



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ «ΕΦΑΡΜΟΣΜΕΝΑ ΠΛΗΡΟΦΟΡΙΑΚΑ ΣΥΣΤΗΜΑΤΑ»

**Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang
υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης.
Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Κανδηλογιαννάκης Γεώργιος

A.M.: ais0107

Επιβλέπων: Καθ. Πάρις Μαστοροκώστας

Αιγάλεω, Ιούνιος 2018

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε στο πλαίσιο του Μεταπτυχιακού Προγράμματος Σπουδών «Εφαρμοσμένα Πληροφοριακά Συστήματα» του τμήματος Μηχανικών Η/Υ Συστημάτων του πρώην Α.Ε.Ι. Πειραιά Τεχνολογικού Τομέα. Θα ήθελα να απευθύνω τις θερμές ευχαριστίες μου, στον επιβλέποντα καθηγητή μου κ. Πάρι Μαστοροκώστα, για την πολύτιμη καθοδήγηση του, την εκτίμηση και την εμπιστοσύνη που μου έδειξε, αφού πρωτίστως μου παρέιχε την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον αντικείμενο που ανταποκρίνεται απολύτως στα επιστημονικά μου ενδιαφέροντα, στο πλαίσιο μιας άριστης συνεργασίας. Τέλος, ιδιαίτερες ευχαριστίες θα ήθελα να εκφράσω προς τους δικούς μου ανθρώπους και κυρίως την οικογένειά μου, για την ποικιλότητα υποστήριξη τους καθ' όλη τη διάρκεια των μεταπτυχιακών σπουδών μου.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

ΠΕΡΙΛΗΨΗ

Σκοπός της διπλωματικής εργασίας είναι η μελέτη και αναπαράσταση ασαφών συστημάτων, που βασίζονται στο μοντέλο Takagi-Sugeno-Kang υψηλής τάξης, και η αποσύνθεση αυτών σε συστήματα πρώτης τάξης. Για την επίτευξη των ανωτέρω γίνεται παρουσίαση ενός αναδρομικού φίλτρου - το οποίο χρησιμοποιεί δύο Δυναμικά Ασαφή Νευρωνικά Δίκτυα - και εφαρμογή αυτού στο πραγματικό πρόβλημα του διαχωρισμού των πνευμονικών ήχων, που λαμβάνονται από ασθενείς με πνευμονική παθολογία. Τα προαναφερθέντα Δυναμικά Ασαφή Νευρωνικά Δίκτυα (Dynamic Fuzzy Neural Networks - DFNN) χρησιμοποιούν ένα πιο σύνθετο μοντέλο Takagi-Sugeno-Kang όπου το τμήμα απόδοσης αποτελεί ένα ξεχωριστό αναδρομικό νευρωνικό δίκτυο. Τα δύο νευρωνικά δίκτυα (DFNN) του φίλτρου λειτουργούν παράλληλα, εκτελώντας διαχωρισμό σε πραγματικό χρόνο των παθολογικών διακοπτόμενων αναπνευστικών ήχων (Discontinuous Adventitious Sounds – DAS) από τους κυψελιδικούς ήχους (Vesicular Sounds – VS). Ο διαχωρισμός των DAS από τους κυψελιδικούς ήχους (VS) έχει μεγάλη σημασία, αφού η απομόνωση των DAS οδηγεί σε καλύτερη αξιολόγηση του διαγνωστικού τους χαρακτήρα. Για την εκπαίδευση των αναδρομικών ασαφών συστημάτων DFNN προτείνεται η προσαρμοστική μέθοδος εκμάθησης, SA-DRPROP (Simulated Annealing Dynamic Resilient Back-PROPagation – Δυναμική Ευπροσάρμοστη Ανάστροφη Διάδοση με χρήση Προσομοιωμένης Ανόπτωσης). Η μέθοδος τροποποιεί τον αλγόριθμο SARPROP (Simulated Annealing Resilient Back-PROPagation), που αναπτύχθηκε αρχικά για στατικά νευρωνικά μοντέλα, προκειμένου να εφαρμοστεί σε δυναμικά μοντέλα. Εκτελούνται εκτεταμένες πειραματικές δοκιμές, τόσο ως προς τις παραμέτρους δομής όσο και ως προς τις παραμέτρους εκπαίδευσης του μοντέλου. Εξετάζονται οι τραχείς και λεπτοί τρίζοντες επιπρόσθετοι αναπνευστικοί ήχοι (fine/coarse crackles), καθώς και τα «κακαρίσματα» (squawks), απ' όπου εξάγεται πλήθος συμπερασμάτων για την απόδοση του φίλτρου.

Επιστημονική περιοχή: Τεχνητή Νοημοσύνη – Μηχανική Μάθηση – Ασαφή Νευρωνικά Δίκτυα

Λέξεις-κλειδιά: αναδρομικό ασαφές – νευρωνικό μοντέλο, παθολογικοί διακοπτόμενοι αναπνευστικοί ήχοι, κυψελιδικοί ήχοι, διαχωρισμός σε πραγματικό χρόνο.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

ABSTRACT

The scope of this thesis is the study higher-order fuzzy systems, based on the Takagi-Sugeno-Kang model, their decomposition into first-order systems. A recurrent filter is presented, consisting of two Dynamically Neural Networks, which is applied to the real-world problem of the separation of pulmonary sounds obtained from patients with pulmonary pathology. The aforementioned Dynamic Fuzzy Neural Networks (DFNN) use a complex Takagi-Sugeno-Kang model, where the consequent part of its fuzzy rules is a recurrent neural network (RNN) with internal feedback. The DFNNs of the filter work in parallel, performing real-time separation of Vesicular Sounds (VS) from Discontinuous Adventitious Sounds (DAS). The separation of DAS from Vesicular Sounds (VS) is of great importance, since isolation of the DAS leads to a better assessment of their diagnostic character. In order to train the DFNNs, the adaptive learning method, SA-DRPROP (Simulated-Annealing Dynamic Resilient back PROPagation) is proposed. The method modifies the SARPROP (Simulated Annealing Resilient back PROPagation) algorithm, originally developed for static neural models, to apply to dynamic models. The pulmonary sound categories of Fine/Coarse and Squawks are examined. Extensive experimental results are provided, including both architectural and training issues, and interesting conclusions are drawn.

Scientific area: Artificial Intelligence - Machine Learning –
Fuzzy Neural Networks

Keywords: recurrent fuzzy-neural modelling; pathological discontinuous adventitious sounds; vesicular sounds; real-time separation

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας περιεχομένων

1. ΕΙΣΑΓΩΓΗ.....	13
2. ΑΣΑΦΗΣ ΛΟΓΙΚΗ (Fuzzy Logic).....	15
2.1 Εισαγωγή	15
2.2 Ιστορική αναδρομή.....	16
2.3 Κλασσικά και ασαφή σύνολα	18
2.4 Κατηγορίες ασαφών συνόλων	21
3. ΙΔΙΟΤΗΤΕΣ – ΟΡΙΣΜΟΙ ΑΣΑΦΩΝ ΣΥΝΟΛΩΝ	23
3.1 Σύνολο υποστήριξης.....	23
3.2 Ύψος	23
3.3 Κανονικό ασαφές σύνολο.....	23
3.4 Πυρήνας.....	23
3.5 Σημείο καμπής	23
3.6 Ασαφές singleton	24
3.7 Μέγεθος ασαφούς συνόλου.....	24
4. ΠΡΑΞΕΙΣ – ΤΕΛΕΣΤΕΣ ΑΣΑΦΩΝ ΣΥΝΟΛΩΝ	25
4.1 Τομή ασαφών συνόλων	25
4.2 Ένωση ασαφών συνόλων.....	25
4.3 Συμπλήρωμα ασαφούς συνόλου.....	25
5. ΣΥΝΑΡΤΗΣΕΙΣ ΣΥΜΜΕΤΟΧΗΣ	27
5.1 Τραπεζοειδής συνάρτηση συμμετοχής.....	27
5.2 Τριγωνική συνάρτηση συμμετοχής	27
5.3 Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής.....	28
5.4 Γκαουσιανή συνάρτηση συμμετοχής	30
5.5 Δισδιάστατες και πολυδιάστατες συναρτήσεις συμμετοχής	30
6. ΑΣΑΦΕΙΣ ΣΧΕΣΕΙΣ, ΛΕΚΤΙΚΕΣ ΜΕΤΑΒΛΗΤΕΣ ΚΑΙ ΚΑΝΟΝΕΣ.....	33
6.1 Ασαφείς σχέσεις.....	33
6.2 Λεκτικές μεταβλητές	33
6.3 Ασαφείς κανόνες	34
7. ΣΥΣΤΗΜΑΤΑ ΑΣΑΦΟΥΣ ΛΟΓΙΚΗΣ – ΑΣΑΦΕΣ ΜΟΝΤΕΛΟ TSK.....	35
7.1 Συστήματα ασαφούς λογικής.....	35
7.2 Το TSK ασαφές μοντέλο.....	36
7.3 Το ζήτημα της αναγνώρισης στα ασαφή συστήματα.....	38
8. ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ – ΠΑΘΟΛΟΓΙΑ ΑΝΑΠΝΕΥΣΤΙΚΩΝ ΗΧΩΝ ΚΑΙ ΜΕΘΟΔΟΙ ΔΙΑΧΩΡΙΣΜΟΥ	43

8.1 Βασικά χαρακτηριστικά των αναπνευστικών ήχων και της σχετιζόμενης παθολογίας.....	43
8.2 Αναδρομή στις προηγούμενες μεθόδους διαχωρισμού των αναπνευστικών ήχων	45
9. ΔΥΝΑΜΙΚΑ ΑΣΑΦΗ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	47
9.1 Από τα στατικά στα δυναμικά συστήματα	47
9.2 Δομές αναδρομικών νευρωνικών και ασαφών μοντέλων	48
9.2.1 Επισκόπηση των αναδρομικών νευρωνικών δικτύων	48
9.2.2 Επισκόπηση των αναδρομικών ασαφών συστημάτων.....	50
9.3 Το δυναμικό ασαφές νευρωνικό δίκτυο DFNN.....	51
9.3.1 TSK ασαφείς κανόνες με νευρωνικά τμήματα απόδοσης	51
9.3.2 Περιγραφή του DFNN.....	52
9.3.3 Ταξινόμηση του DFNN ως μοντέλου αναγνώρισης δυναμικών συστημάτων	55
9.4 Το ζήτημα της αναγνώρισης παραμέτρων στα δυναμικά συστήματα.....	57
9.4.1 Η έννοια της διατεταγμένης παραγώγου.....	57
9.4.2 Εκμάθηση ανά δείγμα και κατά ομάδες	58
9.4.3 Οι τεχνικές εκμάθησης EWBS και EWR	59
9.4.4 Ενημέρωση των παραμέτρων του δικτύου DFNN με χρήση της EWBS	60
9.4.5 Το adjoint μοντέλο ως μέσο υπολογισμού των κλίσεων για το DFNN.....	62
10. ΠΡΟΣΟΜΟΙΩΜΕΝΗ ΑΝΟΠΤΗΣΗ ΔΥΝΑΜΙΚΗ ΕΥΠΡΟΣΑΡΜΟΣΤΗ ΑΝΑΣΤΡΟΦΗ ΔΙΑΔΟΣΗ (SA – DRPROP)	67
10.1 Εισαγωγή	67
10.2 Η μέθοδος SA-DRPROP.....	68
10.2.1 Ο Αλγόριθμος της SA-DRPROP	68
10.2.2 Εξαγωγή των κλίσεων σφάλματος	70
11. ΑΝΑΛΥΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ – ΣΥΜΠΕΡΑΣΜΑΤΑ.....	73
11.1 Υλοποίηση πλατφόρμας δοκιμών και παραμετροποίηση.....	73
11.2 Εξαγωγή αποτελεσμάτων και επεξεργασία.....	79
11.3 Ανάλυση αποτελεσμάτων.....	92
11.4 Συμπεράσματα.....	99
12. ΒΙΒΛΙΟΓΡΑΦΙΑ.....	100

Κατάλογος Σχημάτων

Σχήμα 2.1 Χαρακτηριστική συνάρτηση κλασσικού συνόλου	19
Σχήμα 2.2 Συνάρτηση συμμετοχής ασαφούς συνόλου	20
Σχήμα 3.1 Σημεία καμπής ασαφούς συνόλου	24
Σχήμα 3.2 Ασαφές Singleton	24
Σχήμα 4.1 Τομή των ασαφών συνόλων A και B	25
Σχήμα 4.2 Συμπλήρωμα ασαφούς συνόλου A	26
Σχήμα 5.1 Τραπεζοειδής συνάρτηση συμμετοχής	27
Σχήμα 5.2 Τριγωνική συνάρτηση συμμετοχής	28
Σχήμα 5.3 Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής	28
Σχήμα 5.4 Επίδραση των παραμέτρων $\{a, b, c\}$ στην γενικευμένη καμπανοειδή συνάρτηση συμμετοχής.....	29
Σχήμα 5.5 Γκαουσιανή συνάρτηση συμμετοχής.....	30
Σχήμα 5.6 Δισδιάστατη συνάρτηση συμμετοχής.....	31
Σχήμα 8.1 Ορισμός των IDW και 2CD των τριζόντων επιπρόσθετων αναπνευστικών ήχων. Παράδειγμα ενός λεπτού τρίζοντος.	44
Σχήμα 9.1 Γενική διαμόρφωση της αρχιτεκτονικής του δυναμικού ασαφούς νευρωνικού δικτύου	53
Σχήμα 9.2 Το τμήμα απόδοσης των ασαφών κανόνων.....	54
Σχήμα 9.3 Εξέλιξη καταστάσεων στα μοντέλα σφάλματος εξίσωσης και εξόδου.....	56
Σχήμα 9.4 Συσχέτιση πραγματικού χρόνου και «αντίστροφου χρόνου»	62
Σχήμα 9.5 Το adjoint μοντέλο του τμήματος απόδοσης των ασαφών κανόνων	63
Σχήμα 11. 1 Φίλτρο διαχωρισμού DFNN	73
Σχήμα 11. 2 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (FCst).....	81
Σχήμα 11. 3 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (FCnst).....	83
Σχήμα 11. 4 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (CCst).....	85
Σχήμα 11. 5 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (CCnst).....	87
Σχήμα 11. 6 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (SQst).....	89
Σχήμα 11. 7 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (SQnst).....	91
Σχήμα 11. 8 Λεπτοί τρίζοντες (FC)	94
Σχήμα 11. 9 Τραχείς τρίζοντες (CC)	95
Σχήμα 11. 10 «Κακαρίσματα» (SQ)	96
Σχήμα 11. 11 Απεικόνιση ποιότητας μοντελοποίησης DFNN.....	97

Κατάλογος Πινάκων

Πίνακας 11. 1 Παράμετροι εκπαίδευσης	74
Πίνακας 11. 2 Μέγεθος της Βάσης κανόνων των μοντέλων διαχωρισμού	75
Πίνακας 11. 3 Δομικές παράμετροι δοκιμών μοντέλων διαχωρισμού ήχων.....	75
Πίνακας 11. 4 Υπολογιστικό κόστος του φίλτρου DFNN	79
Πίνακας 11. 5 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - FCst	80

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας 11. 6 Στατιστικά μεγέθη RMSE μοντέλου FCst	81
Πίνακας 11. 7 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - FCnst.....	82
Πίνακας 11. 8 Στατιστικά μεγέθη RMSE μοντέλου FCnst	83
Πίνακας 11. 9 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - CCst	84
Πίνακας 11. 10 Στατιστικά μεγέθη RMSE μοντέλου CCst.....	85
Πίνακας 11. 11 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - CCnst	86
Πίνακας 11. 12 Στατιστικά μεγέθη RMSE μοντέλου CCnst.....	87
Πίνακας 11. 13 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - SQst	87
Πίνακας 11. 14 Στατιστικά μεγέθη RMSE μοντέλου SQst.....	89
Πίνακας 11. 15 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - SQnst	89
Πίνακας 11. 16 Στατιστικά μεγέθη RMSE μοντέλου SQnst.....	90
Πίνακας 11. 17 Ποσοστά δοκιμών ανά z-score	91
Πίνακας 11. 18 Δομικές παράμετροι για το μοντέλο με βέλτιστο RMSE.....	91
Πίνακας 11. 19 Δομικές παράμετροι για το μοντέλο με βέλτιστο Μέγιστο Απόλυτο Σφάλμα	92
Πίνακας 11. 20 Συνολικός ρυθμός ανίχνευσης για κάθε κατηγορία ήχου	92
Πίνακας 11. 21 Ποσοστά διαχωρισμού και επιτευχθέντα RMSE ανά ασθενή	98

Συνομογραφίες

<i>2CD</i>	Two-Cycle Duration
<i>2-D MFs</i>	Two-Dimensional Membership Functions
<i>ANFIS</i>	Adaptive Neuro-Fuzzy Inference System
<i>BP(TT)</i>	Back Propagation (Through Time)
<i>bell_MF</i>	generalized bell Membership Function
<i>CANFIS</i>	Coactive Neuro-Fuzzy Inference System
<i>CC</i>	Coarse Crackles
<i>CPI</i>	Consequent Part Identification
<i>DAS</i>	Discontinuous Adventitious Sounds
<i>D-AFNN</i>	Dynamical Adaptive Fuzzy Neural Network
<i>DFNN</i>	Dynamic Fuzzy Neural Network
<i>EWBS</i>	Epochwise Backsweep
<i>EWR</i>	Epochwise Recursive
<i>FC</i>	Fine Crackles
<i>FIR</i>	Finite Impulse Response
<i>FIS</i>	Fuzzy Inference System
<i>FST-NST filter</i>	Fuzzy Stationary-Nonstationary filter
<i>gauss_MF</i>	gaussian Membership Function
<i>GD</i>	Gradient Descent
<i>G-FGS</i>	Generalized - Frasconi Gori Soda
<i>IDW</i>	Initial Deflection Width
<i>IIR</i>	Infinite Impulse Response
<i>LRGF</i>	Local Recurrent Global Feedforward
<i>MIMO system</i>	Multi-Input-Multiple-Output system
<i>MNN</i>	Memory Neuron Network
<i>(R)MSE</i>	(Root) Mean Squared Error
<i>PPI</i>	Premise Part Identification
<i>QLFM/QNFM</i>	Quasi-Linear/Nonlinear Fuzzy Model
<i>RBF</i>	Radial Basis Function
<i>RFS</i>	Recurrent Fuzzy System
<i>RMF</i>	Rule Membership Function

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

<i>RNeuFuz</i>	R ecurrent N eural F uzzy system
<i>SA-DRPROP</i>	S imulated A nnealing D ynamic R esilient back P RO P agation
<i>SARPROP</i>	S imulated A nnealing R esilient back P RO P agation
<i>SQ</i>	S quawks
<i>ST-NST filter</i>	S tationary- N onstationary <i>filter</i>
<i>mST-NST filter</i>	m odified S tationary- N onstationary filter
<i>TDNN</i>	T ime- D elay N eural N etwork
<i>TDW</i>	T otal- D eflection W idth
<i>trap_MF</i>	t rapezoidal M embership F unction
<i>tri_MF</i>	t riangular M embership F unction
<i>TSK model</i>	T akagi- S ugeno- K ang model
<i>VS</i>	V esicular S ounds
<i>WTST-NST filter</i>	W avelet T ransform-based S tationary- N onstationary filter

1. ΕΙΣΑΓΩΓΗ

Κύρια χαρακτηριστικά του κόσμου που μας περιβάλλει αποτελούν η αβεβαιότητα και η υψηλή πολυπλοκότητα. Αυτή η διαπίστωση είναι αντιληπτή σε όλες τις εκφάνσεις της ζωής, από τις πιο απλές καθημερινές αποφάσεις μας έως αυτές της υψηλής κρισιμότητας για την ανθρώπινη ζωή. Χαρακτηριστικά παραδείγματα κρίσιμων αποφάσεων σε προβλήματα υψηλής πολυπλοκότητας κυριαρχούν καθημερινά στο πεδίο της κλινικής πράξης. Τα βιολογικά συστήματα (μεταξύ άλλων και ο άρρωστος) χαρακτηρίζονται από εξαιρετική πολυπλοκότητα, «η οποία είναι τάξεως μεγέθους πολλαπλώς μεγαλύτερου από αυτό των περισσότερων πολύπλοκων άψυχων συστημάτων, που έχει δημιουργήσει ή περιγράψει ο άνθρωπος», όπως αναφέρει ο «πατέρας» της ασαφούς λογικής Zadeh.

Η τεχνητή νοημοσύνη - μέρος της οποίας αποτελούν και τα συστήματα ασαφούς λογικής - έχει εισχωρήσει σθεναρά μεταξύ άλλων στο πεδίο της ιατρικής, εκμεταλλευόμενη την επιτάχυνση της τεχνολογικής εξέλιξης τα τελευταία χρόνια, σε μία προσπάθεια συνεπικουρίας στην προσπάθεια του εξιδεικευμένου ανθρώπινου δυναμικού σε διάφορους τομείς, όπως π.χ. η διάγνωση ασθενειών.

Στην παρούσα διπλωματική εργασία πρόκειται να εξετάσουμε την απόδοση των Δυναμικών Ασαφών Νευρωνικών Δικτύων (Dynamic Fuzzy Neural Networks - DFNN) στην ανάλυση πνευμονικών ήχων, που λαμβάνονται από ασθενείς με πνευμονική παθολογία, με σκοπό τη διάγνωση. Οι *παθολογικοί διακοπτόμενοι αναπνευστικοί ήχοι* (Discontinuous Adventitious Sounds – DAS) που εντάσσονται στους παθολογικούς ήχους (adventitious sound), διαιρούνται σε *τρίζοντες* (crackles) και *«κακαρίσματα»* (squawks), που χαρακτηρίζονται κυρίως από τα χαρακτηριστικά του χρονικού τους πεδίου, όπως το *συνολικό πλάτος βύθισης* (Total Deflection Width - TDW), το *αρχικό πλάτος βύθισης* (Initial Deflection Width - IDW) και η *διάρκεια δύο περιόδων* (Two-Cycle Duration - 2CD). Η διαδικασία επιτελείται από φίλτρο διαχωρισμού των DAS από τους κυψελιδικούς ήχους (Vesicular Sounds – VS) με τη βοήθεια δύο DFNN που λειτουργούν παράλληλα. Ενδεικτικές παθήσεις που συνδέονται με τις διάφορες κατηγορίες παθολογικών ήχων είναι η συμφορητική καρδιακή ανεπάρκεια (congestive heart failure), η αμυάντωση (asbestosis), η διάμεση ίνωση (interstitial fibrosis), η αλλεργική κυψελίτιδα (allergic alveolitis) κ.ά.

Μία από τις αρχικές ιδέες διαχωρισμού είναι το υπερπαρατό γραμμικό φιλτράρισμα (highpass linear filtering). Ωστόσο, τα αποτελέσματα της μεθόδου αυτής είναι

χαμηλής ποιότητας, καθώς τα διαχωριζόμενα σήματα παρουσιάζουν έντονες παραμορφώσεις. Μία δεύτερη μέθοδος διαχωρισμού είναι η κατωφλίωση πλάτους (level slicing), η οποία παρουσιάζει βελτιωμένα χαρακτηριστικά διαχωρισμού σε σχέση με την προηγούμενη μέθοδο, αλλά αποτυγχάνει στην ανίχνευση και τον διαχωρισμό των DAS μικρού πλάτους. Άλλη μέθοδος που έχει χρησιμοποιηθεί είναι η επιλεκτική μεγέθυνση χρονικών παραθύρων των ηχογραφημένων σημάτων (time-expanded waveform analysis), παρουσιάζοντας έντονη ευαισθησία στην υποκειμενική κάθε φορά επιλογή του υποψήφιου χρονικού παραθύρου, που θα μεγεθυνθεί από τον εκάστοτε αναλυτή, και απαιτεί μεγάλο χρονικό διάστημα παρατήρησης. Η μέθοδος που προτάθηκε από τον Οho και χρησιμοποιεί μη γραμμικό φιλτράρισμα οδηγώντας στην ανάπτυξη ενός στάσιμου-μη στάσιμου φίλτρου ST-NST (Stationary-Nonstationary filter) (εφαρμογή μόνο σε τρίζοντες επιπρόσθετους αναπνευστικούς ήχους), καθώς και των Χατζηλεοντιάδη και Πανά, η οποία χρησιμοποιεί στατιστική τρίτης τάξης και μη γραμμικό φιλτράρισμα, εισάγοντας έτσι το τροποποιημένο στάσιμο-μη στάσιμο φίλτρο mST-NST (modified Stationary-Nonstationary filter), είναι μέθοδοι αυτοματοποιημένου διαχωρισμού με μειονέκτημα τον εμπειρικό ορισμό των παραμέτρων τους. Την πλέον αποτελεσματική μέθοδο αποτελεί το στάσιμο-μη στάσιμο φίλτρο, βασιζόμενο στον μετασχηματισμό κυματιδίων WTST-NST (Wavelet Trans-form-based Stationary-Nonstationary filter) των Χατζηλεοντιάδη και Πανά. Η τελευταία μειονεκτεί στο υπολογιστικό κόστος που απαιτείται με αποτέλεσμα την δυσκολία εφαρμογής σε πραγματικό χρόνο. Μία διαφορετική προσέγγιση στο πρόβλημα του διαχωρισμού προτάθηκε από τον Τόλια, με τη μορφή του στάσιμου-μη στάσιμου φίλτρου, το οποίο βασίζεται σε ασαφή βάση κανόνων FST-NST (Fuzzy rule-based Stationary-Nonstationary filter), η οποία διαχωρίζει επιτυχώς τους τρίζοντες DAS από τους VS σε πραγματικό χρόνο. Η προτεινόμενη μέθοδος αναπτύσσει ένα αναδρομικό νευροασαφές φίλτρο, το οποίο, προς επίτευξη του διαχωρισμού των DAS από τους VS, το οποίο βασίζεται στη μη στάσιμη φύση των πρώτων, με χρήση δύο συστημάτων ασαφούς συμπερασμού FST και FNST με τοπική ανάδραση, τα οποία λειτουργούν παράλληλα τροφοδοτούμενα με το ίδιο διάνυσμα εισόδου και ως επιθυμητές έξοδοι λαμβάνονται οι έξοδοι του φίλτρου WTST-NST. Το φίλτρο που προτείνεται παρουσίασε υψηλή απόδοση, με ποσοστά επιτυχίας από 96,63% έως 100% ανά περίπτωση.

2. ΑΣΑΦΗΣ ΛΟΓΙΚΗ (Fuzzy Logic)

2.1 Εισαγωγή

Τα ασαφή σύνολα είναι επινοήση του Lotfi Zadeh, καθηγητή του Πανεπιστημίου Berkeley της Καλιφόρνια (1965). Αποτελούν γενίκευση των κλασικών (σαφών) συνόλων και της δίτιμης αριστοτελικής λογικής, κατά την οποία «Μία λογική πρόταση μπορεί να είναι αληθής (1) ή ψευδής (0), αποκλείοντας τρίτη λύση» και βάσει αυτής ένα στοιχείο είτε ανήκει είτε δεν ανήκει σε ένα σύνολο. Η καθιέρωση της δίτιμης λογικής από τον 10^ο αιώνα στον δυτικό κόσμο, επήλθε λόγω:

- α) του υψηλού βαθμού απλούστευσης της συλλογιστικής των προβλημάτων,
- β) της απόδοσης απόλυτης «βεβαιότητας» στην απόδοση και «αποδοχή» της αλήθειας.

Τα παραπάνω χαρακτηριστικά όμως επέδειξαν μία ανεπάρκεια ερμηνείας της φυσικής γλώσσας, της ανθρώπινης συμπεριφοράς, καθώς και της – ως επί το πλείστον - ασαφούς πραγματικότητας του κόσμου που μας περιβάλλει. Παράδειγμα αντίφασης της δίτιμης λογικής είναι το ιστορικό λογικό παράδοξο του Κρητικού Επιμενίδη «Κρήτες άει ψεύσται - Οι Κρητικοί λένε πάντα ψέματα».

Ο Επιμενίδης λέει ότι οι Κρητικοί λένε πάντα ψέματα.

Ο Επιμενίδης όμως είναι Κρητικός.

Άρα ο Επιμενίδης λέει ψέματα, ότι οι Κρητικοί ψεύδονται.

