του συγκεκριμένου συνόλου εκπαίδευσης οδηγώντας έτσι σε φτωχά αποτελέσματα όσον αφορά την ικανότητα γενίκευσης του δικτύου (υπερεκπαίδευση). Για την αποφυγή του προβλήματος αυτού χρησιμοποιείται η τεχνική της ομαλοποίησης μηδενικής τάξης (zero-order regularization RBF ή ZORRBF). Τα καλύτερα αποτελέσματα επιτυγχάνονται χρησιμοποιώντας 10 εισόδους. Η δε τιμή της παραμέτρου ομαλοποίησης λ τέθηκε μέσα από τη διαδικασία της δοκιμής και του λάθους ίση με 0.00002 και 0.00008 για την περίπτωση του μέγιστου και ελάχιστου φορτίου αντίστοιχα.

3.4.5 Επαναληπτικά δίκτυα πραγματικού χρόνου (recurrent real-time networks)

Η περιγραφή της δομής του συγκεκριμένου δικτύου έχει ως εξής. Σε ένα δίκτυο με N νευρώνια και N_i εξωτερικές εισόδους, $x(t)$ είναι η $N_i \times 1$ εξωτερική είσοδος που εφαρμόζεται στο δίκτυο τη στιγμή t και $y(t+1)$ το $N \times 1$ διάνυσμα εξόδου τη στιγμή $t+1$. Το διάνυσμα εισόδου $x(t)$ και το διάνυσμα εξόδου $y(t+1)$ αποτελούν από κοινού το $(N+N_i) \times 1$ διάνυσμα $u(t)$. Το δίκτυο έχει δύο στρώματα, ένα συγχωνευμένης εισόδου-εξόδου και ένα στρώμα επεξεργασίας. Το δίκτυο είναι πλήρως διασυνδεδεμένο, έτσι υπάρχουν $N_i N$ συνδέσεις προς τα εμπρός και N^2 αναδρομικές συνδέσεις. Θεωρώντας ότι W είναι ο $N(N_i+N)$ πίνακας των βαρών του δικτύου, η είσοδος κάθε νευρωνίου θα δίνεται από τη σχέση

$$v_j(t) = \sum_{i=1}^{N_i+N} w_{ji}(t) u_i(t)$$

. Την επόμενη χρονική στιγμή $t+1$, η έξοδος κάθε νευρωνίου του στρώματος επεξεργασίας θα δίνεται από τη σχέση $y_j(t+1) = F(v_j(t))$, παρατηρώντας ότι η εξωτερική είσοδος $x(t)$ δεν

επηρεάζει την έξοδο κανενός νευρωνίου μέχρι τη στιγμή $t+1$. Η σχέση $e_j(t) = d_j(t) - y_j(t)$ μας δίνει τη διαφορά της επιθυμητής από την υπολογισμένη έξοδο κάθε νευρωνίου. Στόχος αποτελεί η ελαχιστοποίηση

$$E_{\text{total}} = \sum_{t=1}^{t_{\text{final}}} E(t)$$

της συνάρτησης, όπου t_{final} είναι το τέλος του «τρέξιματος» του NN. Τελικά, με βάση την απαίτηση

$$\frac{\partial E_{\text{total}}}{\partial W} = 0 \Rightarrow \sum_{t=1}^{t_{\text{final}}} \frac{\partial E_{\text{total}}}{\partial W} = 0 \Rightarrow \sum_{t=1}^{t_{\text{final}}} \nabla_w E(t) = 0$$

προκύπτουν οι ακόλουθοι κανόνες ανανέωσης για τα βάρη ενός εξωτερικού νευρωνίου (α) και ενός νευρωνίου εξόδου (β) αντίστοιχα.

$$w_{k\ell}(t+1) = w_{k\ell}(t) + \eta \sum_{j=1}^N e_j(t) F'(v_j(t)) \times \sum_{i=1}^{N_i+N} [\delta_{kj} u_{\ell}(t)] \quad \text{Σχέση (α)}$$

$$w_{k\ell}(t+1) = w_{k\ell}(t) + \eta \sum_{j=1}^N e_j(t) F'(v_j(t)) \sum_{i=1}^{N_i+N} \left[w_{ji}(t) \frac{\partial y_j(t)}{\partial w_{k\ell}(t)} + \delta_{kj} u_{\ell}(t) \right] \quad \text{Σχέση (β)}$$

Στην περίπτωση αυτή χρησιμοποιούνται 24 διαφορετικά νευρωνικά δίκτυα για την πρόβλεψη του φορτίου της επόμενης ημέρας.

3.4.6 Αναδρομικά επαναληπτικά νευρωνικά δίκτυα (autoregressive recurrent neural networks ARNN)

Η τελευταία κατηγορία νευρωνικών δικτύων που παρουσιάζεται στην [43] αποτελεί ένα υβριδικό τύπο τροφοδοτούμενων προς τα εμπρός και προς τα πίσω νευρωνικών δικτύων. Υπάρχουν δύο κρυφά στρώματα με σιγμοειδείς συναρτήσεις μεταφοράς και με έναν μονάχα γραμμικό κόμβο εξόδου. Η τοπολογία του ARNN επιτρέπει την επαναληπτικότητα μονάχα στο πρώτο κρυφό στρώμα. Για το σκοπό αυτό το μοντέλο BP επεκτείνεται έτσι ώστε να περιλάβει μια AR (autoregressive) μνήμη, μια μορφή αυτόανάδραση όπου η έξοδος εξαρτάται επίσης από το ζυγισμένο άθροισμα των προηγούμενων εξόδων. Για την εκπαίδευση του δικτύου χρησιμοποιείται ένας τροποποιημένος BP αλγόριθμος, ο οποίος περιλαμβάνει δυναμικές επαναληπτικές συναρτήσεις του χρόνου. Ο μαθηματικός προσδιορισμός του μοντέλου αυτού θα έχει ως εξής:

$$y(t) = O(t) = \sum_{\ell} W_{\ell}^O Q_{\ell}(t), \quad Q_{\ell} = f(S_{\ell}), \quad S_{\ell} = \sum_j W_{j\ell}^H Z_j(t), \quad \text{και} \quad Z_j(t) = f(H_j(t)),$$

$$H_j(t) = \sum_{k=1}^{k=n} W_{jk}^D Z_j(t-k) + \sum_i W_{ji}^I I_i(t)$$

, όπου $I_i(t)$ η i-οστή είσοδος του ARNN, $H_j(t)$ το άθροισμα των εισόδων του j-οστού επαναληπτικού νευρωνίου στο πρώτο κρυφό στρώμα, $Z_j(t)$ η έξοδος του j-οστού επαναληπτικού νευρωνίου, $S_l(t)$ το άθροισμα των εισόδων του l-οστού νευρωνίου στο δεύτερο κρυφό στρώμα, $Q_l(t)$ η έξοδος του l-οστού νευρωνίου και $O(t)$ η τελική έξοδος του δικτύου. Οι πίνακες W με τους διαφορετικούς δείκτες αποτελούν τους πίνακες βαρών των αντίστοιχων στρωμάτων του δικτύου.

Συμβολίζοντας με $d(t)$ και $y(t)$ τις επιθυμητές και πραγματικές αποκρίσεις του ARNN αντίστοιχα, η συνάρτηση σφάλματος θα δίνεται από τη σχέση: $E = \frac{1}{2}[d(t) - y(t)]^2$

Ο κανόνας ανανέωσης των βαρών θα δίνεται από τη σχέση:

$$W(n+1) = W(n) + n \left(-\frac{\partial E}{\partial W} \right) + \alpha \Delta W(n) \quad , \quad \text{όπου:}$$

$$\begin{aligned} \frac{\partial E}{\partial W} &= -e(t) \frac{\partial y(t)}{\partial W} = -e(t) \frac{\partial O(t)}{\partial W} & \frac{\partial O(t)}{\partial W_{\ell}^o} &= Q_{\ell}(t) & \frac{\partial O(t)}{\partial W_{j\ell}^H} &= f'(S_{\ell}) W_{\ell}^o Z_j(t) & \frac{\partial O(t)}{\partial W_{jk}^D} &= \delta_j(t) \frac{\partial Z_j(t)}{\partial W_{jk}^D} \\ \frac{\partial O(t)}{\partial W_{ij}^I} &= \delta_j(t) \frac{\partial Z_j(t)}{\partial W_{ij}^I} \quad (\text{με} \quad \delta_j(t) = \sum_{\ell} f'(S_{\ell}) W_{\ell}^o W_{j\ell}^H) \end{aligned}$$

και :

$$\begin{aligned} \frac{\partial Z_j(t)}{\partial W_{jk}^D} &= f'(H_j) \left(Z_j(t-k) + \sum_{n=1}^{n-5} W_{jn}^D \frac{\partial Z_j(t-n)}{\partial W_{jk}^D} \right) \frac{\partial Z_j(0)}{\partial W_{jk}^D} = 0 \\ \frac{\partial Z_j(t)}{\partial W_{ij}^I} &= f'(H_j) \left(I_i(t) + \sum_{n=1}^{n-5} W_{jn}^D \frac{\partial Z_j(t-n)}{\partial W_{ij}^I} \right) \frac{\partial Z_j(0)}{\partial W_{ij}^I} = 0 \end{aligned}$$

Το δίκτυο που χρησιμοποιείται στην [43] έχει 8 εισόδους, 20 κόμβους στο πρώτο κρυφό στρώμα, 14 κόμβους στο δεύτερο κρυφό στρώμα και μία έξοδο.

ΚΕΦΑΛΑΙΟ 4

ΤΟ ΦΙΛΤΡΟ KALMAN ΚΑΙ Η ΕΦΑΡΜΟΓΗ ΤΟΥ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ

4.1 Το φίλτρο KALMAN

Θεωρώντας ένα διακριτό σύστημα (είτε συνεχές, στην γενικότερη περίπτωση) της μορφής $x[n+1] = Ax[n] + B(u[n] + w[n])$, $y[n] = Cx[n]$, όπου οι μετρούμενες έξοδοι $y_v[n]$ επηρεαζόμενες από θόρυβο $v[n]$ έτσι ώστε $y_v[n] = Cx[n] + v[n]$ (όπου $v[n]$ λευκός θόρυβος), στόχος μας αποτελεί ο σχεδιασμός ενός φίλτρου *Kalman* τέτοιου ώστε δεδομένο των εισόδων $u[n]$ και τον παρατηρούμενων εξόδων να μπορεί να εκτιμηθεί η πραγματική τιμή της εξόδου.

Οι γενικές εξισώσεις ενός φίλτρου KALMAN σταθερής κατάστασης θα είναι:

$$\hat{x}[n/n] = \hat{x}[n/n-1] + M(y_v[n] - C\hat{x}[n/n-1]) \quad (\text{ανανέωση μέτρησης}) \quad (4.1)$$

$$\hat{x}[n+1/n] = A\hat{x}[n/n] + Bu[n] \quad (\text{ανανέωση στο χρόνο}) \quad (4.2)$$

Σε αυτές τις εξισώσεις $\hat{x}[n/n-1]$ είναι η εκτίμηση του $x[n]$ δεδομένου των παρελθοντικών μετρήσεων μέχρι την $y_v[n-1]$ και $\hat{x}[n/n]$ η ανανεωμένη εκτίμηση βασιζόμενη στην τελευταία μέτρηση $y_v[n]$. Έτσι, δεδομένου της τρέχουσας εκτίμησης $\hat{x}[n/n]$, η (4.2) προβλέπει την τιμή της κατάστασης στο επόμενο χρονικό διάστημα $n+1$. Η (4.1) ακολούθως, ανανεώνει αυτήν την μέτρηση με βάση την καινούρια μέτρηση πλέον $y_v[n+1]$.

Ο όρος διόρθωσης αποτελεί μια συνάρτηση «ανανέωσης»

$y_v[n+1] - C\hat{x}[n+1/n] = C(x[n+1] - \hat{x}[n+1/n])$, ανάμεσα στη μετρούμενη και την προβλεπόμενη τιμή του $y_v[n+1]$ για κάθε χρονική στιγμή. Το κέρδος ανανέωσης M επιλέγεται έτσι ώστε να ελαχιστοποιεί τη διασπορά σταθερής κατάστασης του σφάλματος εκτίμησης δεδομένου των διασπορών του θορύβου $E(w[n]w[n]^T) = Q$ και $E(v[n]v[n]^T) = R$. Ο συνδυασμός των εξισώσεων (4.1) και (4.2) μαζί με το μοντέλο κατάστασης δίνουν το τελικό φίλτρο *Kalman*:

$$\hat{x}[n+1/n] = A(I - MC)\hat{x}[n/n-1] + [B \ AM] \begin{bmatrix} u[n] \\ y_v[n] \end{bmatrix} \quad (4.3)$$

$$\hat{y}[n/n] = C(I - MC)\hat{x}[n/n-1] + CM y_v[n] \quad (4.4)$$

Οι ενδείξεις πάνω στον πίνακα αντιστοιχίζονται ως εξής: το 0 αντιπροσωπεύει την τρέχουσα τιμή του φορτίου $y(k)$, το 1 την τιμή της προηγούμενης ώρας $y(k-1)$, το 2 την ώρα της προηγούμενης ημέρας $y(k-24)$ και ούτω καθεξής. Το παράθυρο μπορεί να «συμπίεστεί» ή να επεκταθεί έτσι ώστε να περιλαμβάνει περισσότερες ή λιγότερες τιμές. Στην [31] αλλά και στην παρούσα μελέτη επιλέγεται η περίπτωση εκείνη όπου χρησιμοποιούνται 4 παρελθοντικές τιμές για το φορτίο.

4.2.1 Εκτίμηση των παραμέτρων του φίλτρου Kalman.

Θεωρούμε αρχικά τις ακόλουθες διακριτές εξισώσεις:

$$\begin{aligned} x(k+1) &= A(k)x(k) + w(k) \\ z(k) &= C(k)x(k) + v(k) \end{aligned} \quad (4.6)$$

, όπου $x(k)$ είναι οι $n \times 1$ καταστάσεις του συστήματος, $A(k)$ είναι ένας $n \times n$ μεταβλητού χρόνου πίνακας κατάστασης, $z(k)$ είναι οι $m \times 1$ μετρήσεις, $C(k)$ είναι ο $m \times n$ μεταβλητού χρόνου πίνακας εξόδου, $w(k)$ ο $n \times 1$ πίνακας σφαλμάτων του συστήματος και $v(k)$ ο $m \times 1$ πίνακας των σφαλμάτων μέτρησης. Τα σφάλματα του θορύβου $w(k)$ και $v(k)$ είναι λευκοί θόρυβοι ασυσχέτιστοι μεταξύ τους έτσι ώστε να ισχύει:

$E[w(k)] = E[v(k)] = 0$ και $E[w(i)w^T(j)] = E[v(i)v^T(j)] = 0$, για $i \neq j$.
 $E[w(k)w^T(k)] = Q_1$, $E[v(k)v^T(k)] = Q_2$ όπου Q_1 και Q_2 είναι θετικά ημιορισμένοι θετικά ορισμένοι πίνακες αντίστοιχα.

Ο βασικός αλγόριθμος του διακριτού φίλτρου Kalman θα δίνεται από το ακόλουθο σύνολο των επαναληπτικών εξισώσεων:

$$\begin{aligned} K(k) &= [A(k)P(k)C^T(k)][C(k)P(k)C^T(k) + Q_2]^{-1} \quad (\text{κέρδος φίλτρου Kalman}) \\ \hat{x}(k+1) &= A(k)\hat{x}(k) + K(k)[z(k) - C(k)\hat{x}(k)] \quad (\text{εκτίμηση νέας κατάστασης}) \\ P(k+1) &= [A(k) - K(k)C(k)]P(k)[A(k) - K(k)C(k)]^T \\ &\quad + K(k)Q_2K^T(k) \quad (\text{ανανέωση του πίνακα συμμεταβλητοτήτων}) \end{aligned}$$

* κρίσιμη αποτελεί η επιλογή των αρχικών τιμών των πινάκων $\hat{x}(k)$ και $P(k)$, οπότε προτείνεται ότι με τη χρήση αρκετών δειγμάτων της κυματομορφής εξόδου $z(k)$ μπορούν μέσω μιας διαδικασίας σταθμισμένων ελαχίστων τετραγώνων να προσδιοριστούν ως αρχικές τιμές οι:

$$\begin{aligned} \hat{x}_0 &= [H^T Q_2^{-1} H]^{-1} H^T Q_2^{-1} z_0 \\ P_0 &= [H^T Q_2^{-1} H]^{-1} \end{aligned} \quad (4.7)$$

, όπου $z_0 = \begin{bmatrix} z(1) \\ z(2) \\ \vdots \\ z(m_1) \end{bmatrix}$ και $H = \begin{bmatrix} C(1) \\ C(2) \\ \vdots \\ C(m_1) \end{bmatrix}$. Το z_0 είναι ένα διάνυσμα

($m \times 1$) των m μετρούμενων δειγμάτων και H ένας ($m \times n$) πίνακας.

