



**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ**  
**Τμήμα Μηχανικών Παραγωγής και**  
**Διοίκησης**

---

**ΠΡΟΒΛΕΨΗ ΦΑΡΜΑΚΕΥΤΙΚΩΝ ΠΩΛΗΣΕΩΝ ΜΕ ΤΗΝ**  
**ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΚΑΙ**  
**ΝΕΥΡΟ-ΑΣΑΦΩΝ ΣΥΣΤΗΜΑΤΩΝ**

---

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**ΤΟΥ**

**ΜΠΡΟΚΑΛΑΚΗ ΙΩΣΗΦ**

**ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ: ΑΤΣΑΛΑΚΗΣ ΓΕΩΡΓΙΟΣ**

---

**ΧΑΝΙΑ, ΜΑΙΟΣ 2014**

## **ΕΥΧΑΡΙΣΤΙΕΣ**

Καταρχήν θα ήθελα να ευχαριστήσω τον κ. Ατσαλάκη Γιώργο για την πολύτιμη επιστημονική του καθοδήγηση στην εκπόνηση της Διπλωματικής εργασίας. Οι παρατηρήσεις του αποδείχτηκαν καθοριστικής σημασίας οποτεδήποτε αντιμετώπιζα πρόβλημα.

Επίσης ευχαριστώ τους συμφοιτητές μου Χρήστο Καραφεΐζη και Μάνο Πριμηκύριο με τους οποίους μοιράστηκα τα φοιτητικά μου χρόνια.

Τέλος θα ήθελα να ευχαριστήσω την οικογένειά μου για την αδιάλειπτη στήριξη και υπομονή τους καθ' όλη την διάρκεια των σπουδών μου.

## Πίνακας περιεχομένων

Περίληψη.....	4
Abstract.....	5
1. Εισαγωγή.....	6
1.1. Η αγορά φαρμάκου στην Ελλάδα.....	6
1.2. Σκοπός της εργασίας.....	7
1.3. Δομή της εργασίας .....	7
2. Πρόβλεψη χρονοσειρών.....	8
2.1. Μέθοδοι πρόβλεψης χρονοσειρών.....	9
2.2. Τεχνητή Νοημοσύνη και πρόβλεψη χρονοσειρών.....	9
2.3. Τεχνητή Νοημοσύνη και πρόβλεψη φαρμακευτικών πωλήσεων.....	10
3. Τεχνητή Νοημοσύνη .....	10
3.1. Τεχνητά Νευρωνικά Δίκτυα.....	11
3.1.1. Νευρωνική δομή.....	11
3.1.2. Αρχιτεκτονική Νευρωνικών Δικτύων .....	14
3.1.3. Λειτουργία Νευρωνικών Δικτύων.....	16
3.1.4. Εφαρμογές Νευρωνικών Δικτύων.....	20
3.2. Νεύρο-Ασαφή Συστήματα .....	21
3.2.1. Ασαφής Λογική.....	21
3.2.2. Ασαφή Συστήματα .....	23
3.2.3. Προσαρμοστικό Νεύρο-Ασαφές Σύστημα Εξαγωγής Συμπεράσματος .....	25
3.2.4. Εφαρμογές ANFIS.....	28
4. Μοντελοποίηση προβλήματος.....	29
4.1. Επεξεργασία δεδομένων.....	29
4.2. Αξιολόγηση ακρίβειας πρόβλεψης.....	30
4.3. Υλοποίηση μοντέλων.....	31
4.3.1. Τεχνητά Νευρωνικά Δίκτυα .....	31
4.3.2. ANFIS .....	35
5. Αποτελέσματα .....	36
5.1. Πρόβλεψη Νευρωνικών Δικτύων .....	36
5.2. Πρόβλεψη ANFIS.....	48
6. Συμπεράσματα .....	58
Βιβλιογραφία.....	59
Παράρτημα Ι – Φαρμακευτικές Πωλήσεις .....	62

## Περίληψη

---

Τα τελευταία χρόνια οι φαρμακευτικές πωλήσεις στην Ελλάδα έχουν υποστεί σημαντική μείωση. Συνέπεια αυτής εξέλιξης αποτελεί ο σκεπτικισμός με τον οποίο αντιμετωπίζουν μεγάλες επιχειρήσεις της φαρμακευτικής βιομηχανίας μελλοντικές τους επενδύσεις. Η ανάγκη για μακροπρόθεσμες και ακριβείς προβλέψεις ως εργαλείο στρατηγικού προγραμματισμού αυξάνει. Στόχος της παρούσας διπλωματικής εργασίας αποτελεί ο σχεδιασμός ενός μοντέλου μακροπρόθεσμης (πολλών βημάτων μπροστά) πρόβλεψης για τις συνολικές πωλήσεις της φαρμακευτικής βιομηχανίας. Προς αυτήν την κατεύθυνση διερευνούμε μεθοδολογίες από τον τομέα της Τεχνητής Νοημοσύνης. Τα Εμπρόσθια Νευρωνικά Δίκτυα και το Προσαρμοστικό Νεύρο-Ασαφές Σύστημα Εξαγωγής Συμπεράσματος υιοθετήθηκαν. Οι συγκεκριμένες τεχνικές έχουν αποδείξει την ανωτερότητά τους έναντι των στατιστικών μεθόδων σε προβλήματα πρόβλεψης ενός βήματος μπροστά. Ωστόσο, η μακροπρόθεσμη πρόβλεψη αποτελεί πρόκληση για τους ερευνητές. Η υλοποίηση των μοντέλων βασίστηκε στα δεδομένα των τελευταίων 14 ετών, τα οποία διατίθενται στην ιστοσελίδα του Εθνικού Οργανισμού Φαρμάκων. Τα αποτελέσματα των δύο μεθοδολογιών συγκρίθηκαν και αξιολογήθηκαν με στόχο τον εντοπισμό του κατάλληλου μοντέλου για το συγκεκριμένο πρόβλημα.

### Λέξεις κλειδιά

Μακροπρόθεσμη πρόβλεψη, Φαρμακευτικές πωλήσεις, Νευρωνικά Δίκτυα, Προσαρμοστικό Νεύρο-Ασαφές Σύστημα Εξαγωγής Συμπεράσματος

## **Abstract**

---

Over the last years, pharmaceutical sales in Greece have undergone significant decline. As a result, major corporations of the pharmaceutical industry are considering future investments with skepticism. The need for accurate long term forecasts, as a tool for strategic planning is increasing. Objective of the present diploma thesis is the development of a multistep-ahead forecasting model that will predict effectively total sales of the pharmaceutical industry. To this direction we explore methodologies from the field of Artificial Intelligence. Feed forward Neural Networks and the Adaptive Neuro-Fuzzy Inference System were employed. These techniques have proven their superiority, compared to statistical methods, in single step forecasting. However multistep-ahead forecasting has been a challenging task among researchers. The models' implementation was based on the last 14 years' data, provided by the Greek National Organization for Medicines (EOF). Results of both methodologies were compared and evaluated in order to identify the appropriate model for this particular task.

## **Keywords**


Multistep-ahead forecasting, Pharmaceutical sales, Feed-forward Neural Networks, Adaptive Neuro-Fuzzy Inference System



## 1. Εισαγωγή

### 1.1. Η αγορά φαρμάκου στην Ελλάδα

Το 2010, το ύψος του δημοσίου χρέους και κατ' επέκταση η πιθανότητα πτώχευσης, οδήγησαν την ελληνική κυβέρνηση στην λήψη μέτρων λιτότητας και περικοπής δαπανών. Οι τομείς της Υγείας και του Φαρμάκου κλήθηκαν να συνεισφέρουν τα μέγιστα στην προσπάθεια δημοσιονομικής προσαρμογής της χώρας. Το Μνημόνιο Συνεννόησης (MoU) μεταξύ Ελληνικής κυβέρνησης, Ευρωπαϊκής Ένωσης και Διεθνούς Νομισματικού Ταμείου προέβλεπε πλήθος μέτρων για την περικοπή δαπανών στον τομέα της δημόσιας υγείας. Προς αυτήν την κατεύθυνση επιβλήθηκαν διαδοχικές υποτιμήσεις στις τιμές των φαρμάκων. Καθιερώθηκε αρνητική (χωρίς αποζημίωση από τα ασφαλιστικά ταμεία) λίστα φαρμάκων. Θεσμοθετήθηκε επιστροφή κερδών από τις φαρμακευτικές επιχειρήσεις προς τα ασφαλιστικά ταμεία. Επιπροσθέτως αποφασίστηκε η προώθηση γεννόσημων φαρμακευτικών σκευασμάτων. Το αποτέλεσμα των προαναφερθέντων μέτρων αντικατοπτρίζεται σε μία δραματική μείωση των φαρμακευτικών πωλήσεων, όπως φαίνεται στο γράφημα 1.



Γράφημα 1.1 Μηνιαίες φαρμακευτικές πωλήσεις (ΕΟΦ, 2013)

Ο κλάδος των φαρμακευτικών επιχειρήσεων, που την δεκαετία του 2000 αποτέλεσε έναν από τους ταχύτερα αναπτυσσόμενους κλάδους της εγχώριας μεταποίησης, είδε τις πωλήσεις του να μειώνονται και τα συνολικά οικονομικά αποτελέσματα να φέρουν αρνητικό πρόσημο. Το ύψος των πωλήσεων έχει φτάσει σε ένα επίπεδο όπου η

οικονομική επιβίωση φαρμακευτικών βιομηχανιών, των προμηθευτών καθώς επίσης και των φαρμακείων τίθεται εν αμφιβόλω. Στην προσπάθειά τους να ανταπεξέλθουν έχουν παρατηρηθεί περιπτώσεις διάθεσης προϊόντων μόνο με την πληρωμή ολόκληρης της αξίας του φαρμάκου ή ακόμα και διακοπή διάθεσης φαρμάκου. Μια κατάρρευση της αλυσίδας εφοδιασμού στο κλάδο του φαρμάκου θα αποτελούσε απειλή για την δημόσια υγεία.

Σύμφωνα με όσα προβλέπονται στο Μνημόνιο, θα συνεχιστεί η προσπάθεια μείωσης της δημόσιας φαρμακευτικής δαπάνης, ώστε αυτή να προσεγγίσει το 1% του ΑΕΠ το 2014. Η φαρμακευτική πολιτική της χώρας πρέπει να ισορροπήσει μεταξύ της δημοσιονομικής εξυγίανσης και της παροχής υπηρεσιών υγείας προς τους ασθενείς. Έως ότου αποκατασταθεί η ομαλή λειτουργία στην αγορά του φαρμάκου, η εύρεση μιας αξιόπιστης μεθόδου πρόβλεψης πωλήσεων καθίσταται μείζονος σημασίας και θα παρείχε στις εταιρείες που δραστηριοποιούνται στον χώρο του φαρμάκου ένα σημαντικό εργαλείο να ανταπεξέλθουν την κρίση.

## **1.2. Σκοπός της εργασίας**

---

Σκοπός της παρούσας εργασίας είναι η ανάπτυξη ενός μοντέλου πρόγνωσης που θα προβλέπει αποτελεσματικά τις συνολικές φαρμακευτικές πωλήσεις της φαρμακοβιομηχανίας στην Ελλάδα. Τα δεδομένα μας αποτελούνται από μηνιαίες φαρμακευτικές πωλήσεις για την περίοδο 2000-2013, όπως έχουν αναρτηθεί στο διαδίκτυο από την ιστοσελίδα του Εθνικού Οργανισμού Φαρμάκων (ΕΟΦ). Αναλυτικά τα δεδομένα παρουσιάζονται στο Παράρτημα Ι.

Προσεγγίσαμε το πρόβλημα με όρους χρονοσειρών. Στόχος μας ήταν η μακροπρόθεσμη πρόβλεψη, 12 βημάτων μπροστά. Τα οφέλη από μία επιτυχή πρόβλεψη ενός έτους πωλήσεων εντοπίζονται στον μακροπρόθεσμο σχεδιασμό τόσο των φαρμακευτικών εταιρειών όσο και της ελληνικής κυβέρνησης.

## **1.3. Δομή της εργασίας**

---

Στο παρόν κεφάλαιο παρουσιάζεται η κατάσταση της αγοράς φαρμάκου στην Ελλάδα. Αναλύονται επιγραμματικά οι λόγοι που έχουν οδηγήσει στην μείωση των πωλήσεων καθώς και οι ανάγκες τις οποίες εξυπηρετεί η εργασία μας.

Ακολουθεί η παρουσίαση των μεθόδων πρόβλεψης χρονοσειρών και οι εφαρμογές τους. Θα επικεντρωθούμε στα μοντέλα τεχνητής νοημοσύνης και στις υλοποιήσεις αυτών στον τομέα των φαρμακευτικών πωλήσεων.

Στο τρίτο κεφάλαιο παρουσιάζεται η θεωρία των Τεχνητών Νευρωνικών Δικτύων (ANN) καθώς επίσης και του προσαρμοστικού νεύρο-ασαφούς συστήματος (ANFIS). Οι συγκεκριμένες μεθοδολογίες θα χρησιμοποιηθούν για την δόμηση του μοντέλου πρόβλεψης, οπότε το θεωρητικό τους υπόβαθρο κρίνεται απαραίτητο.

Στο τέταρτο κεφάλαιο επιχειρείται η μοντελοποίηση του προβλήματος μακροπρόθεσμης πρόβλεψης των φαρμακευτικών πωλήσεων. Σημαντική καθοδήγηση ως προς τη σωστή προσέγγιση του προβλήματος δίνουν παλαιότερες εργασίες, οι οποίες και αναφέρονται.

Στο πέμπτο κεφάλαιο παρουσιάζονται τα αποτελέσματα της έρευνας. Η αξιολόγηση πραγματοποιείται μέσω γραφικών παραστάσεων, ενώ ακολουθούν τα συμπεράσματα της παρούσας μελέτης.

## **2. Πρόβλεψη χρονοσειρών**

---

Με τον όρο πρόβλεψη μπορούμε να ορίσουμε την διαδικασία εκτίμησης ενός μεγέθους σε μελλοντικό χρόνο. Η σπουδαιότητα της πρόβλεψης πηγάζει από την ανάγκη των ανθρώπων να γνωρίζουν τι θα συμβεί στο μέλλον. Μία τέτοια γνώση (σωστή εκτίμηση μίας μελλοντικής κατάστασης) οδηγεί στην ελαχιστοποίηση του ρίσκου. Μικρότερο ρίσκο στην λήψη μιας απόφασης όσον αφορά στην δουλειά τους, στην επιχείρησή τους, στην επένδυσή τους αλλά ακόμα και στην προσωπική τους ζωή.

Με τον όρο χρονοσειρά εννοούμε μία ακολουθία από παρατηρήσεις (ιστορικά δεδομένα) προηγούμενων χρονικών περιόδων. Οι αναλυτές συλλέγουν τα δεδομένα ανά τακτές χρονικές περιόδους (ώρες, μέρες, μήνες, έτη, κ.λ.π.). Στην συνέχεια τα δεδομένα αυτά αναλύονται με σκοπό να προσδιοριστεί η λανθάνουσα διαδικασία η οποία τα παράγει. Ακολουθώς, το μοντέλο ανάγεται για την πρόβλεψη μελλοντικών τιμών.

Η προσέγγιση ενός προβλήματος πρόβλεψης με όρους χρονοσειράς κρίνεται αναγκαία όταν δεν υπάρχει επαρκή γνώση για τις μεταβλητές οι οποίες επηρεάζουν την διαδικασία. Πρόκειται για το ποιο διαδεδομένο είδος ποσοτικού μοντέλου πρόβλεψης και έχει εφαρμοστεί επιτυχώς σε πολλούς τομείς όπως η βιομηχανία, η οικονομία, η ιατρική, το περιβάλλον και πολλές άλλες, δίνοντας λύση σε προβλήματα όπως:

- Πρόγνωση μετεωρολογικών συνθηκών
- Πρόβλεψη κλιματικών αλλαγών και φαινομένων
- Πρόβλεψη οικονομικών μεγεθών



- Πρόβλεψη συνολικής παραγωγής ενέργειας σε μία εγκατάσταση
- Πρόβλεψη θνησιμότητας πληθυσμού σε μια χώρα
- Πρόβλεψη της κυκλοφορίας σε εθνικές οδούς
- Πρόβλεψη ζήτησης ενός συγκεκριμένου είδους κατανάλωσης

## 2.1. Μέθοδοι πρόβλεψης χρονοσειρών

---

Κατά το παρελθόν στον τομέα της πρόβλεψης χρονοσειρών κυριαρχούσαν οι στατιστικές μέθοδοι. Μοντέλα όπως το αυτοπαλίνδρομο (AutoRegressive model - AR), το κινούμενου μέσου (moving average - MA), το αυτοπαλίνδρομο κινούμενου μέσου (AutoRegressive moving average - ARMA) και κυρίως το ολοκληρωμένο αυτοπαλίνδρομο κινούμενου μέσου (autoregressive integrated moving average model - ARIMA) χρησιμοποιούνταν και χρησιμοποιούνται ακόμα και σήμερα στην πρόβλεψη. Η μεθοδολογία Box-Jenkins έχει καταστήσει το μοντέλο ARIMA ως μέτρο σύγκρισης για οποιοδήποτε νέο μοντέλο πρόβλεψης. Ο εγγενής όμως γραμμικός του χαρακτήρας περιορίζει την δυναμική του σε μη γραμμικά προβλήματα, τα οποία αποτελούν και την πλειοψηφία των πραγματικών χρονοσειρών.