Άρα οι Κρητικοί λένε την αλήθεια.

Άρα και ο Επιμενίδης λέει την αλήθεια.

Άρα οι Κρητικοί είναι ψεύτες, κ.ο.κ. (φαύλος κύκλος).

Το ζεύγος ασαφής λογική – ασαφή συστήματα αποτελεί ένα από τα τρία κύρια δομικά στοιχεία, μαζί με τα τεχνητά νευρωνικά δίκτυα (artificial neural networks) και την εξελικτική υπολογιστική, της υπολογιστικής νοημοσύνης (computational intelligence). η οποία με τη σειρά της αποτελεί μέρος του ευρύτερου πεδίου της τεχνητής νοημοσύνης (artificial intelligence). Στον όρο ασαφής λογική (fuzzy logic) η έννοια «ασαφής» δεν αναφέρεται σε αυτή καθ' αυτή τη λογική, δηλαδή τη λογική μεθοδολογία, αλλά στον κόσμο μας, τον οποίο προσπαθεί να περιγράψει. Παρέχει ένα μέσο ποιοτικής περιγραφής των μεγεθών στα οποία ενυπάρχει ασάφεια και απροσδιοριστία, με μηχανισμούς προσεγγιστικού συλλογισμού (approximate reasoning) και εξαγωγής συμπεράσματος (decision making), σε μια προσπάθεια

μοντελοποίησης του ανθρώπινου τρόπου σκέψης και συμπερασμού. Ένα στοιχείο συμμετέχει στο ασαφές σύνολο με ένα ποσοστό (βαθμό) σε ένα διάστημα $[0,1]$.

2.2 Ιστορική αναδρομή

Από την εποχή του Βούδα (5ος αιώνας π.Χ.) και του Πλάτωνα (4ος αιώνας π.Χ.) υπήρχαν αντιρρήσεις περί της ύπαρξης μόνο δύο καταστάσεων, καθώς και ως προς την άποψη ότι αυτές οι δύο καταστάσεις είναι αμοιβαία αποκλειόμενες.

Οι παραπάνω θεωρίες αποκτούν μαθηματική αποτύπωση, τις πρώτες δεκαετίες του 20^{ου} αιώνα με την περιγραφή της τρίτιμης λογικής από τον Πολωνό Jan Lucasiewicz. Ο αμερικανοβρετανός Max Black επινοεί το 1937 ένα είδος συνάρτησης συμμετοχής (membership function). Το 1965 ο ρωσοπερσικής καταγωγής Lotfi Zadeh, επινοεί τα ασαφή σύνολα. Ήταν ήδη ένας επιτυχημένος ακαδημαϊκός, με την ανάπτυξη της έννοιας της *κατάστασης* στο γνωστικό πεδίο της *θεωρίας αυτομάτου ελέγχου* (control theory). Παραταύτα προβληματιζόταν για την αδυναμία της κλασσικής θεωρίας ελέγχου στην ικανοποιητική περιγραφή σύνθετων συστημάτων, λόγω της μεγάλης έμφασής της στην *ακρίβεια* (precision). Ήδη από το 1962 σημείωνε ότι «για να χειριστούμε βιολογικά συστήματα χρειαζόμαστε ένα ριζικά διαφορετικό είδος μαθηματικών, τα μαθηματικά των ασαφών ή νεφελωδών (cloudy) ποσοτήτων, τα οποία δε θα περιγράφονται βάσει κατανομών πιθανοτήτων». Οι αρχικές αντιδράσεις της επιστημονικής κοινότητας ήταν αρνητικές, όπως ενδεικτικά φαίνεται ακολούθως :

«Η ασαφής θεωρία είναι λάθος, λανθασμένη και επιβλαβής. Αυτό που χρειαζόμαστε είναι πιο λογική σκέψη, όχι λιγότερο. Ο κίνδυνος της ασαφούς λογικής είναι ότι θα ενθαρρύνει το είδος της ασαφούς σκέψης που μας έφερε τόσο μεγάλο πρόβλημα. Η ασαφής λογική είναι η κοκαΐνη της επιστήμης.»

Καθηγητής William Kahan UC Berkeley

«Η “Ασαφοποίηση” είναι ένα είδος επιστημονικής επιρροής που τείνει να οδηγήσει σε κοινωνικά ελκυστικά συνθήματα χωρίς να συνοδεύονται από την πειθαρχία της σκληρής επιστημονικής εργασίας και της παρατήρησης των ασθενών.»

Καθηγητής Rudolf Kalman UFlorida

«Η ασάφεια είναι μεταμφιεσμένη πιθανότητα, μπορώ να σχεδιάσω έναν ελεγκτή με πιθανότητα που θα μπορούσε να κάνει το ίδιο πράγμα που θα κάνατε εσείς με ασαφή λογική.»

Καθηγητής Myron Tribus, στην ακρόαση
του ελέγχου ασαφής λογικής του μετρό του Sendai
IEEE Ινστιτούτο, Μάιος 1988.

Τα πιο σημαντικά χρονικά ορόσημα της ασαφούς λογικής είναι τα ακόλουθα:

- 1968 Προτείνεται η έννοια του ασαφούς αλγορίθμου (fuzzy algorithm).
[Zadeh]
- 1970 Προτείνεται η έννοια των ασαφούς λήψης αποφάσεων (fuzzy decision making). [Zadeh, Bellman]
- 1971 Προτείνεται η έννοια της ασαφής διάταξης (fuzzy ordering). [Zadeh]
- 1973,1975 Προτείνεται η έννοια της λεκτικής μεταβλητής (linguistic variable) και των ασαφών κανόνων (fuzzy if-then rules). [Zadeh]

Παραδείγματα εφαρμογών της ασαφούς λογικής

- 1975 Παρουσίαση ενός ασαφούς ελεγκτή για έλεγχο ατμομηχανής
[Αγγλία - Mamdani, Assilian]
- 1976 Προτείνεται ασαφούς ελεγκτής για διαδικασία παραγωγής χάλυβα
[Αγγλία - Tong]
- 1978 Δημιουργία ασαφούς ελεγκτή για κάμινο τσιμέντου
[Δανία - Holmblad, Østergaard]
- 1980 Κατασκευή ασαφούς ελεγκτή για εργοστάσιο καθαρισμού υδάτων
[Ιαπωνία - Sugeno]
- 1983 Ανάπτυξη συστήματος ελέγχου του μετρό
[Ιαπωνία – Yasunobu, Miyamoto]
- 1983 Εφαρμογές στη ρομποτική
[Ιαπωνία – Sugeno, Takagi]
- 1985 Εφαρμογές στη βιομηχανία οχημάτων
[Ιαπωνία – Sugeno, Nishida]
- 1990 Εφαρμογή σε πλυντήρια
[Εταιρία Matsusita]
- 1996 Εφαρμογή σε πλυντήρια
[Εταιρία Siemens]

2.3 Κλασσικά και ασαφή σύνολα

Τα κλασσικά ή συμβατικά σύνολα αποτελούν συλλογές στοιχείων ή μελών, οριζόμενα σε ένα πεδίο ορισμού U (universal set ή universe of discourse) και χαρακτηριζόμενα από μια κοινή ιδιότητα. Με βάση την κλασσική λογική, ένα στοιχείο είτε θα ανήκει είτε δε θα ανήκει στο σύνολο. Θεωρούμε ότι x είναι τα στοιχεία (elements) ή δεδομένα (data) ή αντικείμενα (objects) που αποτελούν το σύνολο U . Θεωρώντας ως πεδίο ορισμού τα – εν δυνάμει – έτη ζωής ενός ανθρώπου σύμφωνα με το ολικό προσδόκιμο ζωής στην Ελλάδα (80 έτη) $\{1,2,3,4,\dots,79,80\}$, το σύνολο A των ετών που χαρακτηρίζουν έναν άνθρωπο ως ανήλικο ορίζεται ως :

$$A = \{x \mid x < 18, x \in U = \{0,1,2,3,4,\dots,79,80\}\}$$

Κατά συνέπεια, μία ηλικία (στοιχείο του πεδίου ορισμού) είτε θα ανήκει είτε δε θα ανήκει στο σύνολο A . Επιπλέον, όλα τα στοιχεία του συνόλου A έχουν την ιδιότητα «ανήλικος» κατά το ίδιο ποσοστό (100%). Ομοίως, όλα τα υπόλοιπα στοιχεία του πεδίου ορισμού U δεν ανήκουν στο σύνολο A κατά 100% ή, εναλλακτικά, ανήκουν στο σύνολο A κατά 0%. Εάν εκφράσουμε με μία τιμή από το πεδίο τιμών $\{0,1\}$ το ποσοστό συμμετοχής σε ένα σύνολο, τότε το σύνολο A μπορεί να περιγραφεί από τη **χαρακτηριστική συνάρτηση** (characteristic function):

$$x_A(x) = \begin{cases} 1, & \text{iff } x \in A \\ 0, & \text{iff } x \notin A \end{cases} \quad (2.1)$$

Όπου *iff* σημαίνει *if and only if* (εάν και μόνο εάν). Η χαρακτηριστική συνάρτηση απεικονίζει το πεδίο ορισμού $U = \{1,2,3,4,\dots,79,80\}$ στο πεδίο τιμών $\{0,1\}$.


Τα κλασσικά σύνολα ονομάζονται εναλλακτικά **σαφή** ή **προσδιορισμένα σύνολα** (crisp sets), καθώς από τον ανωτέρω ορισμό της χαρακτηριστικής συνάρτησης συνάγεται ότι:

α) Στα κλασσικά σύνολα ακολουθείται η αριστοτελική αρχή, όπου οι δύο ομάδες των στοιχείων που ανήκουν και δεν ανήκουν στο σύνολο A είναι αμοιβαία αποκλειόμενες. β) Το όριο του συμβατικού συνόλου είναι σαφές και «απότομο» (crisp), διχοτομώντας κατά τρόπο απόλυτα προσδιορισμένο το πεδίο ορισμού στις δύο παραπάνω ομάδες.

Στο παράδειγμα που προηγήθηκε η ιδιότητα «ανήλικος» είναι απολύτως προσδιορισμένη, με απουσία οποιουδήποτε στοιχείου ασάφειας. Επομένως, είναι προφανές ότι η ενδεδειγμένη λύση είναι η χρήση κλασσικών συνόλων. Σε ορισμένες όμως περιπτώσεις μία ιδιότητα δεν παρουσιάζει ξεκάθαρη ερμηνεία, αντιθέτως παρουσιάζει ασάφεια (fuzziness) ή απροσδιοριστία (vagueness). Επί παραδείγματι, θεωρούμε ως πεδίο ορισμού τις ηλικίες $\{0,1,2,\dots,100\}$ και ως ζητούμενο τη δημιουργία του συνόλου ηλικιών με την ιδιότητα «νέος άνθρωπος». Προσεγγίζοντας την υλοποίηση του ζητουμένου με την αριστοτελική λογική των κλασσικών συνόλων, απαιτείται ο καθορισμός του σημείου διχοτόμησης του συνόλου των ηλικιών κατά απόλυτο τρόπο στις ηλικίες που φέρουν την ιδιότητα «νέος άνθρωπος» και σε αυτές που δεν την φέρουν, π.χ. οι ηλικίες έως και τα 30 έτη, ανήκουν στο σύνολο «νέος άνθρωπος».

Η παραπάνω διαδικασία – εν τέλει – μας οδηγεί στο εξής εννοιολογικό παράδοξο, κατά το οποίο όσοι είναι από 0 έως 25 ετών, είναι μέλη του συνόλου «νέος άνθρωπος» και κατέχουν την ιδιότητα αυτή στο 100%. Αντίθετα, όλες οι υπόλοιπες ηλικίες του πεδίου ορισμού, δηλαδή από 26 έως 100 ετών, φέρουν την ιδιότητα «νέος άνθρωπος» σε ποσοστό 0%. Επομένως με βάση την ανωτέρω λογική, ένας άνθρωπος 1 έτους είναι το ίδιο νέος με έναν άνθρωπο 25 ετών και σε έναν άνθρωπο 26 ετών απουσιάζει η ιδιότητα της νεότητας κατά το ίδιο ποσοστό με έναν άνθρωπο 100 ετών.

A= “Young”

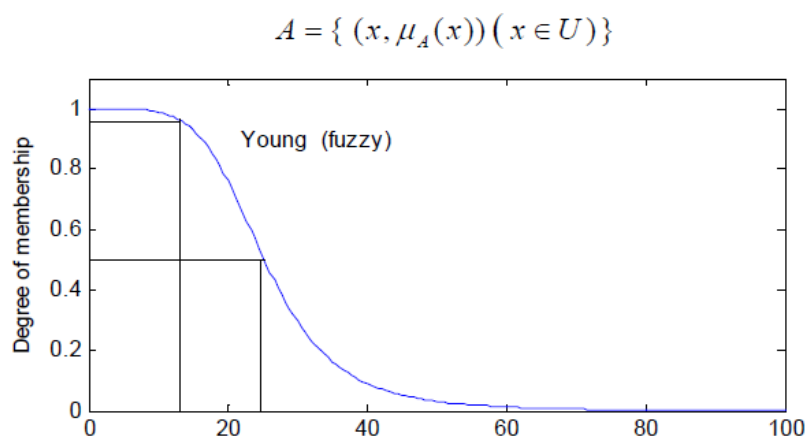


Σχήμα 2.1 Χαρακτηριστική συνάρτηση κλασσικού συνόλου

Είναι εμφανές λοιπόν, πως η χρήση των συμβατικών συνόλων στην συγκεκριμένη περίπτωση δεν ενδείκνυται, καθώς δεν αντικατοπτρίζει τον ανθρώπινο τρόπο

αντίληψης. Στην πραγματικότητα η ιδιότητα της νεότητας φθίνει σταδιακά και όχι απότομα. Κύριο χαρακτηριστικό των ασαφών συνόλων θεωρείται η έννοια της **σταδιακής** ή **βαθμιαίας μετάβασης** από την κατάσταση *συμμετοχής* ενός μέλους στο σύνολο στην κατάσταση της *μη συμμετοχής*, αυξάνοντας την ευελιξία των ασαφών συνόλων στις περιπτώσεις περιγραφών λεκτικών εκφράσεων και εννοιών (π.χ. «νέος άνθρωπος»). Κατ' ουσίαν η ασαφής λογική αποτελεί τη θεμελίωση του αφηρημένου τρόπου αντίληψης του ανθρώπου, ο οποίος αναπαρίσταται γλωσσικά με τη χρήση επιθέτων. Η **συνάρτηση συμμετοχής** (*membership function*) δίνει τη συμμετοχή ενός στοιχείου x στο ασαφές σύνολο A . Ο όρος $\mu_A(x)$ συμβολίζει τη συνάρτηση συμμετοχής και αντιπροσωπεύει τον **βαθμό συμμετοχής** (*membership degree*) του x στο A , παρέχοντας τον βαθμό που το x ανήκει στο A .

Η συνάρτηση συμμετοχής απεικονίζει ένα πεδίο ορισμού U στο πεδίο ορισμού $[0,1]$. Το ζεύγος $(x, \mu_A(x))$ καλείται **ασαφές singleton** (fuzzy singleton).



Σχήμα 2.2 Συνάρτηση συμμετοχής ασαφούς συνόλου

Επομένως στα ασαφή σύνολα ακολουθείται η πλειότιμη λογική του «βαθμού συμμετοχής», με σκοπό την αποτελεσματικότερη περιγραφή των ασαφών και απροσδιόριστων εννοιών του πραγματικού κόσμου. Κατά τον περιορισμό των τιμών της συνάρτησης συμμετοχής σε 0 και 1, έχουμε μετάπτωση του ασαφούς συνόλου στο κλασσικό. Με ανάλογη συλλογιστική προκύπτει ότι η ασαφής λογική μπορεί να θεωρηθεί ως γενίκευση της κλασσικής λογικής.

2.4 Κατηγορίες ασαφών συνόλων

Τα ασαφή σύνολα διαιρούνται σε δύο κατηγορίες

α) Τα **διακριτά ασαφή** σύνολα, τα οποία περιγράφονται με ασυνεχείς συναρτήσεις συμμετοχής, καθώς αναπτύσσονται σε **διακριτό πεδίο ορισμού** (discrete universe of discourse). Ένα διακριτό ασαφές σύνολο περιγράφεται με βάση τα ζεύγη ασαφών singleton.

Έστω ότι το πεδίο ορισμού ορίζεται ως εξής:

$$U = \{x_1, x_2, \dots, x_n\} \quad (2.2)$$

Το διακριτό ασαφές σύνολο περιγράφεται ως εξής:

$$\mu_A = \{(x_1, \mu_A(x_1)), (x_2, \mu_A(x_2)), \dots, (x_n, \mu_A(x_n))\} \quad (2.3)$$

$$A = \mu_1 / x_1 + \mu_2 / x_2 + \dots + \mu_n / x_n \quad (2.4)$$

Τα σύμβολα «+» και «/» στην Εξ. (2.4) δεν υποδηλώνουν το αλγεβρικό άθροισμα και τη διαίρεση, αλλά την ένωση των ασαφών singleton και το ασαφές singleton $(x_i, \mu_A(x_i))$ κατ' αντιστοιχία. Τα στοιχεία του U που παρουσιάζουν μηδενικό βαθμό συμμετοχής συνήθως παραλείπονται.

β) Τα **συνεχή ασαφή** σύνολα, τα οποία περιγράφονται από συνεχείς συναρτήσεις συμμετοχής καθώς έχουν **συνεχές πεδίο ορισμού** (continuous universe of discourse).

$$A = \int_U \frac{\mu_A(x)}{x} \quad (2.5)$$

Το σύμβολο \int_U συμβολίζει την ένωση των ασαφών singleton και όχι την έννοια του αλγεβρικού ολοκληρώματος.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

3. ΙΔΙΟΤΗΤΕΣ – ΟΡΙΣΜΟΙ ΑΣΑΦΩΝ ΣΥΝΟΛΩΝ

3.1 Σύνολο υποστήριξης

Το **σύνολο υποστήριξης** ή **ενεργός περιοχή** ή **στήριγμα** ή **φορέας** (support) ενός συνόλου **A** είναι ένα σαφές σύνολο που εμπεριέχει το σύνολο των στοιχείων x του U για τα οποία ισχύει $\mu_A(x) > 0$

$$Support(A) = \{x \in U \mid \mu_A(x) > 0\} \quad (3.1)$$

3.2 Ύψος

Το **ύψος** (height) ενός ασαφούς συνόλου **A** αποτελεί τη μέγιστη τιμή της συνάρτησης συμμετοχής $\mu_A(x)$ στο δεδομένο σύνολο U .

$$Height(A) = \sup_{x \in U} (\mu_A(x)) = \max_{x \in U} (\mu_A(x)) \quad (3.2)$$

3.3 Κανονικό ασαφές σύνολο

Το **κανονικό** ή **κανονικοποιημένο** (normal – normalized fuzzy set) ασαφές σύνολο έχει ως τιμή ύψους τη μονάδα. $Height(A) = 1$. Σε διαφορετική περίπτωση ($Height(A) < 1$) το ασαφές σύνολο χαρακτηρίζεται ως υποκανονικό (**subnormal**).

3.4 Πυρήνας


Ο **πυρήνας** ή **κόρος** (core ή kernel) ενός ασαφούς συνόλου **A** είναι ένα κλασσικό σύνολο των στοιχείων x του U για τα οποία ισχύει $\mu_A(x) = 1$. Στα κανονικά ασαφή σύνολα υπάρχει τουλάχιστον μία τιμή του x για την οποία ισχύει η ανωτέρω ισότητα.

3.5 Σημείο καμπής

Σημείο καμπής (crossover point) χαρακτηρίζεται το σημείο x του πεδίου ορισμού U εφόσον για το συγκεκριμένο σημείο ισχύει $\mu_A(x) = 0.5$

$$Crossover(A) = \{x \in U \mid \mu_A(x) = 0.5\} \quad (3.3)$$

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.




Σχήμα 3.1 Σημεία καμπής ασαφούς συνόλου

3.6 Ασαφές singleton

Ένα ασαφές σύνολο A καλείται **ασαφές singleton** (fuzzy singleton) όταν το σύνολο υποστήριξής του (support) έχει ένα και μοναδικό σημείο x_0 , για το οποίο ισχύει:

$$\mu_A(x_0) = 1 \text{ και } \mu_A(x) = 0 \quad \forall x \neq x_0, x \in U \quad (3.4)$$



Σχήμα 3.2 Ασαφές Singleton

3.7 Μέγεθος ασαφούς συνόλου

Το **μέγεθος** ή **πληθάριθμος** (cardinality) ενός ασαφούς συνόλου A (συμβολισμός $|A|$) καλείται το άθροισμα των βαθμών συμμετοχής του συνόλου των στοιχείων του.

$$|A| = \sum_{x \in U} \mu_A(x) \quad (3.5)$$

Αποτελεί γενίκευση του μεγέθους των κλασικών συνόλων, στα οποία το μέγεθος ταυτίζεται με τον αριθμό των στοιχείων που ανήκουν στο σύνολο.


4. ΠΡΑΞΕΙΣ – ΤΕΛΕΣΤΕΣ ΑΣΑΦΩΝ ΣΥΝΟΛΩΝ

4.1 Τομή ασαφών συνόλων

Η **τομή** (intersection) δύο ασαφών συνόλων **A** και **B**, στο ίδιο πεδίο ορισμού U , είναι ένα **ασαφές σύνολο C**, με συμβολισμό και συνάρτηση συμμετοχής

$$\mu_C(x) = \mu_A(x) \wedge \mu_B(x) \quad (4.1)$$

Ο τελεστής **min** (\wedge), ο οποίος χρησιμοποιείται στην ανωτέρω συνάρτηση (4.1), βρίσκει το ελάχιστο μεταξύ δύο στοιχείων και αντιστοιχεί στη λογική πράξη **AND** («και»), $C = A \cap B = A \text{ AND } B$.



Σχήμα 4.1 Τομή των ασαφών συνόλων **A** και **B**

4.2 Ένωση ασαφών συνόλων

Η **ένωση** (intersection) δύο ασαφών συνόλων **A** και **B**, στο ίδιο πεδίο ορισμού U είναι ένα **ασαφές σύνολο C**, με συμβολισμό $C = A \cup B$ και συνάρτηση συμμετοχής

$$\mu_C(x) = \mu_A(x) \vee \mu_B(x) \quad (4.2)$$

Ο τελεστής **max** (\vee), ο οποίος χρησιμοποιείται στην ανωτέρω συνάρτηση (4.2), βρίσκει το ελάχιστο μεταξύ δύο στοιχείων και αντιστοιχεί στη λογική πράξη **OR** («ή»), $C = A \cup B = A \text{ OR } B$.

4.3 Συμπλήρωμα ασαφούς συνόλου

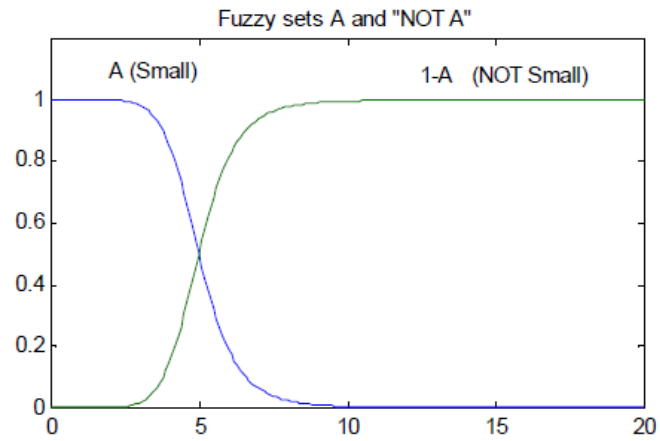
Το **συμπλήρωμα** (complement) ενός συνόλου **A** είναι ένα **ασαφές σύνολο**.

Συμβολίζεται ως \bar{A} και η συνάρτηση συμμετοχής του είναι η παρακάτω,

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \forall x \in U \quad (4.3)$$

και σχετίζεται στην ασαφή λογική με την έννοια της άρνησης $\bar{A} = \text{NOT } A$.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.




Σχήμα 4.2 Συμπλήρωμα ασαφούς συνόλου A

5. ΣΥΝΑΡΤΗΣΕΙΣ ΣΥΜΜΕΤΟΧΗΣ

5.1 Τραπεζοειδής συνάρτηση συμμετοχής

Η **τραπεζοειδής συνάρτηση συμμετοχής** (trapezoidal Membership Function, trap_MF) η οποία είναι μία *τμηματικά γραμμική συνάρτηση* (piecewise-linear function) χαρακτηριζόμενη από τέσσερις παραμέτρους $\{a, b, c, d\}$, που αντιστοιχούν στις τέσσερις κορυφές του τραπεζίου και οι οποίες καθορίζουν την ενεργό περιοχή και τον πυρήνα αυτής.

$$\text{trap_MF}(x; a, b, c, d) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & b \leq x < c \\ \frac{d-x}{d-c}, & c \leq x < d \\ 0, & d \leq x \end{cases} \quad (5.1)$$




Σχήμα 5.1 Τραπεζοειδής συνάρτηση συμμετοχής

5.2 Τριγωνική συνάρτηση συμμετοχής

Η **τριγωνική συνάρτηση συμμετοχής** (triangular Membership Function, tri_MF) είναι κατ' ουσίαν μία τραπεζοειδής συνάρτηση όπου απουσιάζει ο οριζόντιος κλάδος, εάν ισχύει το $b = c$. Επομένως η τριγωνική συνάρτηση περιγράφεται από τρεις παραμέτρους $\{a, b, c\}$, οι οποίες αντιστοιχούν στις τρεις κορυφές του τριγώνου.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

$$tri_MF(x; a, b, c) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ \frac{c-x}{c-b}, & b \leq x < c \\ 0, & c \leq x \end{cases} \quad (5.2)$$




Σχήμα 5.2 Τριγωνική συνάρτηση συμμετοχής

5.3 Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής

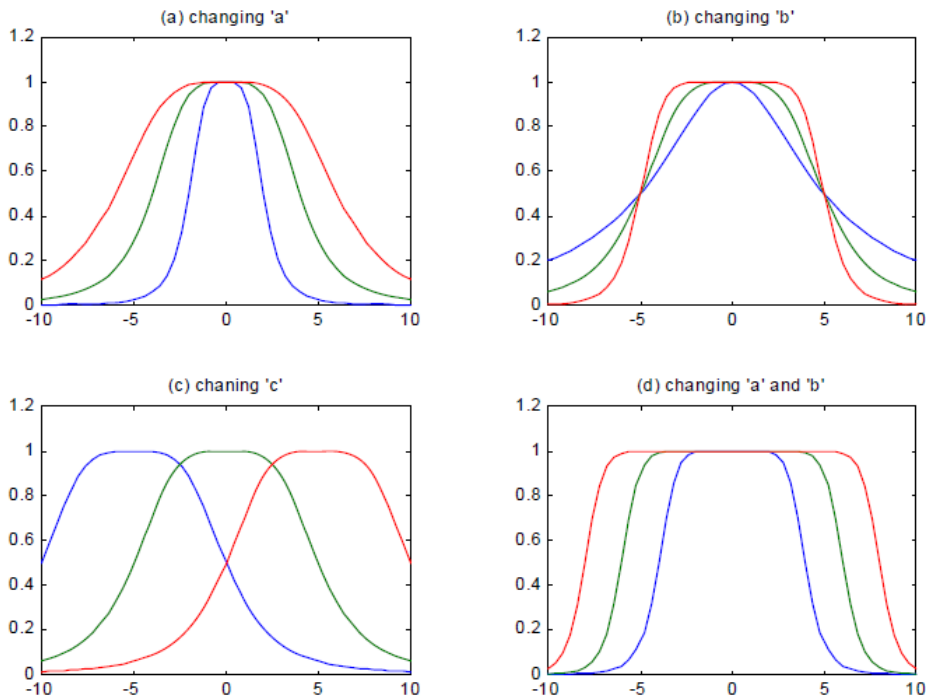
Η *γενικευμένη καμπανοειδής* ή *κωδωνοειδής* συνάρτηση συμμετοχής (generalized bell-shaped Membership Function, bell_MF) περιγράφεται από τρεις παραμέτρους.

$$bell_MF(x; a, b, c) = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}} \quad (5.3)$$



Σχήμα 5.3 Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής

Το σημείο c αποτελεί τον κόρο της συνάρτησης και η τιμή του το κέντρο συμμετρίας αυτής. Στις θέσεις $c \pm a$ έχουμε τα δύο σημεία καμπής της συνάρτησης. Επομένως η «παράμετρος» a ελέγχει το εύρος της συνάρτησης συμμετοχής, με την τιμή της να επηρεάζει αναλογικά το «εύρος» αυτής. Η κλίση στα σημεία καμπής είναι $-\frac{b}{2a}$ με την παράμετρο b να ελέγχει τον ρυθμό πτώσης, μεταβάλλοντας την κλίση της συνάρτησης συμμετοχής στον ανερχόμενο (αριστερό) και κατερχόμενο (δεξιό) κλάδο. Η τιμή του b έχει αναλογική σχέση με τον ρυθμό πτώσης, με την αύξηση της τιμής να προκαλεί μείωση της κλιμάκωσης των από τους υψηλούς βαθμούς συμμετοχής στους χαμηλούς βαθμούς συμμετοχής. Επομένως όσο το b αυξάνεται, τόσο το ασαφές σύνολο τείνει να γίνει σαφές (crisp). Από τα παραπάνω προκύπτει ο έλεγχος που ασκεί η παράμετρος b – με τρόπο αντιστρόφως ανάλογο – στον βαθμό «ασάφειας» του ασαφούς συνόλου, με αποτέλεσμα να θεωρείται και ως «**ασαφοποιητής**» (fuzzifier).