Στην περίπτωση χρήσης του μοντέλου του καιρού [31] (αλλά και με τη χρήση μονάχα του φορτίου, όπως στην παρούσα μελέτη) το δυναμικό σύστημα των εξισώσεων (4.5) χρησιμοποιείται με βάση τους ακόλουθους προσδιορισμούς:

- ✚ Ο πίνακας μετάβασης $A(k)$ είναι ένας σταθερός πίνακας (και συγκεκριμένα ο μοναδιαίος).
- ✚ Οι πίνακες Q_1 και Q_2 (που αντιστοιχούν στις συμμεταβλητότητες των σφαλμάτων) θεωρούνται επίσης σταθεροί και ορίζονται και αυτοί ως μοναδιαίοι πίνακες.
- ✚ Το διάνυσμα κατάστασης $x(k)$ αποτελείται από N παραμέτρους, όπου $N=n+1$.
- ✚ Το $C(k)$ είναι ένα διάνυσμα γραμμής N στοιχείων, τα οποία μεταβάλλονται με το χρόνο, που συσχετίζει τα μετρούμενα δεδομένα με το διάνυσμα κατάστασης.
- ✚ Το διάνυσμα παρατήρησης $z(k)$ είναι ένα βαθμωτό μέγεθος που αντιστοιχεί στην τιμή του φορτίου κάθε στιγμή k .

Το διάνυσμα παρατήρησης $z(k)=C(k)x(k)$ έχει την ακόλουθη μορφή:

$$y(k) = [1 \quad y_1 \quad \cdots \quad y_{n1} \quad t_0 \quad \cdots \quad t_{n2} \quad w_0 \quad \cdots \quad w_{n3}]$$

$$\times \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_{n1} \\ b_1 \\ \vdots \\ b_{n2} \\ c_1 \\ \vdots \\ c_{n3} \end{bmatrix}$$


4.2.2 Βήματα που ακολουθούνται για την πρόβλεψη του φορτίου της επόμενης μέρας

1. Τίθενται οι αρχικές τιμές των διανυσμάτων $x(k)$ και $P(k)$ όπως περιγράφονται μέσα από τις εξισώσεις (4.7), ενώ και οι πίνακες Q_1, Q_2 ορίζονται ως μοναδιαίοι.

2. Το φίλτρο Kalman «τρέχεται» για την πρώτη ώρα και οι προκύπτοντες συντελεστές σώζονται, ώστε να χρησιμοποιηθούν αργότερα για την πρόβλεψη της συγκεκριμένης ώρας.
3. Οι εκτιμώμενοι παράμετροι της προηγούμενης ώρας χρησιμοποιούνται ως αρχικές συνθήκες για τον προσδιορισμό των παραμέτρων της επόμενης ώρας του φίλτρου Kalman. Το φίλτρο Kalman «τρέχεται» εκ νέου και σώζονται τα προκύπτοντα αποτελέσματα.
4. Το βήμα 3 επαναλαμβάνεται και για της 24 ώρες της ημέρας.
5. Τα 24 σύνολα των παραμέτρων που προκύπτουν κατ' αυτόν τον τρόπο χρησιμοποιούνται για την πρόβλεψη του φορτίου κάθε ώρας της επόμενης μέρας.

4.3 Η εφαρμογή του φίλτρου Kalman για την βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου στο απομωνομένο σύστημα της Κρήτης

Η συγκεκριμένη μελέτη πραγματεύεται την πρόβλεψη του φορτίου προκειμένου για δύο συγκεκριμένες ώρες του φορτίου κάθε ημέρας (μέγιστη και ελάχιστη τιμή) και συγκεκριμένα τις 02:00 και 14:00. Τα αποτελέσματα αφορούν τα έτη 2000 και 2001. Τονίζεται ότι στην περίπτωση μας χρησιμοποιήθηκαν μονάχα δεδομένα φορτίου, ενώ το παράθυρο όπως απεικονίζεται στην ενότητα 4.2 διαμορφώνεται έτσι ώστε να περιλαμβάνει 5 τιμές. Η μία αφορά την τρέχουσα τιμή του φορτίου, ενώ οι υπόλοιπες 4 τα φορτία της προηγούμενης ώρας και εβδομάδας καθώς επίσης και τα φορτία που προηγούνται 23 και 25 ώρες της τρέχουσας τιμής.



Σχήμα 4.2

Για κάθε έτος ακολουθήθηκε η εξής διαδικασία:

- Αρχικά, υπολογίζονται οι αρχικές τιμές των διανυσμάτων $x(k)$ και $P(k)$ χρησιμοποιώντας για τον σκοπό αυτό τις δύο πρώτες ημέρες του κάθε έτους χωριστά με βάση τις σχέσεις (4.7).
- Ακολούθως, χρησιμοποιώντας ένα σύνολο εκπαίδευσης 90 ημερών, επαναλαμβάνεται 90 φορές η διαδικασία των βημάτων 2-4 της προηγούμενης παραγράφου, με αποτέλεσμα να προκύψουν 24 σύνολα από παραμέτρους, με το καθένα να αφορά την κάθε ώρα που επιθυμούμε να προβλέψουμε. Με άλλα λόγια προκύπτουν 24 αναδρομικές εξισώσεις της μορφής (4.5) με υπολογισμένους τους συντελεστές.
- Το διάνυσμα $C(k)$ θα είναι της μορφής $C(k)=[1 \ y(k-23) \ y(k-24) \ y(k-25) \ y(k-1)]$, όπου $y(k)$ το διάνυσμα του φορτίου
- Στη συνέχεια, το σετ εκπαίδευσης των 90 ημερών μετατοπίζεται κατά μια ημέρα προς τα εμπρός και έτσι υπολογίζονται εκ νέου οι συντελεστές που θα αντιστοιχούν στην επόμενη του σετ εκπαίδευσης ημέρα, της οποίας το φορτίο επιθυμούμε να προβλέψουμε
- Η όλη διαδικασία πραγματοποιείται τελικά 120 φορές, όσες είναι και οι μέρες των οποίων το φορτίο επιθυμούμε να προβλέψουμε

Η παραπάνω διαδικασία πραγματοποιείται για κάθε έτος χωριστά. Από κάθε μέρα διατηρούμε μονάχα τις προβλεπόμενες τιμές των ωρών 02:00 και 14:00, με αποτέλεσμα 4 χρονοσειρές (2 για κάθε έτος) 120 τιμών, μία για κάθε ώρα που μας ενδιαφέρει.

Όσον αφορά τον υπολογισμό των προβλεπόμενων τιμών ακολουθήθηκαν δύο διαφορετικές προσεγγίσεις, όπως περιγράφονται μέσα από την [31], οι οποίες αποδίδουν βέβαια και διαφορετικά αποτελέσματα. Στην μεν 1^η περίπτωση, σε κάθε ένα από τα 120 βήματα της διαδικασίας, έχοντας εκτιμηθεί οι συντελεστές των αναδρομικών εξισώσεων (4.5), υπολογίζονται οι προβλεπόμενες τιμές του φορτίου της αντίστοιχης ημέρας μια προς μια, χρησιμοποιώντας δηλαδή ως παρελθοντικές τιμές τις πραγματικές τιμές του φορτίου. Στη 2^η περίπτωση, οι προβλεπόμενες τιμές του φορτίου υπολογίζονται για μία ημέρα συνολικά, δηλαδή ως προηγούμενες τιμές για την κάθε ώρα χρησιμοποιούνται εκείνες που έχουν υπολογιστεί στο προηγούμενο βήμα κάθε φορά (συγκεκριμένα η προηγούμενη τιμή της ώρας). Όπως είναι προφανές, το οποίο και παριστάνεται από τα αποτελέσματα της ενότητας 6, τα σφάλματα θα είναι μεγαλύτερα στη 2^η περίπτωση.

ΚΕΦΑΛΑΙΟ 5

Η ΑΣΑΦΗΣ ΛΟΓΙΚΗ ΚΑΙ Η ΕΦΑΡΜΟΓΗ ΤΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ

ΕΙΣΑΓΩΓΗ

Κατά τη διάρκεια των περασμένων δεκαετιών, η κλασική θεωρία συνόλων έχει αποδειχθεί ένα σημαντικό εργαλείο και έχει εφαρμοσθεί με μεγάλη επιτυχία σε πολλά γνωστικά πεδία όπως τα μαθηματικά και οι επιστήμες των υπολογιστών. Είναι φανερό όμως ότι τα κλασικά σύνολα δεν μπορούν να περιγράψουν επαρκώς έννοιες και καταστάσεις του πραγματικού κόσμου, οι οποίες χαρακτηρίζονται από μεγάλο βαθμό ασάφειας (fuzziness) και απροσδιοριστίας (vagueness). Η ασάφεια προκύπτει είτε από την πολυπλοκότητα των πραγματικών συστημάτων που μελετάμε είτε από την άγνοια των συγκεκριμένων μηχανισμών που διέπουν τη λειτουργία τους. Η μεγαλύτερη όμως πηγή ασάφειας προκύπτει από την φύση των ανθρώπινων ιδεών και σκέψεων. Με άλλα λόγια ο ανθρώπινος εγκέφαλος σχηματίζει για τα πράγματα που μας περιβάλλουν μάλλον γενικές και αφηρημένες έννοιες παρά ακριβείς και συγκεκριμένες εικόνες γι' αυτά. Η ασαφής λογική προσομοιώνει τον ανθρώπινο τρόπο σκέψης, που λειτουργεί περισσότερο με σύμβολα παρά με ακριβείς τιμές [51].

5.1 Βασικές Έννοιες

Ασαφή Σύνολα (Fuzzy Sets)

Ένα ασαφές σύνολο μπορεί να θεωρηθεί ως μια επέκταση ενός κλασικού (crisp) συνόλου. Το βασικό χαρακτηριστικό των κλασικών συνόλων είναι ότι τα σύνορα τους (boundaries) είναι σαφή και συγκεκριμένα. Ένα κλασικό σύνολο A μπορεί να περιγραφεί χρησιμοποιώντας την χαρακτηριστική συνάρτηση χ_A η οποία ορίζεται ως

$$\text{εξής} \quad : \quad \chi_A(x) = \begin{cases} 1 & \text{εάν } x \in A \\ 0 & \text{εάν } x \notin A \end{cases}. \quad \text{Αντίθετα, ένα ασαφές σύνολο } A$$

χαρακτηρίζεται από μια συνάρτηση συμμετοχής μ_A που παίρνει τιμές στο διάστημα $[0,1]$. Έτσι, το $\mu_A(x)$ αναφέρεται και ως βαθμός συμμετοχής του x στο A και δίνει τον βαθμό με τον οποίο το στοιχείο x ανήκει στο A . Ανάλογα με το εάν η περιοχή τιμών ενός συνόλου είναι διακριτή ή συνεχής, γίνεται λόγος για διακριτά ή συνεχή ασαφή σύνολα. Οι βασικές πράξεις των ασαφών συνόλων αφορούν την τομή, την ένωση, το

συμπληρωματικό ενός ασαφούς συνόλου, την έννοια του υποσυνόλου και την ισότητα. [51]

Ασαφείς κανόνες (Fuzzy Rules)

Στα ασαφή συστήματα αναγνώρισης και ελέγχου η ανθρώπινη γνώση παρίσταται με την μορφή ασαφών IF/THEN κανόνων. Οι ασαφείς κανόνες είναι υποθετικές προτάσεις οι οποίες περιγράφονται από την παρακάτω μορφή :

IF <ασαφής πρόταση> THEN <ασαφής πρόταση>

π.χ. IF x is A THEN y is B, όπου A και B είναι λεκτικές τιμές(ασαφή σύνολα) των x και y τα οποία ορίζονται στους χώρους X και Y αντίστοιχα.


Ο κανόνας IF x is A THEN y is B πολύ συχνά περιγράφεται εν συντομία $A \rightarrow B$. Η ασαφής αυτή σχέση αναφέρεται συχνά στη βιβλιογραφία σαν σχέση συμπερασμού. Η σχέση συμπερασμού συσχετίζει τον βαθμό αλήθειας ή τον βαθμό εκπλήρωσης της υπόθεσης με αυτόν του συμπεράσματος.

Μια ασαφής βάση κανόνων αποτελείται από ένα σύνολο από IF/THEN κανόνες. Οι κανόνες εκφράζονται με τη μορφή λεκτικών μεταβλητών.

⇒ **Ασαφείς Σχέσεις:** Οι ασαφείς σχέσεις είναι σύνολα τα οποία ορίζονται σε πολυδιάστατους χώρους και αποτελούν μια γενίκευση των κλασικών σαφών σχέσεων. Μια ασαφή σχέση στον χώρο $X \times Y$ ορίζεται ως: $R(X,Y) = \int_{X \times Y} \mu_R(x,y) / (x,y)$. Και εδώ ισχύουν όλες οι πράξεις που αναφέρονται στα ασαφή σύνολα.

⇒ **Λεκτική Μεταβλητή:** Λεκτική ή ασαφής μεταβλητή είναι μια μεταβλητή η οποία παίρνει λέξεις σαν τιμές. Οι λέξεις αυτές περιγράφονται από σύνολα τα οποία ορίζονται στον χώρο όπου ορίζεται και η μεταβλητή. Με άλλα λόγια αποτελούν γενικεύσεις των κλασικών μεταβλητών όπως και τα ασαφή σύνολα είναι γενικεύσεις των σαφών συνόλων [51].

Θεωρούμε για παράδειγμα τη λεκτική μεταβλητή «ταχύτητα» που ορίζεται στο διάστημα $[0,100]$ και παίρνει τρεις ασαφείς τιμές, «αργή», «μεσαία» και «γρήγορη». Κάθε λεκτική μεταβλητή περιγράφεται από το αντίστοιχο ασαφές σύνολο.



Προσεγγιστικός Συλλογισμός (Approximate reasoning)

Η ασαφής λογική είναι μια γενίκευση της κλασικής λογικής. Βασιζόμενη σε ασαφείς και ανακριβείς προτάσεις παρέχει τις βασικές αρχές για την εξαγωγή προσεγγιστικών συλλογισμών. Αρχικά γίνεται λόγος για τον κατηγορηματικό συλλογισμό. Εδώ ανήκουν διάφοροι μέθοδοι συλλογισμού.

