



**ΤΕΧΝΟΛΟΓΙΚΟ ΕΚΠΑΙΔΕΥΤΙΚΟ ΙΔΡΥΜΑ
ΑΘΗΝΑΣ**

ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΚΩΝ ΕΦΑΡΜΟΓΩΝ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΝΙΚΗΣ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΚΑΙ ΑΥΤΟΜΑΤΟΣ
ΕΛΕΓΧΟΣ ΜΗ ΓΡΑΜΜΙΚΟΥ DC ΚΙΝΗΤΗΡΑ
ΜΕ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ**

ΓΙΑΝΝΑΚΑΚΗΣ ΧΑΡΑΛΑΜΠΟΣ

ΚΟΜΠΟΓΙΑΝΝΗΣ ΙΩΑΝΝΗΣ

ΕΠΙΒΛΕΠΩΝ: ΑΛ. ΑΛΕΞΑΝΔΡΙΔΗΣ

ΕΠΙΚΟΥΡΟΣ ΚΑΘΗΓΗΤΗΣ

ΙΟΥΝΙΟΣ 2011

ΕΥΧΑΡΙΣΤΙΕΣ

Με το πέρας της παρούσας πτυχιακής εργασίας θα θέλαμε να ευχαριστήσουμε τον επίκουρο καθηγητή κ. Αλ. Αλεξανδρίδη για την υποστήριξη και την βοήθεια καθόλη τη διάρκεια της εκπόνησής της.

Επίσης ευχαριστούμε ιδιαίτερα τις οικογένειές μας που στηρίζουν τις επιλογές μας και μας παρέχουν εφόδια για να υλοποιήσουμε τα όνειρά μας.

Γιαννακάκης Χαράλαμπος

Κομπογιάννης Ιωάννης

22/06/2011

Περιεχόμενα

ΠΕΡΙΛΗΨΗ.....	4
ABSTRACT.....	6
ΕΙΣΑΓΩΓΗ.....	8

ΚΕΦΑΛΑΙΟ 1ο

ΕΙΣΑΓΩΓΗ ΣΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	13
1.1 Γενικά	14
1.2 Βιολογικά νευρωνικά δίκτυα και η δόμησή τους	15
1.3 Μετάδοση του σήματος	17
1.3.1 Το Νευρωνικό Δίκτυο και η μετάδοση του σήματος	17
1.3.2 Ανατροφοδότηση	18
1.4 Εκπαίδευση του νευρωνικού δικτύου	18
1.5 Πλεονεκτήματα των νευρωνικών δικτύων	19
1.6 Αρχιτεκτονικές νευρωνικών δικτύων	21
1.7 Εφαρμογές των νευρωνικών δικτύων	24

ΚΕΦΑΛΑΙΟ 2ο

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΑΚΤΙΝΙΚΗΣ ΣΥΝΑΡΤΗΣΗΣ ΒΑΣΗΣ (Radial Basis Function, RBF).....	26
2.1 Γενικά για τα δίκτυα ακτινικής συνάρτησης βάσης (RBF)	27
2.2 Δομή του δικτύου.....	28
2.3 Αλγόριθμοι Μάθησης	29
2.3.1 Γενικά	29
2.3.2 Ο Αλγόριθμος κ-μέσων (k-means)	30
2.4 Η Ασαφής Λογική	34
2.4.1 Γενικά	34
2.4.2 Ασαφής Διαμέριση του χώρου των μεταβλητών εισόδου.....	35
2.5 Η Ασαφής Λογική στην δημιουργία νευρωνικού δικτύου RBF	37

ΚΕΦΑΛΑΙΟ 3ο

ΜΗ ΓΡΑΜΜΙΚΟΣ DC ΚΙΝΗΤΗΡΑΣ.....	41
3.1 Γενικά για τους Ηλεκτροκινητήρες	42

3.2 AC Κινητήρες	43
3.3 Βασικές αρχές λειτουργίας των DC κινητήρων.....	44
3.4 Μαθηματική μοντελοποίηση των DC κινητήρων	46
3.4.1 Κινητήρες που ελέγχονται από το ρότορα.....	46
3.4.2 Κινητήρες που ελέγχονται από τον στάτορα	50
3.5 Καθορισμός παραμέτρων ενός μη γραμμικού DC κινητήρα.....	53
3.6 Προσωμοίωση μη γραμμικού DC κινητήρα με το Simulink του πακέτου Matlab.....	55

ΚΕΦΑΛΑΙΟ 4ο

ΜΟΝΤΕΛΟΠΟΙΗΣΗ DC ΚΙΝΗΤΗΡΑ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ RBF	62
4.1 Μοντελοποίηση κινητήρα.....	63
4.2 Γραμμική μοντελοποίηση	68
4.2.1 Γενικά	68
4.2.2 Μέθοδος ελαχίστων τετραγώνων	69
4.2.3 Κανονικοποίηση μεταβλητών.....	71
4.2.4 Στατιστικοί δείκτες MARE και R^2	71
4.2.5 Μοντελοποίηση του DC κινητήρα με γραμμικό μοντέλο	74
4.3 Μοντελοποίηση του DC κινητήρα με νευρωνικό δίκτυο RBF.....	78

ΚΕΦΑΛΑΙΟ 5ο

ΑΥΤΟΜΑΤΟΣ ΕΛΕΓΧΟΣ ΜΗ ΓΡΑΜΜΙΚΟΥ ΚΙΝΗΤΗΡΑ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ RBF	89
5.1 Εισαγωγή στον αυτόματο έλεγχο.....	90
5.2 Συμβατικοί ελεγκτές - Ελεγκτής PID	92
5.2.1 Γενικά	92
5.2.2 Βαθμονόμηση (tuning)	93
5.3 Αυτόματος έλεγχος μη γραμμικού DC κινητήρα.....	94
5.4 Σχεδιασμός νευρωνικού δικτύου ως ελεγκτή	96
5.5 Αποτελέσματα νευρωνικού ελεγκτή	102
5.6 Σύγκριση νευρωνικού και P.I.D. ελεγκτή	103
ΣΥΜΠΕΡΑΣΜΑΤΑ – ΜΕΛΛΟΝΤΙΚΕΣ ΕΡΕΥΝΗΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ.....	108
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	110

ΠΕΡΙΛΗΨΗ

Στόχος αυτής της πτυχιακής εργασίας ήταν η δημιουργία ενός νευρωνικού ελεγκτή, δηλαδή ενός ελεγκτή που υλοποιείται με χρήση νευρωνικών δικτύων με σκοπό να πραγματοποιεί αυτόματο έλεγχο σε μη γραμμικά συστήματα.

Τα νευρωνικά δίκτυα είναι ένας κλάδος της τεχνητής νοημοσύνης που εξελίσσεται διαρκώς τα τελευταία χρόνια. Εξαιτίας της μη γραμμικής δομής τους είναι ιδανικά για την μοντελοποίηση μη γραμμικών συστημάτων. Στην συγκεκριμένη εργασία επιλέχθηκε η αρχιτεκτονική νευρωνικών δικτύων ακτινικής συνάρτησης βάσης (Radial Basis Function, RBF), εξαιτίας της απλής δομής και των γρήγορων αλγορίθμων μάθησης που χρησιμοποιούν. Επιπλέον, για την εκπαίδευση των δικτύων χρησιμοποιήθηκε ο αλγόριθμος των ασαφών μέσων, επειδή διακρίνεται για την ταχύτητά του και την αξιοπιστία του, έναντι των κλασσικών μεθόδων εκπαίδευσης των νευρωνικών δικτύων RBF.

Η προτεινόμενη μεθοδολογία χρησιμοποιήθηκε για τον αυτόματο έλεγχο ενός μη γραμμικού κινητήρα συνεχούς ρεύματος, που προσομοιώθηκε με χρήση του πακέτου Matlab. Αρχικά χρησιμοποιήθηκαν δεδομένα εισόδου – εξόδου από τον κινητήρα, με βάση τα οποία αναπτύχθηκε ένα δυναμικό μοντέλο του συστήματος, βασισμένο σε δίκτυα RBF.

Στη συνέχεια το νευρωνικό δίκτυο κλήθηκε να πραγματοποιήσει αυτόματο έλεγχο στον ίδιο κινητήρα. Οι μέθοδοι προβλεπτικού ελέγχου που βασίζονται σε μοντέλο (Model Predictive Control, MPC), χρησιμοποιούν νευρωνικά δίκτυα εκπαιδευμένα να υπολογίζουν την έξοδο του συστήματος με βάση την μεταβλητή εκχειρισμού και στη συνέχεια σχηματίζεται ένα πρόβλημα βελτιστοποίησης, με στόχο την ελαχιστοποίηση μιας συνάρτησης που περιέχει την απόκλιση ανάμεσα στην έξοδο και την επιθυμητή τιμή. Ωστόσο αυτή η διαδικασία βελτιστοποίησης είναι ιδιαίτερα χρονοβόρα, ενώ μπορεί να παγιδευτεί σε κάποιο τοπικό ελάχιστο.

Σε αυτή την εργασία προτείνεται ένας διαφορετικός τρόπος χρήσης των νευρωνικών δικτύων ως μέσο αυτόματου ελέγχου, όπου το νευρωνικό δίκτυο καλείται να μοντελοποιήσει το αντίστροφο πρόβλημα από αυτό που προαναφέρθηκε. Στην περίπτωση αυτή χρησιμοποιούνται σαν είσοδοι στο νευρωνικό δίκτυο η επιθυμητή τιμή, το τρέχον

διάνυσμα κατάστασης του συστήματος και η τρέχουσα τιμή της διαταραχής, ενώ σαν έξοδος προκύπτει η τρέχουσα τιμή της μεταβλητής εκχειρισμού. Τα αποτελέσματα στον αυτόματο έλεγχο του μη γραμμικού κινητήρα συνεχούς ρεύματος δείχνουν ότι η προτεινόμενη μέθοδος είναι ταχύτερη και αξιόπιστη ενώ πλεονεκτεί έναντι κλασσικών μεθόδων αυτομάτου ελέγχου όπως είναι οι ελεγκτές τύπου PID.

Ο προτεινόμενος νευρωνικός ελεγκτής και τα αποτελέσματα που προέκυψαν από την εφαρμογή του στον έλεγχο του μη γραμμικού DC κινητήρα παρουσιάστηκαν στο διεθνές συνέδριο IEEE International Symposium on INnovations in Intelligent SysTems and Applications (INISTA 2011).

ABSTRACT

The purpose of this thesis is to build a neural controller, i.e. a controller based on neural networks, as a means for controlling nonlinear systems. Neural networks constitute an artificial intelligence technique which is becoming very popular within the last few years. Their nonlinear structure makes them ideal for modeling nonlinear systems. Among the different neural network architectures, we selected the Radial Basis Function (RBF) architecture because of its simple structure and the fast learning algorithms it employs. Moreover, the fuzzy means algorithm has been utilized for training the RBF networks, as it provides more accurate models in shorter computational times, compared to conventional methodologies.

The proposed approach was used for controlling a nonlinear DC motor which was simulated using Matlab. Initially we have generated input-output data from the DC motor in order to build an RBF dynamical model of the system. Then neural network models were utilized for control purposes.

Model Predictive Control (MPC) methodologies employ neural networks trained to calculate the output of the system using as input the manipulated variable. Then, an optimization problem is formulated, aiming to minimize the deviation between the actual output and the set point value. However, calculating the solution to the optimization problem is rather computationally demanding, while no optimality is guaranteed. In this work we present a different way to utilize neural networks for control purposes, training the neural controller to learn directly the inverse law that governs the dynamical behavior of the system. This means that the RBF neural controller, uses as inputs the set point value, the current state vector and the current value of the disturbance variable, while produces as output the current value of the manipulated variable.

Results have shown that the proposed approach is fast and reliable, while it exhibits superior performance compared to classical control methodologies, like PID controllers.

The proposed neural controller together with the results from its application to the control of the nonlinear DC motor, were presented in the international conference IEEE International Symposium on INnovations in Intelligent SysTems and Applications (INISTA 2011).

ΕΙΣΑΓΩΓΗ

Στην φύση όλοι οι οργανισμοί πραγματοποιούν καθημερινά πολύπλοκες διεργασίες και υπολογισμούς. Αρκεί να αναλογιστεί κανείς για παράδειγμα πως ένα πτηνό από την στιγμή που γεννιέται μαθαίνει να ψάχνει για τροφή, να προστατεύεται, να δραστηριοποιείται μέσα σε ομάδες, να εκτελεί δηλαδή πράξεις τις οποίες δεν γνώριζε εκ των προτέρων, αλλά τις έμαθε εμπειρικά (Haykin 1999). Αυτή η επεξεργασία δεδομένων με την οποία γίνεται η συλλογή εμπειριών και η εφαρμογή τους, ονομάζεται μάθηση (Fischler and Firschein 1987). Όλη αυτή η διαδικασία πραγματοποιείται στον εγκέφαλο του πτηνού. Παρόμοιες διεργασίες του εγκεφάλου είναι και η καθημερινή αναγνώριση εχθρών, φυτών και διαφόρων στοιχείων στο περιβάλλον του (Churchland and Sejnowski 1992). Αυτοί οι υπολογισμοί πραγματοποιούνται από ένα μικρό όργανο όπως είναι ο εγκέφαλος σε ελάχιστο χρόνο, την στιγμή που παρόμοιοι υπολογισμοί χρειάζονται ημέρες για να πραγματοποιηθούν από έναν ηλεκτρονικό υπολογιστή (Churchland 1986). Είναι επομένως αυτονόητο πως η δημιουργία μεθόδων που θα λειτουργούν με τρόπο παρόμοιο με αυτόν του εγκεφάλου, θα οδηγήσει σε ταχύτατα τεχνητά συστήματα. Τέτοια συστήματα είναι τα τεχνητά νευρωνικά δίκτυα (Neural Networks, NN).

Υπάρχουν πολλές κατηγορίες νευρωνικών δικτύων, που η κάθε μία παρουσιάζει τα δικά της πλεονεκτήματα και μειονεκτήματα. Άλλα νευρωνικά δίκτυα προσφέρουν απλή δομή και εύκολη υλοποίηση, άλλα χαρακτηρίζονται από την αξιοπιστία τους και άλλα από την ταχύτητά τους. Τα νευρωνικά δίκτυα που επιλέχθηκαν στην συγκεκριμένη πτυχιακή εργασία είναι τα δίκτυα ακτινικής συνάρτησης βάσης (RBF) που διακρίνονται για τους γρήγορους αλγόριθμους μάθησης και την απλή δομή τους (Powell 1987). Οι αλγόριθμοι μάθησης είναι η διαδικασία κατά την οποία το νευρωνικό δίκτυο συλλέγει δεδομένα εισόδου – εξόδου του συστήματος και με έναν μη γραμμικό τρόπο καθορίζει τις παραμέτρους του, ώστε να «μάθει» το σύστημα το οποίο μελετά.

Ο κλασικός αλγόριθμος μάθησης των νευρωνικών δικτύων RBF είναι ο αλγόριθμος των κ-μέσων (k-means) (Darken and Moody 1990). Ο αλγόριθμος αυτός υπολογίζει τα κέντρα του νευρωνικού δικτύου λύνοντας ένα πρόβλημα ελαχιστοποίησης της Ευκλείδειας απόστασης των δεδομένων από τα κέντρα, τα οποία τοποθετούνται στην αρχή σε τυχαία επιλεγμένα δεδομένα. Η μέθοδος αυτή, εξαιτίας της επαναληπτικής διαδικασίας που χρησιμοποιεί ώστε να συγκλίνει στην ελαχιστοποίηση των αποστάσεων των κέντρων από τα δεδομένα, είναι χρονοβόρα. Για τον λόγο αυτό χρησιμοποιήθηκε μια

μέθοδος που εισάγει την ασαφή λογική στον καθορισμό των κέντρων του νευρωνικού δικτύου RBF.

Η έννοια της ασαφούς λογικής (Fuzzy Logic) υιοθετεί την μερική συμμετοχή των δεδομένων, σε αντίθεση με την καθολική χρήση τους (Boolean Logic) (Zadeh 1965). Υποθέτει πως τα δεδομένα δεν χαρακτηρίζονται με βάση την συμμετοχή τους ή τη μη συμμετοχή τους, δηλαδή με τιμές 0 και 1, (μαύρο ή άσπρο) αλλά με την μερική συμμετοχή τους (διαβαθμίσεις του γκρι). Η ασαφής λογική μπορεί να χρησιμοποιηθεί στην επίλυση του προβλήματος επιλογής κέντρων σε ένα δίκτυο RBF με χρήση του αλγορίθμου των ασαφών μέσων (fuzzy means) (Sarimveis et al. 2002, Alexandridis et al. 2003). Αυτός ο αλγόριθμος δημιουργεί τα κέντρα του νευρωνικού δικτύου με βάση τον χωρισμό των δεδομένων σε ασαφή σύνολα. Επειδή ο αλγόριθμος αυτός δεν χρησιμοποιεί κάποια επαναληπτική διαδικασία, είναι πολύ ταχύτερος έναντι του κλασσικού αλγορίθμου k-means, ενώ παράγει δίκτυα μεγαλύτερης ακρίβειας.

Στην παρούσα εργασία, ο αλγόριθμος των ασαφών μέσων χρησιμοποιήθηκε για τη μοντελοποίηση και τον αυτόματο έλεγχο ενός μη γραμμικού κινητήρα συνεχούς ρεύματος (DC) (Kuo and Golnarachi 2010). Οι ηλεκτρικοί κινητήρες διακρίνονται σε συνεχούς ρεύματος και σε εναλλασσομένου ρεύματος, ωστόσο περισσότερο διαδεδομένοι είναι οι κινητήρες συνεχούς ρεύματος επειδή παρουσιάζουν μεγαλύτερη ευκολία στον έλεγχό τους. Η αρχή λειτουργίας των DC κινητήρων στηρίζεται στην δύναμη Lorentz που δημιουργείται όταν ένας ηλεκτροφόρος αγωγός κινείται μέσα σε ένα μαγνητικό πεδίο. Ένας DC κινητήρας απαρτίζεται από δύο διακριτά μέρη, τον στάτορα και τον ρότορα: ο στάτορας δημιουργεί το μαγνητικό πεδίο ενώ, ο ρότορας είναι το κινούμενο μέρος του κινητήρα. Ο έλεγχος των DC κινητήρων μπορεί να πραγματοποιηθεί μεταβάλλοντας την τάση που εφαρμόζεται είτε στον στάτορα, είτε στον ρότορα.

Οι κλασσικές μέθοδοι ελέγχου των DC κινητήρων αφορούν σε ολοκληρωμένα συστήματα ελέγχου με χρήση PID ελεγκτών. Το πρόβλημα με τις μεθόδους αυτές είναι πως στην περίπτωση ύπαρξης μη γραμμικών φαινομένων, όπως αυτά που παρουσιάζονται στους μη γραμμικούς DC κινητήρες, υστερούν στην πραγματοποίηση του ελέγχου, αφού χρησιμοποιούν γραμμικό τρόπο προσέγγισης. Επομένως δημιουργείται η ανάγκη ύπαρξης μη γραμμικών μεθόδων, ικανών να πραγματοποιήσουν

έλεγχο σε τέτοιου είδους συστήματα. Μία τέτοια μέθοδος είναι η υλοποίηση ενός νευρωνικού ελεγκτή, που χρησιμοποιεί μοντέλα νευρωνικών δικτύων ως μέσο ελέγχου του συστήματος.

Υπάρχουν διάφοροι τρόποι να χρησιμοποιηθεί ένα νευρωνικό δίκτυο στον έλεγχο συστημάτων. Συνήθως τα νευρωνικά δίκτυα χρησιμοποιούνται σε συνδυασμό με ελεγκτές PID με σκοπό την ελαχιστοποίηση του σφάλματος, αλλά και ως αυτόνομοι ελεγκτές (Yeo and Kwon 1999). Υπάρχουν όμως μειονεκτήματα που αφορούν στην υλοποίηση τους αλλά και στην αποτελεσματικότητά τους. Οι μέθοδοι προβλεπτικού ελέγχου που βασίζονται σε μοντέλο (Model Predictive Control, MPC) χρησιμοποιούν νευρωνικά δίκτυα εκπαιδευμένα να υπολογίζουν την έξοδο του συστήματος χρησιμοποιώντας σαν είσοδο την μεταβλητή εκχειρισμού (Alexandridis and Sarimveis 2005, Alexandridis et al. 2005). Ένα συνηθισμένο πρόβλημα με αυτές τις μεθόδους είναι η αντιστροφή του μοντέλου που έχει δημιουργηθεί από την διαδικασία της εκπαίδευσης. Στην εκπαίδευση το νευρωνικό δίκτυο μαθαίνει πως συμπεριφέρεται σε αλλαγές εισόδου η έξοδος του συστήματος. Στον έλεγχο όμως του συστήματος καλείται να προβλέψει την τιμή της μεταβλητής εκχειρισμού του, ώστε να οδηγηθεί στον επιθυμητό αριθμό στροφών. Το πρόβλημα επομένως που του ζητείται να επιλύσει είναι αντίστροφο από αυτό που έχει εκπαιδευτεί. Η διαδικασία της αντιστροφής του μοντέλου μέσα από την επίλυση ενός συστήματος βελτιστοποίησης είναι ιδιαίτερα χρονοβόρα, ενώ μπορεί να παγιδευτεί σε κάποιο τοπικό ελάχιστο.

Στην παρούσα πτυχιακή προτείνεται ένας τρόπος εκπαίδευσης, κατά τον οποίο το νευρωνικό δίκτυο μαθαίνει απευθείας το αντίστροφο μοντέλο, γεγονός που οδηγεί σε ταχύτατες προβλέψεις προκειμένου να πραγματοποιηθεί ο έλεγχος του κινητήρα. Συγκεκριμένα υλοποιήθηκε ο νευρωνικός ελεγκτής και πραγματοποιήσε αυτόματο έλεγχο, ενώ για λόγους σύγκρισης χρησιμοποιήθηκε και ένας PID ελεγκτής. Η αξιολόγηση των ελεγκτών έγινε σε προβλήματα όπως η παρακολούθηση της επιθυμητής τιμής του συστήματος (set point tracking) και η απόρριψη εξωτερικής διαταραχής (disturbance rejection). Διαπιστώθηκε πως ο νευρωνικός ελεγκτής οδηγούσε το σύστημα στην επιθυμητή κατάσταση πολύ γρηγορότερα και με μικρότερο σφάλμα από τον PID. Η αποτελεσματικότητα του νευρωνικού ελεγκτή οφείλεται στην ικανότητά του να ερμηνεύει μη γραμμικά φαινόμενα. Αξίζει να σημειωθεί ότι τα αποτελέσματα της

εργασίας αυτής παρουσιάστηκαν στο διεθνές συνέδριο IEEE International Symposium on INnovations in Intelligent SysTems and Applications (INISTA 2011).

Η δομή της πτυχιακής εργασίας αναλύεται περιληπτικά ως εξής:

Στο 1^ο κεφάλαιο γίνεται μια εισαγωγή στα νευρωνικά δίκτυα και τον τρόπο λειτουργίας τους. Συγκεκριμένα παρουσιάζεται η σχέση που έχουν με τους βιολογικούς νευρώνες των οργανισμών, μερικά από τα βασικότερα είδη νευρωνικών δικτύων, η διαδικασία μάθησης και τέλος μερικές εφαρμογές στις οποίες αξιοποιούνται τα νευρωνικά δίκτυα.

Στο 2^ο κεφάλαιο αναλύεται η αρχιτεκτονική των νευρωνικών δικτύων ακτινικής συνάρτησης βάσης (RBF), τα οποία παρουσιάζουν κάποια πλεονεκτήματα έναντι των υπολοίπων νευρωνικών δικτύων. Στη συνέχεια γίνεται περιγραφή των αλγορίθμων εκπαίδευσης που χρησιμοποιούν τα δίκτυα RBF και παρουσιάζεται η μέθοδος που θα ακολουθηθεί στην συγκεκριμένη εργασία.

Στο 3^ο κεφάλαιο γίνεται μια εισαγωγή στους ηλεκτρικούς κινητήρες και παρουσιάζεται ένας μη γραμμικός DC κινητήρας, ο οποίος εξομοιώνεται στο Simulink του πακέτου Matlab. Ο κινητήρας αυτός αποτελεί το σύστημα που θα εφαρμοστεί η μέθοδος αυτομάτου ελέγχου.

Στο 4^ο κεφάλαιο μοντελοποιείται ο μη γραμμικός DC κινητήρας με χρήση ενός γραμμικού δυναμικού μοντέλου και ενός νευρωνικού δικτύου RBF και γίνεται σύγκριση μεταξύ τους.

Στο 5^ο κεφάλαιο πραγματοποιείται ο έλεγχος του κινητήρα με χρήση ενός δικτύου RBF που μοντελοποιεί το αντίστροφο πρόβλημα αυτομάτου ελέγχου και γίνεται σύγκριση με έναν ελεγκτή PID.

Τέλος εξάγονται συμπεράσματα και προτείνονται κατευθύνσεις για μελλοντική ερευνητική δραστηριότητα.

ΚΕΦΑΛΑΙΟ 1ο

ΕΙΣΑΓΩΓΗ ΣΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

1.1 Γενικά

Ο εγκέφαλος μπορεί να θεωρηθεί ως ένας πολυσύνθετος, μη γραμμικός υπολογιστής που χειρίζεται τις πληροφορίες με παράλληλο τρόπο. Μπορεί και οργανώνει τους νευρώνες, που είναι η βασική μονάδα δόμησης του εγκεφάλου, για να πραγματοποιήσει συγκεκριμένους υπολογισμούς (π.χ. αναγνώριση προτύπων, αντίληψη και έλεγχος κίνησης) αρκετές φορές γρηγορότερα από τον πιο γρήγορο υπολογιστή (Haykin 1999).

Γενικά οι νευρώνες είναι 5-6 τάξεις μεγέθους πιο αργοί από τις λογικές πύλες που χρησιμοποιούνται στα ψηφιακά κυκλώματα. Ο χρόνος απόκρισης σε ένα ολοκληρωμένο κύκλωμα είναι της τάξεως των nanosecond (10^{-9} sec), ενώ οι νευρώνες αντιδρούν σε χρόνους ms (10^{-3} sec). Παρόλα αυτά, ο εγκέφαλος αντισταθμίζει αυτόν τον σχετικά αργό χρόνο λειτουργίας του νευρώνα με το να διαθέτει έναν τρομερά μεγάλο αριθμό νευρώνων με μαζικές διασυνδέσεις μεταξύ τους. Εκτιμάται πως υπάρχουν 10 δις νευρώνες στον ανθρώπινο φλοιό του εγκεφάλου και 60 τρις συνάψεις ή συνδέσεις (Shepherd and Koch 1990). Το αποτέλεσμα είναι η δομή του εγκεφάλου να υπερισχύει της ταχύτητας των σύγχρονων ηλεκτρονικών εξαρτημάτων, όσο αφορά την ταχύτητα επεξεργασίας συγκεκριμένων διεργασιών (Rumelhart et al. 1986).

Αρκεί να αναλογιστούμε την ανθρώπινη όραση για παράδειγμα, η οποία είναι μια λειτουργία επεξεργασίας πληροφοριών (Marr 1982, Levine 1985, Churchland and Sejnowski 1992). Η λειτουργία του οπτικού συστήματος δημιουργεί μια αναπαράσταση του περιβάλλοντος γύρω μας και μας παρέχει πληροφορίες που χρειαζόμαστε για να συναναστραφούμε με αυτό. Συγκεκριμένα ο εγκέφαλος συνεχώς καταφέρνει να εκτελεί λειτουργίες αντίληψης και αναγνώρισης (πχ αναγνώριση οικείου προσώπου σε άγνωστο χώρο) σε χρόνους της τάξεως των 100 – 200 ms, ενώ διεργασίες πολύ λιγότερης πολυπλοκότητας χρειάζονται πολλαπλάσιο χρόνο σε συμβατικούς υπολογιστές (Churchland 1986).

Άλλο παράδειγμα είναι η λειτουργία του σόναρ στη νυχτερίδα. Το σόναρ είναι ένα ενεργό σύστημα που συσχετίζει την ηχώ με την απόσταση. Εκτός των πληροφοριών της απόστασης των οργανισμών (π.χ. έντομα), το σύστημα αυτό δίνει πληροφορίες και για την σχετική ταχύτητά τους, το μέγεθός τους καθώς και το μέγεθος των τριγύρω αντικειμένων και την πορεία τους. Οι πολύπλοκοι νευρωνικοί υπολογισμοί που

χρειάζονται για να εξάγουμε όλες αυτές τις πληροφορίες από την ηχώ, συμβαίνουν μέσα σε έναν εγκέφαλο μεγέθους σταφυλιού. Πραγματικά μια νυχτερίδα μπορεί να κυνηγήσει και να αιχμαλωτίσει τον στόχο της με τόσο μικρά εφόδια (εγκέφαλος) και με τόσο μεγάλο ποσοστό επιτυχίας που κάνει το ραντάρ ή το σόναρ ενός μηχανικού να φαίνεται σαν παιχνίδι.

Πώς μπορεί λοιπόν ένας ανθρώπινος εγκέφαλος ή ο εγκέφαλος μιας νυχτερίδας να το πραγματοποιήσει; Από τη στιγμή της γέννησης μας ο εγκέφαλος έχει εκπληκτική δομή και την ικανότητα να σχηματίζει δικούς του κανόνες, μια διαδικασία που είναι γνωστή σε μας ως “εμπειρία”. Πράγματι, μέσα στα πρώτα 2 χρόνια ο εγκέφαλος μαθαίνει να “συνδέει” και να ελέγχει όλο το σώμα μέσω των εμπειριών, αλλά η ανάπτυξη και η εξέλιξή του συνεχίζει για πολύ περισσότερο. Στα πρώτα αυτά στάδια της ανάπτυξης σχηματίζονται περίπου 1 εκατομμύριο συνάψεις το δευτερόλεπτο. Οι συνάψεις είναι οι βασικές δομικές και λειτουργικές μονάδες που μεσολαβούν για τις διασυνδέσεις μεταξύ των νευρώνων.

1.2 Βιολογικά νευρωνικά δίκτυα και η δόμησή τους

Η βασική μονάδα δόμησης του εγκεφάλου ονομάζεται νευρώνας. Όπως αναφέρθηκε προηγουμένως υπάρχει ένας τεράστιος αριθμός νευρώνων, οι οποίοι κατάλληλα δομημένοι και τοποθετημένοι συνθέτουν πάρα πολλά νευρωνικά δίκτυα στον εγκέφαλο, το καθένα εξειδικευμένο για να εκτελεί συγκεκριμένη διεργασία.

Κάθε νευρώνας συνδέεται με άλλους νευρώνες μέσω κάποιων συνδέσεων που ονομάζονται συνάψεις. Ο αριθμός των συνάψεων ανά νευρώνα δεν είναι σταθερός αλλά συνήθως είναι της τάξης των 10^3 - 10^4 συνάψεων, γεγονός που αντικατοπτρίζει την πολυπλοκότητα αλλά και τις δυνατότητες των νευρωνικών δικτύων.

Αξίζει να αναφέρουμε πως οι νευρώνες δεν πολλαπλασιάζονται, δηλαδή ο αριθμός τους καθορίζεται στον άνθρωπο στους πρώτους μήνες της ζωής του, αλλά δε συμβαίνει το ίδιο και για τις συνάψεις. Οι συνάψεις συνεχώς καταστρέφονται και δημιουργούνται καινούριες όσο ο άνθρωπος αποκτά εμπειρίες και γνώσεις.

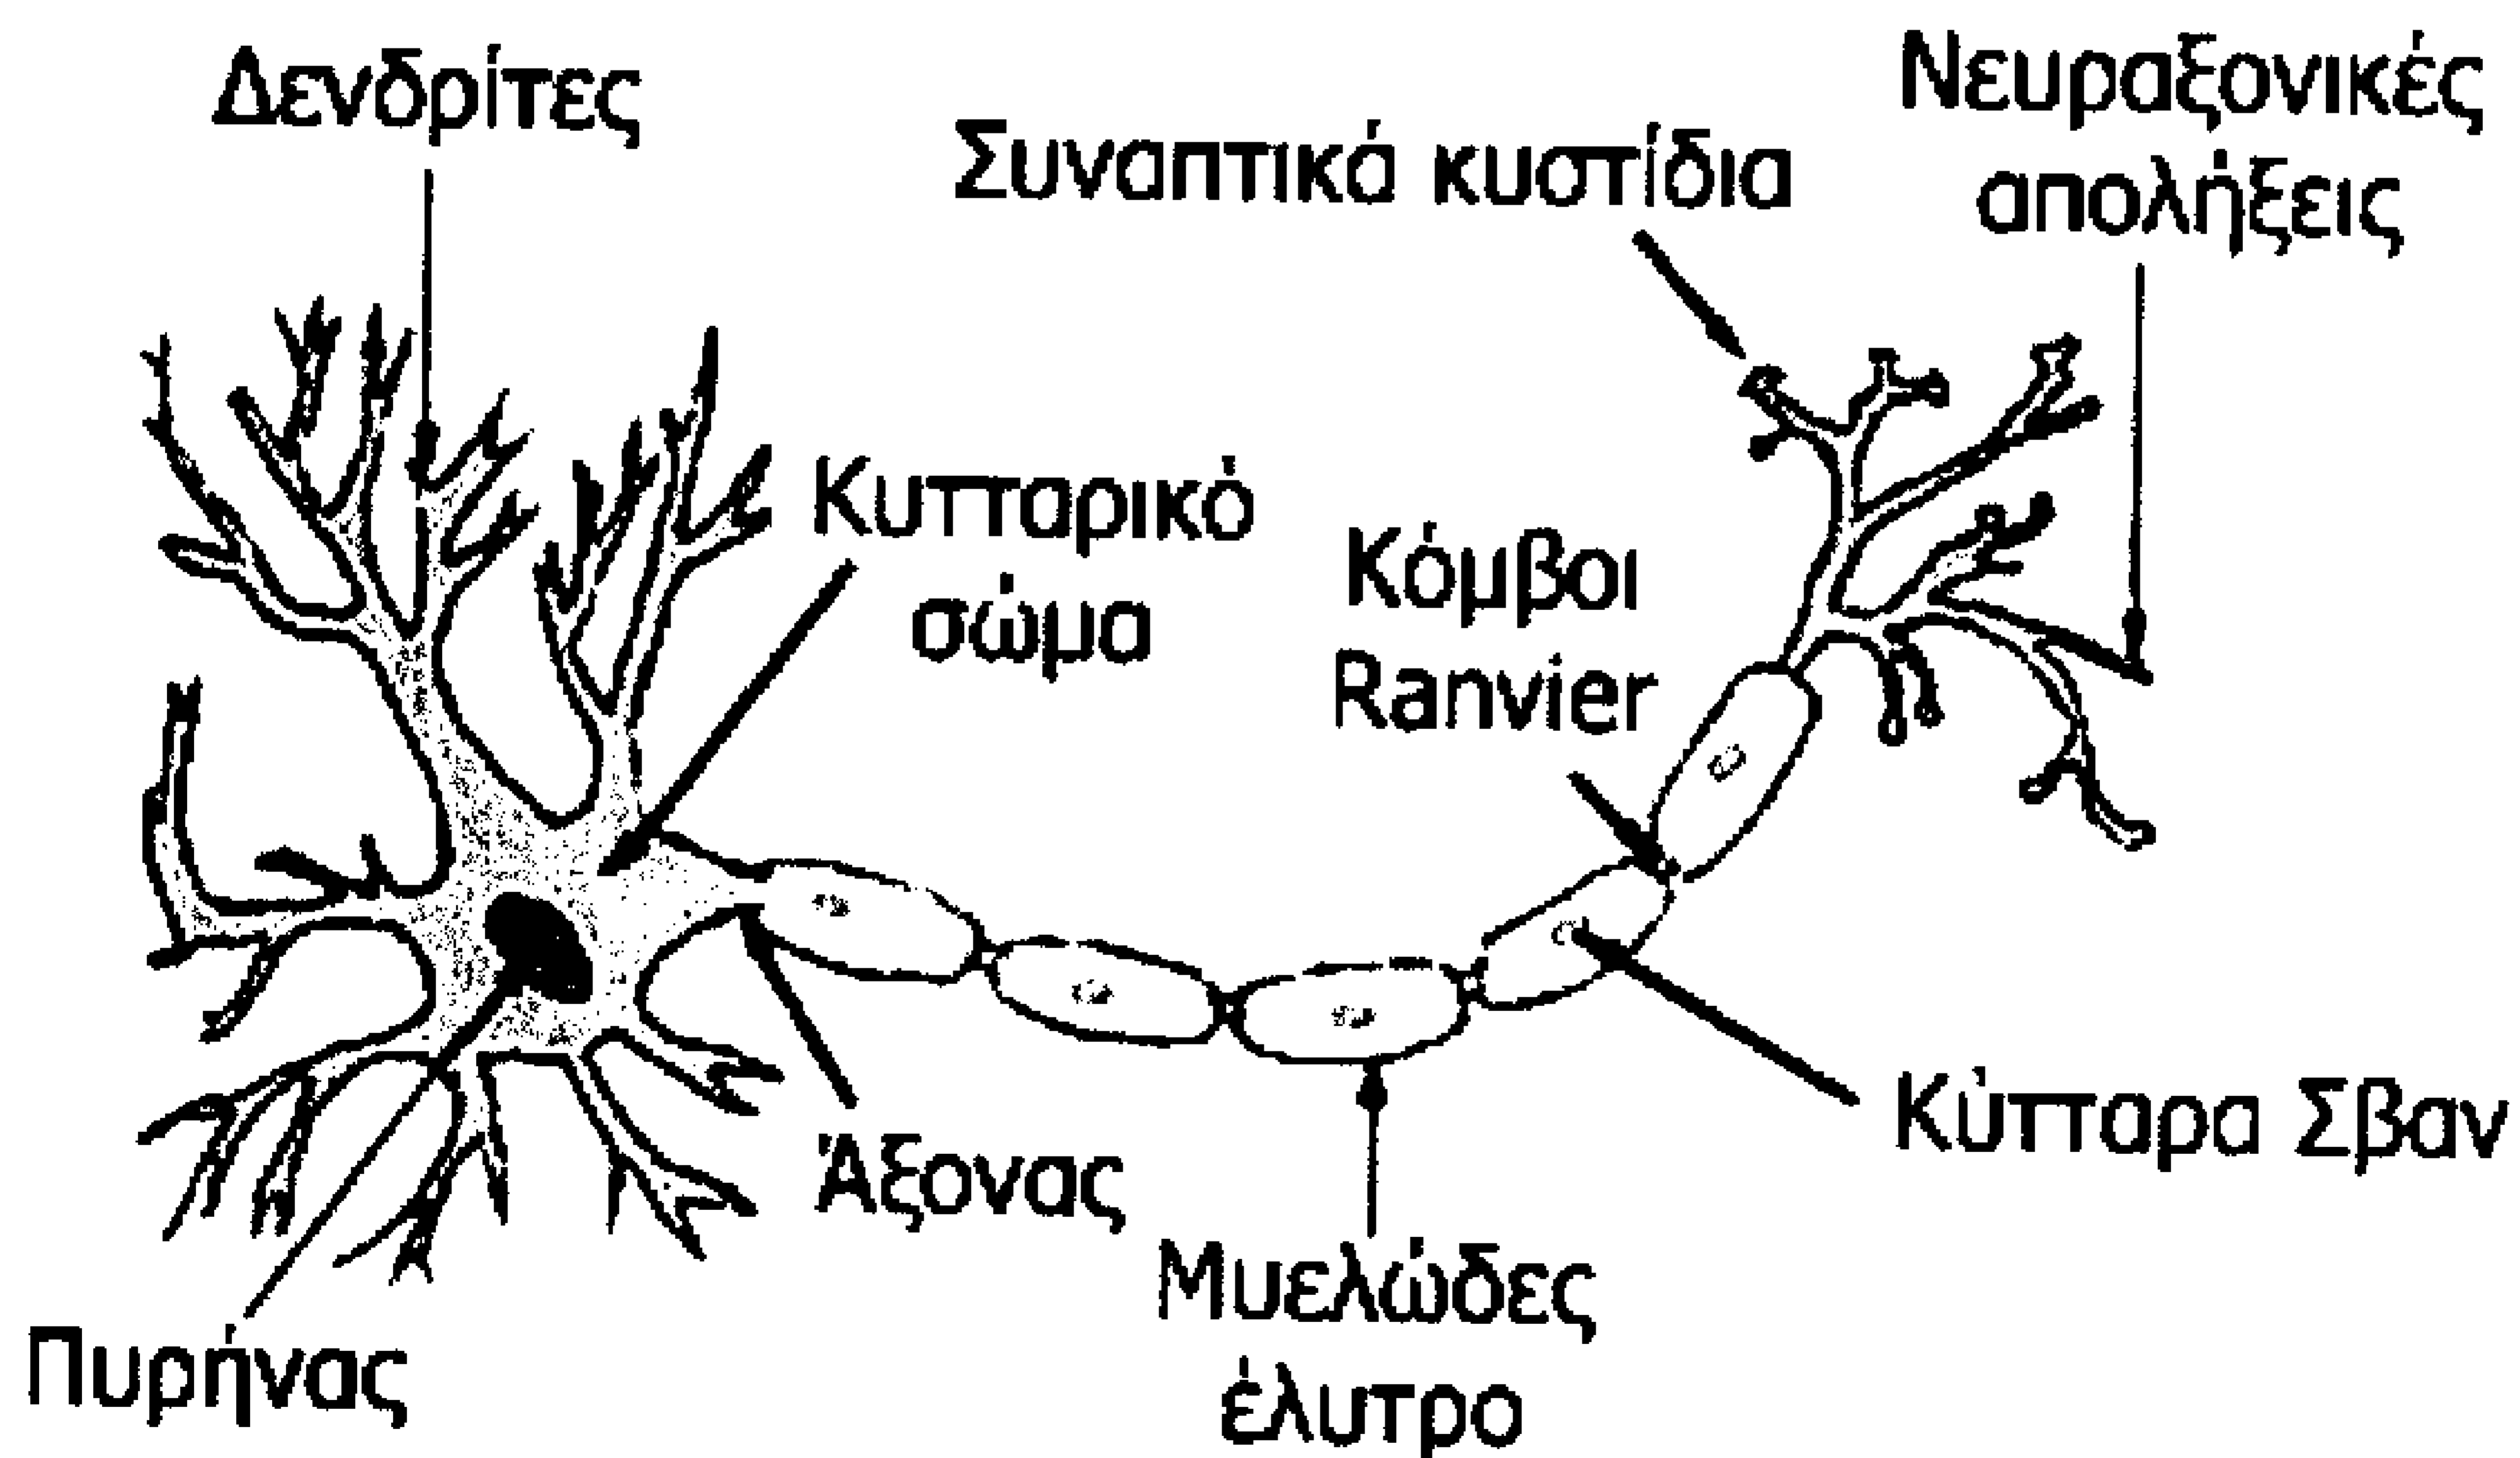
Ο κάθε νευρώνας έχει ως σκοπό να δεχθεί ένα πλήθος σημάτων που προέρχονται

από άλλους νευρώνες, να τα επεξεργαστεί και να τα προωθήσει σε επόμενους νευρώνες, αποτελώντας έτσι κομμάτι ενός νευρωνικού δικτύου. Ο εγκέφαλος αποτελείται από πολλά νευρωνικά δίκτυα, το καθένα εξειδικευμένο σε κάποια λειτουργία ή εργασία, όπως είναι η ακοή, η όραση, η κίνηση.

Ο νευρώνας είναι ουσιαστικά ένα κύτταρο, το οποίο έχει παρόμοια δομή με τα υπόλοιπα κύτταρα του οργανισμού. Αποτελείται από το κυρίως σώμα, τους δενδρίτες και τον άξονα, όπως φαίνεται στο σχήμα 1.1.

Κάθε νευρώνας έχει έναν μόνο άξονα που μεταφέρει το σήμα από τον έναν νευρώνα στον επόμενο. Στην άκρη του νευρώνα υπάρχουν οι δενδρίτες, οι οποίοι έρχονται σε επαφή με τους άλλους νευρώνες, μεταφέροντας έτσι σήματα στον άξονα.

Οι συνδέσεις μεταξύ νευρώνων, άξονα και δενδριτών ονομάζονται συνάψεις. Ο νευρώνας μπορεί να λάβει δύο καταστάσεις, την ενεργό και την μη ενεργό. Έτσι μπορούμε να παρουσιάσουμε τον νευρώνα σαν ένα δυαδικό υπολογιστικό σύστημα που όταν είναι ενεργός άγει (1) και όταν είναι μη ενεργός δεν άγει (0).