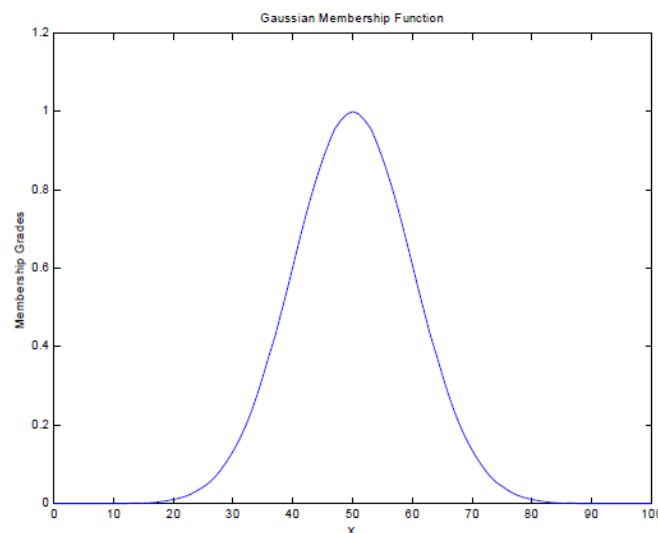
Σχήμα 5.4 Επίδραση των παραμέτρων $\{a, b, c\}$ στην γενικευμένη καμπανοειδή συνάρτηση συμμετοχής

5.4 Γκαουσιανή συνάρτηση συμμετοχής

Η **γκουσιανή** συνάρτηση συμμετοχής (gaussian Membership Function, gauss_MF) έχει δύο παραμέτρους $\{m, \sigma\}$ και περιγράφεται από την παρακάτω συνάρτηση:

$$\text{gauss_MF}(x; m, \sigma) = e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2} \quad (5.4)$$

Οι παράμετροι m και σ είναι το κέντρο συμμετρίας της συνάρτησης gauss_MF (δηλ. το σημείο εστίασης της συνάρτησης συμμετοχής) και η τυπική απόκλιση της κατανομής που ελέγχει τη διασπορά (δηλ. το «εύρος» συνάρτησης συμμετοχής) αντίστοιχα. Τα σημεία $m \pm \sigma$ είναι περίπου τα σημεία καμπής της συνάρτησης, καθώς $\text{gauss_MF}(m \pm \sigma; m, \sigma) = e^{-0.5} = 0.6$




Σχήμα 5.5 Γκαουσιανή συνάρτηση συμμετοχής

5.5 Δισδιάστατες και πολυδιάστατες συναρτήσεις συμμετοχής

Τέτοιου είδους συναρτήσεις συναντώνται συχνά σε ασαφή συστήματα δύο, τριών ή και περισσότερων εισόδων. Σε αυτές τις περιπτώσεις είναι απαραίτητο να δημιουργήσουμε είτε δισδιάστατες συναρτήσεις συμμετοχής MFs (two-dimensional Membership Functions, 2-D MFs) δύο εισόδων x και y , οι οποίες κινούνται σε διαφορετικούς χώρους X και Y , είτε περισσότερες συναρτήσεις ανάλογα με τον αριθμό των εισόδων που κινούνται στον αντίστοιχο αριθμό χώρων. Στη βιβλιογραφία αναφέρονται δύο βασικές μέθοδοι για τη σύνθεση MFs δύο διαστάσεων, η **συνθετική** και η **μη συνθετική** μέθοδος. Στην πρώτη περίπτωση της συνθετικής μεθόδου, η δισδιάστατη συνάρτηση δημιουργείται ως συνδυασμός

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

των αναλυτικών συναρτήσεων συμμετοχής ξεχωριστά προς την εκάστοτε διάσταση. Στην περίπτωση της μη συνθετικής μεθόδου η συνολική συνάρτηση συμμετοχής είναι μία δισδιάστατη αναλυτική συνάρτηση άλλης μορφής.



Σχήμα 5.6 Δισδιάστατη συνάρτηση συμμετοχής

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

6. ΑΣΑΦΕΙΣ ΣΧΕΣΕΙΣ, ΛΕΚΤΙΚΕΣ ΜΕΤΑΒΛΗΤΕΣ ΚΑΙ ΚΑΝΟΝΕΣ

6.1 Ασαφείς σχέσεις

Η ασαφής σχέση είναι ένα ασαφές σύνολο, οριζόμενο στον πολυδιάστατο χώρο $U = X_1 \times X_2 \times \dots \times X_n$ η περιγραφή της οποίας ακολουθεί :

$$R(X_1 \times X_2 \times \dots \times X_n) = \{(x_1, x_2, \dots, x_n), \mu_R(x_1, x_2, \dots, x_n) | x_1 \in X_1, x_2 \in X_2, \dots, x_n \in X_n\} \quad (6.1)$$

Το $\mu_R(x_1, x_2, \dots, x_n)$ συμβολίζει τον βαθμό συμμετοχής του στοιχείου (x_1, x_2, \dots, x_n) στη σχέση $R(X_1 \times X_2 \times \dots \times X_n)$, κινούμενο στο διάστημα $[0,1]$.

Καθότι ασαφές σύνολο και κατ' αντιστοιχία αυτών, η ασαφής σχέση μπορεί να χαρακτηριστεί ως διακριτή ή συνεχής, όπως παρουσιάζονται κατ' αντιστοιχία ακολούθως :

$$R(X_1 \times X_2 \times \dots \times X_n) = \sum_U \frac{\mu_R(x_1, x_2, \dots, x_n)}{(x_1, x_2, \dots, x_n)} \quad (6.2)$$

$$R(X_1 \times X_2 \times \dots \times X_n) = \int_U \frac{\mu_R(x_1, x_2, \dots, x_n)}{(x_1, x_2, \dots, x_n)} \quad (6.3)$$

6.2 Λεκτικές μεταβλητές

Όπως σημειώνει ο Zadeh, οι συμβατικές τεχνικές ανάλυσης συστημάτων είναι ακατάλληλες να διαχειρισθούν την πληροφορία που εμπεριέχεται στην ανθρώπινη σκέψη και τη φυσική γλώσσα, καθώς αυτές επηρεάζονται από την κρίση, την αντίληψη και τα συναισθήματα. Για τον λόγο αυτό πρότεινε την έννοια των *λεκτικών* ή *γλωσσικών* μεταβλητών (linguistic variables) ως μία εναλλακτική προσέγγιση στη μοντελοποίηση της ανθρώπινης σκέψης.

Μια λεκτική μεταβλητή χαρακτηρίζεται από την πεντάδα: $(x, T(x), X, G, M)$, όπου

- x είναι το όνομα της ασαφούς μεταβλητής, π.χ. «θερμοκρασία».
- $T(x)$ είναι το *σύνολο των λεκτικών όρων* (term set), π.χ. $T(\text{θερμοκρασία}) = \{\text{«χαμηλή»}, \text{«μέση»}\}$.
- X είναι το *πεδίο ορισμού* της λεκτικής μεταβλητής.
- G είναι ένας *συντακτικός κανόνας* (syntactic rule), ο οποίος παράγει τους όρους του $T(x)$.

- M είναι ένας ερμηνευτικός κανόνας (semantic rule), ο οποίος προσδίδει σε κάθε λεκτικό όρο $A \in T(x)$ μία συνάρτηση συμμετοχής $\mu_A(x)$.

6.3 Ασαφείς κανόνες

Οι ασαφείς κανόνες (fuzzy IF-THEN rules) είναι υποθετικές προτάσεις, οι οποίες έχουν την ακόλουθη γενική μορφή:

$$IF \ x \ is \ A \ THEN \ y \ is \ B \quad (6.4)$$

όπου οι A και B είναι λεκτικοί όροι των x και y , οριζόμενοι από ασαφή σύνολα στους χώρους X και Y , αντίστοιχα. Οι εκφράσεις $x \ is \ A$ και $y \ is \ B$ είναι ασαφείς προτάσεις (fuzzy propositions) και αποτελούν τα δύο τμήματα του υποθετικού λόγου (1.21). Το αριστερό τμήμα του ασαφούς κανόνα, $IF \ x \ is \ A$, καλείται *τμήμα υπόθεσης* ή *προαπαίτησης* (pre-conditional part, premise part) και περιλαμβάνει την υπόθεση. Το δεξιό τμήμα του ασαφούς κανόνα, $THEN \ y \ is \ B$, είναι το *τμήμα απόδοσης* ή *συμπεράσματος* (consequent part) και περιλαμβάνει το συμπέρασμα του κανόνα.

Ο ασαφής κανόνας (6.4) εναλλακτικά περιγράφεται ως $A \rightarrow B$ και ορίζει μια ασαφή σχέση ανάμεσα στις μεταβλητές x και y , η οποία συσχετίζει τον βαθμό εκπλήρωσης της υπόθεσης με εκείνον του συμπεράσματος. Οι ασαφείς κανόνες αποτελούν τα βασικά δομικά στοιχεία ενός συστήματος εξαγωγής ασαφών συμπερασμάτων.

7. ΣΥΣΤΗΜΑΤΑ ΑΣΑΦΟΥΣ ΛΟΓΙΚΗΣ – ΑΣΑΦΕΣ ΜΟΝΤΕΛΟ TSK

7.1 Συστήματα ασαφούς λογικής

Το σύστημα ασαφούς λογικής παράγει μία απεικόνιση ενός χώρου εισόδου $U \subset \mathfrak{R}^m$ σε ένα χώρο εξόδου $V \subset \mathfrak{R}^r$. Ας θεωρηθεί η πλέον γενική περίπτωση όπου το σύστημα είναι πολλών εισόδων, πολλών εξόδων (multiple-input, multiple-output system, MIMO system). θεωρώντας m τον αριθμό των εισόδων και r τον αριθμό των εξόδων, τόσο ο χώρος εισόδου όσο και ο χώρος εξόδου θα είναι πολυδιάστατοι, ο μεν οριζόμενος ως $U = U_1 \times \dots \times U_m$ και ο δε ως $V = V_1 \times \dots \times V_r$, όπου $U_i, V_j \subset \mathfrak{R}$. Έστω $u = [u_1 \ u_2 \ \dots \ u_m]^T$ και $y = [y_1 \ y_2 \ \dots \ y_r]^T$ τα διανύσματα εισόδου και εξόδου, αντίστοιχα. Το σύστημα ασαφούς λογικής αποτελείται από τα ακόλουθα λειτουργικά τμήματα :

- τον *ασαφοποιητή* (fuzzifier), ο οποίος μετασχηματίζει τις σαφείς (crisp) εισόδους σε βαθμούς συμμετοχής των λεκτικών μεταβλητών.
- τη *βάση κανόνων* (rule base), η οποία συνιστά μία συλλογή ασαφών IF-THEN κανόνων.
- τη *μονάδα ασαφούς συμπερασμού* (fuzzy inference unit), η οποία επεξεργάζεται τις εξόδους του ασαφοποιητή και χρησιμοποιεί τη βάση κανόνων για να εξαγάγει τις εξόδους των κανόνων.
- τον *αποασαφοποιητή* (defuzzifier), η οποία παράγει τις τελικές εξόδους του συστήματος.

Ανάλογα με τη μορφή των τμημάτων απόδοσης των κανόνων και τον τρόπο συμπερασμού των εξόδων των κανόνων, τα συστήματα ασαφούς λογικής διακρίνονται σε δύο μείζονες κατηγορίες: α) τα μοντέλα Mamdani, σύμφωνα με τα οποία οι έξοδοι των κανόνων είναι ασαφή σύνολα και β) τα μοντέλα Takagi-Sugeno-Kang (TSK), σύμφωνα με τα οποία οι έξοδοι των κανόνων είναι συναρτήσεις των εισόδων. Τα μοντέλα Mamdani επιχειρούν να μοντελοποιήσουν μία διαδικασία παρέχοντας μία ποιοτική περιγραφή της λειτουργίας του συστήματος. Συνιστώνται για τις περιπτώσεις όπου η γνώση του συστήματος προσφέρεται από εμπειρογνώμονες. Τα TSK μοντέλα συνίστανται από μία συλλογή γραμμικών ή μη γραμμικών υπομοντέλων (τμήματα απόδοσης των ασαφών κανόνων), τα οποία συνδέονται μη γραμμικά μέσω των τμημάτων υπόθεσης των κανόνων. Συγκρινόμενα με τα μοντέλα Mamdani, εμφανίζουν διευρυμένες δυνατότητες

διαχείρισης της γνώσης, όταν αυτή παρέχεται στη μορφή δεδομένων εισόδου-εξόδου. Το γεγονός ότι οι έξοδοι των κανόνων αποτελούν συναρτήσεις των εισόδων προσδίδει μεγάλη ευελιξία στην ανάπτυξη κανόνων και τα TSK μοντέλα απαιτούν μικρότερη βάση κανόνων από τα μοντέλα Mamdani. Με βάση τα παραπάνω, στην εργασία θα χρησιμοποιηθεί το TSK ασαφές μοντέλο, το οποίο αναπτύσσεται ακολούθως.

7.2 Το TSK ασαφές μοντέλο

Το TSK ασαφές μοντέλο συνίστανται από γλωσσικούς κανόνες IF-THEN, οι οποίοι μπορούν να παρασταθούν με την ακόλουθη γενική μορφή, για την περίπτωση ενός συστήματος MIMO:

$$\begin{aligned} R^{(j)}: & \text{ IF } u_1 \text{ is } A_1^j \text{ AND } u_2 \text{ is } A_2^j \text{ AND } \dots \text{ AND } u_m \text{ is } A_m^j \\ & \text{ THEN } g_j^{(1)} = g_j^{(1)}(\mathbf{u}) \text{ AND } \dots \text{ AND } g_j^{(r)} = g_j^{(r)}(\mathbf{u}) \quad j=1, \dots, n \end{aligned} \quad (7.1)$$

όπου m είναι ο αριθμός των εισόδων, r ο αριθμός των εξόδων και n ο αριθμός των κανόνων, αντίστοιχα. Ο όρος $g_j^{(k)}$ είναι μία μη γραμμική συνάρτηση των μεταβλητών εισόδου και εκφράζει τη συμβολή του j -στού κανόνα στην k -στή συνιστώσα του διανύσματος εξόδου. Οι A_i^j είναι λεκτικοί όροι των ασαφών συνόλων που αναφέρονται στον j -στό κανόνα. Κάθε A_i^j συνδέεται με μία συνάρτηση συμμετοχής $\mu_{A_i^j}(u_i)$, η οποία καθορίζει το βαθμό κατά τον οποίο ένα δεδομένο εισόδου u_i ανήκει στο ασαφές σύνολο A_i^j . Οι συναρτήσεις συμμετοχής, που χρησιμοποιούνται, είναι γκαουσιανές. Οι παράμετροι των συναρτήσεων συμμετοχής συνιστούν το σύνολο των παραμέτρων υπόθεσης.

Ο βαθμός εκπλήρωσης (degree of fulfilment) κάθε κανόνα $R^{(j)}$ δίνεται από την ακόλουθη σχέση:

$$\mu_j(\mathbf{u}) = \mu_{A_1^j}(u_1) \cdot \mu_{A_2^j}(u_2) \cdot \dots \cdot \mu_{A_m^j}(u_m) \quad (7.2)$$

Ο βαθμός εκπλήρωσης ενός κανόνα εκφράζει το ποσοστό κατά το οποίο συμβάλλει ο κανόνας στην εξαγωγή της συνολικής εξόδου του συστήματος, όταν το τελευταίο δέχεται ως είσοδο το διάνυσμα \mathbf{u} , εκφράζει δηλαδή το επίπεδο ενεργοποίησης του κανόνα.

Τα ασαφή σύνολα ενός κανόνα σχηματίζουν μία ασαφή περιοχή (ομάδα) μέσα στο χώρο υπόθεσης, $A_1^j \times A_2^j \times \dots \times A_m^j$, με κατανομή συμμετοχής που περιγράφεται από την (7.2). Με αυτό τον τρόπο, εφόσον κάθε κανόνας σχετίζεται με μία ασαφή περιοχή, η τελευταία μπορεί να θεωρηθεί ως το πολυδιάστατο ασαφές σύνολο του κανόνα, χαρακτηριζόμενο από τη συνάρτηση συμμετοχής του κανόνα (rule membership function, RMF). Η συνάρτηση $\mu_j(z)$ έχει τα χαρακτηριστικά συνάρτησης συμμετοχής πολυδιάστατου συνόλου, με κέντρο το σημείο $c_j = [m_{1j}, \dots, m_{mj}]^T$ και τα αντίστοιχα ασαφή σύνολα να αντιπροσωπεύουν τις προβολές της στους άξονες εισόδου. Χάριν απλότητας, εφεξής η ασαφής περιοχή θα δηλώνεται ως RMF .

Δοθέντος ενός διανύσματος εισόδου \mathbf{u} , η k -στή συνιστώσα εξόδου y_k του ασαφούς συστήματος εξάγεται με χρήση της μεθόδου αποασαφοποίησης του σταθμισμένου μέσου (weighted average defuzzification method) :

$$y_k = \frac{\sum_{j=1}^n \mu_j g_j^{(k)}}{\sum_{j=1}^n \mu_j} \quad k = 1, \dots, r \quad (7.3)$$

Το ασαφές μοντέλο που περιγράφεται από τις εξισώσεις (7.1)-(7.3) και έχει ως εξόδους των κανόνων μη γραμμικές συναρτήσεις, ονομάζεται quasinonlinear ασαφές μοντέλο (Quasi-Nonlinear Fuzzy Model - QNFM). Αν οι έξοδοι των κανόνων γίνουν γραμμικά πολυώνυμα των εισόδων:

$$g_j^{(k)} = w_{0j}^{(k)} + w_{1j}^{(k)} u_1 + \dots + w_{mj}^{(k)} u_m \quad k = 1, \dots, r, \quad j = 1, \dots, n \quad (7.4)$$

οδηγούμαστε στο quasilinear ασαφές μοντέλο (Quasi-Linear Fuzzy Model - QLFM), το οποίο ταυτίζεται με το συμβατικό TSK μοντέλο. Οι $\mathbf{w}_j^{(k)} = [w_{0j}^{(k)}, w_{1j}^{(k)}, \dots, w_{mj}^{(k)}]^T$ είναι πολυωνυμικοί συντελεστές, οι οποίοι σχηματίζουν το σύνολο των παραμέτρων απόδοσης.

Τα TSK μοντέλα αποσκοπούν στο διαχωρισμό του χώρου υπόθεσης (premise space) σε n ασαφείς περιοχές και την προσέγγιση του συστήματος σε κάθε περιοχή με βάση τη συνάρτηση που δημιουργούν οι είσοδοι (για τα QLFM μοντέλα ο χώρος απόδοσης είναι ένα υπερεπίπεδο). Υπ' αυτή την έννοια το συνολικό ασαφές μοντέλο μπορεί να θεωρηθεί ως μία σύνθεση διασυνδεδεμένων απλούστερων

υποσυστημάτων, καθένα από τα οποία περιγράφονται με τον όρο $g_j^{(k)}$. Τόσο το QLFM όσο και το QNFM είναι μη γραμμικά μοντέλα, ένεκα του τμήματος υπόθεσης επιπρόσθετα στα QNFM εισάγεται μη γραμμικότητα και στα τμήματα απόδοσης. Στην περίπτωση που το πολυώνυμο της (7.4) γίνει μηδενικής τάξης (σταθερός συντελεστής), το TSK μοντέλο ταυτίζεται με το μοντέλο Mamdani, όταν η έξοδος κανόνα του τελευταίου είναι σαφής (crisp).

Στον TSK ασαφή κανόνα της (7.1) τα τμήματα υπόθεσης και απόδοσης έχουν κοινό διάνυσμα εισόδου. Η (7.1) μπορεί να γενικευθεί εισάγοντας διαφορετικά διανύσματα εισόδου στα δύο τμήματα. Στην περίπτωση αυτή γίνεται

$$R^{(j)}: IF z_1 \text{ is } A_1^j \text{ AND } \dots \text{ AND } z_m \text{ is } A_m^j \text{ THEN } g_j^{(k)} = g_j^{(k)}(u_1, \dots, u_n) \quad (7.5)$$

Το διάνυσμα $z = [z_1, \dots, z_m]^T$ είναι το διάνυσμα εισόδου του τμήματος υπόθεσης και ορίζεται στο χώρο υπόθεσης $Z = Z_1 \times \dots \times Z_m \subset \mathfrak{R}^m$, ενώ $u = [u_1, \dots, u_n]^T$ είναι το διάνυσμα εισόδου του χώρου απόδοσης και ορίζεται στο χώρο $U = U_1 \times \dots \times U_n \subset \mathfrak{R}^n$. Το συνολικό διάνυσμα εισόδου του ασαφούς συστήματος είναι $x = [z^T, u^T]^T$ και έχει πεδίο ορισμού $\mathfrak{X} = Z \times U$. Η (7.3) λαμβάνει τη μορφή

$$y_k = \frac{\sum_{j=1}^n \mu_j(z) g_j^{(k)}(u)}{\sum_{j=1}^n \mu_j(z)} = \sum_{j=1}^n v_j(z) g_j^{(k)}(u), \quad k = 1, \dots, r \quad (7.6)$$

όπου

$$v_j(z) = \frac{\mu_j(z)}{\sum_{j=1}^n \mu_j(z)} \quad (7.7)$$

είναι ο κανονικοποιημένος βαθμός εκπλήρωσης κανόνα.

7.3 Το ζήτημα της αναγνώρισης στα ασαφή συστήματα

Η αναγνώριση ενός ασαφούς συστήματος αφορά στον καθορισμό της δομής και των παραμέτρων όλων των λειτουργικών τμημάτων του συστήματος. Στην παρούσα περίπτωση έχουν καθορισθεί οι λειτουργίες του ασαφοποιητή (ασαφοποίηση με χρήση γκαουσιανών συναρτήσεων συμμετοχής), του αποασαφοποιητή (μέθοδος αποασαφοποίησης του σταθμισμένου μέσου), το είδος

των κανόνων και του ασαφούς συμπερασμού (TSK). Έτσι η διαδικασία αναγνώρισης περιλαμβάνει πλέον την αναγνώριση των τμημάτων υπόθεσης (Premise Part Identification, PPI) και απόδοσης (Consequent Part Identification, CPI) των ασαφών κανόνων.

Η αναγνώριση του τμήματος υπόθεσης εμπεριέχει τα ακόλουθα ζητήματα:

- $P(\alpha)$ επιλογή των μεταβλητών εισόδου για το τμήμα υπόθεσης
- $P(\beta)$ καθορισμός του αριθμού των ασαφών κανόνων
- $P(\gamma)$ μερισμός του χώρου υπόθεσης
- $P(\delta)$ καθορισμός των παραμέτρων υπόθεσης

Η αναγνώριση του τμήματος απόδοσης αποτελείται από τα ακόλουθα:

- $C(\alpha)$ επιλογή των εισόδων που θα συμμετέχουν στο τμήμα απόδοσης κάθε ασαφούς κανόνα
- $C(\beta)$ καθορισμός των παραμέτρων απόδοσης

Η επιλογή των εισόδων αποτελεί ζήτημα θεμελιώδους σημασίας για την κατάσταση ενός αποδοτικού ασαφούς μοντέλου. Στα πραγματικά προβλήματα δεν είναι γνωστές οι αιτίες που προκαλούν ένα φαινόμενο και υπάρχει απειρία υποψήφιων μεταβλητών εισόδου, από τις οποίες θα πρέπει να εξαχθεί ένα σχετικά περιορισμένο σύνολο, αποτελούμενο από τις πλέον σημαντικές. Στο ζήτημα αυτό πολύτιμη είναι η συμβολή των εμπειρογνομώνων αν και η συνύπαρξη της εμπειρίας με μία μαθηματική μέθοδο συστηματικής επιλογής των μεταβλητών θα αποτελούσε τη βέλτιστη αντιμετώπιση του προβλήματος. Στην περίπτωση που οι ασαφείς κανόνες λαμβάνουν τη μορφή της (7.1) το ζήτημα $C(\alpha)$ ενσωματώνεται στο $P(\alpha)$.

Τα ζητήματα $P(\beta)$ και $P(\gamma)$ συνήθως αντιμετωπίζονται παράλληλα, καθώς ο αριθμός των ασαφών κανόνων σχετίζεται άμεσα με τον μερισμό του χώρου υπόθεσης U . Ο τελευταίος αποσκοπεί στην επιλογή του κατάλληλου αριθμού λεκτικών μεταβλητών, στις οποίες θα απεικονισθούν οι μεταβλητές εισόδου μέσα από τη διαδικασία ασαφοποίησης. Τα πολυδιάστατα ασαφή σύνολα των λεκτικών μεταβλητών θα πρέπει να κατανεμηθούν έτσι ώστε να καλύπτουν επαρκώς το χώρο U . Για κάθε σημείο του χώρου θα πρέπει να υπάρχει ένα τουλάχιστον ασαφές σύνολο, στο οποίο να περιέχεται το σημείο αυτό με έναν σχετικά υψηλό βαθμό συμμετοχής, έτσι ώστε να είναι δυνατή η ενεργοποίηση του αντίστοιχου ασαφούς κανόνα. Παράλληλα θα πρέπει να αποφεύγεται μεγάλος αριθμός ασαφών ομάδων, αφενός μεν για να μην αυξάνεται η πολυπλοκότητα του συστήματος αφετέρου δε

για να δημιουργούνται αντιπροσωπευτικοί κανόνες και να μην εμφανίζονται μεγάλες επικαλύψεις στο χώρο υπόθεσης.

Μία άμεση λύση των $P(\beta)$ και $P(\gamma)$ είναι η κάλυψη κάθε άξονα εισόδου κατά τρόπο ομοιόμορφο. Η βάση κανόνων που προκύπτει ονομάζεται *πλήρης βάση*. Αναπτύσσοντας έναν αριθμό n ασαφών συνόλων σε κάθε άξονα, στην περίπτωση που το πεδίο ορισμού έχει m διαστάσεις η βάση κανόνων θα περιλαμβάνει m^n ασαφείς κανόνες. Οι θέσεις των ασαφών συνόλων συνήθως καθορίζονται με το *κριτήριο πληρότητας με βάση ε* (ε -completeness criterion), σύμφωνα με το οποίο για κάθε σημείο x , που ανήκει σε έναν άξονα εισόδου, υπάρχει τουλάχιστον ένας λεκτικός όρος, για τον οποίο $\mu_A(x) \geq \varepsilon$. Με βάση το κριτήριο πληρότητας ε οι παράμετροι των n ασαφών συνόλων κάθε άξονα υπολογίζονται από τις ακόλουθες σχέσεις:

$$m_i = \frac{(i-1)|b-a|}{n-1} + a \quad (7.8\alpha)$$

$$\sigma_i = \frac{|b-a|}{2(n-1)} \cdot \frac{1}{\sqrt{-2\ln(\varepsilon)}} \quad i=1,\dots,n \quad (7.8\beta)$$

όπου $[a, b]$ το πεδίο ορισμού του άξονα εισόδου.