Ο κανόνας σύνθεσης συμπεράσματος είναι της μορφής :

$$\begin{array}{ccc} \text{X is A} & (\text{X,Y) is A} & (\text{X, Y) is A} \\ \text{X is B} & \text{X is B} & (\text{Y, Z) is B} \\ \hline \text{X is A} \cap \text{B} & , & (\text{X,Y) is A} \cap (\text{BxV}) \text{ και } (\text{X, Y, Z}) = (\text{AxW}) \cap (\text{UxB}) \end{array}$$

Αρκετά δημοφιλής είναι η γενικευμένη μέθοδος Modus Ponens (Generalized Modus Ponens ή GMP). Ο κανόνας GMP περιγράφεται γενικά ως:

$$\begin{array}{l} \text{X is A} \\ \hline \text{IF X is B THEN Y is C} \\ \hline \text{Y is A} \circ (\bar{\text{B}} \oplus \text{C}) \end{array}, \text{ όπου } \mu_{\text{B} \oplus \text{C}}(u, v) = \min(1, 1 - \mu_{\text{B}}(u) + \mu_{\text{C}}(v)).$$

Επίσης, ο κανόνας σύνθεσης περιγράφεται ως:

$$\begin{array}{l} \text{X is A} \\ \hline (\text{X, Y) is R} \\ \hline \text{Y is A} \circ \text{R} \end{array}, \text{ όπου } \mu_{\text{A} \circ \text{R}}(v) = \max \min(\mu_{\text{A}}(u), \mu_{\text{R}}(u, v)).$$

⇒ Αρχή της επέκτασης (Extension principle)

Η αρχή της επέκτασης μας λέει ότι εάν η είσοδος είναι ένα ασαφές σύνολο τότε, η έξοδος είναι πράγματι ένα άλλο ασαφές σύνολο του οποίου η συνάρτηση συμμετοχής είναι :

$$\begin{aligned} B = f(A) &= \mu_A(x_1) / f(x_1) + \dots + \mu_A(x_m) / f(x_m) = \mu_A(x_1) / y_1 + \dots + \mu_A(x_m) / y_m \\ &= \mu_B(y_1) / y_1 + \dots + \mu_B(y_m) / y_m. \end{aligned}$$

$$\frac{X \text{ is } A}{f(X) \text{ is } f(A)}$$

Γενικότερα :

- f is a mapping from U to V and
- $\mu_{f(A)}(v) = \sup_{u \in U, v \in V} \mu_A(u)$

\Rightarrow Κανόνας προβολής συμπεράσματος (Projection rule of inference)

Αρχικά, θεωρούμε την ασαφή σχέση $R(X,Y)$ ένα ασαφές σύνολο που ορίζεται στον χώρο $X \times Y$. Η προβολή της $R(X,Y)$ στον υποχώρο Y συμβολίζεται με $[R \downarrow Y]$ και είναι ένα ασαφές σύνολο που ορίζεται στον Y . Η συνάρτηση συμμετοχής της προβολής $[R \downarrow Y]$ προκύπτει ως εξής :

$$\mu_{[R \downarrow Y]}(y) = \max_x \mu_R(x, y).$$

Οπότε ο κανόνας προβολής συμπεράσματος προκύπτει ως:

$$\frac{(X, Y) \text{ is } R}{X \text{ is } [R \downarrow X]}$$

$$X \text{ is } [R \downarrow X]$$

\Rightarrow Τέλος, υπάρχει ο ποιοτικός συλλογισμός που η σχέση εισόδου-εξόδου ενός συστήματος εκφράζεται ως μια συλλογή από IF/THEN κανόνες, ο συλλογιστικός συλλογισμός και ο συλλογισμός dispositional (όπου οι προτάσεις περιέχουν τον όρο “usually”).

5.2 Ασαφή συστήματα συμπερασμού

Έστω ο ασαφής κανόνας $x \text{ is } A \text{ THEN } y \text{ is } B$ ή αλλιώς $R = A \rightarrow B$. Αυτός αντιπροσωπεύει μια σχέση $\mu_R(x,y) = \{\mu_A(x) \varphi \mu_B(y)\}$, όπου φ ένας τελεστής συμπερασμού που είναι συνήθως είτε ο Mamdani είτε ο Larsen (ώστε $\mu_R(x,y) = \mu_A(x) \wedge \mu_B(y)$ ή $\mu_R(x,y) = \mu_A(x) \cdot \mu_B(y)$ αντίστοιχα). Έτσι, με εφαρμογή του συνθετικού κανόνα για $x \text{ is } A_1 \rightarrow y \text{ is } B_1$, με $B_1 = A_1 \circ R$ (όπου \circ ο τελεστής σύνθεσης που είναι συνήθως ο max-min) προκύπτει η σχέση :

$$\begin{aligned} \mu_{B_1}(y) &= \mu_{A_1 \circ R}(y) \\ &= \max_x \left\{ \min \left\{ \mu_{A_1}(x), \mu_R(x,y) \right\} \right\} = \\ &= \max_x \left\{ \min \left\{ \mu_{A_1}(x), (\mu_A(x) \varphi \mu_B(y)) \right\} \right\} \end{aligned}$$

Όταν δίνεται μια είσοδος crisp τότε το A_1 είναι ένα ασαφές σύνολο singleton τέτοιο ώστε:

$$\begin{aligned}\mu_{A_1}(x_0) &= 1, \quad \mu_{A_1}(x) = 0, \quad x \neq x_0 \\ \mu_{B_1}(y) &= \min\{\mu_{A_1}(x_0), (\mu_A(x_0) \varphi \mu_B(y))\} \\ &= \min\{1, (\mu_A(x_0) \varphi \mu_B(y))\} \\ &= (\mu_A(x_0) \varphi \mu_B(y)) \\ \mu_{B_1}(y) &= (\mu_A(x_0) \varphi \mu_B(y))\end{aligned}$$

Τα ασαφή συστήματα, γενικά, απαρτίζονται από τέσσερα βασικά τμήματα : α) τον ασαφοποιητή (fuzzifier) β) την ασαφή βάση κανόνων (fuzzy Rule Base) γ) τον μηχανισμό εξαγωγής συμπεράσματος (fuzzy inference engine) και δ) τον αποασαφοποιητή (defuzzifier). Οι είσοδοι και οι έξοδοι του συστήματος είναι σαφείς μεταβλητές οι οποίες διαμορφώνουν το άνυσμα των εισόδων $\bar{x} = [x_1, x_2, \dots, x_m]$ και των εξόδων $\bar{y} = [y_1, y_2, \dots, y_q]$.

- Η μονάδα του ασαφοποιητή μετατρέπει τα σαφή σήματα εισόδου σε ασαφείς λεκτικές τιμές, δηλαδή, σε ασαφή σύνολα. Με αυτήν την έννοια ο ασαφοποιητής υλοποιεί τη διασύνδεση μεταξύ του σαφούς εξωτερικού κόσμου και του ασαφούς συστήματος εξαγωγής συμπεράσματος
- Η ασαφής βάση κανόνων αποθηκεύει την εμπειρική γνώση των ειδικών όσον αφορά την λειτουργία και την συμπεριφορά του πραγματικού συστήματος που εξετάζουμε.
- Ο μηχανισμός εξαγωγής συμπεράσματος είναι η καρδιά του ασαφούς συστήματος. Βασιζόμενος στην ασαφή βάση κανόνων χρησιμοποιεί την διαδικασία GMP και τους μηχανισμούς που αντιστοιχούν σε αυτήν για να παράξει προσεγγιστικά συμπεράσματα (approximate reasoning) ανάλογα με τις εισόδους που διεγείρουν το σύστημα.
- Τέλος, η μονάδα του αποασαφοποιητή χρησιμοποιείται για να μετατρέψει τα ασαφή συμπεράσματα που προκύπτουν σε σαφή σήματα εξόδου. Επομένως, ο αποασαφοποιητής παρέχει την διασύνδεση μεταξύ του ασαφούς συστήματος και του χώρου εξόδου. [30]

Αναφορικά με το στάδιο της ασαφοποίησης, δύο πολλοί γνωστοί ασαφοποιητές είναι ο *Singleton* ασαφοποιητής και ο *Gaussian* ασαφοποιητής. Ο ασαφοποιητής Singleton αντιστοιχίζει μια πραγματική

τιμή x^* σε ένα ασαφές σύνολο singleton το οποίο έχει την ακόλουθη συνάρτηση συμμετοχής :

$$\mu_A(\mathbf{x}) = \begin{cases} 1 & \text{if } \mathbf{x} = \mathbf{x}^* \\ 0 & \text{otherwise} \end{cases}$$

Ο Gaussian ασαφοποιητής αντιστοιχίζει μια πραγματική τιμή x^* σε ένα ασαφές σύνολο που έχει τις ακόλουθες Gaussian συναρτήσεις συμμετοχής:

$$\mu_A(\mathbf{x}) = e^{-\left(\frac{x_1 - x_1^*}{a_1}\right)^2} * \dots * e^{-\left(\frac{x_n - x_n^*}{a_n}\right)^2}$$

, όπου a_i είναι θετικοί παράμετροι και ο t-norm τελεστής είναι το αλγεβρικό γινόμενο ή ο min.

Ο μηχανισμός εξαγωγής συμπεράσματος, όπως αναφέρθηκε και πρωτύτερα συνδυάζει τα συμπεράσματα των κανόνων που συνθέτουν την ασαφή βάση κανόνων του συστήματος και προκύπτουν με είσοδο την τιμή που έδωσε ο ασαφοποιητής στο προηγούμενο στάδιο, δίνοντας το συνολικό συμπέρασμα που παρίσταται από ένα νέο ασαφές σύνολο C .

Τέλος ο αποασαφοποιητής παίρνει το ασαφές αυτό σύνολο C και το αντιστοιχίζει σε ένα σαφώς καθορισμένο σημείο y^* που αποτελεί και την έξοδο του συστήματος. Ο πιο συνηθισμένος αποασαφοποιητής είναι ο αποασαφοποιητής σταθμισμένων κέντρων (center averaged defuzzifier ή

$$y^* = \frac{\sum_{l=1}^M \bar{y}^l w_l}{\sum_{l=1}^M w_l}$$

CAD) που ορίζεται από τη σχέση: , όπου \bar{y}^l το κέντρο του l ασαφούς συνόλου και w_l το ύψος του. Άλλοι χρήσιμοι αποασαφοποιητές είναι ο **COA** (center of area, αποασαφοποιητής κέντρου βάρους) και ο **MOM** (mean of maximum, αποασαφοποιητής του μέσου μεγίστου). Στην πρώτη περίπτωση η τιμή εξόδου δίνεται από τη σχέση

$$z = \frac{\sum_{j=1}^n \mu_c(z) z_j}{\sum_{j=1}^n \mu_c(z_j)} \text{ -όπου } n \text{ ο αριθμός των επιπέδων κβάντισης και } \mu_c(z)$$

η συνάρτηση συμμετοχής για $z=1,2,\dots,n$ - ενώ στη δεύτερη περίπτωση θα

$$\text{έχουμε } z = \sum_{j=1}^m \frac{z_j}{m} \text{ όπου } z_j \text{ η τιμή του συνόλου υποστήριξης για την}$$

οποία η κάθε συνάρτηση συμμετοχής $\mu_c(z)$ αποκτά τη μέγιστη της τιμή. Τέλος υπάρχει και ο αποασαφοποιητής **BADD** (BADD defuzzifier) όπου η αποασαφοποίηση επιτυγχάνεται αν πρώτα μετασχηματίσουμε τις εξόδους $z \in Z$ σε μια κατανομή πιθανότητας BADD και στη συνέχεια θεωρήσουμε το z^* σαν τη μέση τιμή της κατανομής αυτής. Το

αποτέλεσμα του αποασαφοποιητή για διακριτούς χώρους προκύπτει ως

$$\text{εξής: } z_{BADD}^* = \sum_{j=1}^N z_j p_j \quad \text{όπου } p_j = \frac{\mu_{C'}^a(z_j)}{\sum_{i=1}^N \mu_{C'}^a(z_i)}, \text{ με το } a \in [0, \infty].$$

5.3 Νευρωασαφή συστήματα (NeuroFuzzy Systems)

Ένα νευρωασαφές σύστημα αποτελεί ένα συνδυασμό των νευρωνικών δικτύων και των ασαφών συστημάτων με τέτοιο τρόπο ώστε τα νευρωνικά δίκτυα να χρησιμοποιηθούν για τον προσδιορισμό των παραμέτρων του ασαφούς συστήματος. Ο κύριος σκοπός μιας νευρωασαφούς προσέγγισης είναι η δημιουργία ή βελτίωση ενός ασαφούς συστήματος αυτόματα, με τη χρήση μεθόδων των νευρωνικών δικτύων. Τα νευρωασαφή συστήματα, τέλος, επιτρέπουν τον ταυτόχρονο συνδυασμό τόσο αριθμητικών όσο και λεκτικών (linguistic) τιμών.

Τα νευρωασαφή συστήματα χωρίζονται σε δύο κύριες κατηγορίες. Στα νευρωνικά-ασαφή συστήματα (που βασίζονται στη χρήση του ασαφούς μηχανισμού εξαγωγής συμπεράσματος) και στα ασαφή-νευρωνικά συστήματα (που ενσωματώνουν την έννοια της ασάφειας στα νευρωνικά δίκτυα. Τα συστήματα αυτής της κατηγορίας αποτελούνται από ένα νευρωνικό και ένα ασαφές σύστημα.)

Νευρωνικά-ασαφή συστήματα (Neural Fuzzy Systems)

Τα συστήματα αυτής της κατηγορίας ενσωματώνουν την παράλληλη αρχιτεκτονική και την ικανότητα εκπαίδευσης σε ασαφή συστήματα εξαγωγής συμπεράσματος. Τα πρώιμα συστήματα αποτελούσαν δίκτυα πολλαπλών στρωμάτων εκπαιδευόμενα με τη μέθοδο της κεκλιμένης καθόδου, ενώ αργότερα παρουσίαζαν αρκετές ομοιότητες με τα δίκτυα RBFN. Για τον σχεδιασμό ενός νευρωνικού-ασαφούς συστήματος απαιτείται σε κάθε περίπτωση, ο καθορισμός της αρχιτεκτονικής και του αλγορίθμου εκπαίδευσης.

Αρχιτεκτονική ενός νευρωνικού-ασαφούς ταξινομητή

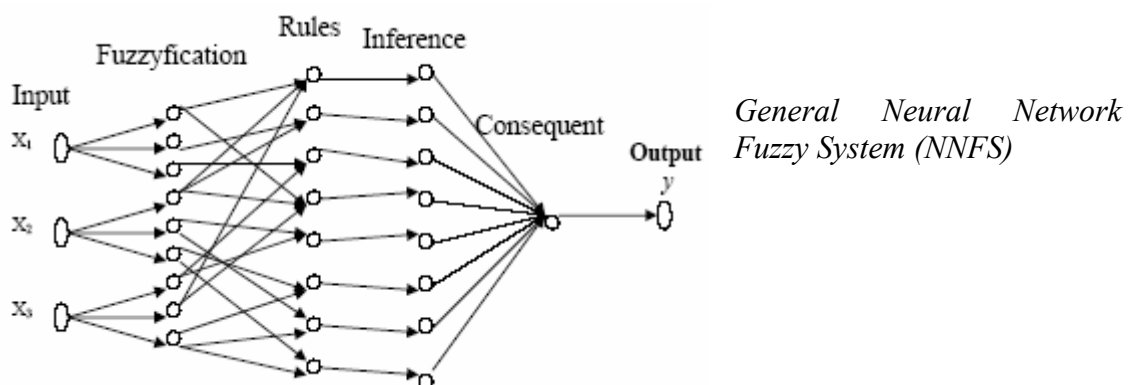
Θεωρώντας ένα σύστημα δύο εισόδων και μιας εξόδου, η ασαφής βάση κανόνων του θα είναι της μορφής:

Rule 1: **IF** x_1 is A_1 **AND** x_2 is B_1 , **THEN** $CLASS$ is 1

Rule 2: **IF** x_2 is A_2 **AND** x_2 is B_2 , **THEN** $CLASS$ is 2

Rule 3: **IF** x_1 is A_1 **AND** x_3 is B_3 , **THEN** $CLASS$ is 1

Η γενική μορφή ενός νευρωνικού-ασαφούς συστήματος είναι εκείνη ενός δικτύου 5 στρωμάτων, κάθε ένα από τα οποία αντιστοιχεί και σε ένα τμήμα του ασαφούς συστήματος:



Στρώμα 1./Ασαφοποίηση

Το πρώτο στρώμα έχει ως εισόδους τα διανύσματα εισόδου του συστήματος δίνοντας στην έξοδο του τις συναρτήσεις συμμετοχής που αντιστοιχούν σε αυτές μετά την ασαφοποίηση τους. Η ασαφοποίηση εφαρμόζεται είτε στο συνολικό διάστημα της εισόδου, είτε σε κάθε μεταβλητή εισόδου χωριστά. Στη δεύτερη περίπτωση π.χ. για κάθε μια εκ των n μεταβλητών εισόδου x_i αντιστοιχεί ένα σύνολο από P_i συναρτήσεις συμμετοχής με μέση τιμή m_p^i και απόκλιση σ_p^i , της μορφής:


$$\mu_{A_p^i}(x_i) = \exp - \left(\frac{x_i - m_p^i}{\sigma_p^i} \right)^2$$

Οι παράμετροι m και σ καθορίζονται εξ αρχής βασιζόμενοι σε διάφορες μεθόδους ταξινόμησης ή εκτιμώνται αργότερα κατά τη διάρκεια της εκπαίδευσης.