Σχήμα 1.1 Η δομή ενός νευρώνα


1.3 Μετάδοση του σήματος

1.3.1 Το Νευρωνικό Δίκτυο και η μετάδοση του σήματος

Στην πιο γενική μορφή του, ένα νευρωνικό δίκτυο είναι μια μηχανή που είναι σχεδιασμένη να μοντελοποιεί τον τρόπο με τον οποίο ο εγκέφαλος πραγματοποιεί συγκεκριμένες λειτουργίες που παρουσιάζουν ενδιαφέρον. Το δίκτυο συνήθως λειτουργεί χρησιμοποιώντας ηλεκτρονικά εξαρτήματα ή εξομοιώνεται με πρόγραμμα στους ηλεκτρονικούς υπολογιστές. Στη συγκεκριμένη εργασία θα ασχοληθούμε με νευρωνικά δίκτυα τα οποία πραγματοποιούν χρήσιμους υπολογισμούς μέσω της διαδικασίας της μάθησης. Για να επιτύχουν καλή απόδοση τα νευρωνικά δίκτυα χρησιμοποιούν μαζικές διασυνδέσεις απλών υπολογιστικών στοιχείων που αναφέρονται ως νευρώνες ή υπολογιστικές μονάδες.

Το νευρωνικό δίκτυο αποτελείται από τις βασικές του μονάδες που είναι οι νευρώνες. Σε αυτούς εισέρχονται τα σήματα εισόδου. Από τον κάθε νευρώνα μπορεί να εξέλθει μόνο ένα σήμα, δηλαδή μπορούμε να έχουμε μόνο μία έξοδο, η οποία είναι η συνάρτηση των σημάτων εισόδου. Έτσι κάθε σήμα που μεταδίδεται από νευρώνα σε νευρώνα συνδέεται με μια συγκεκριμένη τιμή, το βάρος όπως λέγεται και είναι αυτό που δηλώνει τη συσχέτιση των νευρώνων με το συγκεκριμένο σήμα. Ουσιαστικά το βάρος μας φανερώνει το μέγεθος της συμμετοχής του σήματος στη διαμόρφωση της δομής του νευρωνικού δικτύου.

Συνοψίζοντας μπορούμε να πούμε πως τα σήματα που εισέρχονται σε κάθε νευρώνα αθροίζονται και μέσω κάποιας διαδικασίας παράγεται μια έξοδος η οποία είναι έτοιμη προς μετάδοση στον επόμενο νευρώνα. Στο σχήμα 1.2 παρατηρούμε την δομή ενός απλού νευρωνικού δικτύου:



Σχήμα 1.2 Ο νευρώνας και τα συναπτικά βάρη w_1, w_2, w_3 , των εισόδων.

1.3.2 Ανατροφοδότηση

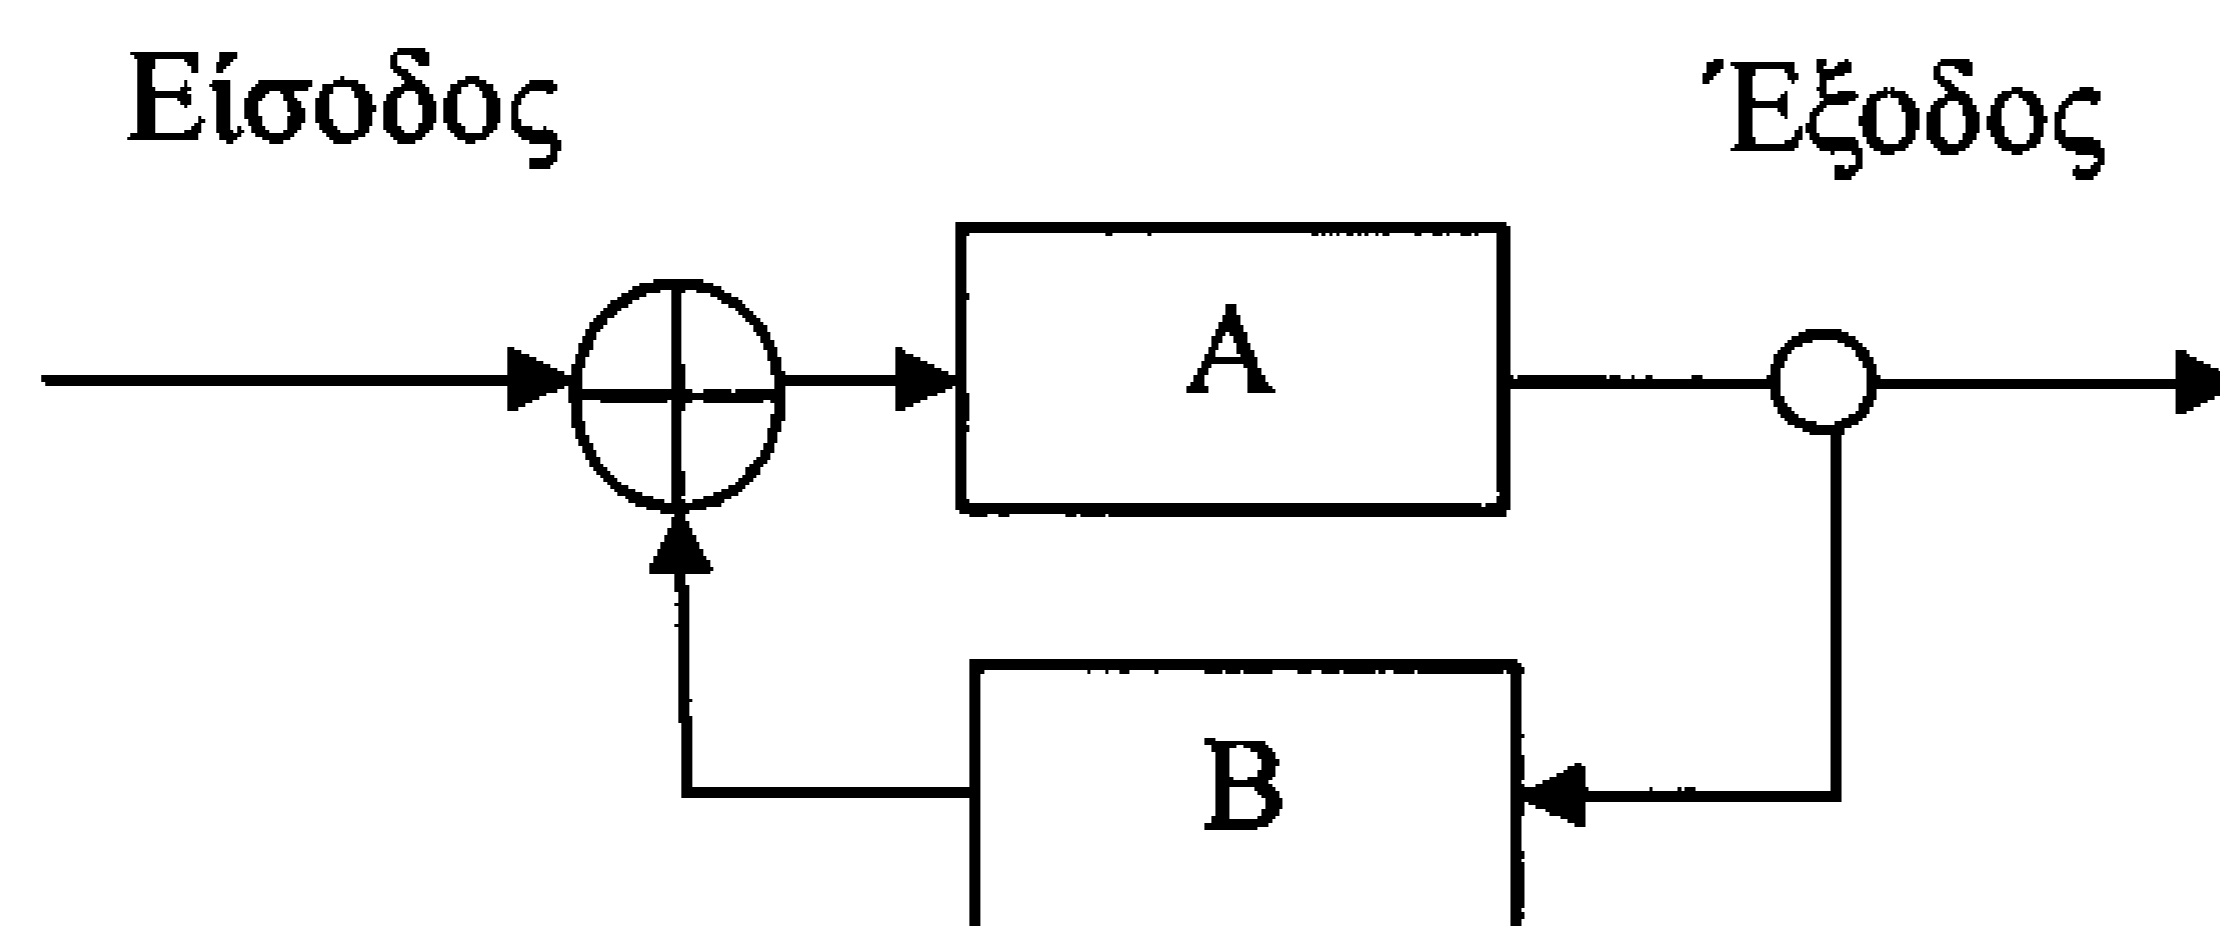
Η ανατροφοδότηση υπάρχει σε ένα σύστημα όταν η έξοδος ενός στοιχείου του συστήματος επηρεάζει την είσοδο που εφαρμόζεται σε αυτό. Στην πραγματικότητα ανατροφοδότηση έχουμε σχεδόν σε κάθε μέρος του νευρικού συστήματος όλων των οργανισμών (Freeman 1975). Στο σχήμα 1.3 αναπαρίσταται η ανατροφοδότηση σε ένα τέτοιο σύστημα.

Όπως φαίνεται η έξοδος αθροίζεται με το σήμα εισόδου αφού περάσει από κάποια επεξεργασία (αύξηση, πολλαπλασιασμός, μείωση) όπως είναι το στοιχείο Β και ανατροφοδοτεί το σύστημα.

1.4 Εκπαίδευση του νευρωνικού δικτύου

Ένα νευρωνικό δίκτυο από μόνο του δεν είναι ικανό να επιλύσει κανένα πρόβλημα ούτε να εκτελέσει καμία λειτουργία. Για να χρησιμοποιηθεί επομένως πρέπει να περάσει από μια διαδικασία που ονομάζεται εκπαίδευση ή μάθηση. Η διαδικασία που χρησιμοποιείται για την λειτουργία της μάθησης ονομάζεται αλγόριθμος μάθησης και η λειτουργία του είναι να μεταβάλλει τα συναπτικά βάρη του νευρωνικού δικτύου με τέτοιο τρόπο ώστε να αποκτήσει το επιθυμητό σχεδιαστικό αποτέλεσμα.

Με την εκπαίδευση γενικά δίνουμε στο νευρωνικό δίκτυο κάποιο πρόβλημα και ταυτόχρονα του προσφέρουμε και την λύση του. Επομένως το νευρωνικό δίκτυο σε αυτή τη φάση πρέπει να αναπροσαρμόσει τους νευρώνες του και τα βάρη ώστε να μπορέσει να αντιστοιχίσει στο πρόβλημα αυτό την προσφερόμενη λύση. Όμως δεν του δίνουμε μόνο



Σχήμα 1.3 Σύστημα ανατροφοδότησης

ένα πρόβλημα αλλά πλήθος προβλημάτων, δηλαδή η διαδικασία επαναλαμβάνεται αρκετές φορές ώστε να αποκτήσει το νευρωνικό δίκτυο αρκετά στοιχεία για καλύτερη εκπαίδευση. Σε αυτό το σημείο πρέπει να προσέξουμε πως τα προβλήματα αυτά πρέπει να είναι ίδιας φύσεως και όχι άσχετα μεταξύ τους π.χ. δε γίνεται να εκπαιδεύουμε το δίκτυο σε θέματα επίλυσης οικονομικών και να απαιτούμε να μας δώσει απάντηση για την πρόβλεψη του καιρού. Αυτός επομένως είναι ο γενικός τρόπος εκπαίδευσης ή μάθησης του νευρωνικού δικτύου. Η διαδικασία όμως αλλάζει σύμφωνα με την μέθοδο εκπαίδευσης που θα επιλέξουμε.

1.5 Ιλιονεκτήματα των νευρωνικών δικτύων

Από τα παραπάνω είναι σαφές ότι το νευρωνικό δίκτυο παράγει την υπολογιστική του δύναμη και ικανότητα από την μεγάλη και παράλληλα κατανεμημένη δομή του και από την ικανότητα να μαθαίνει, συνεπώς να γενικεύει. Η γενίκευση αυτή αναφέρεται στο νευρωνικό δίκτυο με την παραγωγή λογικών αποτελεσμάτων εξόδων, για εισόδους που δεν έχουν χρησιμοποιηθεί στη διαδικασία της μάθησης.

Επομένως αυτά τα δύο χαρακτηριστικά είναι ικανά να επιτρέψουν στο νευρωνικό δίκτυο να επιλύει μεγάλης δυσκολίας προβλήματα, τα οποία δεν μπορούν να επιλυθούν με χρήση βασικών εξισώσεων (first principle equations). Παρόλα αυτά έχουμε πολύ δρόμο ακόμη μέχρι να καταφέρουμε να δημιουργήσουμε νευρωνικά δίκτυα τα οποία είναι ικανά να αντικαταστήσουν τον ανθρώπινο εγκέφαλο.

Η χρήση των νευρωνικών δικτύων επομένως παρουσιάζει τα εξής χαρακτηριστικά:

1. **Μη γραμμικότητα:** Ο νευρώνας είναι ουσιαστικά μια μη γραμμική μονάδα και ως επακόλουθο, το νευρωνικό δίκτυο, που αποτελείται από διασυνδέσεις νευρώνων είναι μη γραμμικό. Επιπλέον, ο τρόπος σύνδεσης των νευρώνων είναι μη γραμμικός. Αυτό το χαρακτηριστικό είναι πολύ σημαντικό καθώς μας επιτρέπει να εξάγουμε αποτελέσματα για συστήματα και μηχανισμούς οι οποίοι είναι μη γραμμικοί.
2. **Χαρτογράφηση εισόδου-εξόδου:** Ένας δημοφιλής τρόπος εκπαίδευσης νευρωνικών δικτύων που ονομάζεται μάθηση με επίβλεψη (supervised learning) περιλαμβάνει την μεταβολή των συναπτικών βαρών του νευρωνικού δικτύου με τη χρήση

ζυγών δεδομένων εισόδου - εξόδου. Κάθε ζεύγος δεδομένων εκφράζει ένα μοναδικό ρα εισόδου και την αντίστοιχη έξοδο. Το νευρωνικό δίκτυο χρησιμοποιεί αυτά τα δεδομένα με τυχαία σειρά και τα συναπτικά βάρη μεταβάλλονται με τέτοιο τρόπο ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ της επιθυμητής τιμής εξόδου και της τιμής που προέβλεψε το νευρωνικό δίκτυο, με κάποιο στατιστικό κριτήριο. Αυτή η διαδικασία επαναλαμβάνεται πολλές φορές έως ότου να μην γίνονται σημαντικές μεταβολές στα συναπτικά βάρη. Είναι σημαντικό να αναφέρουμε πως τα ζεύγη που χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου μπορούν να χρησιμοποιηθούν πολλές φορές και με διαφορετική σειρά. Έτσι το νευρωνικό δίκτυο μαθαίνει από τα δεδομένα δημιουργώντας μια χαρτογράφηση μεταξύ εισόδων-εξόδων για το συγκεκριμένο πρόβλημα.

3. **Προσαρμοστικότητα:** Τα νευρωνικά δίκτυα έχουν ενσωματωμένη την ικανότητα να προσαρμόζουν τα συναπτικά τους βάρη σε αλλαγές στον περιβάλλοντα χώρο. Συγκεκριμένα ένα νευρωνικό δίκτυο που μαθαίνει να λειτουργεί σε ένα συγκεκριμένο περιβάλλον, μπορεί να επανεκπαιδευτεί εύκολα για να ανταποκριθεί στις αλλαγές του περιβάλλοντος αυτού. Επιπλέον όταν το νευρωνικό δίκτυο πρόκειται να χρησιμοποιηθεί σε ένα ασταθές περιβάλλον, μπορεί να εκπαιδευτεί ώστε να αλλάζει τα συναπτικά του βάρη σε πραγματικό χρόνο. Ο φυσικός σχεδιασμός του νευρωνικού δικτύου για κατάταξη προτύπων, επεξεργασία σήματος, έλεγχο εφαρμογών σε συνδυασμό με την ικανότητα του δικτύου να προσαρμόζεται, το κάνουν ιδανικό για τη χρήση σε προσαρμοστικά συστήματα επεξεργασίας σημάτων και έλεγχο εφαρμογών που μεταβάλλονται με το χρόνο και το περιβάλλον.

4. **Τεκμηριωμένη απόφαση:** Μέσα στα πλαίσια της κατάταξης προτύπων, ένα νευρωνικό δίκτυο μπορεί να σχεδιαστεί για να παρέχει πληροφορίες όχι μόνο για το ποιο πρότυπο να επιλέξει, αλλά και για την σιγουριά στην απόφαση που πήρε. Αυτή η πληροφορία μπορεί να χρησιμοποιηθεί για την απόρριψη ασαφών και διφορούμενων προτύπων, εάν αυτά προκύψουν, βελτιώνοντας έτσι την κατάταξη των προτύπων και την απόδοση του δικτύου.

5. **Εμπεριστατωμένη πληροφόρηση:** Η γνώση παριστάνεται με την δομή και την ενεργοποιημένη κατάσταση του νευρωνικού δικτύου. Κάθε νευρώνας στο δίκτυο είναι πιθανό να επηρεαστεί από την γενική παρουσία των άλλων νευρώνων του δικτύου. Ως αποτέλεσμα η πληροφορία ενός νευρώνα σχετίζεται με φυσικό τρόπο και με τους

γειτονικούς του νευρώνες.


6. **Ανοχή λάθους:** Ένα νευρωνικό δίκτυο που είναι υλοποιημένο σε επίπεδο φυσικών εξαρτημάτων και όχι σαν λογισμικό, έχει την ικανότητα να είναι εκ φύσεως ανεκτικό στα λάθη, με την λογική πως με τη χρήση η απόδοση των εξαρτημάτων και συνεπώς του δικτύου ελαττώνεται (Bolt 1992). Για παράδειγμα, εάν ένας νευρώνας ή οι συνδετικοί του σύνδεσμοι καταστραφούν, κανονικά θα έπρεπε να μεταβληθεί και η απόδοση του δικτύου, ή να καταστραφεί. Επειδή όμως η πληροφορία διανέμεται σε ολόκληρο το δίκτυο, η ζημιά του νευρώνα πρέπει να είναι πολύ μεγάλη ώστε να καταφέρει να μειώσει την συνολική απόδοση του δικτύου. Έτσι το νευρωνικό δίκτυο παρουσιάζει, λόγω δομής, μια ανοχή σε περίπτωση μιας μικρής ζημιάς και η απόδοση του μειώνεται ελάχιστα, αντί να παρουσιάσει μια καταστροφική αποτυχία.

7. **Εφαρμογή VLSI:** Η ικανότητα του νευρωνικού δικτύου να δομηθεί με παράλληλο τρόπο, δηλαδή σαν πολλοί επεξεργαστές που δουλεύουν παράλληλα, το κάνει ιδιαίτερα γρήγορο στον υπολογισμό συγκεκριμένων εργασιών. Επίσης αυτό το χαρακτηριστικό το κάνει ιδανικό για την εφαρμογή του σε τεχνολογία VLSI (Very-Large-Scale-Integrated). Το πλεονέκτημα των VLSI συστημάτων είναι πως επιτρέπουν στο νευρωνικό δίκτυο να δομηθεί με τέτοιο τρόπο ώστε να εκτελεί πραγματικά πολύπλοκους υπολογισμούς με ιεραρχικό τρόπο, αφού μπορούν να εμπεριέχουν σε μικρό χώρο πολλούς νευρώνες, κάνοντας το ικανό να χρησιμοποιείται σε εφαρμογές πραγματικού χρόνου όπως η αναγνώριση προτύπων, ο έλεγχος και η επεξεργασία σημάτων.

8. **Νευροβιολογική αναλογία:** Ο σχεδιασμός ενός νευρωνικού δικτύου είναι εμπνευσμένος με την σχεδιαστική αναλογία του εγκεφάλου, που είναι η ζωντανή απόδειξη πως η παράλληλη επεξεργασία με ανοχή στα σφάλματα είναι όχι μόνο υπαρκτή αλλά και γρήγορη και ισχυρή. Οι νευροβιολόγοι χρησιμοποιούν τα νευρωνικά δίκτυα ως εργαλείο έρευνας για την επεξήγηση των νευροβιολογικών φαινομένων.

1.6 Αρχιτεκτονικές νευρωνικών δικτύων

Ο τρόπος με τον οποίο οι νευρώνες ενός νευρωνικού δικτύου είναι δομημένοι, είναι




Σχμα 1.4.α Δίκτυο ενός επιπέδου μιας κατεύθυνσης

σνά συνδεδεμένος με τον αλγόριθμο μάθησης που χρησιμοποιείται για την εκπαίδευσή του. Γενικά μπορούμε να διακρίνουμε 4 διαφορετικές αρχιτεκτονικές δόμησης των δικτύων:

1. **Δίκτυα ενός επιπέδου μιας κατεύθυνσης (single layer feedforward networks):** Σε αυτόν τον τύπο νευρωνικού δικτύου, κάθε είσοδος μπορεί να επικοινωνεί με τους νευρώνες του δικτύου προς μία κατεύθυνση και οι νευρώνες εξόδου παράγουν ένα μόνο σήμα εξόδου (Σχήμα 1.4.α).


2. **Δίκτυα πολλαπλών επιπέδων μιας κατεύθυνσης (multilayer feedforward networks):** Αυτός ο τύπος νευρωνικού δικτύου, διαφέρει από τον προηγούμενο επειδή υπάρχει ένα είτε περισσότερα κρυμμένα επίπεδα νευρώνων. Η λειτουργία τους είναι να διμεσολαβούν μεταξύ των σημάτων εξόδου από τους αρχικούς νευρώνες και της τελικής εξόδου του δικτύου. Με την προσθήκη αυτών των πολλαπλών επιπέδων, το νευρωνικό δίκτυο είναι ικανό να παράγει περαιτέρω στατιστικές για την συσχέτιση των δεδομένων εισόδου-εξόδου και έτσι να παρέχει αποτελέσματα με μεγαλύτερη ακρίβεια. Αυτού του τύπου τα δίκτυα είναι ιδιαίτερα χρήσιμα όταν τα δεδομένα εισόδου είναι πολλών διαστάσεων (Σχήμα 1.4.β).




Σχήμα 1.4.β Δίκτυο πολλαπλών επιπέδων μίας κατεύθυνσης

3. **Ανατροφοδοτούμενα δίκτυα (recurrent networks):** Ένα ανατροφοδοτούμενο δίκτυο ξεχωρίζει από ένα δίκτυο μονής κατεύθυνσης επειδή διαθέτει τουλάχιστον ένα βρόγχο ανατροφοδότησης. Για παράδειγμα ένα ανατροφοδοτούμενο νευρωνικό δίκτυο μπορεί να αποτελείται από ένα επίπεδο νευρώνων και κάθε νευρώνας να τροφοδοτεί την είσοδο του δικτύου με την έξοδό του (Σχήμα 1.4.γ).

4. **Δίκτυα με δομή πλέγματος (lattice structures):** Αυτά τα δίκτυα μπορούν να αποτελούνται είτε από ένα επίπεδο νευρώνων είτε από περισσότερα. Η διαφορά τους με τα υπόλοιπα δίκτυα μιας κατεύθυνσης είναι πως οι νευρώνες εξόδου είναι οργανωμένοι σε σειρές και στήλες (Σχήμα 1.4.δ).



Σχήμα 1.4.γ Ανατροφοδοτούμενο δίκτυο



Σχήμα 1.4.δ Δίκτυο δομής πλέγματος

1.7 Εφαρμογές των νευρωνικών δικτύων

Αν και τα νευρωνικά δίκτυα βρίσκονται ακόμα σε πρώιμο στάδιο, χρησιμοποιούνται κατά κόρον σε πλήθος εφαρμογών που έχουν να κάνουν με αναγνώριση προτύπων, υπολογισμούς, προβλέψεις και αυτόματο έλεγχο.

Πιο συγκεκριμένα παραδείγματα της χρήσης των νευρωνικών δικτύων σε διάφορους τομείς είναι τα εξής:

Αναγνώριση εικόνων και κειμένων. Χαρακτηριστικό παράδειγμα είναι τα προγράμματα οπτικής αναγνώρισης χαρακτήρων (Optical Character Recognition, O.C.R.) τα οποία μέσω ενός σαρωτή (scanner) αναγνωρίζουν γραφικούς χαρακτήρες και τους μετατρέπουν σε επεξεργάσιμη μορφή κειμένου για τον υπολογιστή (ASCII) (Bourbakis and Gumahad II 1991).

Μετατροπή φωνής σε κείμενο και το αντίστροφο. Πλέον τα προγράμματα είναι ικανά να γράφουν σε κείμενο του υπολογιστή ό,τι εμείς τους υπαγορεύουμε με πολύ μεγάλο ποσοστό επιτυχίας (Karaali et al. 1998).

Χρηματιστηριακές προβλέψεις. Οι διακυμάνσεις των τιμών των μετοχών και των χρηματιστηριακών δεικτών είναι ακόμα ένα παράδειγμα ενός πολύπλοκου, πολυδιάστατου μοντέλου. Χρησιμοποιούνται από πολλούς αναλυτές ώστε να κάνουν προβλέψεις για τις μετοχές βασιζόμενοι σε προηγούμενα δεδομένα (Morajda 2000).

Άλλες εφαρμογές είναι στον τομέα της βιολογίας όπως οι προβλέψεις για τις αντιδράσεις των διαφόρων οργανισμών σε χημικές ουσίες και φάρμακα, στη διάγνωση και τη θεραπεία (Kvasnička et al. 1993). Επίσης τα νευρωνικά δίκτυα χρησιμοποιούνται για στρατιωτικούς σκοπούς όπως κωδικοποίηση, κρυπτογράφηση, άμυνα και κατασκοπία (Khashman 1999).

Τέλος τα νευρωνικά δίκτυα έχουν βρεί πολλές σημαντικές εφαρμογές στη βιομηχανία όσον αφορά στον αυτόματο έλεγχο της παραγωγής, στην επιθεώρηση, στην διάγνωση σφαλμάτων (fault diagnosis) κλπ. Σκοπός αυτής της πτυχιακής είναι η εφαρμογή νευρωνικών δικτύων στον αυτόματο έλεγχο ενός μη γραμμικού κινητήρα, που θα αναλυθεί στο τελευταίο κεφάλαιο της παρούσας πτυχιακής εργασίας.

ΚΕΦΑΛΑΙΟ 2ο

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΑΚΤΙΝΙΚΗΣ ΣΥΝΑΡΤΗΣΗΣ ΒΑΣΗΣ (Radial Basis Function, RBF)

2.1 Γενικά για τα δίκτυα ακτινικής συνάρτησης βάσης (RBF)

Στο προηγούμενο κεφάλαιο αναφέρθηκαν αρκετοί τύποι νευρωνικών δικτύων, που ο καθένας πραγματεύεται διαφορετικό τρόπο προσέγγισης για την επίλυση ενός προβλήματος. Σε αυτό το κεφάλαιο θα ασχοληθούμε με τον σχεδιασμό ενός νευρωνικού δικτύου το οποίο έχει σαν σκοπό την δημιουργία μιας επιφάνειας σε ένα πολυδιάστατο χώρο που να παρέχει την καλύτερη επικάλυψη στα δεδομένα εισόδου από στατιστικής απόψεως (Powell 1987). Ως επακόλουθο, τα δεδομένα που χρησιμοποιούνται για την αξιολόγηση του δικτύου προσεγγίζονται από αυτήν την επιφάνεια. Σαν δομή το νευρωνικό δίκτυο χρησιμοποιεί τους κρυμμένους κόμβους, οι οποίοι παρέχουν ένα σύνολο συναρτήσεων που αποτελούν μια αυθαίρετη βάση για τις παραμέτρους εισόδου, όταν απλώνονται στον χώρο που αποτελούν οι κρυφοί αυτοί κόμβοι (Powell 1985). Αυτές οι συναρτήσεις ονομάζονται συναρτήσεις ακτινικής βάσης (Radial Basis Functions, RBF).

Τα δίκτυα RBF είναι ισχυρά υπολογιστικά εργαλεία, τα οποία χρησιμοποιούνται ευρέως στους τομείς της μοντελοποίησης συστημάτων και αναγνώρισης προτύπων (Powell 1992). Τα δίκτυα RBF είναι μια κατηγορία νευρωνικών δικτύων με συγκεκριμένα πλεονεκτήματα σε σχέση με άλλα νευρωνικά δίκτυα, όπως καλύτερη προσεγγιστική ικανότητα, απλές δομές δικτύου και γρηγορότερους αλγορίθμους μάθησης. Η διαφορά στην ταχύτητα της διαδικασίας εκμάθησης ανάμεσα στα δίκτυα RBF και τις άλλες αρχιτεκτονικές νευρωνικών δικτύων, οφείλεται στο γεγονός ότι οι μέθοδοι εκμάθησης που χρησιμοποιούν τα δίκτυα RBF εκτελούνται σε διακριτές φάσεις. Στο σχήμα 2.1 διακρίνεται ένα απλό δίκτυο RBF όπου αριστερά είναι η στοιβάδα εισόδου, στη μέση η κρυφή στοιβάδα που περιέχει την ακτινική συνάρτηση βάσης και τέλος η στοιβάδα εξόδου.

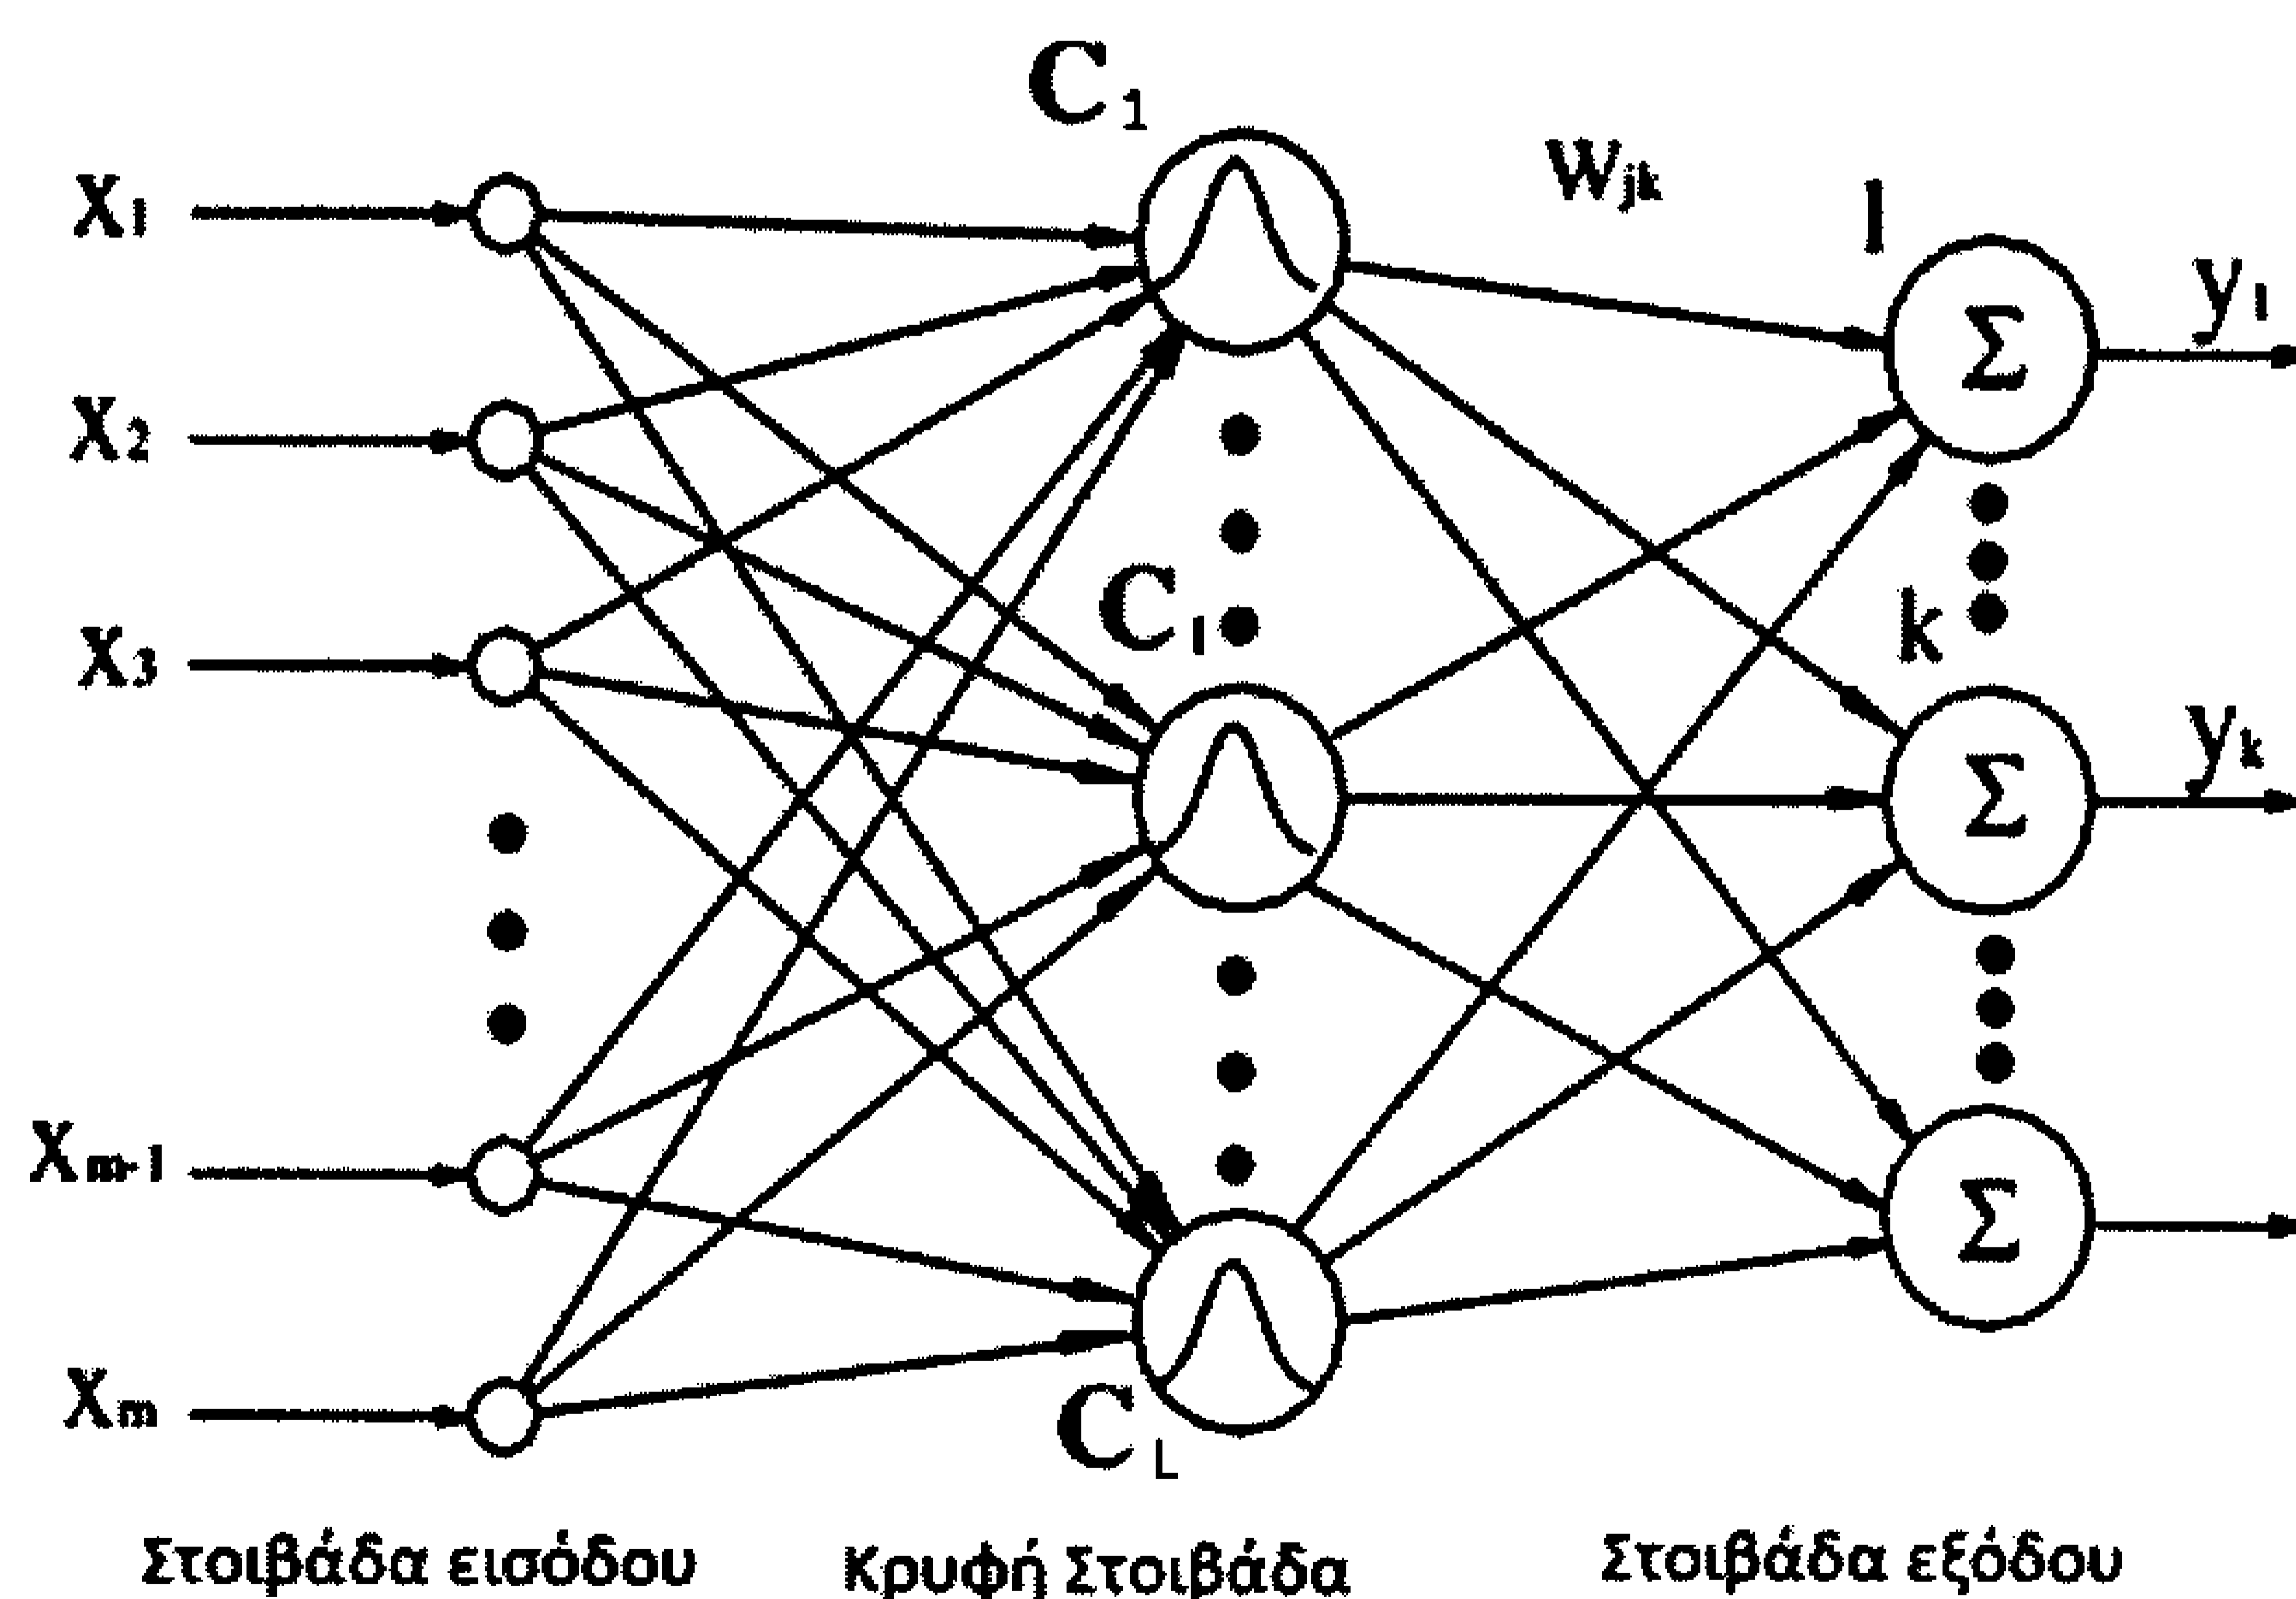
Τα δίκτυα RBF είναι μια μεγάλη ομάδα νευρωνικών δικτύων, όπου η ενεργοποίηση της κρυφής στοιβάδας (δεύτερη στοιβάδα) καθορίζεται από την απόσταση μεταξύ του διανύσματος εισόδου και ενός διανύσματος προτύπου. Μια σημαντική ιδιότητά τους είναι ότι σχηματίζουν γραμμική σχέση ανάμεσα στην κρυφή στοιβάδα και στην στοιβάδα εξόδου. Αυτή η ιδιότητα είναι που προκαλεί το ενδιαφέρον για εύρεση διαδικασιών εκπαίδευσης των δικτύων RBF οι οποίες θα είναι χαρακτηριστικά

ρηγορότερες από τις μεθόδους που χρησιμοποιούνται στα δίκτυα πολλαπλών στοιβάδων (Multi-Layer Perception, MLP) (Dreyfus 1990).

2.2 Δομή του δικτύου

Όπως παρατηρήθηκε στο σχήμα προηγουμένως, τα δίκτυα RBF αποτελούνται από 3 στοιβάδες (layers):

- Την **στοιβάδα εισόδου (input layer)**, στην οποία τοποθετούνται τα δεδομένα εισόδου.
- Την **κρυφή στοιβάδα (hidden layer)**, που αποτελείται από τους κόμβους (nodes) του δικτύου και μέσω μίας μη γραμμικής διαδικασίας, μετασχηματίζει τα δεδομένα εισόδου.
- Την **στοιβάδα εξόδου (output layer)**, στην οποία καταλήγουν τα δεδομένα που προκύπτουν από την κρυφή στοιβάδα, αφού πρώτα πολλαπλασιαστούν με το κατάλληλο βάρος και αθροίζονται.



Σχήμα 2.1 Δομή δικτύου RBF

Γενικά η έξοδος ενός νευρωνικού δικτύου RBF μπορεί να εκφραστεί ως :

$$y_i(k) = \sum_{l=1}^L w_l f_l \left(\sqrt{\sum_{n=1}^N (x_n - \hat{x}_{l,n})^2} \right) \quad 2.1$$

όπου f είναι η συνάρτηση ακτινικής βάσης, \hat{x}_l είναι το κέντρο του l -στου στοιχείου, $w_l^T = [w_{m,1}, w_{m,2}, \dots, w_{m,L}]$ είναι ο παράγοντας των βαρών που πολλαπλασιάζουν την ενεργοποίηση του κρυφού κόμβου ώστε να προκύψει η έξοδος του δικτύου. Μια συνηθισμένη συνάρτηση που χρησιμοποιείται στα δίκτυα RBF είναι η συνάρτηση Gauss:

$$f(x) = \exp\left(\frac{-x^2}{\sigma^2}\right) \quad 2.2$$

όπου σ είναι το πλάτος του κόμβου.

2.3 Αλγόριθμοι Μάθησης

2.3.1 Γενικά

Ο τρόπος με τον οποίο εκπαιδεύεται το νευρωνικό δίκτυο όπως προαναφέρθηκε ονομάζεται αλγόριθμος μάθησης. Γενικά μπορούμε να χωρίσουμε τους αλγόριθμους μάθησης σε δύο βασικές κατηγορίες:

- **Στους αλγορίθμους μάθησης με επίβλεψη (supervised learning).** Σε αυτή την κατηγορία ο αλγόριθμος ελαχιστοποιεί το σφάλμα στον προσδιορισμό της εξόδου αλλάζοντας τις παραμέτρους του δικτύου (Fung et al. 1996).
- **Στους αλγορίθμους μάθησης χωρίς επίβλεψη (unsupervised learning)** Το δίκτυο αναδιοργανώνεται μόνο του χωρίς ανάδραση από τις εξόδους.

Γενικά μπορούμε να πούμε πως οι αλγόριθμοι περιγράφουν την διαδικασία που

χρησιμοποιούμε για να προσδιορίσουμε την μη γραμμική συνάρτηση που απαρτίζει το δίκτυο RBF και μετατρέπει τα δεδομένα εισόδου x_i σε δεδομένα $[f_1(x_i), f_2(x_i), \dots, f_L(x_i)]$ τα οποία είναι οι μετασχηματισμένες εισοδοί που θα διαμορφώσουν τις παραμέτρους του δικτύου, όπως είναι τα κέντρα και τα συναπτικά βάρη (Hinton 1989).