Με την πλήρη βάση κανόνων εξασφαλίζεται μεν η κάλυψη του χώρου αλλά ανακύπτει μία σειρά προβλημάτων, που συνήθως καθιστούν τη μέθοδο αυτή πρακτικά ανεφάρμοστη για μεγάλο αριθμό μεταβλητών εισόδου. Το κύριο πρόβλημα είναι η εκθετική αύξηση του αριθμού των κανόνων και η συνακόλουθη αύξηση της πολυπλοκότητας του συστήματος, με αύξηση του αριθμού των εισόδων ή των ασαφών συνόλων ανά άξονα. Παράλληλα η πλήρης βάση κανόνων δε λαμβάνει υπόψη πληροφορία σχετική με την κατανομή των δεδομένων στο χώρο, με αποτέλεσμα να εμφανίζονται ανενεργοί κανόνες. Για τους λόγους αυτούς τα ζητήματα $P(\beta)$ και $P(\gamma)$ αντιμετωπίζονται με *μεθόδους ομαδοποίησης* (clustering), οι οποίες αποσκοπούν στην εξεύρεση ασαφών περιοχών μέσα στο χώρο εισόδου, που παρουσιάζουν μεγάλες συγκεντρώσεις δεδομένων.

Σε ό,τι αφορά τη ρύθμιση των παραμέτρων ($P(\delta)$ και $C(\beta)$), αυτή αποσκοπεί στην εκμάθηση της σχέσης εισόδου-εξόδου και συνήθως διεξάγεται με χρήση ενός συνόλου δεδομένων εκπαίδευσης και μίας μεθόδου βελτιστοποίησης. Η μέθοδος αποσκοπεί στην ελαχιστοποίηση ενός μέτρου σφάλματος (error measure), το οποίο

είναι συνάρτηση των εξόδων του ασαφούς μοντέλου. Θα πρέπει να ληφθεί πρόνοια έτσι ώστε η διαδικασία εκμάθησης να μην οδηγεί σε «αποστήθιση» (overfitting) της συνάρτησης που δημιουργούν τα δεδομένα εκπαίδευσης, γιατί τότε το ασαφές μοντέλο αδυνατεί να «γενικεύσει», να αναγνωρίζει δηλαδή το σύστημα για οποιοδήποτε διάνυσμα εισόδου.

Θα πρέπει να τονισθεί ότι τα ζητήματα PPI και CPI δεν αντιμετωπίζονται κατ' ανάγκη ξεχωριστά ούτε υπάρχει μία και μοναδική λύση για κάθε περίπτωση. Όπως θα φανεί στη συνέχεια της εργασίας, για το ίδιο πρόβλημα μπορούν να προκύψουν διάφορες προσεγγίσεις, ανάλογα με τη διαθέσιμη πληροφορία και τις προδιαγραφές που τίθενται.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.


8. ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ – ΠΑΘΟΛΟΓΙΑ ΑΝΑΠΝΕΥΣΤΙΚΩΝ ΗΧΩΝ ΚΑΙ ΜΕΘΟΔΟΙ ΔΙΑΧΩΡΙΣΜΟΥ

8.1 Βασικά χαρακτηριστικά των αναπνευστικών ήχων και της σχετιζόμενης παθολογίας

Τα ακουστικά αναπνευστικά σήματα σχετίζονται με ανατομικές μεταβολές ή μεταβολές στη φυσιολογία του αναπνευστικού συστήματος, γεγονός που αντανακλάται στις ακουστικές ιδιότητες των τμημάτων ή των οργάνων, που επηρεάζονται από τις μεταβολές αυτές. Έτσι, όταν π.χ. εμφανίζεται μία στένωση του τραχειοβρογχικού δένδρου του ανθρώπου, παράγεται μία στροβιλώδης ροή του αέρα, που οδηγεί στην γένεση ενός συγκεκριμένου ακουστικού θορύβου, καλούμενου ως *επιπρόσθετος ήχος* (adventitious sound), καθώς προστίθεται στο φυσιολογικό αναπνευστικό ήχο, ο οποίος καλείται *κυψελιδικός ήχος*.

Σύμφωνα με τη βιβλιογραφία, οι επιπρόσθετοι ήχοι, οι οποίοι ακούγονται μόνο σε παθολογικές περιπτώσεις, διακρίνονται σε δύο μείζονες κατηγορίες: τους *συνεχείς* και τους *διακοπτόμενους*. Η πρώτη κατηγορία αποτελείται από τους *συριγμούς* (wheezes) και τους *ρόγχους* (rhonchi), ηχητικά σήματα που χαρακτηρίζονται από σχετικά μικρή διάρκεια (250 msec) και μία οξεία αιχμή στο φάσμα ισχύος, στην περιοχή των 400 Hz για τους συριγμούς και των 200 Hz ή λιγότερο για τους ρόγχους. Η δεύτερη κατηγορία περιλαμβάνει τους *τρίζοντες* (crackles) και τα «κακαρίσματα» (squawks, SQ) όπως αναφέρονται στη βιβλιογραφία, ήχοι διακρινόμενοι κυρίως από τα χαρακτηριστικά τους στο πεδίο του χρόνου (βλ. Σχ. 8.1): α) τη μικρή διάρκεια (20 msec), β) το *αρχικό πλάτος βύθισης* (Initial Deflection Width, IDW), δηλαδή το χρονικό διάστημα που διαρκεί η πρώτη βύθιση του τρίζοντος αναπνευστικού ήχου και γ) τη διάρκεια δύο περιόδων (two Cycle Duration, 2CD), που είναι το χρονικό διάστημα των δύο πρώτων περιόδων του τρίζοντος αναπνευστικού ήχου.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.



Σχήμα 8.1 Ορισμός των IDW και 2CD των τριζόντων επιπρόσθετων αναπνευστικών ήχων. Παράδειγμα ενός λεπτού τριζόντος.

Οι τριζόντες είναι διακριτοί, μη μουσικοί ήχοι, οι οποίοι συμπεριφέρονται ως μη στάσιμος εκρηκτικός θόρυβος, επικαθήμενος στον αναπνευστικό ήχο. Ταξινομούνται στους λεπτούς (fine crackles, FC) και τους τραχείς τριζόντες (coarse crackles, CC). Οι πρώτοι παρουσιάζουν IDW=0.90 msec και 2CD=6.0 msec ενώ οι αντίστοιχες τιμές για τους δεύτερους είναι IDW=1.25 msec και 2CD=9.50 msec. Οι λεπτοί τριζόντες είναι αποκλειστικά ήχοι της εισπνοής. Εμφανίζονται κοντά στη μέση και προς το τέλος της εισπνοής, και επαναλαμβάνονται με τα ίδια ακουστικά χαρακτηριστικά σε συνεχόμενες αναπνοές. Συνδέονται τόσο με πνευμονικές συμφορήσεις λόγω καρδιακής ανεπάρκειας όσο και με πνευμονικές ινώσεις όπως η αμυάντωση (asbestosis) και η διάμεση ίνωση (interstitial fibrosis). Οι τραχείς τριζόντες εκδηλώνονται από την αρχή της αναπνοής και περιστασιακά στην εκπνοή. Είναι λιγότερο επαναλαμβανόμενοι από αναπνοή σε αναπνοή, σε σχέση με τους λεπτούς τριζόντες, γιατί η παραγωγή τους στηρίζεται σε συχνά μεταβαλλόμενους μηχανισμούς. Σχετίζονται με χρόνιες βρογχίτιδες.

Ένα πρόσθετο στοιχείο, που διαφοροποιεί τους λεπτούς από τους τραχείς τριζόντες είναι οι περιοχές συχνοτήτων, στις οποίες εμφανίζεται αύξηση του φασματικού τους περιεχομένου. Έτσι, οι λεπτοί τριζόντες εμφανίζουν μία κορυφή στην περιοχή των 650 Hz ενώ οι τραχείς τριζόντες σε χαμηλότερη ζώνη συχνοτήτων, γύρω στα 250 Hz.

Το «κακάρισμα» είναι ένας συνδυασμός συριγμού και τριζόντος αναπνευστικού ήχου, όπου το πλάτος του αποσβένει πολύ γρήγορα. Αν και εμφανίζεται ως μικρός εισπνευστικός συριγμός, ακούγεται σε συνδυασμό με λεπτούς τριζόντες, ως ήχος

του τέλους της αναπνοής. Οι ήχοι αυτοί σχετίζονται με την αλλεργική κυψελίτιδα (allergic alveolitis) και τη διάμεση ίνωση.

8.2 Αναδρομή στις προηγούμενες μεθόδους διαχωρισμού των αναπνευστικών ήχων

Από την προαναφερθείσα περιγραφή των διακοπτόμενων επιπρόσθετων αναπνευστικών ήχων (DAS) γίνεται προφανής η σημαντική διαγνωστική πληροφορία που περιέχεται στους ήχους αυτούς, όπως και η ιδιαίτερη σημασία που παρουσιάζει ο διαχωρισμός τους από τους κυψελιδικούς ήχους (VS), καθώς η απομόνωση των DAS οδηγεί σε ουσιαστικότερη αξιολόγηση του διαγνωστικού τους χαρακτήρα. Έτσι μέχρι σήμερα έχουν προταθεί διάφορες μέθοδοι διαχωρισμού, από τις οποίες περιγράφονται περιληπτικά οι κυριότερες.

Μία από τις αρχικές ιδέες διαχωρισμού είναι το *υψιπερατό γραμμικό φιλτράρισμα* (highpass linear filtering), το οποίο στηρίζεται στις διαφορές του φασματικού περιεχομένου των επιπρόσθετων αναπνευστικών ήχων από αυτό των κυψελιδικών ήχων. Λόγω όμως του μη στάσιμου χαρακτήρα των DAS, τα αποτελέσματα της μεθόδου αυτής είναι χαμηλής ποιότητας, καθώς τα διαχωριζόμενα σήματα παρουσιάζουν έντονες παραμορφώσεις.

Μία δεύτερη μέθοδος διαχωρισμού είναι η *κατωφλίωση πλάτους* (level slicing), η οποία στηρίζεται στα διαφορετικά επίπεδα πλάτους των δύο αναπνευστικών ήχων. Η μέθοδος αυτή οδηγεί σε βελτιωμένα χαρακτηριστικά διαχωρισμού σε σχέση με το υψιπερατό φιλτράρισμα, όμως εξαιτίας της εξάρτησής της από τον ορισμό της τιμής του κατωφλίου αποτυγχάνει να ανιχνεύσει και να διαχωρίσει DAS μικρού πλάτους.

Μία άλλη χρησιμοποιούμενη μέθοδος είναι η *επιλεκτική μεγέθυνση χρονικών παραθύρων των ηχογραφημένων σημάτων* (time-expanded waveform analysis). Με τον τρόπο αυτό υποψήφια χρονικά διαστήματα του καταγραφόμενου σήματος απομονώνονται και απεικονίζονται σε μεγέθυνση, για να παράσχουν ευκρινέστερη εξαγωγή των χαρακτηριστικών των DAS, στο πεδίο του χρόνου. Όπως αναφέρεται στην βιβλιογραφία, αν και η μέθοδος αυτή απομονώνει τους επιπρόσθετους ήχους, παρουσιάζει έντονη ευαισθησία στην υποκειμενική κάθε φορά επιλογή του υποψήφιου χρονικού παραθύρου, που θα μεγεθυνθεί από διαφορετικούς αναλυτές, και απαιτεί μεγάλο χρονικό διάστημα παρατήρησης.

Οι επόμενες δύο μέθοδοι παρέχουν αυτοματοποιημένο διαχωρισμό των DAS από τους VS και παρουσιάζουν καλύτερα αποτελέσματα. Η πρώτη, που προτάθηκε από τον Ono, χρησιμοποιεί μη γραμμικό φιλτράρισμα και οδηγεί στην ανάπτυξη ενός

στάσιμου-μη στάσιμου φίλτρου ST-NST (**S**tationary-**N**onstationary), ενώ η δεύτερη, των Χατζηλεοντιάδη και Πανά, χρησιμοποιεί στατιστική τρίτης τάξης και μη γραμμικό φιλτράρισμα, εισάγοντας το τροποποιημένο στάσιμο-μη στάσιμο φίλτρο mST-NST (**m**odified **S**tationary-**N**onstationary). Η πρώτη μέθοδος έχει εφαρμοσθεί μόνο σε τρίζοντες επιπρόσθετους αναπνευστικούς ήχους ενώ η δεύτερη και στα τρία ήδη επιπρόσθετων ήχων, εμφανίζοντας βελτιωμένα χαρακτηριστικά σε σχέση με το ST-NST. Οι δύο αυτές μέθοδοι παρουσιάζουν το μειονέκτημα ότι απαιτούν ορισμό των παραμέτρων τους, ο οποίος γίνεται εμπειρικά.

Το στάσιμο-μη στάσιμο φίλτρο, βασιζόμενο στον μετασχηματισμό κυματιδίων WTST-NST (Wavelet Transform-based Stationary-Nonstationary filter) των Χατζηλεοντιάδη και Πανά, αποτελεί την πλέον αποτελεσματική πρόταση στο πρόβλημα του διαχωρισμού των αναπνευστικών ήχων. Το φίλτρο αυτό διαχωρίζει τους πνευμονικούς ήχους σε βαθμίδες (επίπεδα) και υπολογίζει την ισχύ τους σε κάθε βαθμίδα και θέση. Εφαρμόζοντας ένα κατώφλι σε κάθε βαθμίδα γίνεται μία επεξεργασία των συντελεστών του μετασχηματισμού κυματιδίων (WT), σύμφωνα με τη δομή του σήματος. Ο διαχωρισμός του «θορύβου μικρού πλάτους» (κυψελιδικοί ήχοι) από το «σήμα» (DAS) επιτυγχάνεται μέσω μίας επαναληπτικής διαδικασίας, κατά την οποία υπολογίζονται οι συντελεστές WT. Το μειονέκτημα της μεθόδου αυτής είναι το υπολογιστικό κόστος και η παρελκόμενη αδυναμία να εφαρμοσθεί εύκολα σε πραγματικό χρόνο.

Η μέθοδος διαχωρισμού που προτάθηκε από τον Τόλια, με τη μορφή του στάσιμου-μη στάσιμου φίλτρου, βασιζόμενου σε ασαφή βάση κανόνων FST-NST (Fuzzy rule-based Stationary-Nonstationary filter), επιτυγχάνει τον διαχωρισμό των τρίζοντων DAS από τους VS σε πραγματικό χρόνο. Το φίλτρο FST-NST αποτελείται από δύο συστήματα ANFIS, που λειτουργούν παράλληλα, και εκπαιδεύονται με τον υβριδικό αλγόριθμο που πρότεινε ο Jang, για την εκτίμηση του στάσιμου και του μη-στάσιμου τμήματος των αναπνευστικών ήχων.

9. ΔΥΝΑΜΙΚΑ ΑΣΑΦΗ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

9.1 Από τα στατικά στα δυναμικά συστήματα

Τα στατικά ασαφή συστήματα είναι συστήματα στα οποία η έξοδος κάθε χρονική στιγμή είναι συνάρτηση αποκλειστικά των εισόδων της την ίδια χρονική στιγμή. Στην περίπτωση των δυναμικών συστημάτων όμως, στα οποία η έξοδος ή οι καταστάσεις κάθε χρονική στιγμή συναρτώνται και με δικές τους παρελθούσες τιμές, το πρόβλημα της αναγνώρισης γίνεται συνθετότερο. Μία πρώτη προσέγγιση στο ζήτημα παρουσιάσθηκε στο χώρο των νευρωνικών δικτύων με την τροφοδότηση ενός στατικού δικτύου με καθυστερημένες τιμές της επιθυμητής εξόδου, μέσω γραμμών καθυστέρησης (tapped delay lines). Εάν είναι γνωστή η τάξη του συστήματος ή ένα άνω φράγμα αυτής, οι απαραίτητες παρελθούσες εισοδοί και εξοδοί μπορούν να τροφοδοτηθούν άμεσα στο δίκτυο, το οποίο θα μάθει με στατικό τρόπο την εξάρτηση της εξόδου του συστήματος από τις συγκεκριμένες εισόδους και εξόδους. Θεωρητικά μπορεί πάντοτε ένα δίκτυο να τροφοδοτηθεί με «επαρκή» αριθμό παρελθουσών εισόδων και εξόδων· στην πράξη όμως, στις περιπτώσεις που εφαρμόζεται αυτή η μεθοδολογία, είναι γνωστή η ακριβής τάξη του προς αναγνώριση συστήματος. Επιπρόσθετα, η μέθοδος αυτή αδυνατεί να αντιμετωπίσει προβλήματα στα οποία υπάρχουν μη προσβάσιμες (κρυφές) εσωτερικές καταστάσεις.

Για τους παραπάνω λόγους, όταν το άγνωστο σύστημα έχει δυναμική θα πρέπει να χρησιμοποιούνται δυναμικά μοντέλα. Με όρους της θεωρίας ελέγχου, τα στατικά μοντέλα είναι συστήματα ανοικτού βρόχου και η αδυναμία αναγνώρισης ενός δυναμικού συστήματος είναι εγγενής. Για να αναγνωρισθούν με επιτυχία τα δυναμικά συστήματα πρέπει τα μοντέλα να γίνουν συστήματα κλειστού βρόχου, με τις αναδράσεις να εισάγουν δυναμική. Οι αναδράσεις είναι είτε εξωτερικές, αναδρώντας καθυστερημένες τιμές της εξόδου στην είσοδο, είτε εσωτερικές, αναδρώντας καταστάσεις. Στην πρώτη περίπτωση τα προκύπτοντα μοντέλα ονομάζονται *αναδρομικά μοντέλα με εξωτερικές αναδράσεις* (recurrent models with external feedback), ενώ στη δεύτερη *αναδρομικά μοντέλα με εσωτερικές αναδράσεις* (recurrent models with internal feedback).

Στο χώρο της νευρωνικής μοντελοποίησης τα αναδρομικά νευρωνικά δίκτυα έχουν αποκτήσει ιδιαίτερη θέση εδώ και σχεδόν τρεις δεκαετίες, ενώ η εισαγωγή δυναμικών στοιχείων στα ασαφή συστήματα έκανε την εμφάνισή της τα τελευταία

είκοσι χρόνια. Καθώς στα περισσότερα πραγματικά προβλήματα υπάρχει χρονική συσχέτιση των μεταβλητών, τα αναδρομικά δίκτυα έχουν ήδη βρει εφαρμογή σε αρκετούς τομείς όπως στον χώρο του αυτομάτου ελέγχου, στην αναγνώριση φωνής και λέξεων, στην προσαρμοστική καταστολή του θορύβου και σε χημικές διεργασίες.

9.2 Δομές αναδρομικών νευρωνικών και ασαφών μοντέλων

9.2.1 Επισκόπηση των αναδρομικών νευρωνικών δικτύων

Από το αρχικό αναδρομικό νευρωνικό δίκτυο του Hopfield (1982) έως σήμερα έχει προταθεί πληθώρα δομών για τα δυναμικά νευρωνικά δίκτυα. Οι πρώτες προσεγγίσεις του προβλήματος γίνονται με δίκτυα *καθολικής εκμάθησης* (global learning), δηλαδή με πλήρως διασυνδεδετικά δίκτυα, όπου μεταβολή σε ένα οποιοδήποτε βάρος τους συνεπάγεται αλλαγή στις εξόδους τους για κάθε σήμα εισόδου. Ο Hopfield προτείνει ένα τυπικό στατικό δίκτυο, στο οποίο η έξοδος του αναδράται, καθυστερημένη κατά κάποιες χρονικές μονάδες, στη είσοδο.

Οι Narendra και Parthasarathy αντιμετωπίζουν το ζήτημα της αναγνώρισης δυναμικών συστημάτων με ένα υβριδικό μοντέλο· ένα ή περισσότερα στατικά νευρωνικά δίκτυα συνδέονται σε σειρά με ένα γραμμικό δυναμικό φίλτρο, με τα πρώτα να παρέχουν μη γραμμικότητα στο μοντέλο και το γραμμικό φίλτρο να εισάγει δυναμική. Η σύνδεση των νευρωνικών δικτύων και του φίλτρου εξαρτάται από το συγκεκριμένο πρόβλημα και αποτελεί ένα σημαντικό μειονέκτημα, καθώς για να αποφασισθεί ο συνδυασμός που θα χρησιμοποιηθεί απαιτείται αρκετή γνώση της δομής του προς μοντελοποίηση συστήματος.

Μία από τις πλέον γνωστές αρχιτεκτονικές είναι το *πλήρως αναδρομικό δίκτυο* (fully recurrent network) των Williams και Zipser, στο οποίο κάθε νευρώνας μπορεί να συνδεθεί με οποιοδήποτε άλλο νευρώνα του δικτύου. Όλες οι έξοδοι των νευρώνων μπορούν να θεωρηθούν ως έξοδοι του δικτύου και το διάνυσμα των εξόδων του δικτύου δύναται να μεταβάλλεται με την πάροδο του χρόνου.

Η αρχιτεκτονική των Jordan και Elman έχει ένα επιπλέον στρώμα νευρώνων, το οποίο αντιγράφει την είσοδο σε κάθε συνάρτηση ενεργοποίησης των νευρώνων του κρυμμένου στρώματος, τις καθυστερεί κατά μία χρονική μονάδα και στη συνέχεια τις τροφοδοτεί ως επιπρόσθετες εισόδους στους νευρώνες του κρυμμένου στρώματος.

Οι δύο παραπάνω αρχιτεκτονικές, αν και είναι ιδιαίτερα γενικές, παρουσιάζουν ορισμένα μειονεκτήματα. Η αρχιτεκτονική των Williams και Zipser παρουσιάζει προβλήματα ευστάθειας και καθυστερεί να συγκλίνει. Επιπρόσθετα και οι δύο αρχιτεκτονικές εμφανίζουν διαταραχές στην εξέλιξη του σφάλματος κατά τη διάρκεια της διαδικασίας εκμάθησης, οι οποίες λαμβάνουν τη μορφή αιφνίδιων αυξήσεων του σφάλματος, ακολουθούμενων από διαδοχικές μειώσεις.

Τα τελευταία χρόνια έχουν εμφανισθεί στη βιβλιογραφία αρχιτεκτονικές που συνδυάζουν την στατική δομή του Multilayer Perceptron με εκείνη του πλήρως αναδρομικού δικτύου. Οι δομές αυτές έχουν τοπικές εσωτερικές αναδράσεις σε ορισμένους νευρώνες και μορφοποιούν την κατηγορία των *τοπικά αναδρομικών δικτύων* (LRGF, local-recurrent-global-feedforward). Τέτοιες αρχιτεκτονικές υλοποιούνται τόσο με δίκτυα καθολικής εκμάθησης όσο και με δίκτυα τοπικής εκμάθησης (local learning), όπως τα ακτινικής συνάρτησης βάσης RBF (Radial Basis Function) νευρωνικά δίκτυα. Προς αυτή την κατεύθυνση έχουν αναπτυχθεί δίκτυα με συνάψεις που έχουν α) τη μορφή φίλτρου πεπερασμένης κρουστικής απόκρισης (Finite Impulse Response - FIR συνάψεις), όπου στην είσοδο του νευρωνίου εισάγονται η τρέχουσα και παρελθούσες τιμές των εξόδων του προηγούμενου στρώματος, β) τη μορφή φίλτρου άπειρης κρουστικής απόκρισης (Infinite Impulse Response - IIR συνάψεις). Αυτό το είδος της ανάδρασης ονομάζεται *τοπική ανάδραση της σύναψης* (local synapse feedback). Στην κατηγορία των δικτύων με τοπική ανάδραση της σύναψης μπορεί να ενταχθεί και το νευρωνικό δίκτυο χρονικής καθυστέρησης TDNN (Time-Delay Neural Network), που προτάθηκε από τον Weibel και εφαρμόσθηκε στο πρόβλημα της αναγνώρισης φθόγγων. Το TDNN είναι λειτουργικά ισοδύναμο με το δίκτυο με FIR συνάψεις.

Μία άλλη ομάδα LRGF δικτύων είναι εκείνα που χρησιμοποιούν *τοπική ανάδραση της εξόδου* (local output feedback). Κυριάρχη θέση στην ομάδα αυτή κατέχει η αρχιτεκτονική των Frasconi, Gori και Soda, στην οποία μία σειρά καθυστερημένων τιμών της εξόδου αναδράται στην είσοδο του νευρωνίου. Οι υπόλοιπες εισοδοί του νευρώνα εισάγονται σε αυτό χωρίς καθυστέρηση. Ο νευρώνας που προκύπτει ονομάζεται FGS νευρώνας και η συγκεκριμένη αρχιτεκτονική εφαρμόσθηκε στο πρόβλημα της αναγνώρισης φωνής.

Στο πλαίσιο της αρχιτεκτονικής με τοπική ανάδραση της εξόδου, οι Poddar και Unnikrishnan προτείνουν μία μεικτή δομή δικτύου για αναγνώριση και έλεγχο

δυναμικών συστημάτων, το δίκτυο νευρώνων μνήμης MNN (Memory Neuron Network). Στο MNN σε κάθε νευρώνα του δικτύου προσαρτάται ένας νευρώνας μνήμης, το οποίο έχει εσωτερική ανάδραση και τροφοδοτείται με την έξοδο του νευρωνίου του δικτύου, καθυστερημένη κατά μία χρονική στιγμή. Οι έξοδοι του ζεύγους των νευρώνων εισάγονται στην είσοδο των νευρώνων του επόμενου στρώματος. Σε κάθε νευρώνα του στρώματος εξόδου προσαρτάται μία σειρά νευρωνίων μνήμης, προσδίδοντας μεγαλύτερη δυναμική στο σύστημα.

Σε ό,τι αφορά τα νευρωνικά δίκτυα με τοπική εκμάθηση, οι Ye και Loh παρουσιάζουν τρεις τοπικά αναδρομικές δομές RBF: α) οι έξοδοι των RBF ανατροφοδοτούνται στην είσοδο καθυστερημένες κατά μία χρονική μονάδα, αποτελώντας μία νέα συνιστώσα του διανύσματος εισόδου της RBF, β) οι έξοδοι των RBF ανατροφοδοτούνται στην είσοδο καθυστερημένες κατά μία χρονική μονάδα, αποτελώντας ένα συντελεστή του ορίσματος της RBF και γ) οι έξοδοι των RBF οδηγούνται στον αθροιστή της εξόδου του δικτύου μέσω μίας IIR σύναψης. Από τις τρεις αρχιτεκτονικές η πρώτη αυξάνει σημαντικά το υπολογιστικό κόστος χωρίς να παρέχει ικανοποιητικά αποτελέσματα ενώ οι υπόλοιπες δύο εμφανίζουν παρόμοια απόδοση, με την αρχιτεκτονική των IIR συνάψεων να απαιτεί μεγαλύτερο σύνολο παραμέτρων.

9.2.2 Επισκόπηση των αναδρομικών ασαφών συστημάτων

Μία πρώτη προσπάθεια δυναμικής εκμάθησης (ή εκμάθησης τροχιάς, trajectory learning) έγινε από τον Jang, ο οποίος προτείνει έναν ασαφή νευρωνικό ελεγκτή, βασισμένο στο μοντέλο ANFIS, ο οποίος εκπαιδεύεται έτσι ώστε οι καταστάσεις του μοντέλου να ακολουθούν μία επιθυμητή τροχιά.

Το 1994 οι Gorrini και Bersini παρουσιάζουν ένα TSK ασαφές σύστημα με crisp έξοδο κανόνα, το οποίο ονομάζεται *αναδρομικό ασαφές σύστημα* (Recurrent Fuzzy System - RFS). Το σύστημα έχει εσωτερικές μεταβλητές και περιλαμβάνει αναδράσεις τόσο των μεταβλητών αυτών όσο και των εξόδων των κανόνων. Επιπλέον είναι εφοδιασμένο με μία δεύτερη βάση κανόνων, η οποία χρησιμοποιείται για τον υπολογισμό των ενδιάμεσων μεταβλητών.

Την επόμενη χρονιά εμφανίζεται ένα νέο αναδρομικό ασαφές σύστημα, το RNeuFuz (Recurrent Neural Fuzzy System), που χρησιμοποιεί κανόνες με crisp εξόδους, καθυστερημένες τιμές των οποίων αναδρά στην είσοδο. Το RNeuFuz εφαρμόζεται στα προβλήματα αναγνώρισης φωνής και λέξεων.