Κρυφό στρώμα 2./Σχηματοποίηση προτάσεων των κανόνων

Το δεύτερο στρώμα έχει ως εισόδους τις συναρτήσεις συμμετοχής που σχηματίστηκαν προηγουμένως και ως εξόδους τις «τιμές» ενεργοποίησης των κανόνων. Με άλλα λόγια, σε αυτό το επίπεδο πραγματοποιείται ο

σηματισμός των τμημάτων πρότασης της ασαφούς βάσης κανόνων. Για το τμήμα υπόθεσης του κάθε κανόνα θα έχουμε:



και Rule k : if $(x_1 \text{ is } A_{k1}) \text{ AND } \dots \text{ AND } (x_n \text{ is } A_{kn}) \text{ THEN } \dots$

Κρυφό στρώμα 3./Συμπέρασμα κάθε κανόνα

Το τρίτο στρώμα έχει ως εισόδους τις τιμές ενεργοποίησης των κανόνων δίνοντας ως έξοδο τα αντίστοιχα συμπεράσματα κάθε κανόνα.

Η σύνθεση πραγματοποιείται είτε με τη χρήση του τελεστή Mandani R_c είτε με τον Larsen R_p :


R_c : min operation $\mu_R(x,y) = \mu_A(x) \wedge \mu_B(y)$

R_p : product operation $\mu_R(x,y) = \mu_A(x) \cdot \mu_B(y)$

Οπότε θα έχουμε σχηματοποίηση κανόνων της μορφής:

Rule k : if $x_1 \text{ is } A_{1k} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{nk}$
 THEN $(y \text{ is } B_k)$

Για ένα συγκεκριμένο κανόνα αυτό αποδίδεται γραφικά ως:



$$\text{με } y_k = B'_k = s_k \varphi B_k \quad s_k \longrightarrow \text{circle with } s_k \varphi B_k \longrightarrow B_k$$

Εκτός από τα παραπάνω υπάρχει βέβαια και η προσέγγιση TS (Tagasi-Sugeno), όπου χρησιμοποιούνται crisp τιμές για την έξοδο του κάθε κανόνα:


Rule k : if $x_1 \text{ is } A_{1k} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{nk} \text{ THEN } y = g_k(x_1 \dots x_n)$

Συνήθως, χρησιμοποιείται το γραμμικό μοντέλο, οπότε η έξοδος του k κανόνα θα είναι π.χ.:

$$y_k = a_1 x_1 + a_2 x_2 + a_3 x_3 + a_4$$


Κρυφό Στρώμα 4./Συνολικό συμπέρασμα

Στο στρώμα αυτό υπολογίζεται το συνολικό συμπέρασμα με βάση τα επιμέρους συμπεράσματα των κανόνων του προηγούμενου στρώματος.



Στρώμα Εξόδου/Απο-ασαφοποίηση

Το τελικό αυτό στρώμα του συστήματος δέχεται ως είσοδο το συνολικό συμπέρασμα που προέκυψε ως έξοδος του προηγούμενου στρώματος και δίνει ως έξοδο την αριθμητική (crisp) τιμή που υπολογίζεται με βάση τον απο-ασαφοποιητή COA (ή κάποιον άλλο).




Σημειώνεται ότι τα βάρη του δικτύου είναι πάντοτε ίσα με 1.

Η εκπαίδευση ενός νευρωνικού-ασαφούς συστήματος στοχεύει από τη μια στον προσδιορισμό της δομής του συστήματος (με άλλα λόγια στην εύρεση του κατάλληλου αριθμού κανόνων και στη βέλτιστη κατάτμηση του χώρου εισόδου και εξόδου), και από την άλλη στον υπολογισμό ή εκτίμηση των παραμέτρων του συστήματος. Οι δύο πιο δημοφιλείς αλγόριθμοι που χρησιμοποιούνται για το σκοπό αυτό είναι ο back-propagation (που αποτελεί μια εφαρμογή της μεθόδου κεκλιμένης καθόδου όπως συναντάται στα νευρωνικά δίκτυα) και η προσαρμοστική κβάντιση διανύσματος (adaptive vector quantization).

5.3.1 Ο neural fuzzy ελεγκτής FALCON

Χαρακτηριστικό δείγμα της κατηγορίας των νευρωνικών-ασαφών δικτύων αποτελεί το προσαρμοζόμενη εκπαίδευσης ασαφές

δίκτυο ελέγχου (Fuzzy Adaptive Learning Control Network ή **FALCON**). Το συγκεκριμένο δίκτυο αποτελεί ένα μονοκατευθυντικό τροφοδοτούμενο δίκτυο (feed-forward network) που ενσωματώνει τα βασικά στοιχεία και συναρτήσεις ενός παραδοσιακού ασαφούς ελεγκτή σε μια συνδυαστική δομή που έχει κατανομημένες ικανότητες εκμάθησης.



Οι κόμβοι στο στρώμα 1 είναι οι κόμβοι εισόδου και το στρώμα 5 αποτελεί το στρώμα εξόδου. Οι κόμβοι στο πρώτο στρώμα απλά μεταδίδουν τις τιμές εισόδου στο επόμενο στρώμα απευθείας. Στο δεύτερο στρώμα, αντιστοιχίζονται σε κάθε μεταβλητή ένα σύνολο από κόμβους, καθένας από τους οποίους δίνει ως έξοδος μια συνάρτηση συμμετοχής. Οι κόμβοι του 3^{ου} στρώματος επιτελούν το σχηματισμό των προτάσεων κάθε ασαφούς κανόνα. Οι κόμβοι του 4^{ου} στρώματος έχουν δύο λειτουργίες. Την λειτουργία μετάδοσης προς τα επάνω, όπου οι σύνδεσμοι στο 4^ο στρώμα εκτελούν την OR πράξη ώστε να ενσωματώσουν τους ενεργοποιημένους κανόνες που έχουν το ίδιο συμπέρασμα και την λειτουργία μετάδοσης προς τα κάτω, όπου οι κόμβοι αυτού του επιπέδου και οι σύνδεσμοι στο 5^ο στρώμα λειτουργούν κατά τον ίδιο τρόπο όπως εκείνο στο 2^ο στρώμα με τη διαφορά ότι ένας μόνος κόμβος χρησιμοποιείται για το σχηματισμό της συνάρτησης συμμετοχής των λεκτικών μεταβλητών εξόδου. Τέλος στο 5^ο στρώμα υπάρχουν επίσης δύο ειδών κόμβοι: ο πρώτος εκτελεί τη λειτουργία από πάνω προς τα κάτω για την εκπαίδευση των δεδομένων που εισέρχονται στο δίκτυο, ενώ ο δεύτερος εκτελεί τη λειτουργία από κάτω προς τα πάνω για την «απόφαση» του σήματος εξόδου. Αυτοί οι κόμβοι και οι προσαρτημένοι σε αυτούς δεσμοί του 5^{ου} στρώματος ενεργούν ως ο αποασαφοποιητής.

Για την εκτίμηση των συναρτήσεων συμμετοχής χρησιμοποιείται ο αλγόριθμος Kohonen, οπότε γίνεται λόγος για μια εκπαίδευση αυτοοργάνωσης (self-organized learning phase). Μετά από τον

προσδιορισμό αυτών των συναρτήσεων ακολουθεί ο υπολογισμός των παραμέτρων τους, βασιζόμενος πλέον σε επιτηρούμενη εκπαίδευση με χρήση του αλγορίθμου ανάστροφης διάδοσης (back-propagation). [53]

5.3.2 Εκπαίδευση του *FALCON*

Αναφορικά με την εκπαίδευση του δικτύου χρησιμοποιείται ένας υβριδικός αλγόριθμος εκπαίδευσης που συνδυάζει μια μη επιτηρούμενη εκπαίδευση με επιτηρούμενες τεχνικές κεκλιμένης καθόδου, για τον προσδιορισμό των συναρτήσεων συμμετοχής και κανόνων και την συνεπακόλουθη εκπαίδευση τους με στόχο την ρύθμιση των παραμέτρων των συναρτήσεων.

Εκπαίδευση αυτοοργάνωσης [53]

Το ζητούμενο στη συγκεκριμένη περίπτωση έχει να κάνει με το γεγονός ότι, δοθέντος του συνόλου των δεδομένων εισόδου ($x_i(t)$, $i=1,2,...,n$) και των αντίστοιχων επιθυμητών τιμών εξόδου ($y_i^d(t)$, $i=1,2,...,n$), των ασαφών καταταμίσεων εισόδου και εξόδου ($|T(x_i)|$ και $|T(y_i)|$ αντίστοιχα) καθώς και των επιθυμητών μορφών για τις συναρτήσεις συμμετοχής, επιθυμούμε τον προσδιορισμό αυτών των συναρτήσεων συμμετοχής και εύρεση των ασαφών κανόνων.

Αρχικά προσδιορίζονται τα κέντρα και οι διασπορές των συναρτήσεων συμμετοχής μέσω τεχνικών εκμάθησης αυτοοργάνωσης. Οι χώροι ορισμού των συναρτήσεων διαμορφώνονται έτσι ώστε να καλύπτουν τις περιοχές εύρους των τιμών εισόδου και εξόδου. Ο αλγόριθμος Kohonen χρησιμοποιείται για την εύρεση του κέντρου m_i της i συνάρτησης συμμετοχής του x , όπου το x δηλώνει οποιαδήποτε από τις λεκτικές μεταβλητές εισόδου ή εξόδου $x_1, ..., x_n$ ή $y_1, ..., y_n$:

$$\|x(t) - m_{closest}(t)\| = \min_{1 \leq i \leq k} \|x(t) - m_i(t)\|$$

$$m_{closest}(t+1) = m_{closest}(t) + a(t)[x(t) - m_{closest}(t)]$$

$$m_i(t+1) = m_i(t), \quad \text{for } m_i \neq m_{closest}$$

, όπου $a(t)$ είναι ένας μονοτονικά φθίνοντας βαθμωτός δείκτης εκμάθησης και $k=[T(x)]$.

Μόλις βρεθούν τα κέντρα των συναρτήσεων συμμετοχής, οι διασπορές τους μπορούν να προσδιοριστούν μέσα από μια τεχνική N-*nn* (N nearest neighbors), στοχεύοντας στην ελαχιστοποίηση της ακόλουθης αντικειμενικής συνάρτησης με αναφορά στις διασπορές σ_i :

$$E = \frac{1}{2} \sum_{i=1}^N \left[\sum_{j \in N_{nearest}} \left(\frac{m_i - m_j}{\sigma_i} \right)^2 - r \right]^2, \quad \text{όπου } r \text{ είναι ένας παράγοντας}$$

επικάλυψης.

Μόλις βρεθούν οι παράμετροι των συναρτήσεων συμμετοχής, τα σήματα και από τις δύο εξωτερικές πλευρές του δικτύου μπορούν να φθάσουν τα σημεία εξόδου των κόμβων στα στρώματα 2 και 4. Επιπρόσθετα, οι εξόδοι των κόμβων στο 2^ο στρώμα μπορούν να διαδοθούν στους κόμβους των κανόνων διαμέσου των αρχικών συνδέσεων του στρώματος 3. Έτσι επιτυγχάνεται η τιμή ενεργοποίησης του κάθε κόμβου κανόνα. Βασιζόμενοι σε αυτές τις τιμές ενεργοποίησης (δηλώνονται ως $o_i^{(3)}(t)$) και τις εξόδους των κόμβων στο 4^ο στρώμα (δηλώνονται ως $o_j^{(4)}(t)$), στοχεύουμε στον προσδιορισμό των τμημάτων συνέπειας για τον κάθε κανόνα με αποτέλεσμα την τελική εύρεση των ασαφών κανόνων μέσα από ανταγωνιστικούς αλγορίθμους εκμάθησης (*competitive learning algorithms*). Θεωρώντας το δεσμό ανάμεσα στον i-οστό κόμβο κανόνα και τον j-οστό κόμβο εξόδου με βάρος σύνδεσης w_{ij} , ο ακόλουθος κανόνας στοχεύει στην ανανέωση των βαρών για κάθε σύνολο εκπαίδευσης $w_{ij}(t) = o_j^{(4)}(-w_{ij} + o_i^{(3)})$, όπου το $o_j^{(4)}$ δέχεται τις τιμές 0/1. Μετά το πέρασμα ολόκληρου του συνόλου εκπαίδευσης, τα βάρη των συνδέσεων αντιπροσωπεύουν τη «δύναμη» της ύπαρξης του τμήματος συνέπειας κάθε κανόνα. Από τους δεσμούς εκείνου που συνδέουν έναν κόμβο κανόνα και τους κόμβους μιας λεκτικής μεταβλητής εξόδου, επιλέγεται το πολύ ένας δεσμός (εκείνος με τη μέγιστη τιμή). Έτσι, ένας μονάχα από τους κόμβους μιας λεκτικής μεταβλητής μπορεί να γίνει ένας από τα τμήματα συνέπειας ενός κανόνα. Μετά τον προσδιορισμό των τμημάτων συνέπειας των κανόνων, ακολουθεί μια διαδικασία ελάττωσης του αριθμού των κανόνων βασιζόμενη σε διάφορα κριτήρια συγχώνευσης ενός συνόλου από κανόνες σε έναν εφόσον έχουν ακριβώς τα ίδια τμήματα συνέπειας και τα τμήματα υπόθεσης είναι κοινά σε όλους τους κόμβους των κανόνων στο σύνολο.

Επιτηρούμενη εκπαίδευση [53]

Μόλις προσδιοριστούν οι κανόνες (και άρα η συνολική δομή του δικτύου), χρησιμοποιώντας εκ νέου το σύνολο εκπαίδευσης βρίσκονται οι βέλτιστοι παράμετροι που αντιστοιχούν στις συναρτήσεις συμμετοχής εισόδου και εξόδου. Για το σκοπό της εκπαίδευσης χρησιμοποιείται ο αλγόριθμος της ανάστροφης διάδοσης προς τα πίσω (back propagation), με στόχο την ελαχιστοποίησης μιας συνάρτησης σφάλματος

$$E = \frac{1}{2} (y^d(t) - y(t))^2 \quad (5.1)$$

Θεωρώντας ότι σε κόμβο η παράμετρος προς ρύθμιση είναι η w (που δηλώνει τα κέντρα και τις διασπορές των συναρτήσεων συμμετοχής και σ_{ij} αντίστοιχα) ο γενικός κανόνας εκπαίδευσης θα είναι της μορφής:

$$\Delta w \in -\frac{\partial E}{\partial W}, w(t+1) = w(t) + \eta \left(-\frac{\partial E}{\partial W} \right) \quad (5.2), \text{ όπου } \eta, \text{ ο ρυθμός εκπαίδευσης}$$

και

$$\frac{\partial E}{\partial W} = \frac{\partial E}{\partial(\text{activation function})} \cdot \frac{\partial(\text{activation function})}{\partial w} = \frac{\partial E}{\partial a} \cdot \frac{\partial a}{\partial w}. \quad (5.3)$$

Ακολουθεί η αναλυτική παρουσίαση της διαδικασίας εκπαίδευσης στρώμα προς στρώμα του δικτύου, αρχίζοντας με τους κόμβους εξόδου και χρησιμοποιώντας Gaussian συναρτήσεις με κέντρα m_i και διασπορές σ_i (θεωρείται η περίπτωση της μιας εξόδου).

Στρώμα 5.

Η αποασαφοποιημένη έξοδος του δικτύου θα δίνεται από τη σχέση

$$a = \frac{\sum_i (m_i \sigma_i) u_i^{(5)}}{\sum_i \sigma_i u_i^{(5)}} \quad (5.4).$$

Χρησιμοποιώντας τις (5.3) και (5.4) ο προσαρμοστικός κανόνας για το κέντρο m_i προκύπτει: $\frac{\partial E}{\partial m_i} = \frac{\partial E}{\partial a^{(5)}} \cdot \frac{\partial a^{(5)}}{\partial m_i} = -[y^d(t) - y(t)] \frac{\sigma_i u_i^{(5)}}{\sum_i \sigma_i u_i^{(5)}}$, όπου

$a^{(5)}(t)$ η έξοδος του δικτύου $y(t)$. Έτσι, ο κανόνας ανανέωσης για την παράμετρο του κέντρου θα είναι: $m_i(t+1) = m_i(t) + \eta [y^d(t) - y(t)] \frac{\sigma_i u_i^{(5)}}{\sum_i \sigma_i u_i^{(5)}}$.