Οι αλγόριθμοι της πρώτης κατηγορίας είναι αρκετά χρονοβόροι επειδή βασίζονται στην διαδικασία δοκιμής – σφάλματος (trial-error), προκειμένου να αποφασίσουν για τον βέλτιστο αριθμό κόμβων (Houlomb and Morari 1991, Fritzke 1994, Zhu et al. 1999). Μια συνηθισμένη τεχνική μάθησης αυτής της κατηγορίας είναι η επιλογή των κέντρων των κόμβων χρησιμοποιώντας την μεθοδολογία κ-μέσων (k-means) (MacQueen 1967, Moody and Darken 1989, Darken and Moody 1990). Στη συνέχεια ο αλγόριθμος υπολογίζει τις υπόλοιπες παραμέτρους του δικτύου με τη μέθοδο της γραμμικής παλινδρόμησης (Powell 1987, Leonard and Kramer 1991).

Η δεύτερη κατηγορία αλγορίθμων καθορίζει και την δομή του δικτύου αλλά και τις παραμέτρους του (Musavi et al. 1992, Billings 1995). Μια τέτοια μέθοδος είναι ο αλγόριθμος ορθογωνίων ελαχίστων τετραγώνων (Chen et al. 1990). Ένα μεγάλο μειονέκτημα αυτής της διαδικασίας είναι πως απαιτείται αρκετά μεγάλος υπολογιστικός χρόνος για να πραγματοποιηθεί.

2.3.2 Ο Αλγόριθμος κ-μέσων (k-means)

Ο αλγόριθμος *k-means* είναι ένας από τους πιο διαδεδομένους αλγόριθμους που πραγματοποιούν ομαδοποίηση των δεδομένων βάσει των χαρακτηριστικών τους. Ο αλγόριθμος υποθέτει ότι τα χαρακτηριστικά αυτά δημιουργούν ένα χώρο διανυσμάτων και προσπαθεί να τοποθετήσει κάποια κέντρα ώστε να κατηγοριοποιηθούν όσο το δυνατό καλύτερα γίνεται τα δεδομένα στις ομάδες που σχηματίζουν αυτά τα κέντρα.


Η λειτουργία του μπορεί να περιγραφεί σε δύο στάδια. Στην αρχή λαμβάνει σαν είσοδο k δεδομένα και έναν ακέραιο αριθμό $N (N \subseteq k)$ και διαμερίζει το αρχικό σύνολο των δεδομένων εισόδου, όπως φαίνεται στο σχήμα 2.2, σε N ομάδες με τέτοιο τρόπο ώστε να μεγιστοποιηθεί η ομοιότητα των δεδομένων μιας ομάδας μεταξύ τους άλλα ταυτόχρονα να ελαχιστοποιηθεί η ομοιότητα μεταξύ των ομάδων. Η διαδικασία αυτή μπορεί να εκφραστεί με την συνάρτηση τετραγωνικού σφάλματος:

$$A = \sum_{k=1}^N \sum_{k_l \in C_i} q(k_l, k_{m_j}) \quad 2.3$$


όπου k είναι το σημείο στο χώρο που αντιπροσωπεύει ένα δεδομένο, k_{m_j} το μέσο της ομάδας C_i και η συνάρτηση q είναι η τετραγωνική Ευκλείδεια απόσταση :

$$q(x, y) = \|x - y\|^2 \quad 2.4$$

Στην περίπτωση που τα δεδομένα εισόδου είναι περισσότερων διαστάσεων ο τύπος προσαρμόζεται αναλόγως. Επομένως το κέντρο κάθε ομάδας αρχικοποιείται πάνω σε ένα τυχαίο δεδομένο εισόδου (Σχήμα 2.3).




Σχήμα 2.2 Τα σημεία μπορούν να χωριστούν σε δύο ομάδες εκφραζόμενες από δύο κέντρα ανάλογα με τη θέση τους στο επίπεδο.



Σχήμα 2.3 Τα δύο κέντρα τοποθετούνται αρχικά σε δύο τυχαία δεδομένα, ανάλογα με την ομάδα.

Στην συνέχεια κάθε νέο δεδομένο εισόδου που χρησιμοποιείται για τη διαδικασία της μάθησης, ανατίθεται στο πιο κοντινό κέντρο, το οποίο επιλέγεται υπολογίζοντας την απόστασή του από όλα τα κέντρα. Η διαδικασία αυτή επαναλαμβάνεται έως ότου επιτευχθεί σύγκλιση, ελαχιστοποιώντας τη με το κριτήριο του τετραγωνικού σφάλματος όπως φαίνεται στο σχήμα 2.4.



Σχήμα 2.4 Τα κέντρα έχουν καθοριστεί ώστε να ελαχιστοποιηθεί η απόστασή τους από όλα τα κέντρα της ομάδας

Αφού καθοριστούν τα κέντρα υπολογίζεται η ενεργοποίηση του κάθε κέντρου σε κάθε δεδομένο χρησιμοποιώντας τον ευρεστικό (heuristic) αλγόριθμο P-nearest neighbor:

$$\sigma_i = \left(\frac{1}{P} \sum_{j=1}^P \|\hat{x}_i - \hat{x}_j\|^2 \right)^{1/2} \quad 2.5$$

όπου \hat{x}_j είναι τα P κοντινότερα κέντρα στο \hat{x}_i .

Τέλος, υπολογίζονται τα βάρη των κόμβων με την μέθοδο της γραμμικής παλινδρόμησης ελαχίστων τετραγώνων (Geladi and Kowalski 1986).

Όπως μπορεί κανείς να παρατηρήσει, ο προηγούμενος αλγόριθμος, παρότι είναι προγραμματιστικά απλός, έχει κάποια σοβαρά μειονεκτήματα. Προκειμένου να πραγματοποιηθούν αρκετές επαναλήψεις του αλγορίθμου, ώστε να συγκλίνει στον καθορισμό των σημείων των κέντρων, απαιτείται μεγάλη υπολογιστική ισχύς και αρκετός χρόνος. Επίσης επειδή τα κέντρα τοποθετούνται στην αρχή σε τυχαία σημεία, κάθε φορά που εκπαιδεύεται το δίκτυο από την αρχή, θα υλοποιείται και διαφορετικό νευρωνικό δίκτυο. Για τον λόγο αυτό στην πτυχιακή αυτή εργασία χρησιμοποιήθηκε ένας διαφορετικός αλγόριθμος, ο οποίος δεν παρουσιάζει αυτά τα προβλήματα και ταυτόχρονα είναι πιο αξιόπιστος.

Σε αυτή τη μέθοδο που ονομάζεται αλγόριθμος ασαφών μέσων (Sarimveis et al. 2002, Alexandridis et al. 2003), χρησιμοποιείται η ασαφής διαμέριση του χώρου των μεταβλητών εισόδου (fuzzy partition), με βάση την οποία χωρίζουμε το κάθε διάνυσμα εισόδου σε τομείς. Έτσι η δομή του νευρωνικού δικτύου καθώς και τα κέντρα που το απαρτίζουν, υπολογίζονται μία μόνο φορά και μάλιστα κάθε φορά που χρησιμοποιείται ο αλγόριθμος, η δομή, τα κέντρα και οι παράμετροι του δικτύου παραμένουν αμετάβλητα, επειδή ο αλγόριθμος δεν εξαρτάται από μια τυχαία επιλογή των αρχικών κέντρων, αλλά υλοποιεί το δίκτυο με βάση την διασπορά των δεδομένων.

2.4 Η Ασαφής Λογική

2.4.1 Γενικά

Την ιδέα της ασαφούς λογικής (Fuzzy Logic) συνέλαβε ο Lofti Zadeh, καθηγητής του Πανεπιστημίου της Καλιφόρνια. Αρχικά παρουσιάστηκε ως ένας τρόπος επεξεργασίας δεδομένων επιτρέποντας τη μερική συμμετοχή των δεδομένων σε αντίθεση με τη μέχρι πρότινος ολική ή μη συμμετοχή αυτών. Αυτή η προσέγγιση στη θεωρία των δεδομένων δεν εφαρμόστηκε για τον έλεγχο συστημάτων μέχρι τη δεκαετία του 70 λόγω ανεπαρκούς υπολογιστικής ικανότητας μέχρι εκείνη την εποχή. Ο καθηγητής Zadeh βασίστηκε στο γεγονός ότι οι άνθρωποι μπορούν και πραγματοποιούν διαδικασίες προσαρμοστικού ελέγχου καθημερινά, χωρίς την ανάγκη να έχουν ακριβή, αριθμητική εισροή πληροφοριών. Επομένως υποστήριξε πως εάν οι ελεγκτές ανατροφοδότησης που χρησιμοποιούνται στην βιομηχανία, μπορούσαν να προγραμματιστούν για να δέχονται θορυβώδεις, ανακριβείς (ασαφείς) εισροές, τότε θα ήταν πολύ πιο αποτελεσματικοί και πιθανόν πιο εύκολο να καθιερωθούν. Οι Αμερικάνοι κατασκευαστές άργησαν να εναρμονιστούν με αυτήν την τεχνολογία ενώ οι Ευρωπαίοι και οι Ιάπωνες ανέπτυξαν προϊόντα με ραγδαίους ρυθμούς γύρω από αυτήν (Ross 2004).

Η ασαφής λογική είναι μια μεθοδολογία επίλυσης προβλημάτων ελέγχου που προσφέρεται για εφαρμογή σε πληθώρα συστημάτων. Μπορεί να υλοποιηθεί με εξαρτήματα (hardware), λογισμικά αλλά και με συνδυασμό των δύο. Η ασαφής λογική παρέχει έναν απλό τρόπο για να οδηγηθεί σε οριστικό συμπέρασμα με βάση αόριστα, ασαφή και ανακριβή, επηρεασμένα από θόρυβο ή ελλιπή στοιχεία εισροών. Η ασαφής λογική μιμείται το τρόπο λήψης αποφάσεων του ανθρώπου για τον έλεγχο προβλημάτων με την διαφορά ότι το κάνει πιο γρήγορα.

Η μεγάλη διαφορά στην λειτουργία της ασαφούς λογικής σε αντίθεση με άλλες μεθόδους επίλυσης προβλημάτων είναι πως υιοθετεί έναν κανόνα εμπειρικό για να εξάγει συμπεράσματα, ενώ οι άλλες μέθοδοι προσπαθούν να μοντελοποιήσουν ένα σύστημα με μαθηματικούς τρόπους. Για παράδειγμα σε ένα σύστημα όπου θέλουμε να ρυθμίζουμε τη θερμοκρασία, οι κλασικές μέθοδοι θα υπολόγιζαν την μεταβολή λαμβάνοντας υπόψη πως η τιμή της θερμοκρασίας τώρα είναι π.χ. 10°C , ενώ ένα μοντέλο ασαφούς λογικής θα καταλάβαινε πως η θερμοκρασία τώρα είναι ψυχρή και γίνεται ακόμα πιο ψυχρή, άρα θα

ανεβάσει τη θερμοκρασία για να ζεσταθεί. Αυτοί οι όροι «ψύχος», «ζέστη» είναι μη ακριβείς και όμως περιγράφουν την κατάσταση του προβλήματος και μέσω αυτών δίνεται λύση. Το προηγούμενο παράδειγμα το εφαρμόζει ο άνθρωπος καθημερινά όταν έρθει σε επαφή με το νερό και είναι κρύο, χρησιμοποιώντας μια τέτοιου είδους λογική καταφέρνει να φέρει το νερό στην επιθυμητή θερμοκρασία. Η ασαφής λογική είναι ικανή να μιμηθεί τέτοιου είδους συμπεριφορές.

2.4.2 Ασαφής Διαμέριση του χώρου των μεταβλητών εισόδου

Η θεωρία της ασαφούς λογικής περιγράφει συστήματα που χαρακτηρίζονται από μεγάλη αβεβαιότητα. Στην μεθοδολογία που ακολουθήθηκε, διαμερίστηκαν τα δεδομένα εισόδου σε ασαφή σύνολα, τα οποία είχαν ίδιο μέγεθος, για προγραμματιστική ευκολία και εξοικονόμηση υπολογιστικού χρόνου.

Τα δεδομένα εισόδου για κάθε μεταβλητή x_i χωρίζονται σε αντίστοιχο αριθμό C_i τριγωνικών ασαφών συνόλων, $A_i^1, A_i^2, \dots, A_i^{C_i}$ με την ακόλουθη συνάρτηση συμμετοχής :

$$\mu_A(x) = \begin{cases} 1 - \frac{|x-a|}{\delta a}, & \text{εάν } x \in [a - \delta a, a + \delta a] \\ 0 & \text{για τις υπόλοιπες τιμές} \end{cases} \quad 2.6$$

όπου a είναι το κεντρικό στοιχείο το οποίο έχει τη μέγιστη συμμετοχή και στο οποίο τοποθετείται το δεδομένο, και δa είναι το μισό από το πλάτος του τριγώνου. Το πλάτος αυτό επιλέγεται ώστε οι δύο πλευρές των τριγώνων που γειτνιάζουν με το επιλεγμένο τρίγωνο να τέμνονται στη μέση από την πλευρά του τριγώνου αυτού. Επομένως το ασαφές σύνολο A μπορεί να περιγραφεί πλήρως από το αντίστοιχο κέντρο και πλάτος του τριγώνου που το απαρτίζει :

$$A = \{a, \delta a\} \quad 2.7$$

Εάν ορίσουμε τον ασαφή χώρο κάθε μεταβλητής εισόδου ως :

$$T_i = \{A_i^1, A_i^2, \dots, A_i^{C_i}\}, \quad 1 \leq i \leq N \quad 2.8$$

τότε μπορούμε να ορίσουμε το σύνολο των ασαφών υποχώρων όλων των δεδομένων μιας μεταβλητής X με τους επιμέρους υπόχωρους A^1, A^2, \dots, A^C ως:

$$C = \prod_{i=1}^N C_i, \quad (1 \leq l \leq C) \quad 2.9$$

Ο l -ιστός ασαφής υπόχωρος A^l ($1 \leq l \leq C$) αποτελείται από τον συνδυασμό N επιμέρους ασαφών συνόλων $A_1^l \in T_1, A_2^l \in T_2, \dots, A_N^l \in T_N$ και μπορεί να διατυπωθεί ως:


$$A_1^l \in T_1, A_2^l \in T_2, \dots, A_N^l \in T_N \quad 2.10$$

Το Σχήμα 2.5 απεικονίζει έναν ασαφή χώρο ενός δισδιάστατου χώρου εισόδου, όπου και οι δύο μεταβλητές χωρίζονται σε 5 τριγωνικά ασαφή σύνολα. Έτσι ορίζονται 25 ασαφή υποσύνολα για τα δεδομένα εισόδου.

Στο σχήμα 2.5 ορίζεται ο ασαφής υπόχωρος $A = [A_1^3, A_2^3]$. Αν καθορίσουμε τους παράγοντες $a^l = [a_1^l, a_2^l, \dots, a_N^l]^T$, $\delta a = [\delta a_1, \delta a_2, \dots, \delta a_N]^T$ τότε ο υπόχωρος A^l στην σχέση 2.10 χρησιμοποιώντας την σχέση 2.7 μπορεί να γραφεί ως

$$A^l = \{a^l, \delta a\} \quad 2.11$$

Η παραπάνω σχέση δείχνει πως το A^l είναι ένα υπέρ-ορθογώνιο μέσα στον χώρο που ορίζουν οι μεταβλητές εισόδου, όπου ο παράγοντας a^l είναι ο κεντρικό σημείο και ο παράγοντας δa είναι η πλευρά του.



Σχήμα 2.5 Ορισμός ενός ασαφούς χώρου σε ένα δισδιάστατο χώρο εισόδου

2.5 Η Ασαφής Λογική στην δημιουργία νευρωνικού δικτύου RBF

Η προηγούμενη λογική της διαμέρισης του χώρου που δημιουργούν οι μεταβλητές εισόδου, σε ασαφείς υπόχωρους, μπορεί να χρησιμοποιηθεί για την κατασκευή ενός νευρωνικού δικτύου RBF. Ο προσδιορισμός των κέντρων του δικτύου επομένως είναι εύκολος, αρκεί να διαμερίσουμε τον χώρο που ορίζουν τα δεδομένα σε ασαφείς υπόχωρους (fuzzy subspaces), οι οποίοι καλύπτουν τα δεδομένα ομοιόμορφα. Αυτό πραγματοποιείται με την συνάρτηση συμμετοχής $\mu_{A^i}(x(k))$ (Nie 1997) ενός δεδομένου εισόδου $x(k)$ στο A^i και ορίζεται ως:

$$\mu_{A^i}(x(k)) = \begin{cases} 1 - rd^i(x(k)), & \text{εάν } rd^i(x(k)) \leq 1 \\ 0 & \text{για τις υπόλοιπες τιμές} \end{cases} \quad 2.12$$

όπου $rd^l(\mathbf{x}(k))$ είναι η Ευκλείδεια σχετική απόσταση μεταξύ του A^l και του δεδομένου εισόδου

$$rd^l(\mathbf{x}(k)) = \frac{\left[\sum_{i=1}^N (a_i^l - x_i(k))^2 \right]^{1/2}}{\left[\sum_{i=1}^N (\delta a_i)^2 \right]^{1/2}} \quad 2.13$$


Επομένως εύκολα καταλήγουμε στο συμπέρασμα πως ο ασαφής υπόχωρος που περιγράφει καλύτερα ένα δεδομένο εισόδου είναι αυτός με την μικρότερη Ευκλείδεια σχετική απόσταση, εφόσον αυτός ο υπόχωρος παρουσιάζει την μεγαλύτερη τιμή για την συνάρτηση συμμετοχής. Ο αλγόριθμος που περιγράφει την διαδικασία επιλογής κέντρων και συναπτικών βαρών είναι πλέον εύκολο να πραγματοποιηθεί με την ακόλουθη διαδικασία:

Ας θεωρήσουμε ότι έχουμε στη διάθεση μας δεδομένα εισόδου $\mathbf{x}(k)$, όπου $\mathbf{x}(k) \in R^N$, τότε με μια διεργασία το σύνολο τιμών κάθε μεταβλητής χωρίζεται σε τριγωνικά ασαφή σύνολα. Πιο συγκεκριμένα έστω ότι διαθέτουμε δεδομένα εισόδου 2 μεταβλητών, τότε μπορούν να αναπαρασταθούν στο επίπεδο όπως στα σχήματα 2.6 και 2.7. Στο παράδειγμα αυτό για 2 δεδομένα x_1, x_2 τα ασαφή σύνολα είναι :


$$T_1 = \{A_1^1, A_1^2, A_1^3, A_1^4, A_1^5, A_1^6\} \quad 2.14$$

$$T_2 = \{A_2^1, A_2^2, A_2^3, A_2^4, A_2^5, A_2^6\} \quad 2.15$$

Τα δεδομένα x_1, x_2 απεικονίζονται στους άξονές τους μέσω των τριγωνικών ασαφών συνόλων.



Σχήμα 2.6 Τα τριγωνικά σύνολα που ενεργοποιούνται από το x_1



Σχήμα 2.7 Τα τριγωνικά σύνολα που ενεργοποιούνται από το x_2

Στην αρχή καθορίζουμε μέσω των ασαφών συνόλων την συνάρτηση συμμετοχής $\mu(x)$. Το δεδομένο x_1 ενεργοποιεί το A_1^2 κατά 0.7 και το A_1^3 κατά 0.3 ενώ τα υπόλοιπα καθόλου. Το δεδομένο x_2 ενεργοποιεί το A_2^1 κατά 0.75 και το A_2^2 κατά 0.25.

Στη συνέχεια αναθέτουμε τα δεδομένα x_1, x_2 στα ασαφή σύνολα με τον μέγιστο βαθμό συμμετοχής. Δηλαδή το x_1 ανατίθεται στο A_1^2 και το x_2 στο A_2^1 . Το ίδιο συμβαίνει και με τα υπόλοιπα δεδομένα εισόδου.

Για κάθε δεδομένο $x(k)$ (που αναλύεται σε $x_1(k)$ και $x_2(k)$) ο κοντινότερος ασαφής υπόχωρος A^{j0} είναι ο συνδυασμός των ασαφών συνόλων που επιλέχθηκαν στο

προηγούμενο βήμα . Δηλαδή

$$A^{j0} = [A_1^2, A_2^1] = \{[a_1^2, a_2^1], [\delta a_1, \delta a_2]\} \quad 2.16$$

Το κέντρο του ασαφούς υπόχωρου, γίνεται κέντρο του νευρωνικού δικτύου και περιγράφει το συγκεκριμένο δεδομένο. Επομένως σε ένα δισδιάστατο διάνυσμα εισόδου που είναι χωρισμένο σε 5 τριγωνικά σύνολα ανά διάσταση, δημιουργούνται 25 ασαφείς υπόχωροι και επομένως 25 πιθανά κέντρα για το νευρωνικό δίκτυο. Στον αλγόριθμο μάθησης το πρώτο δεδομένο εισόδου ανατίθεται σε ένα κέντρο με την παραπάνω διαδικασία. Για τα επόμενα δεδομένα, καθώς εισέρχονται διαδοχικά στο δίκτυο, υπολογίζεται η Ευκλείδεια απόστασή τους από τα ήδη υπάρχοντα κέντρα ώστε να βρεθεί η ελάχιστη από αυτές για το κάθε δεδομένο. Στη συνέχεια γίνεται έλεγχος γι' αυτή την ελάχιστη Ευκλείδεια απόσταση κάθε δεδομένου προκειμένου να βρεθεί σε ποια από τις δύο κατηγορίες του κριτηρίου της σχέσης 2.12 ανήκει. Αν η συνάρτηση συμμετοχής είναι 0 τότε δημιουργείται ένα νέο κέντρο με την διαδικασία που περιγράφηκε προηγουμένως. Με την διαδικασία αυτή έχουν δημιουργηθεί όλα τα κέντρα της κρυφής στοιβάδας του RBF δικτύου.

Στη συνέχεια χρησιμοποιώντας τον ευρεστικό αλγόριθμο P-nearest neighbors (Σχέση 2.5) υπολογίζεται η διακύμανση του κάθε κέντρου και έπειτα με την γκαουσιανή συνάρτηση της σχέσης 2.2 υπολογίζεται η ενεργοποίηση του κάθε κέντρου για το κάθε δεδομένο εισόδου. Τέλος τα συναπτικά βάρη των κέντρων του δικτύου RBF υπολογίζονται μέσω της μεθόδου των ελαχίστων τετραγώνων

Αυτός ο αλγόριθμος αυξάνει σημαντικά την ταχύτητα εκπαίδευσης του νευρωνικού δικτύου επειδή χρησιμοποιείται μόνο μια φορά, ενώ οι συμβατικοί αλγόριθμοι απαιτούν πολλαπλά περάσματα ώστε να συγκλίνουν στο επιθυμητό αποτέλεσμα.

ΚΕΦΑΛΑΙΟ 3ο

ΜΗ ΓΡΑΜΜΙΚΟΣ DC ΚΙΝΗΤΗΡΑΣ

3.1 Γενικά για τους Ηλεκτροκινητήρες


Οι ηλεκτρικοί κινητήρες αποτελούν μια κατηγορία των στρεφόμενων ηλεκτρικών μηχανών. Το βασικό στοιχείο μιας στρεφόμενης ηλεκτρικής μηχανής είναι η μετατροπή ενέργειας από ηλεκτρική σε μηχανική μορφή και αντίστροφα. Υπάρχουν τρεις τρόποι λειτουργίας των ηλεκτρικών μηχανών: η λειτουργία τους σαν κινητήρες, σαν γεννήτριες και σαν πέδες. Σε μια γεννήτρια συνεχούς ρεύματος η μηχανική ενέργεια μετατρέπεται σε ηλεκτρική και αυτό εκφράζεται με την παραγωγή ηλεκτρικού ρεύματος, ενώ στους κινητήρες το ηλεκτρικό ρεύμα μετατρέπεται σε μηχανική ενέργεια.

Η αρχή λειτουργίας ενός ηλεκτρικού κινητήρα βασίζεται στη δύναμη Lorentz. Όταν ένας αγωγός, ο οποίος διαρρέεται από ηλεκτρικό ρεύμα, βρεθεί μέσα σε ένα μαγνητικό πεδίο ασκείται πάνω του μία δύναμη που είναι ίση με:

$$F = BIl$$

3.1

όπου B είναι η ένταση του μαγνητικού πεδίου, I η ένταση του ρεύματος και l το μήκος του αγωγού. Στο παρακάτω σχήμα φαίνεται διανυσματικά η δύναμη Lorentz.



Σχήμα 3.1 Διανυσματική αναπαράσταση της δύναμης Lorentz σε έναν αγωγό.

Οι κινητήρες συνεχούς ρεύματος (Direct Current Motors, DC) είναι οι πιο διαδεδομένοι. Παλαιότερα η πλειοψηφία των κινητήρων που χρησιμοποιούνταν σε διαδικασίες ελέγχου ήταν εναλλασσομένου ρεύματος (Alternate Current, AC). Στην πραγματικότητα, οι AC κινητήρες παρουσιάζουν μεγαλύτερη δυσκολία στον έλεγχο, ιδιαίτερα στην περίπτωση του ελέγχου θέσης. Επειδή τα χαρακτηριστικά τους είναι μη γραμμικά, η ανάλυση τους γίνεται αρκετά πιο δύσκολη. Από την άλλη μεριά οι DC κινητήρες έχουν μεγαλύτερο κόστος, λόγω των ψηκτρών και των συλλεκτών. Η ανάπτυξη των ηλεκτρονικών ισχύος έκανε τις DC μηχανές δίχως ψήκτρα να κερδίζουν συνεχώς έδαφος στη χρήση τους για συστήματα ελέγχου υψηλής απόδοσης. Με τη χρήση προηγμένων τεχνικών παρασκευής καταφέραμε να παράγουμε DC κινητήρες με ρότορες που δεν αποτελούνταν από σίδηρο, μειώνοντας έτσι την αδράνεια και αυξάνοντας την ροπή τους, καθώς και την βελτίωση της σταθεράς χρόνου (Kuo and Golnarachi 2010). Όλα αυτά άνοιξαν δρόμους για νέες εφαρμογές των DC κινητήρων σε περιφερειακά Η/Υ, όπως εκτυπωτές, οδηγούς δισκετών και κασετών, καθώς και στην αυτοματοποίηση και στις εργαλειομηχανές στη βιομηχανία.

3.2 AC Κινητήρες

Οι κινητήρες εναλλασσόμενου ρεύματος διακρίνονται σε μονοφασικούς και πολυφασικούς. Τόσο οι μονοφασικοί όσο και οι πολυφασικοί κινητήρες διακρίνονται σε σύγχρονους κινητήρες και σε κινητήρες επαγωγής ή ασύγχρονους. Ένας σύγχρονος κινητήρας αποτελείται από μια σειρά τριών τυλιγμάτων στο στάτορα με ένα απλό στρεφόμενο μέρος. Καθώς το ρεύμα που περνάει από το πηνίο μεταβάλλεται ο κινητήρας εργάζεται ομαλά μόνο στη συχνότητα του ημιτονοειδούς ρεύματος επιτυγχάνοντας μια λειτουργία με σταθερή ταχύτητα από μηδενικό ως πλήρες φορτίο λειτουργίας. Στους ασύγχρονους κινητήρες το ηλεκτρικό ρεύμα χρησιμεύει κυρίως για να επάγει την περιστροφή των τυλιγμάτων παρά για να περιστρέφει ευθέως τον άξονα. Οι πολυφασικοί κινητήρες εναλλασσόμενου ρεύματος είναι κατά βάση μηχανές σταθερής ταχύτητας, αλλά διαφοροποιούνται ως προς κάποια σχεδιαστικά στοιχεία τους.

3.3 Βασικές αρχές λειτουργίας των DC κινητήρων

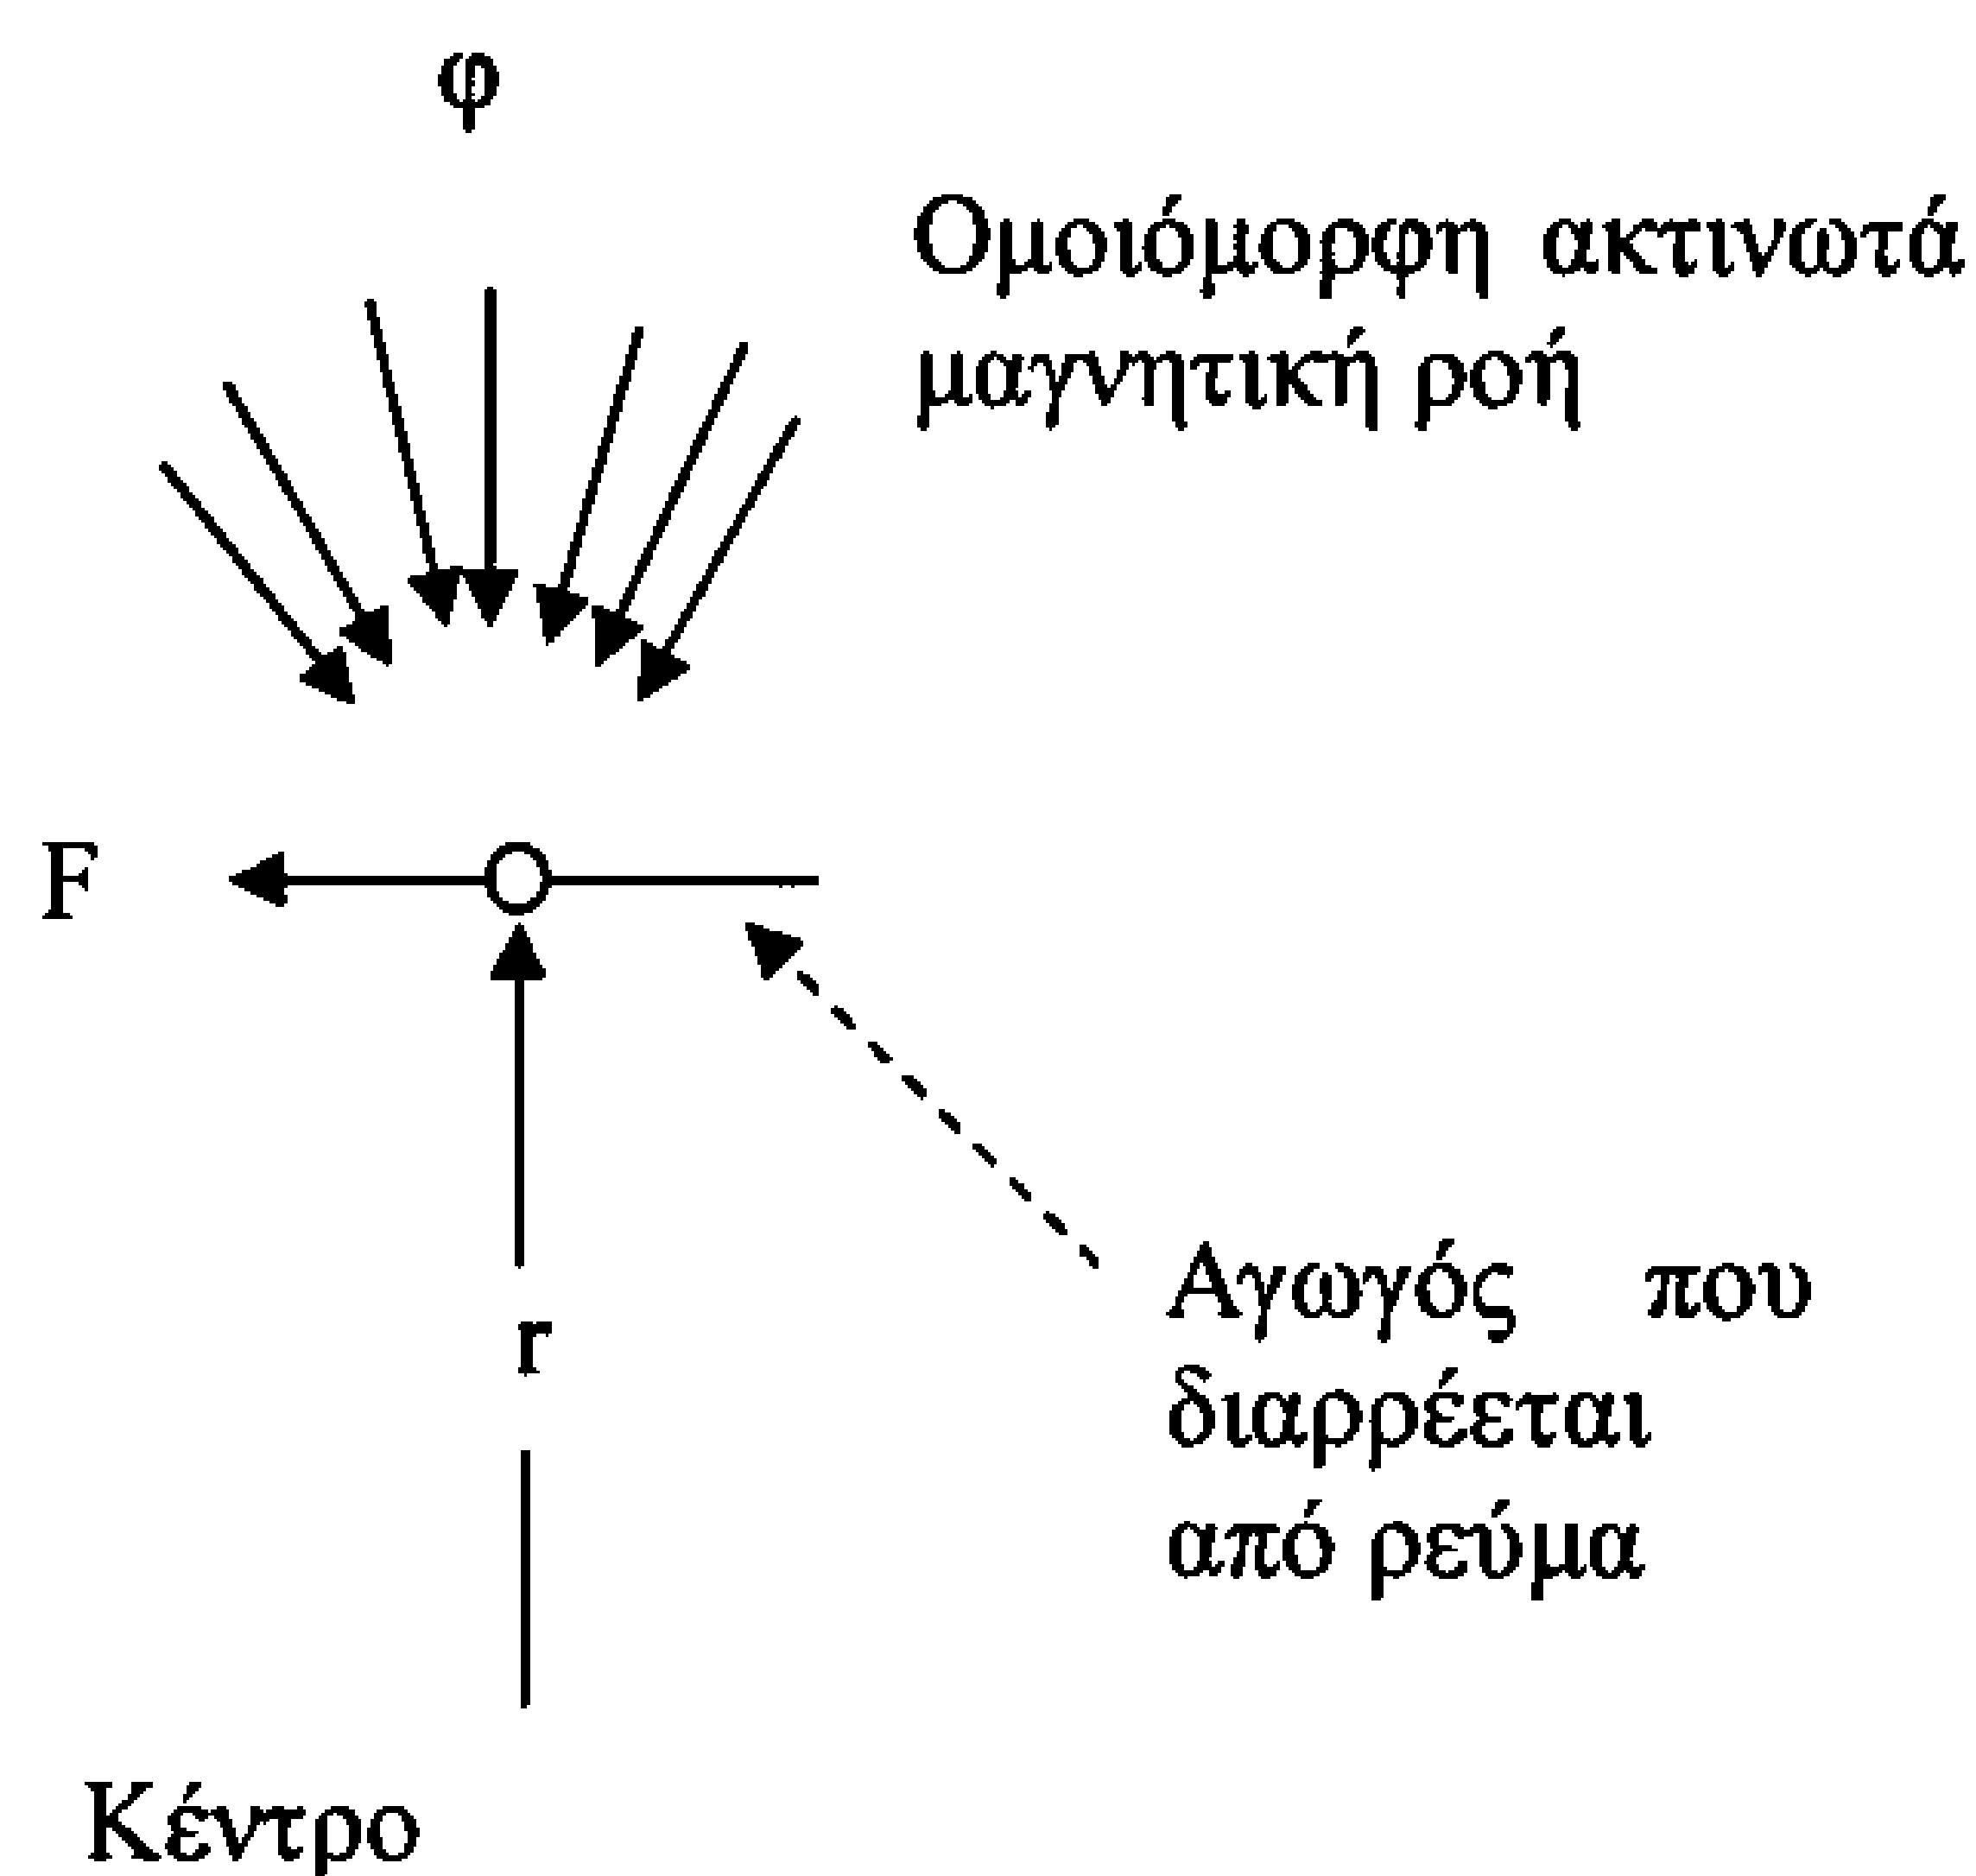
Ο DC κινητήρας είναι ένας μετατροπέας ροπής, που μετατρέπει την ηλεκτρική ενέργεια σε περιστροφική, ή πιο απλά σε μηχανική ενέργεια. Η ροπή που αναπτύσσεται στο στέλεχος (άξονα) του κινητήρα είναι ευθέως ανάλογη προς τη ροή του πεδίου και το ρεύμα οπλισμού (Bishop 1997). Όπως φαίνεται στο σχήμα 3.2 ένας αγωγός που μεταφέρει ρεύμα εγκαθίσταται σ' ένα μαγνητικό πεδίο με ροή ϕ και ο αγωγός βρίσκεται σε απόσταση r από το κέντρο περιστροφής.

Η σχέση μεταξύ της ροπής T_m , της ροής ϕ και του ρεύματος i_a είναι:

$$T_m = K_m \phi i_a \quad 3.2$$

όπου T_m (Nm) είναι η ροπή του κινητήρα, ϕ (Weber) η μαγνητική ροή μεταξύ του στάτορα και του ρότορα, i_a (A) το ρεύμα του ρότορα και K_m μια σταθερά.

Επιπρόσθετα στη ροπή που αναπτύσσεται σύμφωνα με το σχήμα 3.2, όταν ο αγωγός κινείται μέσα στο μαγνητικό πεδίο μια τάση παράγεται στα άκρα του. Αυτή η τάση, ονομάζεται αντιηλεκτρεγερτική δύναμη (ΑΗΕΔ), είναι ανάλογη με την ταχύτητα του άξονα (shaft) και τείνει να αντισταχθεί στη ροή του ρεύματος. Η σχέση ανάμεσα στην




Σχήμα 3.2: Παραγωγή ροπής σε dc κινητήρα

ΑΗΕΔ και την ταχύτητα του άξονα είναι :

$$e_b = K_m \phi \omega_m$$

3.3

όπου e_b (Volts) υποδηλώνει την ΑΗΕΔ και ω_m (rad/sec) την γωνιακή ταχύτητα του άξονα. Οι εξισώσεις 3.2 και 3.3 αποτελούν τη βάση της λειτουργίας του DC κινητήρα. Στο παρακάτω σχήμα φαίνεται ο τρόπος με τον οποίο πραγματοποιείται η περιστροφή σε έναν κινητήρα, όπου B είναι η ένταση του μαγνητικού πεδίου, I η ένταση του ρεύματος και F η δύναμη που ασκείται στον αγωγό που διαρρέεται από ρεύμα.