Η πρώτη ολοκληρωμένη μελέτη ασαφών δυναμικών συστημάτων πραγματοποιήθηκε από τους Θεοχάρη και Βαχτσεβάνο, όπου εξετάζεται συνολικά το πρόβλημα της αναγνώρισης συστήματος. Προτείνεται το *δυναμικό προσαρμοστικό ασαφές νευρωνικό δίκτυο* D-AFNN (Dynamical Adaptive Fuzzy Neural Network), ένα TSK ασαφές μοντέλο με πολυωνυμικό τμήμα απόδοσης και εξωτερικές αναδράσεις της συνολικής εξόδου, οι οποίες εισάγονται και στα δύο τμήματα των ασαφών κανόνων. Η βάση κανόνων δεν είναι σταθερή αλλά αναπτύσσεται σταδιακά, με εφαρμογή μίας μεθόδου αυτόματης αναπροσαρμογής της βάσης κανόνων.

Κοινό στοιχείο των παραπάνω μεθόδων είναι η χρήση αναδρώντων μεταβλητών στις εισόδους και των δύο τμημάτων του ασαφούς κανόνα, με αποτέλεσμα την αύξηση του διανύσματος εισόδου και τη συνακόλουθη αύξηση των παραμέτρων του μοντέλου. Επιπρόσθετα, στις περιπτώσεις που αναδράται η έξοδος του ασαφούς μοντέλου, διαφοροποιούνται τα χαρακτηριστικά και ο τοπικός χαρακτήρας δράσης του ασαφούς συστήματος, καθώς οι κανόνες, πέραν του τμήματος αποασαφοποίησης, συζεύγνυνται μεταξύ τους και μέσω της συγκεκριμένης ανάδρασης.

9.3 Το δυναμικό ασαφές νευρωνικό δίκτυο DFNN

9.3.1 TSK ασαφείς κανόνες με νευρωνικά τμήματα απόδοσης

Ο TSK ασαφής κανόνας (§7.2) λαμβάνει την ακόλουθη γενική μορφή:

$$IF \ z_1(k) \text{ is } A_1 \text{ AND } z_2(k) \text{ is } A_2 \text{ AND } \dots \text{ AND } z_m(k) \text{ is } A_m \text{ THEN } g(k) = g(\mathbf{u}(k)) \quad (9.1)$$

όπου $z(k)$ και $\mathbf{u}(k)$ είναι οι είσοδοι των τμημάτων υπόθεσης και απόδοσης, αντίστοιχα. Στον κλασικό TSK κανόνα η συνάρτηση $g(k)$ είναι ένα πολυώνυμο των εισόδων, επιτρέποντας στην έξοδο του κανόνα να κείται στο υπερεπίπεδο που σχηματίζουν οι μεταβλητές εισόδου. Ο κλασικός TSK κανόνας έχει απλή δομή και είναι πλήρως ερμηνεύσιμος (interpretable), ιδιότητες που χαρακτηρίζουν τα ασαφή συστήματα και τα αντιδιαστέλλουν από τα νευρωνικά δίκτυα, τα οποία λειτουργούν με τη λογική του «μαύρου κουτιού». Ταυτόχρονα όμως δεν εκμεταλλεύεται πλήρως τις δυνατότητες απεικόνισης, που του παρέχει το τμήμα απόδοσης. Η εισαγωγή μίας μη γραμμικής συνάρτησης, και μάλιστα νευρωνικής δομής, στο τμήμα απόδοσης του κανόνα θα μείωνε μεν την ερμηνευσιμότητά του, παράλληλα όμως θα επέτρεπε στην έξοδο του κανόνα να κινηθεί σε ένα συνθετότερο χώρο. Με αυτό

τον τρόπο ένα ασαφές μοντέλο αποτελούμενο από τέτοιους κανόνες θα μπορούσε να καταστεί πρόσφορο μέσο ενσωμάτωσης τόσο του εξελιγμένου ασαφούς συμπερασμού όσο και της υπολογιστικής ισχύος των νευρωνικών δομών.

Τα πλεονεκτήματα των παραπάνω υβριδικών μοντέλων άρχισαν να γίνονται αντιληπτά στις αρχές της δεκαετίας του '90, με τις εργασίες του Takagi, ενώ οι πρώτες εφαρμογές στην αναγνώριση και τον έλεγχο εμφανίζονται στα μέσα της δεκαετίας. Η πλέον γνωστή υβριδική πρόταση παρουσιάζεται από τους Mizutani και Jang, οι οποίοι αναπτύσσουν μία γενικευμένη δομή ANFIS, το CANFIS (Coactive Neuro-Fuzzy Inference System). Ωστόσο η σύζευξη της ασαφούς με τη νευρωνική μοντελοποίηση περιορίζεται σε στατικές δομές, χωρίς να καταγράφονται στη βιβλιογραφία αναδρομικά ασαφή νευρωνικά συστήματα. Το συγκεκριμένο κενό επεδίωξε να καλύψει το μοντέλο DFNN, στο οποίο εισάγεται δυναμική στα νευρωνικά τμήματα απόδοσης των κανόνων του.

9.3.2 Περιγραφή του DFNN

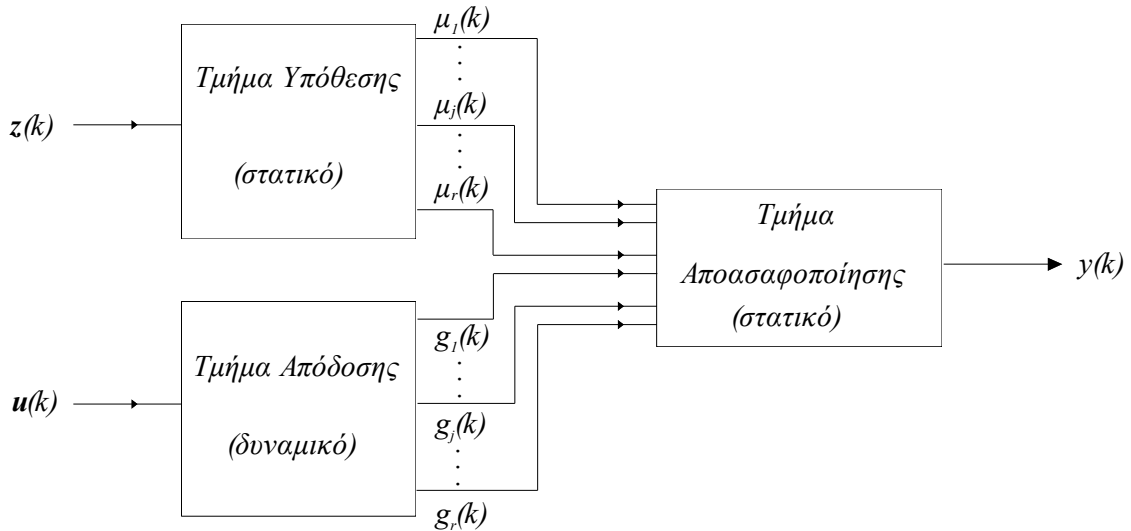
Το δυναμικό ασαφές νευρωνικό δίκτυο DFNN (Dynamic - Fuzzy Neural Network) αποτελείται από TSK κανόνες της μορφής (6.1), όπου η συνάρτηση $g(u(k))$ υλοποιείται με ένα αναδρομικό νευρωνικό δίκτυο 1-Hn-1, με γραμμικό στρώμα εισόδου και τροποποιημένους FGS νευρώνες στο κρυμμένο στρώμα και το στρώμα εξόδου. Η γενική διαμόρφωση της αρχιτεκτονικής του DFNN παρουσιάζεται στο Σχ. 9.1, ενώ στο επόμενο σχήμα απεικονίζεται το τμήμα απόδοσης των ασαφών κανόνων. Με βάση τα δύο σχήματα παρατηρούνται τα ακόλουθα δομικά χαρακτηριστικά:

- Τα τμήματα υπόθεσης και αποασαφοποίησης είναι στατικά και περιγράφονται από συναρτήσεις της μορφής

$$\mu_l(k) = f_\mu(z(k); m_l(k), \sigma_l(k)) \quad (9.2)$$

$$y(k) = f_y(\mu_1(k), \dots, \mu_r(k), g_1(k), \dots, g_r(k)) \quad (9.3)$$

όπου r είναι ο αριθμός των κανόνων, $\mu_l(k)$ ο βαθμός εκπλήρωσης κανόνα και $m_l(k)$, $\sigma_l(k)$ οι παράμετροί του. Ο βαθμός εκπλήρωσης κανόνα είναι το γινόμενο των αντίστοιχων συναρτήσεων συμμετοχής και η αποασαφοποίηση γίνεται με τη μέθοδο του σταθμισμένου μέσου.



Σχήμα 9.1 Γενική διαμόρφωση της αρχιτεκτονικής του δυναμικού ασαφούς νευρωνικού δικτύου

Στο δίκτυο εισάγεται δυναμική μόνο μέσω του τμήματος απόδοσης. Το τελευταίο αποτελείται από αναδρομικά νευρωνικά δίκτυα με εσωτερική ανάδραση, τύπου LRGF.

- Τα δομικά στοιχεία των τμημάτων απόδοσης των ασαφών κανόνων είναι οι νευρώνες γενικευμένου τύπου Frasconi-Gori-Soda (Generalized Frasconi Gori-Soda - G-FGS). Η διαφορά τους από τους τυπικούς FGS νευρώνες έγκειται στην εισαγωγή των εισόδων μέσω FIR σύναψης. Με αυτό τον τρόπο εισάγεται δυναμική τόσο μέσω των αναδράσεων όσο και μέσω των καθυστερημένων εξόδων του προηγούμενου στρώματος.

Η λειτουργία του τμήματος απόδοσης του l -στού ασαφούς κανόνα περιγράφεται από το ακόλουθο σύστημα εξισώσεων:

$$O_{li}^1(k) = f_1 \left(\sum_{j=1}^{con} \sum_{q=0}^{Ou} [w_{lijq}(k) u_j(k-q)] + \sum_{j=1}^{Oy_1} [w_{2lj}(k) O_{li}^1(k-j)] + w_{3li}(k) \right) \quad (9.4)$$

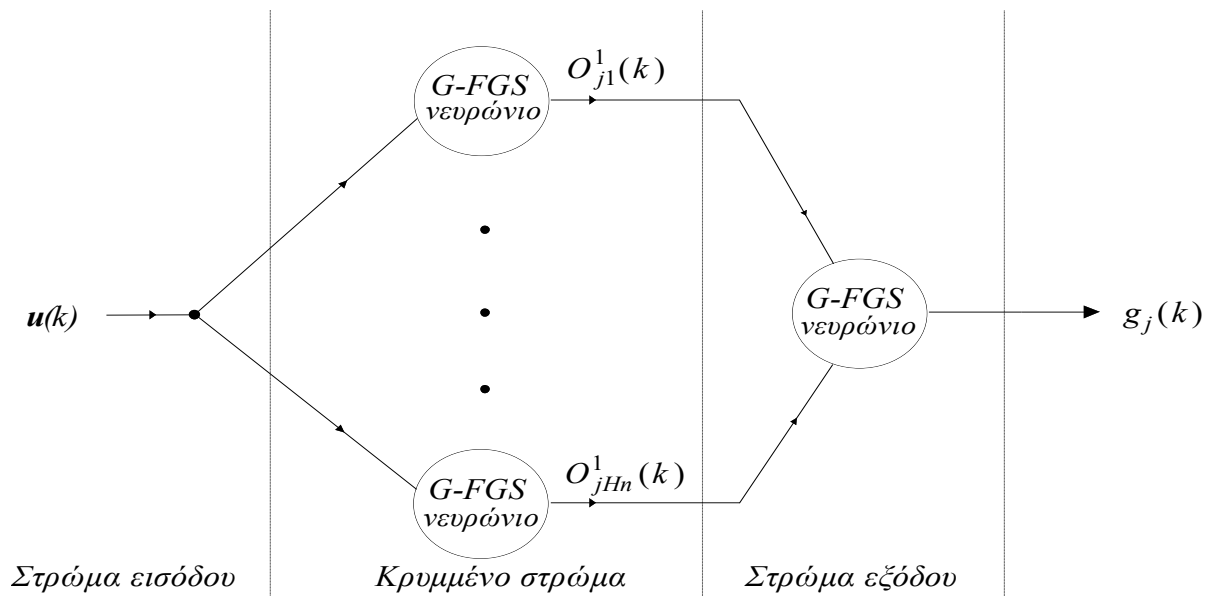
$$l=1, \dots, r, \quad j=1, \dots, Hn$$

$$g_l(k) = f_2 \left(\sum_{j=1}^{Hn} \sum_{q=0}^{Oy_3} [w_{4ljq}(k) O_{lj}^1(k-q)] + \sum_{j=1}^{Oy_2} [w_{5lj}(k) g_l(k-j)] + w_{6l}(k) \right) \quad l=1, \dots, r \quad (9.5)$$


όπου f_1, f_2 οι συναρτήσεις ενεργοποίησης του κρυμμένου στρώματος και του στρώματος εξόδου, αντίστοιχα. Ως συνάρτηση ενεργοποίησης επιλέγεται και για τα δύο στρώματα η υπερβολική εφαπτομένη $\tanh(\cdot)$.

Η επιλογή των παραπάνω δομικών χαρακτηριστικών του DFNN υπαγορεύεται από τα εξής:

- Το δίκτυο διατηρεί τα μακροσκοπικά χαρακτηριστικά και τον τοπικό χαρακτήρα της λειτουργίας του.



(α) Γενική διαμόρφωση του τμήματος απόδοσης για το j -στό ασαφή κανόνα



(β) Νευρώνας γενικευμένου τύπου Frasconi-Gori-Soda (G-FGS)

Σχήμα 9.2 Το τμήμα απόδοσης των ασαφών κανόνων

Από πλευράς δομής η μόνη διαφορά τους βρίσκεται στα τμήματα απόδοσης των κανόνων. Επομένως το DFNN είναι ένα σύστημα που αποτελείται από ασαφώς διασυνδεδεμένα υποσυστήματα, καθένα από τα οποία είναι ένα LRGF νευρωνικό

δίκτυο. Δεν υπάρχει χρονική σύζευξη ανάμεσα στους κανόνες είτε μέσω εξωτερικών είτε μέσω εσωτερικών αναδράσεων · οι κανόνες συνδέονται μεταξύ τους μόνο μέσω του τμήματος αποασαφοποίησης. Το τμήμα υπόθεσης επιτελεί το μερισμό του χώρου και το τμήμα απόδοσης επιτελεί την απεικόνιση εισόδου-εξόδου. Κατά συνέπεια οι εσωτερικές αναδράσεις στα νευρωνικά δίκτυα των τμημάτων απόδοσης επιτρέπουν στα τελευταία να ανιχνεύσουν τη δυναμική των εσωτερικών καταστάσεων του συστήματος, στις περιοχές που οριοθετούν τα αντίστοιχα τμήματα υπόθεσης.


- Προτιμώνται τα τοπικά αναδρομικά δίκτυα από τα πλήρη αναδρομικά για να αποφευχθούν τα μειονεκτήματα των τελευταίων, που αναφέρονται στην §9.2.1, και να μειωθεί ο αριθμός των συνδέσεων και των παραμέτρων. Επιπρόσθετα, λαμβάνοντας υπόψη τα αποτελέσματα αναφορών των P. Frasconi, M. Gori, και G. Soda, όπως επίσης των A.C. Tsoi και A.D. Back, τα τοπικά δίκτυα εμφανίζουν καλύτερη απόδοση σε πραγματικά προβλήματα αναγνώρισης.

- Ως δομική μονάδα χρησιμοποιείται ο G-FGS νευρώνας καθώς, σύμφωνα με τις παρατηρήσεις των Tsoi και Back, παρουσιάζει βελτιωμένα χαρακτηριστικά αναγνώρισης σε σχέση με τα δυναμικά στοιχεία με τοπική ανάδραση σύναψης. Επιπλέον η τοπική ανάδραση της εξόδου συνεισφέρει στην ευστάθεια της απόκρισης του νευρωνίου. Η FIR σύναψη, μέσω της οποίας τροφοδοτείται το σήμα εισόδου στο νευρώνα, αποσκοπεί στη δημιουργία άμεσης χρονικής συσχέτισης ανάμεσα στην είσοδο και την έξοδο του νευρωνίου.


9.3.3 Ταξινόμηση του DFNN ως μοντέλου αναγνώρισης δυναμικών συστημάτων

Τα μοντέλα αναγνώρισης δυναμικών συστημάτων μπορούν να χωρισθούν σε δύο μείζονες κατηγορίες: α) το *μοντέλο σφάλματος εξίσωσης* (equation error model) και β) το *μοντέλο σφάλματος εξόδου* (output error model). Στο πρώτο οι καταστάσεις είναι μετρήσιμες σε κάθε χρονική στιγμή και δύνανται να λαμβάνουν τις επιθυμητές τιμές. Ένα τέτοιο μοντέλο είναι στατικό και βρίσκεται σε λειτουργία *σειράς-παράλληλα* (series-parallel model). Τα σφάλματα αναγνώρισης οφείλονται αποκλειστικά στην απόκλιση των παραμέτρων από τις βέλτιστες και για να βελτιστοποιηθεί το μοντέλο απαιτείται ένας στατικός αλγόριθμος εκμάθησης παραμέτρων, ο οποίος καλείται *οδηγούμενος αλγόριθμος* (directed algorithm), καθώς το μοντέλο «οδηγείται» από τις επιθυμητές καταστάσεις. Για το μοντέλο της

δεύτερης περίπτωσης οι καταστάσεις είναι εσωτερικές και δεν είναι μετρήσιμες. Συνήθως αρχικοποιούνται λαμβάνοντας μικρές τιμές για να αποφευχθούν φαινόμενα αστάθειας, και αφήνονται να εξελιχθούν σύμφωνα με τη δυναμική του μοντέλου. Ένα τέτοιο μοντέλο είναι δυναμικό και βρίσκεται σε *παράλληλη λειτουργία* (parallel model). Τα σφάλματα αναγνώρισης οφείλονται στις αποκλίσεις των παραμέτρων από τις βέλτιστες, στα σφάλματα των καταστάσεων, που οφείλονται στην απόκλιση των καταστάσεων από τις επιθυμητές και στο σφάλμα αρχικής κατάστασης. Για να βελτιστοποιηθεί το μοντέλο απαιτείται ένας αλγόριθμος που να λαμβάνει υπόψη τη δυναμική των καταστάσεων. Στην περίπτωση αυτή ο αλγόριθμος καλείται *μη οδηγούμενος αλγόριθμος* (undirected algorithm). Τα παραπάνω απεικονίζονται παραστατικά στο Σχ. 9.3, όπου παρουσιάζεται η εξέλιξη των καταστάσεων για τα μοντέλα σφάλματος εξίσωσης και εξόδου.



(α) μοντέλο σφάλματος εξίσωσης



(β) μοντέλο σφάλματος εξόδου

Σχήμα 9.3 Εξέλιξη καταστάσεων στα μοντέλα σφάλματος εξίσωσης και εξόδου.

Με λευκή βούλα απεικονίζονται οι επιθυμητές καταστάσεις και με μαύρη οι καταστάσεις του μοντέλου. Η διακεκομμένη γραμμή εκφράζει την εξέλιξη των καταστάσεων του μοντέλου και ο διακεκομμένος κύκλος τις αρχικές συνθήκες

Όπως προκύπτει από τις (9.4), (9.5) και το Σχ. 9.2, οι καταστάσεις του DFNN $g_l(k)$, $O_{li}^1(k)$, οι οποίες έχουν δυναμική, είναι εσωτερικές και δεν είναι μετρήσιμες. Η μόνη μετρήσιμη έξοδος του δικτύου είναι η συνολική έξοδος $y(k)$. Κατά συνέπεια το DFNN αποτελεί μοντέλο σφάλματος εξόδου και μπορεί να εφαρμοσθεί για την αναγνώριση δυναμικών συστημάτων οιασδήποτε μορφής, χωρίς να απαιτεί γνώση του συστήματος πέραν των δεδομένων εισόδου-εξόδου. Από την άλλη πλευρά εφόσον το DFNN βρίσκεται σε παράλληλη λειτουργία και οι καταστάσεις ακολουθούν αποκλειστικά τη δυναμική του, απαιτείται ένας ισχυρός αλγόριθμος

εκμάθησης, ο οποίος να λαμβάνει υπόψη τη δυναμική του μοντέλου και να έχει διευρυμένες δυνατότητες αναζήτησης του βέλτιστου σημείου μέσα στον ιδιαίτερα σύνθετο χώρο παραμέτρων με τα πολλά τοπικά ελάχιστα, που παρουσιάζουν τα δυναμικά συστήματα. Προς αυτή την κατεύθυνση έρχεται να συνδράμει ο αλγόριθμος SA-DRPROP, που θα αναπτυχθεί στην §10.2.

9.4 Το ζήτημα της αναγνώρισης παραμέτρων στα δυναμικά συστήματα

Η θεωρία που αφορά στην εκπαίδευση δυναμικών προσαρμοστικών συστημάτων, όπως τα δυναμικά νευρωνικά και ασαφή συστήματα, μπορεί να διαχωρισθεί σε τρία επίπεδα. Στο πρώτο επίπεδο περιλαμβάνεται η μαθηματική θεωρία, που σχετίζεται με τον υπολογισμό της συνάρτησης κλίσης του σφάλματος ως προς τις παραμέτρους του μοντέλου. Στο δεύτερο επίπεδο περιέχονται γενικές τεχνικές εκπαίδευσης δυναμικών συστημάτων και στο τρίτο οι προσαρμογές των τεχνικών αυτών για την εκπαίδευση αναδρομικών νευρωνικών δικτύων.

9.4.1 Η έννοια της διατεταγμένης παραγώγου

Βασικό ζήτημα στις μεθόδους αναγνώρισης παραμέτρων με χρήση της συνάρτησης κλίσης του σφάλματος (Gradient Descent - GD) αποτελεί η εξαγωγή των κλίσεων του σφάλματος ως προς τις παραμέτρους ($\nabla_{\theta} E$). Στην περίπτωση των στατικών συστημάτων δεν υπάρχει χρονική συσχέτιση μεταξύ των καταστάσεων ή της εξόδου και η εξαγωγή της κλίσης είναι άμεση, με χρήση του κανόνα της αλυσίδας (chain rule). Στα δυναμικά συστήματα όμως, όπως στην περίπτωση του DFNN, οι καταστάσεις συνδέονται χρονικά και το σφάλμα στην παρούσα χρονική στιγμή δεν εξαρτάται μόνο από τις παραμέτρους αυτής της στιγμής αλλά και από τις παρελθούσες τιμές τους μέσω των αναδράσεων. Έτσι το ζήτημα της εξαγωγής της συνάρτησης κλίσης καθίσταται περίπλοκο καθώς για τον υπολογισμό της θα πρέπει να ληφθούν υπόψη αυτές οι εξαρτήσεις.

Σημαντικό εργαλείο στον υπολογισμό της συνάρτησης κλίσης αποτελεί η έννοια της *διατεταγμένης μερικής παραγώγου* (ordered partial derivative), όπως αυτή ορίσθηκε από τον Werbos. Για να ορισθεί η διατεταγμένη παράγωγος αρχικά θεωρείται ένα σύνολο αποτελούμενο από n μεταβλητές $\{z_i, i=1, \dots, n\}$, για τις οποίες ισχύει η σχέση

$$z_i = f_i(z_1, \dots, z_{i-1}) \quad (9.6)$$

Η (9.6) υποδηλώνει ότι για τον υπολογισμό της μεταβλητής z_i απαιτείται η γνώση όλων των προηγούμενων μεταβλητών z_1, \dots, z_{i-1} . Η (9.6) αποτελεί ένα διατεταγμένο σύνολο εξισώσεων.

Με βάση την (9.6) η διατεταγμένη παράγωγος ορίζεται ως

$$\frac{\partial^+ z_j}{\partial z_i} = \frac{\partial z_j}{\partial z_i} \Big|_{\{z_1, \dots, z_i\} \text{ σταθερές}} \quad (9.7)$$

Από την (6.7) προκύπτουν οι ακόλουθες ιδιότητες:

$$\frac{\partial^+ z_{i+1}}{\partial z_i} = \frac{\partial z_{i+1}}{\partial z_i} \quad (9.8\alpha)$$

$$\frac{\partial^+ z_j}{\partial z_i} = 0 \quad \text{εφόσον } j < i$$

Όταν $j > i+1$ ο υπολογισμός της διατεταγμένης παραγώγου γίνεται χρησιμοποιώντας ένα από τα δύο ακόλουθα αναπτύγματα

$$\frac{\partial^+ z_j}{\partial z_i} = \frac{\partial z_j}{\partial z_i} + \sum_{k=i+1}^{j-1} \frac{\partial^+ z_j}{\partial z_k} \cdot \frac{\partial z_k}{\partial z_i} \quad (9.9\alpha)$$

$$\frac{\partial^+ z_j}{\partial z_i} = \frac{\partial z_j}{\partial z_i} + \sum_{k=i+1}^{j-1} \frac{\partial z_j}{\partial z_k} \cdot \frac{\partial^+ z_k}{\partial z_i} \quad (9.9\beta)$$

Οι εξισώσεις (6.9) αποτελούν τη βάση για την ανάπτυξη τεχνικών εκμάθησης, καθώς καθορίζουν την φορά επάνω στον άξονα του χρόνου, κατά την οποία θα γίνει ο υπολογισμός του $\nabla_{\theta} E$.

9.4.2 Εκμάθηση ανά δείγμα και κατά ομάδες

Για την εκμάθηση των παραμέτρων στα προσαρμοστικά συστήματα έχουν προταθεί δύο γενικές μέθοδοι: α) η εκμάθηση κατά ομάδες (batch/epochwise learning) και β) η εκμάθηση ανά δείγμα (on-line/pattern learning). Στην εκμάθηση κατά ομάδες τα δεδομένα χωρίζονται σε ομάδες $(u(k), y(k))$, $k = 1, \dots, k_f$. Το σύστημα τροφοδοτείται με τα δεδομένα και οι παράμετροί του ενημερώνονται μετά την εισαγωγή και του τελευταίου δεδομένου της ομάδας. Οι παράμετροι του συστήματος θεωρούνται σταθερές καθόλη τη διάρκεια της ομάδας. Η συνάρτηση σφάλματος για την περίπτωση συστήματος μίας εξόδου είναι η εξής:

$$E = \frac{1}{2} \sum_{k=1}^{k_f} (y_d(k) - y(k))^2 \quad (9.10)$$

Στην εκμάθηση ανά δείγμα οι παράμετροι του δικτύου ενημερώνονται σε κάθε δείγμα και η συνάρτηση σφάλματος είναι το στιγμιαίο σφάλμα

$$E(k') = \frac{1}{2} (y_d(k') - y(k'))^2 \quad (9.11)$$

Θα πρέπει να σημειωθεί ότι στην εκμάθηση κατά ομάδες υπολογίζεται η πραγματική κλίση $\nabla_{\theta} E$, ενώ στην εκμάθηση ανά δείγμα η κλίση που υπολογίζεται είναι προσέγγιση της πραγματικής. Για να είναι ακριβείς οι ενημερώσεις των βαρών με τη μέθοδο εκμάθησης ανά δείγμα και η κλίση να προσεγγίζει την πραγματική, θα πρέπει ο ρυθμός εκμάθησης να είναι χαμηλός. Στο κεφάλαιο αυτό θα εξετασθεί μόνο το ζήτημα της εκμάθησης κατά ομάδες.

9.4.3 Οι τεχνικές εκμάθησης EWBS και EWR

Έστω μία ομάδα αποτελούμενη από k_f δεδομένα εισόδου εξόδου $(u(k), y(k))$, $k = 1, \dots, k_f$. Όπως αναφέρεται στην §9.4.1, το ανάπτυγμα που θα ακολουθηθεί για τον υπολογισμό των διατεταγμένων παραγώγων της (9.9), καθορίζει και τη μέθοδο εκμάθησης. Σε αυτή τη βάση έχουν αναπτυχθεί δύο γενικές τεχνικές εκπαίδευσης κατά ομάδες: α) η EWBS (**E**POCHWISE **B**ACKSWEEP) και β) η EWR (**E**POCHWISE **R**ECURSIVE). Η EWBS χρησιμοποιεί το ανάπτυγμα (9.9α) και ο υπολογισμός της κλίσης $\nabla_{\theta} E$ ξεκινά από το τελικό χρονικό σημείο της ομάδας (δείγμα), k_f , και προχωρεί προς τα πίσω στον άξονα των χρόνων, έως την αρχική χρονική στιγμή. Στην κατηγορία αυτή εντάσσεται ο γνωστός αλγόριθμος εκπαίδευσης αναδρομικών νευρωνικών δικτύων BPTT (**B**ACKPROPAGATION **T**HROUGH **T**IME), σύμφωνα με την οποία το νευρωνικό δίκτυο «ξεδιπλώνεται στο χρόνο», δημιουργώντας ένα εικονικό δίκτυο από k_f χρονικά τμήματα, και στη συνέχεια υπολογίζονται οι κλίσεις μεταδίδοντας το σφάλμα από το τελικό χρονικό τμήμα προς το αρχικό.