Ανάλογα προκύπτει και για την παράμετρο σ_i η σχέση ανανέωσης:

$$\sigma_i(t+1) = \sigma_i(t) + \eta [y^d(t) - y(t)] \frac{m_i u_i^{(5)} \left(\sum_i \sigma_i u_i^{(5)} \right) - \left(\sum_i m_i \sigma_i u_i^{(5)} \right) u_i^{(5)}}{\left(\sum_i \sigma_i u_i^{(5)} \right)^2}.$$

Το σφάλμα διάδοσης προς τα πίσω θα είναι:

$$\delta^{(5)} = -\frac{\partial E}{\partial a^{(5)}} = -\frac{\partial E}{\partial y} = y^d(t) - y(t) \quad (5.5)$$

Στρώμα 4.

Στην μετάδοση από κάτω προς τα πάνω δεν υπάρχει παράμετρος για να ρυθμιστεί. Μόνο το σήμα του σφάλματος ($\delta_i^{(4)}$) χρειάζεται να υπολογιστεί και να διαδοθεί. Το $\delta_i^{(4)}$ προκύπτει ως:

$$\delta_i^{(4)} = -\frac{\partial E}{\partial a^{(4)}} = -\frac{\partial E}{\partial u_i^{(5)}} = -\frac{\partial E}{\partial a^{(5)}} \cdot \frac{\partial a^{(5)}}{\partial u_i^{(5)}}, \text{ οπότε από την (5.4) καταλήγουμε}$$

$$\text{στην: } \delta_i^{(4)}(t) = [y^d(t) - y(t)] \frac{m_i \sigma_i \left(\sum_i \sigma_i u_i^{(5)} \right) - \left(\sum_i m_i \sigma_i u_i^{(5)} \right) \sigma_i}{\left(\sum_i \sigma_i u_i^{(5)} \right)^2}$$

Στρώμα 3.

Και σε αυτό το στρώμα απαιτείται μονάχα ο υπολογισμός των σημάτων σφάλματος. Έτσι, θα έχουμε $\delta_i^{(3)} = -\frac{\partial E}{\partial a_i^{(3)}} = -\frac{\partial E}{\partial a_i^{(4)}} \frac{\partial a_i^{(4)}}{\partial u_i^{(4)}} = -\frac{\partial E}{\partial a_i^{(4)}} = \delta_i^{(4)}$ (5.6)

Στρώμα 2.

Η έξοδος ενός κόμβου στο στρώμα 2 θα δίνεται από τη σχέση $a = e^f$, όπου $f = -\frac{(u_i^{(2)} - m_{ij})^2}{\sigma_{ij}^2}$ (5.7), ενώ η είσοδος ενός κόμβου του στρώματος 3 εκτελεί την πράξη AND έτσι ώστε η έξοδος του να είναι $\alpha = \min(u_1^{(3)}, u_2^{(3)}, \dots, u_p^{(3)})$ (5.8).

Ο κανόνας ανανέωσης για την m_{ij} με βάση τις (5.3) και (5.7) θα είναι $\frac{\partial E}{\partial m_{ij}} = \frac{\partial E}{\partial a_i^{(2)}} \frac{\partial a_i^{(2)}}{\partial m_{ij}} = \frac{\partial E}{\partial a_i^{(2)}} e^{f_i} \frac{2(u_i^{(2)} - m_{ij})}{\sigma_{ij}^2}$, όπου $\frac{\partial E}{\partial a_i^{(2)}} = \frac{\partial E}{\partial u_i^{(3)}} = \frac{\partial E}{\partial a_i^{(3)}} \frac{\partial a_i^{(3)}}{\partial u_i^{(3)}}$, - από (5.6)- $\frac{\partial E}{\partial a_i^{(3)}} = -\delta_i^{(3)}$ και - από (5.8)- $\frac{\partial a_i^{(3)}}{\partial u_i^{(3)}} = \begin{cases} 1 & \text{if } u_i^{(3)} = \min(\text{inputs of rule node } i) \\ 0 & \text{otherwise} \end{cases}$


Άρα, $\frac{\partial E}{\partial a_i^{(2)}} \hat{=} \delta_i^{(2)} = \sum_k q_k$, όπου η άθροιση πραγματοποιείται μέσω των κόμβων των κανόνων που τροφοδοτεί η $a_i^{(2)}$ και $q_k = \begin{cases} -\delta_k^{(3)} & \text{if } a_i^{(2)} \text{ is minimum in } k\text{th rule nodes' inputs} \\ 0 & \text{otherwise} \end{cases}$

Ο κανόνας ανανέωσης τότε θα είναι $m_{ij}(t+1) = m_{ij}(t) + \eta \delta_i^{(2)} e^{f_i} \frac{2(u_i^{(2)} - m_{ij})}{\sigma_{ij}^2}$.

Με ακριβώς ανάλογο τρόπο προκύπτει η σχέση ανανέωσης για την $\sigma_{ij}(t+1) = \sigma_{ij}(t) + \eta \delta_i^{(2)} e^{f_i} \frac{2(u_i^{(2)} - m_{ij})^2}{\sigma_{ij}^3}$

5.4 Το δίκτυο ANFIS

Υποπερίπτωση του δικτύου FALCON αποτελεί το προσαρμοζόμενο σύστημα ασαφούς εξαγωγής συμπερασμάτων (adaptive-network fuzzy inference system ή ANFIS), το οποίο και θα χρησιμοποιηθεί στην παρούσα εργασία με σκοπό την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου.



Σχήμα 5.4.1

Το μοντέλο αυτό μοιάζει με εκείνο που παρουσιάστηκε στην αρχή της ενότητας με τη μόνη διαφορά ότι υπάρχει ένα επιπλέον στρώμα για την κανονικοποίηση των τιμών ενεργοποίησης των κανόνων. Οι συναρτήσεις συμμετοχής για κάθε μεταβλητή προσδιορίζονται ευρυστικά και ως τελεστής AND χρησιμοποιείται το γινόμενο. Τα δίκτυα ANFIS, αφορούν την περίπτωση εκείνη όπου ο αριθμός κανόνων είναι γνωστός εξ αρχής, στοχεύοντας ουσιαστικά μέσω της διαδικασίας εκπαίδευσης στον προσδιορισμό των παραμέτρων αυτών των συναρτήσεων. Για την εκπαίδευση του δικτύου χρησιμοποιείται είτε ο αλγόριθμος back-propagation (όπως περιγράφηκε στην προηγούμενη ενότητα) αυτόνομα, είτε σε συνδυασμό με μια εκτίμηση ελαχίστων τετραγώνων.

Ας θεωρήσουμε για παράδειγμα την περίπτωση ενός ασαφούς συστήματος ελέγχου με δύο εισόδους x_1, x_2 και μια έξοδο y , του οποίου η ασαφής βάση κανόνων περιέχει δύο TSK (Takagi-Sugeno-Kang) κανόνες όπως οι ακόλουθοι:


$$R^1 : IF \ x_1 \text{ is } A_1^1 \text{ AND } x_2 \text{ is } A_2^1 \text{ THEN } y = f_1 = a_0^1 + a_1^1 x_1 + a_2^1 x_2$$

$$R^2 : IF \ x_1 \text{ is } A_1^2 \text{ AND } x_2 \text{ is } A_2^2 \text{ THEN } y = f_2 = a_0^2 + a_1^2 x_1 + a_2^2 x_2$$

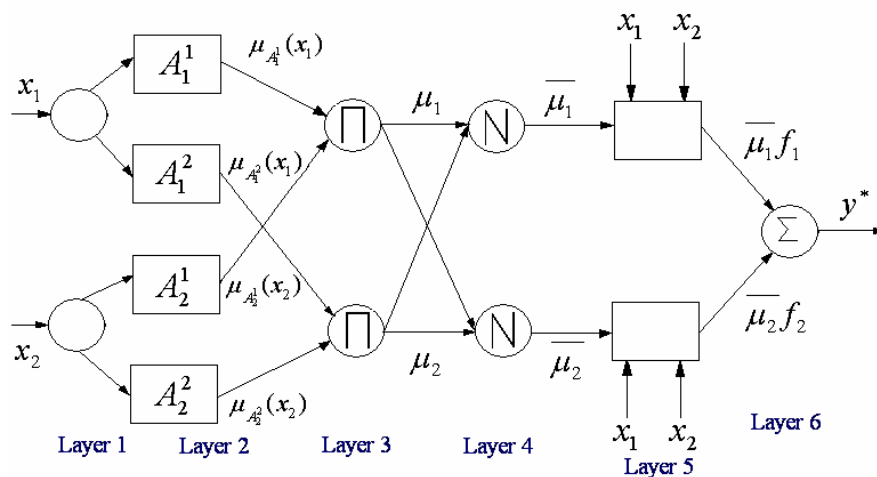
Για δύο δοσμένες τιμές εισόδου x_1, x_2 , η έξοδος y^* θα δίνεται ως εξής:

$$y^* = \frac{\mu_1 f_1 + \mu_2 f_2}{\mu_1 + \mu_2}, \text{ όπου } \mu_1, \mu_2 \text{ οι τιμές ενεργοποίησης των κανόνων } R^j, j=1,2$$

που θα δίνονται ως $\mu_j = \mu_{A_1^j}(x_1) \cdot \mu_{A_2^j}(x_2), j=1,2$. [53]



Σχήμα 5.4.2 Σύστημα εξαγωγής συμπεράσματος, ANFIS



Σχήμα 5.4.3 Δομή του δικτύου ANFIS

Η δομή του παραπάνω δικτύου, συνοπτικά, θα έχει ως εξής:

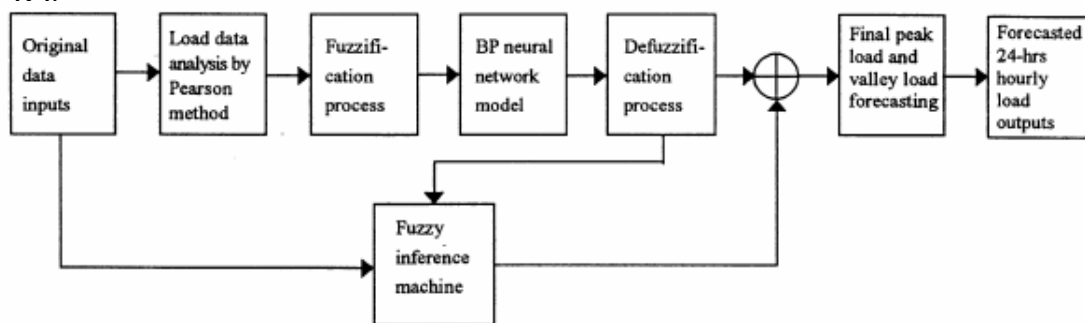
- ❖ **Στρώμα 1.** Κάθε κόμβος σε αυτό το επίπεδο είναι ένας κόμβος εισόδου που μεταφέρει εξωτερικά σήματα προς το επόμενο στρώμα.
- ❖ **Στρώμα 2.** Κάθε κόμβος σε αυτό το επίπεδο δρα ως μια συνάρτηση συμμετοχής $\mu_{A_i^j}(x_i)$ της οποίας η έξοδος προσδιορίζει τον βαθμό στον οποίο το δοσμένο x_i ικανοποιεί το A_i^j .
- ❖ **Στρώμα 3.** Κάθε κόμβος σε αυτό το επίπεδο συμβολίζεται με Π και πολλαπλασιάζει τα σήματα εισόδου, επιτελώντας το ρόλο του τελεστή AND.
- ❖ **Στρώμα 4.** Κάθε κόμβος σε αυτό το επίπεδο συμβολίζεται με N και υπολογίζει τις κανονικοποιημένες τιμές ενεργοποίησης κάθε κανόνα.

- ❖ **Στρώμα 5.** Κάθε κόμβος σε αυτό το επίπεδο υπολογίζει τη ζυγισμένη τιμή του τμήματος συνέπειας $\overline{\mu_j}(\alpha_o^j + \alpha_1^j x_1 + \alpha_2^j x_2)$, όπου $\overline{\mu_j}$ η έξοδος του 4^{ου} επιπέδου και $\{\alpha_o^j, \alpha_1^j, \alpha_2^j\}$ οι παράμετροι που πρέπει να υπολογιστούν.
- ❖ **Στρώμα 6.** Ο μοναδικός κόμβος σε αυτό το επίπεδο συμβολίζεται με Σ και αθροίζει όλα τα εισερχόμενα σήματα, δίνοντας την αποασαφοποιημένη τελική τιμή εξόδου για το σύστημα.
- ✓ Όλα τα παραπάνω ισχύουν βέβαια για κάθε δίκτυο ANFIS, με οποιοδήποτε πλήθος εισόδων και κανόνων.

5.5 Εφαρμογές των νευροασαφών συστημάτων στην πρόβλεψη φορτίου.

Οι R.Liang και C.Cheng, στη μελέτη τους με τίτλο “*Short-term load forecasting by a neuro-fuzzy approach*” [54] συνδυάζουν ένα νευρωνικό δίκτυο με ένα ασαφές σύστημα με στόχο την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου. Η διαδικασία της πρόβλεψης περιλαμβάνει δύο μέρη. Ένα μοντέλο πρόβλεψης των ακραίων (max και min) τιμών κάθε μέρας και ένα μοντέλο πρόβλεψης των 24 ωρών της επόμενης μέρας. Επειδή εν προκειμένω τα προβλεπόμενα ωριαία φορτία εξαρτώνται από τις ακραίες τιμές, όταν υπολογισθούν οι ακραίες αυτές τιμές το σφάλμα των προβλεπόμενων ωριαίων τιμών του φορτίου μπορεί να ελαττωθεί.

Η διαδικασία που ακολουθήθηκε παριστάνεται γραφικά στο ακόλουθο σχήμα.




Σχήμα 5.5.1

α.) Τα δεδομένα εισόδου του συστήματος (μέγιστες και ελάχιστες τιμές του φορτίου για κάθε μέρα) ταξινομούνται σε δύο ομάδες, σε αυτά που ανήκουν στις καθημερινές και σε εκείνα του σαββατοκύριακου. Επίσης

χρησιμοποιούνται οι μέγιστες και ελάχιστες τιμές της θερμοκρασίας κάθε ημέρας ως επιπρόσθετες μεταβλητές εισόδου. Ακολουθεί μια ανάλυση των δεδομένων του φορτίου βασιζόμενη στη μέθοδο ανάλυσης Pearson [56] με στόχο την προσεκτική επιλογή των προηγούμενων προτύπων φορτίου για τη μέρα πρόβλεψης ώστε να επιτευχθεί η καλύτερη δυνατή εκπαίδευση του δικτύου. Η μέθοδος Pearson είναι μια διαδικασία για την «απόφαση» της σχέσης ανάμεσα σε μια αντικειμενική τιμή και τους παράγοντες που την επηρεάζουν. Οι σχετικοί βαθμοί αυτών των παραγόντων στην αντικειμενική τιμή μπορούν να χρησιμοποιηθούν ως αναφορά για την επιλογή των μεταβλητών εισόδου. Μια υψηλή τιμή σχετικότητας σημαίνει μια καλύτερη σχέση ανάμεσα στην αντικειμενική τιμή και τους αντίστοιχους παράγοντες επηρεασμού.

β.) Ακολουθεί η διαδικασία ασαφοποίησης όπου οι επιλεγόμενες με βάση τη μέθοδο ανάλυσης Pearson είσοδοι και οι σχετιζόμενες με αυτές θερμοκρασίες (παρελθοντικές και προβλεπόμενες) ασαφοποιούνται με τη χρήση τριγωνικών συναρτήσεων συμμετοχής που διαιρούν το διάστημα υποστήριξης κάθε μιας σε τρία σύνολα, με κανονικοποιημένες τις τιμές για τα φορτία.