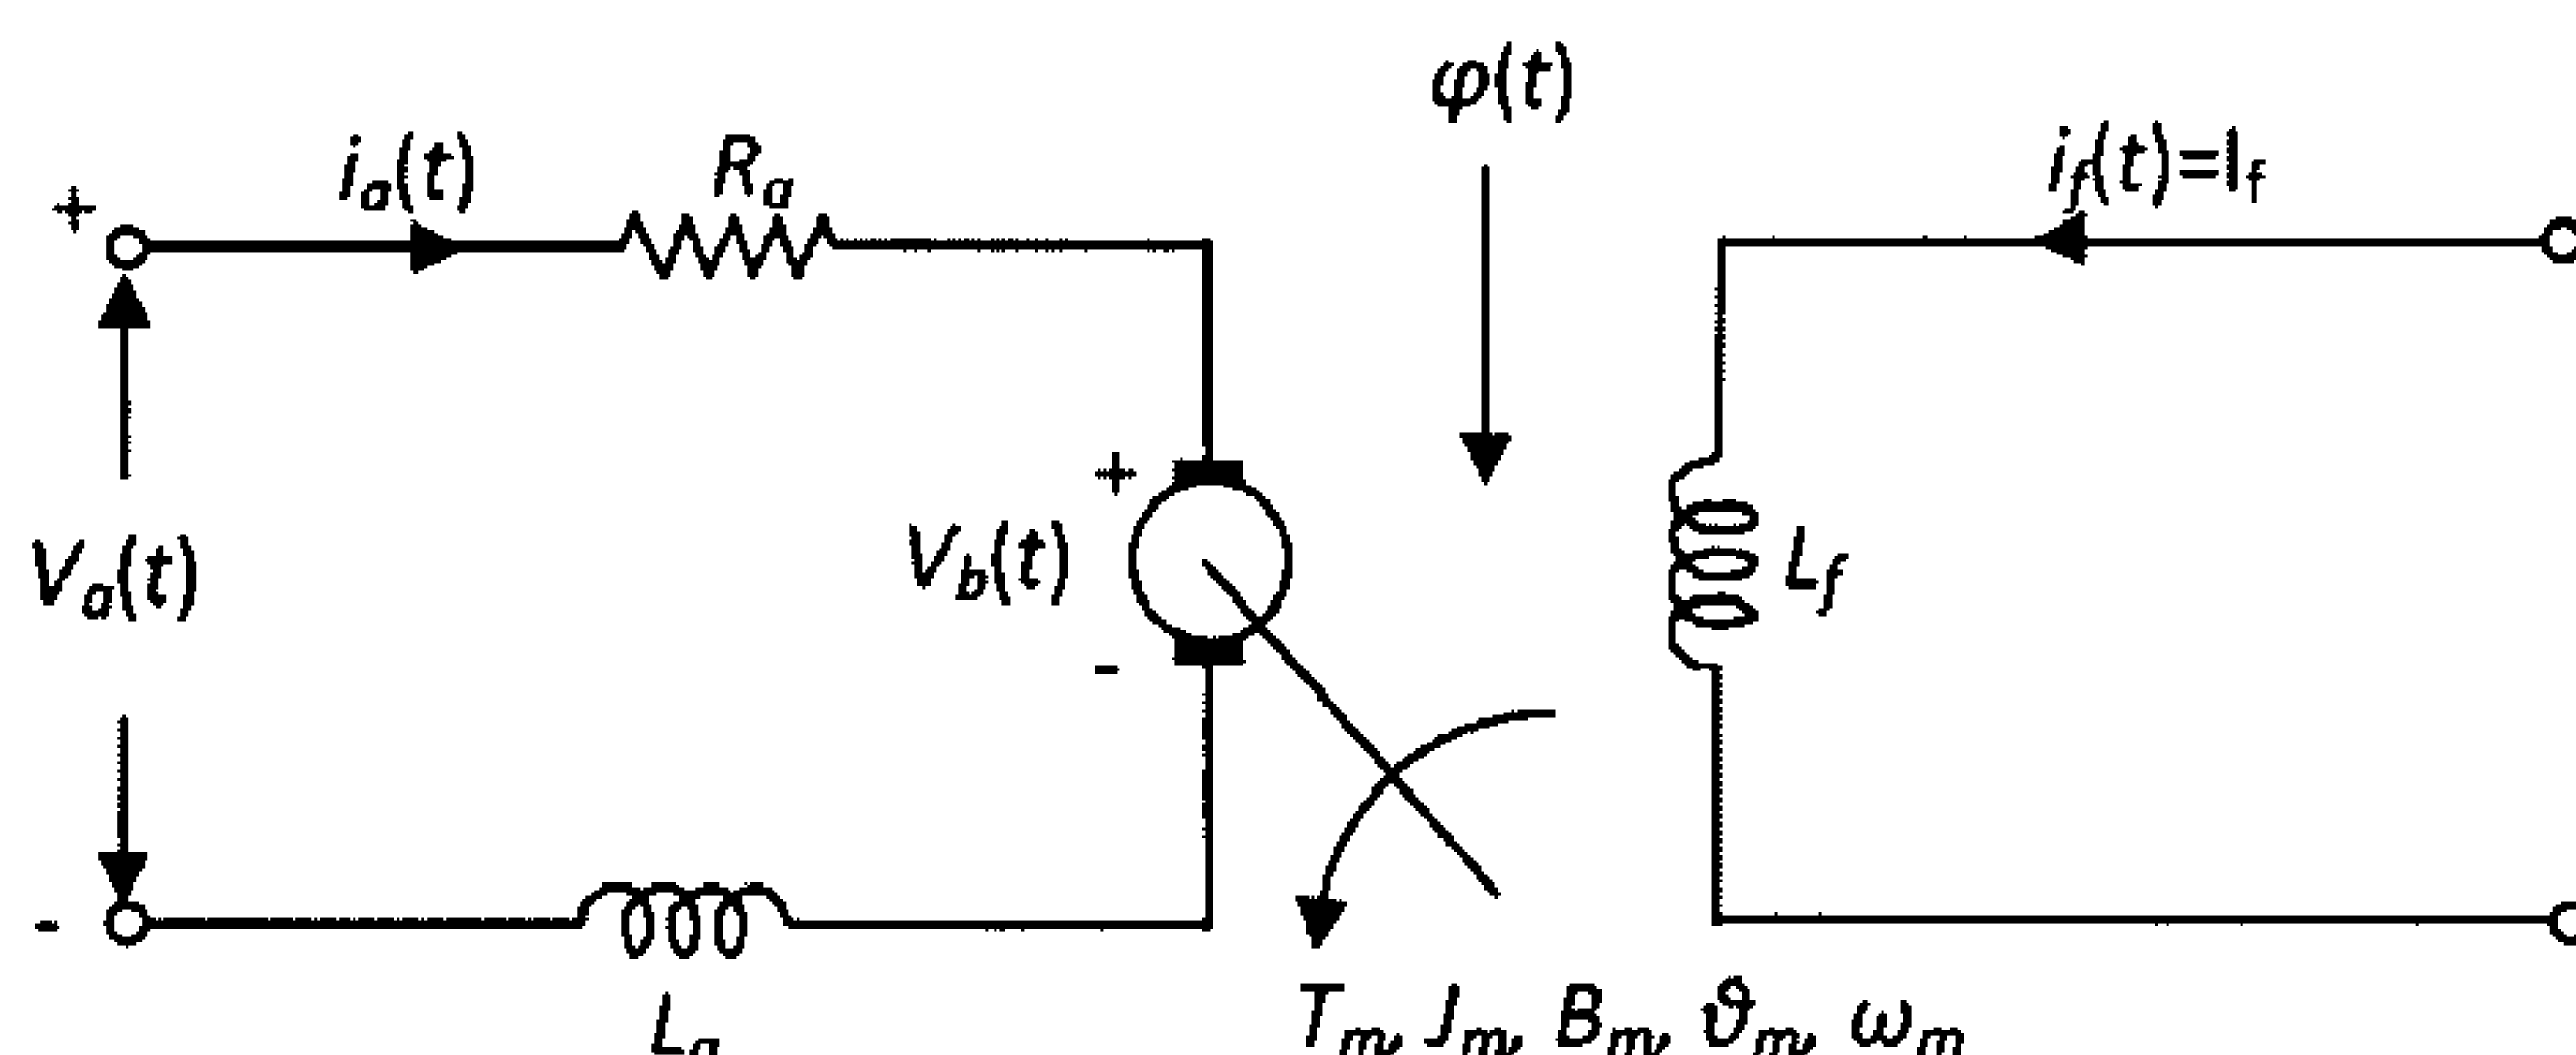
Σχήμα 3.3 Περιστροφή του ρότορα του κινητήρα

3.4 Μαθηματική μοντελοποίηση των DC κινητήρων

3.4.1 Κινητήρες που ελέγχονται από το ρότορα

Τα συστήματα ελέγχου έχουν ευρεία εφαρμογή στους DC κινητήρες. Σε αυτή την παράγραφο αναλύεται το μαθηματικό μοντέλο ενός DC κινητήρα χρησιμοποιώντας γραμμική προσέγγιση (Παρασκευόπουλος 2001). Στο σχήμα 3.4 φαίνεται σχηματικά ένας DC κινητήρας.

Ο ρότορας απεικονίζεται ως ένα κύκλωμα με αντίσταση R_a συνδεδεμένο σε σειρά με μια αυτεπαγωγή (πηνίο) L_a και μια πηγή τάσης V_b που αντιπροσωπεύει την αντιηλεκτρεγερτική δύναμη e_b (ΑΗΕΔ) στον οπλισμό όταν αυτός περιστρέφεται. Στον πίνακα 3.1 δίνονται οι μεταβλητές που χρησιμοποιούνται :



Σχήμα 3.4: Μοντέλο κινητήρα ελεγχόμενου από τον ρότορα

Συμβολισμός	Επεξήγηση	Συμβολισμός	Επεξήγηση
$i_a(t)$	Ρεύμα οπλισμού	L_a	Επαγωγή οπλισμού
R_a	Αντίσταση οπλισμού	$V_a(t)$	Εφαρμοζόμενη τάση
$V_b(t)$	Πηγή Τάσης	K_b	ΑΗΕΔ σταθερά
$T_L(t)$	Ροπή φορτίου	Φ	Μαγνητική ροή σε κενό αέρα
$T_m(t)$	Ροπή κινητήρα	$\omega_m(t)$	Γωνιακή ταχύτητα κινητήρα
$\theta_m(t)$	Γωνιακή θέση	J_m	Στιγμιαία αδράνεια
K_i	Σταθερά ροπής	B_m	Συντελεστής τριβής
K_m	Σταθερά κινητήρα	K_f	Σταθερά στάτορα
$i_f(t)$	Ρεύμα στάτορα		

Πίνακας 3.1: Μεταβλητές και επεξήγηση αυτών

Ο έλεγχος του DC κινητήρα γίνεται από ρότορα χρησιμοποιώντας την τάση $V_a(t)$ που εφαρμόζεται στα άκρα του. Για γραμμική ανάλυση θεωρούμε ότι η ροπή που δημιουργείται στον κινητήρα είναι ανάλογη με την μαγνητική ροή και το ρεύμα του οπλισμού. Έτσι:

$$T_m(t) = K_m \varphi(t) i_a(t) \quad 3.4.1$$

Το ρεύμα του στάτορα $i_f(t)$ είναι σταθερό δηλαδή $i_f(t) = I_f$, άρα και η μαγνητική ροή που ορίζεται από την σχέση $\varphi(t) = K_f i_f(t)$ γίνεται $\varphi(t) = K_f I_f = \Phi = \text{σταθερή}$. Η σχέση 3.4.1 στη συνέχεια γράφεται :

$$T_m(t) = K_i i_a(t) \quad 3.4.2$$

όπου $K_i = K_m K_f I_f$ η σταθερά ροπής, σε Nm/A.

Η τάση $V_b(t)$ είναι ανάλογη προς την γωνιακή ταχύτητα του κινητήρα, δηλαδή:

$$V_b(t) = K_b \omega_m(t) \quad 3.5$$

Εφαρμόζοντας την ελεγχόμενη τάση εισόδου $V_a(t)$ οι διαφορικές εξισώσεις για το σύστημα του σχήματος 3.4 είναι:

$$\frac{di_a(t)}{dt} = \frac{1}{L_a} V_a(t) - \frac{R_a}{L_a} i_a(t) - \frac{1}{L_a} V_b(t) \Leftrightarrow \frac{di_a(t)}{dt} = \frac{1}{L_a} V_a(t) - \frac{R_a}{L_a} i_a(t) - \frac{1}{L_a} K_b \omega_m(t) \quad 3.6$$

(λόγω της σχέσης 3.5)

$$\frac{d\omega_m(t)}{dt} = \frac{1}{J_m} T_m(t) - \frac{B_m}{J_m} \omega_m(t) \Leftrightarrow \frac{d\omega_m(t)}{dt} = \frac{K_i}{J_m} i_a(t) - \frac{B_m}{J_m} \omega_m(t) \quad 3.7$$

(λόγω της 3.4.2)

$$w_m(t) = \frac{d\theta_m(t)}{dt} \quad 3.8$$

Μια άλλη περιγραφή του συστήματος μπορεί να γίνει με τις εξισώσεις κατάστασης. Ορίζουμε ως μεταβλητές κατάστασης $x_1 = \theta_m(t)$, $x_2 = w_m(t)$ και $x_3 = i_a(t)$. Το σύστημα διαφορικών εξισώσεων γράφεται στη μορφή :

$$\dot{x} = Ax + bu \text{ και } y = c^T x$$

$$\begin{pmatrix} \frac{di_a(t)}{dt} \\ \frac{dw_m(t)}{dt} \\ \frac{d\theta_m(t)}{dt} \end{pmatrix} = \begin{pmatrix} -\frac{R_a}{L_a} & -\frac{K_b}{L_a} & 0 \\ \frac{K_i}{J_m} & -\frac{B_m}{J_m} & 0 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} i_a(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix} + \begin{pmatrix} \frac{1}{L_a} \\ 0 \\ 0 \end{pmatrix} V_a(t) \quad 3.9$$

$$\text{και } y(t) = \begin{pmatrix} 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} i_a(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix} \quad 3.10$$

$$\text{όπου, } A = \begin{pmatrix} -\frac{R_a}{L_a} & -\frac{K_b}{L_a} & 0 \\ \frac{K_i}{J_m} & -\frac{B_m}{J_m} & 0 \\ 0 & 1 & 0 \end{pmatrix}, \quad x = \begin{pmatrix} i_a(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix}, \quad b = \begin{pmatrix} \frac{1}{L_a} \\ 0 \\ 0 \end{pmatrix}, \quad u = V_a(t) \text{ και } c = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

Στη συνέχεια μετασχηματίζουμε κατά Laplace τις σχέσεις 3.6, 3.7, 3.8 και έχουμε:

$$V_a(s) = sL_a I_a(s) + R_a I_a(s) + K_b \Omega_m(s) \quad 3.11$$

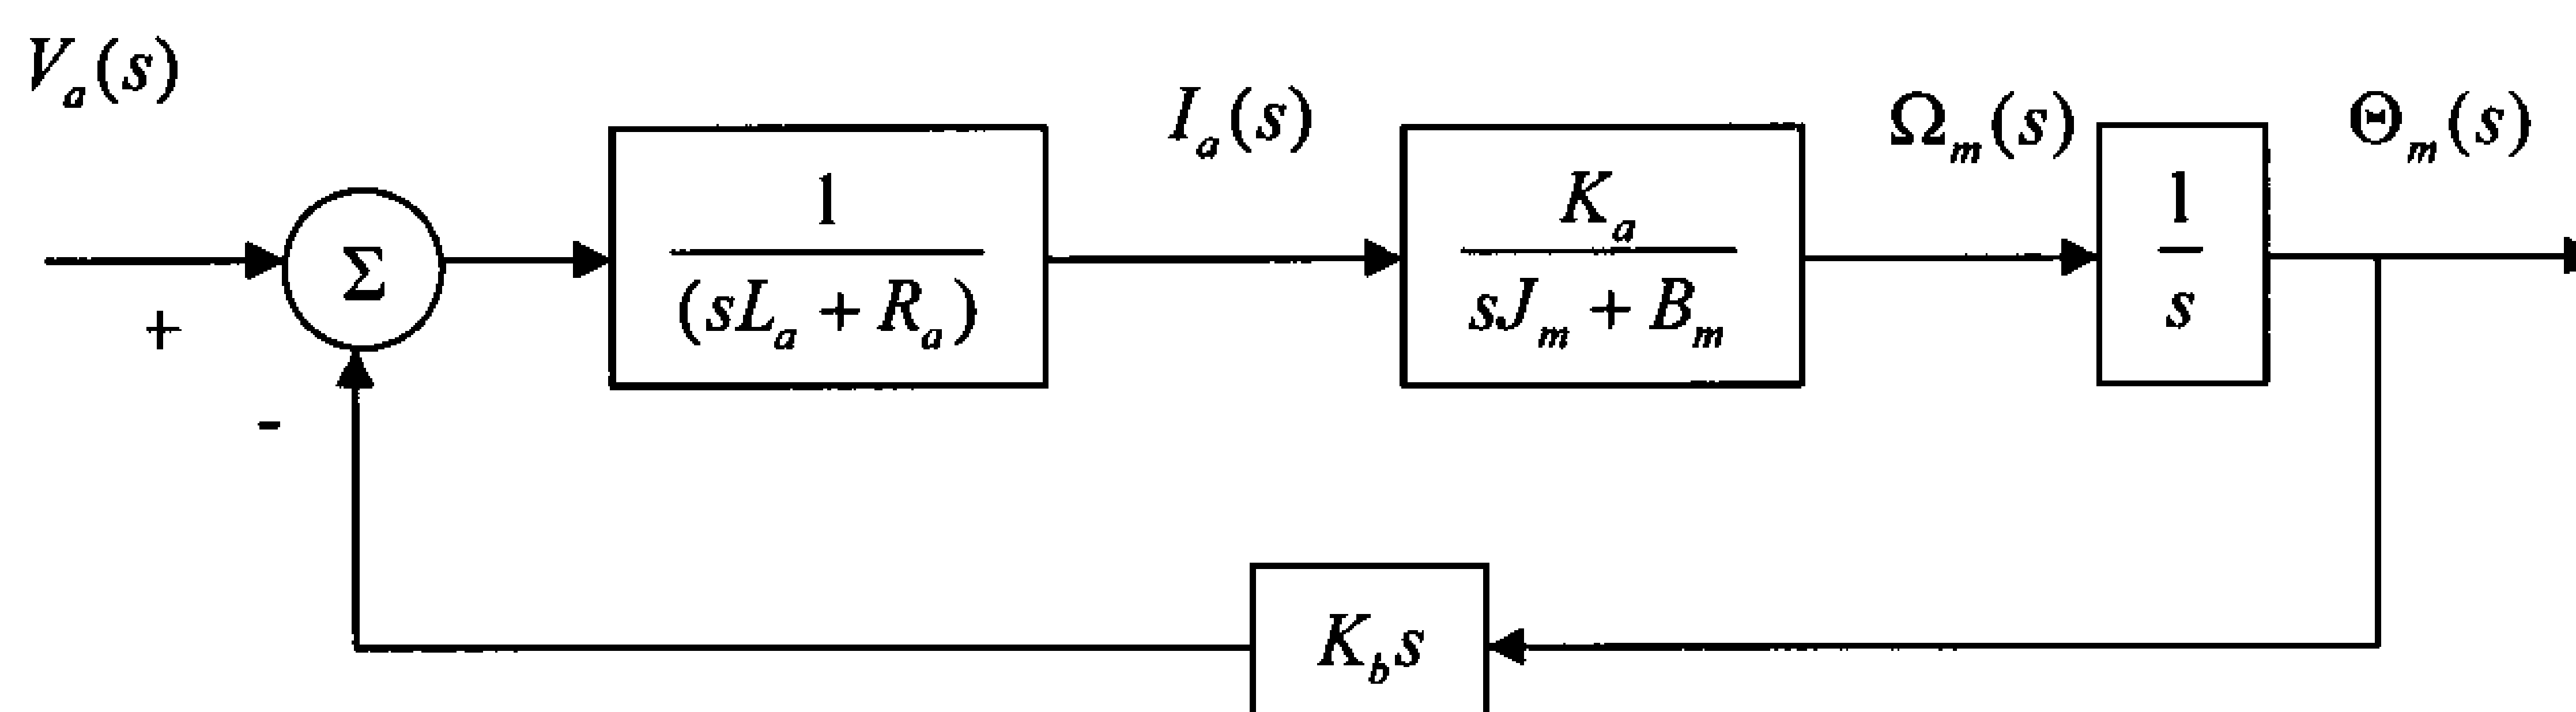
$$sJ_m \Omega_m(s) = K_i I_a(s) - B_m \Omega_m(s) \quad 3.12$$

$$\Omega_m(s) = s\Theta_m(s) \quad 3.13$$

Η συνάρτηση μεταφοράς του συστήματος, ανάμεσα στη γωνιακή θέση και την τάση εισόδου είναι:

$$G(s) = \frac{\Theta_m(s)}{V_a(s)} = \frac{K_i}{L_a J_m s^3 + (R_a J_m + L_a B_m) s^2 + (R_a B_m + K_i K_b) s} \quad 3.14$$

Οι εξισώσεις 3.11, 3.12, 3.13 μπορούν να παρασταθούν με το κλειστό διάγραμμα βαθμίδων του σχήματος 3.5. Το διάγραμμα αυτό έχει το πλεονέκτημα ότι μας δίνει μια ξεκάθαρη εικόνα της συνάρτησης μεταφοράς και κάθε βαθμίδας του συστήματος. Επίσης σε αυτό το διάγραμμα φαίνεται και ο ρόλος της σταθεράς K_b που ρυθμίζει το ποσό της ανατροφοδότησης της παραγώγου της εξόδου $\Theta_m(s)$.



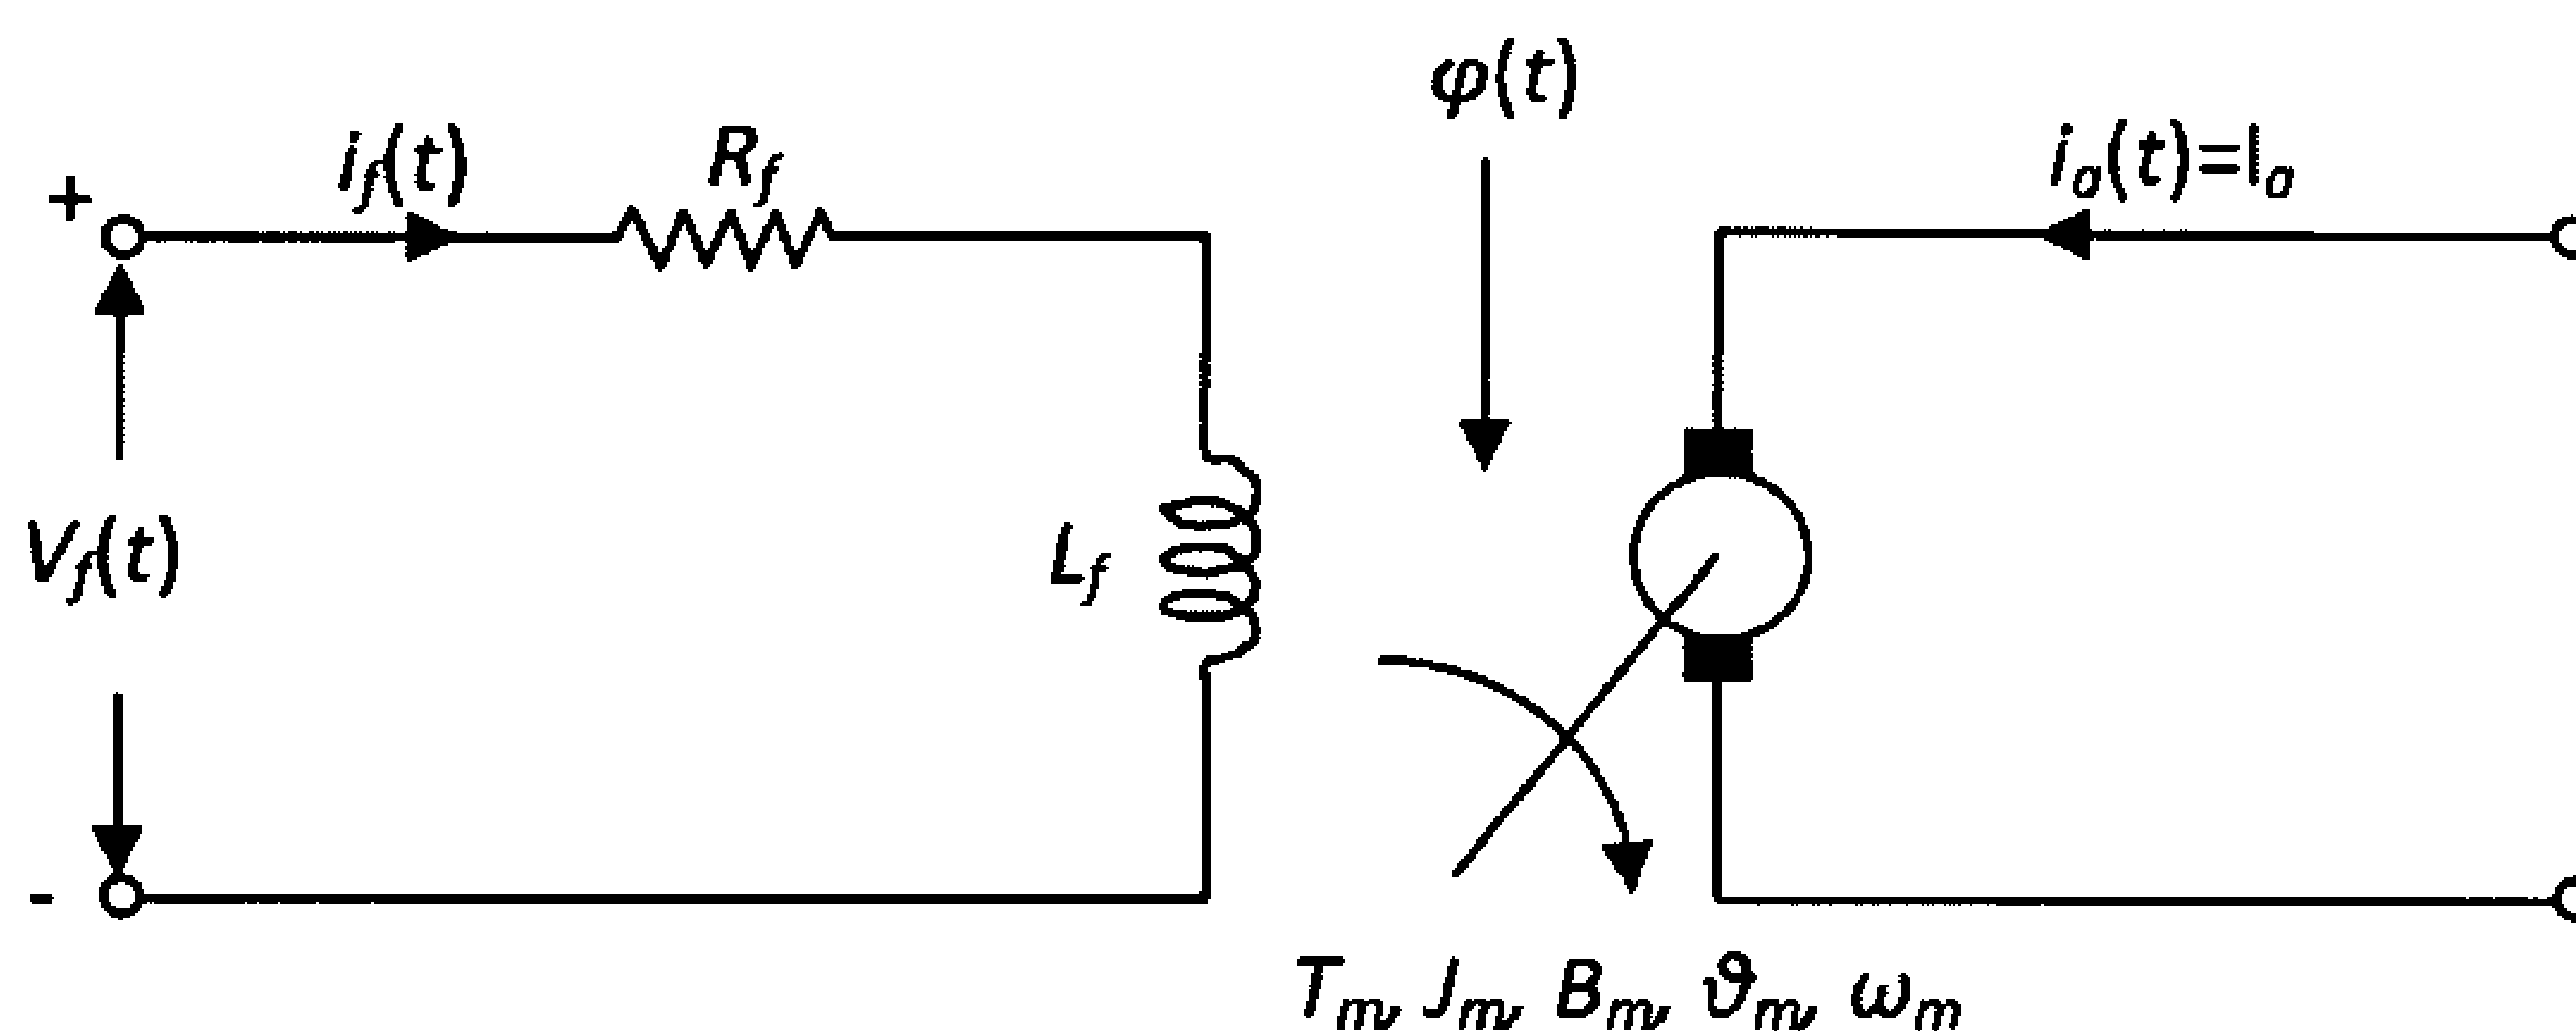
Σχήμα 3.5: Διάγραμμα βαθμίδων κινητήρα που ελέγχεται από ρότορα

Παρόλο που ο DC κινητήρας είναι ένα σύστημα ανοιχτού βρόγχου το διάγραμμα βαθμίδων δείχνει ότι ο κινητήρας έχει ενσωματωμένο ένα βρόγχο ανατροφοδότησης που προκαλείται από την ΑΗΕΔ. Όπως φαίνεται στην σχέση 3.14 η σταθερά ΑΗΕΔ (K_b) είναι ένας όρος ο οποίος προστίθεται στην R_a και τον συντελεστή μηχανικών τριβών B_m . Συνεπώς το αποτέλεσμα της ΑΗΕΔ ισοδυναμεί με ενός είδους ηλεκτρική τριβή που τείνει

να βελτιώσει την ευστάθεια του κινητήρα και γενικότερα όλου του συστήματος.

3.4.2 Κινητήρες που ελέγχονται από τον στάτορα

Το σχήμα 3.6 απεικονίζει ένα κινητήρα συνεχούς ρεύματος που ελέγχεται από τον στάτορα (Παρασκευόπουλος 2001).



Σχήμα 3.6: Μοντέλο DC κινητήρα ελεγχόμενου από τον στάτορα

Το κύκλωμα του στάτορα αποτελείται από μια αντίσταση R_f συνδεδεμένη σε σειρά με μια αυτεπαγωγή (πηνίο) L_f και μια πηγή τάσης. Θεωρούμε ότι το ρεύμα του ρότορα $i_a(t)$ είναι σταθερό, άρα $i_a(t) = I_a$. Η μαγνητική ροή μεταξύ του στάτορα και του ρότορα, όπως και στον έλεγχο από ρότορα είναι :

$$\varphi(t) = K_f i_f(t) \quad 3.15$$

Ισχύει και εδώ ότι $T_m(t) = K_m \varphi(t) i_a(t)$ με την διαφορά ότι εδώ ισχύει $i_a(t) = I_a$, άρα η σχέση γίνεται:

$$T_m(t) = K_m \varphi(t) I_a \quad 3.16$$

Η σχέση 3.16 μέσω της σχέσης 3.15 με απλή αντικατάσταση γίνεται:

$$T_m(t) = K_m K_f I_a i_f(t) \quad 3.17$$

Εφαρμόζοντας τώρα την ελεγχόμενη τάση εισόδου $V_f(t)$ οι εξισώσεις για το κύκλωμα του σχήματος 3.6 είναι:

$$\frac{di_f(t)}{dt} = \frac{1}{L_f} V_f(t) - \frac{R_f}{L_f} i_f(t) \quad 3.18$$

$$\frac{dw_m(t)}{dt} = \frac{1}{J_m} T_m(t) - \frac{B_m}{J_m} w_m(t) \quad 3.19$$

$$w_m(t) = \frac{d\theta_m(t)}{dt} \quad 3.20$$

Η διαφορική 3.19 μέσω της 3.17 γίνεται:

$$\frac{dw_m(t)}{dt} = \frac{K_m K_f I_a}{J_m} i_f(t) - \frac{B_m}{J_m} w_m(t) \quad 3.21$$

Για να βγάλουμε τις εξισώσεις κατάστασης ορίζουμε ως μεταβλητές κατάστασης $x_1 = \theta_m(t)$, $x_2 = w_m(t)$ και $x_3 = i_f(t)$. Τότε το σύστημα διαφορικών εξισώσεων γράφεται στη μορφή :

$$\dot{x} = Ax + bu \text{ και } y = c^T x$$

$$\begin{pmatrix} \frac{di_f(t)}{dt} \\ \frac{dw_m(t)}{dt} \\ \frac{d\theta_m(t)}{dt} \end{pmatrix} = \begin{pmatrix} -\frac{R_f}{L_f} & 0 & 0 \\ \frac{K_m K_f I_a}{J_m} & -\frac{B_m}{J_m} & 0 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} i_f(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix} + \begin{pmatrix} \frac{1}{L_f} \\ 0 \\ 0 \end{pmatrix} V_f(t) \quad 3.22$$

$$y(t) = \begin{pmatrix} 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} i_f(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix} \quad 3.23$$

$$\text{Όπου } \dot{x} = \begin{pmatrix} \frac{di_f(t)}{dt} \\ \frac{dw_m(t)}{dt} \\ \frac{d\theta_m(t)}{dt} \end{pmatrix}, A = \begin{pmatrix} -\frac{R_f}{L_f} & 0 & 0 \\ \frac{K_m K_f I_a}{J_m} & -\frac{B_m}{J_m} & 0 \\ 0 & 1 & 0 \end{pmatrix}, x = \begin{pmatrix} i_f(t) \\ w_m(t) \\ \theta_m(t) \end{pmatrix}, b = \begin{pmatrix} \frac{1}{L_f} \\ 0 \\ 0 \end{pmatrix}, u = V_f(t)$$

$$\text{και } c = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

Μετασχηματίζοντας κατά Laplace τις εξισώσεις 3.18 , 3.20 , 3.21 :

$$sI_f(s) = \frac{1}{L_f} V_f(s) - \frac{R_f}{L_f} I_f(s) \quad 3.24$$

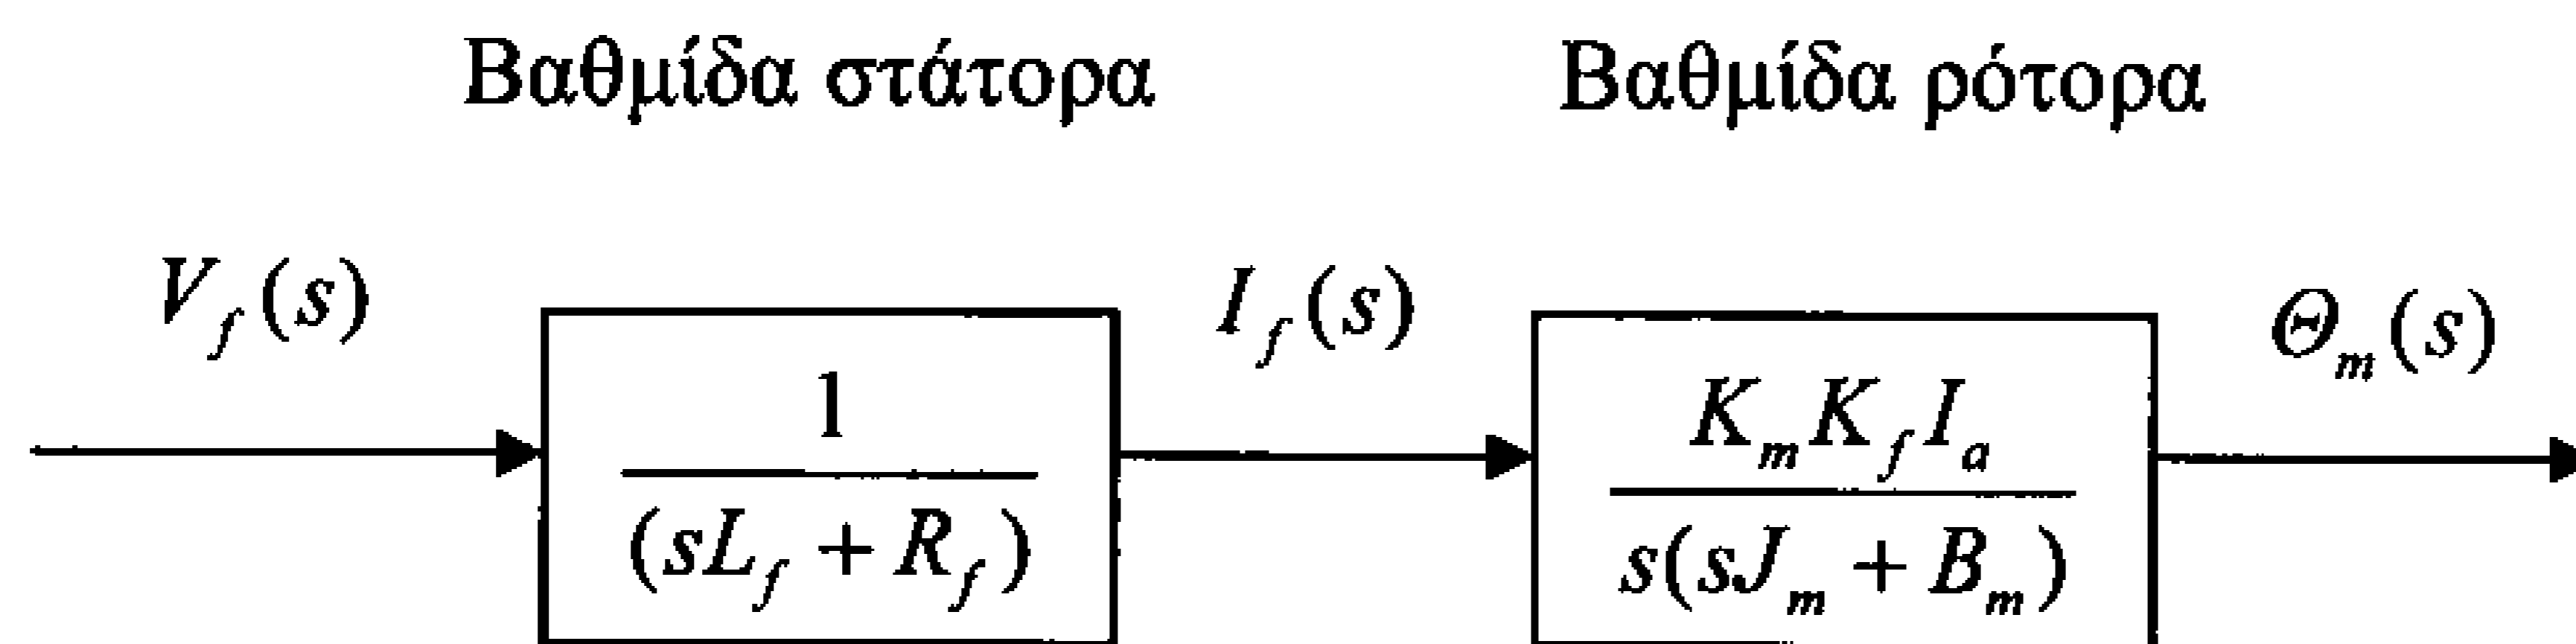
$$\Omega_m(s) = s\Theta_m(s) \quad 3.25$$

$$s\Omega_m(s) = \frac{K_m K_f I_a}{J_m} I_f(s) - \frac{B_m}{J_m} \Omega_m(s) \quad 3.26$$

και κατόπιν αλγεβρικών πράξεων παίρνουμε την παρακάτω συνάρτηση μεταφοράς:

$$G(s) = \frac{\Theta_m(s)}{V_f(s)} = \frac{K_m K_f I_a}{s(sJ_m + B_m)(sL_f + R_f)} \quad 3.27$$

Το διάγραμμα βαθμίδων για την παραπάνω συνάρτηση μεταφοράς (3.27) φαίνεται στο σχήμα 3.7

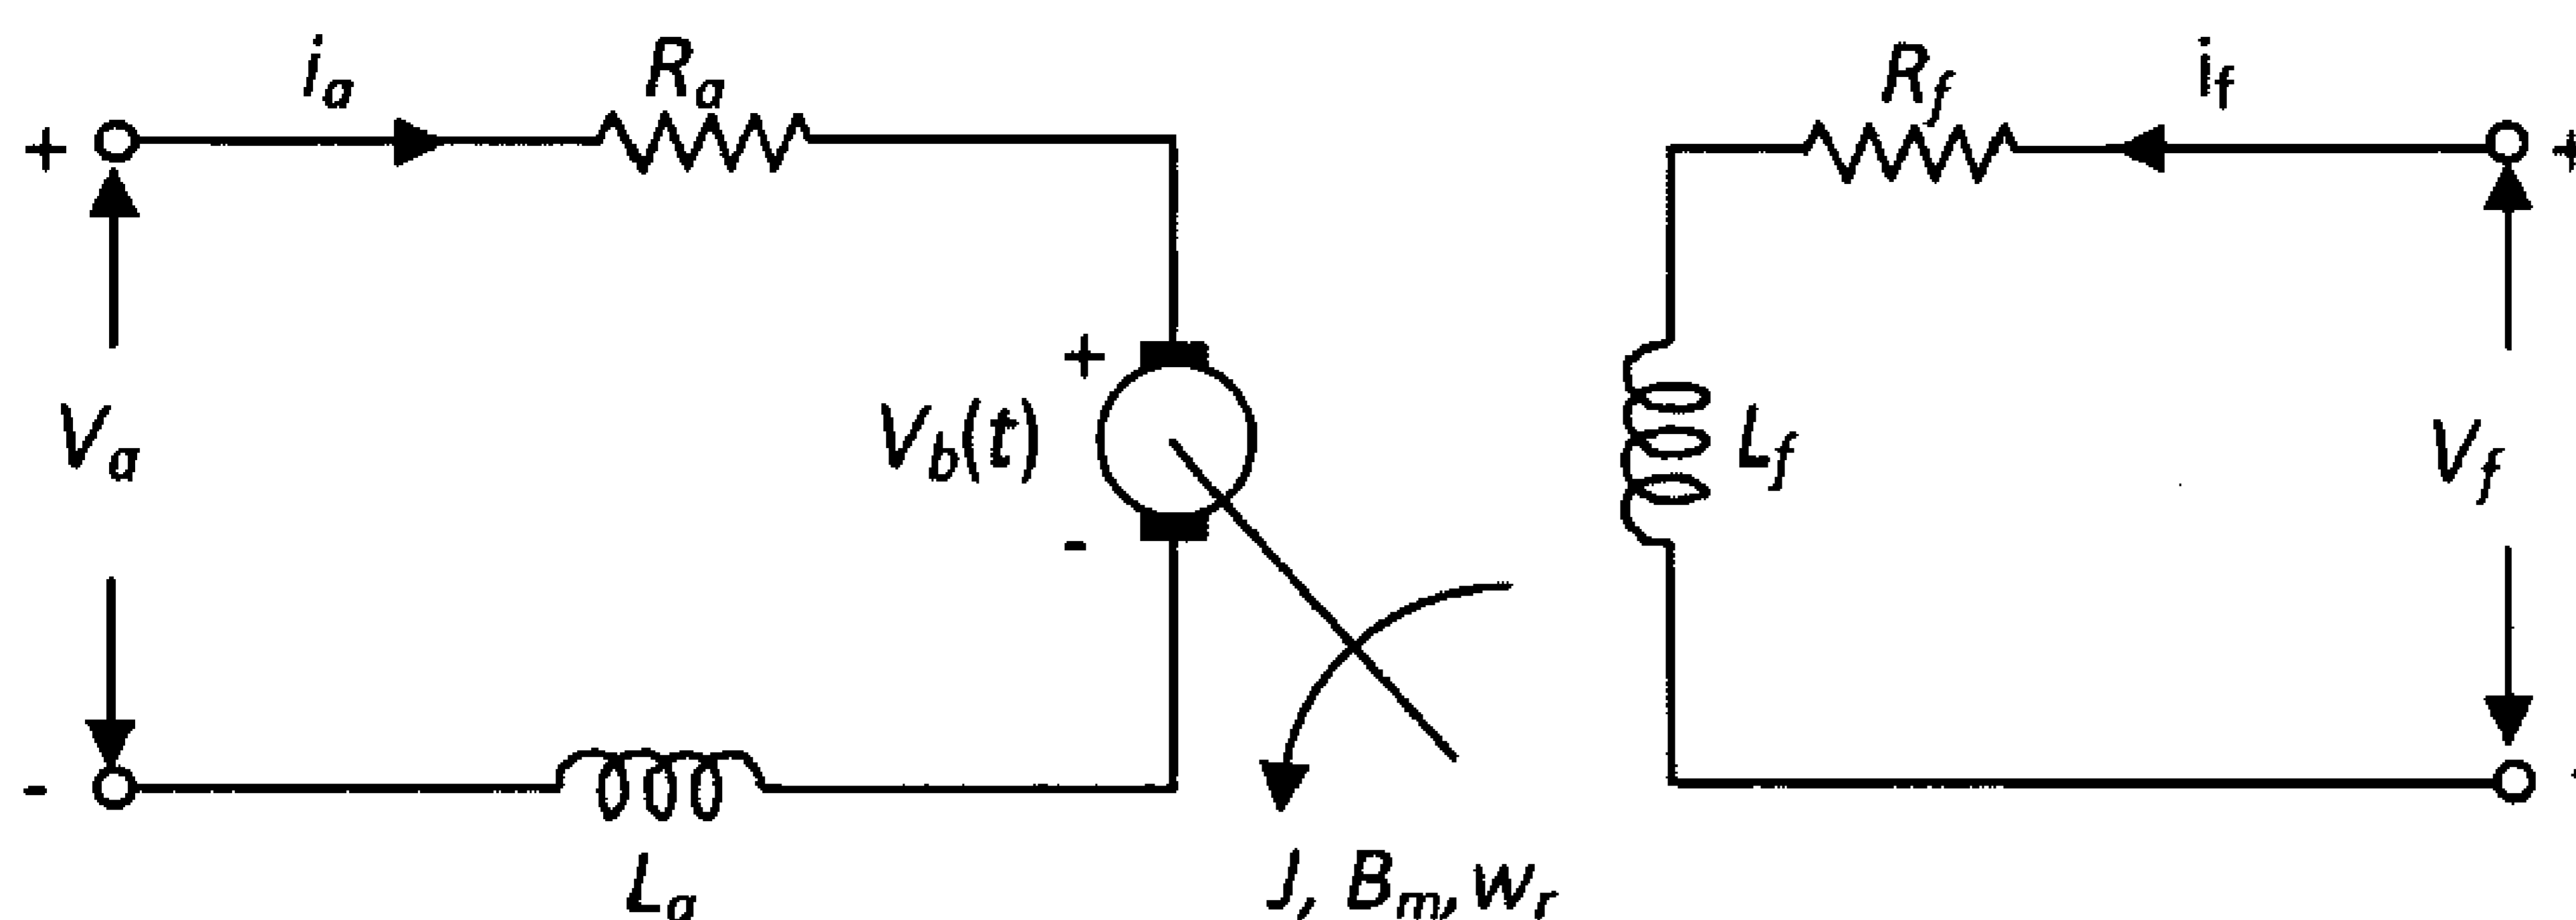


Σχήμα 3.7: Διάγραμμα βαθμίδων κινητήρα που ελέγχεται από στάτορα

3.5 Καθορισμός παραμέτρων ενός μη γραμμικού DC κινητήρα

Η ανάλυση που παρουσιάστηκε στην προηγούμενη παράγραφο χρησιμοποιεί κάποιες παραδοχές που καταλήγουν σε γραμμικά μοντέλα. Συγκεκριμένα στην πρώτη περίπτωση που επιτυγχάνεται έλεγχος από τον ρότορα θεωρήθηκε πως το ρεύμα i_f ήταν σταθερό, ενώ στην δεύτερη περίπτωση που ο έλεγχος γίνεται με από τον στάτορα, θεωρήθηκε το ρεύμα i_a του ρότορα σταθερό. Ωστόσο σε έναν πραγματικό DC κινητήρα κανένα από τα δύο αυτά ρεύματα δεν είναι συνέχεια σταθερό, με συνέπεια να χρειάζεται ένα σύνολο μη γραμμικών διαφορικών εξισώσεων προκειμένου να περιγραφεί αυτό το φαινόμενο. Οι ακόλουθες μη γραμμικές εξισώσεις κατάστασης, οι οποίες προέκυψαν χρησιμοποιώντας τους νόμους του Kirchhoff και Newton όπως στα προηγούμενα κεφάλαια, περιγράφουν την μεταβατική συμπεριφορά ενός DC ηλεκτρικού κινητήρα (σχήμα 3.8):

$$\begin{pmatrix} \frac{di_f(t)}{dt} \\ \frac{di_a(t)}{dt} \\ \frac{dw_r(t)}{dt} \end{pmatrix} = \begin{pmatrix} -\frac{r_f i_f}{L_f} + \frac{V_f}{L_f} \\ -\frac{r_a i_a}{L_a} - \frac{L_{af} i_f w_r}{L_a} + \frac{V_a}{L_a} \\ \frac{L_{af} i_f i_a}{J} - \frac{B_L w_r}{J} \end{pmatrix} \quad 3.28$$



Σχήμα 3.8: Μη γραμμικός DC κινητήρας

Όπου $x = [\omega, i_f, i_a]^T$ είναι το διάνυσμα κατάστασης, $u = [V_a, V_f]^T$ είναι το διάνυσμα εισόδου και $y = [\omega, i_f, i_a]^T$ είναι η έξοδος.