Η EWR χρησιμοποιεί το δεύτερο ανάπτυγμα της (9.9) και εκτελεί την αντίστροφη διαδικασία. Ξεκινώντας από το αρχικό χρονικό σημείο ($k = 1$) προχωρεί προς το τέλος της ομάδας ($k = k_f$), υπολογίζοντας τις παραγώγους κάθε χρονική στιγμή ως συνάρτηση των παραγώγων στις προηγούμενες στιγμές. Στην κατηγορία αυτή

εντάσσεται η Dynamic Backpropagation, που προτάθηκε από τους Narendra και Parthasarathy και η Recurrent Backpropagation των Williams και Zipser.

Οι δύο γενικές τεχνικές βασίζονται στην ίδια μαθηματική θεωρία και από αυτή την άποψη είναι ισοδύναμες. Ωστόσο, η τεχνική EWBS έχει μικρότερο υπολογιστικό κόστος και χαμηλότερες απαιτήσεις αποθήκευσης από την EWR, στοιχείο που την καθιστά πιο ελκυστική από την EWR. Στη συνέχεια η EWBS μελετάται εφαρμοζόμενη στο δίκτυο DFNN.

9.4.4 Ενημέρωση των παραμέτρων του δικτύου DFNN με χρήση της EWBS

Καθώς τα τμήματα υπόθεσης και αποασαφοποίησης είναι στατικά, η εξαγωγή των παραγώγων του σφάλματος ως προς τις παραμέτρους υπόθεσης, $\frac{\partial E}{\partial m}$ και $\frac{\partial E}{\partial \sigma}$, γίνεται άμεσα με χρήση του κανόνα της αλυσίδας. Το ενδιαφέρον εστιάζεται στα τμήματα απόδοσης των κανόνων, τα οποία είναι δυναμικά. Έστω μία ομάδα αποτελούμενη από k_f δεδομένα εισόδου εξόδου $(u(k), y(k))$ κατά τη διάρκεια της οποίας οι παράμετροι διατηρούνται σταθερές. Από τις (9.4) και (9.5) συνάγεται ότι οι έξοδοι του κρυμμένου στρώματος και του στρώματος εξόδου θα δίνονται από τις ακόλουθες συναρτήσεις:

$$O_{ji}^1(k) = f_1(O_{ji}^1(k-1), \dots, O_{ji}^1(k-Oy_1), u(k), u(k-1), \dots, u(k-Ou), w_{1ji}, w_{2ji}, w_{3ji}) \quad (9.12)$$

$$g_j(k) = f_2(O_{ji}^1(k), O_{ji}^1(k-1), \dots, O_{ji}^1(k-Oy_3), g_j(k-1), \dots, g_j(k-Oy_2), w_{4j}, w_{5j}, w_{6j}) \quad (9.13)$$

$i = 1, \dots, Hn$

Από τις (9.12), (9.13) προκύπτει ότι οι έξοδοι $O_{ji}^1(k)$ και $g_j(k)$, οι οποίες αποτελούν τις καταστάσεις του συστήματος, συσχετίζονται χρονικά μεταξύ τους και θα επηρεάζουν τις καταστάσεις σε επόμενες χρονικές στιγμές ως εξής:

$$g_j(k) \rightarrow \begin{cases} g_j(k+1) \\ \dots \\ g_j(k+Oy_2) \end{cases} \quad (9.14\alpha)$$

$$O_{ji}^1(k) \rightarrow \begin{cases} O_{ji}^1(k+1) \\ \dots \\ O_{ji}^1(k+Oy_1) \\ g_j(k+1) \\ \dots \\ g_j(k+Oy_3) \end{cases} \quad (9.14\beta)$$

Κατά συνέπεια, ορίζοντας ως w_{1ji} και w_{2j} τις παραμέτρους του κρυμμένου στρώματος και του στρώματος εξόδου, αντίστοιχα, για το δίκτυο του j – στό κανόνα, οι συναρτήσεις κλίσης του σφάλματος ως προς τις παραμέτρους θα δίνονται από τις ακόλουθες σχέσεις

$$\frac{\partial E}{\partial w_{1ji}} = \sum_{k=1}^{k_f} \frac{\partial^+ E}{\partial O_{ji}^1(k)} \cdot \frac{\partial O_{ji}^1(k)}{\partial w_{1ji}} \quad (9.15\alpha)$$

$$\frac{\partial E}{\partial w_{2j}} = \sum_{k=1}^{k_f} \frac{\partial^+ E}{\partial g_j(k)} \cdot \frac{\partial g_j(k)}{\partial w_{2j}} \quad (9.15\beta)$$

Ορίζοντας $\lambda_{ji}^1(k) = \frac{\partial^+ E}{\partial O_{ji}^1(k)}$ και $\lambda_j^2(k) = \frac{\partial^+ E}{\partial g_j(k)}$, οι διατεταγμένες παράγωγοι

εξάγονται με εφαρμογή της (9.9α)

$$\lambda_j^2(k) = \frac{2}{k_f} \cdot (y(k) - y_d(k)) \frac{\mu_j(k)}{\sum_{i=1}^n \mu_i(k)} + \sum_{\substack{l=1 \\ k+l \leq k_f}}^{Oy_2} [\lambda_j^2(k+l) f_2'(k+l) w_{5jl}^{(j)}] \quad (9.16\alpha)$$

$$\lambda_{ji}^1(k) = \sum_{\substack{l=1 \\ k+l \leq k_f}}^{Oy_1} [\lambda_{ji}^1(k+l) f_1'(k+l) w_{2jil}^{(j,i)}] + \sum_{\substack{q=0 \\ k+q \leq k_f}}^{Oy_3} [\lambda_j^2(k+q) f_2'(k+q) w_{4jiq}^{(j)}] \quad (9.16\beta)$$

όπου $f_2'(k+l)^{(j)}$ και $f_1'(k+l)^{(j,i)}$ είναι οι παράγωγοι των $g_j(k+l)$ και $O_{ji}^1(k+l)$, αντίστοιχα, ως προς τα ορίσματά τους.

Από τις (9.16) προκύπτει ότι για να υπολογισθούν οι πολλαπλασιαστές $\lambda_j^2(k)$, $\lambda_{ji}^1(k)$, απαιτείται γνώση επόμενων τιμών τους, σύμφωνα με τις χρονικές συσχετίσεις των (9.14). Έτσι οι πολλαπλασιαστές υπολογίζονται ξεκινώντας από το τελικό δείγμα ($k = k_f$) και οπισθοχωρώντας προς την αρχή. Οι αρχικές τιμές των πολλαπλασιαστών (τελικό δείγμα, $k = k_f$) δίνονται από τις (9.17)

$$\lambda_j^2(k_f) = \frac{2}{k_f} \cdot (y(k_f) - y_d(k_f)) \frac{\mu_j(k_f)}{\sum_{i=1}^n \mu_i(k_f)} \quad (9.17\alpha)$$

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

$$\lambda_{ji}^1(k_f) = \lambda_{E_j}^2(k_f) f_2^{(j)}(k_f) w_{4,ji0} \quad (9.17\beta)$$

Οι παράμετροι ενημερώνονται σύμφωνα με τις ακόλουθες σχέσεις

$$w_{1,ji}(t+1) = w_{1,ji}(t) - \mu \frac{\partial E}{\partial w_{1,ji}} \quad (9.18\alpha)$$


$$w_{2,j}(t+1) = w_{2,j}(t) - \mu \frac{\partial E}{\partial w_{2,j}} \quad (9.18\beta)$$

όπου μ είναι ο ρυθμός εκμάθησης.

9.4.5 Το adjoint μοντέλο ως μέσο υπολογισμού των κλίσεων για το DFNN

Μία εναλλακτική πρόταση υπολογισμού της κλίσης του μέτρου σφάλματος ως προς τις παραμέτρους προτάθηκε από το Srinivasan. Η μέθοδος αυτή δε στηρίζεται στην έννοια της διατεταγμένης παραγώγου αλλά απαιτεί τη δημιουργία του adjoint μοντέλου του συστήματος, στο οποίο ο χρόνος κυλά αντίστροφα, και τη μετάδοση του σφάλματος από την τελική χρονική στιγμή ($k = k_f$) έως την αρχική μέσω αυτού του μοντέλου. Άρα και σχηματισθεί το adjoint μοντέλο, η εξαγωγή των παραγώγων είναι άμεση, καθώς αυτές θα αποτελούν τις εξόδους των επιμέρους τμημάτων του μοντέλου. Η κατασκευή του στηρίζεται στους ακόλουθους κανόνες:

- Στο δυναμικό σύστημα αντιστρέφεται η ροή των σημάτων, μετασχηματίζοντας τους κόμβους σε αθροιστές και τους αθροιστές σε κόμβους. Με αυτό τον τρόπο οι έξοδοι γίνονται είσοδοι και αντίστροφα.
- Το όρισμα όλων των χρονικά μεταβαλλόμενων μεταβλητών μετασχηματίζεται σε $k - \varphi$, όπου φ είναι η μεταβλητή του «αντίστροφου χρόνου», όπως φαίνεται στο Σχ. 9.4.

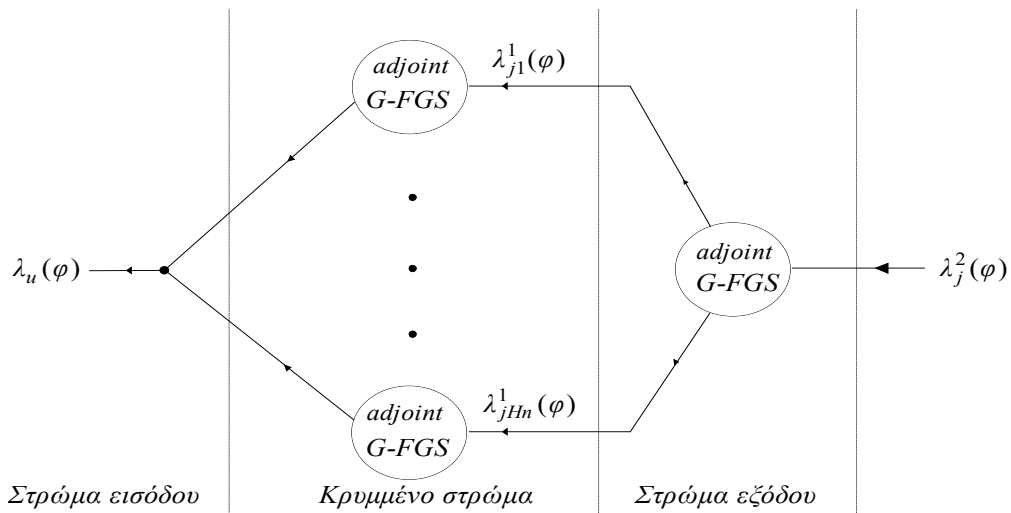


Σχήμα 9.4 Συσχέτιση πραγματικού χρόνου και «αντίστροφου χρόνου»


- Εάν υπάρχουν μη γραμμικά τμήματα αντικαθίστανται από την παράγωγο της μη γραμμικότητας.

Για να γίνει κατανοητή η λειτουργία του adjoint μοντέλου, στη συνέχεια κατασκευάζεται το adjoint μοντέλο των δυναμικών τμημάτων απόδοσης του DFNN. Ακολουθώντας τους παραπάνω κανόνες, τα adjoint μοντέλα των σχημάτων 9.2(α) και (β) παρατίθενται στο Σχ. 9.5.

Το ζητούμενο στο Σχ. 9.5(β) είναι να υπολογισθεί το σφάλμα $\lambda_y(\varphi)$. Από το Σχ. 9.5(β)



(α) Γενική διαμόρφωση του adjoint μοντέλου για το τμήμα απόδοσης του j-στού ασαφούς κανόνα



(β) Το adjoint μοντέλο του G-FGS. Τα βάρη του νευρωνίου δε σημειώνονται για λόγους ευκρίνειας του σχήματος· είναι εκείνα του σχήματος 9.2(β).

Σχήμα 9.5 Το adjoint μοντέλο του τμήματος απόδοσης των ασαφών κανόνων

προκύπτει ότι η είσοδος του adjoint μοντέλου για το νευρώνα G-FGS είναι το άμεσο σφάλμα για $\varphi=0$, το οποίο ορίζεται ως εξής:

$$\frac{\partial E}{\partial y(k-\varphi)} = \begin{cases} \frac{\partial E}{\partial y(k)}, & \text{αν } \varphi = 0 \\ 0, & \text{αν } \varphi \neq 0 \end{cases} \quad (9.18)$$

Στη συνέχεια, κάθε μη γραμμικό τμήμα αντικαθίσταται από την παράγωγό του και το σφάλμα διαχέεται από το τέλος προς την αρχή της δομής. Συμβολίζοντας το σφάλμα στην είσοδο της μη γραμμικότητας ως $\lambda_y(\varphi)$, η έξοδος αυτής θα δώσει τους

όρους $\lambda_z(\varphi) = \lambda_y(\varphi) \cdot \frac{\partial f(k-\varphi)}{\partial y(k-\varphi)}$ για το τμήμα ανάδρασης του νευρώνα και

$\lambda_p(\varphi) = \lambda_y(\varphi) \cdot \frac{\partial f(k-\varphi)}{\partial x(k-\varphi)}$ για την FIR σύναψη. Όταν ένας όρος διέρχεται από έναν

καθυστερητή, καθυστερείται κατά μία χρονική μονάδα στον αντίστροφο χρόνο, επομένως προχωρεί κατά μία μονάδα στον πραγματικό. Κατά συνέπεια, όταν π.χ. ο όρος $\lambda_p(\varphi)$ διέλθει από j καθυστερητές θα έχει μετασχηματισθεί ως εξής:

$$\lambda_p(\varphi-j) = \lambda_y(\varphi-j) \cdot \frac{\partial f(k-\varphi+j)}{\partial x(k-\varphi)} \quad (9.19)$$

Έτσι το σφάλμα $\lambda_y(\varphi)$ δίνεται από τη σχέση

$$\lambda_y(\varphi) = \frac{\partial E}{\partial y(k-\varphi)} + \sum_{j=1}^{O_y} \lambda_z(\varphi-j) = \frac{\partial E}{\partial y(k-\varphi)} + \sum_{j=1}^{O_y} \lambda_y(\varphi-j) \cdot \frac{\partial y(k-\varphi+j)}{\partial y(k-\varphi)} \quad (9.20)$$

Εάν η είσοδος x είναι μία εξωτερική είσοδος, τότε δε χρειάζεται να εξαχθεί το αντίστοιχο $\lambda_x(\varphi)$. Εφόσον όμως, όπως στην παρούσα περίπτωση, ο νευρώνας είναι τμήμα μίας γενικότερης δυναμικής δομής, η είσοδος x θα αποτελεί έξοδο ενός άλλου στοιχείου και το $\lambda_x(\varphi)$ απαιτείται να υπολογισθεί:

$$\lambda_x(\varphi) = \sum_{j=1}^{O_u} \lambda_p(\varphi-j) = \sum_{j=1}^{O_u} \lambda_y(\varphi-j) \cdot \frac{\partial y(k-\varphi+j)}{\partial x(k-\varphi)} \quad (9.21)$$

Με βάση τα παραπάνω, η συνολική δυναμική δομή χωρίζεται σε επιμέρους τμήματα, εξάγονται τα σφάλματα $\lambda(\varphi)$ ως προς όλα τα τμήματα, που περιέχουν δυναμική, και στη συνέχεια υπολογίζονται οι κλίσεις ως προς τις παραμέτρους συναρτήσεων των $\lambda(\varphi)$. Για την παρούσα περίπτωση οι κλίσεις της συνάρτησης σφάλματος ως προς τις παραμέτρους δίνονται από τις ακόλουθες σχέσεις:

$$\frac{\partial E}{\partial w_{1ji}} = \sum_{k=1}^{k_f} \sum_{\varphi=0}^{k-1} \frac{\partial E}{\partial w_{1ji}(k-\varphi)} \quad (9.22\alpha)$$

$$\frac{\partial E}{\partial w_{2j}} = \sum_{k=1}^{k_f} \sum_{\varphi=0}^{k-1} \frac{\partial E}{\partial w_{2j}(k-\varphi)} \quad (9.22\beta)$$

όπου

$$\frac{\partial E}{\partial w_{1ji}(k-\varphi)} = \frac{\partial O_{ji}^1(k-\varphi)}{\partial w_{1ji}(k-\varphi)} \cdot \lambda_{ji}^1(\varphi) \quad (9.23\alpha)$$

$$\frac{\partial E}{\partial w_{2j}(k-\varphi)} = \frac{\partial g_j(k-\varphi)}{\partial w_{2j}(k-\varphi)} \cdot \lambda_j^2(\varphi) \quad (9.23\beta)$$

και τα $\lambda_{ji}^1(\varphi)$ και $\lambda_j^2(\varphi)$ υπολογίζονται αναδρομικά ως εξής:

$$\lambda_j^2(\varphi) = \frac{2}{k_f} \cdot (y(k) - y_d(k)) \frac{\mu_j(k)}{\sum_{i=1}^n \mu_i(k)} + \sum_{l=1}^{Oy_2} [\lambda_j^2(\varphi-l) f_2'(k-\varphi+l) w_{5jl}^{(j)}] \quad (9.24\alpha)$$

$$\lambda_{ji}^1(\varphi) = \sum_{l=1}^{Oy_1} [\lambda_{ji}^1(\varphi-l) f_1'(k-\varphi+l) w_{2jil}^{(j,i)}] + \lambda_j^2(\varphi) f_2'(k-\varphi) w_{4ji0}^{(j)} \quad (9.24\beta)$$

Το adjoint μοντέλο αποτελεί μία γενική και συστηματική μέθοδο εξεύρεσης των συναρτήσεων κλίσης, η οποία μπορεί να εφαρμοσθεί σε οποιαδήποτε δυναμική δομή ή σύνολο διασυνδεδεμένων δυναμικών δομών. Συγκρίνοντας όμως τις (9.22), (9.24) με τις (9.15), (9.16) γίνεται αντιληπτό ότι παρουσιάζει πολύ μεγάλο υπολογιστικό φόρτο, ο οποίος αυξάνεται με την αύξηση του μεγέθους της ομάδας, k_f , καθώς δε λαμβάνει υπόψη τις τάξεις των καθυστερήσεων του συστήματος. Αντίθετα στην τεχνική EWBS, όπου χρησιμοποιείται η διατεταγμένη παράγωγος, δεν εξετάζονται χρονικοί συσχετισμοί σε βάθος πέραν της μέγιστης καθυστέρησης στο σύστημα. Το μειονέκτημα αυτό είναι επακόλουθο της γενικότητας του adjoint μοντέλου.

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

10. ΠΡΟΣΟΜΟΙΩΜΕΝΗ ΑΝΟΠΤΗΣΗ ΔΥΝΑΜΙΚΗ ΕΥΠΡΟΣΑΡΜΟΣΤΗ ΑΝΑΣΤΡΟΦΗ ΔΙΑΔΟΣΗ (SA – DRPROP)

10.1 Εισαγωγή

Μια προσαρμοστική μέθοδος εκμάθησης, η SA-DRPROP (Προσομοιωμένη Ανόπτηση Δυναμική Ευπροσάρμοστη Ανάστροφη Διάδοση), προτείνεται σε αυτή την εργασία, για την εκπαίδευση αναδρομικών ασαφών συστημάτων. Η μέθοδος τροποποιεί τον αλγόριθμο SARPROP, που αναπτύχθηκε αρχικά για στατικά νευρωνικά μοντέλα, προκειμένου να εφαρμοστεί σε δυναμικά μοντέλα. Οι ιδιότητες του SA-DRPROP διερευνώνται από μια σειρά παραδειγμάτων προσομοίωσης.

Τα αναδρομικά νευρωνικά και ασαφή μοντέλα έχουν προσελκύσει μεγάλη προσοχή κατά τις τελευταίες δύο δεκαετίες, λόγω των αυξημένων δυνατοτήτων αναγνώρισης χρονικών συσχετίσεων, και έχουν χρησιμοποιηθεί εκτενώς σε διάφορες εφαρμογές στον πραγματικό κόσμο, συμπεριλαμβανομένης της αναγνώρισης συστήματος, του ελέγχου και της αναγνώρισης χρονικών προτύπων. Η πιο συνηθισμένη μέθοδος εκπαίδευσης για δυναμικά ασαφή μοντέλα είναι η Back Propagation Through Time (BPTT) [13], μία επέκταση της δημοφιλούς μεθόδου Back Propagation σε δυναμικά μοντέλα. Ωστόσο, το BPTT παρουσιάζει ορισμένα μειονεκτήματα, όπως η χαμηλή ταχύτητα εκμάθησης και η σύγκλιση με τα τοπικά ελάχιστα της επιφάνειας σφάλματος.

Πρόσφατα ο αλγόριθμος δυναμικής ευπροσάρμοστης ανάστροφης διάδοσης (D-RPROP) προτάθηκε για την κατάρτιση αναδρομικών ασαφών νευρωνικών δικτύων, παρέχοντας βελτιωμένα χαρακτηριστικά απόδοσης σε σχέση με το BPTT. Ο αλγόριθμος D-RPROP είναι μία προσαρμογή της μεθόδου RPROP στο πρόβλημα της εκπαίδευσης των δυναμικών μοντέλων. Η RPROP αναπτύχθηκε αρχικά για στατικά νευρωνικά δίκτυα και αποτελεί μία από τις μεθόδους εκμάθησης πρώτης τάξης με τις καλύτερες επιδόσεις για ασαφή και νευρωνικά συστήματα. Παρ' όλα αυτά, στη μέθοδο RPROP το ζήτημα της προβληματικής σύγκλισης προς τοπικά ελάχιστα, που αντιμετωπίζουν όλες οι μέθοδοι που βασίζονται στη επικλινή κάθοδο (gradient descent), δεν εξαλείφεται πλήρως. Ως εκ τούτου, σε μια προσπάθεια να αμβλυθεί αυτό το μειονέκτημα, ένας συνδυασμός RPROP με την τεχνική καθολικής αναζήτησης της Simulated Annealing (SA) είχε ως αποτέλεσμα την δημιουργία ενός αλγόριθμου που ονομάστηκε SARPROP και ο οποίος αποδείχθηκε μια αποτελεσματική μέθοδος εκμάθησης για στατικά νευρωνικά δίκτυα. Η παρούσα

εργασία επεκτείνει τον συνδυασμό της καθολικής αναζήτησης και της δυναμικής ανάστροφης διάδοσης στην περίπτωση αναδρομικών ασαφών συστημάτων. Συγκεκριμένα, ο αλγόριθμος D-RPROP τροποποιείται: (α) προσθέτοντας έναν όρο προσομοιωμένης ανόπτησης στην κλίση σφάλματος και (β) με μερική τροποποίηση του σχήματος προσαρμογής του μεγέθους βήματος που χρησιμοποιείται D-RPROP.

10.2 Η μέθοδος SA-DRPROP

10.2.1 Ο Αλγόριθμος της SA-DRPROP

Σε μεθόδους που βασίζονται στη επικλινή κάθοδο (gradient descent), όπως η BPTT, οι μεταβολές βάρους είναι ανάλογες με το μέγεθος της κλίσης μιας συνάρτησης σφάλματος E :

$$\Delta w_i(t) = -\mu \frac{\partial^+ E(t)}{\partial w_i} \quad (10.1)$$

όπου $\frac{\partial^+ E}{\partial w_i}$ είναι η διατεταγμένη μερική παράγωγος (ordered partial derivative) του E

σε σχέση με ένα βάρος w_i που χρησιμοποιείται σε αναδρομικά μοντέλα, t αντιπροσωπεύει τον δείκτη επανάληψης και μ είναι ο ρυθμός εκμάθησης, ο οποίος διατηρείται σταθερός σε όλη τη διάρκεια της διαδικασίας εκμάθησης και είναι κοινός για όλες τις ενημερώσεις βάρους. Επομένως, η κατάλληλη επιλογή του ρυθμού εκμάθησης είναι ζωτικής σημασίας για την εξέλιξη της διαδικασίας εκμάθησης και αποτελεί σημαντικό περιορισμό. Το D-RPROP προσπαθεί να αμβλύνει αυτό το μειονέκτημα του BPTT επιτρέποντας σε κάθε παράμετρο προσαρμογής να έχει το ατομικό της μέγεθος βήματος, το οποίο προσαρμόζεται κατά τη διάρκεια της διαδικασίας εκμάθησης βάσει του προσήμου της αντίστοιχης μερικής παραγώγου στην τρέχουσα και στην προηγούμενη επανάληψη. Επομένως, η επίδραση της διαδικασίας προσαρμογής δε δυσχεραίνεται από την επίδραση του μεγέθους της κλίσης των παραμέτρων, αλλά εξαρτάται μόνο από τη πρόσφατη συμπεριφορά της κλίσης ([9]).

Συγκεκριμένα, οι $\frac{\partial^+ E(t)}{\partial w_i}$ και $\frac{\partial^+ E(t-1)}{\partial w_i}$ εκφράζουν την παράγωγο του E σε σχέση με το w_i στην τρέχουσα και την προηγούμενη επανάληψη, αντίστοιχα.

Καθορίζοντας ως n^+ και n^- τους συντελεστές αύξησης και εξασθένησης, αντίστοιχα, η D-RPROP περιγράφεται σε μορφή ψευδοκώδικα ως εξής:

(α) Για όλα τα βάρη w_i αρχικοποιούνται τα μεγέθη βήματος $\Delta_i^{(1)} = \Delta_0$

Επανάληψη

(β) Για όλα τα βάρη w_i υπολογίζεται η κλίση σφάλματος: $\frac{\partial^+ E(t)}{\partial w_i}$

(γ) Για όλα τα βάρη w_i , ενημερώνονται τα μεγέθη βήματος:

$$(γ.1) \quad \text{If} \quad \frac{\partial^+ E(t)}{\partial w_i} \times \frac{\partial^+ E(t-1)}{\partial w_i} > 0 \quad \text{then} \quad \Delta_i^{(t)} = n^+ \cdot \Delta_i^{(t-1)} \quad (2)$$

$$(γ.2) \quad \text{Else if} \quad \frac{\partial^+ E(t)}{\partial w_i} \times \frac{\partial^+ E(t-1)}{\partial w_i} < 0 \quad \text{then} \\ \Delta_i^{(t)} = \max \{ n^- \cdot \Delta_i^{(t-1)}, \Delta_{\min} \} \quad (3)$$

$$(γ.3) \quad \text{Else} \quad \Delta_i^{(t)} = \Delta_i^{(t-1)} \quad (4)$$

$$(δ) \quad \text{Ενημέρωση βαρών } w_i: \Delta w_i(t) = -\text{sign}\left(\frac{\partial^+ E(t)}{\partial w_i}\right) \cdot \Delta_i^{(t)} \quad (5)$$

Μέχρι την επίτευξη σύγκλισης

Ο αλγόριθμος SA-DRPROP τροποποιεί τα βήματα (β) και (γ.2) του D-RPROP όπως φαίνεται ακολούθως:

(β') Υπολογίζεται η κλίση σφάλματος SA-DRPROP =

$$\frac{\partial^+ E(t)}{\partial w_i} - 0.01 \cdot SA \cdot \frac{w_i}{1 + w_i^2} \quad (6)$$

$$(γ.2') \quad \text{Else if} \quad \frac{\partial^+ E(t)}{\partial w_i} \times \frac{\partial^+ E(t-1)}{\partial w_i} < 0 \quad \text{then}$$

$$\text{If} \quad (\Delta_i^{(t)} < 0.4 \cdot SA^2)$$

$$\text{then} \quad \Delta_i^{(t)} = \max \{ n^- \cdot \Delta_i^{(t-1)} \cdot 0.8 \cdot r \cdot SA^2, \Delta_{\min} \} \quad (7)$$

$$\text{else} \quad \Delta_i^{(t)} = \max \{ n^- \cdot \Delta_i^{(t-1)}, \Delta_{\min} \} \quad (8)$$

όπου $SA = 2^{-t \cdot Temp}$ είναι ο προσομοιωμένος όρος απόπτωσης, η παράμετρος r λαμβάνει τυχαίες τιμές εντός του διαστήματος $[0, 1]$ και $Temp$ είναι η θερμοκρασία.