Κάθε ασαφές σύνολο παριστάνεται από την τιμή συμμετοχής του και αυτοί οι πραγματικοί αριθμοί στέλνονται στο νευρωνικό δίκτυο για εκπαίδευση και δοκιμή.

γ.) Για την πρόβλεψη της μέγιστης και ελάχιστης τιμής του φορτίου της επόμενης ημέρας χρησιμοποιούνται δύο διαφορετικά δίκτυα, ένα για κάθε περίπτωση. Συγκεκριμένα για την πρόβλεψη του μέγιστου φορτίου χρησιμοποιούνται ζεύγη εισόδων-εξόδων της μορφής : $[P_{1,peak}, P_{2,peak}, T_{d-1,high}, T_{d-2,high}, FT_{d,high}, target\ output]$, όπου $P_{1,peak}$ και $P_{2,peak}$ οι δύο παρελθοντικές max τιμές του φορτίου, $T_{d-1,high}$ και $T_{d-2,high}$ οι δύο παρελθοντικές τιμές για τη θερμοκρασία και $FT_{d,high}$ η προβλεπόμενη τιμή φορτίου της επόμενης μέρας.. Ανάλογα και για την πρόβλεψη του ελάχιστου φορτίου. Το νευρωνικό δίκτυο σε κάθε περίπτωση είναι ένα feed-forward δίκτυο τριών στρωμάτων.

δ.) Στο επόμενο στάδιο ακολουθεί η από-ασαφοποίηση των ασαφών τιμών εξόδου των νευρωνικών δικτύων που αναφέρθηκαν πριν και οι οποίες κυμαίνονται στο διάστημα $[0,1]$, με χρήση

εξισώσεων της μορφής
$$L_p' = L_{p,min} + L_{pn}'(L_{p,max} - L_{p,min})$$
, όπου L_{pn}' και L_{vn}' οι
$$L_v' = L_{v,min} + L_{vn}'(L_{v,max} - L_{v,min})$$

έξοδοι των προηγούμενων νευρωνικών δικτύων.

ε.) Η ασαφής μηχανή εξαγωγής συμπερασμάτων στοχεύει στην ελαχιστοποίηση του σφάλματος ανάμεσα στις πραγματικές και προβλεπόμενες τιμές του φορτίου, χρησιμοποιώντας τους ακόλουθους κανόνες:

Rule1: IF ΔT is NS and ΔP_{ave} is NS, THEN Z is NS.

Rule2: IF E_{d-1} is PS, THEN Z is PS.

E_{d-1} : το σφάλμα στην πρόβλεψη της προηγούμενης μέρας, ΔT : η διαφορά ανάμεσα στην προβλεπόμενη τιμή της θερμοκρασίας και εκείνη της προηγούμενης μέρας, ΔP_{ave} : η μέση διακύμανση της τάσης του φορτίου.

Η πραγματική τιμή για κάθε κανόνα δίνεται από τις σχέσεις:

$$\alpha_1 = \mu_{NS}(\Delta T) \wedge \mu_{NS}(\Delta P_{ave}).$$

$\alpha_2 = \mu_{PS}(E_{d-1})$, όπου $\mu_{NS}(\Delta T)$ είναι η τιμή συμμετοχής του ΔT στο NS (negative set, ένα εκ των πέντε συνόλων αναφοράς που χρησιμοποιούνται· τα άλλα είναι τα NL(negative large), zero(ZE), positive small(PS), positive large(PL)).

Με βάση τα παραπάνω το τελικό αποτέλεσμα είναι ένα ασαφές σύνολο που μπορεί να απο-ασαφοποιηθεί, παίρνοντας έτσι για την crisp τιμή της

$$\text{εξόδου } E_d: E_d = \frac{\alpha_1 Z + \alpha_2 Z}{\alpha_1 + \alpha_2}$$

στ.) Οι τελικές προβλεπόμενες τιμές των μέγιστων και ελαχίστων τιμών για κάθε φορτίο προκύπτουν ίσες με:

$L_p'' = L_p' + E_p$ και $L_v'' = L_v' + E_v$. (E_p και E_v είναι οι crisp τιμές των δυο νευρωνικών δικτύων)

ζ.) Έχοντας υπολογισθεί στο προηγούμενο στάδιο οι μέγιστες και ελάχιστες τιμές φορτίου της επόμενης ημέρας ακολουθείται ο υπολογισμός του φορτίου κάθε ώρας για την ημέρα αυτή που γίνεται ως εξής:

Για το σκοπό αυτό έχει σχηματισθεί μια 24ωρη βάση δεδομένων για τον προσδιορισμό εκείνων των ημερών που έχουν παρόμοια ωριαία πρότυπα φορτίου και ανήκουν στον ίδιο τύπο μέρας με τη συλλογή 24 ωριαίων φορτίων $L(t), t=1,2,\dots,24$. Αυτά τα ωριαία φορτία αρχικά κανονικοποιούνται με βάση τη σχέση $L_n(t) = \frac{L(t) - L_{dv}}{L_{dp} - L_{dv}}$, $t = 1, 2, \dots, 24$


Έτσι προκύπτει το διάνυσμα $L_n' = [L_n'(1), L_n'(2), \dots, L_n'(24)]^T$, όπου $L_n'(t)$ το μέσο κανονικοποιημένο φορτίο τη χρονική στιγμή t .

Τελικά οι τιμές του φορτίου $L'(t)$ για τις επόμενες 24 ώρες που επιθυμούμε να προβλέψουμε δίνονται από τη σχέση:

$$L'(t) = L_v'' + L_n'(t)(L_p'' - L_v''), \quad t = 1, 2, \dots, 24,$$

Επίσης, οι M.Vellasco, M.Pacheco, L.Neto, F.Souza στη μελέτη τους με τίτλο “*Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model*” [55] προτείνουν ένα υβριδικό νευροασαφές μοντέλο το HNFB για την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου ανά ώρα.

Αρχικά εισάγεται η έννοια της δυαδικής κατάτμησης χώρου (binary space partitioning, εφεξής BSP) κατά την οποία ο χώρος διαιρείται αναδρομικά σε δύο περιοχές.

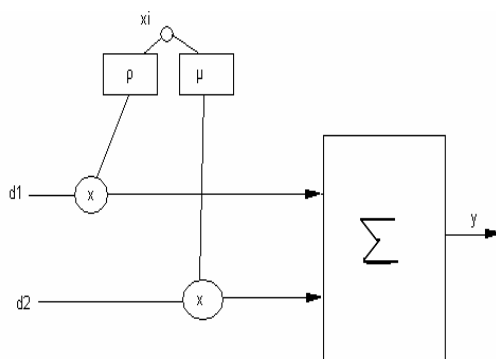


Παράδειγμα κατάτμησης του δισδιάστατου χώρου των μεταβλητών x_1, x_2 .

Το HNBF (hierarchical Neuro-Fuzzy BSP) κελί είναι ένα μίνι νευροασαφές σύστημα που πραγματοποιεί μια κατάτμηση BSP του χώρου εισόδου και δημιουργεί μια crisp τιμή στην έξοδο μετά από μια διαδικασία από-ασαφοποίησης. Θεωρώντας έτσι ένα σύστημα δύο κανόνων της μορφής: Rule 1. *If $x \in \rho$ then $y = d_1$*

Rule 2. *If $x \in \mu$ then $y = d_2$*

κάθε κανόνας θα ανταποκρίνεται σε μία από τις δύο κατατμήσεις που δημιουργούνται από την BSP κατάτμηση.



Διάγραμμα ενός BSP κελιού, του οποίου η έξοδος $y = \rho(x)xd_1 + \mu(x)xd_2$, όπου τα d_i είναι γενικά είτε σταθερές τιμές, είτε ένας γραμμικός συνδυασμός των εισόδων είτε η έξοδος ενός προηγούμενου σταδίου. Οι $\rho(x)$ και $\mu(x)$ αποτελούν συναρτήσεις συμμετοχής.

Σχήμα 5.5.2

Ένα HNFB σύστημα αποτελείται από ένα σύνολο από HNFB κελιά συνδεδεμένα μεταξύ τους. Η εκπαίδευση ενός τέτοιου δικτύου βασίζεται στη μέθοδο της κεκλιμένης καθόδου. Οι παράμετροι που καθορίζουν τις συναρτήσεις συμμετοχής των τμημάτων υπόθεσης και συνέπειας του κάθε κανόνα θεωρούνται ως τα ασαφή βάρη του συστήματος αυτού.

Αρχικά χρησιμοποιούνται διάφορα νευρωνικά δίκτυα διαφορετικών τοπολογιών αναφορικά με τις εισόδους τους όπου και προκύπτει ένα σύνολο από διάφορες τιμές σχετικά με τα σφάλματα πρόβλεψης. Στη συνέχεια παρουσιάζονται τα αποτελέσματα των δοκιμών με χρήση πλέον του προτεινόμενου HNFB συστήματος. Το συγκεκριμένο αυτό σύστημα πραγματοποιεί εσωτερικά μια κανονικοποίηση των εισόδων, γεγονός που ελαχιστοποιεί το πλήθος των απαιτούμενων εισόδων. Ένα διαφορετικό σύστημα χρησιμοποιήθηκε χωριστά για κάθε μέρα της εβδομάδας. Στο τέλος της ενότητας παρουσιάζεται, τέλος, ένα υβριδικό νευρωνικό και νευρωσαφές δίκτυο, όπου το μεν νευρωνικό δίκτυο χρησιμοποιείται για την πρόβλεψη των μελλοντικών ωριαίων τιμών του φορτίου και το νευρωσαφές σύστημα (επιλέχθηκε το HNFB) χρησιμοποιείται για τη ρύθμιση των αποτελεσμάτων της πρόβλεψης.

Οι προβλέψεις των αποτελεσμάτων σε κάθε περίπτωση ήταν σε του τύπου 24-βήματα (ώρες) προς τα εμπρός. Τα αποτελέσματα ήταν καλύτερα στην πλειοψηφία των περιπτώσεων με χρήση του προτεινόμενου HSFP μοντέλου.

Ακολούθως, οι Σ.Παπαδάκης, Ι.Θεοχάρης και Α.Μπακιρτζής στη μελέτη με τίτλο “*A load curve based fuzzy modeling technique for short-term load forecasting*” [52], ασχολούνται με την εφαρμογή fuzzy μοντέλων στην βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Η διαδικασία σχηματισμού του βέλτιστου μοντέλου πρόβλεψης διαιρείται σε 3 στάδια : Αρχικά, επιτυγχάνεται ο προσδιορισμός της δομής του μοντέλου βασιζόμενος σε μια μέθοδο ασαφούς C-παλινδρόμησης, ακολουθεί η επιλογή των κατάλληλων εισόδων για το μοντέλο με τη βοήθεια της χρήσης ενός μηχανισμού που βασίζεται στους γενετικούς αλγορίθμους και τέλος γίνεται η ρύθμιση των παραμέτρων με τη χρήση ενός υβριδικού γενετικού, ελαχίστων τετραγώνων αλγορίθμου.

Για τους παραπάνω σκοπούς θεωρείται ένα ασαφές μοντέλο με γενικευμένους TSK (Takagi-Sugeno-Kang) κανόνες. Έστω ότι το φορτίο της k-ης μέρας δίνεται από τη σχέση $LC_k = [L_k(1), \dots, L_k(24)]^T$. Η καμπύλη φορτίου του Ελληνικού διασυνδεδεμένου συστήματος χαρακτηρίζεται από 4 ακραία φορτία (το ελάχιστο του πρωινού $L_{\min1,k}(h_{\min1,k})$ το μέγιστο του μεσημεριού $L_{\max1,k}(h_{\max1,k})$, το ελάχιστο του μεσημεριού $L_{\min2,k}(h_{\min2,k})$ και το μέγιστο του απογεύματος $L_{\max2,k}(h_{\max2,k})$). Οι τιμές στις παρενθέσεις δηλώνουν τις ώρες στις οποίες συμβαίνει η συγκεκριμένη τιμή για το φορτίο. Άρα για κάθε ημέρα σχηματίζεται το διάλυμα:

$F_k = [f_{k,1}, \dots, f_{k,4}]^T = [L_{\min 1,k}, L_{\max 1,k}, L_{\min 2,k}, L_{\max 2,k}]^T$. Αυτού του είδους η περιγραφή χρησιμοποιείται προκειμένου για το μέρος της υπόθεσης (premise) του κάθε κανόνα του ασαφούς μοντέλου. Για την περιγραφή της συνέπειας (consequent) του κάθε κανόνα ακολουθείται μια διαφορετική προσέγγιση κατά την οποία οι καμπύλες φορτίου θεωρούνται συναρτήσεις του χρόνου και χρησιμοποιούνται οι συναρτήσεις B-spline για να τις προσεγγίσουν. Τελικά για το φορτίο της

κάθε ώρας προκύπτει $L_k(h) = \sum_{j=0}^7 \theta_j^k N_{j,4}(h)$, $h = 1, \dots, 24$ το οποίο

γράφεται και με τη μορφή : $L_k(h) = N(h)^T \cdot \theta_k$, $h = 1, \dots, 24$, όπου $N(h)^T = [N_{0,4}(h), \dots, N_{7,4}(h)]$ και $\theta_k = [\theta_0^k, \dots, \theta_7^k]^T$. Το συνολικό φορτίο της επόμενης ημέρας θα είναι: $LC_k = NC^T \cdot \theta_k$, όπου $NC = [N(1), \dots, N(24)]$.

*Σημείωση: Το $N_{j,4}$ υπολογίζεται από τη γενική σχέση:

$$N_{j,\ell}(h) = \left(\frac{h - \lambda_j}{\lambda_{j+k-1} - \lambda_j} \right) N_{j,\ell-1}(h) + \left(\frac{\lambda_{j+k} - h}{\lambda_{j+k} - \lambda_{j+1}} \right) N_{j+1,\ell-1}(h), \quad \lambda_j \leq h < \lambda_{j+k}$$

Με βάση τα παραπάνω προκύπτει το υποψήφιο ασαφές μοντέλο που αποτελείται από c κανόνες της μορφής:

$$R^{(i)}: \text{IF } F_{d-1} \text{ is } A_1^i \text{ AND } \dots \text{ AND } F_{d-m} \text{ is } A_m^i \text{ AND } T_d \text{ is } B^i \text{ THEN } LC_d^i = NC^T \cdot \theta_d^i$$

$i=1,2,\dots,c$ οι ασαφείς κανόνες, m το πλήθος των παρελθοντικών καμπυλών φορτίου και T_d το διάνυσμα της μορφής $T_d = [T_{d,1} \ T_{d,2}] = [T_{\max,d} \ T_{\min,d}]$ όπου $T_{\max,d}$ και $T_{\min,d}$ οι προβλεπόμενες τιμές για τη θερμοκρασία της μέρας, το φορτίο της οποίας θέλουμε να προβλέψουμε.

Οι προτάσεις της μορφής $F_{d-i} \text{ is } A_j^i$ και $T_d \text{ is } B^i$ δίνονται από τις σχέσεις:

$$F_{d-j} \text{ is } A_j^i = (f_{(d-j),1} \text{ is } A_{j,1}^i \text{ AND } \dots \text{ AND } f_{(d-j),4} \text{ is } A_{j,4}^i) \text{ και}$$

$$T_d \text{ is } B^i = (\hat{T}_{\max,d} \text{ is } B_1^i \text{ AND } \hat{T}_{\min,d} \text{ is } B_2^i).$$

Οι A_j^i και B^i θεωρούνται της μορφής:

$$A_{j,r}^i(f_{(d-j),r}) = \exp \left\{ -\frac{1}{2} \frac{(f_{(d-j),r} - m_{j,r}^i)^2}{(\sigma_{j,r}^i)^2} \right\}, \quad i = 1, \dots, c, \quad j = 1, \dots, m, \quad r = 1, \dots, 4$$

$$B_j^i = \exp \left\{ -\frac{1}{2} \frac{(T_{d,j} - M_j^i)^2}{(\Sigma_j^i)^2} \right\}, \quad i = 1, \dots, c, \quad j = 1, 2$$

όπου $m_{j,r}^i$, $\sigma_{j,r}^i$ οι μέσες τιμές και αποκλείσεις των $A_{j,r}^i$ και M_j^i , Σ_j^i οι μέσες τιμές και αποκλείσεις των B_j^i .