Για να ξεπεραστούν οι περιορισμοί που θέτουν τα προαναφερθείσα μοντέλα, αναπτύχθηκαν μη γραμμικές μεθοδολογίες όπως το οριακό αυτοπαλίνδρομο μοντέλο (TAR), το αυτοπαλίνδρομο μοντέλο με δεσμευμένη ετεροσκεδαστικότητα (autoregressive with conditional heteroscedasticity - ARCH) και η γενίκευση αυτού (GARCH model). Ωστόσο, και τα συγκεκριμένα μοντέλα δείχνουν αδυναμίες στην γενίκευσή τους καθώς χτίστηκαν βάσει συγκεκριμένων πρότυπων.

Μία διαφορετική οπτική στην πρόβλεψη χρονοσειρών έρχεται να δώσει ο τομέας της Τεχνητής Νοημοσύνης. Μέθοδοι όπως τα Τεχνητά Νευρωνικά Δίκτυα, τα Ασαφή Συστήματα και οι Γενετικοί Αλγόριθμοι έχουν εφαρμοστεί αποτελεσματικά στην πρόβλεψη χρονοσειρών.

Τα τελευταία χρόνια παρατηρείται η τάση οι ερευνητές να συνδυάζουν διαφορετικά μοντέλα για την καλύτερη αξιοποίηση των πλεονεκτημάτων τους. Έχουν αναπτυχθεί Υβριδικά Μοντέλα που συνδυάζουν τα Τεχνητά Νευρωνικά Δίκτυα τόσο με την μέθοδο ARIMA (Khashei & Bijari, M., 2011) όσο και με τα Ασαφή Συστήματα (Jang, 1993).

## 2.2. Τεχνητή Νοημοσύνη και πρόβλεψη χρονοσειρών

---

Τα Τεχνητά Νευρωνικά Δίκτυα (ANN) και το Προσαρμοστικό Νεύρο-ασαφές Σύστημα Εξαγωγής Συμπερασμάτων (ANFIS) αποτελούν δύο πολλά υποσχόμενες μεθοδολογίες στον τομέα της πρόβλεψης. Η μη γραμμική δομή τους, τους δίνει την

δυνατότητα να αντιλαμβάνονται τόσο γραμμικές όσο και μη γραμμικές συσχετίσεις μεταξύ των δεδομένων. Οι Zhang et al. (1998) υποστηρίζουν ότι τα νευρωνικά δίκτυα αποτελούν ικανό ανταγωνιστή των παραδοσιακών μεθόδων πρόβλεψης. Οι Balkin and Ord (2000), μελετώντας τα αποτελέσματα πολλών διαγωνισμών πρόβλεψης, υποδεικνύουν τα νευρωνικά δίκτυα ως μία σημαντική προσθήκη στην εργαλειοθήκη της πρόβλεψης χρονοσειρών. Όσον αφορά στο σύστημα ANFIS, η ανωτερότητα του ως προς την μοντελοποίηση χρονοσειρών έχει επιδειχθεί τόσο από τους Jang et al. (1997), όσο και από τους Abraham et al. (2005).

### **2.3. Τεχνητή Νοημοσύνη και πρόβλεψη φαρμακευτικών πωλήσεων**

---

Προηγούμενες μελέτες στον τομέα της πρόβλεψης φαρμακευτικών πωλήσεων περιλαμβάνουν την εφαρμογή Νευρωνικών Δικτύων (Bansal, Vadhavkar, & Gupta, 1998), την σύγκριση του μοντέλου ARIMA με Υβριδικά Νευρωνικά Δίκτυα (Khalilzadeh, 2008), την υιοθέτηση Νευρωνικών Δικτύων πρόσθιας τροφοδότησης, ανατροφοδότησης, γενικευμένης παλινδρόμησης, ακτινικών δικτύων και του συστήματος ANFIS (Koulouriotis & Mantas, 2012), την εφαρμογή παλινδρομικών μοντέλων (Wettermark et al., 2010) καθώς επίσης και την χρήση Νευρωνικών Δικτύων με τον αλγόριθμο Levenberg-Maquardt (Jiang X. F., 2012).

Τα Υβριδικά Νευρωνικά Δίκτυα αποδεικνύονται ανώτερα της μεθόδου ARIMA στην πρόβλεψη φαρμακευτικών πωλήσεων. Τα Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης και Ανατροφοδότησης καταγράφουν υψηλότερες επιδόσεις σε σχέση με τα Ακτινικά και τα Γενικευμένης Παλινδρόμησης Νευρωνικά Δίκτυα, ενώ το σύστημα ANFIS δείχνει ικανό να δώσει ικανοποιητικά αποτελέσματα με χαμηλό βαθμό πολυπλοκότητας και γρήγορη υλοποίηση. Ο αλγόριθμος Levenberg-Maquardt δίνει καλά αποτελέσματα στην πρόβλεψη φαρμακευτικών πωλήσεων.

Ωστόσο, όλες οι προαναφερθείσες μελέτες προσεγγίζουν το πρόβλημα με όρους αποθέματος, εστιάζοντας σε πωλήσεις συγκεκριμένων φαρμακευτικών προϊόντων.

## **3. Τεχνητή Νοημοσύνη**

---

Το χαρακτηριστικό της νοημοσύνης αποδίδεται κατ' αποκλειστικότητα στο ανθρώπινο είδος. Συνίσταται σε τρεις διακριτές αλλά ταυτόχρονα διαδραστικές διαδικασίες: την παρατήρηση, την αξιολόγηση (ή επεξήγηση) της παρατήρησης και κατόπιν την λήψη απόφασης βάσει της αξιολόγησης. Ο τομέας της Τεχνητής Νοημοσύνης ασχολείται με μεθοδολογίες που στόχο έχουν την προσομοίωση των

παραπάνω λειτουργιών. Ανάμεσα τους συγκαταλέγονται μοντέλα όπως τα Τεχνητά Νευρωνικά Δίκτυα, η Ασαφής Λογική και οι Γενετικοί Αλγόριθμοι.

Το εναρκτήριο λάκτισμα για την γέννηση της επιστήμης της Τεχνητής Νοημοσύνης δόθηκε από τον Βρετανό μαθηματικό Alan Turing όταν την δεκαετία του 1940 αναρωτήθηκε “Μπορούν οι υπολογιστές να σκεφτούν;”. Το περίφημο Turing Test χρησιμοποιείται ακόμη και σήμερα για να αξιολογήσει την ικανότητα ενός υπολογιστή να επιδεικνύει στοιχεία νοημοσύνης. Η πρώτη εργασία που διακρίνεται από στοιχεία Τεχνητής Νοημοσύνης παρουσιάστηκε από τους Warren McCulloch και Walter Pitts το 1943 και αποτέλεσε το πρώτο μοντέλο Τεχνητών Νευρωνικών Δικτύων. Η εργασία τους ενέπνευσε και άλλους ερευνητές να συνεχίσουν την εξέλιξη των Τεχνητών Νευρωνικών Δικτύων. Το 1956, οι John McCarthy, Martin Minsky και Claude Shannon οργάνωσαν στο Dartmouth College μία διάσκεψη για όσους ερευνητές είχαν δείξει ενδιαφέρον στα Νευρωνικά Δίκτυα. Η διάσκεψη αυτή έμελε να ονοματίσει την νέα επιστήμη ως «Τεχνητή Νοημοσύνη» («Artificial Intelligence»).

### 3.1. Τεχνητά Νευρωνικά Δίκτυα


---

#### 3.1.1. Νευρωνική δομή

---

Τα Τεχνητά Νευρωνικά Δίκτυα συνιστούν μία μέθοδο Τεχνητής Νοημοσύνης, εμπνευσμένη από το ανθρώπινο νευρικό σύστημα. Όπως φαίνεται στο σχήμα 3.1, ένας νευρώνας (δομικό στοιχείο του νευρικού συστήματος) αποτελείται από:

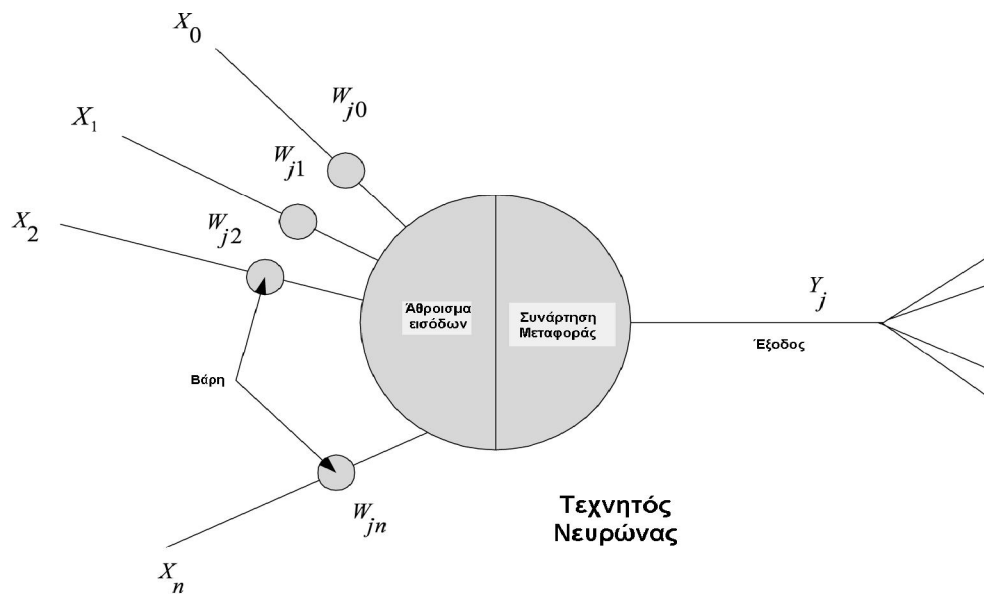
- τους δενδρίτες, οι οποίοι λαμβάνουν το σήμα
- το σώμα, το οποίο συγκεντρώνει και επεξεργάζεται όλα τα εισερχόμενα σήματα
- τον άξονα, ο οποίος προωθεί το αποτέλεσμα της επεξεργασίας
- τις συνάψεις, οι οποίες μεταβιβάζουν το τελικό σήμα στους επόμενους νευρώνες



Σχήμα 3.1 Μορφολογία φυσικού νευρώνα


Κατ' αντιστοιχία, ένας τεχνητός νευρώνας (σχήμα 3.2) αποτελείται από:

- τα δεδομένα εισόδου ( $X_i$ )
- τα βάρη με τα οποία συνδέεται η κάθε είσοδος ( $W_{ij}$ )
- την συνάρτηση μεταφοράς ( $\Phi_j$ )
- την έξοδο ( $Y_j$ )



Σχήμα 3.2 Μορφολογία τεχνητού νευρώνα

Όπως στην ανθρώπινη φυσιολογία πολλοί νευρώνες συνδέονται για την δημιουργία του νευρικού συστήματος, έτσι και τα Τεχνητά Νευρωνικά Δίκτυα αποτελούνται από κόμβους (νευρώνες) που συνδέονται μεταξύ τους και λειτουργούν παράλληλα (Σχήμα 3.3).




Σχήμα 3.3 Σύνδεση νευρώνων μέσω συνάψεων για την δημιουργία νευρικού συστήματος / Τεχνητών Νευρωνικών Δικτύων

Επιγραμματικά:

- Κάθε νευρώνας έχει πολλές εισόδους αλλά μόνο μία έξοδο η οποία αποτελεί είσοδο για άλλους νευρώνες
- Οι συνδέσεις διαφέρουν ως προς την σημαντικότητά τους που προσδιορίζεται από τα συναπτικά βάρη
- Η επεξεργασία κάθε νευρώνα καθορίζεται από την συνάρτηση μεταφοράς, η οποία καθορίζει την έξοδο σε σχέση με τις εισόδους και τα συναπτικά βάρη

Αναλυτικά:

Έστω ένας απλοϊκός νευρώνας (Σχήμα 3.4), ο οποίος λαμβάνει  $n$  εισόδους ( $X_1, X_2, \dots, X_n$ ) και παράγει μία έξοδο ( $Y$ ). Κάθε νευρώνας χαρακτηρίζεται από μία πόλωση  $b$ , η οποία μπορεί να είναι μηδενική ή μη μηδενική.



**Σχήμα 3.4** Είσοδοι ενός απλοϊκού τεχνητού νευρώνα


Σε κάθε μία από τις εισόδους αντιστοιχεί ένα βάρος ( $W_1, W_2, \dots, W_n$ ). Η συνολική είσοδος του νευρώνα υπολογίζεται βάσει του τύπου:

$$U = \sum_{i=1}^n (X_i \cdot W_i) + b \quad (3.1)$$

Η έξοδος του νευρώνα ( $Y$ ) υπολογίζεται βάσει του τύπου:

$$Y = \Phi(U) \quad (3.2)$$

Η συνάρτηση  $\Phi$  ονομάζεται συνάρτηση ενεργοποίησης ή συνάρτηση μεταφοράς και πιο συχνά συναντάται με τις ακόλουθες μορφές:



**Σχήμα 3.5** Παραδείγματα συναρτήσεων μεταφοράς

Όπου:

(a) Συνεχής συνάρτηση

$$\Phi(U) = U \quad (3.3)$$

(b) Λογιστική σιγμοειδής συνάρτηση

$$\Phi(U) = \frac{1}{1 + e^{-U}} \quad (3.4)$$

(c) Υπερβολική εφαπτομένη σιγμοειδής συνάρτηση

$$\Phi(U) = \frac{2}{1 + e^{-2U}} - 1 \quad (3.5)$$

Η μη γραμμική δομή των Τεχνητών Νευρωνικών Δικτύων τους δίνει την δυνατότητα να αναγνωρίζουν συσχετίσεις και πρότυπα ανάμεσα στα δεδομένα που επεξεργάζονται.


### 3.1.2. Αρχιτεκτονική Νευρωνικών Δικτύων

Βασικοί παράμετροι της αρχιτεκτονικής των ΤΝΔ αποτελούν:


- i. Το πλήθος των επιπέδων του δικτύου. Διακρίνονται σε ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και, αναλόγως τις ανάγκες του προβλήματος, σε ένα ή περισσότερα κρυφά επίπεδα.
- ii. Το πλήθος των νευρώνων σε κάθε επίπεδο. Η φύση του προβλήματος υποδεικνύει τον αριθμό των νευρώνων που απαιτούνται. Οι μεταβλητές του προβλήματος ορίζονται ως είσοδοι του δικτύου, ενώ για την πλειοψηφία των ΤΝΔ μία έξοδος αρκεί. Το πλήθος των νευρώνων των κρυφών επιπέδων συνήθως καθορίζεται μέσω δοκιμής και σφάλματος.
- iii. Οι συνδέσεις μεταξύ των επιπέδων. Αυτές μπορεί να διακρίνονται σε εμπρόσθια τροφοδότηση (Feed-forward Neural Networks) όπως φαίνεται στο




Σχήμα 3.6 και σε ανατροφοδότηση (Recurrent Neural Networks). Όταν υπάρχει ανατροφοδότηση από το κρυφό επίπεδο προς το επίπεδο εισόδου, το δίκτυο ονομάζεται Elman (Σχήμα 3.7). Όταν το επίπεδο εξόδου ανατροφοδοτεί το επίπεδο εισόδου, το δίκτυο ονομάζεται Jordan (Σχήμα 3.8).



Σχήμα 3.6 Πολυεπίπεδο νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης



Σχήμα 3.7 Ανατροφοδοτούμενο νευρωνικό δίκτυο τύπου Elman



Σχήμα 3.8 Ανατροφοδοτούμενο νευρωνικό δίκτυο τύπου Jordan

### 3.1.3. Λειτουργία Νευρωνικών Δικτύων

Οι λειτουργίες που μπορεί να εκτελέσει ένα Τεχνητό Νευρωνικό Δίκτυο είναι:

- (a) Η εκπαίδευση, η οποία ορίζεται ως η διαδικασία τροποποίησης των βαρών των συνδέσεων, ώστε όταν του παρέχεται μία συγκεκριμένη είσοδος να μπορεί να αποδώσει μία συγκεκριμένη έξοδο.
- (b) Η ανάκληση, η οποία ορίζεται ως η διαδικασία υπολογισμού της εξόδου βάσει συγκεκριμένων τιμών εισόδου και βαρών.