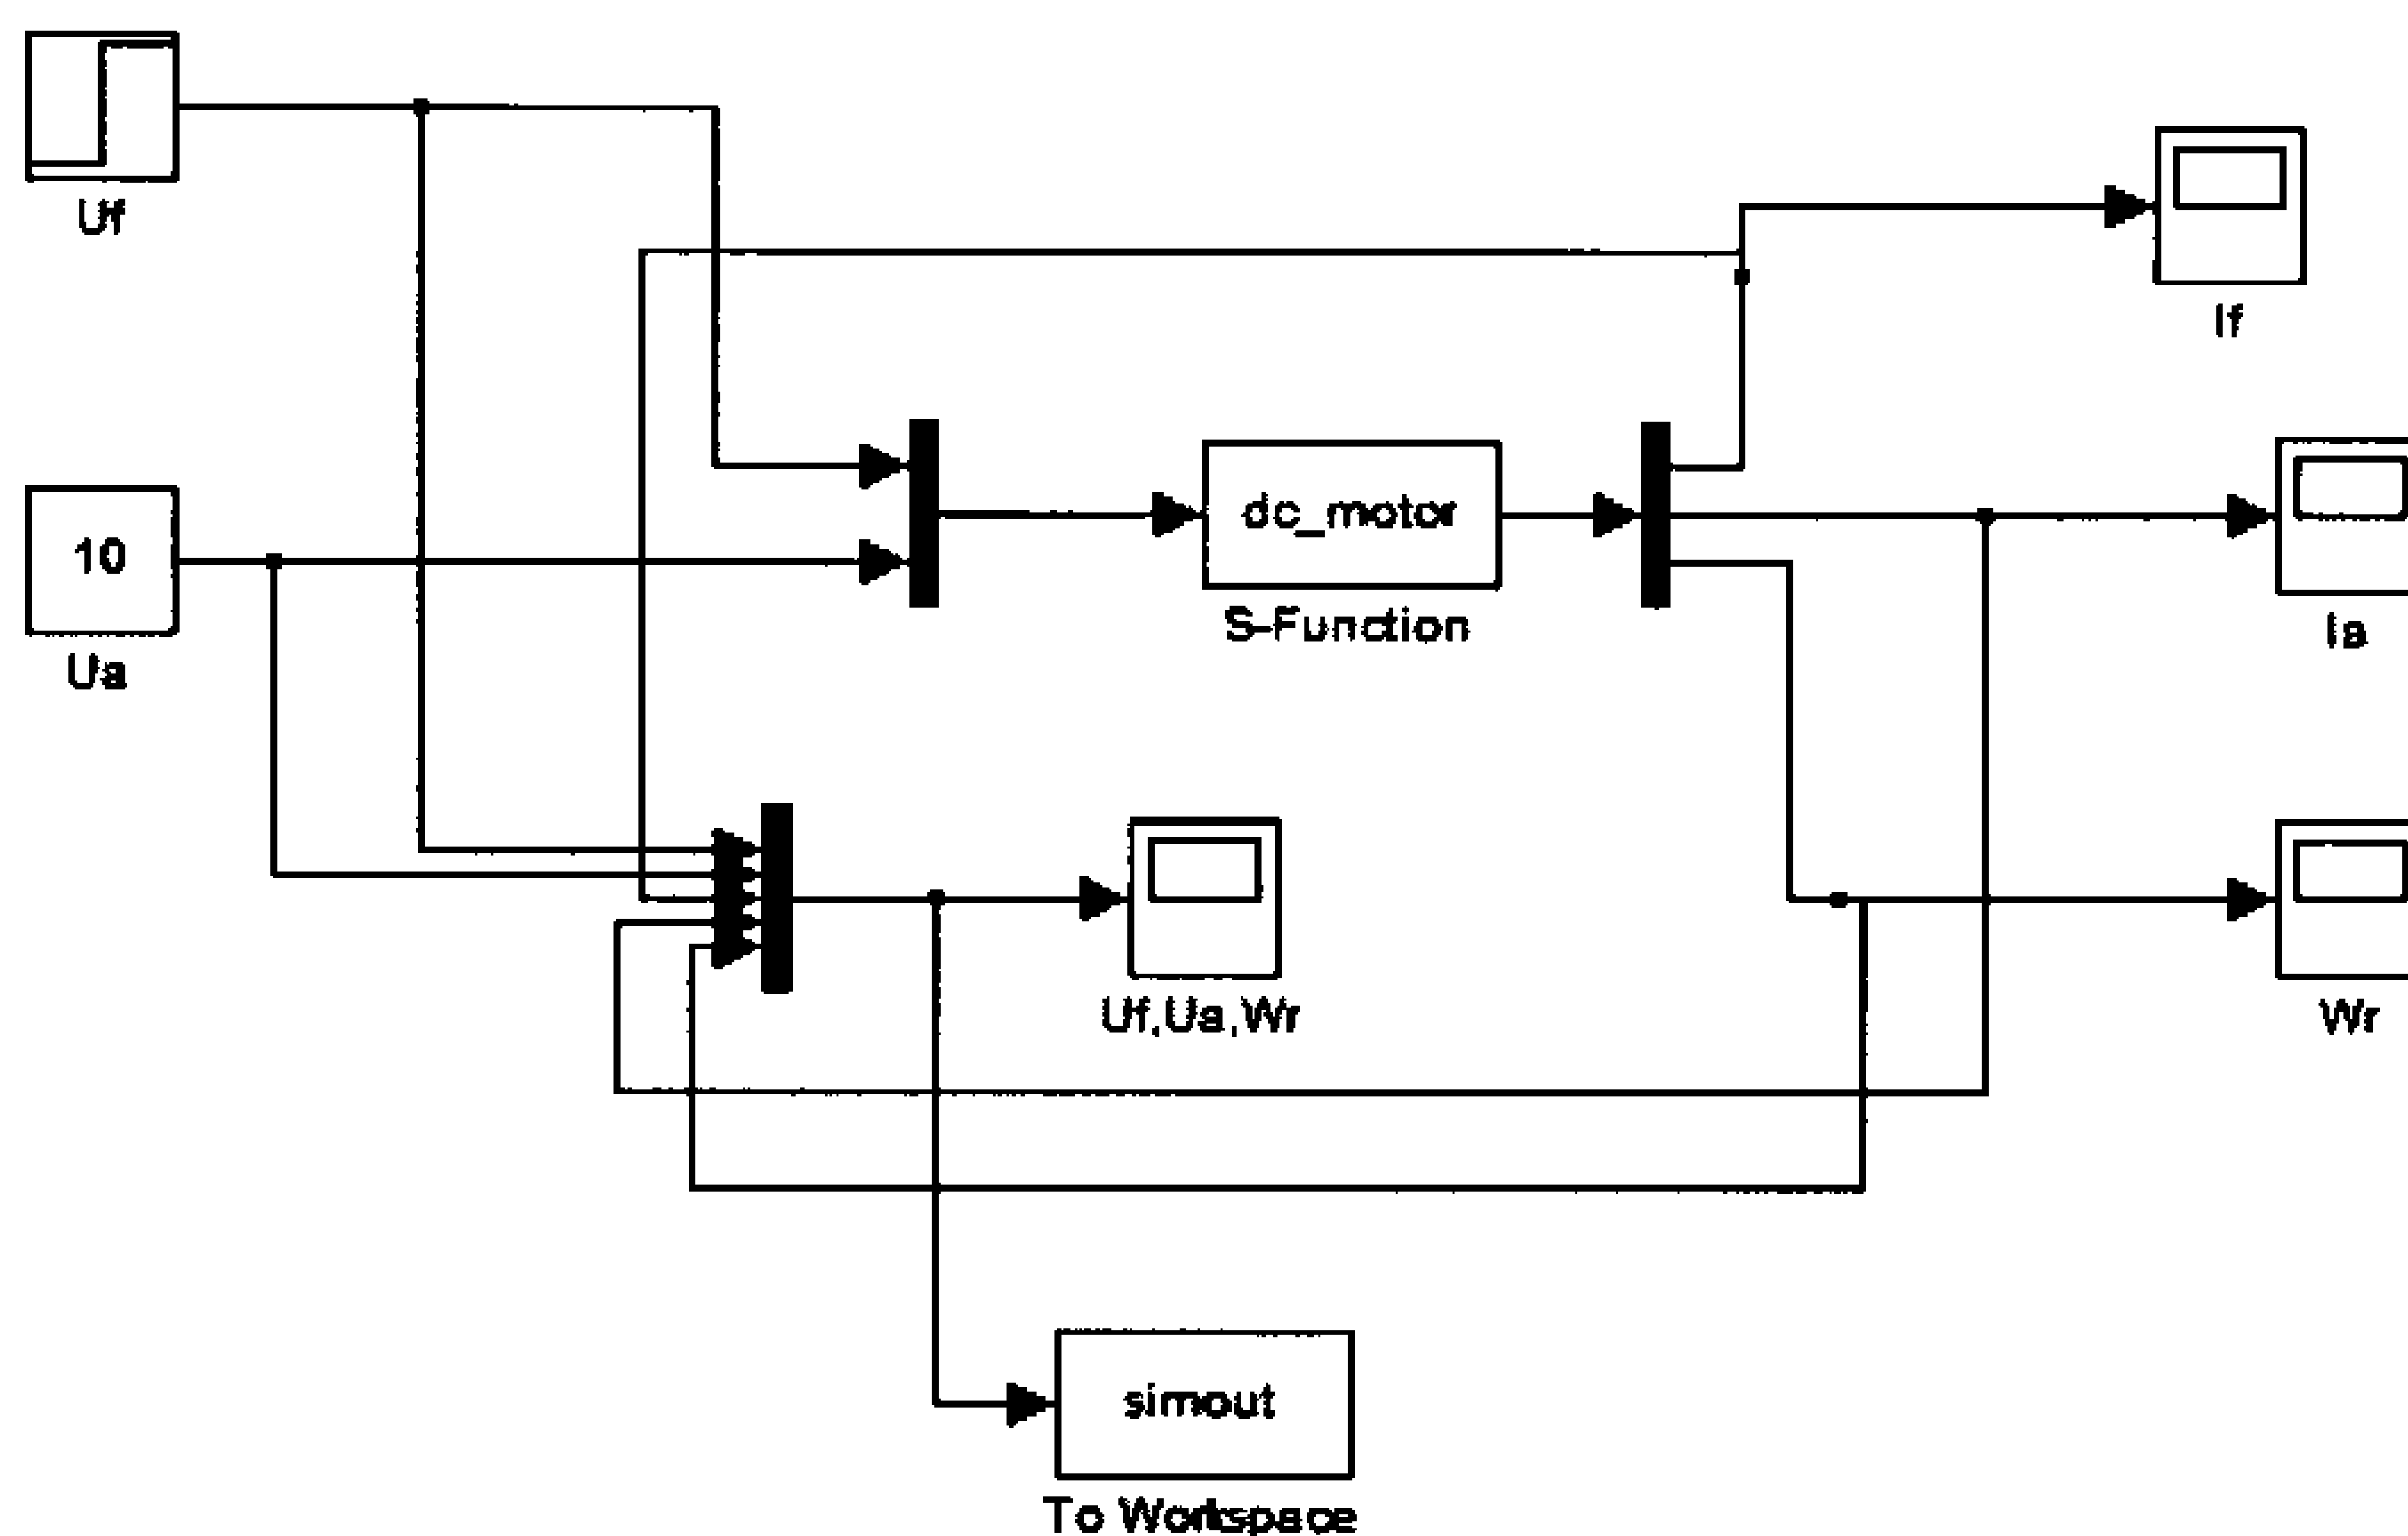
Ο πίνακας 3.2 παρουσιάζει τις μεταβλητές που χρησιμοποιήθηκαν για την εύρεση των παραμέτρων των διαφορικών εξισώσεων (3.28) του κινητήρα καθώς και τις τιμές τους (Salas-Cabrera et al. 2008).

ΠΑΡΑΜΕΤΡΟΙ	ΣΥΜΒΟΛΙΣΜΟΣ	ΤΙΜΗ
Γωνιακή ταχύτητα κινητήρα	ω_r	Μεταβλητή κατάστασης
Ρεύμα οπλισμού	i_a	Μεταβλητή κατάστασης
Ρεύμα στάτορα	i_f	Μεταβλητή κατάστασης
Τάση στα άκρα του οπλισμού	V_a	Μεταβλητή ελέγχου
Τάση στα άκρα του στάτορα	V_f	Μεταβλητή ελέγχου
Αντίσταση του ρότορα	r_a	10.5479Ω
Αντίσταση του στάτορα	r_f	320.6955Ω
Αυτεπαγωγή ρότορα	L_a	3.0948×10^{-6} H
Αυτεπαγωγή στάτορα	L_f	20.5245H
Αμοιβαία αυτεπαγωγή	L_{af}	2.6116H
Στιγμιαία αδράνεια	J	0.0015kgm ²
Συντελεστής μηχανικών τριβών	B_L	0.0042Nmsec

Πίνακας 3.2 Τιμές και συμβολισμός παραμέτρων του μη γραμμικού DC κινητήρα.

3.6 Προσωμοίωση μη γραμμικού DC κινητήρα με το Simulink του πακέτου Matlab


Όπως έχει αναφερθεί προηγουμένως, το σύστημα που μελετάται έχει δύο εισόδους V_a και V_f , οι οποίες εισάγονται στο σύστημα (S-function) και εξέρχονται τρεις έξοδοι i_a , i_f και ω_r . Στο σχήμα 3.9 φαίνεται το διάγραμμα βαθμίδων του κινητήρα και ξεχωρίζουν οι εισοδοί, ο κινητήρας (S-function) και τα scope όπου παρατηρείται η κάθε έξοδος ξεχωριστά. Η βαθμίδα simout είναι ουσιαστικά ένας πίνακας που αποθηκεύονται όλα τα δεδομένα την ώρα που τρέχει η προσομοίωση και σώζονται στο workspace. Ο πίνακας αυτός έχει 5 στήλες που είναι οι εισοδοί και οι έξοδοι του συστήματος.




Σχήμα 3.9: Διάγραμμα βαθμίδων του κινητήρα στο simulink

Το S-Function περιέχει τις διαφορικές εξισώσεις (σχέση 3.28) τις οποίες επιλύει με αριθμητικές μεθόδους προσομοιώνοντας με αυτόν τον τρόπο τον κινητήρα. Προκειμένου να μελετηθεί η συμπεριφορά του κινητήρα σε μεταβολές των εισόδων V_f και V_a δοκιμάστηκαν διάφορες περιπτώσεις :


1. Η τάση V_f κρατείται σταθερή και ίση με 10V και στην V_a εφαρμόζεται βηματική μεταβολή από τα 100V στα 105V. Η απόκριση των εξόδων παρουσιάζεται στα σχήματα 3.10.α, 3.10.β, 3.10.γ.



Σχήμα 3.10.α: Το ρεύμα i_f όταν η τάση V_f είναι σταθερή και η τάση V_a ακολουθεί βηματική μεταβολή.




Σχήμα 3.10.β: Το ρεύμα i_a όταν η τάση V_f είναι σταθερή και η τάση V_a ακολουθεί βηματική μεταβολή.




Σχήμα 3.10.γ: Οι στροφές ω_r του κινητήρα όταν η τάση V_f είναι σταθερή και η τάση V_a ακολουθεί βηματική μεταβολή.


2. Η τάση V_a κρατείται σταθερή και ίση με 100V και στην V_f εφαρμόζεται βηματική μεταβολή από τα 15V στα 20V. Στα σχήματα 3.11.α, 3.11.β, 3.11.γ παρουσιάζεται η απόκριση των εξόδων.



Σχήμα 3.11.α: Το ρεύμα i_f όταν η τάση V_a είναι σταθερή και η τάση V_f ακολουθεί βηματική μεταβολή.



Σχήμα 3.11.β: Το ρεύμα i_a όταν η τάση V_a είναι σταθερή και η τάση V_f ακολουθεί βηματική μεταβολή.




Σχήμα 3.11.γ: Οι στροφές w_r του κινητήρα όταν η τάση V_a είναι σταθερή και η τάση V_f ακολουθεί βηματική μεταβολή.

Με βάση τα παραπάνω διαγράμματα, παρατηρούμε την επίδραση των μεταβλητών εισόδου στην απόκριση όχι μόνο των στροφών του κινητήρα αλλά και των υπολοίπων δύο μεταβλητών κατάστασης.


Στην πραγματοποίηση αυτών των μετρήσεων παρατηρήθηκε υψηλός υπολογιστικός χρόνος προκειμένου να επιλυθεί το σύστημα των διαφορικών εξισώσεων του κινητήρα. Το γεγονός αυτό οφείλεται στην πολύ γρήγορη μεταβολή κάποιων εκ των μεταβλητών κατάστασης του κινητήρα, γεγονός που αναγκάζει τον επιλυτή να επιλέγει πολύ μικρό βήμα (Eberly 2003, Hairer and Wanner 2010). Τέτοια συστήματα διαφορικών εξισώσεων για την επίλυση των οποίων συγκεκριμένες μαθηματικοί μέθοδοι είναι αριθμητικά ασταθείς, εκτός και αν το βήμα είναι υπερβολικά μικρό, ονομάζονται δύσκαμπτα (stiff). Η λύση στο πρόβλημα αυτό είναι η επιλογή ενός stiff επιλυτή για την προσομοίωση, όπως είναι ο ode15s (stiff/NDF). Στο σχήμα 3.12.α φαίνεται πως πραγματοποιείται η stiff επίλυση ενός συστήματος και στο σχήμα 3.12.β η απλή επίλυση.

Αυτό που επιτυγχάνεται με τον stiff επιλυτή είναι η πραγματοποίηση μεγάλων βημάτων στις γραμμικές περιοχές όπου δε χρειαζόμαστε πολλές τιμές, ενώ στην περίπτωση της περιοχής όπου πραγματοποιείται η έντονη μεταβολή, το βήμα προσαρμόζεται για να ακολουθήσει την αλλαγή.

Μελετώντας πως μεταβάλλονται οι στρόφες του κινητήρα (w_r) σε κατάσταση ισορροπίας (μόνιμη κατάσταση), σε σχέση με τις μεταβολές των τάσεων V_a και V_f , προέκυψαν τα παρακάτω γραφήματα 3.13 και 3.14.




Σχήμα 3.12.α: stiff επίλυση




Σχήμα 3.12.β: απλή επίλυση

Στο σχήμα 3.13 η τιμή της τάσης V_a είναι σταθερή και ίση με 10 Volt ενώ μεταβάλλεται η τάση V_f από 0 έως 120 Volt. Οι τιμές των στροφών του κινητήρα (w_r) αναφέρονται πάντα σε μόνιμη κατάσταση.

Στο σχήμα 3.14 η τιμή της τάσης V_f είναι σταθερή και ίση με 10 Volt ενώ μεταβάλλεται η τάση V_a από 0 έως 200 Volt.



Σχήμα 3.13: Οι στροφές του κινητήρα σε μόνιμη κατάσταση συναρτήσκει του V_f



Σχήμα 3.14: Οι στροφές του κινητήρα σε μόνιμη κατάσταση συναρτήσκει του V_a

Αυτό που μπορεί να επισημανθεί είναι ότι οι στροφές του κινητήρα (w_r) σε συνάρτηση με την τάση στα άκρα του οπλισμού (V_a) παρουσιάζουν μια γραμμική εξάρτηση, ενώ σε συνάρτηση με την τάση στα άκρα του στάτορα (V_f) παρατηρούνται μη γραμμικά φαινόμενα. Για τιμές της τάσης V_a κοντά στα 25 Volt τα μη γραμμικά φαινόμενα είναι εντονότερα.


ΚΕΦΑΛΑΙΟ 4ο

ΜΟΝΤΕΛΟΠΟΙΗΣΗ DC ΚΙΝΗΤΗΡΑ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ RBF

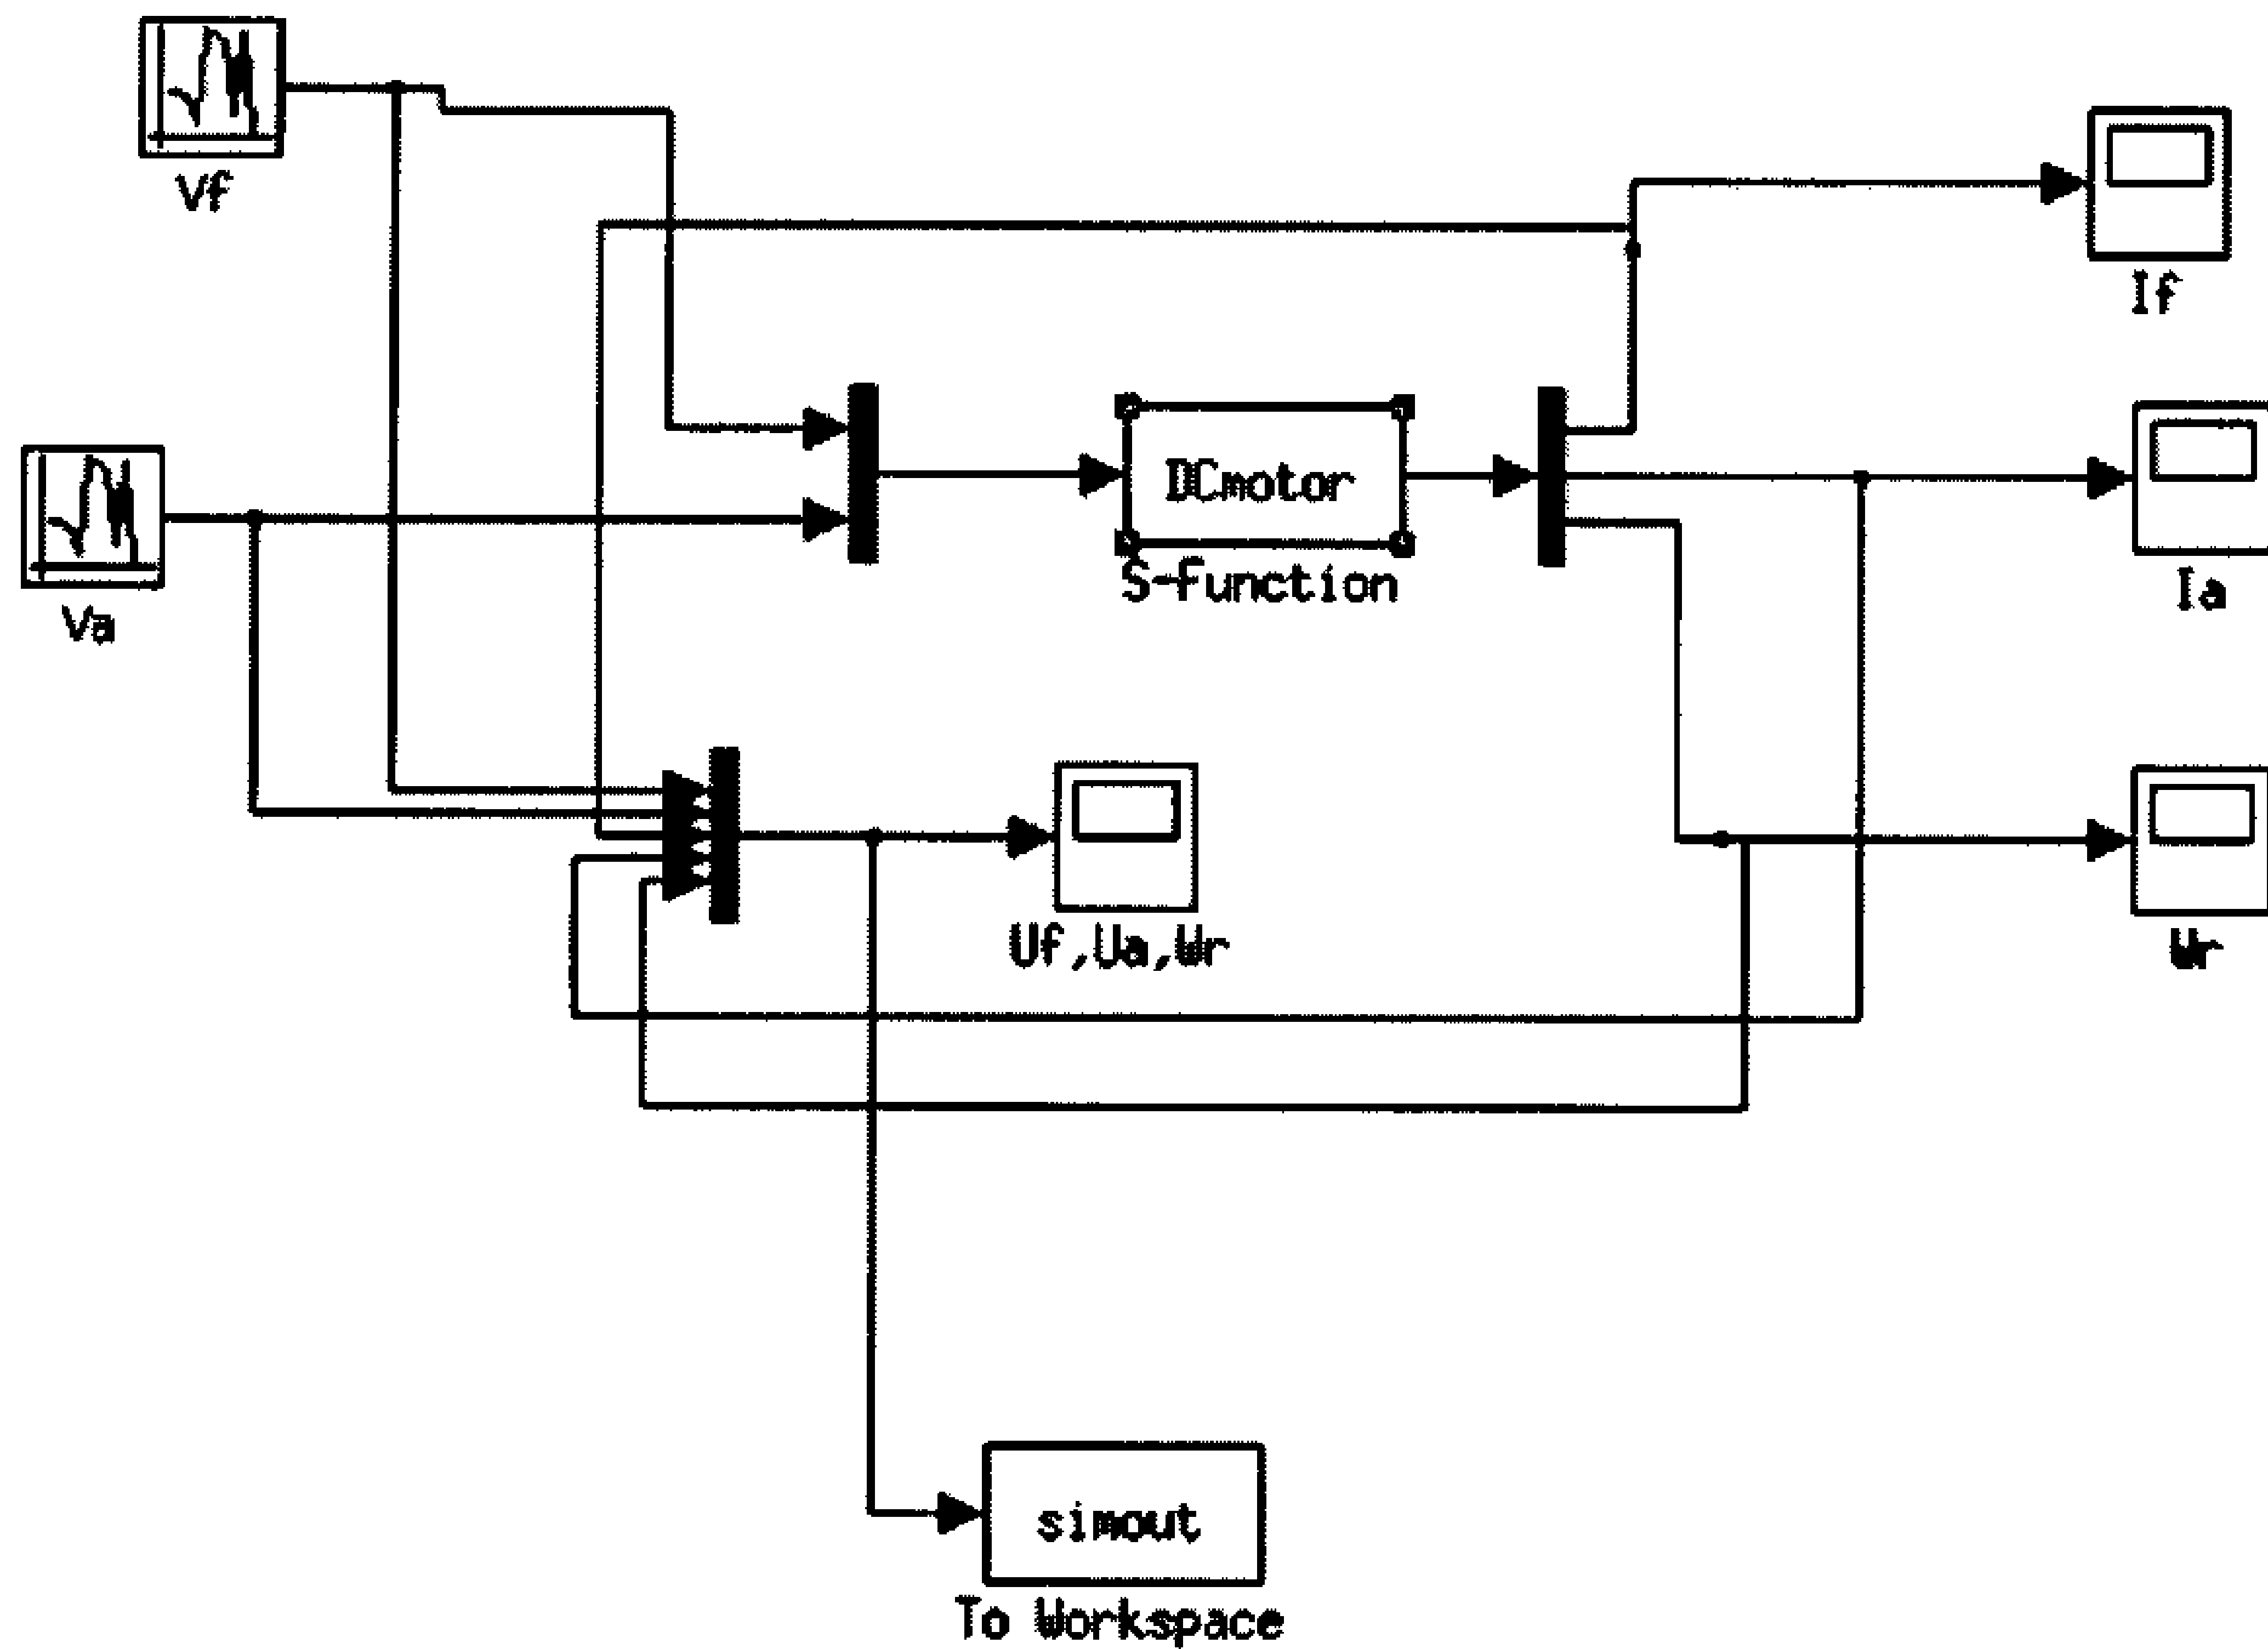
4.1 Ιοντελοποίηση κινητήρα

Στο 1ο ηγούμενο κεφάλαιο αναλύθηκε ένας DC κινητήρας, ο οποίος περιγράφεται από ένα ενολο μη γραμμικών διαφορικών εξισώσεων. Αυτές οι εξισώσεις συμπεριλήφθηκαν στο Function του Simulink που διατίθεται με το πακέτο Matlab, κατασκευάζοντας έτσι ένανικονικό DC κινητήρα. Αρχικά στόχος ήταν να μοντελοποιηθεί το σύστημα σαν ένα «μαύο κουτί», δηλαδή σαν ένα σύστημα για το οποίο δεν γνωρίζουμε τους μαθηματικούς νόμους που το διέπουν και η μόνη πληροφορία που μπορούμε να έχουμε είναιιμές εισόδου και εξόδου από αυτό, όπως φαίνεται στο σχήμα 4.1. Σε αυτά τα συστήματα η μοναδική δυνατότητα που έχουμε ώστε να εξάγουμε κάποια συμπεράσματα για τ σύστημα είναι να συσχετίσουμε με κάποιο τρόπο τα δεδομένα εισόδου-εξόδου. Με άλλολόγια μπορούμε να δίνουμε στο σύστημα κάποια είσοδο και να μετράμε κάθε φορά την ίοδο, ώστε στο τέλος να προσεγγίσουμε με βάση αυτά τα δεδομένα, τους νόμους που έπουν την λειτουργία του συστήματος και τον τρόπο που επηρεάζει η είσοδος την έξοδο του συστήματος.

Για το σκοπό αυτό πραγματοποιήθηκε ένα διάγραμμα βαθμίδων στο Simulink το οποίόπως φαίνεται στο σχήμα 4.2 παρείχε στον κινητήρα τις 2 πηγές εισόδου (V_a , V_f) μεταλητών κατάστασης (i_a , i_f , w_r). Στη συνέχεια, αυτά τα δεδομένα αποθηκεύτηκαν μέσω του simout στο Matlab για περαιτέρω επεξεργασία.




Σχήμα 4.1 Είσοδος έξοδος ενός αγνώστου συστήματος (black box)




Σχήμα 4.2 Το διάγραμμα βαθμίδων που εφαρμόστηκε στο Simulink για την μοντελοποίηση του DC κινητήρα.

Οι δύο τάσεις εισόδου V_a και V_f παράγονται από πηγές τυχαίων αριθμών με κανονική κατανομή (Σχήμα 4.3, 4.4).




Σχήμα 4.3 Η τάση εισόδου V_f συναρτήσει του χρόνου




Σχήμα 4.4 Η τάση εισόδου V_a συναρτήσει του χρόνου


Όπως φαίνεται και στα πιο πάνω γραφήματα, οι πηγές είναι ανεξάρτητες μεταξύ τους. Πιο συγκεκριμένα η V_f δημιουργείται από μια γκαουσιανή κατανομή με μέση τιμή 15V, διακύμανση 5V και χρόνο δειγματοληψίας 15sec, ενώ η V_a δημιουργείται από μια γκαουσιανή κατανομή με μέση τιμή 100V, διακύμανση 3V και χρόνο δειγματοληψίας 20sec. Τα αποτελέσματα της απόκρισης των μεταβλητών κατάστασης του κινητήρα (i_a , i_f , ω_r) φαίνονται στα σχήματα 4.5, 4.6 και 4.7.



Σχήμα 4.5 Το ρεύμα του κινητήρα i_f συναρτήσει του χρόνου




Σχήμα 4.6 Το ρεύμα i_a συναρτήσει του χρόνου



Σχήμα 4.7 Οι στροφές του κινητήρα συναρτήσει του χρόνου

Σε αυτό το σημείο πρέπει να αναφερθεί πως το πεδίο τιμών των τάσεων εισόδου δεν επιλέχθηκε τυχαία, αλλά με γνώμονα τον έλεγχο του κινητήρα, παράμετρος που θα αναλυθεί εκτενέστερα στο επόμενο κεφάλαιο.

Το επόμενο στάδιο είναι η επιλογή του χρόνου δειγματοληψίας των δεδομένων που θα εισαχθούν εν τέλει στο Matlab ώστε να εμπεριέχουν όση περισσότερη πληροφορία γίνεται, χωρίς πλεονασμούς. Στο ακόλουθο σχήμα (4.8) διακρίνεται ο χρόνος



Σχήμα 4.8 Η απόκριση των στροφών του κινητήρα μέχρι να ισορροπήσει

που χρειάζεται το σύστημα ώστε μετά από μια μεταβολή στις τάσεις εισόδου να επανέλθει σε ισορροπία.

Μπορεί κανείς να παρατηρήσει πως από την στιγμή που πραγματοποιείται μια μεταβολή στην είσοδο, ενώ προηγουμένως βρισκόταν σε ισορροπία το σύστημα, μέχρι να ισορροπήσει εκ νέου χρειάζονται περίπου 2.5-3.0 sec. Επομένως ιδανικά θα πρέπει να χρησιμοποιηθεί ένας χρόνος δειγματοληψίας, τέτοιο ώστε να είναι αρκετά σύντομος προκειμένου να καταγράφει αρκετές μεταβολές στην καμπύλη που δημιουργείται έως ότου ισορροπήσει το σύστημα, αλλά ταυτόχρονα να μην λαμβάνονται πολλές τιμές όσο είναι σε ισορροπία, διότι στην ισορροπία δεν μπορούμε να αντλήσουμε πληροφορίες για την συμπεριφορά και την απόκριση του κινητήρα. Ένας καλός χρόνος για δειγματοληψία για το συγκεκριμένο σύστημα είναι 0.5 sec. Επίσης για να έχει πρακτική εφαρμογή ένα τέτοιο μοντέλο, θα πρέπει οι μετρήσεις και οι υπολογισμοί που θα γίνουν σε αυτό το διάστημα να είναι εφικτοί. Δεν είναι χρήσιμο ένα μοντέλο που για να λειτουργήσει πρέπει να δειγματοληπτεί κάθε 1 ms, διότι έτσι δε θα υπάρχει αρκετός χρόνος προκειμένου να πραγματοποιηθούν υπολογισμοί.

4.2 Γραμμική μοντελοποίηση


4.2.1 Γενικά

Τα προβλήματα στα οποία προσπαθούμε να βρούμε τη σχέση μεταξύ μιας μεταβλητής X και μιας άλλης Y , όπου Y είναι η εξαρτημένη μεταβλητή και X η ανεξάρτητη ονομάζονται προβλήματα παλινδρόμησης. Η πιο απλή μορφή παλινδρόμησης που απαρτίζεται από 2 μόνο μεταβλητές ονομάζεται απλή παλινδρόμηση. Ο πιο εύκολος τρόπος για να βρούμε την σχέση ανάμεσα στις 2 μεταβλητές, είναι να έχουμε ζεύγη τιμών X, Y και απεικονίζοντας στα στο επίπεδο (Σχήμα 4.9) να βρούμε μια γραμμή η οποία θα τα πλησιάζει όσο το δυνατόν πιο κοντά στα σημεία αυτά (Σχήμα 4.10). Για παράδειγμα έστω πως το X είναι η ηλικία των ανθρώπων ενός σχολείου και Y είναι το ύψος τους. Δημιουργώντας ζεύγη των 2 μεταβλητών έχουμε:

$$X = [5, 8, 12, 15, 18]$$


$$Y = [1.10, 1.31, 1.52, 1.70, 1.76]$$

Απεικονίζοντας τις 2 μεταβλητές σε ένα ορθοκανονικό σύστημα αξόνων έχουμε:



Σχήμα 4.9 Το ύψος του πληθυσμού συναρτίζεται της ηλικίας

Ύψος σε σχέση με την ηλικία



Σχήμα 4.10 Η ευθεία της γραμμικής παλινδρόμησης που αντιπροσωπεύει τις 2 μεταβλητές

Μπορούμε να σχεδιάσουμε μία γραμμή η οποία θα είναι όσο το δυνατόν πιο κοντά σε όλα τα σημεία και σύμφωνα με την γραμμή αυτή, μέσα στα όρια των τιμών που έχουμε εισάγει (δηλαδή τιμές για την ηλικία από 5 μέχρι 15) θα μπορεί να γίνει μια πρόβλεψη για το ύψος. Η διαδικασία αυτή γίνεται μέσω της παλινδρόμησης.

Μια απλή τέτοια ευθεία είναι της μορφής $y = b_0 + bx$. Οι συντελεστές αυτής της ευθείας υπολογίζονται με την μέθοδο ελαχίστων τετραγώνων. Στην περίπτωση που οι ανεξάρτητες μεταβλητές είναι 2 ή περισσότερες η παλινδρόμηση ονομάζεται πολυμεταβλητή γραμμική παλινδρόμηση.