Δεδομένου ενός προτύπου διανύσματος εισόδου θα έχουμε:

$$w_{j,A}^i(F_{d-j}) = \min_{r=1}^4 A_{j,r}^i(f_{(d-j),r}) \text{ και } w_B^i(T_d) = \min_{j=1}^2 B_j^i(T_{d,j}), \text{ έτσι ώστε το συνολικό}$$

συμπέρασμα ενός κανόνα $R^{(i)}$ να δίνεται ως: $w^i(u) = \min (\min_{j=1}^m w_{j,A}^i, w_B^i)$.

Έχοντας υπολογίσει τα επιμέρους συμπεράσματα από όλους τους κανόνες η προβλεπόμενη έξοδος για το μοντέλο θα δίνεται από τον απο-ασαφοποιητή σταθμισμένων κέντρων (COA):

$$\hat{LC}_d = \frac{\sum_{i=1}^c w^i(\mathbf{u}) \cdot LC_d^i(\theta_d^i)}{\sum_{i=1}^c w^i(\mathbf{u})}$$

Τροποποιώντας την παραπάνω σχέση προκύπτει:

$$\hat{LC}_d = \sum_{i=1}^c v_i(\mathbf{u}) NC^T \theta_d^i, \text{ όπου } v_i(\mathbf{u}) \text{ το κανονικοποιημένο συμπέρασμα του}$$

$$\text{κανόνα } R^{(i)}. \left(v_i(\mathbf{u}) = \frac{w^i(\mathbf{u})}{\sum_{i=1}^c w^i(\mathbf{u})}, \quad i = 1, \dots, c. \right).$$

Από αυτή την οπτική γωνία, το ασαφές μοντέλο που αναφέρθηκε παραπάνω προσπαθεί να δώσει μια σχέση ανάμεσα στα παρελθοντικά και στα μελλοντικά φορτία $LC : FV_d \rightarrow LC_d$ (με την προσθήκη του παράγοντα θερμοκρασία).

Ακολουθεί ο υπολογισμός των βέλτιστων εισόδων και κανόνων για το συγκεκριμένο μοντέλο πρόβλεψης με τη χρήση τεχνικών που βασίζονται στους γενετικούς αλγορίθμους.

Τελικά επιλέγεται ως καταλληλότερο μοντέλο εκείνο που έχει 3 κανόνες της μορφής $R^{(i)} : IF F_{d-1} \text{ is } A_1^i \text{ AND } F_{d-2} \text{ is } A_2^i \text{ AND } \hat{T}_{\max,d} \text{ is } B_1^i \text{ THEN}$

$$LC^i(h) = \sum_{j=0}^7 g_j^i N_{j,4}(h), \quad h = 1, \dots, 24, \quad i = 1, 2, 3.$$

5.6 Η εφαρμογή του δικτύου ANFIS στην βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου για το απομονωμένο σύστημα της Κρήτης

Η παρούσα μελέτη χρησιμοποιεί το μοντέλο ANFIS με στόχο την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου προκειμένου για το διασυνδεδεμένο σύστημα της Κρήτης. Η συγκεκριμένη εφαρμογή εμπνεύστηκε από την μελέτη των Π.Μαστροκώστα, Ι.Θεοχάρη, Σ.Κιαρτζή και Α.Μπακιρτζή με τίτλο «*A hybrid fuzzy modeling method for short-term load forecasting*» [57], που εφαρμόζουν ένα σύστημα ANFIS με κανόνες TSK. Στο συγκεκριμένο paper προτείνεται επιπρόσθετα και μια τεχνική ελάττωσης του αριθμού των λογικών κανόνων και ακολούθως της εκπαίδευσης του δικτύου, κάτι όμως το οποίο δε λαμβάνεται εδώ υπόψιν. Επιπρόσθετα στη δική μας περίπτωση σε αντίθεση με την [57] χρησιμοποιούνται αποκλειστικά και μόνον δεδομένα φορτίου, .

Για την εφαρμογή των δοκιμών χρησιμοποιήθηκε το toolbox του MATLAB 6.5. Μετά από συνεχείς και διεξοδικές δοκιμές καταλήξαμε στην ακόλουθη βέλτιστη δομή για το δίκτυο ANFIS:

- ✚ Ως σύνολο εκπαίδευσης χρησιμοποιείται ολόκληρο το έτος 2000, με τις δοκιμές να αφορούν το ακόλουθο έτος, 2001.

- ✚ Το δίκτυο θα είναι 3 εισόδων (με τρία ασαφή σύνολα για την κάθε μια) και μιας εξόδου, με την έξοδο για τον κάθε ένα από τους 27 προκύπτοντες κανόνες (3 είσοδοι \times 3 ασαφή σύνολα) να λαμβάνει σταθερές τιμές, με άλλα λόγια οι συναρτήσεις συμπεράσματος για τον κάθε κανόνα θα είναι της μορφής: $f_i = a_i$.
- ✚ Οι συναρτήσεις συμμετοχής επιλέχθηκαν να έχουν τριγωνική μορφή και η εκπαίδευση του δικτύου να έχει υβριδική μορφή (δηλαδή back - propagation σε συνδυασμό με τεχνικές ελαχίστων τετραγώνων), που είναι πολύ ταχύτερη εκείνης της κλασικής back - propagation μεθόδου.
- ✚ Αναφορικά με τα ζεύγη εκπαίδευσης αυτά θα είναι της μορφής : $x_{in} = \{Load_j(i) Load_j(i+6) Load_{j-1}(i+7)\}$, $x_{out} = \{Load_j(i+7)\}$, δηλαδή για κάθε ώρα εξόδου, λαμβάνονται ως είσοδοι οι τιμές φορτίου της προηγούμενης μέρας και εβδομάδας και της προηγούμενης ώρας.
- ✚ Τα αποτελέσματα που παρουσιάζονται αφορούν και σε αυτήν την περίπτωση τις ώρες 02:00 και 14:00 (ξεχωριστά δίκτυα ANFIS για κάθε ώρα), για ένα διάστημα 120 ημερών για κάθε μία.

ΚΕΦΑΛΑΙΟ 6

ΑΠΟΤΕΛΕΣΜΑΤΑ ΔΟΚΙΜΩΝ


ΕΙΣΑΓΩΓΗ

Στην ενότητα αυτή γίνεται παρουσίαση των γραφικών παραστάσεων και αποτελεσμάτων (σφάλματα κ.τ.λ.) των δύο μεθόδων πρόβλεψης που προτείνονται μέσα από αυτήν τη μελέτη καθώς επίσης και σύγκριση τους με τα μοντέλα εκείνα που αναφέρονται στην 3^ο κεφάλαιο, με αναφορά και στις δύο περιπτώσεις το απομονωμένο σύστημα φορτίου της Κρήτης


6.1 Γραφικές παραστάσεις αποτελεσμάτων πρόβλεψης με το φίλτρο KALMAN

Όπως αναφέρθηκε και στο 4^ο κεφάλαιο πραγματοποιήθηκαν δοκιμές χωριστά και για τα δύο έτη, τα οποία ήταν διαθέσιμα (2000 και 2001), προβλέποντας και στις δύο περιπτώσεις το φορτίο για τις χρονοσειρές των ωρών 02:00 και 14:00, προκειμένου για 120 ημέρες. Τα αποτελέσματα που θα παρουσιαστούν αφορούν δύο ξεχωριστές περιπτώσεις. Στη μεν πρώτη, η πρόβλεψη γίνεται ώρα με ώρα (δηλαδή κάθε ώρα καταφθάνουν νέα δεδομένα), ενώ στη δεύτερη περίπτωση η πρόβλεψη αφορά μια μέρα συνολικά (με τα δεδομένα να ανανεώνονται κάθε ημέρα πρόβλεψης).

- Αρχικά, παριστάνονται ενδεικτικά οι συντελεστές των αναδρομικών εξισώσεων για κάθε ώρα προκειμένου για την 31^η Μαρτίου 2000 (επόμενη ημέρα του συνόλου εκπαίδευσης) και η αντίστοιχες καμπύλες φορτίου για την ημέρα αυτή:




Σχήμα 6.1.1, Συντελεστές αναδρομικών εξισώσεων για την 31^η Μαρτίου 2000.




Σχήμα 6.1.2, Γραφικές παραστάσεις για την 31^η Μαρτίου 2000.


- Ακολουθούν οι γραφικές παραστάσεις των χρονοσειρών 02:00 και 14:00 για τα έτη 2000 και 2001




Σχήμα 6.1.3 Πρόβλεψη φορτίου ώρα με ώρα (ώρα 02:00), έτος 2000




Σχήμα 6.1.4 Πρόβλεψη φορτίου μια ημέρα τη φορά (ώρα 02:00), έτος 2000




Σχήμα 6.1.5 Πρόβλεψη φορτίου ώρα με ώρα (ώρα 14:00), έτος 2000




Σχήμα 6.1.6 Πρόβλεψη φορτίου μια ημέρα τη φορά (ώρα 14:00), έτος 2000




Σχήμα 6.1.7 Πρόβλεψη φορτίου ώρα με ώρα (ώρα 02:00), έτος 2001



Σχήμα 6.1.8 Πρόβλεψη φορτίου μια ημέρα τη φορά (ώρα 02:00), έτος 2001




Σχήμα 6.1.9 Πρόβλεψη φορτίου ώρα με ώρα (ώρα 14:00), έτος 2001




Σχήμα 6.1.10 Πρόβλεψη φορτίου μια ημέρα τη φορά (ώρα 14:00), έτος 2001

6.2 Γραφικές παραστάσεις αποτελεσμάτων πρόβλεψης με το μοντέλο ANFIS

Το συγκεκριμένο μοντέλο χρησιμοποιεί ως δεδομένα εκπαίδευσης τη χρονοσειρά του ηλεκτρικού φορτίου για το έτος 2000 και προβλέπει 120 ημέρες (τις τιμές 02:00 και 14:00 αυτών) με τα αντίστοιχα διακριτά δίκτυα ANFIS για την κάθε ώρα.



Σχήμα 6.2.1 Πρόβλεψη φορτίου για την χρονοσειρά 02:00, έτος 2001



Σχήμα 6.2.2 Πρόβλεψη φορτίου για την χρονοσειρά 14:00, έτος 2001

6.3 Σφάλματα, συγκριτικά αποτελέσματα

Αρχικά, παρουσιάζονται τα σφάλματα προκειμένου για την περίπτωση του φίλτρου *KALMAN*:

Έτος 2000 (ώρα 02:00)

Πρόβλεψη	Relative Error (%)	RMSE (%)	Standard Deviation Error
Ωρα με ώρα	1,38	2,07	3,2458
Μια ημέρα	2,74	3,65	5,925

Έτος 2000 (ώρα 14:00)

Πρόβλεψη	Relative Error (%)	RMSE (%)	Standard Deviation Error
Ωρα με ώρα	2,48	3,77	9,8
Μια ημέρα	7,98	13,12	33,2

Έτος 2001 (ώρα 02:00)

Πρόβλεψη	Relative Error (%)	RMSE (%)	Standard Deviation Error
Ωρα με ώρα	1,26	1,57	3,03
Μια ημέρα	2,64	3,47	6,367

Έτος 2001 (ώρα 14:00)

Πρόβλεψη	Relative Error (%)	RMSE (%)	Standard Deviation Error
Ωρα με ώρα	2,67	3,82	10,6
Μια ημέρα	7,58	11,11	32,47

Ακολουθεί η παρουσίαση των σφαλμάτων για την περίπτωση του μοντέλου ANFIS:

Έτος 2001

	Relative Error (%)	RMSE (%)	Standard Deviation Error
02:00	0,96	1,3	2,02
14:00	2,36	3,04	7,3007

Για λόγους σύγκρισης παρουσιάζονται και τα σφάλματα των μοντέλων του 2^{ου} κεφαλαίου:

Statistical indices for the 2h00 hour load forecasting (min load case)

Models	AR	BP	ALRBP
Relative error (%)	3.86297	4.22628	2.73460
Standard deviation error	5.90894	5.16192	3.91741
RMSE (%)	5.80199	5.18811	3.80634
Models	GE	RAWN	MWRAWN
Relative error (%)	1.51737	6.82535	2.75417
Standard deviation error	2.13450	9.24337	4.19438
RMSE (%)	2.03138	8.98179	4.06330
Models	ZORRBF	RTRL	ARNN
Relative error (%)	1.35119	2.98850	1.22330
Standard deviation error	1.96127	4.35816	1.83768
RMSE (%)	1.86722	4.08409	1.71771


Πίνακας 6.3.1 (σφάλματα μοντέλων 3^{ου} κεφαλαίου για την ώρα 02:00)

Statistical indices for the 14h00 hour load forecasting (max load case)

Models	AR	BP	ALRBP
Relative error (%)	11.18372	13.40970	11.9674
Standard deviation error	25.60678	27.20622	24.3568
RMSE (%)	17.20486	19.04599	17.6778
Models	GE	RAWN	MWRAWN
Relative error (%)	3.40010	11.81696	10.59024
Standard deviation error	7.71597	26.29459	21.74416
RMSE (%)	4.61941	17.54215	15.19347
Models	ZORRBF	RTRL	ARNN
Relative error (%)	2.79244	11.5430	2.73292
Standard deviation error	5.77855	24.2722	5.92847
RMSE (%)	3.60609	16.4966	3.68308

Πίνακας 6.3.2 (σφάλματα μοντέλων 3^{ου} κεφαλαίου για την ώρα 14:00)

Τέλος, για λόγους σύγκρισης, δίδονται γραφικά τα μέσα απόλυτα σφάλματα όλων των μοντέλων:



Σχήμα 6.3 Τιμές μέσων απόλυτων σφαλμάτων όλων των μοντέλων

- ❖ KALMAN_2000_1: Kalman για το έτος 2000, με πρόβλεψη ώρα με ώρα
- ❖ KALMAN_2000_2: Kalman για το έτος 2000, με πρόβλεψη μια ημέρα τη φορά
- ❖ KALMAN_2001_1: Kalman για το έτος 2001, με πρόβλεψη ώρα με ώρα
- ❖ KALMAN_2001_2: Kalman για το έτος 2001, με πρόβλεψη μια ημέρα τη φορά

6.4 Συμπεράσματα

Για την δοκιμή των μοντέλων πρόβλεψης φορτίου των κεφαλαίων 4 και 5 (φίλτρο Kalman και δίκτυο ANFIS) χρησιμοποιήθηκαν δεδομένα φορτίου από τα έτη 2000 και 2001 (σε αντίθεση με τα έτη 1994 και 1995 που χρησιμοποιήθηκαν για τα μοντέλα του 4^{ου} κεφαλαίου). Προκειμένου λοιπόν να υπάρχει ένα κοινό μέτρο σύγκρισης επιλέχθηκε για την περίπτωση των μοντέλων που πραγματεύεται η μελέτη αυτή να υπολογιστούν οι χρονοσειρές του φορτίου για τις ώρες 02:00 και 14:00 με διάστημα 120 ημερών, όπως απεικονίζεται και μέσα από τα προηγούμενα σχήματα.

Διαπιστώνεται εύκολα από το διάγραμμα 6.3 ότι τα καλύτερα αποτελέσματα δίνει το δίκτυο ANFIS, ενώ ακολουθεί με εξίσου ικανοποιητικά αποτελέσματα το δίκτυο ARNN (autoregressive neural network). Όσον αφορά το φίλτρο Kalman, που δοκιμάζεται επίσης σε αυτήν την μελέτη, διαπιστώνεται ότι τα σφάλματα των προβλέψεων κινούνται μέσα σε «λογικά» πλαίσια (της τάξεως του 2-8%),

αποτελώντας έτσι ένα εναλλακτικό μοντέλο πρόβλεψης σε σχέση με τα νευρωνικά δίκτυα που εφαρμόζονται κυρίως, στην πράξη. Στην περίπτωση αυτή, βεβαίως, διαπιστώνεται ότι τα σφάλματα προκύπτουν αρκετά μεγαλύτερα προβλέποντας μια ολόκληρη ημέρα τη φορά από ότι μια ώρα κάθε φορά, σε κάθε επανάληψη του αλγορίθμου εκτίμησης των παραμέτρων των αναδρομικών εξισώσεων του φορτίου της μορφής (4.5), γεγονός αναμενόμενο μιας και στην πρώτη περίπτωση σε κάθε βήμα προς τα εμπρός αυξάνεται και ο βαθμός δυσκολία ακριβούς πρόβλεψης του ηλεκτρικού φορτίου καθώς απαιτείται η πρόβλεψη με μιας μεγαλύτερων μελλοντικών χρονικών διαστημάτων (24 ώρες τη φορά).