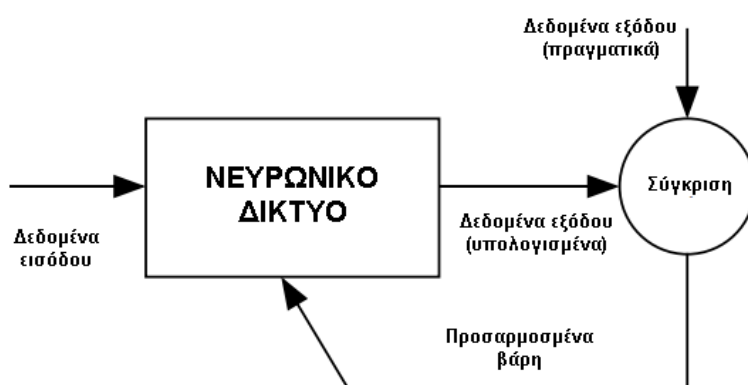
Για να χρησιμοποιηθεί ένα δίκτυο πρέπει πρώτα να περάσει την διαδικασία εκπαίδευσης. Αρχικά στο δίκτυο παρέχονται τα δεδομένα εισόδου και εξόδου. Στην συνέχεια τροποποιούνται τα συναπτικά βάρη έως ότου επιτευχθεί η βέλτιστη σύγκλιση μεταξύ των πραγματικών δεδομένων εξόδου και αυτών που παράγει το δίκτυο. Η διαδικασία εκπαίδευσης ή μάθησης διακρίνεται στα παρακάτω είδη:

- i. Μάθηση υπό επίβλεψη
- ii. Μάθηση χωρίς επίβλεψη
- iii. Βαθμολογημένη Μάθηση

Η πλειοψηφία των εφαρμογών υιοθετεί την μάθηση υπό επίβλεψη στην οποία έχουν αναπτυχθεί οι εξής αλγόριθμοι:

- i. Κανόνας Δέλτα
- ii. Αλγόριθμος οπισθοδιάδοσης σφάλματος
- iii. Ανταγωνιστική μάθηση
- iv. Τυχαία μάθηση

Σχηματικά, η εκπαίδευση ενός Τεχνητού Νευρωνικού Δικτύου μπορεί να απεικονιστεί ως εξής:



Σχήμα 3.9 Διαδικασία εκπαίδευσης υπό επίβλεψη

Στο σημείο αυτό πρέπει να τονίσουμε την σημαντική επίπτωση που είχε η ανάπτυξη του αλγορίθμου οπισθοδιάδοσης σφάλματος (Backpropagation algorithm) στην εξέλιξη των Τεχνητών Νευρωνικών Δικτύων. Μέχρι την εξεύρεση του, τα Τεχνητά Νευρωνικά Δίκτυα αδυνατούσαν να λύσουν απαιτητικά προβλήματα, γεγονός που οδήγησε σε δυσμενή κριτική και κατ' επέκταση στην περιθωριοποίησή τους. Η ανάπτυξη του αλγορίθμου, στις αρχές της δεκαετίας του 1980, έδωσε νέα ώθηση στην έρευνα στον τομέα των Τεχνητών Νευρωνικών Δικτύων.

Η λειτουργία του έχει ως εξής:

- Τα δεδομένα εκπαίδευσης παρουσιάζονται στο δίκτυο και υπολογίζονται οι έξοδοι σύμφωνα με τους τύπους (3.1-3.5).
- Για τον κάθε κόμβο  $i$  του επιπέδου εξόδου  $j$  υπολογίζεται το σφάλμα  $e$  σύμφωνα με τον τύπο:

$$e_{ij} = |\hat{y}_{ij} - y_{ij}| \quad (3.6)$$

όπου  $\hat{y}_{ij}$  : η έξοδος που υπολογίζει το δίκτυο

$y_{ij}$  : η επιθυμητή έξοδος

- Στην συνέχεια υπολογίζεται το προσαρμοσμένο σφάλμα του κάθε νευρώνα ως εξής:

$$\delta_{ij} = e_{ij} \cdot \Phi'(U_{ij}) \quad (3.7)$$

όπου  $\Phi'(U_{ij})$ : η παράγωγος της συνάρτησης μεταφοράς

- Η διαδικασία συνεχίζεται με την οπισθοκύλιση του σφάλματος στο προηγούμενο της εξόδου επίπεδο  $j-1$ :

$$\delta_{ij-1} = \Phi'(U_{ij-1}) \cdot \sum (w_{ij-1,ij} \cdot \delta_{ij}) \quad (3.8)$$

όπου το άθροισμα αναφέρεται σε όλους τους νευρώνες του επόμενου επιπέδου με τους οποίους ο νευρώνας  $i$  συνδέεται με βάρη  $w_{ij-1,ij}$ .

- Η διαδικασία συνεχίζεται έως ότου διαδοθεί τα σφάλμα μέχρι το επίπεδο εισόδου.

- Η προσαρμογή των βαρών που ενώνουν τον νευρώνα  $i$  του επιπέδου  $j-1$  με τον νευρώνα  $i$  του επιπέδου  $j$  υπολογίζεται με τον τύπο:

$$\Delta w_{ij-1,ij} = -d \cdot \delta_{ij} \cdot \hat{y}_{ij-1} \quad (3.9)$$

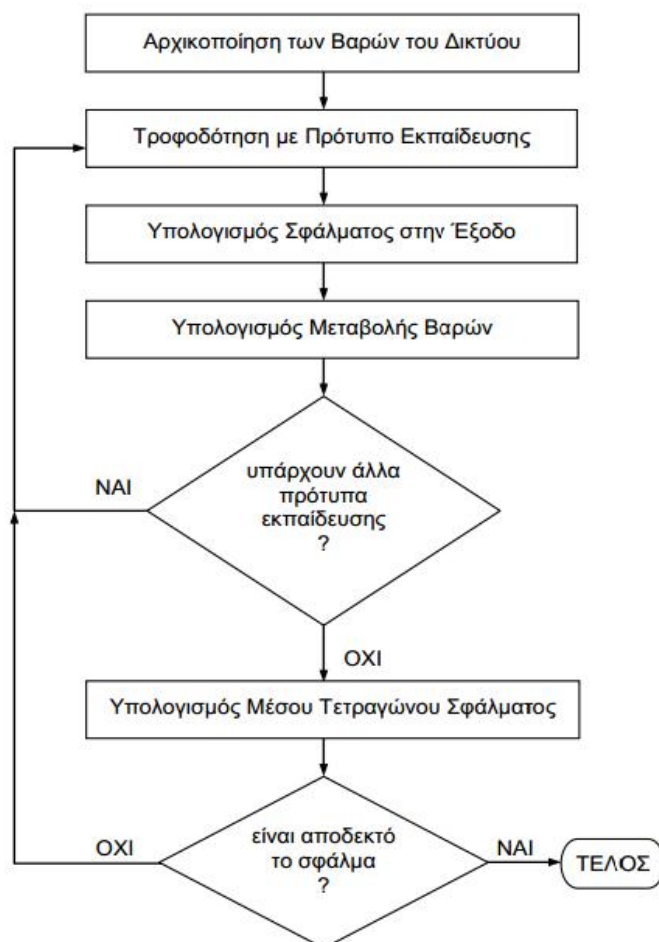
όπου  $d$  : ο ρυθμός εκπαίδευσης

- Το συνολικό σφάλμα για  $n$  νευρώνες εξόδου σε  $m$  δεδομένα εκπαίδευσης ορίζεται ως εξής:

$$E = \frac{1}{m \cdot n} \sum_{k=1}^m \sum_{i=1}^n \delta_{k,i}^2 \quad (3.10)$$

- Η εκπαίδευση τερματίζεται εφόσον ελαχιστοποιηθεί το συνολικό σφάλμα.


Η σχηματική απεικόνιση του αλγόριθμου παρουσιάζεται παρακάτω.




**Σχήμα 3.10** Αλγόριθμος εκπαίδευσης με διάδοση του σφάλματος προς τα πίσω

Η βασική ιδέα του αλγορίθμου οπισθοδιάδοσης σφάλματος συνίσταται στον καθορισμό του ποσοστού του συνολικού σφάλματος που αντιστοιχεί σε κάθε νευρώνα του ολικού δικτύου.

Η εκπαίδευση ενός Τεχνητού Νευρωνικού Δικτύου δεν δίνει πάντα επιθυμητά αποτελέσματα. Παραδείγματα μη επιθυμητής εκπαίδευσης αποτελούν η υποπροσαρμογή (Σχήμα 3.11) και η υπερπροσαρμογή (Σχήμα 3.12).



Σχήμα 3.11 Παράδειγμα ελλιπούς εκπαίδευσης



Σχήμα 3.12 Παράδειγμα υπερβολικής εκπαίδευσης

Στα πλεονεκτήματα των Νευρωνικών Δικτύων συγκαταλέγονται:

- Η μη γραμμική δομή τους η οποία τους δίνει την δυνατότητα να αναγνωρίζουν συσχετίσεις και πρότυπα ανάμεσα στα δεδομένα που επεξεργάζονται
- Η προσαρμοστικότητα σε διαφορετικά περιβάλλοντα, καθώς διαθέτουν την ικανότητα να μαθαίνουν μέσω παραδειγμάτων
- Η μεγάλη ανοχή τους σε σφάλματα, εξαιτίας των πολλών μονάδων επεξεργασίας και της διανομής της πληροφορίας σε όλο το δίκτυο

- Η ταχύτητα επεξεργασίας, που οφείλεται στην παράλληλη επεξεργασία των κόμβων
- Ο υψηλός βαθμός ελευθερίας που προσφέρει στην μοντελοποίηση ενός προβλήματος

Στα μειονεκτήματα των Νευρωνικών Δικτύων συγκαταλέγονται:

- Η έλλειψη δυνατότητας ερμηνείας των αποτελεσμάτων. Στην πράξη, τα Τεχνητά Νευρωνικά Δίκτυα λειτουργούν ως μαύρα κουτιά. Λαμβάνουν τα δεδομένα εισόδου και ρυθμίζοντας τα συναπτικά βάρη μεταξύ των νευρώνων, προσεγγίζουν τα δεδομένα εξόδου
- Ο υψηλός βαθμός ελευθερίας που προσφέρει στην μοντελοποίηση ενός προβλήματος, απαιτεί την αντίστοιχη γνώση και εμπειρία του μελετητή

### 3.1.4. Εφαρμογές Νευρωνικών Δικτύων

Εφαρμογές των Νευρωνικών Δικτύων συναντώνται σε διάφορους τομείς όπως η οικονομία, η βιομηχανία, το περιβάλλον, οι μεταφορές, η ιατρική και πολλοί άλλοι. Τα προβλήματα που καλούνται να επιλύσουν διακρίνονται στην πρόβλεψη, την ταξινόμηση και τον έλεγχο. Στον επόμενο πίνακα αναφέρουμε ενδεικτικά μερικές πρόσφατες εφαρμογές των Τεχνητών Νευρωνικών Δικτύων.

**Πίνακας 3-1** Μερικές πρόσφατες εφαρμογές των Νευρωνικών Δικτύων

Εφαρμογές	Μελέτη
Πωλήσεις τροφίμων	Doganis et al. (2006)
Συγκέντρωση Μονοξειδίου του Άνθρακα	Chelani & Devotta (2007)
Ροή κυκλοφορίας	Jiang & Adeli (2005)
Τουριστική ζήτηση	Atsalakis (2005), Palmer et al. (2006)
Ενεργειακή ζήτηση	Abdel-Aal (2008)
Διάγνωση Θυρεοειδούς	Zhang & Berardi (1998)
Ανάπτυξη νέων προϊόντων	Thieme et al. (2000)
Τραχύτητα επιφάνειας	Feng & Wang (2002)
Πτώχευση	Pendkarkar (2005)
Πιστοληπτική ικανότητα	Lee et al. (2000)
Τιμή συναλλάγματος	Zhang & Wan (2007)
Τιμή Χρηματιστηριακού Δείκτη	Wang (2009)



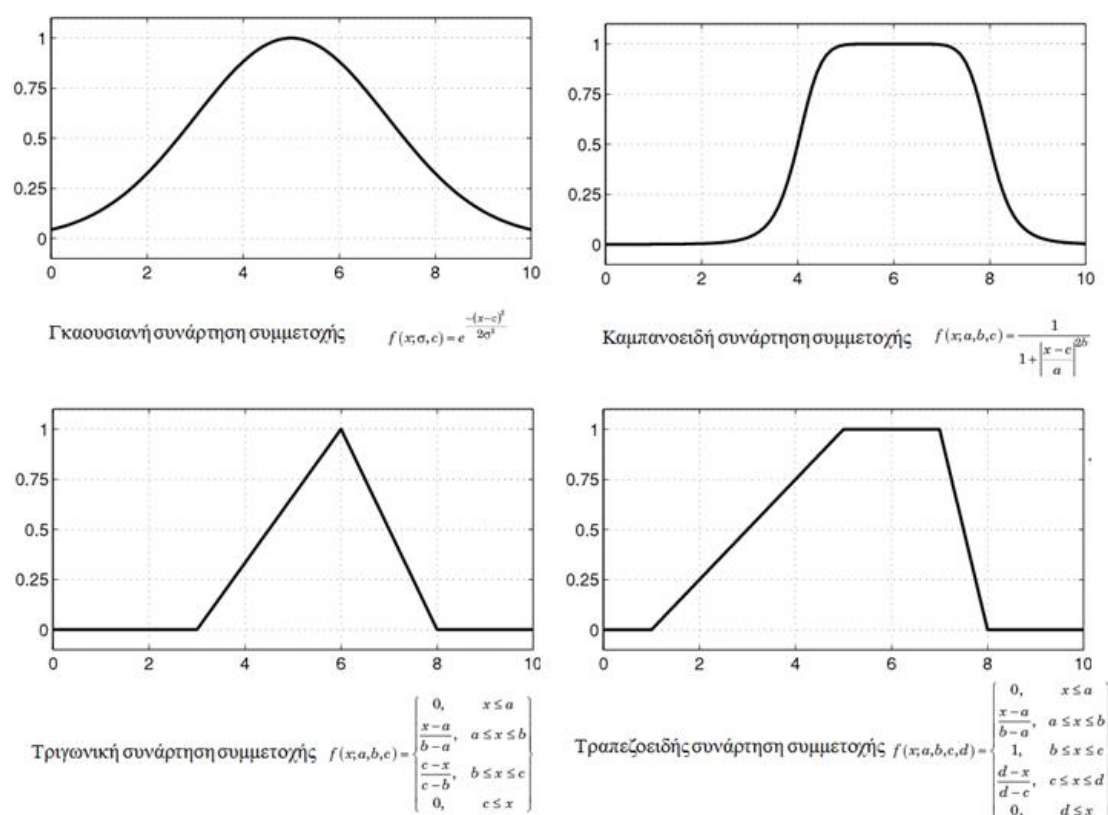
### 3.2. Νεύρο-Ασαφή Συστήματα

Τα Νεύρο-Ασαφή Συστήματα αποτελούν τον συνδυασμό των Νευρωνικών Δικτύων με την Ασαφή Λογική. Προέκυψαν στην προσπάθεια να υπερκεραστούν τα μειονεκτήματα τόσο των ασαφών συστημάτων εξαγωγής συμπερασμάτων (οι ασαφείς κανόνες πρέπει να καθοριστούν εκ των προτέρων) όσο και των Νευρωνικών Δικτύων (οι σχέσεις που δημιουργούν είναι δύσκολο να κατανοηθούν).

#### 3.2.1. Ασαφής Λογική

Η **ασαφής λογική** προτάθηκε από τον Zadeh (1965) ως ένας εναλλακτικός τρόπος απεικόνισης των δεδομένων. Σε αντίθεση με την κλασσική μαθηματική λογική όπου τα δεδομένα είτε ανήκουν είτε δεν ανήκουν σε ένα σύνολο, στην ασαφή λογική τα δεδομένα μπορεί να ανήκουν σε ένα ή περισσότερα σύνολα.


Η **συνάρτηση συμμετοχής** καθορίζει τον βαθμό στον οποίο τα δεδομένα ανήκουν στα διαφορετικά σύνολα. Το πιο συνηθισμένο εύρος για τις τιμές μια συνάρτησης συμμετοχής είναι  $[0,1]$ . Όσο μεγαλύτερη είναι η τιμή συμμετοχής  $A(x)$  τόσο περισσότερο τυπικά το  $x$  ανήκει στο  $A$ . Παραδείγματα συναρτήσεων συμμετοχής απεικονίζονται στο Σχήμα 3.13.



Σχήμα 3.13 Παραδείγματα συναρτήσεων συμμετοχής

Κάθε σύνολο που ορίζεται μέσω μιας συνάρτησης συμμετοχής ονομάζεται **ασαφές σύνολο**.

**Ασαφής Μεταβλητή** είναι μία μεταβλητή της οποίας οι τιμές ορίζονται με ασαφή σύνολα. Παραδείγματος χάριν τα ασαφή σύνολα {νεαρός, μεσήλικας, ηλικιωμένος} θα μπορούσαν να είναι το πεδίο τιμών της ασαφούς μεταβλητής «ηλικία». Η μεταβλητή «ηλικία» χαρακτηρίζεται και ως λεκτική μεταβλητή.



Σχήμα 3.14 Παραδείγματα ασαφών συνόλων

**Ασαφής πρόταση** είναι αυτή που θέτει μια τιμή σε μια ασαφή μεταβλητή. Για παράδειγμα στην ασαφή πρόταση «Η ηλικία του Γιάννη είναι μεσήλικας», η «ηλικία» είναι η ασαφής μεταβλητή και το «μεσήλικας» είναι ένα ασαφές σύνολο που είναι η τιμή της μεταβλητής.

**Ασαφής κανόνας** είναι μια υπό συνθήκη έκφραση που συσχετίζει δύο ή περισσότερες ασαφείς προτάσεις. «ΕΑΝ η ηλικία του Γιάννη είναι ηλικιωμένος ΤΟΤΕ η πίεση του είναι υψηλή».