4.2.2 Μέθοδος ελαχίστων τετραγώνων

Η Μέθοδος των Ελαχίστων Τετραγώνων (MET) χρησιμοποιείται για την κατασκευή της γραφικής παράστασης που περιγράφει ένα φαινόμενο, όταν γνωρίζουμε μόνο μια σειρά από πειραματικές τιμές των μεγεθών που το περιγράφουν και όχι την ακριβή σχέση τους (τύπο). Στην πραγματικότητα, κατά τη μελέτη ενός φαινομένου, προσπαθούμε να προσδιορίσουμε τη μορφή της άγνωστης σχέσης, στην οποία ταιριάζουν καλύτερα τα πειραματικά μας δεδομένα, ελέγχοντας μια σειρά γνωστών σχέσεων. Στόχος της MET είναι ο προσδιορισμός των σταθερών συντελεστών ($b_0, b_1, b_2...$) της σχέσης που

επιλέξαμε για να περιγράψουμε το φαινόμενο. Η σχέση για την οποία τα πειραματικά δεδομένα προσαρμόζονται καλύτερα πάνω στη γραφική της παράσταση είναι και η ζητούμενη. Σε μια απλή εξίσωση $y = b_0 + bx$ οι συντελεστές b_0 και b υπολογίζονται ως:

$$b = \frac{\sum_{i=1}^n x_i y_i - n \cdot \bar{x} \cdot \bar{y}}{\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2} \quad 4.1.1$$

$$b_0 = \bar{y} - b \cdot \bar{x} \quad 4.1.2$$

όπου x_i, y_i μετρήσεις για τις μεταβλητές X και Y , n το πλήθος των ζευγών των μεταβλητών και \bar{x} και \bar{y} οι μέσοι όροι των αντιστοίχων μεταβλητών. Σε ένα πολυμεταβλητό παράδειγμα παλινδρόμησης η εξαρτημένη μεταβλητή με την ανεξάρτητη μπορούν να συσχετιστούν με την ακόλουθη σχέση:

$$y_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_k x_{ik} \quad 4.1.3$$

με τον πρώτο δείκτη (i) σε κάθε μεταβλητή να δείχνει τον αριθμό της παρατήρησης και τον δεύτερο την μεταβλητή. Για n παρατηρήσεις με μορφή πινάκων θα έχουμε $Y = X \cdot B$ με :

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}_{n \times 1} \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix}_{n \times (k+1)} \quad B = \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_k \end{bmatrix}_{(k+1) \times 1}$$

Ο πίνακας X περιέχει μία στήλη με τιμές 1 εξαιτίας του συντελεστή b_0 , ο οποίος είναι σταθερός όρος και όχι κάποιος συντελεστής του x_{ij} . Στη συνέχεια ο πίνακας B υπολογίζεται από με τον ακόλουθο τρόπο:

$$Y = X \cdot B$$

$$X' \cdot Y = X' \cdot X \cdot B$$

$$(X' \cdot X)^{-1} \cdot X' \cdot Y = B$$

$$\text{Άρι προκύπτει: } B = (X'X)^{-1} X'Y$$

4.1.4

4.2.3 Κανονικοποίηση μεταβλητών

Στιν στατιστική πολλές φορές όταν εξετάζουμε ανεξάρτητες μεταβλητές οι οποίες δεν αναφέρονται σε ίδια μεγέθη, ή έχουν διαφορετική τάξη μεγέθους ως αριθμοί, χρησιμοποιείται η κανονικοποίηση (normalization) των μεταβλητών. Ο λόγος για τον οποίο γίνεται αυτό είναι για να εξακριβωθεί, ποια από τις ανεξάρτητες μεταβλητές έχει μεγαλύτερη επιρροή στην εξαρτημένη μεταβλητή ώστε να εφαρμοστεί η παλινδρόμηση με μεγαλύτερη ακρίβεια. Ο τρόπος με τον οποίο επιτυγχάνεται αυτό είναι με τον υπολογισμό του μέσου όρου της εκάστοτε μεταβλητής και την αφαίρεσή του από το κάθε στοιχείο της μεταβλητής και στη συνέχεια η διαίρεσή του στοιχείο αυτού με την τυπική απόκλιση (σ), όπου σ είναι η τετραγωνική ρίζα της διασποράς, μεγέθους που δείχνει πόσο «αλωμένα» είναι τα στοιχεία της μεταβλητής.

$$\hat{x}_i = \frac{x_i - \bar{x}}{\sigma}$$

4.2

4.2.4 Στατιστικοί δείκτες MARE και R^2

Γυ την αξιολόγηση του αποτελέσματος και της αξιοπιστίας της παλινδρόμησης χρειαζόμαστε κάποιους στατιστικούς δείκτες, οι οποίοι δίνουν μια ένδειξη του σφάλματος της πρόβλεψης που παρέχει το μοντέλο σε σχέση με την πραγματική τιμή. Δύο τέτοιοι δείκτες είναι το μέσο απόλυτο σχετικό σφάλμα (Mean Absolute Relative Error, MARE) και ο συντελεστής R^2 . Ο δείκτης MARE υπολογίζει τον μέσο όρο του

απόλυτου σχετικού σφάλματος με τον τύπο:

$$MARE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad 4.3.1$$

όπου y_i είναι οι πραγματικές τιμές και \hat{y}_i η πρόβλεψη των τιμών. Δεν έχει μέγιστη τιμή και όσο πιο κοντά στο 0 είναι, τόσο καλύτερο είναι το μοντέλο το οποίο περιγράφει. Ο δείκτης R^2 υπολογίζεται ως:


$$R^2 = 1 - \frac{SSe}{SSt} \quad 4.3.2$$

$$\text{όπου } SSt = \sum_i (y_i - \bar{y})^2$$


Στην παραπάνω σχέση y_i είναι οι πραγματικές τιμές και \bar{y} ο μέσος όρος της μεταβλητής y . Επίσης

$$SSe = \sum_i (y_i - \hat{y}_i)^2$$

όπου y_i είναι οι πραγματικές τιμές και \hat{y}_i η πρόβλεψη για τις εκάστοτε τιμές. Ο δείκτης αυτός εκφράζει το ποσοστό της μεταβλητότητας της μεταβλητής Y που εξηγείται από την μεταβλητή X . Έχει μέγιστη τιμή 1 και όσο πιο κοντά στο 1 είναι, τόσο το μοντέλο που εξετάζουμε είναι πιο κοντά στις πραγματικές τιμές. Στα σχήματα 4.11 και 4.12 φαίνεται η γραμμή της παλινδρόμησης ανάμεσα στην μεταβλητή Y και την μεταβλητή X . Όσο πιο κοντά στο 1 είναι η τιμή του δείκτη R^2 τόσο η ευθεία της παλινδρόμησης θα είναι πιο κοντά στα δεδομένα.



Σχήμα 4.11 Η ευθεία της παλινδρόμησης είναι κοντά στα δεδομένα και έχει υψηλό R^2

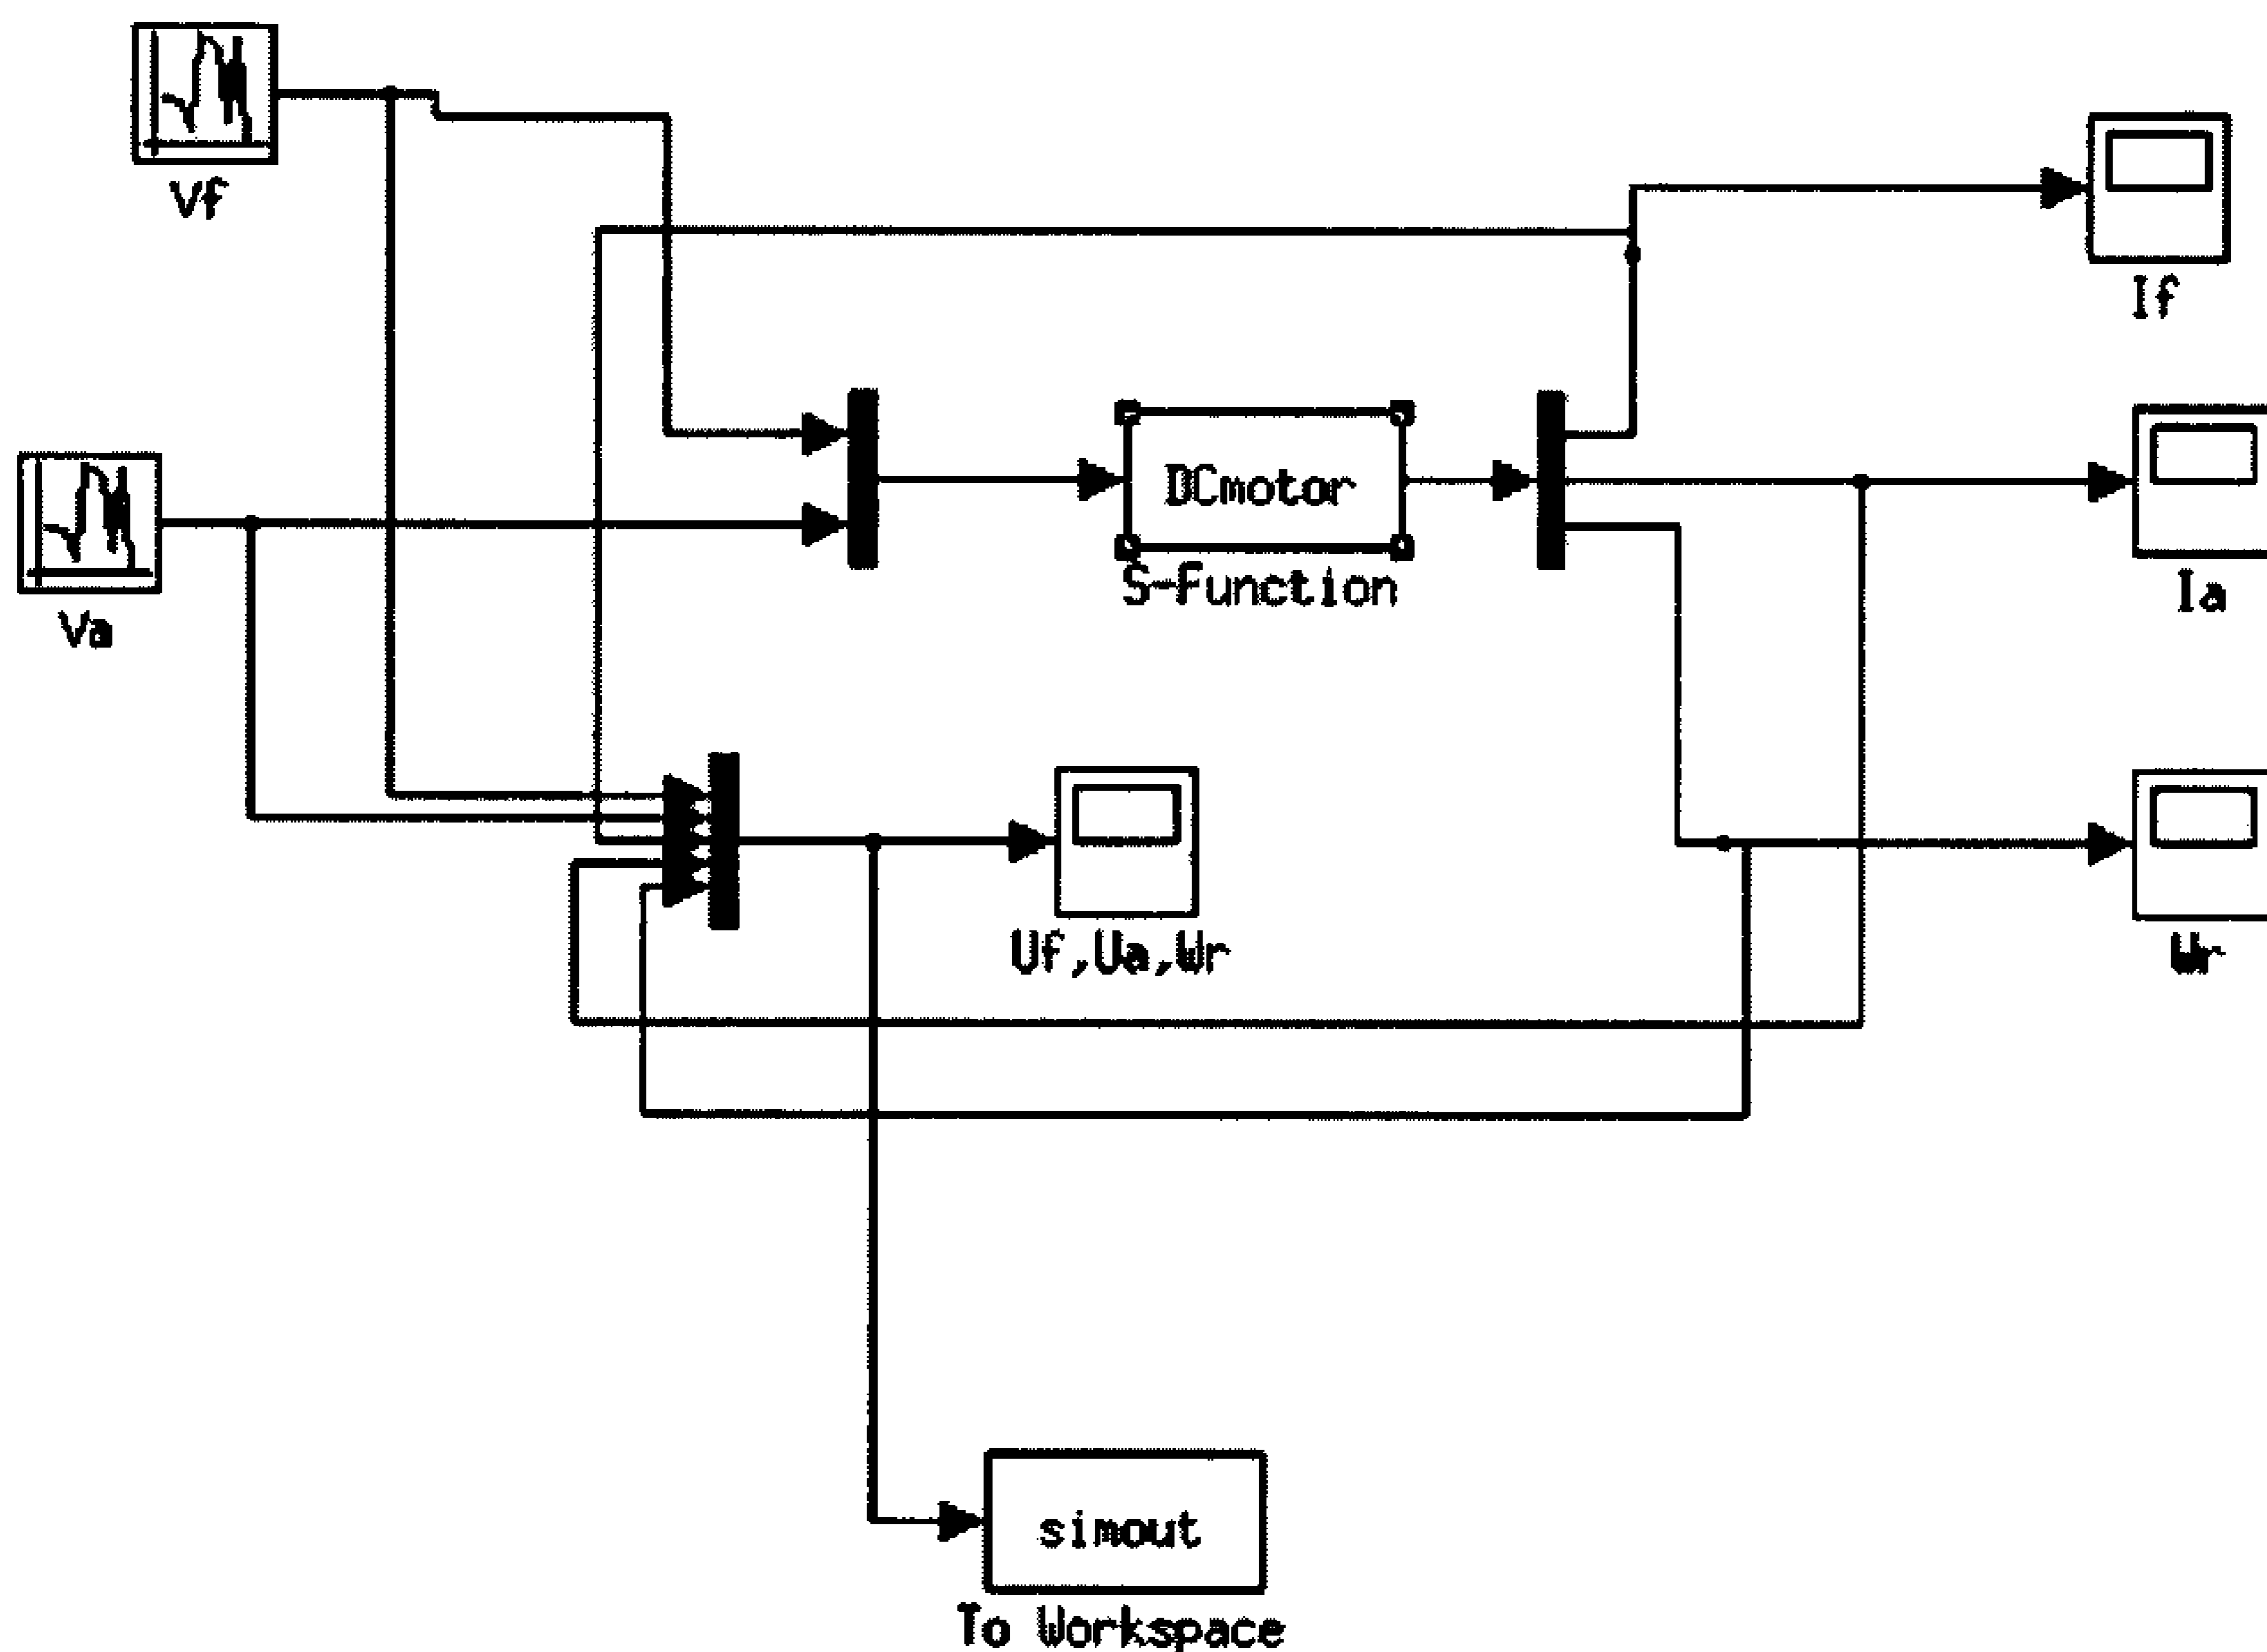


Σχήμα 4.12 Η ευθεία της παλινδρόμησης είναι μακριά από τα δεδομένα και έχει χαμηλό R^2

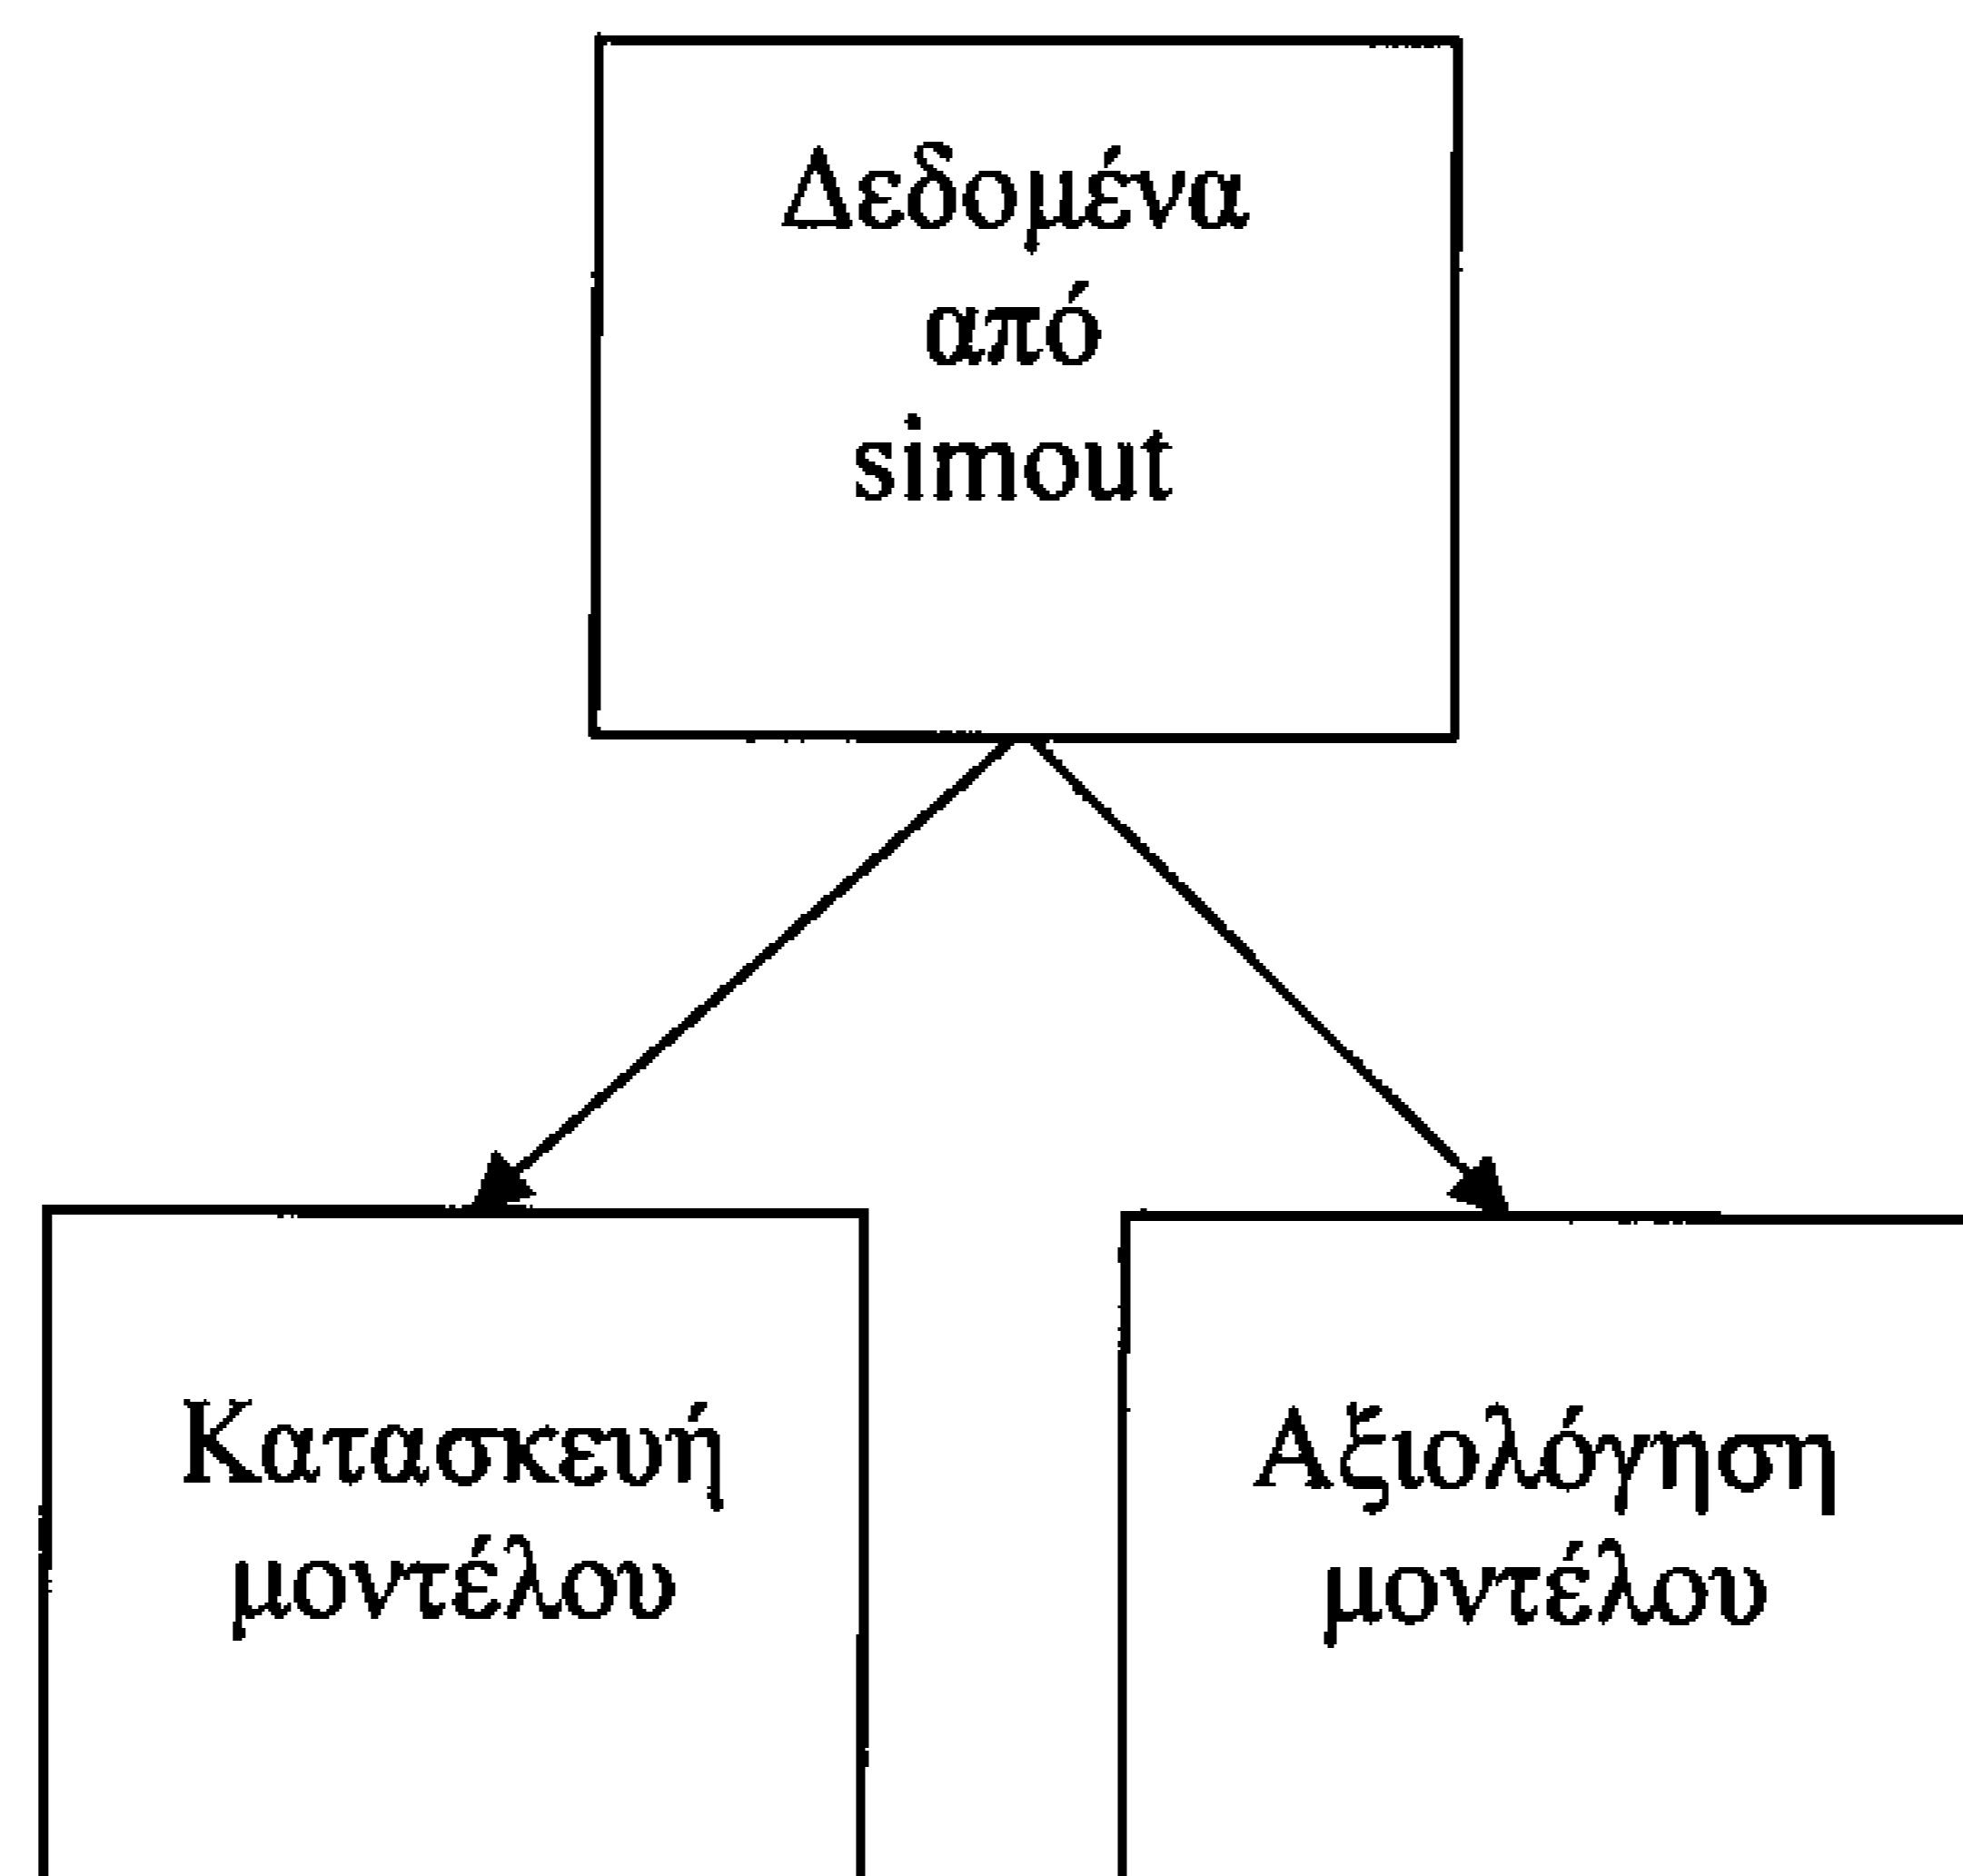
4.2.5 Μοντελοποίηση του DC κινητήρα με γραμμικό μοντέλο

Όπως αναφέρθηκε στην αρχή του κεφαλαίου, δημιουργήθηκε στο Simulink ένα διάγραμμα βαθμίδων με τον DC κινητήρα (Σχήμα 4.13), στο οποίο εισάγονται τιμές για τις 2 τάσεις (ανεξάρτητες μεταβλητές) και μετριοούνται οι τιμές των ρευμάτων και των στροφών του κινητήρα. Με αυτά τα δεδομένα μπορεί να κατασκευαστεί ένα γραμμικό μοντέλο μέσω της παλινδρόμησης που προβλέπει την συμπεριφορά του κινητήρα.

Για να αξιολογηθεί το μοντέλο πρέπει να υπάρχουν κάποια δεδομένα πραγματικών τιμών ώστε να συγκριθούν με τις προβλέψεις που θα παρέχονται από αυτό. Έτσι χωρίστηκαν τα δεδομένα που κατέγραψε το `simout` του Simulink στη μέση. Το πρώτο μισό κομμάτι είναι τα δεδομένα βάσει των οποίων θα υπολογιστεί μέσω της γραμμικής παλινδρόμησης το μοντέλο, ενώ το δεύτερο μισό θα είναι το σημείο αναφοράς για την αξιολόγηση του όπως φαίνεται στο σχήμα 4.14.



Σχήμα 4.13 Το διάγραμμα βαθμίδων που εφαρμόστηκε στο Simulink για την μοντελοποίηση του DC κινητήρα. Τα δεδομένα μαζεύονται στο `simout`



Σχήμα 4.14: Διαχωρισμός δεδομένων για να επιτευχθεί η κατασκευή και η αξιολόγηση του μοντέλου.

Η απλούστερη μορφή που θα μπορούσε να έχει το γραμμικό μοντέλο είναι $y = a_0 + a_1x_1 + a_2x_2$. Προσαρμοσμένος ο μαθηματικός τύπος στα δικά μας δεδομένα είναι:

$$w_r(k+1) = a_0 + a_1V_a(k) + a_2V_f(k) \quad 4.4$$

Αυτή η έκφραση δεν είναι ικανή να μας περιγράψει με αρκετή ακρίβεια ένα τόσο πολυσύνθετο πρόβλημα όπως είναι ο DC κινητήρας. Ο λόγος είναι πως υπάρχει εξάρτηση ανάμεσα στις μεταβλητές κατάστασης και στον τρόπο απόκρισης του κινητήρα, π.χ. για διαφορετικό σημείο ισορροπίας του συστήματος, η απόκριση θα είναι διαφορετική αν βάλουμε την ίδια είσοδο στο σύστημα. Επομένως οι μεταβλητές κατάστασης i_a , i_f και w_r μπορούν να θεωρηθούν σαν μεταβλητές εισόδου στο γραμμικό μοντέλο, αφού οι τιμές τους επηρεάζουν την απόκριση του κινητήρα. Η σχέση 4.4 αυτή αναπροσαρμόζεται σύμφωνα με τις εξισώσεις κατάστασης ως:

$$w_r(k+1) = a_0 + a_1V_a(k) + a_2V_f(k) + a_3i_f(k) + a_4i_a(k) + a_5w_r(k) \quad 4.5$$

Δηλαδή η έξοδος w_r την επόμενη χρονική στιγμή $(k+1)$ εξαρτάται από την είσοδο $u_f(k)$

την τρέχουσα χρονική στιγμή, από την είσοδο $u_a(k)$ την τρέχουσα χρονική στιγμή, και τις μεταβλητές κατάστασης του κινητήρα $i_f(k)$, $i_a(k)$, $w_r(k)$ την τρέχουσα χρονική στιγμή.

Το μοντέλο της παραπάνω σχέσης συσχετίζει την τιμή της μεταβλητής που πρόκειται να προβλέψει, με τις προηγούμενες τιμές της ίδιας της μεταβλητής καθώς και με τις μεταβλητές οι οποίες εξαρτώνται από αυτήν. Μοντέλα αυτού του τύπου λέγονται αυτοπαλίνδρομα εξωγενή (AutoRegressive eXogenous models, ARX).

Ο αλγόριθμος που περιγράφει τον υπολογισμό των συντελεστών της σχέσης 4.5 λειτουργεί ως εξής:

1. Δέχεται σαν είσοδο τα δεδομένα από το simout που προκύπτει από το Simulink
2. Δημιουργούνται οι πίνακες εισόδου και εξόδου:

$$X = [V_a, V_f, i_a, i_f, w_r]$$

$$Y = [w_r(k+1)]$$

3. Οι πίνακες αυτοί χωρίζονται στη μέση ώστε να μισά στοιχεία να χρησιμοποιηθούν για την δημιουργία των συντελεστών της παλινδρόμησης και τα υπόλοιπα μισά για την αξιολόγηση της παλινδρόμησης.
4. Στη συνέχεια τα δεδομένα των πινάκων κανονικοποιούνται ώστε η συμμετοχή της κάθε μεταβλητής στην πρόβλεψη της εξαρτημένης μεταβλητής να είναι πιο σωστή
5. Με την διαδικασία αντιστροφής πινάκων μέσω της σχέσης 4.1.4 υπολογίζεται το πίνακας A , ο πίνακας δηλαδή που περιέχει όλους δείκτες για την παλινδρόμηση (a_0, a_1, \dots, a_n)
6. Κανονικοποιείται ο πίνακας δεδομένων εισόδου που θα χρησιμοποιηθεί για την αξιολόγηση του μοντέλου επειδή οι συντελεστές A αναφέρονται σε κανονικοποιημένες τιμές
7. Στη συνέχεια γίνεται η πρόβλεψη με βάση τους κανονικοποιημένους συντελεστές
$$Y_{st} = X \cdot A$$
8. Τέλος γίνεται αποκανονικοποίηση στον πίνακα Y_{st} ώστε να πάρουμε τις πραγματικές προβλέψεις του Y

Στο τέλος του αλγόριθμου πραγματοποιείται και η μέτρηση των στατιστικών δεικτών που


Γραμμικό μοντέλο	MARE	R ²
$w_r(k+1) = a_0 + a_1V_a(k) + a_2V_f(k)$	7.253e-03	0.9602
$w_r(k+1) = a_0 + a_1V_a(k) + a_2V_f(k) + a_3i_f(k) + a_4i_a(k) + a_5w_r(k)$	1.412e-03	0.9986

Πίνακας 4.1 Σύγκριση των δύο γραμμικών μοντέλων.


αναφέρθηκαν προηγουμένως καθώς και ένα γράφημα που απεικονίζει πόσο πλησιάζουν οι τιμές που προβλέφθηκαν τις πραγματικές.

Στον πίνακα 4.1 και στα σχήματα 4.15.α 4.15.β φαίνονται τα αποτελέσματα του γραμμικού μοντέλου των σχέσεων 4.4 και 4.5:

Το πείραμα επαναλήφθηκε πολλές φορές προκειμένου να παρθούν διαφορετικά δεδομένα για τον κινητήρα και στον πίνακα απεικονίζονται οι μέσοι όροι.



Σχήμα 4.15.α Οι πραγματικές τιμές(μπλε) και οι τιμές που προέβλεψε το γραμμικό μοντέλο(κόκκινο) της σχέσης 4.4




Σχήμα 4.15.β Οι πραγματικές τιμές(μπλε) και οι τιμές που προέβλεψε το γραμμικό μοντέλο(κόκκινο) της σχέσης 4.5

4.3 Μοντελοποίηση του DC κινητήρα με νευρωνικό δίκτυο RBF

Το γραμμικό μοντέλο που δημιουργήθηκε περιγράφει αρκετά καλά τον κινητήρα, ωστόσο δε μπορεί να λάβει υπ' όψη τα μη γραμμικά χαρακτηριστικά του. Στο 2^ο κεφάλαιο αναλύθηκαν τα νευρωνικά δίκτυα RBF και ο αλγόριθμος μάθησης που θα χρησιμοποιηθεί σε αυτήν την πτυχιακή εργασία. Το βασικό πλεονέκτημα που προσφέρει το νευρωνικό δίκτυο έναντι του μοντέλου που προέκυψε από την γραμμική παλινδρόμηση είναι πως μπορεί και ερμηνεύει τα μη γραμμικά φαινόμενα που παρουσιάζει ο κινητήρας, εξαιτίας του τρόπου κατασκευής του νευρωνικού δικτύου. Στο σχήμα 4.16 φαίνεται η αδυναμία ενός απλού γραμμικού μοντέλου να ερμηνεύσει δεδομένα που έχουν μη γραμμική σχέση μεταξύ τους.

Γραμμικό μοντέλο



Σχήμα 4.16 Γραμμικό μοντέλο όταν οι 2 μεταβλητές δεν χαρακτηρίζονται από γραμμικότητα

Με τη βοήθεια του νευρωνικού δικτύου η σχέση 4.5 τροποποιείται ως εξής:

$$w_r(k+1) = NN(V_a(k), V_f(k), i_f(k), i_a(k), w_r(k)) \quad 4.6$$

όπου με NN συμβολίζουμε τη μη γραμμική συνάρτηση. Σε αντιστοιχία με το ARX μοντέλο που αναφέρθηκε προηγουμένως, που υλοποιείται από το νευρωνικό δίκτυο το μοντέλο αυτό ονομάζεται μη γραμμικό αυτοπαλίνδρομο εξωγενές (Nonlinear AutoRegressive eXogenous model, NARX).

Ο αλγόριθμος στα πρώτα στάδια υλοποίησής του μοιάζει αρκετά με τον αλγόριθμο δημιουργίας του γραμμικού μοντέλου όμως διαφοροποιείται στη συνέχεια. Παρακάτω παρουσιάζονται τα βήματα πραγματοποίησης του αλγόριθμου.

1. Δέχεται σαν είσοδο τα δεδομένα από το simout που προκύπτει από το Simulink
2. Δημιουργούνται οι πίνακες εισόδου και εξόδου:

$$X = [V_a, V_f, i_a, i_f, w_r]$$

$$Y = [w_r(k+1)]$$

3. Οι πίνακες αυτοί χωρίζονται στη μέση ώστε να μισά στοιχεία να χρησιμοποιηθούν για την δημιουργία των συντελεστών της παλινδρόμησης και τα υπόλοιπα μισά για την αξιολόγηση της παλινδρόμησης.
4. Στη συνέχεια τα δεδομένα των πινάκων κανονικοποιούνται ώστε η συμμετοχή της κάθε μεταβλητής στην πρόβλεψη της εξαρτημένης μεταβλητής να είναι πιο σωστή

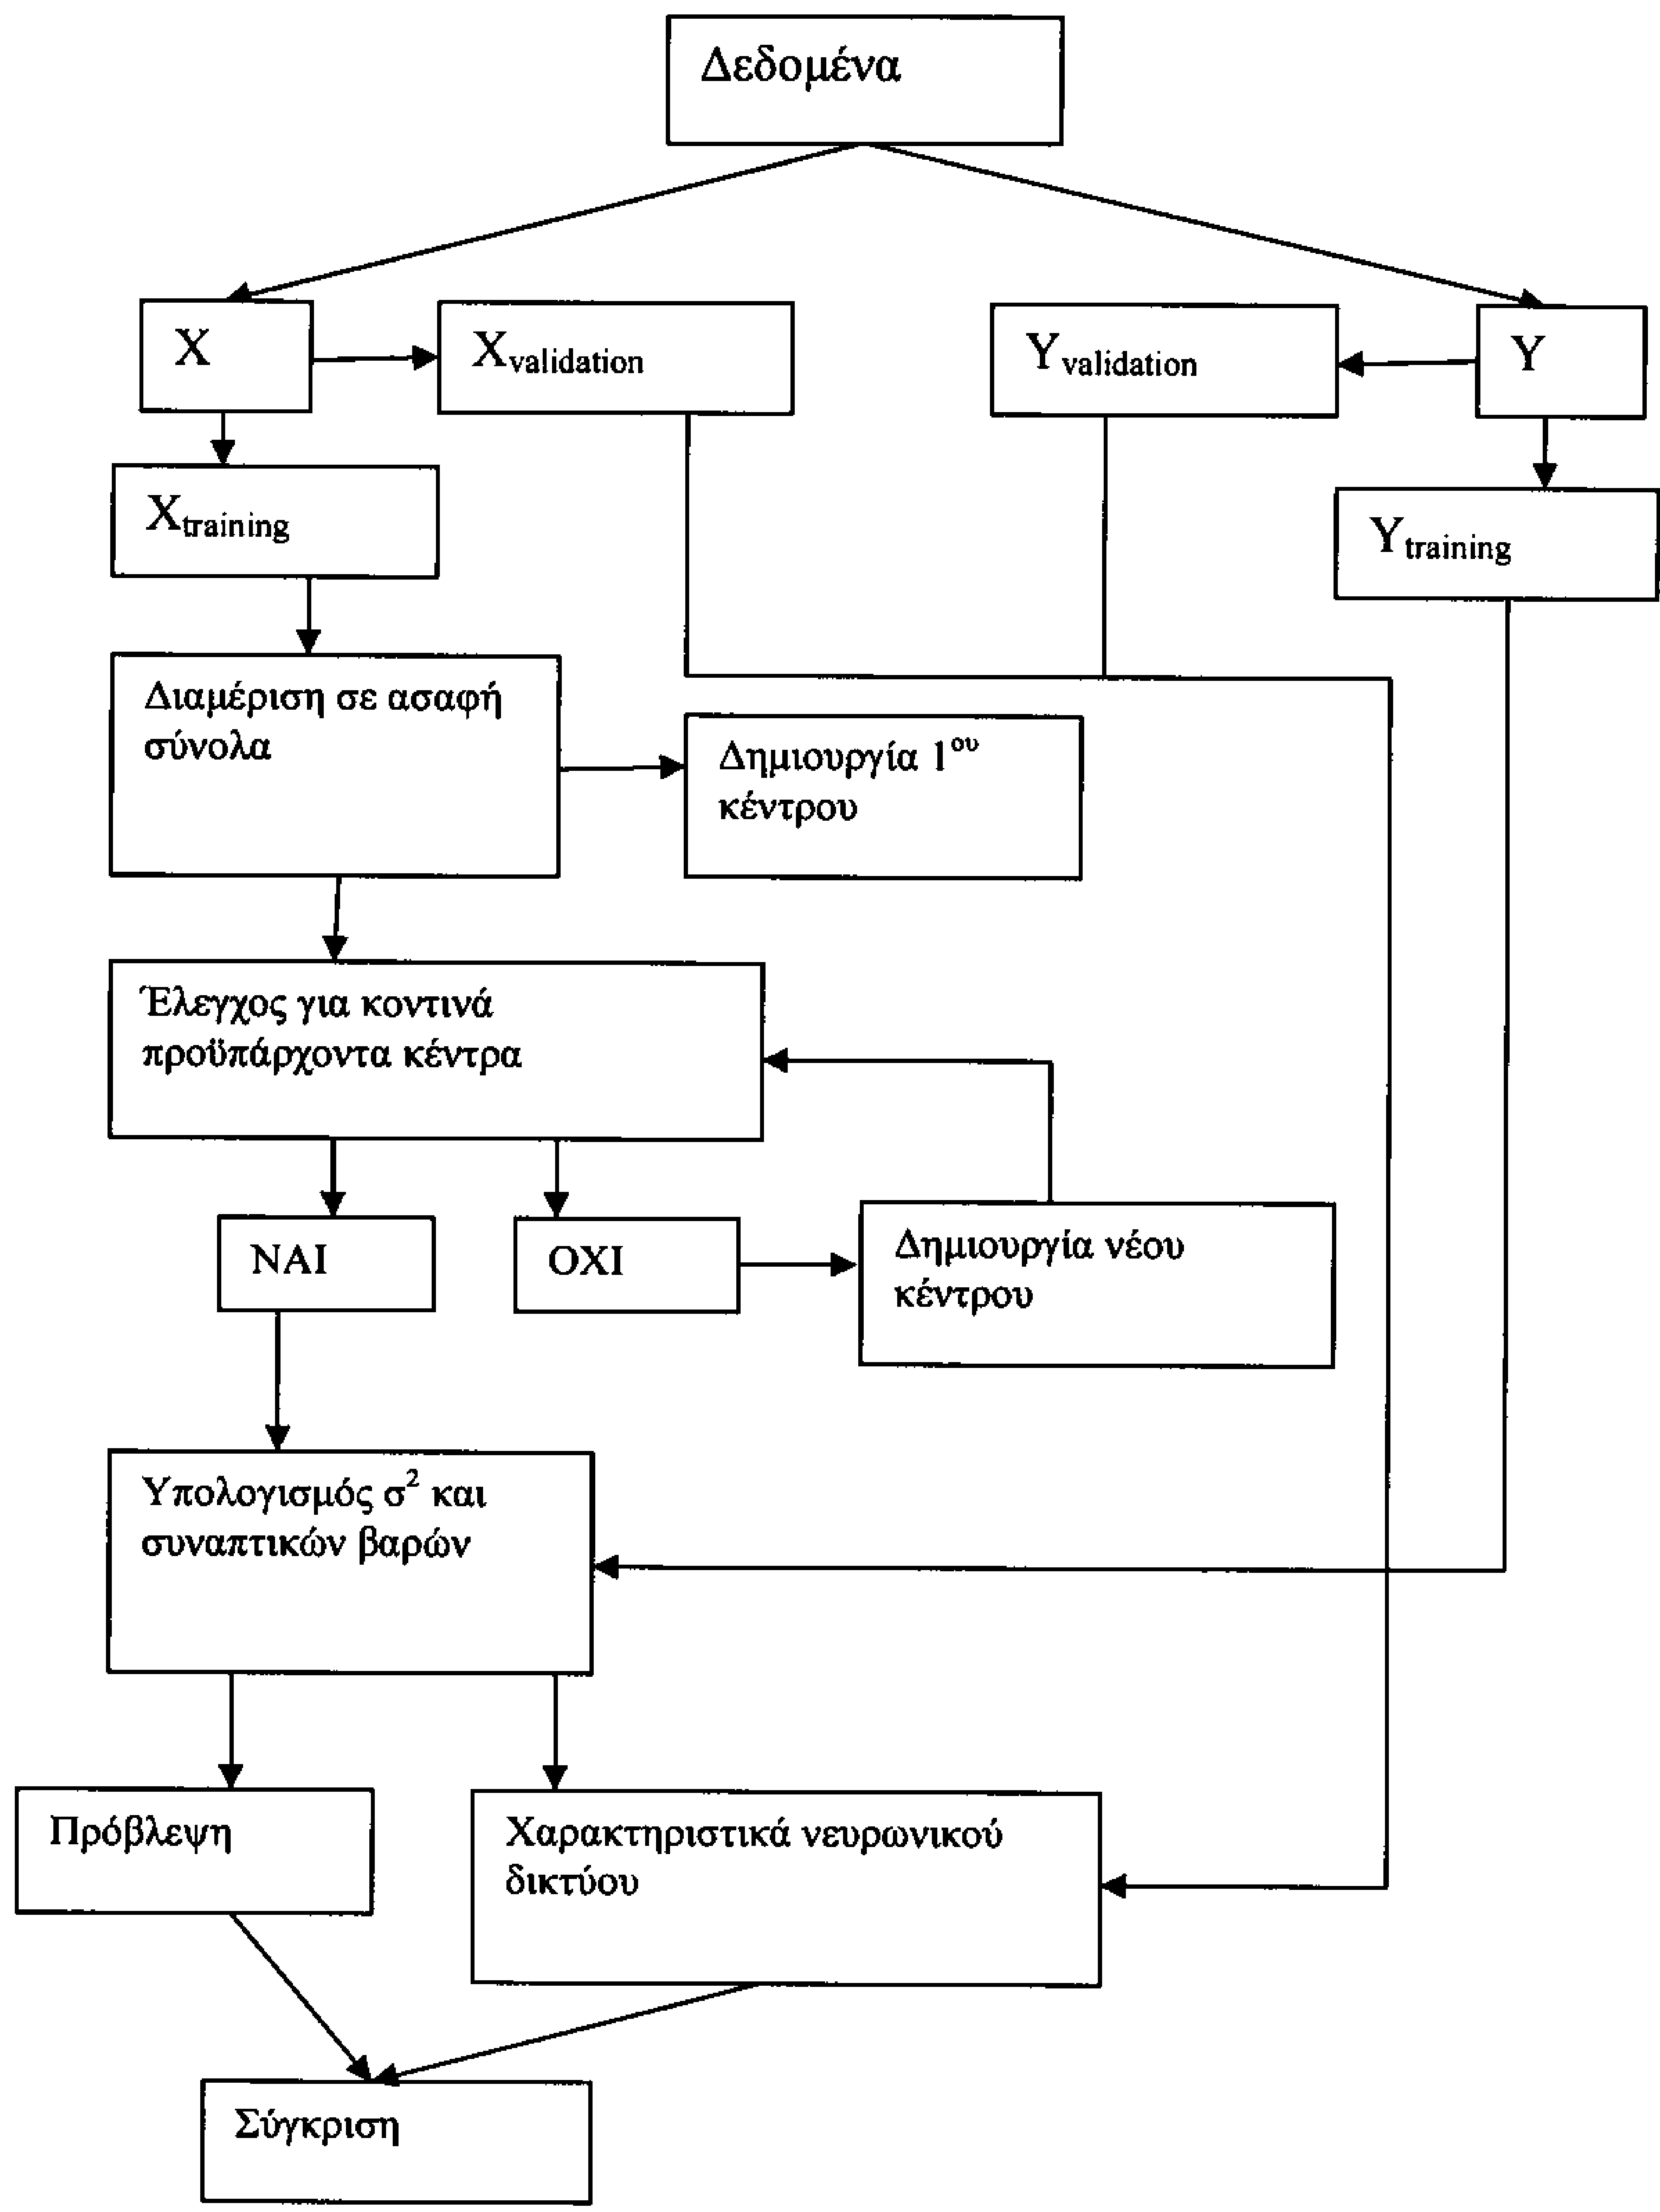
Από το βήμα αυτό αρχίζει η διαφοροποίηση και η δημιουργία του νευρωνικού δικτύου RBF

5. Ορίζεται ο αριθμός των ασαφών διαμερίσεων των διανυσμάτων εισόδου του νευρωνικού δικτύου και αναλόγως χωρίζονται οι άξονες των διανυσμάτων σε ίσα τμήματα (ασαφή σύνολα)
6. Από τις διαμερίσεις αυτές ορίζονται πόσα θα είναι τα κέντρα των ασαφών υποχώρων και επομένως τα πιθανά κέντρα του νευρωνικού δικτύου.
7. Υπολογίζεται η ακτίνα κάθε κέντρου που είναι ίδια για όλα τα κέντρα αφού οι μεταβλητές ορίζουν τετράγωνους ασαφείς υπόχωρους.
8. Στη συνέχεια εισέρχεται το πρώτο δεδομένο εισόδου και ελέγχεται ποιο είναι το κοντινότερό του κέντρο και ανατίθεται σε αυτό
9. Για τα υπόλοιπα δεδομένα εισόδου γίνεται ο εξής έλεγχος: αν υπάρχει κέντρο που έχει δημιουργηθεί από τα προηγούμενα δεδομένα και που το δεδομένο αυτό να είναι μέσα στην ακτίνα του κέντρου, τότε επιλέγεται το κοντινότερο από αυτά τα κέντρα και ανατίθεται αυτό το κέντρο στο δεδομένο. Αν δεν υπάρχει κάποιο κέντρο που η ακτίνα του να μπορεί να συμπεριλάβει το δεδομένο, τότε δημιουργείται καινούριο κέντρο με την διαδικασία του προηγούμενου βήματος.