- Για τον υπολογισμό των διαφόρων σφαλμάτων χρησιμοποιήθηκαν οι ακόλουθες σχέσεις:

- Σχετικό σφάλμα (percent relative error): $\varepsilon = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}_i| * 100$ (επί τοις εκατό σφάλμα)

- Τυπική απόκλιση (standard deviation error): $\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N [y_i - \bar{y}_i]^2}$

- Ρίζα μέσου τετραγωνικού σφάλματος (Root mean square error):

$$\varepsilon_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N \left[\frac{y_i - \bar{y}_i}{y_i} \right]^2}$$

Βιβλιογραφία

- [1].Αναστάσιος Γ. Μπακιρτζής “Οικονομική λειτουργία συστημάτων ηλεκτρικής ενέργειας”, ΑΠΘ
- [2].Karanta, I., 1990, "Short-Term load forecasting in communal electric utilities", Licentiate thesis, Systems Analysis Laboratory, Helsinki University of Technology.
- [3].Rasanen, M., 1995, "Modeling processes in the design of electricity tariffs", Research Report A60, Systems Analysis Laboratory, Helsinki University of Technology.
- [4].Gross, G., F. D. Galiana, 1987, "Short-term load forecasting", Proceedings of the IEEE, Vol. 75, No. 12, December 1987, pp. 1558-1573.
- [5].Kim, K.-H., J.-K. Park, K.-J. Hwang, S.-H. Kim, 1995, "Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems", IEEE Transactions on Power Systems, Vol. 10, No. 3, August 1995, pp. 1534-1539.
- [6].Kallio, M., 1985, "LampOtilatekija sahkOnkulutuksen ennUstamisessa", Master's thesis, Systems Analysis Laboratory, Helsinki University of Technology (in Finnish).
- [7].Gross, G., F. D. Galiana, 1987, "Short-term load forecasting", Proceedings of the IEEE, Vol. 75, No. 12, December 1987, pp. 1558-1573.
- [8].Chow, T. W. S., C. T. Leung, 1996, "Neural network based short-term load forecasting using weather compensation", IEEE Transactions on Power Systems, Vol. 11, No. 4, November 1996, pp. 1736-1742.
- [9].Kallio, M., 1985, "LampOtilatekija sahkOnkulutuksen ennUstamisessa", Master's thesis, Systems Analysis Laboratory, Helsinki University of Technology (in Finnish).
- [10].Khotanzad, A., M. H. Davis, A. Abaye, D. J. Maratukulam, 1996, "An artificial neural network hourly temperature forecaster with applications in load forecasting", IEEE Transactions on Power Systems, Vol. 11, No. 2, May 1996, pp. 870-876.
- [11].Hsu, Y.-Y., C.-C. Yang, 1991, "Design of artificial neural networks for short-term load forecasting. Part I: Self-organising feature maps for day type selection", IEEE Proceedings-C, Vol. 138, No. 5, September 1991, pp. 407-413.
- [12].Hsu, Y.-Y., C.-C. Yang, 1991, "Design of artificial neural networks for short-term load forecasting. Part II: Multilayer feedforward networks for peak load and valley load forecasting", IEEE Proceedings-C, Vol. 138, No. 5, September 1991, pp. 414-418.
- [13].Bunn, D. W., E. D. Farmer (eds.), 1985, "Comparative models for electrical load forecasting", John Wiley & Sons, Belfast.
- [14].Allera, S. Y., and J. E. McGowan, 1986, "Medium-term forecasts of half-hourly system demand: development of an interactive demand estimation coefficient model", IEEE Proceedings-C, Vol. 133, No. 7, November 1986, pp. 393-396.
- [15].Broehl, J. H., 1981, "An end-use approach to demand forecasting", IEEE Transactions on Power Apparatus and Systems, Vol. PAS-I00, No. 6, June 1981, pp. 2714-2718.
- [16].Goh, T. N., S. S. Choi, and S. B. Chien, 1983, "Forecasting of electricity demand by end-use characteristics", Electric Power Systems Research, Vol. 10, No. 2, March 1986, pp. 145-148.

- [17].Papalexopoulos, A. D., T. C. Hesterberg, 1990, "A regression-based approach to short-term system load forecasting", IEEE Transactions on Power Systems, Vol. 5, No. 4, November 1990, pp. 1535-1547.
- [18].Piggot, J. L., 1985, "Short-term forecasting at British Gas", in: Bmm D. W, E. D. Famler (eds), "Comparative models for electrical load forecasting", John Wiley & Sons, Belfast, 1985, pp. 173-211.
- [19].Hagan, M. T. and S. M. Behr, 1987, "The time series approach to short-term load forecasting", IEEE Transaction on Power Systems, Vol. PWRS-2, No. 3, August 1987, pp. 785-791.
- [20].Toyoda, J., M.-C. Chen, and Y. Inoue, 1970, "An application of state estimation to short-term load forecasting, Part I: Forecasting modeling, Part II: implementation", IEEE Transactions on Power Apparatus and Systems, Vol. PAS-89, No. 7 , September/October 1970, pp. 1678-1688.
- [21].Gupta, P. C. and K. Yamada, 1972, "Adaptive short-term load forecasting of hourly loads using weather information", IEEE Transactions on Power Apparatus and Systems, Vol. PAS-91, No. 5, Sept./Oct. 1972, pp. 2085-2094.
- [22].Campo, R. and P. Ruiz, 1987, "Adaptive weather-sensitive short-term load forecast, IEEE Transactions on Power Systems, Vol. PWRS-2, No. 3, August 1987, pp. 592- 600.
- [23].Rahman, S., Bhatnagar, R., 1988, "An expert system based algorithm for short-term load forecast", IEEE Transactions on Power Systems, Vol. 3, No. 2, May 1988, pp. 392-399.
- [24].Rahman, S., O. Hazim, " A generalized knowledge-based short-term load-forecasting technique", IEEE Transactions on Power Systems, Vol. 8, No. 2, May 1993, pp. 508- 514.
- [25].Jabbour, K., J. F. V. Riveros, D. Landsbergen, and W. Meyer, 1988, "ALFA: Automated Load Forecasting Assistant", IEEE Transactions on Power Systems, Vol. 2, No. 3, August 1988, pp. 908-914.
- [26].Hsu, Y.- Y., K.-L. Ho, 1992, "Fuzzy expert systems: an application to short-term load forecasting", IEEE Proceedings-C, Vol. 139, No. 6, November 1992, pp. 471-477 .
- [27].Kim, K.-H., J.-K. Park, K.-J. Hwang, S.-H. Kim, 1995, "Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems", IEEE Transactions on Power Systems, Vol. 10, No. 3, August 1995, pp. 1534-1539.
- [28].Momoh, J. A., K. Tomsovic, 1995, "Overview and literature survey of fuzzy set theory in power systems", IEEE Transactions on Power Systems, Vol. 10, No. 3, August 1995, pp. 1676-1690.
- [29].R.H.Liang, C.C.Cheng, 2001 "Short-term load forecasting by a neuro-fuzzy based approach", Electrical power & energy systems, Elsevier 2001.
- [30].Asar, A., J. R. McDonald, 1994, "A specification of neural network applications in the load forecasting problem", IEEE transactions on control systems technology, Vol. 2, No. 2, June 1994, pp. 135-141.
- [31]. H.M. Al-Hamadi, S.A. Soliman, Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model. Electric Power Systems Research, May 2003.
- [32] J. Hertz, A. Krogh, R.G. Palmer, Introduction to Theory of Neural Computation, Addison-Wesley, 1991.

- [33] K.L. Ho, et al., Short-term load forecasting of Taiwan power system using a knowledge based expert system, IEEE Trans. Power Syst. 5 (4) (1990) 1214_ 1219.
- [34] S. Rahman, R. Bhatnagar, An expert system based algorithm for short-term load forecast, IEEE Trans. Power Syst. AS-101 (1982)
- [35] K. Lee, Y. Cha, C. Ku, A study on neural networks for short-term load forecasting, Proc. ANNPS '91, Seattle, July (1991) 26_ 30.
- [36] C.N. Lu, H.T. Wu, S. Vemuri, Neural network based short-term load forecasting, IEEE Trans. Power Syst. 8 (1) (1993) 337_ 342.
- [37] G.N. Kariniotakis, E. Kosmatopoulos, G. Stavrakakis, Load forecasting using dynamic high-order neural networks, Proc. IEEE-NTUA Joint Int. Power Conf., Athens, Greece, 1993, pp. 801_ 805.
- [38] A. Bakirtzis, V. Petridis, S. Klartzis, A neural network short-term load forecasting model for the Greek power system, IEEE Trans. Power Syst. 11 (2) (1996) 858_ 863.
- [39] A. Papalexopoulos, S. How, T.M. Peng, An implementation of a neural network based load forecasting model for the EMS, IEEE Trans. Power Syst. 9 (4) (1994) 1956_ 1962.
- [40] Srinivasan, Dipti, Evolving artificial neural networks for short term load forecasting, Neurocomputing 23 (1998) 265_ 276.
- [41] G.N. Kariniotakis, G.S. Stavrakakis, E.F. Nogaret, Wind power forecasting using advanced neural networks models, IEEE Trans. Energy Convers. 11 (4) (1996) 762_ 767.
- [42] I. Drezga, S. Rahman, Short-term load forecasting with local ANN predictors, IEEE Trans. Power Syst. 14 (1999) 3.
- [43] K. Kalaitzakis, G.S. Stavrakakis, E.M. Anagnostakis, Short-term load forecasting based on artificial neural networks parallel implementation. Department of Electronics and Computer Engineering, Technical University of Crete, 2002
- [44] IEEE Committee report, Load forecasting bibliography Phase I, IEEE Trans. Power Appl. Syst. 99 (1980) 53_ /58.
- [45] I. Moghram, S. Rahman, Analysis and evaluation of five short term load forecasting techniques, IEEE Trans. Power Syst. 4 (4) (1989) 1484_ /1491.
- [46] S. Chen, E. Chng, Regularized orthogonal least squares algorithm for constructing radial basis function networks, Int. J. Control 64 (5) (1996) 829_ 837.
- [47] C.-T. Lin, G.S.G. Lee, Neural Fuzzy Systems, Prentice Hall, NJ, 1996.
- [48] G.S. Stavrakakis, A. Pouliezios, Fatigue life prediction using a new moving window regression method, Mech. Syst. Signal Processing 5 (4) (1991) 327_ 340.
- [49] Haykin, S., 1994, "Neural networks - a comprehensive foundation", MacMillan College Publ. Co., New York
- [50] Bazaraa, M. S., H. D. Sherali, C. M. Shetty, 1993, "Nonlinear programming - theory and algorithms", 2nd edition, John Wiley & Sons, Singapore
- [51] Ι.Θεοχάρης, "Ασαφή Συστήματα". Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης 2002.
- [52] S.E Papadakis, J.B. Theocharis, A.G. Bakirtzis A load curve based fuzzy modeling technique for short-term load forecasting. Fuzzy Sets And Systems;2002
- [53] Chin-Teng Lin, C.S.George Lee Neural Fuzzy Systems 1996;p.535-544
- [54] R.Liang, C.Cheng. "Short-term load forecasting by a neuro-fuzzy approach". Elsevier 2002.
- [55] M.Velasco, M.Pacheco, L.Neto, F.Souza. "Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model".

- [56] Bollen KA, Barb KH. Pearson's r and coarsely categorized measures. *Am social rev* 1981;46:232-9.
- [57] P.A. Mastorocostas, J.B. Theocharis, S.J. Kiartzis, A.G. Bakirtzis. «A hybrid fuzzy modeling method for short-term load forecasting» *Department of lectrical and Computer Engineering, Aristotle University of Thessaloniki, Thessaloniki, Greece*

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1

Εισαγωγή

1.1	Υπόβαθρο.....	1
1.2	Σκοπός της μελέτης.....	4
1.3	Δομή της μελέτης.....	5

ΚΕΦΑΛΑΙΟ 2

Πρόβλεψη φορτίου

2.1	Παράγοντες που επηρεάζουν το φορτίο.....	6
2.2	Ιδιότητες της καμπύλης φορτίου.....	10
2.3	Δυνατές προσεγγίσεις.....	16
2.3.1	Ταξινόμηση των μεθόδων.....	16
2.3.2	Μερικές από τις πιο δημοφιλείς μεθόδους.....	17
	Μοντέλα time -of- day.....	17
	Μοντέλα απόκλισης εξαρτημένης στατιστικής μεταβλητής	18
	Μοντέλα στοχαστικών χρονοσειρών.....	19
	Μοντέλα χώρων κατάστασης.....	21
	Εξειδικευμένα συστήματα.....	21
	Τεχνητή νοημοσύνη και νευρωνικά δίκτυα.....	22

ΚΕΦΑΛΑΙΟ 3

Βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου με βάση τα νευρωνικά δίκτυα

3.1.	Εισαγωγή.....	25
3.2	Εκπαίδευση νευρωνικών δικτύων.....	25
3.3	Γενίκευση.....	28
3.4	Τεχνικές πρόβλεψης ηλεκτρικού φορτίου.....	30
3.4.1	Η μέθοδος αναδρομής.....	30
3.4.2	Προχωρημένοι αλγόριθμοι ανάστροφης διάδοσης.....	31
3.4.3	Δίκτυα τυχαίας ενεργοποίησης βαρών (RAWN) και εκπαιδευόμενα RAWN με κινούμενο παράθυρο αναδρομής MWAWN	32
3.4.4	Δίκτυα με συναρτήσεις radial basis.....	34
3.4.5	Επαναληπτικά δίκτυα πραγματικού χρόνου.....	35

ΚΕΦΑΛΑΙΟ 4

Το φίλτρο Kalman και η εφαρμογή του στην πρόβλεψη του ηλεκτρικού φορτίου

4.1	Το φίλτρο Kalman.....	38
4.2	Η εφαρμογή του φίλτρου KALMAN στην πρόβλεψη φορτίου.....	39
4.2.1	Εκτίμηση των παραμέτρων του φίλτρου Kalman.....	40
4.2.2	Βήματα που ακολουθούνται για την πρόβλεψη του φορτίου της επόμενης μέρας.....	41
4.3	Η εφαρμογή του φίλτρου Kalman στην βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου για το απομονωμένο σύστημα της Κρήτης.....	42

ΚΕΦΑΛΑΙΟ 5

Η ασαφής λογική και η εφαρμογή της στην πρόβλεψη του ηλεκτρικού φορτίου.

5.1	Βασικές Έννοιες.....	44
5.2	Ασαφή συστήματα συμπερασμού.....	47
5.3	Νευρώσαφα συστήματα.....	50
5.3.1	Ο neural-fuzzy ελεγκτής FALCON.....	53
5.3.2	Εκπαίδευση του FALCON.....	55
5.4	Το δίκτυο ANFIS.....	59
5.5	Εφαρμογές των νευρώσαφων συστημάτων στην πρόβλεψη φορτίου.....	61
5.6	Η εφαρμογή του δικτύου ANFIS στην βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου για το απομονωμένο σύστημα της Κρήτης.....	67

ΚΕΦΑΛΑΙΟ 6

Αποτελέσματα δοκιμών

6.1	Γραφικές παραστάσεις αποτελεσμάτων πρόβλεψης με το φίλτρο KALMAN.....	69
6.2	Γραφικές παραστάσεις αποτελεσμάτων πρόβλεψης με το μοντέλο ANFIS.....	75
6.3	Σφάλματα, συγκριτικά αποτελέσματα.....	77
6.4	Συμπεράσματα.....	79
	Βιβλιογραφία.....	81