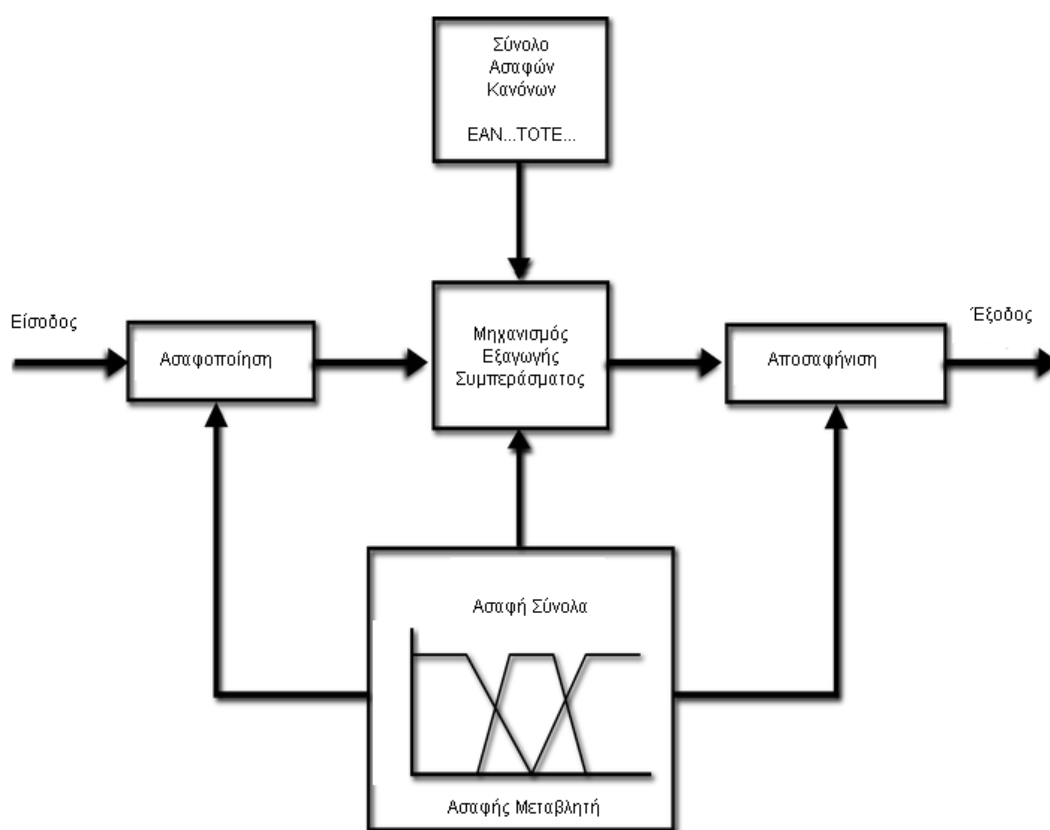
Το κύριο πλεονέκτημα της ασαφούς λογικής είναι ότι με την χρήση των ασαφών συνόλων μπορεί να κατηγοριοποιήσει δεδομένα τα οποία χαρακτηρίζονται από ανακρίβεια ή που επιδέχονται διαφορετικές ερμηνείες. Οι άνθρωποι σκέπτονται συνήθως όχι με όρους ακριβών συμβόλων και αριθμών αλλά με ασαφείς όρους. Αυτοί οι ασαφείς όροι προσδιορίζουν κατηγορίες όχι απόλυτα διαχωρίσιμες. Καθορίζοντας λοιπόν έναν βαθμό αληθείας (μέσω των συναρτήσεων συμμετοχής) και κάνοντας χρήση λεκτικών μεταβλητών οι οποίες μπορούν να γίνουν εύκολα αντιληπτές από τον ανθρώπινο νου, η ασαφής λογική μπορεί να καταστεί αποτελεσματική στην αντιμετώπιση μη γραμμικών προβλημάτων, με αβεβαιότητα.

### 3.2.2. Ασαφή Συστήματα

Τα ασαφή συστήματα εξαγωγής συμπερασμάτων (Fuzzy Inference Systems) αποτελούν την διαδικασία αντιστοίχισης δεδομένων εισόδου σε δεδομένα εξόδου με την χρήση ασαφούς λογικής.

Σύμφωνα με τους Jang et al. (1997), ένα ασαφές σύστημα αποτελείται από:

- i. Ένα σύνολο ασαφών κανόνων
- ii. Μία βάση δεδομένων που καθορίζει τις συναρτήσεις συμμετοχής
- iii. Τον μηχανισμό βάσει του οποίου γίνεται η εξαγωγή συμπερασμάτων




Σχήμα 3.15 Λειτουργία Ασαφών Συστημάτων

Γενικά ένας κανόνας από μόνος του δεν επαρκεί για τα περισσότερα πρακτικά προβλήματα. Αυτό που χρειαζόμαστε είναι περισσότεροι του ενός κανόνες οι οποίοι να αλληλεπιδρούν μεταξύ τους. Η έξοδος κάθε κανόνα θα είναι ένα ασαφές σύνολο. Τα ασαφή σύνολα που προκύπτουν σαν συνέπεια των κανόνων συγκεντρώνονται για να σχηματίσουν ένα ασαφές σύνολο εξόδου από το οποίο μέσω της διαδικασίας της αποσαφήνισης θα δώσει μια μοναδική τιμή.

Τα είδη ασαφών συστημάτων που υπάρχουν είναι:

- (a) Το σύστημα Mamdani, το οποίο σαν έξοδο παράγει ένα ασαφές σύνολο και πρέπει να αποασαφοποιηθεί
- (b) Το σύστημα Sugeno, το οποίο στην έξοδό του χρησιμοποιεί μία συνάρτηση για την παραγωγή πραγματικών αριθμών



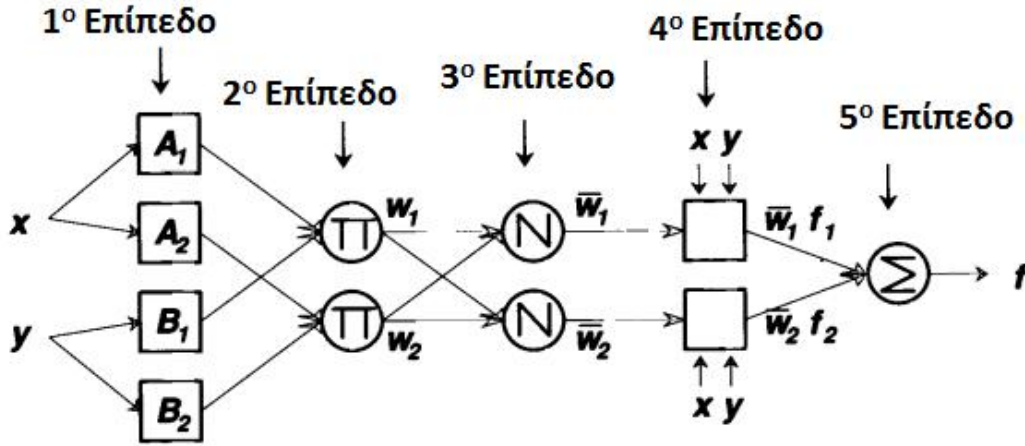
Σχήμα 3.14 Αρχιτεκτονική Ασαφών Συστημάτων

Η λειτουργία των Ασαφών συστημάτων διακρίνεται επιμέρους:


- Στην ασαφοποίηση των εισόδων, όπου για κάθε μεταβλητή προσδιορίζεται ο βαθμός συμμετοχής της
- Στην εφαρμογή ασαφών τελεστών (π.χ. MIN, MAX)
- Στην εφαρμογή της μεθόδου εξαγωγής συμπεράσματος
- Στην άθροιση των αποτελεσμάτων
- Στην αποσαφήνιση της εξόδου

### 3.2.3. Προσαρμοστικό Νεύρο-Ασαφές Σύστημα Εξαγωγής Συμπεράσματος

Το προσαρμοστικό νεύρο-ασαφές σύστημα εξαγωγής συμπεράσματος (Adaptive Neuro-Fuzzy Inference System, ANFIS) θεμελιώθηκε από τον Jang (1993) και αποτελεί έναν συνδυασμό των Τεχνητών Νευρωνικών Δικτύων και των Ασαφών Συστημάτων.



Σχήμα 3.15 Αρχιτεκτονική ANFIS



Σχήμα 3.16 Το σύστημα Sugeno που υιοθετεί το ANFIS

Αναλυτικά οι υπολογισμοί που πραγματοποιούνται σε κάθε επίπεδο είναι:

- Το 1<sup>ο</sup> επίπεδο περιλαμβάνει προσαρμόσιμους κόμβους με συναρτήσεις:

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), & \text{for } i = 1,2 \\ O_{1,i} &= \mu_{B_{i-2}}(y), & \text{for } i = 3,4 \end{aligned} \quad (3.11)$$

Όπου  $x$  και  $y$  είναι οι κόμβοι εισόδου,  $A$  και  $B$  είναι τα ασαφή σύνολα, ενώ  $\mu(x)$  και  $\mu(y)$  είναι οι συναρτήσεις συμμετοχής. Διάφορες συναρτήσεις συμμετοχής μπορούν να χρησιμοποιηθούν, έστω όμως η καμπανοειδής συνάρτηση με τον ακόλουθο τύπο:

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}}, \quad (3.12)$$

Οι παράμετροι  $a_i$ ,  $b_i$ ,  $c_i$  ονομάζονται και αρχικές παράμετροι.

- **Το 2ο επίπεδο** περιλαμβάνει σταθερούς κόμβους, οι έξοδοι των οποίων δίνεται από το γινόμενο των εισερχόμενων σημάτων. Η έξοδος αυτού του επιπέδου αντιπροσωπεύει τον βαθμό ενεργοποίησης του κάθε ασαφούς κανόνα.

$$O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad for \ i = 1,2 \quad (3.13)$$

- **Το 3ο επίπεδο** περιλαμβάνει σταθερούς κόμβους οι οποίοι υπολογίζουν τον λόγο του βαθμού ενεργοποίησης του κάθε κανόνα προς το άθροισμα όλων των βαθμών ενεργοποίησης. Αναφέρεται και κανονικοποιημένος βαθμός ενεργοποίησης.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad for \ i = 1,2 \quad (3.14)$$

- **Το 4ο επίπεδο** περιλαμβάνει προσαρμόσιμους κόμβους οι οποίοι υπολογίζουν

$$O_{4,i} = \bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i \cdot x + q_i \cdot y + r_i), \quad (3.15)$$

Οι παράμετροι  $p_i, q_i, r_i$  ονομάζονται και επακόλουθοι παράμετροι.

- **Το 5ο επίπεδο** περιλαμβάνει έναν σταθερό κόμβο ο οποίος αθροίζει όλα τα εισερχόμενα σήματα.

$$O_{5,i} = \sum_i \bar{w}_i \cdot f_i, \quad (3.16)$$

Η εκπαίδευση του ANFIS απαιτεί την βελτιστοποίηση των:

- Αρχικών παραμέτρων ( $a_i, b_i, c_i$  για την περίπτωση καμπανοειδούς συνάρτησης)
- Επακόλουθων παραμέτρων ( $p_i, q_i, r_i$ )

Οι Jang et al. (1997) προτείνουν μία υβριδική μεθοδολογία για την βελτιστοποίηση των παραπάνω παραμέτρων, σε δύο φάσεις. Με το εμπρόσθιο πέρασμα το σήμα διαδίδεται από το 1ο επίπεδο προς το 4ο επίπεδο και οι παράμετροι του ασαφούς συστήματος τύπου Sugeno ( $p_i, q_i, r_i$ ) βελτιστοποιούνται με την μέθοδο των ελαχίστων τετραγώνων. Κατά την διάρκεια του όπισθεν πέρασματος βελτιστοποιούνται οι παράμετροι των συναρτήσεων συμμετοχής με την χρήση ενός αλγορίθμου βαθμωτής κατάβασης.



	Εμπροσθόδρομο πέρασμα	Οπισθόδρομο πέρασμα
Αρχικές παράμετροι ( $a_i, b_i, c_i$ )	Προκαθορισμένες	Βαθμωτή κατάβαση
Επακόλουθες παράμετροι ( $p_i, q_i, r_i$ )	Εκτιμήτρια ελαχίστων τετραγώνων	Προκαθορισμένες
Σήματα	Έξοδοι των κόμβων	Σήματα σφάλματος

Το πλεονέκτημα της μεθόδου έγκειται στο γεγονός της ύπαρξης τόσο γραμμικών όσο και μη γραμμικών μεθόδων, που την καθιστά ταχύτερη από τα κλασικά νευρωνικά δίκτυα. Οι επακόλουθες παράμετροι ( $p_i, q_i, r_i$ ) που ευρίσκονται με αυτόν τον τρόπο, είναι βέλτιστες υπό την προϋπόθεση ότι οι αρχικές παράμετροι ( $a_i, b_i, c_i$ , για την περίπτωση καμπανοειδούς συνάρτησης) των προϋποθέσεων είναι προκαθορισμένες (αμετάβλητες). Αναλόγως, η υβριδική προσέγγιση συγκλίνει πολύ γρηγορότερα μιας και μειώνει τις διαστάσεις του διαστήματος αναζήτησης της αρχικής καθαρής μεθόδου οπισθόδρομης διάδοσης.

Μέχρι τώρα γινόταν χρήση προκαθορισμένων και αυθαίρετα επιλεγμένων συναρτήσεων συμμετοχής. Πολλές φορές έχουμε μια συλλογή από δεδομένα εισόδου-εξόδου και δεν μπορούμε να χρησιμοποιήσουμε ένα προκαθορισμένο μοντέλο βασισμένο στα στοιχεία αυτά ώστε να ξέρουμε ποιες συναρτήσεις συμμετοχής και με ποιες παραμέτρους να χρησιμοποιήσουμε. Τότε μπορούμε να βοηθηθούμε από το ANFIS, ώστε να βρούμε τις καταλληλότερες συναρτήσεις συμμετοχής.

Οι νεύρο-προσαρμοστικές τεχνικές είναι αρκετά απλές. Έτσι παρέχεται μια μέθοδος ώστε το ασαφές μοντέλο να εκπαιδευτεί με τις πληροφορίες που του δίνει το σύνολο των δεδομένων, ώστε να υπολογιστούν οι παράμετροι των συναρτήσεων συμμετοχής με σκοπό την εύρεση του καλύτερου τρόπου ώστε να επιτρέπει στο σύστημα εξαγωγής συμπερασμάτων να ανιχνεύει τα δεδομένα εισόδου-εξόδου. Η μέθοδος αυτή είναι παρόμοια με αυτή των νευρωνικών δικτύων.

Ο υπολογισμός των παραμέτρων αυτών, που αλλάζουν κατά τη διάρκεια της διαδικασίας εκμάθησης, διευκολύνεται από ένα βαθμωτό διάνυσμα που μας δείχνει πόσο καλά το FIS μοντελοποιεί τα δεδομένα εισόδου-εξόδου για το εν λόγω σύνολο παραμέτρων. Μόλις αποκτήσουμε το βαθμωτό διάνυσμα μπορούμε να εφαρμόσουμε κάποιον από τους πολλούς αλγόριθμους βελτιστοποίησης, για να βελτιώσουμε αυτές τις παραμέτρους, ούτως ώστε να μειώσουμε το μέγεθος του σφάλματος (συνήθως το άθροισμα των τετραγώνων των διαφορών μεταξύ πραγματικών και επιθυμητών τιμών).

Όσον αφορά στους περιορισμούς του ANFIS, αυτοί πηγάζουν κυρίως από την υιοθέτηση τους ασαφούς συστήματος Sugeno οπότε και πρέπει να είναι:

- Πρώτης ή μηδενικής τάξης συστήματα
- Μιας εξόδου, που αποκτήθηκε με χρήση αποσαφήνισης ζυγισμένου μέσου όρου (γραμμικές ή σταθερές συναρτήσεις συμμετοχής)
- Μοναδιαίου βάρους για κάθε κανόνα

Επιπλέον δεν μπορεί να γίνει χρήση οποιασδήποτε συνάρτησης συμμετοχής, παρά μόνο προκαθορισμένων.

#### 3.2.4. Εφαρμογές ANFIS

Εφαρμογές Νεύρο-ασαφών Συστημάτων συναντώνται σε διάφορους τομείς όπως η οικονομία, η βιομηχανία, το περιβάλλον, οι μεταφορές, η ιατρική και πολλοί άλλοι. Τα προβλήματα που καλούνται να επιλύσουν διακρίνονται στην πρόβλεψη, την ταξινόμηση και τον έλεγχο. Στον επόμενο πίνακα αναφέρουμε ενδεικτικά μερικές πρόσφατες εφαρμογές των Νεύρο-ασαφών Συστημάτων.

**Πίνακας 3-2** Μερικές πρόσφατες εφαρμογές του ANFIS

Εφαρμογές	Μελέτη
Αγορά μετοχών	Atsalakis & Valavanis (2009)
Ταχύτητα ανέμου	Mohandes et al. (2011)
Ηλιακή ακτινοβολία	Moghaddamnia et al. (2009)
Τουριστική ζήτηση	Chen et al. (2010)
Ενεργειακή ζήτηση	Atsalakis & Ucenic (2006)
Ανίχνευση κρίσης επιληψίας	Subasi (2007)
Επιλογή προμηθευτή	Güneri et al. (2011)
Πωλήσεις αυτοκινήτων	Wang et al. (2011)
Τιμή συναλλάγματος	Atsalakis et al. (2007)

## 4. Μοντελοποίηση προβλήματος

---

Κατά την διαδικασία μοντελοποίησης τόσο των Τεχνητών Νευρωνικών Δικτύων όσο και του συστήματος ANFIS, παράμετροι όπως η επεξεργασία δεδομένων και η μέθοδος αξιολόγησης πρέπει να ληφθούν υπόψη. Κατά την υλοποίηση των Νευρωνικών Δικτύων πρέπει επίσης να προσδιοριστεί ο τύπος και η βέλτιστη αρχιτεκτονική του δικτύου, οι συναρτήσεις μεταφοράς καθώς και ο αλγόριθμος εκπαίδευσης. Όσον αφορά στο ANFIS, δεν υπάρχει δυνατότητα εναλλακτικής αρχιτεκτονικής, οπότε η υλοποίηση του περιορίζεται στην επιλογή των συναρτήσεων συμμετοχής.