10. Υπολογίζεται το σ^2 για όλα τα κέντρα που έχουν προκύψει από τα δεδομένα και στη συνέχεια η ενεργοποίηση του κάθε κέντρου για κάθε ένα από τα δεδομένα εισόδου (δηλαδή το κάθε δεδομένο εκφράζεται με τον συνδυασμό όλων των κέντρων) με τον τύπο : $f(x) = \exp\left(\frac{-x^2}{\sigma^2}\right)$
11. Τέλος υπολογίζονται τα συναπτικά βάρη με την μέθοδο της αντιστροφής πινάκων όπως και με το γραμμικό μοντέλο
12. Συγκρίνονται οι προβλέψεις που παρείχε το νευρωνικό δίκτυο με τις τιμές που είχαμε από το simout.

Στο σχήμα 4.17 απεικονίζεται ένα διάγραμμα ροής που παρουσιάζει συνοπτικά τον αλγόριθμο.


Η διαδικασία αυτή παράγει το νευρωνικό δίκτυο που είναι σε θέση πλέον να κάνει αξιόπιστες προβλέψεις. Επίσης παρέχεται η δυνατότητα επιλογής του πλήθους των ασαφών συνόλων που θα χρησιμοποιηθούν, μεταβάλλοντας έτσι τον αριθμό των κέντρων που θα απαρτίσουν το νευρωνικό δίκτυο . Στον πίνακα 4.2 πάρθηκαν τιμές για τα ασαφή σύνολα από 5 μέχρι 60 όπου απεικονίζονται γραφικά στα σχήματα 4.18.α και 4.18.β.




Σχήμα 4.17 Διάγραμμα ροής του αλγορίθμου.

Ασαφή Σύνολα	MARE	R ²
5	0.00849492660714893	0.963199017809521
10	0.000930135141557340	0.999533463981604
15	0.000153303259916592	0.999976311103917
20	8.31341628711459e-05	0.999993119677100
25	4.37696295618051e-05	0.999997045183148
30	3.48736460942641e-05	0.999997895068049
35	4.51915853158147e-05	0.999994776929173
40	7.31988734229243e-05	0.999989145934104
45	0.000112074893978841	0.999923100704720
50	0.000173235765810573	0.999795884183374
55	0.00359904880296255	0.889740874477007
60	0.000202018786265122	0.999738822815230

Πίνακας 4.2 Οι στατιστικοί δείκτες *MARE* και *R²* για διάφορες τιμές ασαφών συνόλων στο νευρωνικό δίκτυο.



Σχήμα 4.18.α Ο στατιστικός δείκτης *MARE* για το νευρωνικό δίκτυο




Σχήμα 4.18.β Ο στατιστικός δείκτης R^2 για το νευρωνικό δίκτυο


Επικεντρώνοντας στην περιοχή που το MARE γινόταν μικρότερο (άρα καλύτερο το μοντέλο) και το R^2 μεγαλύτερο, επαναλάβαμε την διαδικασία ανά ένα ασαφές σύνολο ώστε να βρούμε το καλύτερο νευρωνικό δίκτυο για τον συγκεκριμένο όγκο δεδομένων. Στα σχήματα 4.19 και 4.20 καθώς και στον πίνακα 4.3 φαίνονται τα αποτελέσματα.

Ασαφή Σύνολα	MARE	R ²
25	4.37696295618051e-05	0.999997045183148
26	4.99630281196499e-05	0.999996206236209
27	4.15397084262705e-05	0.999998216966960
28	3.44837198092982e-05	0.999997869988346
29	3.56864612428785e-05	0.999997591749460
30	3.48736460942641e-05	0.999997895068049
31	4.67659846871597e-05	0.999993743019448
32	4.54854389022161e-05	0.999993909371541
33	5.58699281483593e-05	0.999994080382425
34	3.93204514185935e-05	0.999996245535864
35	4.51915853158147e-05	0.999994776929173
36	0.000109969005091728	0.999943777159030
37	6.86155841186830e-05	0.999986822256384
38	7.39589331717468e-05	0.999982810958046
39	4.74429700793851e-05	0.999995967368084
40	7.31988734229243e-05	0.999989145934104

Πίνακας 4.3 Οι στατιστικοί δείκτες MARE και R² για 25-40 ασαφή συνόλα στο νευρωνικό δίκτυο.



Σχήμα 4.19 Ο στατιστικός δείκτης MARE για ασαφή σύνολα 25-40




Σχήμα 4.20 Ο στατιστικός δείκτης R² για ασαφή σύνολα 25-40

Από τις μετρήσεις φαίνεται πως το καλύτερο νευρωνικό δίκτυο προκύπτει για 28 και 30 ασαφή σύνολα με ελάχιστες διαφορές. Συγκεκριμένα συγκρίνοντάς το με το γραμμικό μοντέλο λαμβάνουμε τα αποτελέσματα του πίνακα 4.4 καθώς και την πρόβλεψη που απεικονίζεται στο σχήμα 4.21:

Μοντέλο	MARE	R ²
Γραμμικό μοντέλο 1	7.253e-03	0.9602
Γραμμικό μοντέλο 2	1.412e-03	0.9986
Νευρωνικό με 28 ασαφή σύνολα	3.448e-05	0.99999786
Νευρωνικό με 30 ασαφή σύνολα	3.487e-05	0.99999789

Πίνακας 4.4 Σύγκριση γραμμικών μοντέλων και του νευρωνικού δικτύου με 28 και 30 ασαφή σύνολα.



Σχήμα 4.21 Οι προβλέψεις του νευρωνικού δικτύου με 30 ασαφή σύνολα.

Όπως φαίνεται από τις μετρήσεις το νευρωνικό δίκτυο στον στατιστικό δείκτη MARE είναι 3 τάξεις μεγέθους καλύτερο από το γραμμικό, αντιστοίχως και στον δείκτη R^2 . Στο σχήμα 4.21 μάλιστα δεν φαίνεται με γυμνό μάτι οι διαφορές των προβλέψεων από τις πραγματικές τιμές. Αυτό οφείλεται στο γεγονός πως τα μη γραμμικά φαινόμενα που παρουσιάζει ο κινητήρας δεν μπορούν να περιγραφούν από το γραμμικό μοντέλο, ενώ το νευρωνικό δίκτυο μπορεί και τα ερμηνεύει. Αναμφισβήτητα λοιπόν το νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί για την πρόβλεψη σύνθετων και μη γραμμικών συστημάτων στα οποία δε γνωρίζουμε τους νόμους που το περιγράφουν αλλά μόνο ζεύγη μεταβλητών εισόδου-εξόδου από αυτά.

ΚΕΦΑΛΑΙΟ 5^ο


ΑΥΤΟΜΑΤΟΣ ΕΛΕΓΧΟΣ ΜΗ ΓΡΑΜΜΙΚΟΥ ΚΙΝΗΤΗΡΑ ΜΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ RBF

5.1 Εισαγωγή στον αυτόματο έλεγχο

Τα συστήματα αυτομάτου ελέγχου βασίζονται στην θεωρία της ανατροφοδότησης και στη γραμμική ανάλυση συστημάτων. Μπορούν να χρησιμοποιηθούν στον έλεγχο χημικών, ηλεκτρολογικών και μηχανικών συστημάτων. Ένα σύστημα αυτόματου ελέγχου είναι η διασύνδεση στοιχείων που δημιουργούν μια διάταξη που θα παρέχει την επιθυμητή απόκριση του συστήματος (Dorf and Bishop 2011).

Η αρχή με την οποία γίνεται συνήθως η ανάλυση του συστήματος στηρίζεται στην γραμμική θεωρία συστημάτων, η οποία θεωρεί πως υπάρχει μια σχέση αιτίας – αποτελέσματος στα μέρη του συστήματος. Με βάση αυτή τη λογική, ένα εξάρτημα ή μια διεργασία που θα εφαρμοστεί έλεγχος μπορεί να θεωρηθεί ως μια βαθμίδα (Σχήμα 5.1). Η σχέση εισόδου – εξόδου αντιπροσωπεύει τη σχέση αιτίας – αποτελέσματος της διεργασίας, η οποία με τη σειρά της αντιπροσωπεύει μια επεξεργασία του σήματος εισόδου που παρέχει ένα σήμα εξόδου. Τα συστήματα αυτομάτου ελέγχου μπορούν να διακριθούν σε δύο κατηγορίες, στα συστήματα ανοιχτού και κλειστού βρόγχου.

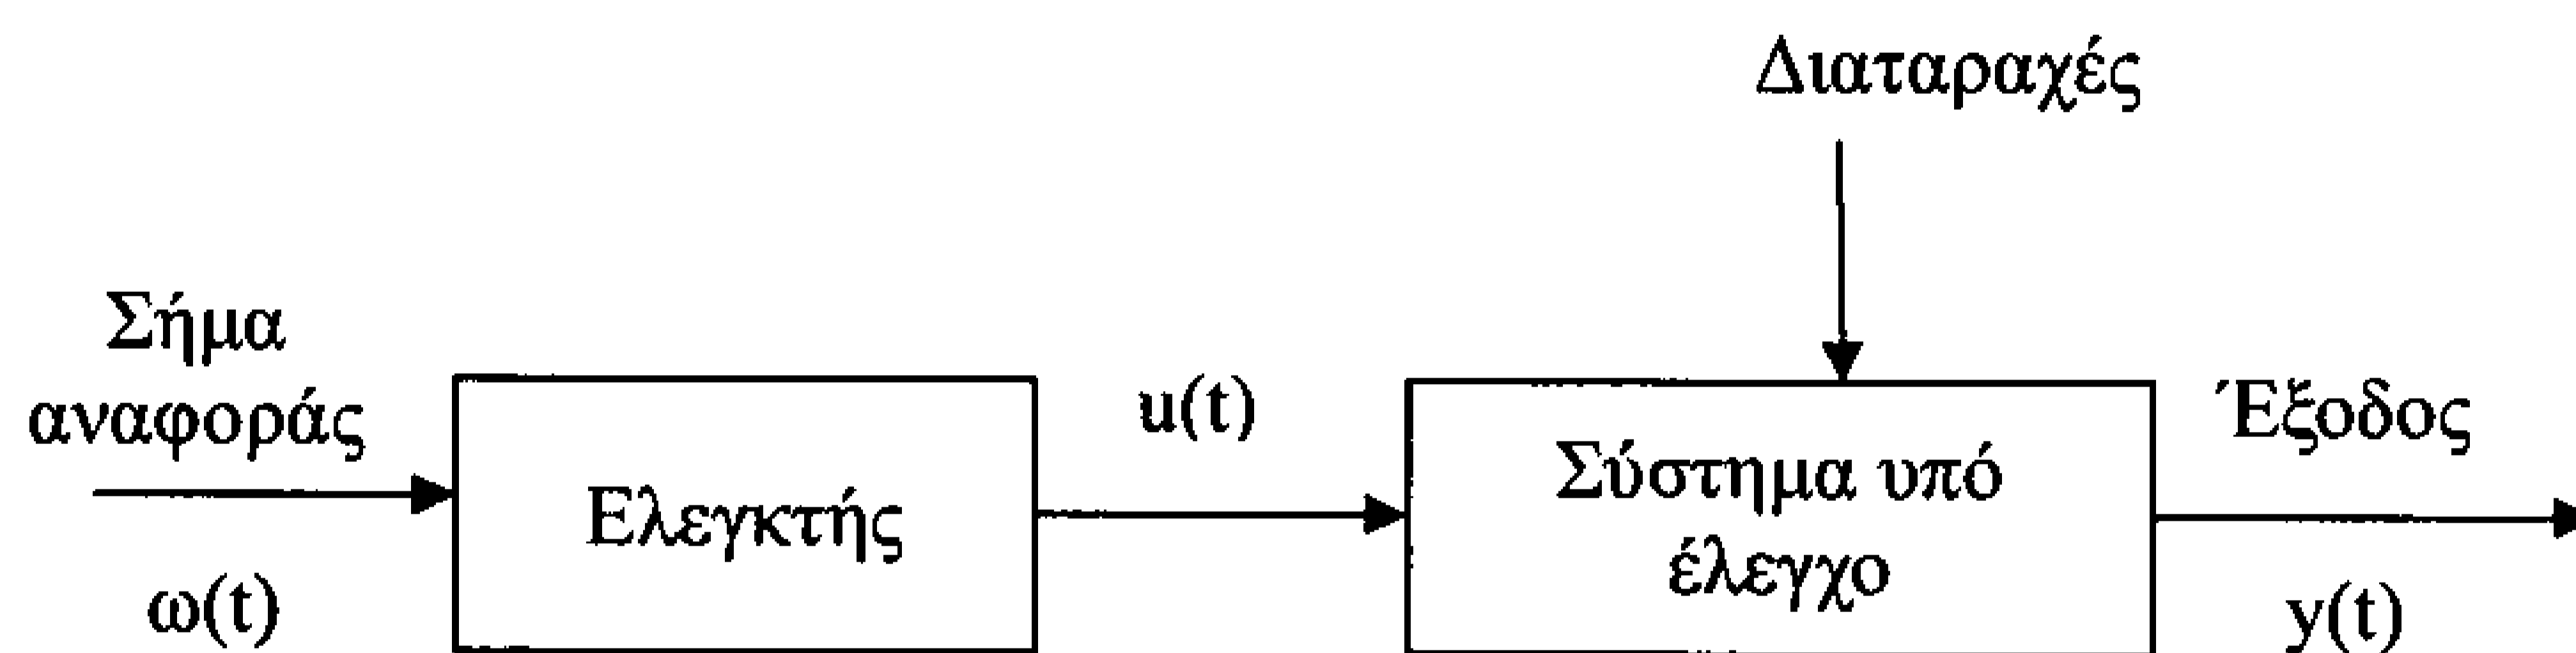
Ένα σύστημα ελέγχου ανοιχτού βρόγχου χρησιμοποιεί έναν ελεγκτή ώστε να παρέχει την επιθυμητή απόκριση, όπως φαίνεται στο σχήμα 5.2.α Το σύστημα αυτό είναι ένα σύστημα χωρίς ανατροφοδότηση, δηλαδή η είσοδος δεν είναι συνάρτηση της εξόδου.



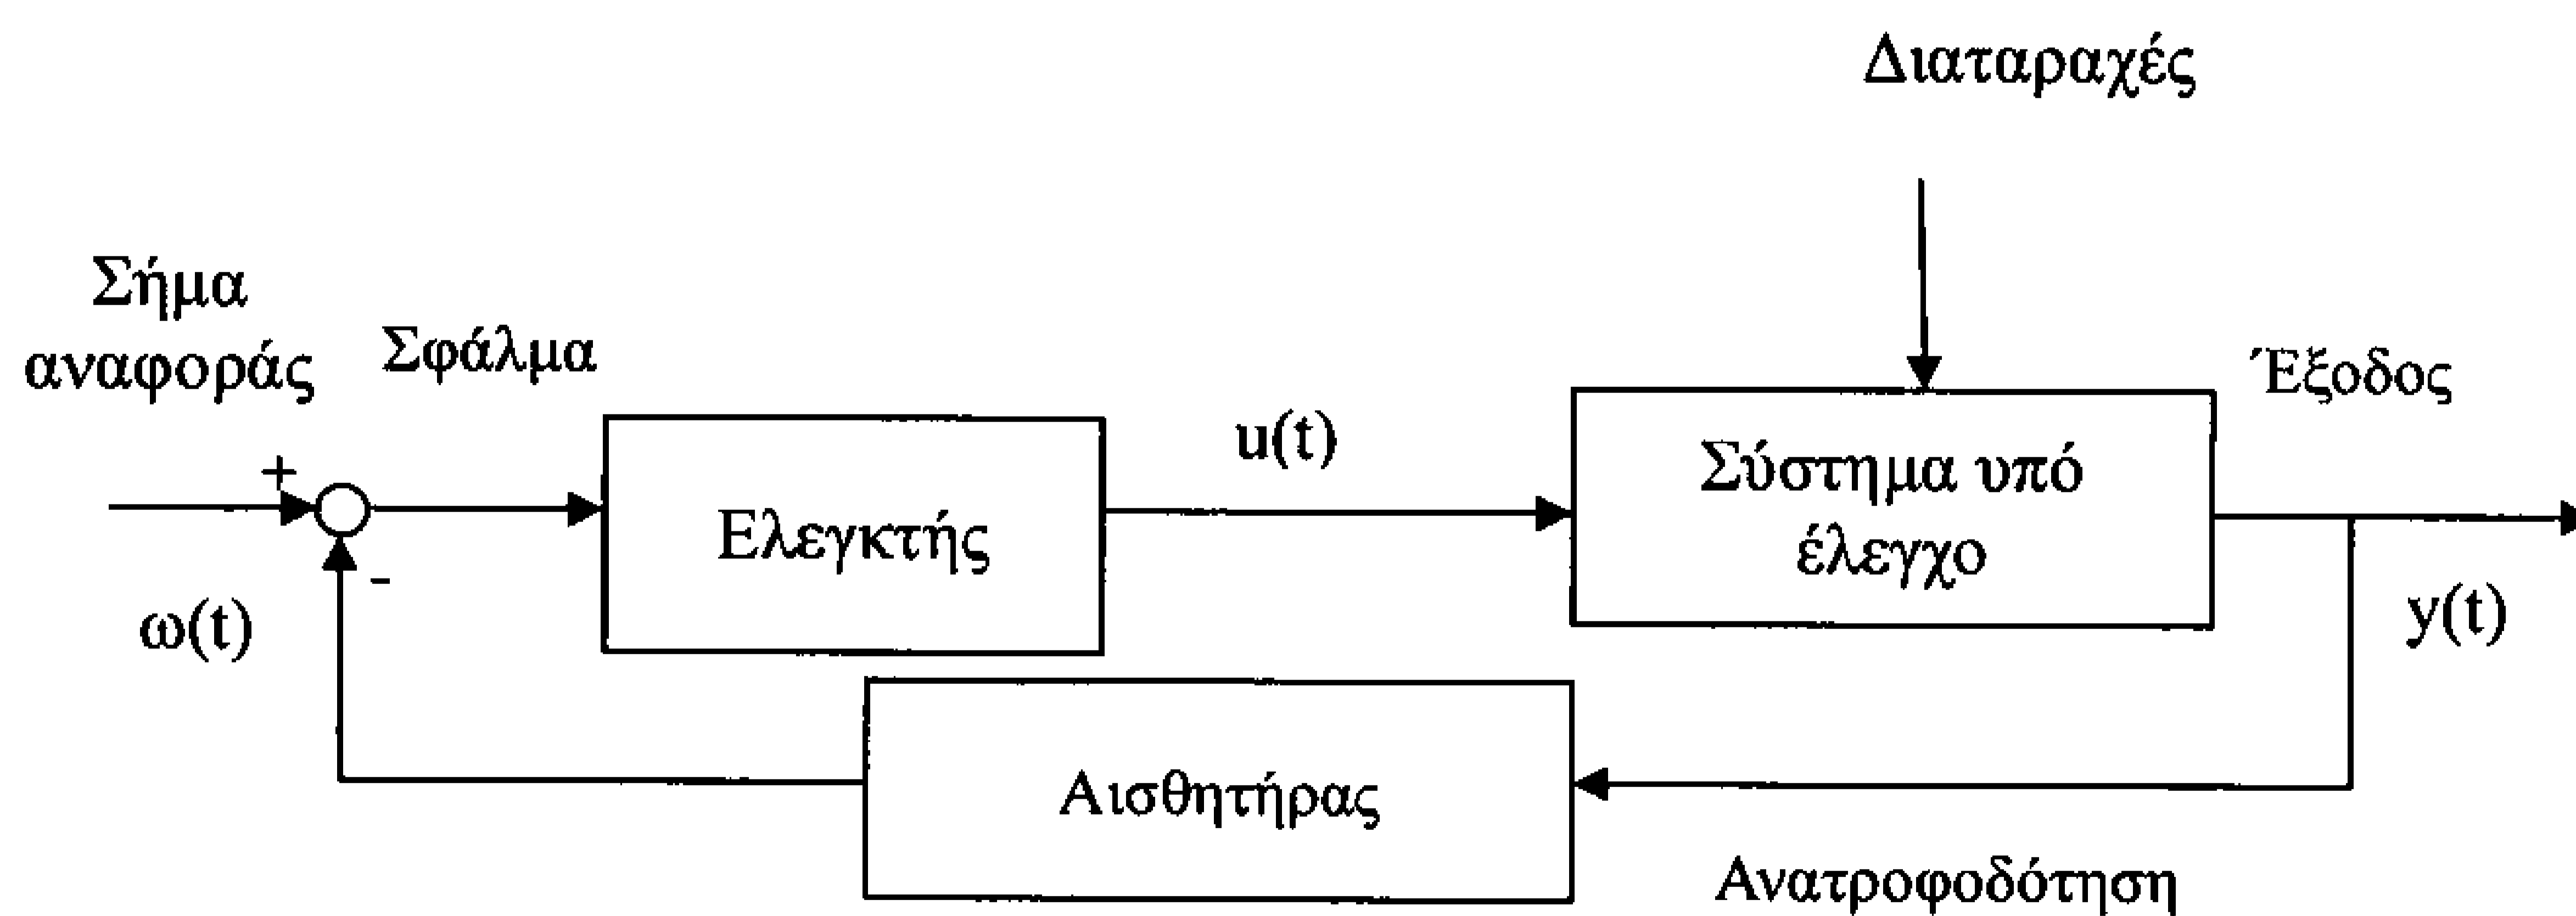
Σχήμα 5.1 Σύστημα εισόδου - εξόδου

Σε αντίθεση με τα συστήματα ελέγχου ανοιχτού βρόγχου, ένα σύστημα ελέγχου κλειστού βρόγχου λαμβάνει υπόψη την τιμή της εξόδου και την συγκρίνει με την επιθυμητή τιμή που θέλει να οδηγήσει το σύστημα. Αυτή η τιμή της εξόδου λέγεται σήμα ανατροφοδότησης. Ένα απλό σύστημα ελέγχου κλειστού βρόγχου παρουσιάζεται στο σχήμα 5.2.β.

Ένα σύστημα ελέγχου με ανατροφοδότηση συχνά χρησιμοποιεί μια συνάρτηση η οποία περιέχει μια προκαθορισμένη σχέση ανάμεσα στην έξοδο και το σήμα αναφοράς για να ελέγξει τη διαδικασία. Συνήθως η διαφορά ανάμεσα στην έξοδο και του σήματος αναφοράς είναι ενισχυμένη και χρησιμοποιείται για τον έλεγχο του συστήματος με σκοπό την συνεχή μείωσή της. Η έννοια της ανατροφοδότησης είναι το θεμέλιο για την ανάλυση και τον σχεδιασμό των συστημάτων ελέγχου.



Σχήμα 5.2.α Σύστημα ελέγχου ανοιχτού βρόγχου



Σχήμα 5.2.β Σύστημα ελέγχου κλειστού βρόγχου

5. 2 Συμβατικοί ελεγκτές - Ελεγκτής PID

5.2.1 Γενικά

Μια μορφή ελεγκτή που είναι ιδιαίτερα διαδεδομένη στον έλεγχο στον τομέα της βιομηχανίας είναι ο αποτελούμενος από τρεις όρους ελεγκτής PID. Η συνάρτηση μεταφοράς ενός τέτοιου ελεγκτή είναι:

$$G_c(s) = K_p + \frac{K_I}{s} + s \cdot K_D \quad 5.1$$

Η εξίσωση για την έξοδο συναρτήσει του χρόνου είναι:

$$u(t) = K_p e(t) + K_I \int e(t) dt + K_D \frac{de(t)}{dt} \quad 5.2$$

Ο ελεγκτής τριών όρων ονομάζεται PID ελεγκτής διότι περιέχει έναν αναλογικό (Proportional), έναν ολοκληρωτικό (Integral) και έναν διαφορικό (Derivative) όρο, τα K_p , K_I και K_D αντίστοιχα. Η συνάρτηση μεταφοράς του διαφορικού όρου είναι:

$$G_d(s) = \frac{K_D s}{\tau_d s + 1} \quad 5.3$$

Ο όρος τ_d είναι συνήθως πολύ μικρότερος από τις σταθερές χρόνου της ίδιας της διαδικασίας, γι' αυτό σκόπιμα παραλείπεται.


Θεωρώντας τον PID ελεγκτή:

$$G_c(s) = K_p + \frac{K_I}{s} + K_D s = \frac{K_D s^2 + K_p s + K_I}{s} = \frac{K_D (s^2 + a s + b)}{s} = \frac{K_D (s + z_1)(s + z_2)}{s} \quad 5.4$$

Όπου $a = K_p / K_D$ και $b = K_I / K_D$. Επομένως ένας PID ελεγκτής εισάγει μια συνάρτηση μεταφοράς με έναν πόλο και δύο μηδενικά που μπορεί να βρίσκονται οπουδήποτε στο σύστημα αξόνων των πραγματικών και φανταστικών αριθμών.

5.2.2 Βαθμονόμηση (tuning)

Η χρήση του PID ελεγκτή σε ένα σύστημα αυτομάτου ελέγχου, απαιτεί τον καθορισμό των παραμέτρων K_p , K_i και K_d . Το Simulink του Matlab προσφέρει έναν αυτοματοποιημένο τρόπο εύρεσης των παραμέτρων αυτών, μέσω του εργαλείου PID Tuner (The Math Works 1994-2011). Το εργαλείο αυτό δίνει την δυνατότητα της επιλογής των παραμέτρων ώστε να επιτευχθεί ένας ελεγκτής που προσφέρει ταχύτητα και ευστάθεια στο σύστημα (Σχήμα 5.3). Η αυτοματοποιημένη διαδικασία πραγματοποιείται σε διάφορα στάδια. Επειδή η εύρεση των παραμέτρων χρησιμοποιεί γραμμικό τρόπο προσέγγισης, στην περίπτωση που ο έλεγχος αναφέρεται σε μη γραμμικά συστήματα, αρχικά γραμμικοποιείται το σύστημα γύρω από ένα σημείο λειτουργίας. Το σημείο αυτό λαμβάνεται από τις αρχικές συνθήκες που υπάρχουν στο σύστημα. Επειδή είναι πιθανό οι αρχικές συνθήκες να μην αναφέρονται σε περιοχή μόνιμης κατάστασης του συστήματος, υπάρχει η δυνατότητα επιλογής χρονικής περιόδου ώστε ο καθορισμός των παραμέτρων να γίνει σε περιοχή μόνιμης κατάστασης.



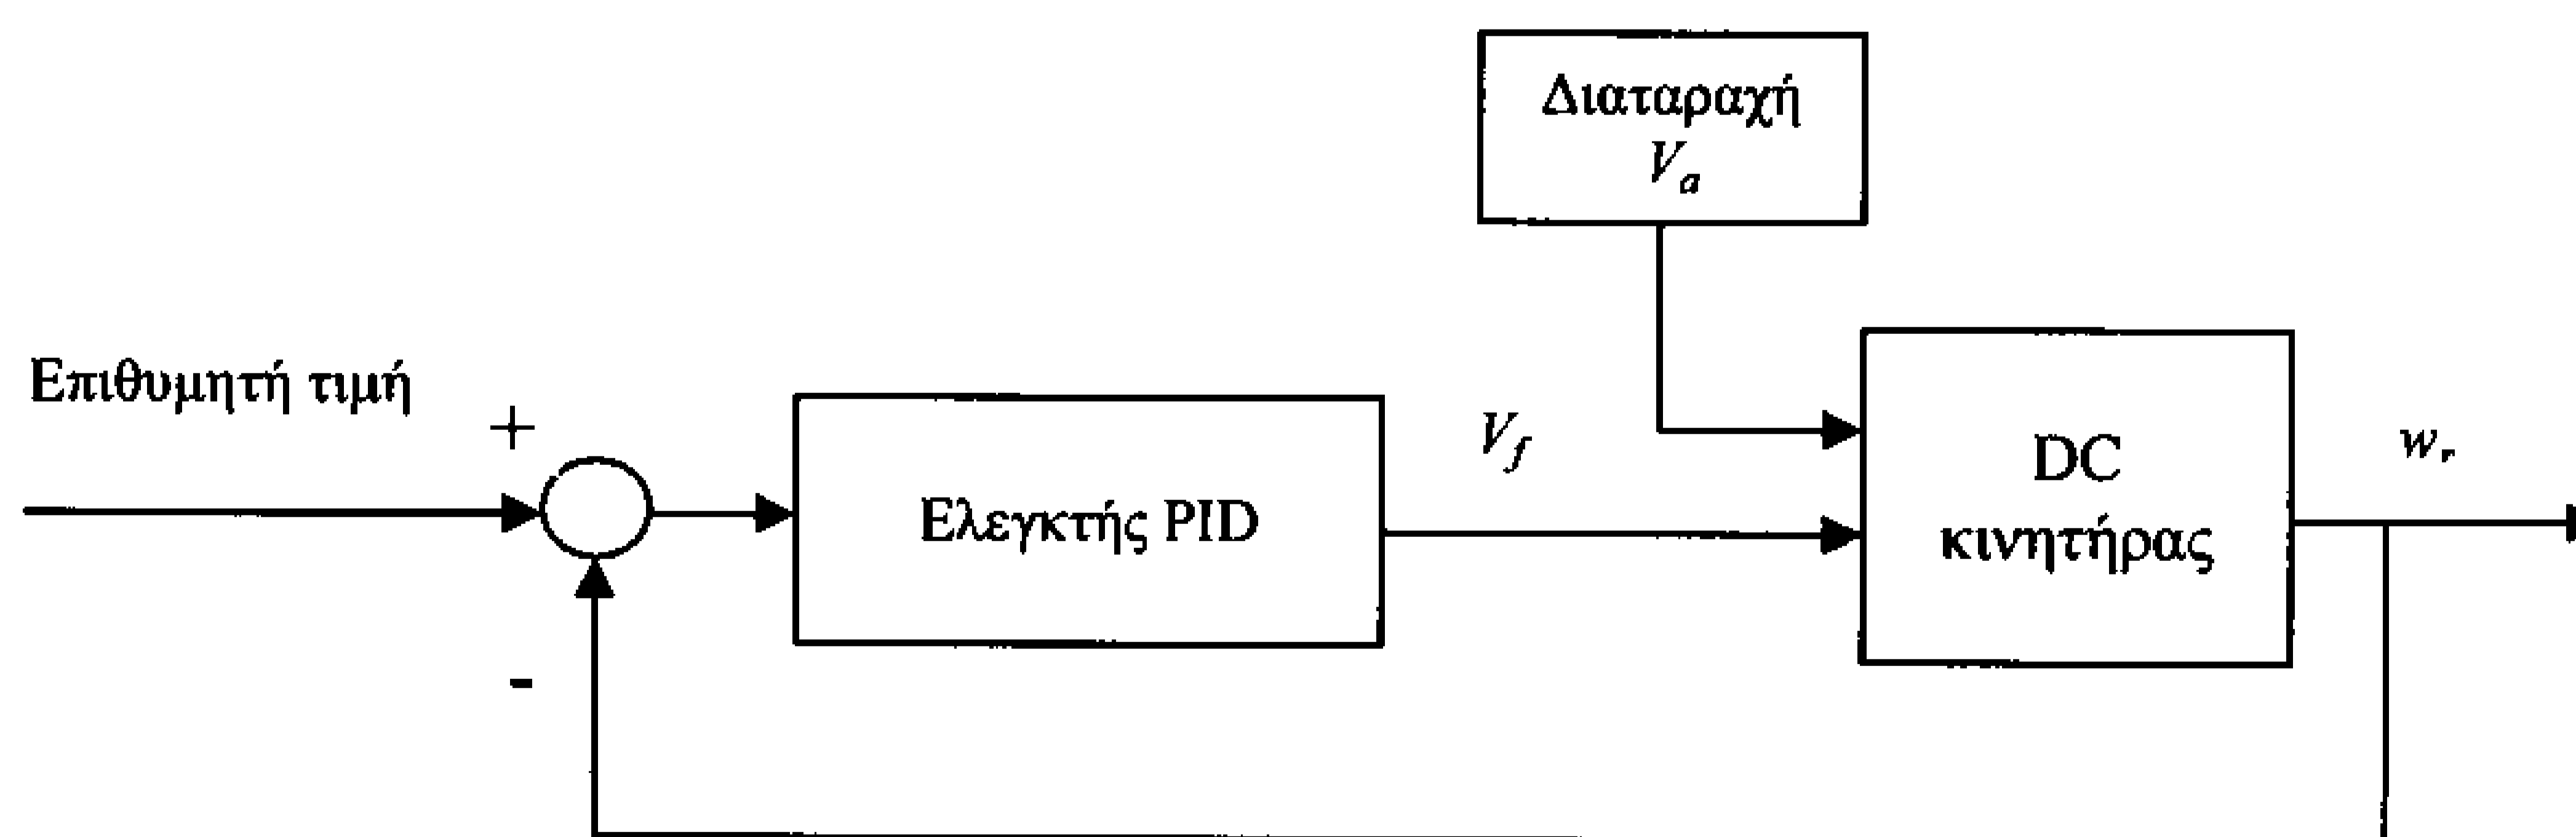
Σχήμα 5.3 Επιλογές για ρύθμιση παραμέτρων του PID ελεγκτή μέσα από το εργαλείο tuning του Simulink.

Στη συνέχεια πραγματοποιείται ο αλγόριθμος εύρεσης των παραμέτρων κατά τον οποίο σχεδιάζεται ένας αρχικός ελεγκτής, ο οποίος προσφέρει έναν συνδυασμό ταχύτητας και ευστάθειας με βάση την απόκριση συχνότητας σε ανοιχτό βρόγχο του συστήματος. Σε αυτόν τον ελεγκτή δίνεται η δυνατότητα επιλογής χρόνου απόκρισης, εύρους ζώνης και περιθωρίου φάσης. Τέλος, αφού πραγματοποιηθούν τυχόν αλλαγές στις παραπάνω επιλογές, υπολογίζονται εκ νέου οι παράμετροι K_p , K_i , K_d .

5.3 Αυτόματος έλεγχος μη γραμμικού DC κινητήρα

Στα προηγούμενα κεφάλαια μελετήθηκε ένας μη γραμμικός DC κινητήρας μέσω της επίλυσης των διαφορικών εξισώσεων που τον συνθέτουν και υλοποιήθηκε εικονικά μέσω του Simulink του Matlab. Στη συνέχεια μοντελοποιήθηκε η δυναμική συμπεριφορά του με ένα νευρωνικό δίκτυο RBF. Σε αυτό το κεφάλαιο στόχος είναι ο αυτόματος έλεγχος του κινητήρα, χρησιμοποιώντας έναν νευρωνικό ελεγκτή (neural controller), δηλαδή ένα νευρωνικό δίκτυο που θα δέχεται σαν είσοδο το σφάλμα και θα παράγει σαν έξοδο την τάση που θα οδηγήσει τον κινητήρα στην επιθυμητή κατάσταση.

Όταν πραγματοποιείται αυτόματος έλεγχος στον DC κινητήρα, σκοπός είναι η διατήρηση των στροφών του ω_r στην επιθυμητή τιμή, χρησιμοποιώντας την τάση V_f ως μεταβλητή εκχειρισμού. Η τάση στα άκρα του ρότορα V_a μπορεί να θεωρηθεί ως εξωτερική διαταραχή. Ο κλασικός τρόπος ελέγχου του DC κινητήρα παρουσιάζεται στο σχήμα 5.4.




Σχήμα 5.4 Το διάγραμμα βαθμίδων αυτομάτου ελέγχου του κινητήρα από τον PID ελεγκτή.

Ο ελεγκτής PID δέχεται σαν είσοδο την τιμή των στροφών του κινητήρα καθώς και την επιθυμητή τιμή των στροφών και σύμφωνα με την διαφορά τους, παράγει την τάση εκχειρισμού V_f , τέτοια ώστε να μηδενίσει την διαφορά αυτή.

Επειδή ο στόχος του προτεινόμενου αυτομάτου ελέγχου ήταν ο έλεγχος των στροφών, διερευνήθηκε η επίδραση των μεταβλητών V_a και V_f σε αυτές. Στο κεφάλαιο 3 διαπιστώθηκε πως η τάση εισόδου V_a συμπεριφέρεται σχεδόν γραμμικά σε σχέση με τις στροφές του κινητήρα (Σχήμα 3.14), ενώ η τάση V_f είναι φανερά μη γραμμική (Σχήμα 3.13). Εξαιτίας αυτής της συμπεριφοράς των τάσεων αποφασίστηκε πως πρέπει να ισχύουν 2 συνθήκες οι οποίες απεικονίζονται στο Σχήμα 5.5:

- Οι τιμές εκπαίδευσης της τάσης V_f θα πρέπει να είναι τέτοιες ώστε να μπορούν να μεταβάλουν τις στροφές του κινητήρα από την ελάχιστη ως την μέγιστη.
- Οι τιμές εκπαίδευσης της τάσης V_a θα πρέπει να είναι μεγάλες, ώστε να οδηγούν σε υψηλές στροφές τον κινητήρα, αλλά ταυτόχρονα να έχουν μικρή διασπορά ώστε να μην επηρεάζουν σε μεγάλο βαθμό τον αριθμό των στροφών.

Όπως φαίνεται στα διαγράμματα εάν η τάση V_a είναι μικρή, τότε η V_f δεν είναι ικανή να ρυθμίσει τον κινητήρα σε μεγάλη διακύμανση στροφών, αφού προκαλώντας μη γραμμική εξάρτηση των στροφών υπάρχει ένα μέγιστο σε αυτές. Παράλληλα αν έχει μεγάλη μεταβολή αυτή η τάση (V_a) τότε παίζει καθοριστικό ρόλο στον αριθμό των στροφών επομένως ο κινητήρας είναι αδύνατον να ελεγχθεί από την V_f . Επομένως εξασφαλίζοντας πως οι 2 συνθήκες που προαναφέρθηκαν ισχύουν, μπορεί να επιτευχθεί έλεγχος με την V_f .



Σχήμα 5.5 Η απόκριση του κινητήρα συναρτήσει της τάσης V_f για διαφορετικές τιμές της τάσης V_a .