Το τροποποιημένο βήμα (γ.2') στοχεύει στην προσθήκη «θορύβου» στα βάρη, σύμφωνα με την έννοια της προσομοιωμένης απόπτωσης, προκειμένου να αυξηθεί η ταχύτητα σύγκλισης της διαδικασίας εκμάθησης. Στη μέθοδο SA-DRPROP

προστίθεται «θόρυβος» στις τιμές ενημέρωσης βάρους όταν η κλίση σφάλματος αλλάζει πρόσημο σε δύο διαδοχικές επαναλήψεις και το μέγεθος της τιμής ενημέρωσης είναι μικρότερο από μία τιμή, η οποία είναι ανάλογη προς τον όρο SA.

Τοιουτοτρόπως, η ενημέρωση βάρους τροποποιείται από τον «θόρυβο» μόνο όταν έχει σχετικά μικρή τιμή, επιτρέποντας έτσι στο βάρος να κινηθεί εκτός του τοπικού ελάχιστου, ελαχιστοποιώντας παράλληλα τη διαταραχή της διαδικασίας προσαρμογής.

Στο τροποποιημένο στάδιο (β'), ένας όρος «απόσβεσης» βάρους (weight decay) προστίθεται στην κλίση σφάλματος. Η επίδραση αυτού του όρου είναι η τροποποίηση της επιφάνειας σφάλματος έτσι ώστε να ευνοούνται αρχικά βάρη με χαμηλότερες τιμές. Καθώς η εκπαίδευση προχωρά, το μέγεθος της απόσβεσης βάρους μειώνεται, διευκολύνοντας την αύξηση των μεγαλύτερων βαρών και επιτρέποντας στο μοντέλο να διερευνήσει περιοχές της επιφάνειας σφάλματος που προηγουμένως δεν ήταν διαθέσιμες. Επιπροσθέτως, η χρήση της απόσβεσης βάρους αποδεικνύεται ότι βελτιώνει τη δυνατότητα γενίκευσης του μοντέλου.

10.2.2 Εξαγωγή των κλίσεων σφάλματος

Στη συνέχεια, ο αλγόριθμος SA-DRPROP θα εφαρμοστεί στο Dynamic Fuzzy Neural Network (DFNN), χρησιμοποιώντας ως μέτρο σφάλματος το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error - MSE). Λόγω των χρονικών σχέσεων που υπάρχουν σε ένα δυναμικό σύστημα, η εξαγωγή των διατεταγμένων μερικών παραγώγων δεν είναι απλή και επιτυγχάνεται μέσω ενός συνόλου *αναδρομικών εξισώσεων*. Θα πρέπει να σημειωθεί ότι, πέραν του DFNN, το προτεινόμενο σχήμα εκμάθησης SA-DRPROP είναι αρκετά γενικό, εφαρμόσιμο σε άλλες δομές δικτύου, αφού τα δομικά χαρακτηριστικά κάθε μοντέλου ενσωματώνονται άμεσα στις κλίσεις σφάλματος.

Το DFNN αποτελείται από r ασαφείς κανόνες της μορφής:

$$R^{(l)} : \text{IF } u_1(k) \text{ is } A_1^l \text{ AND } \dots \text{ AND } u_m(k) \text{ is } A_m^l \text{ THEN } \hat{y}_l(k) = RNN_l(\mathbf{u}(k)) \quad (10.2)$$
$$l = 1, \dots, r$$

όπου RNN_l είναι ένα αναδρομικό νευρωνικό δίκτυο της μορφής $m - H - 1$, με m και H να εκφράζουν τον αριθμό των νευρώνων των στρωμάτων εισόδου και των

κρυμμένων στρωμάτων, αντίστοιχα. Το στρώμα εξόδου περιλαμβάνει έναν μόνο νευρώνα, ο οποίος παρέχει την έξοδο του κανόνα $\hat{y}_l(k)$.

Η έξοδος του μοντέλου τη χρονική στιγμή k , $\hat{y}(k)$, προσδιορίζεται χρησιμοποιώντας τη μέθοδο αποασαφοποίησης σταθμισμένων κέντρων (weighted average defuzzification method). Ο βαθμός εκπλήρωσης του εκάστοτε κανόνα είναι το αλγεβρικό γινόμενο των συναρτήσεων συμμετοχής που εμπλέκονται στον κανόνα. Οι συναρτήσεις συμμετοχής είναι Γκαουσιανές.

Τα τμήματα υπόθεσης και αποασαφοποίησης είναι στατικά, ενώ το τμήμα απόδοσης είναι δυναμικό. Η λειτουργία του RNN_l για τον l -th ασαφή κανόνα περιγράφεται από το ακόλουθο σύνολο εξισώσεων:

$$O_{li}^1(k) = \tanh\left(\sum_{j=1}^m \sum_{q=0}^{O_u} w_{ijq}^{1(l)} \cdot u_j(k-q) + \sum_{j=1}^{O_{y1}} w_{ij}^{2(l)} \cdot O_{li}^1(k-j) + w_i^{3(l)}\right) \quad l=1,\dots,r \quad i=1,\dots,l \quad (10.3\alpha)$$

$$\hat{y}_l(k) = \tanh\left(\sum_{j=1}^H \sum_{q=0}^{O_{y3}} w_{jq}^{4(l)} \cdot O_{lj}^1(k-q) + \sum_{j=1}^{O_{y2}} w_j^{5(l)} \cdot \hat{y}_l(k-j) + w^{6(l)}\right) \quad l=1,\dots,r \quad (10.3\beta)$$

όπου χρησιμοποιείται η ακόλουθη σημειογραφία:

- $O_{li}^1(k)$ είναι η έξοδος του i -th κρυμμένου νευρώνα τη χρονική στιγμή k .
- $\hat{y}_l(k)$ η έξοδος του νευρώνα του στρώματος εξόδου τη χρονική στιγμή k .
- O_u , O_{y1} και O_{y3} , O_{y2} είναι οι σειρές χρονικών υστερήσεων των εισόδων και η ανάδραση των τοπικών εξόδων, για τους νευρώνες στα κρυφά στρώματα και σε αυτά της εξόδου, αντίστοιχα.

• $w_{ijq}^{1(l)}$, $w_{ij}^{2(l)}$ και $w_{jq}^{4(l)}$, $w_j^{5(l)}$ είναι FIR και IIR συναπτικά βάρη στα κρυφά στρώματα και σε αυτά της εξόδου, αντίστοιχα. $w_i^{3(l)}$, $w^{6(l)}$ είναι οι όροι πόλωσης των νευρώνων του κρυφού στρώματος και του νευρώνα της εξόδου.

Προκειμένου να προσδιοριστούν οι κλίσεις σφάλματος του δυναμικού μέρους του DFNN, εισάγουμε

(α) το διάνυσμα κατάστασης (state vector) $x(k)$:

$$x(k) = \left[O_{11}^1(k), \dots, O_{1H}^1(k), \dots, O_{r1}^1(k), \dots, O_{rH}^1(k), \hat{y}_1(k), \dots, \hat{y}_r(k) \right]^T \quad (10.4)$$

(β) το διάνυσμα ελέγχου (control vector) θ , που περιλαμβάνει τις παραμέτρους απόδοσης

$$\theta = [w_1^T, w_2^T, w_3^T, w_4^T, w_5^T, w_6^T]^T \quad (10.5)$$

(γ) τις συναρτήσεις κατάστασης:

$$f = [f_{11}^1(k), \dots, f_{r1}^1(k), \dots, f_{1H}^1(k), \dots, f_{rH}^1(k), f_1^2(k), \dots, f_r^2(k)]^T = \mathbf{0} \quad k = 1, \dots, k_f \quad (10.6)$$

- Οι κλίσεις σφάλματος δίδονται από το

$$\frac{\partial^+ E}{\partial \theta} = \lambda^T \frac{\partial f}{\partial \theta} \quad (10.7)$$

όπου οι πολλαπλασιαστές Lagrange λ διαμορφώνουν ένα $[r \cdot k_f \cdot (1+H)] \times 1$

διάνυσμα, που ορίζεται ως εξής:

$$\lambda^T = [(\lambda(1))^T, \dots, (\lambda(k_f))^T] \quad (10.8)$$

$$\lambda(k) = [\lambda_{11}^1(k), \dots, \lambda_{r1}^1(k), \dots, \lambda_{1H}^1(k), \dots, \lambda_{rH}^1(k), \lambda_1^2(k), \dots, \lambda_r^2(k)]^T \quad (10.9)$$

- Η εξαγωγή των πολλαπλασιαστών Lagrange βασίζεται στον τύπο

$$\frac{\partial E}{\partial x} + \lambda^T \frac{\partial f}{\partial \theta} = \mathbf{0} \quad (10.10)$$

- Αφού οι υπολογισμοί διεξαχθούν στον (10.10), οι πολλαπλασιαστές προσδιορίζονται με τις ακόλουθες επαναλαμβανόμενες εξισώσεις:

$$\lambda_l^2(k) = \frac{2}{k_f} \cdot [y(k) - y_d(k)] \cdot \frac{\mu_l(k)}{\sum_{i=1}^r \mu_i(k)} + \sum_{\substack{j=1 \\ k+j \leq k_f}}^{Oy_2} [\lambda_l^2(k+j) \cdot f_2'^{(l)}(k+j) \cdot w_j^{5(l)}] \quad (10.11\alpha)$$

$$\lambda_{li}^1(k) = \sum_{\substack{j=1 \\ k+j \leq k_f}}^{Oy_1} [\lambda_{li}^1(k+j) \cdot f_1'^{(l,i)}(k+j) \cdot w_{ij}^{2(l)}] + \sum_{\substack{q=0 \\ k+q \leq k_f}}^{Oy_3} [\lambda_l^2(k+q) \cdot f_2'^{(l)}(k+q) \cdot w_{iq}^{4(l)}] \quad (10.11\beta)$$

όπου $i = 1, \dots, H$, $l = 1, \dots, r$ και $f_2'^{(l)}(k+j)$, $f_1'^{(l,i)}(k+j)$ είναι οι παράγωγοι του $\hat{y}_j(k+l)$ και

$O_{ii}^1(k+j)$, αντίστοιχα, ως προς τα ορίσματά τους. Οι εξισώσεις (10.11) είναι αναδρομικές εξισώσεις διαφορών, που μπορούν να επιλυθούν για $k = k_f, k_f - 1, \dots, 1$

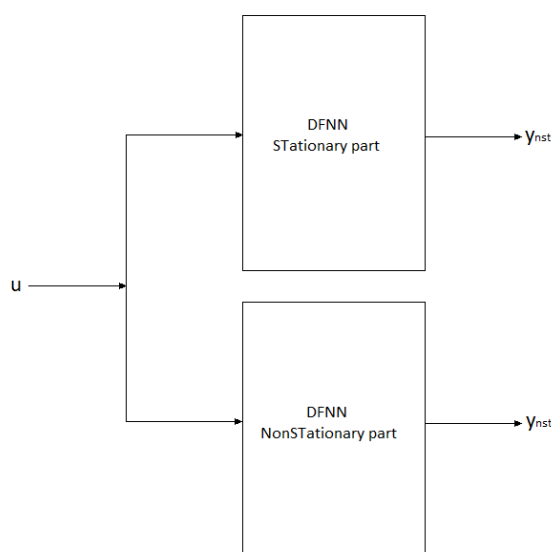
. Για $k = k_f$, οι δεύτεροι όροι των αθροισμάτων στις (10.11α) και (10.11β) εξαλείφονται, οδηγώντας στις απαραίτητες οριακές συνθήκες.

- Οι κλίσεις σφάλματος υπολογίζονται από την (10.7), μετά την αντικατάσταση των (10.6), (10.8) στο (10.7) και λαμβάνοντας υπόψη τις (10.5) και (10.11).

11. ΑΝΑΛΥΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ – ΣΥΜΠΕΡΑΣΜΑΤΑ

11.1 Υλοποίηση πλατφόρμας δοκιμών και παραμετροποίηση

Για τις ανάγκες των δοκιμών, δημιουργήθηκε μία πλατφόρμα η οποία υλοποίησε το μοντέλο DFNN με χρήση της μεθόδου SA-DRPROP που προτείνεται στην παρούσα διπλωματική. Η πλατφόρμα αποτελούταν από τρία κύρια τμήματα για κάθε ένα από τα νευρωνικά δίκτυα των φίλτρων διαχωρισμού, της εκάστοτε κατηγορίας πνευμονικών ήχων.



Σχήμα 11. 1 Φίλτρο διαχωρισμού DFNN

Τα δύο πρώτα τμήματα υλοποιήθηκαν με χρήση της γλώσσα προγραμματισμού C, με σκοπό την εκπαίδευση (training) του μοντέλου της εκάστοτε κατηγορίας και την αξιολόγηση (testing) αυτού, για το σύνολο των δεδομένων (datasets) της κατηγορίας. Το τρίτο τμήμα υλοποιήθηκε με χρήση της γλώσσα προγραμματισμού MATLAB, το οποίο διαχώριζε τα αποτελέσματα ανά περίπτωση (ασθενή) και τα απεικόνιζε υπό μορφή γραφημάτων.

Σε κάθε περίπτωση προηγούνταν των δοκιμών κατάλληλη ρύθμιση των δομικών παραμέτρων του μοντέλου και αναλόγως αυτών της εκπαίδευσης, όπως βλέπουμε παρακάτω.

Οι δομικές παράμετροι είναι ίδιες κατά την εκπαίδευση και κατά την αξιολόγηση στην εκάστοτε δοκιμή.

Πίνακας 11. 1 Παράμετροι εκπαίδευσης

Παραμετροποίηση των Μοντέλων				
Όνομα		Τιμή	Περιγραφή	
Παράμετροι Δομής	<i>Rules</i>		2-7 Αριθμός κανόνων ανάλογα με το μοντέλο διαχωρισμού	
	<i>Con_inp</i>		1 Διάνυσμα εισόδου $u(k)$ άνευ αναδράσεως	
	<i>Ou</i>		0-1 Τάξη του FIR $U \rightarrow O1[i]$	
	<i>Oy1</i>		0-2 Τάξη του IIR του $O1[i]$	
	<i>Oy2</i>		0-2 Τάξη του IIR του $y[i]$	
	<i>Oy3</i>		0-2 Τάξη του FIR $O1[i] \rightarrow y[i]$	
	<i>N_hid</i>		3-6 Αριθμών νευρώνων κρυφού στρώματος	
Παράμετροι Εκπαίδευσης	<i>Temp</i>		1.2 Θερμοκρασία SA-RDROP	
	<i>Kf_trn</i>	<i>Coarse Crackles</i>	4086	Σύνολο δεδομένων εκπαίδευσης
		<i>Fine Crackles</i>	5110	
		<i>Squawks</i>	5110	
	<i>Max_epochs</i>		1000	Μέγιστος αριθμός εποχών εκπαίδευσης τους μοντέλου
	<i>Lr_con</i>		0.01	Αρχικός ρυθμός εκμάθησης
	<i>Lower</i>		-0.8	Κάτω όριο κανονικοποίησης
	<i>Upper</i>		0.8	Άνω όριο κανονικοποίησης
	<i>Gamma</i>		0.4	Συντελεστής επικάλυψης
	<i>N_plus_w (n⁺)</i>		1.05	Συντελεστής αύξησης
	<i>N_minus_w (n⁻)</i>		0.5	Συντελεστής εξασθένισης
	<i>Dmin_w (Δ_{min})</i>		0.0001	Κάτω όριο μεγέθους βήματος
	<i>Dmax_w (Δ_{max})</i>		0.5	Άνω όριο μεγέθους βήματος
	<i>DO_w (Δ₀)</i>		0.01	Αρχικοποίηση των μεγεθών βημάτων για όλα τα βάρη

Συνολικά εκπονήθηκαν 420 δοκιμές εκπαίδευσης και αξιολόγησης των μοντέλων για όλες τις κατηγορίες ήχου (35 συνδυασμοί δομικών παραμέτρων μοντέλου x 6 φίλτρα x 2 [εκπαίδευση – αξιολόγηση]). Μόνο οι πρώτοι κατά σειρά συνδυασμοί

δομικών παραμέτρων των μοντέλων των 6 φίλτρων διαφέρουν μεταξύ τους. Οι υπόλοιποι 34 από το σύνολο των 35 δοκιμών, επαναλήφθηκαν και για τις 6 περιπτώσεις. Προσπαθήσαμε με αυτόν τον τρόπο να καλύψουμε έναν ικανοποιητικό αριθμό διαφορετικών δομών του μοντέλου. Η παράμετρος *Rules* παρέμεινε σταθερή σε κάθε μοντέλο διαχωρισμού, στο σύνολο των δοκιμών, ως εξής :

Πίνακας 11. 2 Μέγεθος της Βάσης κανόνων των μοντέλων διαχωρισμού

DFNN	Rules
FCst	2
FCnst	7
CCst	5
CCnst	4
SQst	4
SQnst	5

Πίνακας 11. 3 Δομικές παράμετροι δοκιμών μοντέλων διαχωρισμού ήχων

α/α Δοκιμής	Filter (St-Nst)	Ou	Oy1	Oy2	Oy3	N_hid
1	<i>FCst</i>	2	2	4	4	2
	<i>FCnst</i>	2	2	4	4	3
	<i>CCst</i>	2	2	2	2	3
	<i>CCnst</i>	1	1	2	2	3
	<i>SQst</i>	1	1	1	1	3
	<i>SQnst</i>	2	2	4	4	3
2	Σύνολο των μοντέλων	1	0	0	0	3
3	Σύνολο των μοντέλων	1	0	0	0	4

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

4	Σύνολο των μοντέλων	1	0	0	0	6
5	Σύνολο των μοντέλων	0	0	0	1	3
6	Σύνολο των μοντέλων	0	0	0	1	6
7	Σύνολο των μοντέλων	1	0	0	1	3
8	Σύνολο των μοντέλων	1	0	0	1	6
9	Σύνολο των μοντέλων	0	1	0	0	3
10	Σύνολο των μοντέλων	0	1	0	0	6
11	Σύνολο των μοντέλων	1	1	0	0	3
12	Σύνολο των μοντέλων	1	2	0	0	3
13	Σύνολο των μοντέλων	1	2	0	0	6
14	Σύνολο των μοντέλων	0	0	1	0	3
15	Σύνολο των μοντέλων	0	0	1	0	6

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

16	Σύνολο των μοντέλων	1	0	1	0	3
17	Σύνολο των μοντέλων	1	0	2	0	3
18	Σύνολο των μοντέλων	1	0	2	0	6
19	Σύνολο των μοντέλων	0	1	0	0	4
20	Σύνολο των μοντέλων	0	0	1	0	4
21	Σύνολο των μοντέλων	0	2	1	0	4
22	Σύνολο των μοντέλων	0	1	2	0	4
23	Σύνολο των μοντέλων	0	2	2	0	4
24	Σύνολο των μοντέλων	1	2	2	0	4
25	Σύνολο των μοντέλων	1	2	1	1	4
26	Σύνολο των μοντέλων	1	1	2	1	4
27	Σύνολο των μοντέλων	1	1	0	0	4

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

28	Σύνολο των μοντέλων	1	0	1	0	4
29	Σύνολο των μοντέλων	1	2	1	0	4
30	Σύνολο των μοντέλων	1	1	2	0	4
31	Σύνολο των μοντέλων	0	2	2	1	4
32	Σύνολο των μοντέλων	1	2	2	1	4
33	Σύνολο των μοντέλων	0	2	2	0	6
34	Σύνολο των μοντέλων	1	2	2	0	6
35	Σύνολο των μοντέλων	1	2	2	1	6

Πίνακας 11. 4 Υπολογιστικό κόστος του φίλτρου DFNN

Εργασία	LUT	ADD	MULT
Συναρτήσεις συμμετοχής μ_{λ_i}	r	0	0
Βαθμοί εκπλήρωσης κανόνα μ_j	0	0	0
Κανονικοποιημένοι βαθμοί εκπλήρωσης κανόνα	0	r^2	r
Έξοδοι κανόνων	$r(Ou+Oy_1+Oy_2+Oy_3)$	$r(4+Ou+Oy_1+Oy_2+H Oy_3)$	$r(4+Ou+Oy_1+Oy_2+H Oy_3)$
Αποασαφοποίηση	0	r	r
Σύνολο	$r(1+Ou+Oy_1+Oy_2+Oy_3)$	$r(5+r+Ou+Oy_1+Oy_2+H Oy_3)$	$r(2+Ou+Oy_1+Oy_2+H Oy_3)$

LUT: Λειτουργίες Look-up table, ADD: Αριθμός αθροίσεων, MULT: Αριθμός πολλαπλασιασμών, r: αριθμός κανόνων, H: αριθμός νευρώνων στο κρυφό στρώμα του τμήματος απόδοσης.

Το υπολογιστικό κόστος ανά δείγμα εξόδου για το DFNN παρουσιάζεται στον πίνακα 11.5. Το κόστος πρακτικά εξαρτάται από τον αριθμό των πολλαπλασιασμών, καθώς ο απαιτούμενος χρόνος για προσθέσεις και look-up table λειτουργίες είναι αμελητέος συγκριτικά με τον απαιτούμενο χρόνο για πολλαπλασιασμούς. Από τον συνδυασμό των πινάκων 11.3, 11.4 και 11.5 συμπεραίνεται ότι τα μοντέλα για τα μη-στάσιμα μέρη στις περιπτώσεις των λεπτών τριζόντων (FCnst) και «κακαρισμάτων» (SQnst) απαιτούν περισσότερους πολλαπλασιασμούς, 154 και 110 αντίστοιχα. Ο αριθμός των πολλαπλασιασμών όλων των άλλων μοντέλων ποικίλει από 6 έως 91. Θεωρώντας ότι η περίοδος δειμγατοληψίας ήταν 0.4 ms, είναι σαφές ότι υλοποίηση σε πραγματικό χρόνο είναι εφικτή είτε με χρήση κοινού προσωπικού υπολογιστή, είτε με χρήση εξειδικευμένου συστήματος.

11.2 Εξαγωγή αποτελεσμάτων και επεξεργασία

Σε κάθε δοκιμή παράγονταν ή ενημερώνονταν αρχεία δεδομένων (.dat), όπως - επί παραδείγματι και κατά αντιστοιχία- αρχεία εξέλιξης σφάλματος εκπαίδευσης του μοντέλου ανά εποχή ή αρχεία καταγραφής της τελικής τιμής σφάλματος εκπαίδευσης της εκάστοτε δοκιμής.

Ακολουθούν πίνακες με την καταγραφή του σφάλματος RMSE (Root Mean Square Error – Ρίζα Μέσου Τετραγωνικού Σφάλματος) κατά τη χιλιοστή εποχή

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

εκπαίδευσης του εκάστοτε νευρωνικού δικτύου, ανά κατηγορία ήχου και του μετασχηματισμού Z – score ανά δοκιμή. Τα δεδομένα συλλέχθηκαν από τα αρχεία δεδομένων που παρήγαγε η πλατφόρμα κατά τη διαδικασία δοκιμών. Σε κάθε περίπτωση εξάγονται μεταδεδομένα μέσω στατιστικής ανάλυσης.

Πίνακας 11. 5 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - FCst


Μοντέλο FCst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,05549	-1,16254
2	0,05616	-0,75497
3	0,05618	-0,74338
4	0,05619	-0,73545
5	0,06033	1,78560
6	0,06046	1,86858
7	0,05892	0,92654
8	0,05947	1,26516
9	0,05852	0,68554
10	0,05878	0,84295
11	0,05639	-0,61708
12	0,05608	-0,80439
13	0,05612	-0,78182
14	0,06039	1,82770
15	0,05815	0,45735
16	0,05573	-1,01855
17	0,05556	-1,12105
18	0,05565	-1,06858
19	0,05874	0,81977
20	0,05812	0,44149
21	0,05688	-0,31812
22	0,05690	-0,30470

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

23	0,05692	-0,29067
24	0,05563	-1,08139
25	0,05877	0,83441
26	0,05560	-1,09543
27	0,05617	-0,75070
28	0,05575	-1,00818
29	0,05563	-1,07834
30	0,05549	-1,16254
31	0,05804	0,39024
32	0,05886	0,89176
33	0,05928	1,14497
34	0,05873	0,80940
35	0,05888	0,90641

Πίνακας 11. 6 Στατιστικά μεγέθη RMSE μοντέλου FCst

RMSE - FCst	
Μέση τιμή	0,05740
Μέγιστο	0,06046
Ελάχιστο	0,05549
Τυπική απόκλιση	0,00164



Σχήμα 11. 2 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (FCst)

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας 11. 7 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - FCnst


Μοντέλο FCnst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,05296	-2,90768
2	0,05799	0,95242
3	0,05798	0,94169
4	0,05798	0,94552
5	0,05784	0,83436
6	0,05795	0,91793
7	0,05687	0,09224
8	0,05706	0,23790
9	0,05781	0,81519
10	0,05788	0,87116
11	0,05652	-0,17762
12	0,05582	-0,70891
13	0,05601	-0,56632
14	0,05767	0,70403
15	0,05792	0,90183
16	0,05722	0,36287
17	0,05703	0,21644
18	0,05718	0,32990
19	0,05786	0,84893
20	0,05792	0,89493
21	0,05804	0,99382
22	0,05762	0,66800
23	0,05782	0,82516
24	0,05555	-0,91591
25	0,05444	-1,77073
26	0,05494	-1,38664
27	0,05652	-0,17532
28	0,05730	0,42420

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

29	0,05584	-0,69358
30	0,05594	-0,61922
31	0,05674	-0,00589
32	0,05445	-1,75846
33	0,05731	0,42803
34	0,05563	-0,86071
35	0,05458	-1,65956

Πίνακας 11. 8 Στατιστικά μεγέθη RMSE μοντέλου FCnst

RMSE - FCnst	
Μέση τιμή	0,05675
Μέγιστο	0,05804
Ελάχιστο	0,05296
Τυπική απόκλιση	0,00130



Σχήμα 11. 3 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (FCnst)

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας 11. 9 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - CCst

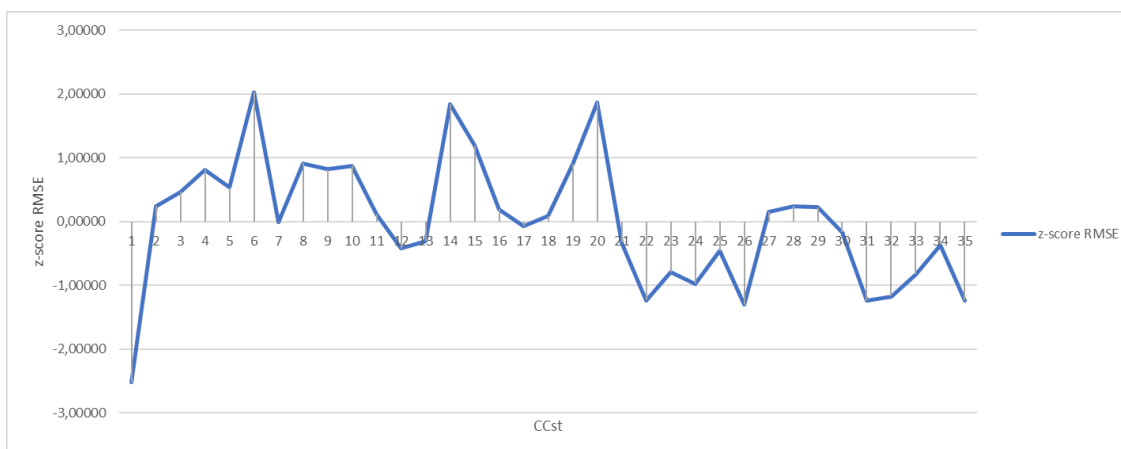
Μοντέλο CCst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,06666	-2,52520
2	0,06918	0,24173
3	0,06938	0,46291
4	0,06970	0,81329
5	0,06945	0,53518
6	0,07081	2,02649
7	0,06895	-0,01339
8	0,06980	0,91293
9	0,06971	0,81548
10	0,06976	0,87242
11	0,06906	0,11034
12	0,06858	-0,42290
13	0,06868	-0,31231
14	0,07065	1,84473
15	0,07005	1,18886
16	0,06914	0,19246
17	0,06889	-0,07471
18	0,06904	0,08625
19	0,06978	0,89870
20	0,07067	1,86663
21	0,06866	-0,33092
22	0,06783	-1,23973
23	0,06824	-0,79409
24	0,06807	-0,97913
25	0,06854	-0,46232
26	0,06777	-1,30324
27	0,06910	0,15523
28	0,06918	0,23735