Και στις δύο περιπτώσεις η επιλογή των εισόδων και ο τρόπος παρουσίασης των δεδομένων στο μοντέλο, ώστε αυτό να εκπαιδευτεί σωστά, είναι μείζονος σημασίας. Τόσο τα Νευρωνικά δίκτυα όσο και το ANFIS συγκαταλέγονται στις μεθοδολογίες που καθοδηγούνται από τα δεδομένα (data-driven techniques). Αυτό σημαίνει ότι ο τρόπος με τον οποίο θα παρουσιαστούν τα δεδομένα στο δίκτυο θα καθορίσει εν πολλοίς και την συμπεριφορά του δικτύου.

Από τις προαναφερθείσες παραμέτρους, κάποιες θα καθοριστούν μέσω διαδικασιών δοκιμής-σφάλματος, ενώ άλλες θα προεπιλεγούν πριν την εξέταση του μοντέλου βάσει προηγούμενων μελετών που έδωσαν αξιόπιστα αποτελέσματα.

### 4.1. Επεξεργασία δεδομένων

---

Τα δεδομένα μας αποτελούνται από μηνιαίες φαρμακευτικές πωλήσεις για την περίοδο 2000-2013, όπως αυτά έχουν ανακοινωθεί τον Εθνικό Οργανισμό Φαρμάκων (ΕΟΦ). Το μέγεθος του δείγματος αριθμεί 168 παρατηρήσεις, το οποίο κρίνεται αρκετό δεδομένου ότι δεν υπάρχουν περαιτέρω επίσημα στοιχεία.

Η κατανομή των δεδομένων σε εντός-δείγματος (in-sample) και εκτός-δείγματος (out-of-sample) αποφασίστηκε να έχει αναλογία 90:10 (%). Αυτό μεταφράζεται στην περίοδο Ιανουαρίου 2000 έως και Δεκεμβρίου 2012 για τα εντός-δείγματος δεδομένα, ενώ η περίοδος Ιανουαρίου 2013 έως και Δεκεμβρίου 2013 αντιστοιχεί στα εκτός-δείγματος δεδομένα.

Για την αποφυγή υπολογιστικών προβλημάτων και την ομαλή λειτουργία των αλγορίθμων εκπαίδευσης, τα δεδομένα μας κανονικοποιήθηκαν στο διάστημα  $[-1,1]$ . Η συγκεκριμένη διαδικασία αποτελεί προεπιλογή της εργαλειοθήκης Νευρωνικών Δικτύων του λογισμικού MATLAB στο οποίο πραγματοποιήθηκε και η υλοποίηση των μοντέλων.

Όπως η πλειοψηφία των χρονοσειρών, έτσι και οι φαρμακευτικές πωλήσεις διακρίνονται από τάσεις και εποχικότητα. Ωστόσο οι Jang et al. (1997), κάνοντας χρήση του θεωρήματος Stone-Weierstrass, απέδειξαν ότι εφόσον δεν υπάρχει περιορισμός ως προς τον αριθμό των κανόνων, ένα μοντέλο Sugeno, μηδενικής τάξης, έχει απεριόριστη δύναμη προσέγγισης οποιασδήποτε μη γραμμικής συνάρτησης. Πάραυτα εφιστούν την προσοχή, διότι δεν υπάρχει κάποια μεθοδολογία για την σωστή δόμηση του μοντέλου Sugeno ώστε αυτό να μπορεί να προσεγγίσει τα δεδομένα εκπαίδευσης. Αλλά και τα Τεχνητά Νευρωνικά Δίκτυα έχουν αποδειχτεί ως καθολικοί προσεγγιστές από τους Hornik et al. (1989) και τον Cybenko (1989). Η ικανότητά τους να εντοπίζουν την εποχικότητα και την τάση μέσα στα δεδομένα έχει αποδειχτεί τόσο από τους Franses & Draisma (1997) όσο και από τους Alon et al. (2001). Ως εκ τούτου επιλέξαμε να μην αφαιρέσουμε αυτά τα χαρακτηριστικά από τα δεδομένα μας.

#### 4.2. Αξιολόγηση ακρίβειας πρόβλεψης

Ως κριτήρια απόδοσης για την αξιολόγηση των δικτύων που κατασκευάστηκαν επιλέξαμε τα παρακάτω:

- i. Το Μέσο Τετραγωνικό Σφάλμα (Mean Square Error – MSE), σύμφωνα με τον τύπο:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (4.1)$$

- ii. Την Ρίζα του Μέσου Τετραγωνικού Σφάλματος (Root Mean Square Error – RMSE), που ορίζεται ως:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (4.2)$$

- iii. Το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error – MAE), σύμφωνα με τον τύπο:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (4.3)$$

- iv. Το Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error – MAPE), το οποίο υπολογίζεται ως εξής:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \cdot 100 \quad (4.4)$$

όπου  $n$  : ο συνολικός αριθμός των νευρώνων εξόδου  
 $i$  : ο εκάστοτε νευρώνας εξόδου  
 $y_i$  : οι πραγματικές τιμές εξόδου  
 $\hat{y}_i$  : οι τιμές εξόδου που υπολογίζει το δίκτυο

### 4.3. Υλοποίηση μοντέλων

---


#### 4.3.1. Τεχνητά Νευρωνικά Δίκτυα

---

Βασικοί παράμετροι της αρχιτεκτονικής των ΤΝΔ αποτελούν:


- i. *Το πλήθος των επιπέδων του δικτύου.* Διακρίνονται σε ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και, αναλόγως τις ανάγκες του προβλήματος, σε ένα ή περισσότερα κρυφά επίπεδα. Στην προκειμένη περίπτωση επιλέξαμε ένα κρυφό επίπεδο, ακολουθώντας την πρακτική της πλειοψηφίας των ερευνητών στον τομέα της πρόβλεψης.
- ii. *Το πλήθος των νευρώνων σε κάθε επίπεδο.* Σε προβλήματα πρόβλεψης χρονοσειρών, το επίπεδο εισόδου αποτελείται από παρελθοντικές τιμές, ενώ το επίπεδο εξόδου εξαρτάται από τον ορίζοντα πρόβλεψης. Εάν στόχος είναι η πρόβλεψη ενός βήματος μπροστά, τότε ένας μοναδικός νευρώνας εξόδου κρίνεται επαρκής. Ωστόσο, στην περίπτωση πρόβλεψης πολλών βημάτων μπροστά, διαφορετικές προσεγγίσεις μπορούν να υιοθετηθούν. Ο Kline (2004) διερεύνησε τρεις μεθόδους για πρόβλεψη πολλών βημάτων μπροστά: την συνδυαστική μέθοδο (joint method), την ανεξάρτητη μέθοδο (independent method) και την επαναληπτική μέθοδο (iterated method). Η συνδυαστική μέθοδος χρησιμοποιεί ένα μοναδικό δίκτυο για την ταυτόχρονη πρόβλεψη όλων των επόμενων βημάτων. Η ανεξάρτητη μέθοδος αξιοποιεί ένα διαφορετικό δίκτυο για κάθε ορίζοντα πρόβλεψης. Η επαναληπτική μέθοδο χρησιμοποιεί ένα μοναδικό δίκτυο για την πρόβλεψη ενός βήματος μπροστά και στην συνέχεια εισάγει το αποτέλεσμα της πρόβλεψης στο επίπεδο εισόδου για την πρόβλεψη του επόμενου βήματος. Η διαδικασία επαναλαμβάνεται έως ότου ολοκληρωθεί ο ορίζοντας πρόβλεψης. Ο Kline συμπέρανε ότι η ανεξάρτητη μέθοδος υπερέχει των άλλων δύο αλλά το μέγεθος του δείγματος εκπαίδευσης καθώς επίσης και ο ορίζοντας πρόβλεψης ενδέχεται να επηρεάσουν αυτή της την υπεροχή. Οι Hamzacebi et. al. (2009) αναφέρουν καλύτερα αποτελέσματα με την χρήση της άμεσης μεθόδου η οποία ταυτίζεται με την συνδυαστική μέθοδο του Kline. Επιπροσθέτως, ο Hamzacebi (2008) ανέπτυξε το Εποχιακό Τεχνητό Νευρωνικό Δίκτυο (Seasonal Artificial Neural Network – SANN), το οποίο χρησιμοποιεί την εποχιακή παράμετρο “s” για τον καθορισμό των νευρώνων εισόδου και εξόδου. Η συγκεκριμένη εργασία καταλήγει στο συμπέρασμα ότι το δίκτυο SANN βελτιώνει τα αποτελέσματα πρόβλεψης σε δεδομένα με ισχυρή εποχικότητα. Εφόσον στόχος μας είναι η πρόβλεψη 12 βημάτων μπροστά (ένας χρόνος) αποφασίσαμε να υιοθετήσουμε

την άμεση μέθοδο δημιουργώντας ένα δίκτυο SANN με 12 νευρώνες στην είσοδο και 12 νευρώνες στην έξοδο (Σχήμα 12).



**Σχήμα 4.1** Αρχιτεκτονική Νευρωνικού Δικτύου που χρησιμοποιηθεί για μακροπρόθεσμη πρόβλεψη

- iii. Ο τρόπος παρουσίασης των δεδομένων στο μοντέλο. Τα Νευρωνικά Δίκτυα συγκαταλέγονται στις μεθοδολογίες που καθοδηγούνται από τα δεδομένα (data-driven techniques). Ο τρόπος λοιπόν με τον οποίο θα παρουσιαστούν τα δεδομένα στο δίκτυο θα καθορίσει εν πολλοίς και την συμπεριφορά του δικτύου. Βάσει της συνδεσμολογίας που επιλέχθηκε και παρουσιάστηκε στο Σχήμα 12, ο κάθε νευρώνας του επιπέδου εισόδου όπως επίσης και του επιπέδου εξόδου αντιπροσωπεύει κατ' αποκλειστικότητα μία συγκεκριμένη εποχή. Παραδείγματος χάριν, ο 1ος νευρώνας εισόδου αφοσιώνεται στην παροχή δεδομένων για  $s=1$  (Ιανουάριος), ο 2ος νευρώνας εισόδου αφοσιώνεται στην παροχή δεδομένων για  $s=2$  (Φεβρουάριος) και ούτω καθεξής.



**Γράφημα 4.2** Στρατηγική παρουσίασης των δεδομένων στο προς εκπαίδευση μοντέλο



Κατά αυτό τον τρόπο, το σύνολο των δεδομένων εισόδου-εξόδου που θα παρουσιαστούν στο δίκτυο μας για εκπαίδευση μειώνονται από:

$$n = N - H = 156 \quad , \text{όπου } N = 168 \text{ (πλήθος παρατηρήσεων)} \\ H = 12 \text{ (ορίζοντας πρόβλεψης)}$$

σε:  $n = \frac{N-H}{s} = 13 \quad , \text{όπου } s = 12 \text{ (εποχικότητα)}$

Ακολουθώντας την συγκεκριμένη τακτική μειώνουμε αισθητά το πλήθος των παρατηρήσεων μας, επιδιώκουμε όμως την καλύτερη απεικόνιση της εποχικότητας.

- iv. Την συνάρτηση μεταφοράς σε κάθε επίπεδο (*Transfer Function*). Ως προς αυτή την παράμετρο επιλέξαμε την γραμμική συνάρτηση (*purelin*) για το επίπεδο εξόδου και την υπερβολική εφαπτομένη σιγμοειδής συνάρτηση (*tansig*) για το κρυφό επίπεδο. Η επιλογή μας βασίστηκε στην κοινή πρακτική μεταξύ των ερευνητών. Η πλειοψηφία κάνει χρήση της μη γραμμικής συνάρτησης μεταφοράς *tansig* εφόσον η λανθάνουσα σχέση ανάμεσα στα δεδομένα είναι μη γραμμικού χαρακτήρα.
- v. Οι συνδέσεις μεταξύ των επιπέδων. Σύμφωνα με τον Zhang (2012), τα πιο ευρέως διαδεδομένα μοντέλα Νευρωνικών Δικτύων για πρόβλεψη χρονοσειρών είναι τα δίκτυα εμπρόσθιας τροφοδότησης (*Feed-forward*). Οπότε αποφασίσαμε να διερευνήσουμε τον συγκεκριμένο τύπο Νευρωνικών Δικτύων.

Όλες οι παραπάνω παράμετροι προκαθορίστηκαν βάσει της βιβλιογραφίας. Ωστόσο υπάρχουν επιπλέον παράμετροι οι οποίες θα διερευνηθούν και θα αξιολογηθούν βάσει των κριτηρίων που περιγράφονται στην παράγραφο 4.2. Αυτές περιλαμβάνουν:

- i. Τον αριθμό των νευρώνων στο κρυφό επίπεδο. Σύμφωνα με τους Bakirtzis et al. (1996), τα νευρωνικά δίκτυα δεν είναι πολύ ευαίσθητα στην συγκεκριμένη παράμετρο. Πάραυτα έστω και μικρές βελτιώσεις στην τελική πρόβλεψη μπορούν να θεωρηθούν ευεργετικές όταν η τάξη μεγέθους είναι εκατομμύρια Ευρώ.
- ii. Την περαιτέρω κατανομή των εντός-δείγματος δεδομένων σε δεδομένα εκπαίδευσης (*Training data*) και δεδομένα επικύρωσης (*Validation data*). Η συγκεκριμένη τακτική, που αποκαλείται και *early stopping*, έχει ως σκοπό την αποφυγή υπερπροσαρμογής του μοντέλου μας στα δεδομένα εκπαίδευσης. Όσο το δίκτυο εκπαιδεύεται, υπολογίζεται και το σφάλμα στα δεδομένα

επικύρωσης. Το σφάλμα επικύρωσης (*Validation error*) στα αρχικά στάδια της εκπαίδευσης ακολουθεί την πορεία του σφάλματος εκπαίδευσης (*Training error*) και μειώνεται. Όταν όμως το μοντέλο αρχίσει την υπερπροσαρμογή, το σφάλμα επικύρωσης αυξάνεται. Όταν το σφάλμα επικύρωσης αυξηθεί για συγκεκριμένο αριθμό επαναλήψεων, η εκπαίδευση τερματίζεται και το δίκτυο επιστρέφει τα συναπτικά βάρη που είχαν υπολογιστεί για το ελάχιστο σφάλμα επικύρωσης. Αν και η συγκεκριμένη μεθοδολογία έχει συνήθως ευεργετικά αποτελέσματα για την απόδοση του μοντέλου, χαρακτηρίζεται από δύο βασικά μειονεκτήματα. Ο καθορισμός του υποσυνόλου επικύρωσης είναι δύσκολος καθώς πρέπει να είναι αντιπροσωπευτικό του ολικού δείγματος εκπαίδευσης. Επιπροσθέτως, ο καθορισμός δεδομένων επικύρωσης μειώνει περισσότερο το ουσιαστικό δείγμα εκπαίδευσης. Στην προκειμένη περίπτωση που το δείγμα μας αριθμεί 168 παρατηρήσεις, η κατανομή σε εντός-δείγματος και εκτός-δείγματος, μειώνει τα δεδομένα εκπαίδευσης σε 156 παρατηρήσεις. Η περαιτέρω κατανομή σε υποσύνολα εκπαίδευσης και επικύρωσης θα μειώσει τα ουσιαστικά δεδομένα εκπαίδευσης κατά τουλάχιστον 12 παρατηρήσεις. Λαμβάνοντας υπόψη τα παραπάνω, η χρήση δεδομένων επικύρωσης θα γίνει εφόσον κριθεί αναγκαίο.

- iii. *Τον αλγόριθμο εκπαίδευσης.* Όσον αφορά στην συγκεκριμένη παράμετρο πειραματιστήκαμε με τους αλγόριθμους *trainscg* (Scaled Conjugate gradient backpropagation) και *traingdx* (Gradient descent with momentum and adaptive learning rate backpropagation).

Για την καλύτερη γενίκευση του μοντέλου μας όπως επίσης και την αποφυγή υπερπροσαρμογής, δημιουργήσαμε 30 δίκτυα, τα εκπαιδεύσαμε στα εντός-δείγματος δεδομένα και τα αξιολογήσαμε στα εκτός-δείγματος δεδομένα. Τα αποτελέσματα παρουσιάζονται στην παράγραφο 5.1.