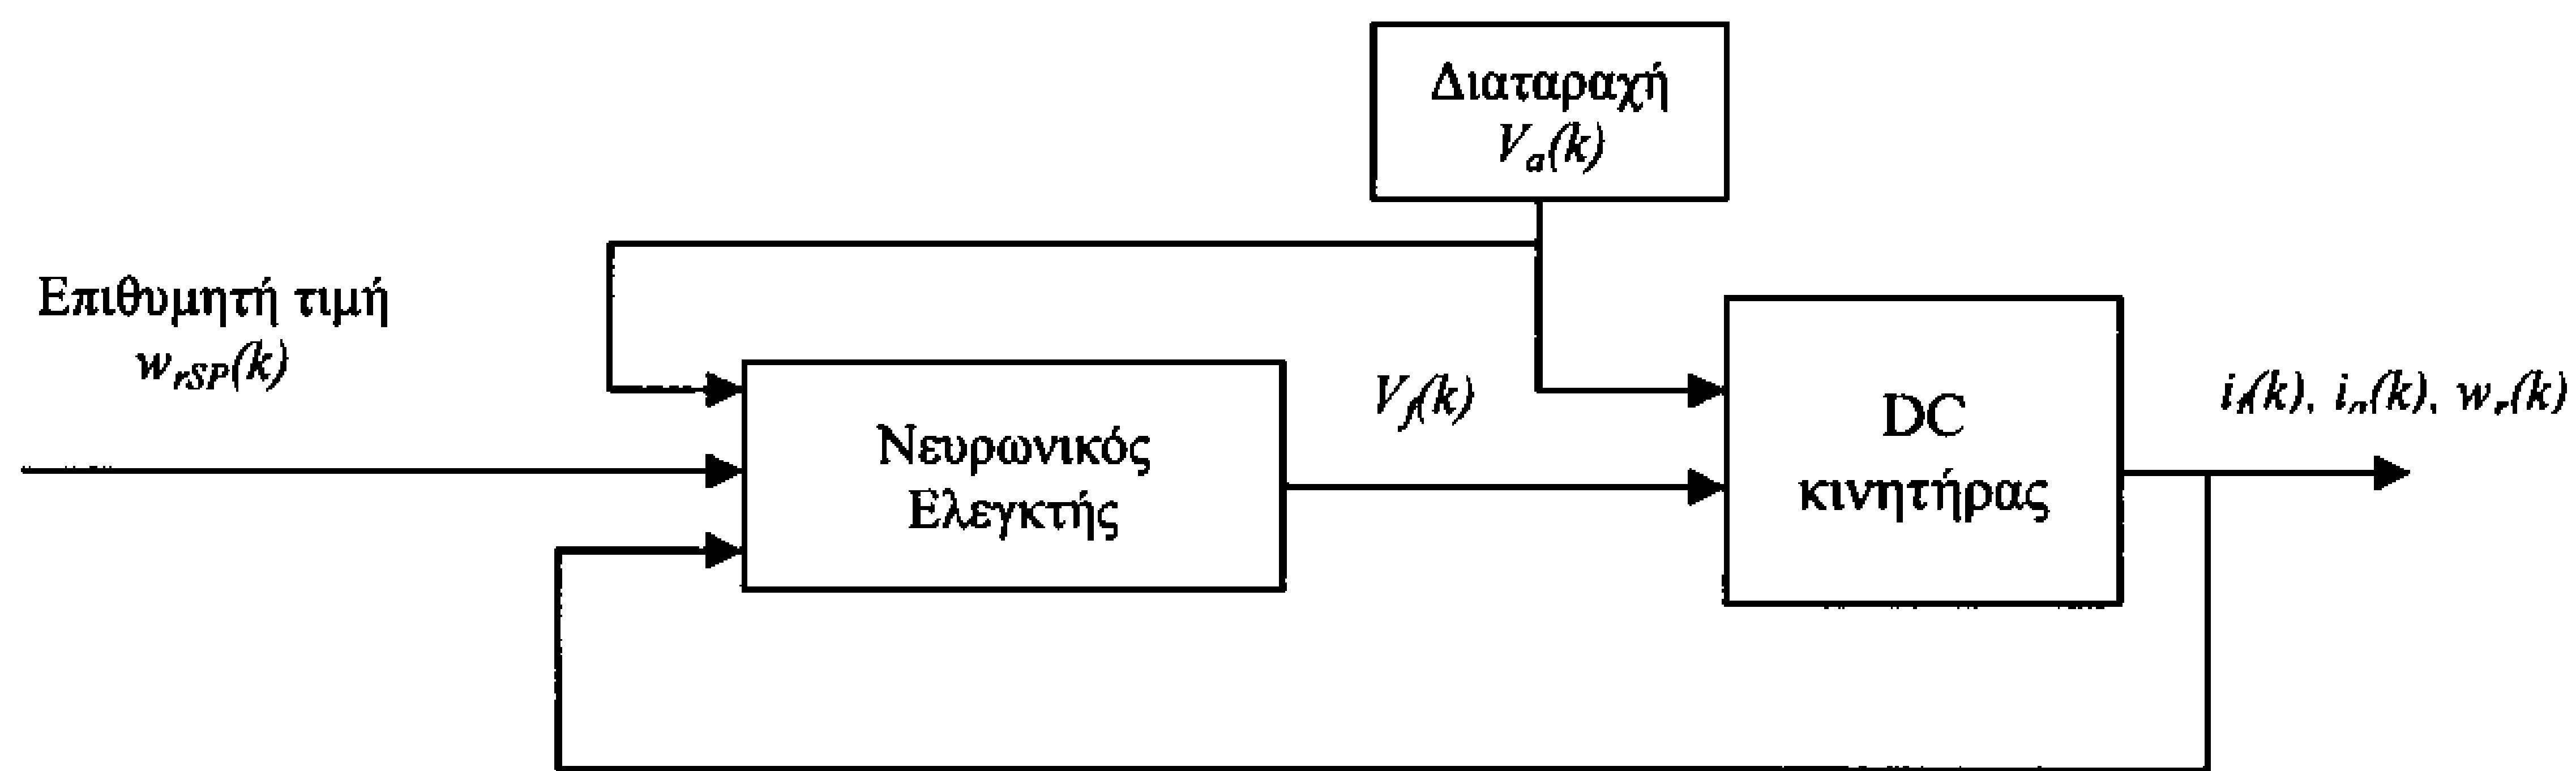
5.4 Σχεδιασμός νευρωνικού δικτύου ως ελεγκτή

Στην περίπτωση του νευρωνικού ελεγκτή, λαμβάνονται μέσω ανατροφοδότησης οι τιμές των μεταβλητών κατάστασης του κινητήρα, καθώς και η τιμή της διαταραχής V_a , με αποτέλεσμα ο ελεγκτής να παράγει την τάση εκχειρισμού V_f που θα οδηγήσει το σύστημα στην επιθυμητή κατάσταση (Σχήμα 5.6).

Στο 4^ο κεφάλαιο σχεδιάστηκε το νευρωνικό δίκτυο ώστε να υπολογίζει τη σχέση:

$$w_r(k+1) = NN(V_a(k), V_f(k), i_f(k), i_a(k), w_r(k)) \quad 5.5$$

όπου υπολόγιζε την μελλοντική τιμή των στροφών του κινητήρα γνωρίζοντας τις τωρινές τιμές των μεταβλητών κατάστασης (i_a , i_f , w_r) και τις τιμές των τάσεων εισόδου (V_a , V_f).



Σχήμα 5.6 Το διάγραμμα βαθμίδων αυτομάτου ελέγχου του κινητήρα από τον PID ελεγκτή.

Ένας απλός τρόπος να σχεδιαστεί ο νευρωνικός ελεγκτής είναι να εκπαιδευτεί ένα νευρωνικό δίκτυο που θα προβλέπει τον αντίστροφο νόμο που διέπει το σύστημα (Ninos et al. 2011). Αυτό το νευρωνικό δίκτυο εκφράζεται από την ακόλουθη σχέση:

$$V_f(k) = NN(i_f(k), i_a(k), w_r(k), w_r(k+1), V_a(k)) \quad 5.6$$

Το παραγόμενο νευρωνικό δίκτυο προβλέπει την τρέχουσα τιμή της μεταβλητής εκχειρισμού V_f χρησιμοποιώντας σαν είσοδο τις τρέχουσες τιμές των μεταβλητών κατάστασης του κινητήρα, την τρέχουσα τιμή της διαταραχής V_a και την επόμενη τιμή της εξαρτημένης μεταβλητής των στροφών του κινητήρα. Μετά το πέρας της εκπαίδευσης, το νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί σαν ελεγκτής που θα προβλέπει την τρέχουσα τιμή της μεταβλητής εκχειρισμού V_f που θα οδηγήσει τον DC κινητήρα στον επιθυμητό αριθμό στροφών w_{rsp} την επόμενη διακριτή χρονική στιγμή. Επομένως ο νευρωνικός ελεγκτής θα κάνει την πρόβλεψη με την ακόλουθη σχέση:

$$V_f(k) = NN(i_f(k), i_a(k), w_r(k), w_{rsp}(k), V_a(k)) \quad 5.7$$

Προκειμένου να παραχθούν δεδομένα για την εκπαίδευση του νευρωνικού δικτύου RBF, ο κινητήρας διεγέρθηκε με τις τάσεις V_a και V_f που προερχόντουσαν από κανονική κατανομή, όπως φαίνονται στον πίνακα 5.1 και οι τιμές των μεταβλητών κατάστασης του κινητήρα λαμβάνονταν κάθε 1 sec. Η διαδικασία εκπαίδευσης ήταν η ίδια με αυτήν που περιγράφεται στο 4^ο κεφάλαιο, όπου τα δεδομένα χωρίζονται στη μέση ώστε τα μισά να


χρησιμοποιηθούν για την εκπαίδευση και τα υπόλοιπα για την αξιολόγηση των προβλέψεων του δικτύου. Εκπαιδευόντας επομένως το νευρωνικό δίκτυο με ασαφή σύνολα από 5-30 με βήμα 5, λαμβάνονται τα αποτελέσματα του πίνακα 5.2 και η αντίστοιχη απεικόνισή τους στα σχήματα 5.7.α και 5.7.β.

Είσοδος	Μέση τιμή	Τυπική απόκλιση (s)	Sample Time
V_a	100	2	20
V_f	25	5	15


Πίνακας 5.1 Παράμετροι των τάσεων εισόδου του κινητήρα κατά την διάρκεια της εκπαίδευσης.

Ασαφή Σύνολα	MARE	R^2
5	0.00138791119754602	0.927789639460483
10	0.00139005403934605	0.968403848397581
15	0.00029444146477091	0.997528416740502
20	0.00017167300591546	0.999873192998443
25	0.00018832853997752	0.999829507164958
30	0.00084518124768907	0.942582288298300

Πίνακας 5.2 Οι στατιστικοί δείκτες MARE και R^2 σε σχέση με τον αριθμό των ασαφών συνόλων του νευρωνικού δικτύου.



Σχήμα 5.7.α Ο στατιστικός δείκτης MARE σε σχέση με τον αριθμό ασαφών συνόλων του νευρωνικού δικτύου.




Σχήμα 5.7.β Ο στατιστικός δείκτης R^2 σε σχέση με τον αριθμό ασαφών συνόλων του νευρωνικού δικτύου.


Προκειμένου να βρεθεί ο ιδανικός αριθμός ασαφών συνόλων, οι μετρήσεις εστιάστηκαν στο πεδίο 15-25 όπου το σφάλμα φαίνεται να είναι το μικρότερο (Πίνακας 5.3). Τα αποτελέσματα απεικονίζονται στα σχήματα 5.8.α και 5.8.β.

Ασαφή Σύνολα	MARE	R^2
15	0.00029444146477091	0.997528416740502
16	0.00030899538349227	0.997231753134202
17	0.00037652026475681	0.990010351272084
18	0.00033657357156608	0.994017047315325
19	0.00033451680619219	0.999298193402897
20	0.00017167300591546	0.999873192998443
21	0.00026500369277343	0.999600107525374
22	0.00029497407103744	0.999241263467491
23	0.00020982164475794	0.999845168763513
24	0.00015652502418076	0.999896424237639
25	0.00018832853997752	0.999829507164958

Πίνακας 5.3 Οι στατιστικοί δείκτες MARE και R^2 σε σχέση με τον αριθμό των ασαφών συνόλων του νευρωνικού δικτύου.



Σχήμα 5.8.α Ο στατιστικός δείκτης $MARE$ σε σχέση με τον αριθμό ασαφών συνόλων του νευρωνικού δικτύου.



Σχήμα 5.8.β Ο στατιστικός δείκτης R^2 σε σχέση με τον αριθμό ασαφών συνόλων του νευρωνικού δικτύου.

Όπως διακρίνεται από τις τιμές και τα γραφήματα, καλύτερα αποτελέσματα λαμβάνονται για 24 ασαφή σύνολα.

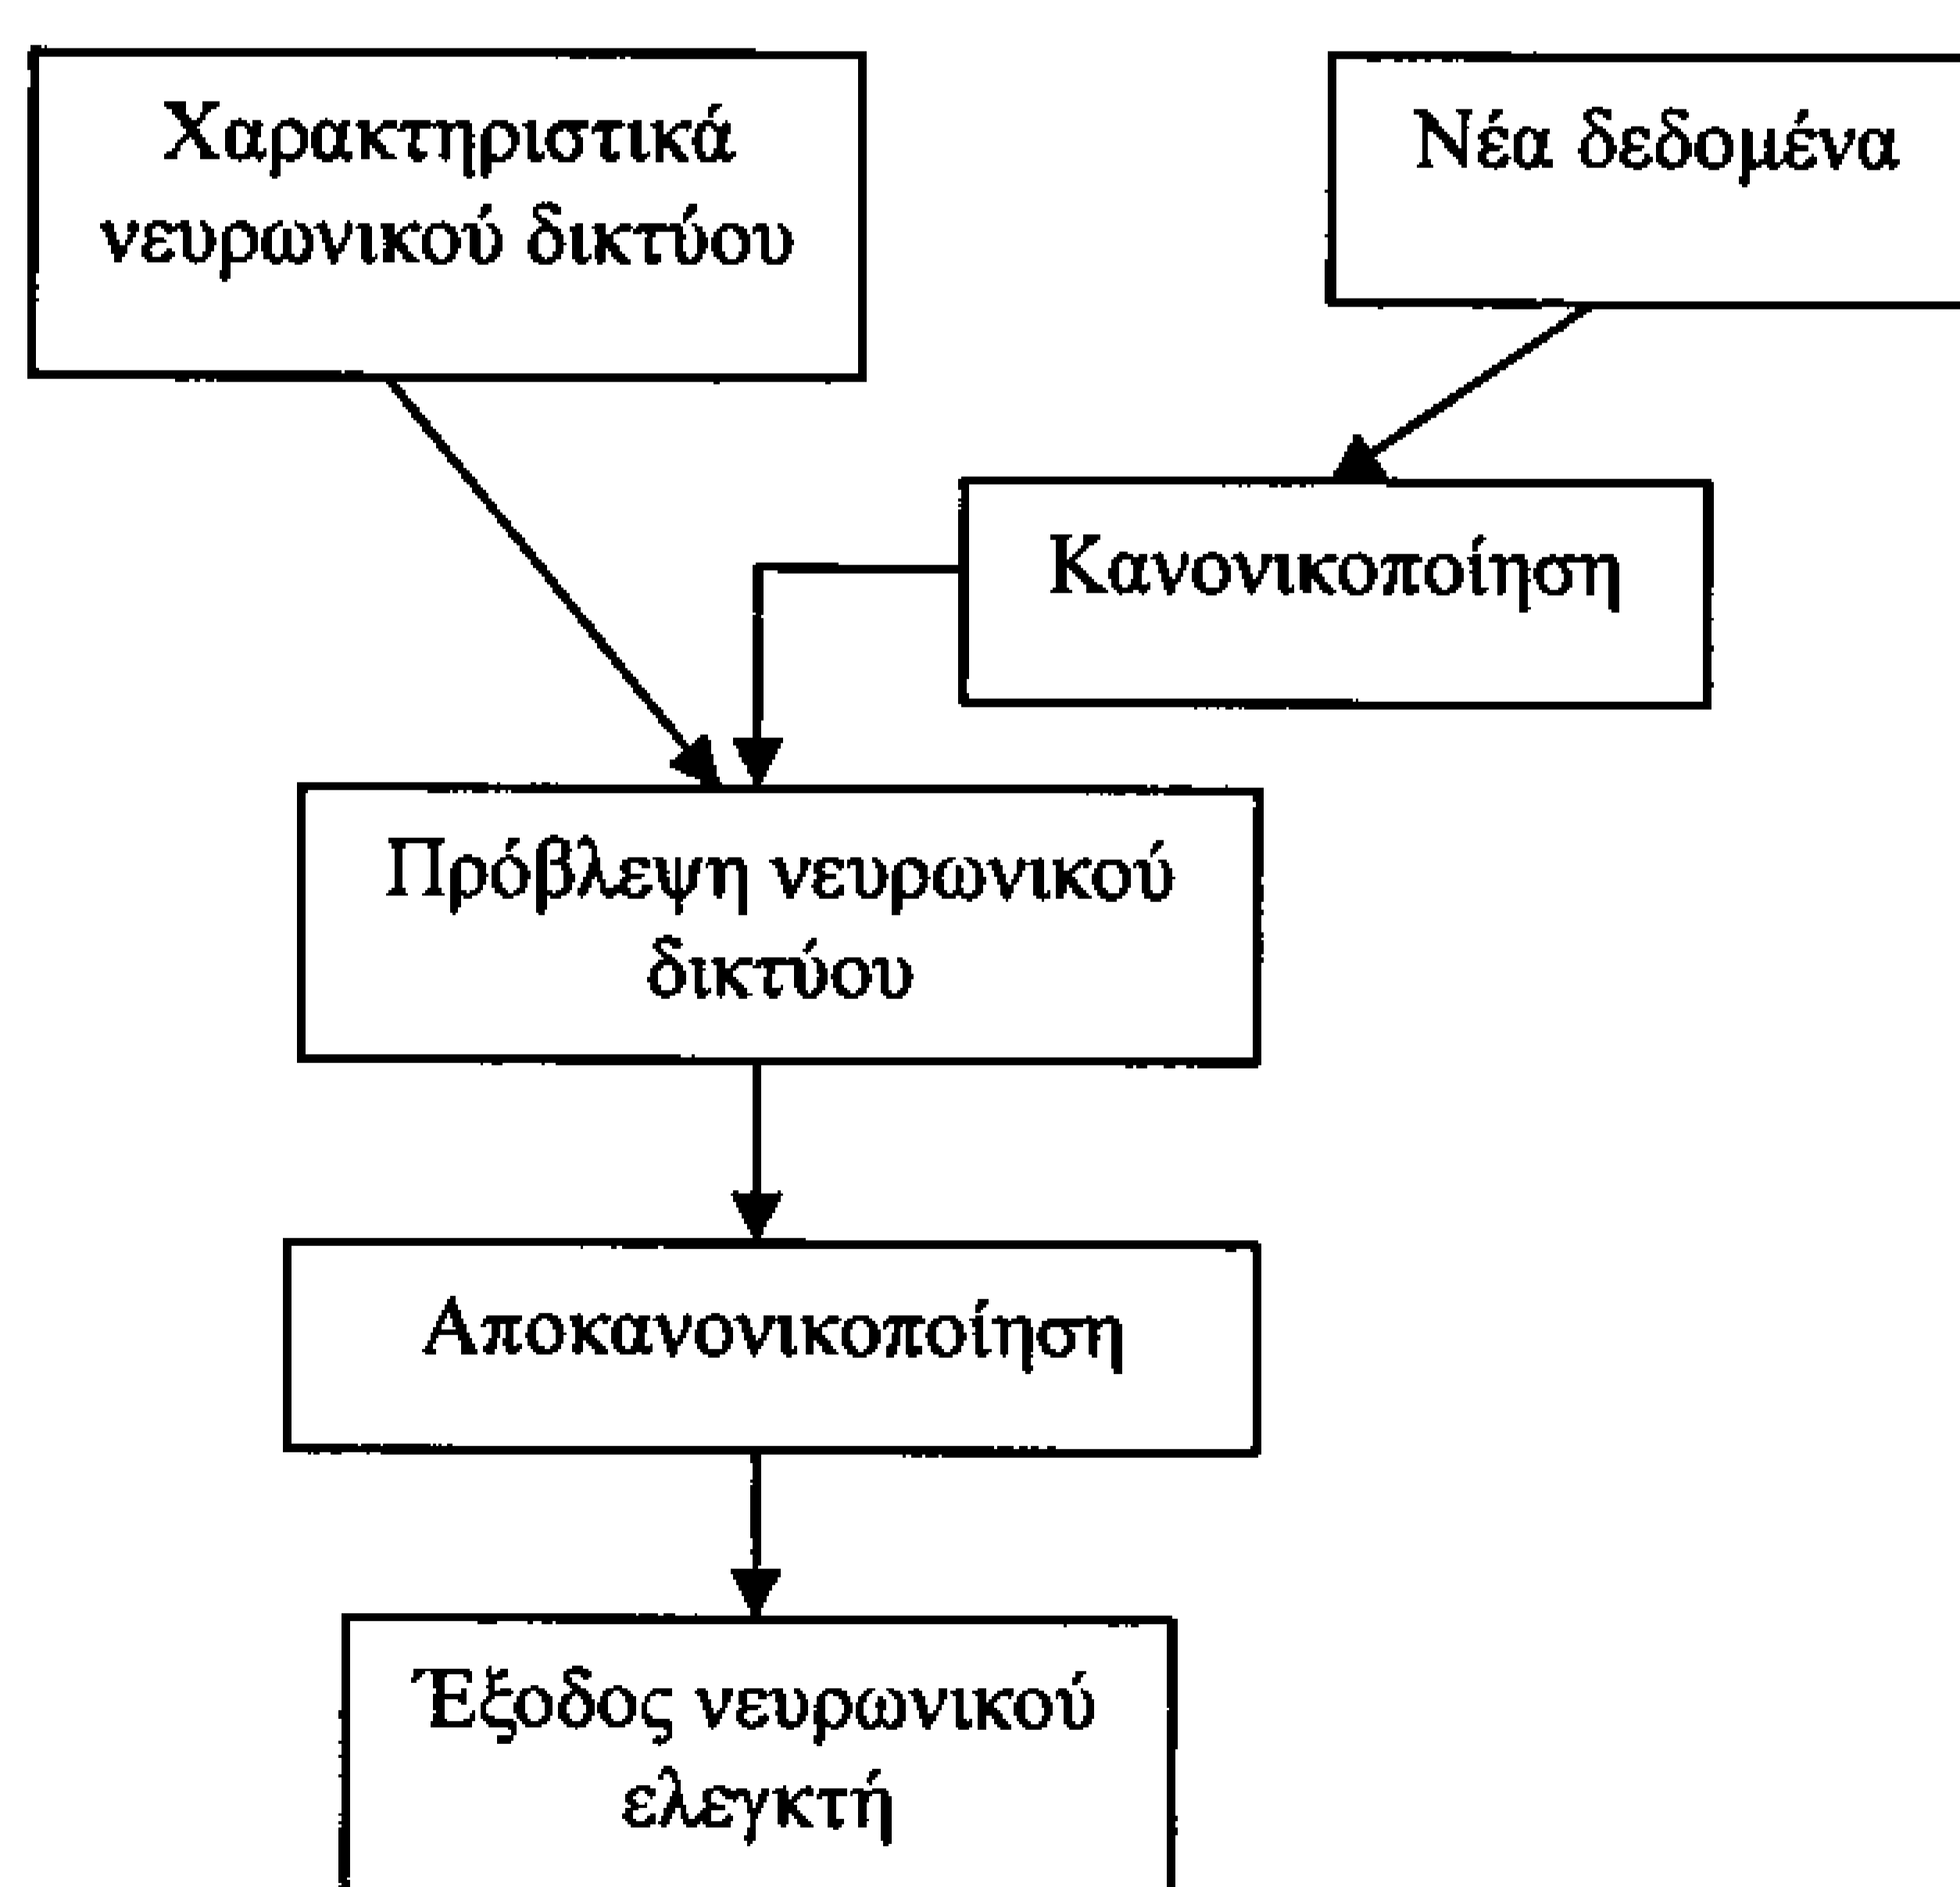
Κάθε φορά που πραγματοποιεί πρόβλεψη ο νευρωνικός ελεγκτής πρέπει να του γίνονται γνωστά τα χαρακτηριστικά του νευρωνικού δικτύου όπως:

- ο αριθμός και οι θέσεις των κέντρων
- τα συναπτικά τους βάρη
- και οι παράμετροι κανονικοποίησης των δεδομένων εισόδου και εξόδου, ώστε να υπολογίζονται κάθε φορά οι νέες τιμές για τα διανύσματα

Ο αλγόριθμος λειτουργίας του ελεγκτή καθώς και το διάγραμμα ροής του (Σχήμα 5.9) είναι ως εξής:

1. Ανακτώνται τα χαρακτηριστικά του δικτύου και δημιουργείται ο πίνακας εισόδων $X = [i_f(k), i_a(k), w_r(k), SP, V_a(k)]$
2. Τα δεδομένα κανονικοποιούνται σύμφωνα με τον μέσο όρο και την τυπική απόκλιση που αποθηκεύτηκαν κατά την διάρκεια της εκπαίδευσης του δικτύου.
3. Χρησιμοποιούνται τα νέα δεδομένα εισόδου για να πραγματοποιηθούν προβλέψεις για τις τρέχουσες τιμές μέσω του νευρωνικού δικτύου που έχει δημιουργηθεί προηγουμένως, αφού πρώτα οι προβλέψεις αυτές αποκανονικοποιηθούν.

Με αυτή τη διαδικασία κάθε φορά ο νευρωνικός ελεγκτής πραγματοποιεί αυτόματο έλεγχο στον DC κινητήρα. Ο χρόνος δειγματοληψίας του ελεγκτή θα πρέπει να είναι ίσος με τον χρόνο δειγματοληψίας που χρησιμοποιήθηκε για την εκπαίδευση του δικτύου, αλλιώς ο ελεγκτής δεν μπορεί να κάνει σωστή πρόβλεψη. Αυτό συμβαίνει διότι η αλλαγή του χρόνου δειγματοληψίας σημαίνει αλλαγή των χαρακτηριστικών του νευρωνικού δικτύου, εφόσον έχει εκπαιδευτεί να δέχεται αλλαγές σε συγκεκριμένο χρονικό πλαίσιο.




Σχήμα 5.9 Διάγραμμα ροής του αλγορίθμου του νευρωνικού ελεγκτή.

5.5 Αποτελέσματα νευρωνικού ελεγκτή


Τα προβλήματα αυτομάτου ελέγχου μπορούν να κατηγοριοποιηθούν σε προβλήματα παρακολούθησης επιθυμητής τιμής (Set Point Tracking) και σε προβλήματα απόρριψης διαταραχής (Disturbance Rejection):

- Πρόβλημα Set point tracking: Σε αυτού του είδους τα προβλήματα στόχος είναι ο ελεγκτής να ακολουθεί με ακρίβεια τις συνεχείς μεταβολές της επιθυμητής τιμής.
- Πρόβλημα Disturbance rejection: Σε αυτού του είδους τα προβλήματα στόχος είναι η επαναφορά και διατήρηση της επιθυμητής τιμής από τον ελεγκτή, τη στιγμή που το σύστημα μεταβάλλεται από κάποια εξωτερική διαταραχή.

Τοποθετώντας μια μεταβλητή επιθυμητή τιμή στροφών, λαμβάνεται η απεικόνιση της απόκρισης του κινητήρα που φαίνεται στο Σχήμα 5.10.α. Στη συνέχεια δοκιμάζεται ο ελεγκτής στο πρόβλημα απόρριψης διαταραχής, μεταβάλλοντας ως εξωτερική διαταραχή την τάση V_a . Η απόκριση του κινητήρα παρουσιάζεται στο Σχήμα 5.10.β.



Σχήμα 5.10.α Πρόβλημα Set Point Tracking: Η έξοδος του κινητήρα ελεγχόμενη από νευρωνικό ελεγκτή.




Σχήμα 5.10.β Πρόβλημα *Disturbance Rejection*: Η έξοδος του κινητήρα ελεγχόμενη από νευρωνικό ελεγκτή.

Από τα παραπάνω σχήματα φαίνεται πως ο νευρωνικός ελεγκτής καταφέρνει να ανταπεξέλθει γρήγορα στις αλλαγές, καθώς και να μην παρουσιάζει μεγάλο overshoot σε αυτές.

5.6 Σύγκριση νευρωνικού και P.I.D. ελεγκτή

Όπως διαπιστώθηκε το νευρωνικό δίκτυο ως ελεγκτής για τον αυτόματο έλεγχο του μη γραμμικού κινητήρα λειτουργεί αρκετά ικανοποιητικά. Προκειμένου να εξακριβωθεί η αξιοπιστία και η χρησιμότητά του, συγκρίνεται με μια συμβατική μέθοδο ελέγχου, χρησιμοποιώντας έναν ελεγκτή PID.


Παράλληλα με το νευρωνικό σύστημα ελέγχου του κινητήρα, υλοποιείται ένα δεύτερο σύστημα αυτομάτου ελέγχου με έναν ψηφιακό PID ελεγκτή. Για λόγους σύγκρισης ο ρυθμός δειγματοληψίας του PID ήταν ίδιος με αυτόν του νευρωνικού δικτύου, ίσος με 1 sec. Οι τιμές των παραμέτρων του PID ρυθμίστηκαν γύρω από ένα σημείο ισορροπίας. Επιλέχθηκε ένας συντηρητικός χρόνος απόκρισης, διότι εξαιτίας των



Σχήμα 5.11 Μικρός χρόνος απόκρισης του PID που οδηγεί απώλεια ελέγχου του συστήματος.

μη γραμμικών φαινομένων του κινητήρα, ο PID ελεγκτής δεν μπορούσε να πραγματοποιήσει έλεγχο (Σχήμα 5.11).


Όπως φαίνεται στο Σχήμα 5.12 όπου απεικονίζονται οι στροφές του κινητήρα, διαπιστώνεται εύκολα πως ο ψηφιακός PID ελεγκτής υστερεί σε σχέση με τον νευρωνικό ελεγκτή, καθότι αργεί να οδηγήσει στην επιθυμητή τιμή τον κινητήρα.




Σχήμα 5.12 Πρόβλημα Set Point Tracking: Η έξοδος του κινητήρα ελεγχόμενη από νευρωνικό και ψηφιακό PID ελεγκτή.

Λόγω του τρόπου λειτουργίας του PID ελεγκτή, που προσπαθεί μέσω της σύγκρισης της τιμής της εξόδου του συστήματος με την επιθυμητή τιμή να βελτιώσει την είσοδο του κινητήρα, χωρίς να έχει καμία άλλη γνώση για το σύστημα, ο ψηφιακός PID ελεγκτής αποδεικνύεται πιο αργός από τον νευρωνικό. Μέσα στον χρόνο δειγματοληψίας (1sec) που πραγματοποιεί την σύγκριση ο νευρωνικός ελεγκτής γνωρίζει με ποια τάση πρέπει να τροφοδοτήσει τον κινητήρα προκειμένου να τον οδηγήσει στην επιθυμητή τιμή, ενώ ο ψηφιακός PID ανάλογα με τις παραμέτρους του αυξομειώνει την τροφοδοσία του κινητήρα. Στη συνέχεια αντικαταστήθηκε ο ψηφιακός PID ελεγκτής με έναν αναλογικό. Ο αναλογικός ελεγκτής δεν έχει διακριτό χρόνο δειγματοληψίας καθώς συνεχώς ρυθμίζει την έξοδό του σύμφωνα με την διαφορά μεταξύ της επιθυμητής και της πραγματικής τιμής των στροφών του κινητήρα.

Πραγματοποιήθηκε η σύγκριση των δύο αυτών ελεγκτών τόσο στο πρόβλημα παρακολούθησης της επιθυμητής τιμής, όσο και στο πρόβλημα της απόρριψης της διαταραχής. Στα σχήματα 5.13-5.16 φαίνονται οι διαφορές τους.




Σχήμα 5.13 Πρόβλημα *Set Point Tracking*: Η έξοδος του κινητήρα ελεγχόμενη από νευρωνικό και αναλογικό PID ελεγκτή.




Σχήμα 5.14 Πρόβλημα *Set Point Tracking*: Αναλογικός PID και νευρωνικός ελεγκτής σε μια μεταβολή των στροφών του κινητήρα.

Όπως φαίνεται από το σχήμα 5.13, ο PID ακολουθεί αρκετά καλά το νευρωνικό δίκτυο, όμως είναι πιο αργός στην οδήγηση του κινητήρα στον επιθυμητό αριθμό στροφών.



Σχήμα 5.15 Πρόβλημα *Disturbance rejection*: Η έξοδος του κινητήρα ελεγχόμενη από νευρωνικό και αναλογικό PID ελεγκτή.



Σχήμα 5.16 Πρόβλημα *Disturbance rejection*: Αναλογικός PID και νευρωνικός ελεγκτής σε μία μεταβολή στροφών του κινητήρα.

Στην απόρριψη εξωτερικής διαταραχής (*disturbance rejection*) ο νευρωνικός ελεγκτής σταθεροποιείται σε μόνιμη κατάσταση γρηγορότερα από τον PID περιορίζοντας ταυτόχρονα την μεγάλη διακύμανση των στροφών και έχοντας συνολικά μικρότερο σφάλμα από τον PID.

ΣΥΜΠΕΡΑΣΜΑΤΑ – ΜΕΛΛΟΝΤΙΚΕΣ ΕΡΕΥΝΗΤΙΚΕΣ ΚΑΤΕΥΘΥΝΣΕΙΣ

Σε αυτή τη πτυχιακή εργασία μελετήθηκε η αρχιτεκτονική νευρωνικών δικτύων RBF και οι αλγόριθμοι που χρησιμοποιούνται για την εκμάθησή τους. Στη συνέχεια αναλύθηκε ένας μη γραμμικός DC κινητήρας ο οποίος εξομοιώθηκε στο Simulink του πακέτου Matlab και μοντελοποιήθηκε με ένα γραμμικό μοντέλο και ένα νευρωνικό δίκτυο RBF, όπου και διαπιστώθηκε η υπεροχή του νευρωνικού μοντέλου. Τέλος υλοποιήθηκε ένα νέο νευρωνικό δίκτυο RBF το οποίο πραγματοποίησε αυτόματο έλεγχο στον κινητήρα και συγκρίθηκε με έναν PID ελεγκτή.

Τα νευρωνικά δίκτυα είναι ιδανικά για την μοντελοποίηση άγνωστων συστημάτων, καθώς χρησιμοποιώντας μόνο δεδομένα εισόδου – εξόδου, καταφέρνουν και «μαθαίνουν» τον τρόπο λειτουργίας του συστήματος. Εξαιτίας της ευελιξίας που παρουσιάζει ο μη γραμμικός τρόπος κατασκευής τους, τα νευρωνικά δίκτυα είναι ικανά να προσφέρουν μεγαλύτερο ποσοστό επιτυχίας στις προβλέψεις τους σε σχέση με κάποιου άλλου τύπου μοντελοποίηση, όπως τα γραμμικά μοντέλα.

Τα νευρωνικά δίκτυα RBF είναι μια κατηγορία δικτύων που προσφέρουν σημαντικά προτερήματα, σε σχέση με τα υπόλοιπα νευρωνικά δίκτυα. Τέτοια πλεονεκτήματα είναι η απλή δομή του δικτύου, οι γρήγοροι αλγόριθμοι μάθησης και η καλύτερη προσεγγιστική ικανότητα. Ένας από τους αλγόριθμους εκμάθησης δικτύων RBF, ο οποίος χρησιμοποιήθηκε και στην συγκεκριμένη πτυχιακή εργασία, είναι ο αλγόριθμος των ασαφών μέσων (fuzzy means) ο οποίος πλεονεκτεί έναντι των υπολοίπων σε υπολογιστική ισχύ και ταχύτητα.

Ο κινητήρας που εξομοιώθηκε μελετήθηκε ως προς τη μη γραμμικότητα του ώστε να αναδειχθούν καλύτερα τα πλεονεκτήματα του νευρωνικού δικτύου έναντι κλασικών μεθόδων ελέγχου όπως είναι οι PID ελεγκτές. Στη συνέχεια υλοποιήθηκε ένα νευρωνικό δίκτυο RBF το οποίο μοντελοποίησε τον κινητήρα προβλέποντας τις μελλοντικές τιμές των στροφών του, χρησιμοποιώντας σαν εισόδους τις τωρινές τιμές των μεταβλητών κατάστασης καθώς και των τάσεων εισόδου. Στη συνέχεια προτάθηκε ένα σύστημα αυτομάτου ελέγχου, όπου το νευρωνικό δίκτυο λειτουργεί ως ελεγκτής. Προκειμένου να

επιτευχθεί αυτό, υλοποιήθηκε νευρωνικό δίκτυο RBF το οποίο μοντελοποιούσε το αντίστροφο πρόβλημα. Συγκεκριμένα το δίκτυο RBF υπολογίζει την τιμή της μεταβλητής εκχειρισμού V_f με την οποία ο κινητήρας οδηγείται στον επιθυμητό αριθμό στροφών.

Ο νευρωνικός ελεγκτής συγκρίθηκε με έναν ψηφιακό και στην συνέχεια έναν αναλογικό PID ελεγκτή, πραγματοποιώντας αυτόματο έλεγχο παράλληλα στο ίδιο σύστημα. Δοκιμάστηκε η απόδοσή τους σε προβλήματα ακολουθίας επιθυμητής τιμής και απόρριψης εξωτερικής διαταραχής, όπου ο νευρωνικός ελεγκτής αποδείχθηκε γρηγορότερος και πιο αξιόπιστος.

Όσον αφορά στις μελλοντικές ερευνητικές κατευθύνσεις, ιδιαίτερο ερευνητικό ενδιαφέρον παρουσιάζει η χρησιμοποίηση ενός προσαρμοστικού (adaptive) νευρωνικού ελεγκτή. Με αυτόν τον ελεγκτή δε θα χρησιμοποιείται ένα στατικό νευρωνικό δίκτυο που έχει εκπαιδευτεί εκτός του κλειστού βρόγχου ελέγχου, αλλά η διαδικασία της εκμάθησης θα γίνεται παράλληλα με τον αυτόματο έλεγχο, δίνοντας έτσι τη δυνατότητα στον ελεγκτή να προσαρμόζεται σε πραγματικό χρόνο σε τυχόν αλλαγές του υπό έλεγχο συστήματος.

Επίσης, μία άλλη ενδιαφέρουσα ερευνητική κατεύθυνση αφορά στην ενσωμάτωση ενός μηχανισμού που θα πραγματοποιεί ολοκληρωτική δράση (integral action) στον νευρωνικό ελεγκτή, καθιστώντας τον ικανό να μηδενίζει σε κάθε περίπτωση την απόκλιση ανάμεσα στην επιθυμητή τιμή και την έξοδο του συστήματος.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- Alexandridis and Sarimveis (2005). "Nonlinear Adaptive Model Predictive Control Based on Self-Correcting Neural Network Models." *AICHE*(51): 2495-2506.
- Alexandridis, A., H. Sarimveis, G. Bafas (2003). "A new algorithm for online structure and parameter adaptation of RBF networks." *Neural Networks*(16): 1003-1017.
- Alexandridis A., P. Patrinos, H. Sarimveis, G. Tsekouras (2005). "A two-stage evolutionary algorithm for variable selection in the development of RBF neural network models." *Chemometrics and Intelligent Laboratory Systems*(75): 149-162.
- Billings (1995). "Radial Basis Function network configuration using genetic algorithms." *Neural Networks* 8: 887-890.
- Bishop (1997). *Neural Networks for Pattern Recognition*, Oxford University Press.
- Bolt (1992). *Fault Tolerance in Artificial Neural Networks*. Ontario, York University.
- Bourbakis and Gumahad II (1991). *Knowledge-Based Recognition of Typed Text Characters*. *Character & Handwriting Recognition: Expanding Frontiers*. Singapore, World Scientific Publishing Co. Pte. Ltd.
- Chen, S., Billings, S. A., Cowan, C. F. N. and Grant, P. M. (1990). "Practical identification of NARMAX models using radial basis functions." *International Journal of Control* 52: 1327-1350.
- Churchland (1986). *Neurophilosophy: Toward a Unified Science of the Mind/Brain*. Cambridge, MIT Press.
- Churchland and Sejnowski (1992). *The Computational Brain*. Cambridge, MIT Press.
- Darken and Moody (1990). *Fast Adaptive K-Means Clustering: Some Empirical Results*. IEEE INNS International Joint Conference On Neural Networks. San Diego, CA. 2: 233-238.
- Dorf and Bishop (2011). *Modern Control Systems*, 12th Edition, Prentice-Hall.
- Dreyfus (1990). "Artificial Neural Networks, Back Propagation and the Kelley-Bryson Gradient Procedure." *Journal of Guidance, Control and Dynamics*(13): 926-928.
- Eberly (2003). *Stability Analysis for Systems of Differential Equations*.

- Fischler and Firschein (1987). *Intelligence: The Eye, the Brain, and the Computer*.
- Freeman (1975). *Mass Action in the Nervous System*. New York, Academic Press.
- Fritzke (1994). "Fast learning with incremental RBF networks." *Neural Processing Letters* **1**(1): 2-5.
- Fung Chi F., Stephen A. Billings, Wan Luo (1996). "On-line supervised adaptive training using radial basis function networks." *Neural Networks* **9**(1597-1617).
- Geladi and Kowalski (1986). "Partial Least Squares Regression A Tutorial." *Analytica Chimica Acta* **185**: 1-17.
- Hairer and Wanner (2010). *Solving Ordinary Differential Equations II (Stiff and Differential - Algebraic Problems)*.
- Haykin (1999). *Neural Networks: A comprehensive foundation*.
- Hinton (1989). "Connectionist learning procedures." *Artificial Intelligence*(40): 185-234.
- Houlomb and Morari (1991). Local training for radial basis function networks: towards solving the hidden unit problem. American Control Conference.
- Karaali O., Gerald Corrigan, Noel Massey, Corey Miller, Otto Schnurr, Andrew Mackie (1998). A high quality text-to-speech system composed of multiple neural networks. IEEE International Conference on Acoustics, Speech and Signal Processing. Seattle, USA.
- Khashman (1999). Automatic Detection of Military Targets utilising Neural Networks and Scale Space Analysis. Department of Computer Engineering, Near East University.
- Kuo and Golnarachi (2010). *Automatic Control System*.
- Kvasnička Vladimír, Sklenák Štěpán, Pospíchal Jiří (1993). "Application of high-order neural networks in chemistry " *Theoretical Chemistry Accounts: Theory, Computation, and Modeling (Theoretica Chimica Acta)* **86**(3): 257-267.
- Leonard and Kramer (1991). "Radial basis function networks for classifying process faults." *IEEE Control Systems*: 31-38.
- Levine (1985). *Man and Machine Vision*. New York, McGraw-Hill.
- MacQueen (1967). Some Methods for Classification and Analysis of Multivariate Observations. Fifth Berkeley Symposium on Mathematical Statistics and Probability: 281.

- Marr (1982). *Vision*. New York, Freeman.
- Moody and Darken C. (1989). "Fast Learning in networks of locally-tuned processing units." *Neural Computation*(2): 281-294.
- Morajda (2000). *Neural Networks as Predictive Models in Financial Futures Trading. Neural Networks and Soft Computing*. Zakopane.
- Musavi M.T, W. Ahmed, K.H. Chan, K.B. Faris, D.M. Hummels (1992). "On the training of radial basis function classifiers." *Neural_Networks*(5): 595-603.
- Nie (1997). "Fuzzy control of Multivariable Nonlinear Servomechanisms with Explicit Decoupling Scheme." *IEEE Transactions on Fuzzy Systems*(5): 304.
- K. Ninos, C. Giannakakis, I. Kompogiannis, I. Stavrakas, A. Alexandridis (2011). *Nonlinear Control of a DC-Motor Based on Radial Basis Function Neural Networks*. IEEE International Symposium on INnovations in Intelligent SysTems and Applications. Istanbul, Turkey.
- Powell (1985). Radial basis functions for multi-variable interpolation: A review. IMA Conference on Algorithms for the Approximation of Functions and Data. Shrivenham, England: 143-167.
- Powell (1987). Radial basis function approximations to polynomials. *Numerical Analysis 1987 Proceedings*. Dundee, UK: 223-241.
- Powell (1992). The theory of radial basis function approximation in 1990. In *Advances in Numerical Analysis*. Oxford, Oxford University Press: 105-210.
- Ross (2004). *Fuzzy Logic With Engineering Applications*.
- Rumelhart, D. E., McClelland, J. L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, MIT Press : Cambridge, Mass
- Salas-Cabrera R., C. Reyna-Lopez, E. N. Salas-Cabrera, M. Gomez-Garcia, C. Garcia-Guendulain and H. E. Sanjuan-Garcia (2008). *Identification of a Nonlinear Model for a DC Motor*, Instituto Tecnológico de Cd. Madero.
- Sarimveis H., A. Alexandridis, G. Tsekouras and G. Bafas (2002). "A fast and efficient algorithm for training radial basis function neural networks based on a fuzzy partition of the input space." *Industrial and Engineering Chemistry Research* **41**: 751-759.
- Shepherd and Koch, Eds. (1990). Introduction to synaptic circuits, in *The Synaptic*

- Organization of the Brain. New York, Oxford University Press.
- The MathWorks (1994-2011). Matlab.
- Yeo and Kwon (1999). "A Neural PID Controller for the pH Neutralization Process."
Industrial and Engineering Chemistry Research **38**(3): 978–987.
- Zadeh (1965). "Fuzzy sets." Information and Control **8**: 338-353.
- Zhu Qiuming, Yao Cai, Luzheng Liu. (1999). "A global learning algorithm for a RBF network." Neural Networks **12**: 527-540.
- Παρασκευόπουλος (2001). Εισαγωγή στον Αυτόματο Έλεγχο Τόμος Α: Θεωρία.