#### 4.3.2. ANFIS

---

Βασικοί παράμετροι της αρχιτεκτονικής του ANFIS αποτελούν:

- i. *Το πλήθος των μεταβλητών εισόδου.* Σε προβλήματα πρόβλεψης χρονοσειρών, το επίπεδο εισόδου αποτελείται από παρελθοντικές τιμές. Η μοντελοποίηση του ANFIS βασίζεται στον καθορισμό “n” παρελθοντικών τιμών, με χρονική απόσταση “d” μεταξύ τους για την πρόβλεψη της επόμενης μελλοντικής τιμής. Μαθηματικά εκφράζεται με τον ακόλουθο τύπο:

$$\hat{y}_{(t+d)} = f(y_t, y_{(t-d)}, y_{(t-2 \cdot d)}, \dots, y_{(t-(n-1) \cdot d)})$$

Όπου:

$t$  : η τρέχουσα χρονική στιγμή

$d$  : η απόσταση δειγματοληψίας

(υποδεικνύει την συσχέτιση των δεδομένων)

$n$  : το πλήθος των μεταβλητών εισόδου

Εφόσον τα δεδομένα μας παρουσιάζουν μηνιαία εποχικότητα, θέσαμε  $d=12$ . Όσον αφορά στην παράμετρο “n”, η βέλτιστη τιμή της θα προσδιοριστεί μέσω πειραματισμού και θα αξιολογηθεί βάσει των κριτηρίων που περιγράφονται στην παράγραφο 4.2.

- ii. *Το πλήθος και ο τύπος των συναρτήσεων συμμετοχής.* Οι βέλτιστες τιμές των συγκεκριμένων παραμέτρων δεν μπορούν να καθοριστούν εκ των προτέρων. Διάφοροι συνδυασμοί θα δοκιμαστούν και η απόδοση των επιμέρους μοντέλων θα αξιολογηθεί βάσει των κριτηρίων που περιγράφονται στην παράγραφο 4.2.

## 5. Αποτελέσματα


### 5.1. Πρόβλεψη Νευρωνικών Δικτύων

Για τον καθορισμό του βέλτιστου μεγέθους του κρυφού επιπέδου, διερευνήσαμε το δίκτυό μας για νευρώνες από 1 έως και 24. Για κάθε επιλογή μας, 30 δίκτυα δημιουργήθηκαν, εκπαιδεύτηκαν και στην συνέχεια προσομοιώθηκαν. Στην συνέχεια επιλέχθηκε το δίκτυο που παρουσίασε το ελάχιστο σφάλμα MAPE στο δείγμα δοκιμής.

**Πίνακας 5-1** Σφάλματα εκπαίδευσης και δοκιμής για δίκτυα που εκπαιδεύτηκαν με τον αλγόριθμο trainscg

Αριθμός κρυφών νευρώνων	Δείγμα	Σφάλματα			
		MSE	RMSE	MAE	MAPE
1	Training	1,33233E+15	36501036	24599900	5,278611
	Test	1,18549E+16	108880193	103911346	23,80967
2	Training	7,56297E+14	27500861	18918873	3,977475
	Test	4,06583E+15	63763841	57550946	13,78724
3	Training	3,82168E+14	19549129	14357683	3,229349
	Test	4,87808E+15	69843226	55023815	13,33229
4	Training	2,94377E+14	17157412	13453306	3,07635
	Test	5,69586E+15	75470914	62575515	14,51306
<b>5</b>	<b>Training</b>	<b>1,53728E+14</b>	<b>12398701</b>	<b>9825925,2</b>	<b>2,381645</b>
	<b>Test</b>	<b>1,69966E+15</b>	<b>41226879</b>	<b>31787482</b>	<b>7,322693</b>
6	Training	1,47069E+14	12127196	9133044,1	2,060807
	Test	3,25782E+15	57077302	50751804	11,7666
7	Training	9,66174E+13	9829412,5	6801844,7	1,637016
	Test	5,65244E+15	75182728	63724066	15,11742
8	Training	4,93891E+13	7027735,1	5162974	1,320678
	Test	9,4281E+15	97098383	78543350	17,62626
9	Training	1,52338E+13	3903045,6	2542473	0,694278
	Test	7,94692E+15	89145483	65362295	15,68981
10	Training	1,47955E+13	3846488,5	2638316,9	0,633437
	Test	7,17111E+15	84682384	70496878	16,10032
11	Training	1,33977E+13	3660293,5	2444283,7	0,625463
	Test	1,02989E+16	101483344	86855576	20,92684
12	Training	1,45141E+13	3809731,8	2754788,4	0,707638
	Test	8,28058E+15	90997690	80033939	18,11769
18	Training	2,23989E+12	1496625,8	1101347	0,254787
	Test	9,72303E+15	98605428	89604618	19,95589
24	Training	1,23388E+12	1110799,5	768658,07	0,225623
	Test	2,42754E+16	155805711	107607450	22,80211


Η διακύμανση του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος (MAPE) για το δείγμα εκπαίδευσης και το δείγμα δοκιμής σε σχέση με τον αριθμό των κρυφών νευρώνων παρουσιάζεται στο παρακάτω γράφημα.




**Γράφημα 5.1** Διακύμανση σφάλματος εκπαίδευσης και δοκιμής σε σχέση με τον αριθμό των κρυφών νευρώνων

Το δίκτυο παρουσιάζει την καλύτερη απόδοση για 5 κρυφούς νευρώνες. Περισσότερα στοιχεία για την εκπαίδευση και την απόδοση του συγκεκριμένου δικτύου δίνονται στα παρακάτω γραφήματα.


Είναι εμφανές ότι αυξάνοντας τον αριθμό των κρυφών νευρώνων περαιτέρω, ενώ επιτυγχάνουμε μικρότερο σφάλμα εκπαίδευσης, το σφάλμα δοκιμής αυξάνεται και το δίκτυο μας αποτυγχάνει να προβλέψει ικανοποιητικά.




**Γράφημα 5.2** Δεδομένα εξόδου για το δείγμα εκπαίδευσης και δοκιμής




**Γράφημα 5.3** Εξέλιξη του βήματος κατά την διαδικασία εκπαίδευσης



**Γράφημα 5.4** Γραμμική παλινδρόμηση των αποτελεσμάτων του εκπαιδευμένου δικτύου με τα δεδομένα στόχου του δείγματος εκπαίδευσης και δοκιμής κατά αντιστοιχία




**Γράφημα 5.5** Εξέλιξη του Μέσου Τετραγωνικού Σφάλματος κατά την διαδικασία της εκπαίδευσης




**Γράφημα 5.6** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου σε όλο το δείγμα





Γράφημα 5.7 Σφάλμα πρόβλεψης σε όλο το δείγμα



Γράφημα 5.8 Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου στο δείγμα δοκιμής

Στους παρακάτω πίνακες παρουσιάζονται τα βάρη και τα bias του δικτύου που πέτυχε το χαμηλότερο σφάλμα στο δείγμα δοκιμής.

**Πίνακας 5-2** Βάρη από το επίπεδο εισόδου προς το κρυφό επίπεδο

Νευρώνας	Είσοδος											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,0199	0,2737	-0,913	-0,119	0,4281	-0,294	0,2481	0,2434	-0,025	-1,378	0,0327	1,4321
2	-0,296	-0,317	1,2687	-1,032	-0,296	-0,324	-0,171	0,0573	-0,931	-0,432	-0,469	0,4603
3	0,3187	-0,809	-0,798	0,619	0,6916	-0,973	0,2645	-0,777	-1,056	0,7391	0,3838	0,8755
4	0,5867	-0,225	-1,275	0,3266	0,4793	-0,364	0,2019	-1,143	-1,201	1,3212	0,548	1,1457
5	-0,155	-0,602	-1,047	-0,247	-0,258	1,3679	0,4349	-0,065	-0,542	0,9215	-0,107	-0,126

**Πίνακας 5-3** bias κρυφών νευρώνων

Νευρώνας	
1	-1,0812442
2	-0,1225226
3	-0,3247471
4	0,3444648
5	1,2277553


**Πίνακας 5-5** Βάρη από κρυφό επίπεδο προς επίπεδο εξόδου

Έξοδος	Νευρώνας				
	1	2	3	4	5
1	-0,784	-1,425	1,6509	-0,385	0,0426
2	-0,407	-1,513	2,089	-0,455	-0,281
3	0,5871	-0,146	-1,231	1,017	0,0942
4	0,0282	-0,657	0,4335	0,6458	-0,75
5	0,3848	-0,926	0,5097	0,3246	-0,22
6	0,6659	-0,617	0,2149	0,7262	-0,089
7	0,2308	-0,993	1,4689	0,4256	-1,076
8	0,8824	-1,065	1,0843	-0,076	-1,379
9	-0,864	-0,667	0,4247	1,0334	-0,367
10	0,8273	-1,179	1,0165	-0,038	0,6062
11	1,2508	-0,725	0,2166	0,4073	-0,333
12	0,1814	-0,893	0,857	0,6521	0,346

**Πίνακας 5-4** bias εξόδων

Έξοδος	
1	-0,5221913
2	0,0189307
3	-0,1405146
4	0,4595421
5	0,3415541
6	0,1929032
7	0,8785879
8	1,7402106
9	-0,7871996
10	0,0037855
11	0,9386141
12	-0,4534065

Για την βελτίωση της απόδοσης του δικτύου μας, χωρίσαμε το δείγμα εκπαίδευσης σε δύο επιμέρους τμήματα. Ένα τμήμα χρησιμοποιείται για την εκπαίδευση του δικτύου (training sample) και το άλλο τμήμα (validation sample), μικρότερο σε μέγεθος για την επικύρωση της εκπαίδευσης.




**Γράφημα 5.9** Δεδομένα εξόδου για το δείγμα εκπαίδευσης, επικύρωσης και δοκιμής

Επιπροσθέτως δοκιμάσαμε και τον αλγόριθμο *trainidx* ο οποίος συγκλίνει με πιο αργό ρυθμό από τον *trainscg*, ένα χαρακτηριστικό που ενδεχομένως να οδηγήσει σε καλύτερα αποτελέσματα. Στον επόμενο πίνακα παρουσιάζονται τα συγκριτικά αποτελέσματα.

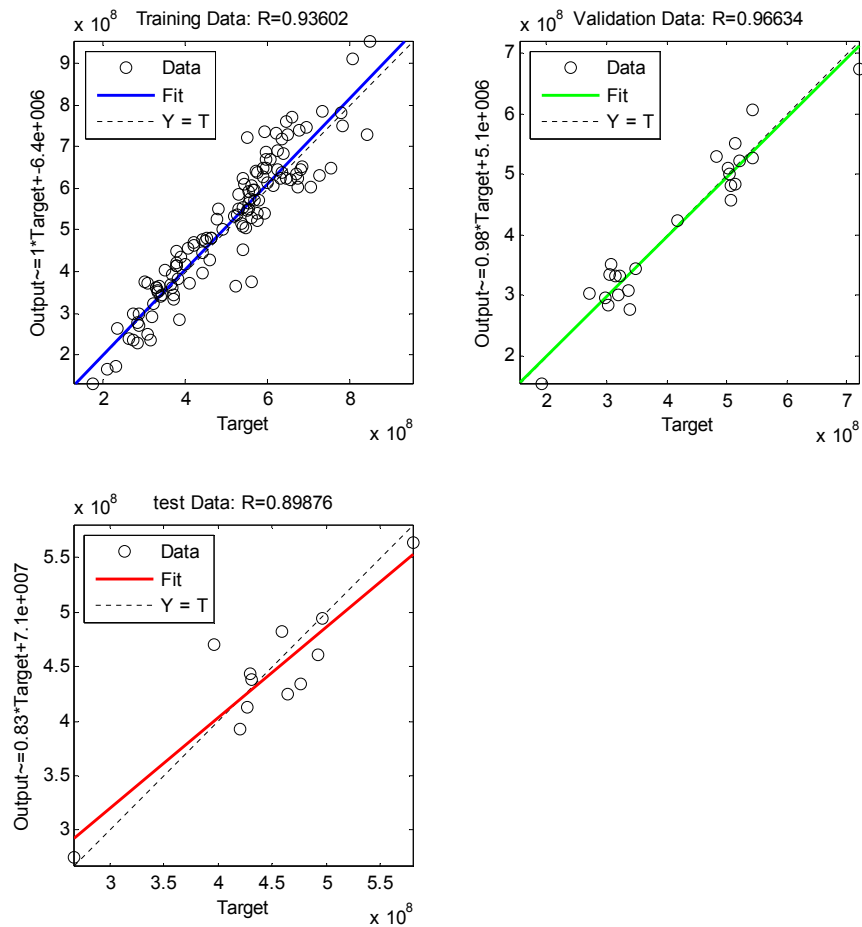
**Πίνακας 5-6** Σφάλματα εκπαίδευσης, επικύρωσης και δοκιμής

Αλγόριθμος Εκπαίδευσης		trainscg				traingdx			
Αριθμός κρυφών νευρώνων	Δείγμα	Σφάλματα				Σφάλματα			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
1	Training	3,507E+15	59215884	42693114	8,4281214	3,15E+15	56130403	42334809	8,577782
	Validation	5,411E+14	23261982	18020708	4,4633686	6,05E+14	24590855	20301768	5,119395
	Test	1,328E+15	36439303	29472366	6,9680995	1,58E+15	39803109	35159995	8,112385
2	Training	2,565E+15	50641754	36545411	7,5717074	3,14E+15	56022423	41443727	8,113054
	Validation	6,957E+14	26375383	19521890	4,9843492	4,79E+14	21895806	16669072	4,086307
	Test	1,407E+15	37513158	31417070	7,3922472	1,35E+15	36777572	31817710	7,354018
3	Training	<b>2,43E+15</b>	<b>49295761</b>	<b>38551522</b>	<b>7,9694345</b>	<b>3,47E+15</b>	<b>58889184</b>	<b>46313029</b>	<b>9,789419</b>
	Validation	<b>5,849E+14</b>	<b>24185628</b>	<b>19117025</b>	<b>4,7545128</b>	<b>1,03E+15</b>	<b>32118624</b>	<b>26462514</b>	<b>7,192799</b>
	Test	<b>1,307E+15</b>	<b>36152524</b>	<b>29376579</b>	<b>6,7445519</b>	<b>9,75E+14</b>	<b>31220597</b>	<b>24759896</b>	<b>5,607075</b>
4	Training	1,773E+15	42108733	31753778	6,6636812	2,5E+15	49996826	37502167	7,880289
	Validation	1,112E+15	33343160	21024407	5,4232368	1,27E+15	35663982	29774357	7,696299
	Test	2,817E+15	53079932	39800461	9,4886324	1,21E+15	34725169	30894662	7,288501
5	Training	4,005E+15	63283619	47929754	10,01562	1,77E+15	42116343	30478724	5,682667
	Validation	1,387E+15	37241527	31718163	7,8849597	7,59E+14	27550113	20899515	4,854022
	Test	1,908E+15	43678463	36448445	8,2072963	3,03E+15	55001750	42460518	9,743802
6	Training	1,89E+15	43474947	34388042	7,22206	2,97E+15	54525296	43171595	8,810258
	Validation	1,34E+15	36603744	27181851	6,9370855	1,78E+15	42168280	27803375	6,436909
	Test	2,935E+15	54172972	39512786	8,7211145	6,08E+15	77954595	55840048	12,32245
7	Training	2,354E+15	48517669	39026219	8,0113724	4,58E+15	67653726	53281635	12,32954
	Validation	6,983E+14	26425060	21404660	5,3326154	2E+15	44707337	38449974	12,20839
	Test	3,961E+15	62939508	42166143	9,9338232	3,49E+15	59115331	51041523	11,17168
12	Training	1,188E+15	34471324	25416977	5,3382682	1,49E+15	38645776	27550645	5,289626
	Validation	1,47E+15	38336596	29921907	7,5638247	2,41E+16	155000000	99756469	20,29707
	Test	2,217E+15	47080525	38448189	8,8081795	7,89E+15	88808832	68539759	15,69327
18	Training	1,576E+15	39699932	29956962	6,1967518	1,86E+15	43142522	31250064	6,426987
	Validation	1,019E+15	31916874	25789529	6,0962807	1,63E+15	40337227	32155461	7,488114
	Test	6,695E+15	81820010	62660714	14,37666	2,09E+16	145000000	95850391	21,90253


Με τον καθορισμό τμήματος επικύρωσης, επιτυγχάνουμε να κρατήσουμε το δίκτυό μας στον σωστό δρόμο. Με την χρήση της συγκεκριμένης τεχνικής, το δίκτυο με την καλύτερη απόδοση εκπαιδεύεται με τον αλγόριθμο *traingdx* και έχει 3 κρυφούς νευρώνες. Αναλυτικότερα,




**Γράφημα 5.10** Εξέλιξη του βήματος κατά την διαδικασία εκπαίδευσης




**Γράφημα 5.11** Γραμμική παλινδρόμηση των αποτελεσμάτων του εκπαιδευμένου δικτύου με τα δεδομένα στόχου του δείγματος εκπαίδευσης, επικύρωσης και δοκιμής κατά αντιστοιχία



**Γράφημα 5.12** Εξέλιξη του Μέσου Τετραγωνικού Σφάλματος κατά την διαδικασία της εκπαίδευσης



**Γράφημα 5.13** Σφάλμα πρόβλεψης σε όλο το δείγμα



**Γράφημα 5.14** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου στο δείγμα δοκιμής

Στους παρακάτω πίνακες παρουσιάζονται τα βάρη και τα bias του δικτύου που πέτυχε το χαμηλότερο σφάλμα στο δείγμα δοκιμής, όταν κατά την διαδικασία της εκπαίδευσης υιοθετήθηκε δείγμα επικύρωσης.

**Πίνακας 5-7** Βάρη από το επίπεδο εισόδου προς το κρυφό επίπεδο

Νευρώνας	Είσοδος											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,4717	-0,499	0,7038	0,4343	0,0311	-0,961	0,0064	-0,063	-0,711	-0,538	-0,199	-0,051
2	-0,43	0,1924	0,0841	0,4636	0,0285	-0,052	0,4796	0,0576	-0,578	0,4036	0,21	0,1125
3	-0,571	-0,671	-0,424	-0,277	0,2495	-0,089	0,4556	-0,606	-0,673	0,3702	0,4711	0,2889

**Πίνακας 5-8** bias κρυφών νευρώνων

Νευρώνας	
1	-0,384
2	-0,892
3	-1,726

**Πίνακας 5-9** Βάρη από κρυφό επίπεδο προς επίπεδο εξόδου

Εξόδος	Νευρώνας		
	1	2	3
1	-0,582	0,3759	-0,231
2	-0,594	-0,184	-0,283
3	-0,641	0,3649	-0,506
4	-0,429	0,3927	-0,601
5	-0,923	0,3875	0,1959
6	-0,551	0,3718	-0,139
7	-0,862	-0,168	-0,342
8	-0,644	0,3433	-0,137
9	-0,803	0,3624	0,0468
10	-0,983	0,661	0,5539
11	-0,95	0,5547	0,3438
12	-0,729	0,1747	-0,082

**Πίνακας 5-10** bias εξόδων

Εξόδος	
1	-0,108
2	-0,476
3	-0,387
4	-0,216
5	0,1916
6	-0,031
7	-0,493
8	0,1205
9	-0,002
10	0,3883
11	0,2736
12	-0,188




## 5.2. Πρόβλεψη ANFIS

Για τον καθορισμό του βέλτιστου αριθμού εισόδων, διερευνήσαμε το μοντέλο μας για  $n=1-4$ . Για περαιτέρω αύξηση των εισόδων, το πλήθος των παραμέτρων που επιχειρεί να βελτιστοποιήσει το ANFIS υπερβαίνει τον αριθμό των δειγμάτων εκπαίδευσης. Στον παρακάτω πίνακα παρουσιάζονται τα σφάλματα εκπαίδευσης και δοκιμής για το κάθε μοντέλο.

**Πίνακας 5-11** Σφάλματα εκπαίδευσης και δοκιμής για ANFIS με συνάρτηση συμμετοχής gbell και πλήθος συναρτήσεων 2

Αριθμός εισόδων	Δείγμα	Σφάλματα			
		MSE	RMSE	MAE	MAPE
1	Training	3,86369E+15	62158625	43625450,6	8,580936
	Test	1,32662E+16	115179106	100727392	24,36894
2	Training	2,38562E+15	48842854,8	32385726,3	6,404709
	Test	1,07672E+16	103765030	82869425,8	20,70214
3	Training	1,67668E+15	40947270,7	26736680,7	5,29842
	Test	3,03676E+16	174262970	131353073	32,05614
4	Training	5,11542E+14	22617299,6	14904391,2	2,839437
	Test	2,34274E+18	1530600749	1172332824	276,205

Η διακύμανση του Μέσου Απόλυτου Ποσοστιαίου Σφάλματος (MAPE) για το δείγμα εκπαίδευσης και το δείγμα δοκιμής σε σχέση με τον αριθμό των εισόδων παρουσιάζεται στο παρακάτω γράφημα.




**Γράφημα 5.15** Διακύμανση σφάλματος εκπαίδευσης και δοκιμής σε σχέση με τον αριθμό των κρυφών νευρώνων


Το δίκτυο παρουσιάζει την καλύτερη απόδοση για 2 εισόδους. Περισσότερα στοιχεία για την εκπαίδευση και την απόδοση του συγκεκριμένου δικτύου δίνονται στα παρακάτω γραφήματα.

Είναι εμφανές ότι αυξάνοντας τον αριθμό των εισόδων περαιτέρω, ενώ επιτυγχάνουμε μικρότερο σφάλμα εκπαίδευσης, το σφάλμα δοκιμής αυξάνεται και το δίκτυο μας αποτυγχάνει να προβλέψει ικανοποιητικά.


Number of nodes: 21  
Number of linear parameters: 12  
Number of nonlinear parameters: 12  
Total number of parameters: 24  
Number of training data pairs: 132  
Number of checking data pairs: 0  
Number of fuzzy rules: 4




**Γράφημα 5.16** Δεδομένα εξόδου για το δείγμα εκπαίδευσης και δοκιμής




**Γράφημα 5.17** Δεδομένα 1<sup>ης</sup> εισόδου, 2<sup>ης</sup> εισόδου και εξόδου για το δείγμα εκπαίδευσης




**Γράφημα 5.18** Δεδομένα 1<sup>ης</sup> εισόδου, 2<sup>ης</sup> εισόδου και εξόδου για το δείγμα εκπαίδευσης




**Γράφημα 5.19** Αρχικές καμπύλες συναρτήσεων συμμετοχής




**Γράφημα 5.20** Τελικές καμπύλες συναρτήσεων συμμετοχής




**Γράφημα 5.21** Εξέλιξη σφάλματος RMSE και μέγεθος βήματος κατά την διαδικασία εκπαίδευσης



**Γράφημα 5.22** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου σε όλο το δείγμα



**Γράφημα 5.23** Σφάλμα πρόβλεψης σε όλο το δείγμα



**Γράφημα 5.24** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου στο δείγμα δοκιμής

Για τον καθορισμό του βέλτιστου αριθμού συναρτήσεων συμμετοχής, διερευνήσαμε το μοντέλο μας από 2 έως και 5 συναρτήσεις. Για περαιτέρω αύξηση των συναρτήσεων το πλήθος των παραμέτρων που επιχειρεί να βελτιστοποιήσει το ANFIS υπερβαίνει τον αριθμό των δειγμάτων εκπαίδευσης. Στον παρακάτω πίνακα παρουσιάζονται τα σφάλματα εκπαίδευσης και δοκιμής για το κάθε μοντέλο.


**Πίνακας 5-12** Σφάλματα εκπαίδευσης και δοκιμής για ANFIS με **συνάρτηση συμμετοχής gbell** και **πλήθος ειδόδων 2**

Αριθμός συναρτήσεων	Δείγμα	Σφάλματα			
		MSE	RMSE	MAE	MAPE
2	Training	2,38562E+15	48842854,8	32385726,3	6,404709
	Test	1,07672E+16	103765030	82869425,8	20,70214
3	Training	1,58847E+15	39855656,5	26849180	5,676171
	Test	9,92419E+16	315026763	170714890	40,65985
4	Training	1,33014E+15	36471066	23700249,9	5,071764
	Test	9,44399E+16	307310682	191882731	45,39013
5	Training	7,365E+14	27138535,3	19046449	4,177216
	Test	3,76214E+17	613362652	435701621	101,8136


Παρατηρούμε ότι αυξάνοντας τον αριθμό των συναρτήσεων συμμετοχής, ενώ επιτυγχάνουμε μικρότερο σφάλμα εκπαίδευσης, το σφάλμα δοκιμής αυξάνεται και το δίκτυο μας αποτυγχάνει να προβλέψει ικανοποιητικά.

Στο σημείο αυτό κρίνεται αναγκαίος ο καθορισμός δείγματος ελέγχου μεταξύ των δεδομένων εκπαίδευσης. Κατ' αυτόν τον τρόπο, το μοντέλο μας ίσως μπορέσει να γενικεύσει καλύτερα σε δεδομένα που δεν του έχουν παρουσιαστεί για εκπαίδευση.


Δοκιμάσαμε πολλούς συνδυασμούς για δείγμα ελέγχου, σε καμία όμως των περιπτώσεων, το σφάλμα ελέγχου δεν σύγκλινε με το σφάλμα εκπαίδευσης. Το γεγονός αυτό μας οδήγησε στο συμπέρασμα ότι δεν υπάρχει αρκετή ομογένεια μεταξύ των δεδομένων και κατ' επέκταση δεν μπορεί να προσδιοριστεί ικανοποιητικό δείγμα ελέγχου. Στην συνέχεια αφήσαμε τον αλγόριθμο να προσδιορίσει τυχαία δείγματα ελέγχου. Τον τρέξαμε αρκετές φορές μέχρις ότου πετύχουμε ικανοποιητικές καμπύλες σφάλματος. Μετά από αρκετές προσπάθειες βρέθηκε ένας συνδυασμός που για συγκεκριμένο αριθμό επαναλήψεων μειώνεται τόσο το σφάλμα εκπαίδευσης όσο και το σφάλμα ελέγχου. Ακόμα όμως και στην συγκεκριμένη περίπτωση το σφάλμα δοκιμής δεν μειώθηκε. Αναλυτικότερα,




**Γράφημα 5.25** Κατανομή δεδομένων εξόδου σε δεδομένα εκπαίδευσης, επικύρωσης και δοκιμής



**Γράφημα 5.26** Αρχικές καμπύλες συναρτήσεων συμμετοχής




**Γράφημα 5.27** Τελικές καμπύλες συναρτήσεων συμμετοχής




**Γράφημα 5.28** Εξέλιξη σφάλματος RMSE και μέγεθος βήματος κατά την διαδικασία εκπαίδευσης





**Γράφημα 5.29** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου σε όλο το δείγμα



**Γράφημα 5.30** Πραγματικές τιμές και τιμές πρόβλεψης του μοντέλου στο δείγμα δοκιμής

**Πίνακας 5-13** Σφάλματα εκπαίδευσης, επικύρωσης και δοκιμής για ANFIS με **συνάρτηση συμμετοχής gbell** και **πλήθος εισόδων 2**

Αριθμός συναρτήσεων	Δείγμα	Σφάλματα			
		MSE	RMSE	MAE	MAPE
2	Training	2,36631E+15	48644737,4	33595056,1	6,526058
	checking	2,98181E+15	54605995,2	37395515,8	7,514679
	Test	1,17326E+16	108317171	91819251,2	22,85565

Επόμενο βήμα στην μοντελοποίηση του ANFIS αποτελεί η επιλογή της βέλτιστης συνάρτησης συμμετοχής. Ως προς την συγκεκριμένη παράμετρο διερευνήσαμε την *καμπανοειδή (gbellmf)*, την *τριγωνική (trimf)*, την *γκουσιανή (gaussmf)*, την *επέκτασή της (gauss2mf)* και την *τραπεζοειδή συνάρτηση συμμετοχής (trapmf)*. Τα αποτελέσματα παρατίθενται στον παρακάτω πίνακα.

**Πίνακας 5-14** Σφάλματα εκπαίδευσης και δοκιμής για ANFIS με **πλήθος εισόδων 2** και **πλήθος συναρτήσεων 2**

Τύπος Συνάρτησης	Δείγμα	Σφάλματα			
		MSE	RMSE	MAE	MAPE
<b>gbell</b>	<b>Training</b>	<b>2,38562E+15</b>	<b>48842854,8</b>	<b>32385726,3</b>	<b>6,404709</b>
	<b>Test</b>	<b>1,07672E+16</b>	<b>103765030</b>	<b>82869425,8</b>	<b>20,70214</b>
tri	Training	2,74836E+15	52424848,2	34462352,5	6,732383
	Test	1,60377E+16	126640097	109186596	26,76844
gauss2	Training	2,28229E+15	47773321,9	32346708,2	6,432642
	Test	1,20433E+16	109742050	88472435,6	21,80374
gauss	Training	2,3824E+15	48809800,9	32755026,9	6,53219
	Test	1,34708E+16	116063911	99231573,2	24,53758
trap	Training	2,53714E+15	50370019,5	34716704,7	6,765876
	Test	2,97768E+16	172559658	115907502	28,33478

## 6. Συμπεράσματα

---

Αναλύοντας τα αποτελέσματα που περιγράφονται στην προηγούμενη ενότητα, μπορούμε με ασφάλεια να συμπεράνουμε ότι τα Τεχνητά Νευρωνικά Δίκτυα αποδείχτηκαν πιο αξιόπιστα στην πρόβλεψη πολλών βημάτων μπροστά για τις φαρμακευτικές πωλήσεις. Η χαμηλή απόδοση του ANFIS οφείλεται κυρίως σε δύο παράγοντες:

- Στην αρχιτεκτονική του, που δεν επιδέχεται παραμετροποίησης, οπότε ο καθορισμός μίας και μοναδικής εξόδου αποτελεί μονόδρομο. Σε προβλήματα όμως πρόβλεψης πολλών βημάτων μπροστά, η πρακτική υιοθέτησης πολλών εξόδων έχει αποδείξει την ανωτερότητά της.
- Στο δείγμα εκπαίδευσης, όπου τελικά δεν αποδείχτηκε αρκετά μεγάλο και ομοιογενές ώστε να μπορέσουν τα μοντέλα πρόβλεψης να εκπαιδευτούν σωστά και να γενικεύσουν ικανοποιητικά σε καινούργια δεδομένα. Σε αρκετές προσομοιώσεις εκπαιδευμένων μοντέλων, οι εισοδοί δεν μπορούσαν να καταταξιωθούν σε κάποιο από τα διαμορφωμένα ασαφή σύνολα.

Σε κάθε περίπτωση και οι δύο μεθοδολογίες απέδειξαν τον χαρακτηρισμό τους ως καθολικοί προσεγγιστές μη γραμμικών συναρτήσεων. Στα Τεχνητά Νευρωνικά Δίκτυα, αυξάνοντας τον αριθμό των κρυφών νευρώνων επιτυγχάναμε αρκετά μικρό σφάλμα εκπαίδευσης. Το ίδιο συνέβαινε και στην περίπτωση του ANFIS όπου αυξάνοντας είτε τον αριθμό εισόδων είτε τον αριθμό των ασαφών κανόνων επιτυγχάναμε ακόμα μικρότερο σφάλμα εκπαίδευσης.

Για περαιτέρω διερεύνηση προτείνουμε την υιοθέτηση ενός δικτύου NARX (Nonlinear Autoregressive with eXogenous input), το οποίο εφαρμόστηκε από τους Menezes & Barreto (2008) επιδεικνύοντας ικανοποιητικά αποτελέσματα σε προβλήματα μακροπρόθεσμης (πολλών βημάτων μπροστά) πρόβλεψης.

## Βιβλιογραφία

---

- Abdel-Aal, R. E. (2008). Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks. *Computers & Industrial Engineering*, 54, pp. 903-917.
- Abraham, A. (2005). Adaptation of fuzzy inference system using neural learning, fuzzy system engineering: Theory and practice. In N. Nedjah (Ed.), *Studies in fuzziness and soft computing* (pp. 53-83). Germany: Springer-Verlag.
- Alon, I., Qi, M., & Sadowski, R. J. (2001). Forecasting aggregate retail sales: A comparison of artificial neural networks and traditional methods. *Journal of Retailing and Consumer Services*, 8(3), pp. 147-156.
- Atsalakis, G. (2005). Modeling tourism demand by neural networks techniques. Management of technological changes. In *Proceedings of 4th international conference on the management of technological changes*. TUC, Chania, Greece.
- Atsalakis, G., & Ucenic, C. (2006). Forecasting the electricity demand using a neuro-fuzzy approach versus traditions methods. *Journal of WSEAS Transactions on Business and Economics*, 1(3), pp. 9-17.
- Atsalakis, G., & Valavanis, K. (2009). Forecasting stock market short-term trends using a neuro-fuzzy based methodology. *Expert Systems with Applications*, 36, pp. 10696-10707.
- Atsalakis, G., Skiadas, C., & Braimis, I. (2007). Probability of trend prediction of exchange rate by neuro-fuzzy techniques. In *Recent advances in stochastic modeling and data analysis*. London: World Scientific Publishing Co. Pte. Ltd.
- Bakirtzis, A. G., Petridis, V., Kiartzis, S. J., Alexiadis, M. C., & Maissis, A. H. (1996). A neural network short term load forecasting model for the Greek power system. *IEEE Transactions on Power Systems*, 11(2), pp. 858-863.
- Balkin, D. S., & Ord, K. (2000). Automatic neural network modeling for univariate time series. *International Journal of Forecasting*, 16, pp. 509-515.
- Bansal, K., Vadhavkar, S., & Gupta, A. (1998). Neural networks based data mining applications for medical inventory problems. *International Journal of Agile Manufacturing*, 1(2).
- Chelani, A. B., & Devotta, S. (2007). Prediction of ambient carbon monoxide concentration using nonlinear time series analysis technique. *Transportation Research Part D: Transport and Environment*, 12, pp. 596-600.
- Chen, M. S., Ying, L. C., & Pan, M. C. (2010). Forecasting tourist arrivals by using the adaptive network-based fuzzy inference system. *Expert Systems with Applications*, 37, pp. 1185-1191.
- Cybenko, G. (1989). Approximation by superposition of a sigmoidal function. *Mathematics of Control Signals and Systems*, 2, σσ. 303-314.
- Doganis, P., Aggelogiannaki, E., Patrinos, P., & Sarimvesis, H. (2006). Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. *Journal of Food Engineering*, 75, pp. 196-204.
- Feng, C.-X., & Wang, V. (2002). Surface roughness predictive modeling: Neural networks versus regression. *IIE Transactions on Design and Manufacturing*, 40(3), pp. 683-697.
- Franses, P. H., & Draisma, G. (1997). Recognizing changing seasonal patterns using artificial neural networks. *Journal of Econometrics*, 81, σσ. 273-280.
- Güneri, A. F., Ertay, T., & Yücel, A. (2011). An approach based on ANFIS input selection and modeling for supplier selection problem. *Expert Systems with Applications*, 38, pp. 14907-14917.
- Hamzacebi, C. (2008). Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*, 178, pp. 4550-4559.

- Hamzacebi, C., Akay, D., & Kutay, F. (2009). Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting. *Expert Systems with Applications*, 36(2), pp. 3839-3844.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feed-forward networks are universal approximators. *Neural Networks*, 2, pp. 359-366.
- Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference systems. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), pp. 665-685.
- Jang, J.-S. R., Sun, C.-T. E., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. NJ: Prentice-Hall.
- Jiang, X. F. (2012). Research on the prediction of drug sales based on Levenberg-Marquardt algorithm. *Applied Mechanics and Materials*, 198-199, pp. 1452-1456.
- Jiang, X., & Adeli, H. (2005). Dynamic wavelet neural network model for traffic flow forecasting. *Journal of Transportation Engineering*, 131(10), pp. 771-779.
- Khalilzadeh, N. (2008). *Sales Prediction for pharmaceutical Distribution Companies - A Data mining Based Approach*. Master thesis, Lulea University of Technology, Sweden.
- Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11, pp. 2664-2675.
- Kline, D. M. (2004). Methods for multi-step time series forecasting with neural networks. In G. P. Zhang (Ed.), *Neural networks for business forecasting* (pp. 226-250). Hershey: Information Science Publishing.
- Koulouriotis, D. E., & Mantas, G. (2012). Health products sales forecasting using computational intelligence and adaptive neuro fuzzy inference systems. *Operational Research International Journal*, 12(1), pp. 29-43.
- Lee, T. H., & Jung, S. (2000). Forecasting creditworthiness: Logistic vs. artificial neural net. *The Journal of Business Forecasting Methods and Systems*, 18(4), pp. 28-30.
- Menezes, J. M., & Barreto, G. A. (2008). Long-term time series prediction with the NARX network: an empirical evaluation. *Neurocomputing*, 71, pp. 3335-3343.
- Moghaddamnia, A., Remesan, R., Hassanpour, M., Mohammadi, M., Han, D., & Piri, J. (2009). Comparison of LLR, MLP, Elman, NNARX and ANFIS Models with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71(8-9), σσ. 975-982.
- Mohandes, M., Rehman, S., & Rahman, S. M. (2011). Estimation of wind speed profile using adaptive neuro-fuzzy inference system (ANFIS). *Applied Energy*, 88, pp. 4024-4032.
- Palmer, A., Montano, J. J., & Sese, A. (2006). Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27, pp. 781-790.
- Pendharkar, P. C. (2005). A threshold-varying artificial neural network approach for classification and its application to bankruptcy prediction problem. *Computers and Operations Research*, 32, pp. 2561-2582.
- Subasi, A. (2007). Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction. *Computers in Biology and Medicine*, 37, pp. 227-244.
- Thieme, R. J., Song, M., & Calantone, R. J. (2000). Artificial neural network decision support systems for new product development project selection. *Journal of Marketing research*, 37(4), pp. 499-507.
- Wang, F. K., Chang, K. K., & Tzeng, C. W. (2011). Using adaptive network-based fuzzy inference system to forecast automobile sales. *Expert Systems with Applications*, 38, σσ. 10587-10593.
- Wang, Y.-H. (2009). Nonlinear neural network forecasting model for stock index option price: Hybrid GJR-GARCH approach. *Expert Systems with Applications*, 36(1), pp. 564-570.

- Wettermark et al. (2010). Forecasting drug utilization and expenditure in a metropolitan health region. *BMC Health Services Research*, 10(128).
- Zadeh, L. (1965). Fuzzy sets. *Information and Control*, 8(3), pp. 338-353.
- Zhang, G. P. (2012). Neural networks for time-series forecasting. In Rozenberg, & et al. (Eds.), *Handbook of Natural Computing* (pp. 461-477). Germany: Springer-Verlag.
- Zhang, G. P., & Berardi, V. (1998). An investigation of neural networks in thyroid function diagnosis. *Health Care Management Science*, 1, pp. 29-37.
- Zhang, G. P., Patuwo, E. P., & Hu, M. Y. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, 14, pp. 35-62.
- Zhang, Y. Q., & Wan, X. (2007). Statistical fuzzy interval neural networks for currency exchange rate time series prediction. *Applied Soft Computing*, 7, pp. 1149-1156.

## Παράρτημα Ι – Φαρμακευτικές Πωλήσεις

### ΜΗΝΙΑΙΑ ΚΑΤΑΝΑΛΩΣΗ ΦΑΡΜΑΚΩΝ (€) 2000-2003

	ΝΟΣΟΚΟΜΕΙΑ	ΦΑΡΜΑΚΕΙΑ	ΣΥΝΟΛΟ
I-00	33.007.774,12	184.887.359,31	217.895.133,43
Φ-00	34.394.109,37	167.243.680,29	201.637.789,66
M-00	38.760.918,61	181.665.037,60	220.425.956,21
A-00	36.047.496,77	166.018.102,94	202.065.599,71
M-00	37.015.253,08	183.205.880,03	220.221.133,11
I-00	41.256.730,33	185.772.495,43	227.029.225,76
I-00	52.690.441,64	217.629.952,04	270.320.393,68
A-00	21.465.916,14	84.428.645,02	105.894.561,16
Σ-00	34.101.125,22	194.865.305,47	228.966.430,69
O-00	36.051.566,97	203.629.712,08	239.681.279,05
N-00	40.368.039,75	194.941.268,35	235.309.308,10
Δ-00	37.022.646,83	190.023.260,69	227.045.907,52
I-01	37.500.831,89	198.193.695,71	235.694.527,60
Φ-01	36.716.697,10	200.216.934,75	236.933.631,85
M-01	43.803.272,06	217.792.190,07	261.595.462,13
A-01	40.014.112,53	189.566.111,99	229.580.224,52
M-01	48.778.549,73	222.619.413,45	271.397.963,18
I-01	44.453.563,21	206.188.256,24	250.641.819,45
I-01	61.572.091,24	281.286.108,55	342.858.199,79
A-01	25.939.652,02	105.988.594,13	131.928.246,15
Σ-01	40.214.865,57	236.779.004,59	276.993.870,16
O-01	47.638.063,29	250.700.605,42	298.338.668,71
N-01	49.676.336,35	250.141.700,73	299.818.037,08
Δ-01	44.230.274,11	247.391.344,24	291.621.618,35
I-02	45.990.498,42	237.321.363,43	283.311.861,85
Φ-02	46.810.908,48	230.657.897,63	277.468.806,11
M-02	47.340.620,99	255.127.021,47	302.467.642,46
A-02	60.446.781,69	290.810.875,11	351.257.656,80
M-02	48.044.372,51	252.288.729,82	300.333.102,33
I-02	52.817.288,41	254.890.728,77	307.708.017,18
I-02	74.600.623,70	349.062.115,01	423.662.738,71
A-02	25.900.588,12	128.533.872,28	154.434.460,40
Σ-02	50.643.921,04	282.317.525,86	332.961.446,90
O-02	55.684.029,82	280.300.599,34	335.984.629,16
N-02	55.979.335,45	277.021.381,17	333.000.716,62
Δ-02	57.599.105,11	286.955.538,95	344.554.644,06
I-03	58.489.450,91	280.180.489,23	338.669.940,14
Φ-03	56.338.517,55	277.579.582,90	333.918.100,45
M-03	61.167.307,49	289.308.860,48	350.476.167,97
A-03	66.093.241,63	301.731.705,76	367.824.947,39
M-03	63.423.598,67	291.193.845,44	354.617.444,11
I-03	66.921.743,88	294.778.541,73	361.700.285,61
I-03	95.577.236,22	429.975.559,17	525.552.795,39
A-03	30.616.814,76	134.084.447,67	164.701.262,43
Σ-03	62.452.661,02	301.802.998,68	364.255.659,70
O-03	64.772.683,49	310.756.330,06	375.529.013,55
N-03	65.519.078,62	297.504.932,25	363.024.010,87
Δ-03	71.540.952,51	341.230.072,05	412.771.024,56

**ΜΗΝΙΑΙΑ ΚΑΤΑΝΑΛΩΣΗ ΦΑΡΜΑΚΩΝ (€) 2004-2007**

	ΝΟΣΟΚΟΜΕΙΑ	ΦΑΡΜΑΚΕΙΑ	ΣΥΝΟΛΟ
I-04	59.903.411,98	323.333.082,45	383.236.494,43
Φ-04	65.485.645,50	306.248.976,72	371.734.622,22
M-04	76.843.914,14	358.870.267,66	435.714.181,80
A-04	69.057.076,38	347.093.236,60	416.150.312,98
M-04	65.974.834,15	346.450.602,96	412.425.437,11
I-04	81.281.722,98	374.266.623,60	455.548.346,58
I-04	97.868.582,04	525.672.058,77	623.540.640,81
A-04	42.194.627,82	130.440.280,84	172.634.908,66
Σ-04	66.398.522,03	356.236.569,71	422.635.091,74
O-04	61.927.399,24	340.144.547,21	402.071.946,45
N-04	78.575.647,37	370.661.975,27	449.237.622,64
Δ-04	71.985.609,21	391.358.293,87	463.343.903,08
I-05	71.324.483,80	324.840.381,48	396.164.865,28
Φ-05	73.769.421,79	352.667.126,23	426.436.548,02
M-05	84.186.320,30	397.391.695,46	481.578.015,76
A-05	81.053.118,24	398.011.143,44	479.064.261,68
M-05	72.515.009,83	373.151.785,04	445.666.794,87
I-05	79.484.747,65	402.449.496,22	481.934.243,87
I-05	105.590.376,21	520.046.218,78	625.636.594,99
A-05	46.750.467,31	192.606.263,03	239.356.730,34
Σ-05	72.979.830,69	404.748.970,11	477.728.800,80
O-05	75.241.367,11	395.576.303,96	470.817.671,07
N-05	83.838.265,87	388.227.461,08	472.065.726,95
Δ-05	74.653.986,78	477.154.251,11	551.808.237,89
I-06	76.872.719,46	381.250.888,44	458.123.607,90
Φ-06	79.176.829,51	402.952.181,10	482.129.010,61
M-06	86.181.733,94	441.365.409,45	527.547.143,39
A-06	77.242.774,11	405.847.239,12	483.090.013,23
M-06	89.334.386,68	421.576.128,18	510.910.514,86
I-06	93.914.322,34	428.266.803,15	522.181.125,49
I-06	116.867.660,80	557.766.217,66	674.633.878,46
A-06	55.145.719,88	240.666.430,52	295.812.150,40
Σ-06	80.268.315,13	420.133.148,94	500.401.464,07
O-06	87.157.787,01	442.730.694,58	529.888.481,59
N-06	93.499.040,87	457.335.641,33	550.834.682,20
Δ-06	81.740.833,49	523.917.275,87	605.658.109,36
I-07	91.411.605,00	458.025.458,49	549.437.063,49
Φ-07	91.388.262,98	423.724.388,03	515.112.651,01
M-07	105.766.148,51	508.014.747,56	613.780.896,07
A-07	86.930.782,52	460.066.560,72	546.997.343,24
M-07	99.338.769,06	492.764.765,65	592.103.534,71
I-07	107.827.567,47	486.591.355,47	594.418.922,94
I-07	138.224.858,25	642.594.823,96	780.819.682,21
A-07	60.398.608,39	261.857.126,21	322.255.734,60
Σ-07	88.953.331,50	477.062.460,04	566.015.791,54
O-07	99.945.406,67	509.225.350,30	609.170.756,97
N-07	110.719.602,14	525.832.582,63	636.552.184,77
Δ-07	95.466.283,21	533.930.938,96	629.397.222,17



**ΜΗΝΙΑΙΑ ΚΑΤΑΝΑΛΩΣΗ ΦΑΡΜΑΚΩΝ (€) 2008-2011**

	ΝΟΣΟΚΟΜΕΙΑ	ΦΑΡΜΑΚΕΙΑ	ΣΥΝΟΛΟ
I-08	170.720.945,13	565.815.441,71	736.536.386,84
Φ-08	182.761.456,10	538.933.584,40	721.695.040,50
M-08	97.894.704,40	524.885.667,10	622.780.371,50
A-08	110.212.473,05	538.698.367,27	648.910.840,32
M-08	111.888.226,24	535.916.706,14	647.804.932,38
I-08	118.617.955,72	549.530.284,50	668.148.240,22
I-08	164.745.933,27	746.887.452,22	911.633.385,49
A-08	64.454.110,05	279.695.114,75	344.149.224,80
Σ-08	108.639.998,06	562.059.607,86	670.699.605,92
O-08	116.687.511,72	569.677.239,02	686.364.750,74
N-08	112.699.962,26	532.138.847,19	644.838.809,45
Δ-08	108.018.992,62	623.324.983,10	731.343.975,72
I-09	119.171.898,97	519.208.608,94	638.380.507,91
Φ-09	116.692.762,09	524.835.666,68	641.528.428,77
M-09	128.640.487,55	617.629.469,38	746.269.956,93
A-09	125.792.546,70	563.707.134,85	689.499.681,55
M-09	117.631.713,07	565.883.743,66	683.515.456,73
I-09	141.748.005,45	617.900.268,61	759.648.274,06
I-09	168.261.934,66	783.451.572,95	951.713.507,61
A-09	67.064.991,46	327.353.947,36	394.418.938,82
Σ-09	113.554.503,18	604.375.802,53	717.930.305,71
O-09	124.049.808,16	604.493.638,23	728.543.446,39
N-09	126.612.916,17	613.058.958,26	739.671.874,43
Δ-09	116.816.486,00	653.476.390,84	770.292.876,84
I-10	116.840.714,55	486.273.221,78	603.113.936,33
Φ-10	105.149.135,77	425.872.826,12	531.021.961,89
M-10	134.096.649,74	652.805.558,75	786.902.208,49
A-10	92.236.690,57	528.724.791,38	620.961.481,95
M-10	129.262.859,90	493.140.443,31	622.403.303,21
I-10	111.540.694,35	541.440.378,04	652.981.072,39
I-10	137.773.063,86	591.207.501,62	728.980.565,48
A-10	69.652.589,92	213.656.785,39	283.309.375,31
Σ-10	97.834.176,07	536.557.514,79	634.391.690,86
O-10	102.611.604,19	499.835.759,89	602.447.364,08
N-10	114.072.953,69	516.096.449,04	630.169.402,73
Δ-10	101.025.153,01	543.235.230,12	644.260.383,13
I-11	102.007.623,56	493.758.023,85	595.765.647,41
Φ-11	91.912.616,14	462.016.939,61	553.929.555,75
M-11	103.842.406,02	501.238.151,55	605.080.557,57
A-11	95.168.285,38	476.667.042,84	571.835.328,22
M-11	102.104.316,28	474.451.632,93	576.555.949,21
I-11	105.261.578,13	416.590.451,41	521.852.029,54
I-11	140.040.368,61	611.528.049,18	751.568.417,79
A-11	61.262.200,08	299.876.206,27	361.138.406,35
Σ-11	95.009.620,62	510.495.829,64	605.505.450,26
O-11	92.363.387,36	412.107.793,62	504.471.180,98
N-11	109.276.281,55	463.283.067,14	572.559.348,69
Δ-11	101.943.488,83	436.639.912,65	538.583.401,48

**ΜΗΝΙΑΙΑ ΚΑΤΑΝΑΛΩΣΗ ΦΑΡΜΑΚΩΝ (€) 2012-2013**

	ΝΟΣΟΚΟΜΕΙΑ	ΦΑΡΜΑΚΕΙΑ	ΣΥΝΟΛΟ
I-12	108.381.849,26	443.052.784,50	551.434.633,76
Φ-12	97.226.333,28	440.883.163,92	538.109.497,20
M-12	115.982.257,10	424.387.994,54	540.370.251,64
A-12	103.534.353,10	403.983.638,20	507.517.991,30
M-12	118.567.274,75	414.950.364,77	533.517.639,52
I-12	126.653.527,88	324.311.777,82	450.965.305,70
I-12	157.018.456,74	492.454.659,23	649.473.115,97
A-12	92.736.032,73	280.541.782,16	373.277.814,89
Σ-12	95.919.171,88	268.072.917,71	363.992.089,59
O-12	111.469.191,57	388.365.905,32	499.835.096,89
N-12	124.308.692,59	459.943.599,14	584.252.291,73
Δ-12	109.379.427,85	265.516.325,47	374.895.753,32
I-13	107.971.047,70	373.974.242,59	481.945.290,29
Φ-13	109.726.528,92	303.156.536,02	412.883.064,94
M-13	104.193.791,34	355.998.497,88	460.192.289,22
A-13	122.600.978,01	371.184.706,39	493.785.684,40
M-13	98.623.590,81	294.527.783,18	393.151.373,99
I-13	113.441.680,23	320.997.737,63	434.439.417,86
I-13	154.668.086,12	408.844.490,39	563.512.576,51
A-13	67.398.043,14	208.489.281,40	275.887.324,54
Σ-13	103.058.767,13	334.762.012,29	437.820.779,42
O-13	118.938.478,69	351.691.135,02	470.629.613,71
N-13	114.655.777,02	329.407.098,41	444.062.875,43
Δ-13	123.408.807,89	301.968.439,09	425.377.246,98