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

29	0,06916	0,21874
30	0,06881	-0,16668
31	0,06783	-1,24082
32	0,06789	-1,17841
33	0,06821	-0,82693
34	0,06862	-0,36925
35	0,06783	-1,23973

Πίνακας 11. 10 Στατιστικά μεγέθη RMSE μοντέλου CCst

RMSE - CCst	
Μέση τιμή	0,06896
Μέγιστο	0,07081
Ελάχιστο	0,06666
Τυπική απόκλιση	0,00091



Σχήμα 11. 4 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (CCst)

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας 11. 11 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - CCnst


Μοντέλο CCnst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,07322	-1,79739
2	0,07480	0,92233
3	0,07480	0,92750
4	0,07482	0,95680
5	0,07482	0,95680
6	0,07481	0,93267
7	0,07467	0,68966
8	0,07439	0,21741
9	0,07477	0,87407
10	0,07481	0,94474
11	0,07466	0,67414
12	0,07417	-0,17211
13	0,07406	-0,34963
14	0,07474	0,81375
15	0,07478	0,88441
16	0,07438	0,20535
17	0,07383	-0,74259
18	0,07436	0,16570
19	0,07481	0,93440
20	0,07474	0,81375
21	0,07418	-0,14798
22	0,07468	0,71206
23	0,07457	0,52420
24	0,07378	-0,84428
25	0,07407	-0,33239
26	0,07324	-1,76119
27	0,07454	0,46904
28	0,07432	0,09504

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

29	0,07418	-0,15142
30	0,07351	-1,30618
31	0,07420	-0,11006
32	0,07267	-2,75222
33	0,07411	-0,26345
34	0,07385	-0,72363
35	0,07295	-2,25929

Πίνακας 11. 12 Στατιστικά μεγέθη RMSE μοντέλου CCnst

RMSE - CCnst	
Μέση τιμή	0,07426
Μέγιστο	0,07482
Ελάχιστο	0,07267
Τυπική απόκλιση	0,00058



Σχήμα 11. 5 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (CCnst)

Πίνακας 11. 13 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - SQst

Μοντέλο SQst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,06786	-0,14895
2	0,07184	1,29813
3	0,07186	1,30541


Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

4	0,07192	1,32614
5	0,07193	1,33086
6	0,07194	1,33195
7	0,06944	0,42566
8	0,06948	0,43875
9	0,07183	1,29304
10	0,07184	1,29704
11	0,06577	-0,90941
12	0,06767	-0,21914
13	0,06881	0,19691
14	0,07130	1,09956
15	0,07055	0,82753
16	0,06759	-0,24787
17	0,06725	-0,37153
18	0,06844	0,06198
19	0,07030	0,73734
20	0,07129	1,09774
21	0,06975	0,53695
22	0,06809	-0,06785
23	0,06723	-0,38098
24	0,06384	-1,61095
25	0,06376	-1,64295
26	0,06675	-0,55555
27	0,06588	-0,87050
28	0,06773	-0,19769
29	0,06434	-1,43129
30	0,06478	-1,26873
31	0,06756	-0,26024
32	0,06343	-1,76151
33	0,06774	-0,19441
34	0,06444	-1,39565
35	0,06533	-1,06979

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

Πίνακας 11. 14 Στατιστικά μεγέθη RMSE μοντέλου SQst

RMSE - SQst	
Μέση τιμή	0,06827
Μέγιστο	0,07194
Ελάχιστο	0,06343
Τυπική απόκλιση	0,00275



Σχήμα 11. 6 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (SQst)

Πίνακας 11. 15 Τελικό σφάλμα RMSE ανά δοκιμή και το αντίστοιχο Z-score - SQst

Μοντέλο SQst		
α/α Δοκιμής	RMSE_trn	Z - score
1	0,06267	-3,41423
2	0,07135	1,06855
3	0,07137	1,07577
4	0,07137	1,07887
5	0,07097	0,87037
6	0,07139	1,08609
7	0,06808	-0,61907
8	0,06862	-0,34400
9	0,07135	1,06493
10	0,07135	1,06751


Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.

11	0,07044	0,59839
12	0,06796	-0,68462
13	0,06817	-0,57417
14	0,07140	1,09332
15	0,07118	0,97771
16	0,07059	0,67167
17	0,06945	0,08591
18	0,06917	-0,05705
19	0,07135	1,06855
20	0,07135	1,06493
21	0,06872	-0,29187
22	0,06907	-0,11072
23	0,06866	-0,32335
24	0,06818	-0,56747
25	0,06733	-1,00976
26	0,06656	-1,40508
27	0,07056	0,65929
28	0,07055	0,65361
29	0,06798	-0,67326
30	0,06780	-0,76668
31	0,06861	-0,34967
32	0,06702	-1,17078
33	0,06829	-0,51224
34	0,06842	-0,44825
35	0,06761	-0,86319

Πίνακας 11. 16 Στατιστικά μεγέθη RMSE μοντέλου SQnst

RMSE - SQnst	
Μέση τιμή	0,06928
Μέγιστο	0,07140
Ελάχιστο	0,06267
Τυπική απόκλιση	0,00194

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.



Σχήμα 11. 7 Γράφημα μετασχηματισμού Z-score του σφάλματος RMSE (SQst)

Πίνακας 11. 17 Ποσοστά δοκιμών ανά z-score

	Αριθμός δοκιμών ανά z-score							
	1 SD	%	1.5 SD	%	2 SD	%	3 SD	%
FCst	21	60,00%	11	31,43%	3	8,57%	0	0,0%
FCnst	30	85,71%	1	2,86%	3	8,57%	1	2,86%
CCst	25	71,43%	6	17,14%	2	5,71%	2	5,71%
CCnst	30	85,71%	1	2,86%	2	5,71%	2	5,71%
SQst	19	54,29%	13	37,14%	3	8,57%	0	0,0%
SQnst*	22	62,86%	12	34,29%	0	0,0%	0	0,0%

* Μία δοκιμή παρουσίασε z-score με απόκλιση πάνω από 3 SD (2,86%)

Πίνακας 11. 18 Δομικές παράμετροι για το μοντέλο με βέλτιστο RMSE

Μοντέλο	Κανόνες	O_u	O_{y_1}	O_{y_2}	O_{y_3}	H
FCst	2	2	2	4	4	2
FCnst	7	2	2	4	4	3
CCst	5	2	2	2	2	3
CCnst	4	1	2	2	1	4
SQst	4	1	2	2	1	4
SQnst	5	2	2	4	4	3

Πίνακας 11. 19 Δομικές παράμετροι για το μοντέλο με βέλτιστο Μέγιστο Απόλυτο Σφάλμα

Model	Rules	O_u	O_{y_1}	O_{y_2}	O_{y_3}	H
FCst	2	0	2	2	0	6
FCnst	7	1	1	2	1	4
CCst	5	2	2	2	2	3
CCnst	4	1	1	0	0	3
SQst	4	0	1	2	0	4
SQnst	5	0	0	0	1	6

Πίνακας 11. 20 Συνολικός ρυθμός ανίχνευσης για κάθε κατηγορία ήχου

	WTST-NST	FST-NST (στατικόμοντέλο)	Προτεινόμενο (δυναμικό μοντέλο)
FC	100	92.82	96.63
CC	97.5	95.68	98.18
SQ	100	94.46	100

11.3 Ανάλυση αποτελεσμάτων

Κατά τη διαδικασία εκπαίδευσης επετεύχθησαν ικανοποιητικές τιμές σφάλματος RMSE οι οποίες -για τις δομές των μοντέλων που επιλέξαμε- κυμάνθηκαν από 0,05675 έως 0,07426 οι οποίες αντιστοιχούν κατά σειρά στα μοντέλα διαχωρισμού μη-στάσιμων ήχων FCnst και CCnst. Η τυπική απόκλιση σφάλματος στο σύνολο των δοκιμών, ανά μοντέλο διαχωρισμού, αναδεικνύει τη χαμηλή διασπορά των τιμών και κυμαίνεται από 0,00058 έως 0,00275. Οι συγκεκριμένες οριακές τιμές αντιστοιχούν στις περιπτώσεις των μοντέλων διαχωρισμού ήχου CCnst και SQst. Για να έχουμε καλύτερη εικόνα των μεγεθών απόκλισης σε σχέση με τη μέση τιμή, η ποσοστιαία διακύμανση αυτών είναι της τάξης του 0,78% έως και 4,03% με τις συγκεκριμένες ακραίες ποσοτώσεις να αντιστοιχούν κατά σειρά στις δύο

κατηγορίες που προαναφέραμε. Για να έχουμε την καλύτερη δυνατή εικόνα για την ποιότητα και αποτελεσματικότητα του αλγόριθμου εκπαίδευσης χρησιμοποιήσαμε στα αποτελέσματα σφάλματος RMSE που παρήχθησαν, τον μετασχηματισμό z-score ο οποίος είναι μία αξιόπιστη μέθοδος σύγκρισης αποτελεσμάτων που προέρχονται από ετερογενή μεταξύ τους σύνολα. Ο μετασχηματισμός z-score υπολογίζεται ως εξής: $z_i = \frac{x_i - \bar{x}}{S}$ όπου x_i είναι το στοιχείο που ελέγχεται \bar{x} είναι η μέση τιμή του συνόλου και S η τυπική απόκλιση.


Με το συγκεκριμένο μέτρο, υπολογίζεται η απόκλιση της εκάστοτε τιμής σε τυπικές αποκλίσεις από την μέση τιμή του συνόλου στο οποίο ανήκει η τιμή που ελέγχεται. Τα αποτελέσματα ανέδειξαν την υψηλή ευρωστία του αλγόριθμου, καθώς στη συντριπτική πλειοψηφία των περιπτώσεων παρουσίασε χαμηλές αποκλίσεις με τιμές 1 ή 1,5 τυπικών αποκλίσεων (Standard Deviations). Πιο συγκεκριμένα σε ποσοστό 54,29% έως 85,71% τα αποτελέσματα σφάλματος των δοκιμών που εκπονήθηκαν ανά μοντέλο, παρουσίασαν απόκλιση μίας τυπικής απόκλισης. Αντίστοιχα για z – score 1,5 τυπικής απόκλισης τα ποσοστά διακυμάνθηκαν από 2,86% έως 37,14%, με τις εναπομείναντες περιπτώσεις χαμηλής ποσόστωσης να διαχέονται σε υψηλότερες τιμές απόκλισης.

Ενδεικτικά αποτελέσματα της εφαρμογής του φίλτρου στα τρία είδη των διακοπτόμενων επιπρόσθετων αναπνευστικών ήχων (λεπτούς/τραχείς τρίζοντες και «κακαρίσματα») απεικονίζονται στα σχήματα 11.8, 11.9, 11.10, όπου «ενθόρυβοι» ηχογραφημένοι κυψελιδικοί ήχοι, διαχωρισμένοι επιπρόσθετοί ήχοι και «καθαροί» κυψελιδικοί ήχοι παρουσιάζονται για κάθε περίπτωση στα (α), (β) και (γ), αντίστοιχα. Η χρονική θέση των αναγνωρισμένων από το γιατρό DAS σημειώνεται με βέλη, ορίζοντας τα σημεία σύγκρισης της μη στάσιμης εξόδου του φίλτρου με τους πραγματικούς διακοπτόμενους επιπρόσθετους αναπνευστικούς ήχους στο αρχικό σήμα εισόδου. Με αυτόν τον τρόπο γίνεται άμεσα ένας ποιοτικός έλεγχος του διαχωρισμού των DAS από τους κυψελιδικούς ήχους.


Στο σχήμα 11.8(α) απεικονίζεται ένα τμήμα (C2-1024 δείγματα) από λεπτούς τρίζοντες, ηχογραφημένο από έναν ασθενή με πνευμονική ίνωση. Στο σχήμα αυτό γίνεται φανερός ο μη στάσιμος χαρακτήρας των ήχων FC και η μικρή διάρκειά τους στο χρόνο, αφού επικάθονται στους στάσιμους κυψελιδικούς ήχους μικρού πλάτους. Τα αποτελέσματα της εφαρμογής του φίλτρου στο συγκεκριμένο σήμα παρουσιάζονται στα σχήματα 11.8(β), 11.8 (γ). Συγκρίνοντας το μη στάσιμο μέρος

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.


του σχήματος 11.8(α) με το σχήμα 11.8(β), καθίσταται προφανές ότι και οι επτά τρίζοντες έχουν αναγνωρισθεί. Επίσης, στο σχήμα 11.8(β) όλα τα δομικά στοιχεία των DAS είναι εύκολα αναγνωρίσιμα, και τα μορφολογικά τους στοιχεία αλλά και η χρονική τοποθέτησή τους διακρίνονται καθαρά. Επιπλέον, το στάσιμο μέρος του σήματος εισόδου, δηλαδή ο VS, αναπαράγεται πλήρως στο σχήμα 11.8(γ), διατηρώντας το αυθεντικό πλάτος και δομή του.



(α)



(β)



(γ)

(α) Ένα χρονικό τμήμα από 0.4096 sec με λεπτούς τρίζοντες DAS, ηχογραφημένο από έναν ασθενή με πνευμονική ίνωση (περίπτωση C2), θεωρούμενο ως σήμα εισόδου του φίλτρου.


(β) Η μη στάσιμη έξοδος του φίλτρου.

(γ) Η στάσιμη έξοδος του φίλτρου.


Τα βέλη προσδιορίζουν τις θέσεις των οπτικά αναγνωρίσιμων DAS.

Σχήμα 11. 8 Λεπτοί τρίζοντες (FC)


Ένα χρονικό τμήμα ήχου CC (C7-2048 δείγματα), ηχογραφημένο από ασθενή με χρόνια βρογχίτιδα, απεικονίζεται στο σχήμα 11.9(α). Παρόλο που τα σήματα των CC διαφέρουν από τους FC, τόσο στη δομή και στη μορφή τους όσο και στην ομοιομορφία επανάληψής τους, η απόδοση του φίλτρου παραμένει σε υψηλά επίπεδα. Αυτό γίνεται φανερό από το σχήμα 11.9(β), όπου στη μη στάσιμη έξοδο οι πραγματικές θέσεις των CC έχουν ανιχνευθεί επακριβώς, μαζί με το πλάτος τους, τη χρονική διάρκεια και τη μορφολογία τους.



(α)



(β)



(γ)

(α) Ένα χρονικό τμήμα από 0.8192 sec με τραχείς τρίζοντες DAS, ηχογραφημένο από έναν ασθενή με χρόνια βρογχίτιδα (περίπτωση C7), θεωρούμενο ως σήμα εισόδου του φίλτρου.

(β) Η μη στάσιμη έξοδος του φίλτρου.

(γ) Η στάσιμη έξοδος του φίλτρου.


Τα βέλη προσδιορίζουν τις θέσεις των οπτικά αναγνωρίσιμων DAS.

Σχήμα 11. 9 Τραχείς τρίζοντες (CC)


Ένα χρονικό τμήμα από ήχους SQ (C12-1024 δείγματα), ηχογραφημένο από ασθενή με διάμεση ίνωση, απεικονίζεται στο Σχήμα 11.10(α). Οι δύο ήχοι SQ, που

Αναπαράσταση ασαφών συστημάτων Takagi-Sugeno-Kang υψηλής τάξης και αποσύνθεση σε συστήματα πρώτης τάξης. Εφαρμογή σε φίλτρο διαχωρισμού πνευμονικών ήχων.


περιλαμβάνονται σε αυτή την εικόνα, αναδεικνύουν τα δύο βασικά χαρακτηριστικά του «κακαρίσματος», την ύπαρξη ενός λεπτού τρίζοντος (στις χρονικές στιγμές που υποδηλώνονται από τα βέλη του σχήματος) ακολουθούμενου από έναν συριγμό μικρής διάρκειας, με σχεδόν εκθετική απόσβεση. Τα χαρακτηριστικά αυτά είναι σαφώς αναγνωρίσιμα στη μη στάσιμη έξοδο του φίλτρου, όπως φαίνεται στο Σχήμα 11.10(β). Οι αυθεντικοί κυψελιδικοί ήχοι του σήματος εισόδου διαχωρίζονται και αναπαράγονται πλήρως στη μη στάσιμη έξοδο του φίλτρου, που απεικονίζεται στο Σχήμα 11.10 (γ).



(α)



(β)



(γ)

(α) Ένα χρονικό τμήμα από κακάρισμα μήκους 0.4096 sec, ηχογραφημένο από έναν ασθενή με διάμεση ίνωση (περίπτωση C12), θεωρούμενο ως σήμα εισόδου του φίλτρου.


(β) Η μη στάσιμη έξοδος του φίλτρου.

(γ) Η στάσιμη έξοδος του φίλτρου.


Τα βέλη προσδιορίζουν τις θέσεις των οπτικά αναγνωρίσιμων DAS.

Σχήμα 11. 10 «Κακάρισματα» (SQ)

Στο σχήμα 11.11 αναδεικνύεται η ποιότητα μοντελοποίησης του αναδρομικού νευροασαφούς μοντέλου. Στο σχήμα 11.11(α) παρουσιάζεται η εκτίμηση του στάσιμου τμήματος σε ένα χρονικό τμήμα 50 msec. Καθίσταται φανερό ότι το εκτιμώμενο σήμα ακολουθεί πιστά Όπως φαίνεται η έξοδος του φίλτρου ακολουθεί πιστά το ίχνος του πραγματικού VS. Στο σχήμα 11.11(β) παρουσιάζεται ένα χρονικό τμήμα 12 msec από την ίδια περίπτωση, που αντιστοιχεί σε τραχύ τρίζοντα. Είναι προφανές ότι το μοντέλο έχει ανιχνεύσει αποτελεσματικά την ύπαρξη και τη μορφή του τρίζοντος, σε ό,τι αφορά τα χαρακτηριστικά IDW και 2CD.



(α)



(β)

Συνεχής γραμμή: (α) Πραγματικό σήμα Διακεκομμένη γραμμή: Εκτιμώμενο σήμα

(α) Ένα χρονικό τμήμα 50 msec κυψελιδικών ήχων, μαζί με την εκτίμηση του στάσιμου τμήματος του φίλτρου.

(β) Ένα χρονικό τμήμα 12 msec τραχέως τρίζοντος, μαζί με την εκτίμηση του στάσιμου τμήματος του φίλτρου.

Σχήμα 11. 11 Απεικόνιση ποιότητας μοντελοποίησης DFNN

Πίνακας 11. 21 Ποσοστά διαχωρισμού και επιτευχθέντα RMSE ανά ασθενή

Ασθενής	DAS	Διάγνωση	N	N_E / N_R	D_R (%)	$RMSE_{ST}$	$RMSE_{NST}$
C1	FC	PF	2048	18/18	100	0.04244	0.03821
C2	FC	PF	1024	7/7	100	0.04789	0.04661
C3	FC	PF	1024	8/9	88.88	0.05515	0.05242
C4	FC	PF	1024	9/9	100	0.03595	0.03901
C5	FC	PF	1024	10/11	90.90	0.04451	0.04327
C6	FC	IF	2048	19/19	100	0.06330	0.06018
C7	CC	CB	2048	7/7	100	0.04519	0.04382
C8	CC	CB	2048	7/7	100	0.05246	0.05276
C9	CC	CB	1024	8/8	100	0.07478	0.06211
C10	CC	CB	1024	8/8	100	0.08390	0.09600
C11	CC	CB	1024	10/11	90.90	0.06913	0.08147
C12	SQ	IF	1024	2/2	100	0.05638	0.05492
C13	SQ	IF	1024	4/4	100	0.06348	0.06199
C14	SQ	IF	1024	5/5	100	0.08397	0.08142
C15	SQ	AA	1024	6/6	100	0.06037	0.06569
C16	SQ	AA	2048	26/26	100	0.05236	0.05103

- PF: Πνευμονική Ίνωση (Pulmonary Fibrosis)
- IF: Διάμεση Ίνωση (Interstitial Fibrosis)
- CB: Χρόνια Βρογχίτιδα (Chronic Bronchitis)
- AA: Αλλεργική Κυψελίτιδα (Allergic Alveolitis)
- N : Αριθμός δειγμάτων
- $RMSE_{ST} / RMSE_{NST}$: Τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος για την εκτιμώμενη στατική/μη στατική έξοδο του φίλτρου.
- N_R : Αριθμός των οπτικά αναγνωρίσιμων DAS από γιατρό (θεωρούμενος ως ο αντικειμενικά αποδεκτός αριθμός των διακοπτόμενων επιπρόσθετων αναπνευστικών ήχων)
- N_E : ρυθμός των εκτιμώμενων DAS από το φίλτρο
- D_R : Ρυθμός ανίχνευσης (Rate of detectability) του φίλτρου

Ο ρυθμός ανίχνευσης :

$$D_R = \left(1 - \frac{N_R - N_E}{N_R}\right) \cdot 100\% , \text{ όπου } N_E \text{ είναι ο αριθμός των εκτιμώμενων DAS και } N_R$$

είναι ο αριθμός των οπτικά αναγνωρισμένων DAS από έναν γιατρό (θεωρείται ο πραγματικός αριθμός DAS στο σήμα εισόδου).

Η ρίζα μέσου τετραγωνικού σφάλματος :

$$RMSE = \frac{1}{k_f} \sum_{k=1}^{k_f} [y(k) - \hat{y}(k)]^2 \text{ όπου } y(k) \text{ είναι η έξοδος του DFNN (στάσιμο ή μη-}$$

στάσιμο) του k -th δείγματος, $\hat{y}(k)$ είναι η αντίστοιχη πραγματική έξοδος και k_f είναι ο αριθμός των δειγμάτων.

Θα πρέπει να σημειωθεί ότι οι τιμές του RMSE δεν παρουσιάζουν πάντα καλά αποτελέσματα διαχωρισμού καθώς δεν επικεντρώνονται στις συγκεκριμένες λεπτομέρειες του σήματος για τις οποίες ενδιαφέρεται ο γιατρός. Σκοπός τους είναι μόνο να παρέχουν μία ένδειξη της ποιότητας της επίτευξης των επιθυμητών σχέσεων εισόδου-εξόδου. Τα αποτελέσματα (Πίνακα 11.21) δείχνουν ότι το φίλτρο DFNN παρουσίασε υψηλή απόδοση. Πιο συγκεκριμένα ο ρυθμός ανίχνευσης του φίλτρου κυμάνθηκε από 88.88% έως 100% ανά περίπτωση, με μέσο όρο ρυθμού ανίχνευσης για όλες τις περιπτώσεις στο 96.16%

11.4 Συμπεράσματα

Ένα στάσιμο – μη στάσιμο φίλτρο διαχωρισμού που συνδυάζει δύο DFNN's, εκπαιδευμένο με τον αλγόριθμο εκμάθησης SA – DRPROP, έχει εφαρμοστεί για τον διαχωρισμό του DAS από τον VS. Το σχήμα έχει αξιολογηθεί σε προταξινομημένους DAS, δηλαδή τραχείς και λεπτούς τρίζοντες επιπρόσθετους αναπνευστικούς ήχους (fine/coarse crackles), καθώς και σε «κακαρίσματα» (squawks), επιλεγμένοι από τρεις βάσεις δεδομένων πνευμονικών ήχων. Από τα αποτελέσματα των πειραμάτων και τα μεταδεδομένα που εκπονήθηκαν από τη στατιστική ανάλυση των αποτελεσμάτων, συνάγεται το συμπέρασμα ότι το φίλτρο DFNN εκτελεί πολύ αποτελεσματικά τον διαχωρισμό των DAS από τους VS παρά τις διαφορές στον δομικό τους χαρακτήρα και είναι ικανό να πραγματοποιεί διαχωρισμό σε πραγματικό χρόνο. Ως εκ τούτου το προτεινόμενο φίλτρο μπορεί να χρησιμοποιηθεί ως αντικειμενική μέθοδος για ανάλυση DAS σε πραγματικό χρόνο.

12. ΒΙΒΛΙΟΓΡΑΦΙΑ

1. Π. Μαστοροκόστας, «Θεωρήματα της ασαφούς λογικής – προχωρημένες πράξεις ασαφών συνόλων», ΣΕΑΒ, Αθήνα, 2015.
2. L.A. Zadeh, "Fuzzy Sets," *Information and Control*, vol. 8, pp. 338-353, 1965.
3. L.A. Zadeh, "The concept of Linguistic Variable and its Application to Approximate Reasoning, Part I," *Information Sciences*, vol. 8, pp. 199-249, 1975.
4. E.H Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, no. 1, pp. 1-13, 1975.
5. T. Takagi and M. Sugeno, "Fuzzy Identification of Systems and Its Applications," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 15, no. 1, pp. 116-132, 1985.
6. X.-J. Zeng and M.G. Singh, "Approximation Accuracy Analysis of Fuzzy Systems as Function Approximators," *IEEE Transactions on Fuzzy Systems, Man, and Cybernetics*, vol. 4, no. 1, pp. 44-63, 1996.
7. C.C. Lee, "Fuzzy Logic in Control Systems: Fuzzy Logic Controller - Part I," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 20, no. 2, pp. 404-418, 1990.
8. R.R. Yager and D.P. Filev, "Unified Structure and Parameter Identification of Fuzzy Models," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 4, pp. 1198-1205, 1993.
9. A. Cohen, "Signal processing methods for upper airway and pulmonary dysfunction diagnosis," *IEEE Engineering in Medicine and Biology Magazine*, pp. 72-75, 1990.
10. R. Loudon and R.L. Murphy, Jr., "Lung Sounds," *Amer. Rev. Respir. Dis.*, vol. 130, pp. 663-673, 1984.
11. S. Lehrer, *Understanding Lung Sounds*. Philadelphia, PA: Saunders, 1993, workbook.
12. Λ.Ι. Χατζηλεοντιάδης, *Ανάλυση και επεξεργασία των αναπνευστικών ήχων με τη χρήση της στατιστικής - φάσματος ανώτερης τάξης και του μετασχηματισμού κυματιδίων*, Διδακτορική διατριβή, Αριστοτέλειο Πανεπιστήμιο, Θεσσαλονίκη 1997.
13. M. Ono, et al., "Separation of fine crackles from vesicular sounds by a nonlinear digital filter," *IEEE Transactions on Biomedical Engineering*, vol. 36, no. 2, pp. 286-291, 1989.
14. R.L. Murphy, Jr., S.K. Holford, and W.C. Knowler, "Visual lung sound characterization by time-expanded waveform analysis," *New England Journal of Medicine*, vol. 296, pp. 968-971, 1977.
15. L.J. Hadjileontiadis and S.M. Panas, "Nonlinear Separation of Crackles and Squawks from Vesicular Sounds using Third-Order Statistics," *Proceedings of the 18th*

International Conference of the IEEE Engineering in Medicine and Biology Society-EMBS'96, cd-rom index 522, 1996.

16. L.J. Hadjileontiadis and S.M. Panas, "Separation of Discontinuous Adventitious Sounds from Vesicular Sounds Using a Wavelet-Based Filter," *IEEE Transactions on Biomedical Engineering*, vol. 44, no. 12, pp. 1269-1281, 1997.
17. Y.A. Toliass, L.J. Hadjileontiadis, and S.M. Panas, "A Fuzzy Rule-Based System for Real-Time Separation of Crackles from Vesicular Sounds," *Proceedings of the 19th International Conference of the IEEE Engineering in Medicine and Biology Society-EMBS'97*, pp. 1115-1118, 1997.
18. W.T. Miller, III, R.S. Sutton, and P.J. Werbos (editors), *Neural Networks for Control*, MIT Press, Cambridge, MA, 1990.
19. K.S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems using Neural Networks," *IEEE Transactions on Neural Networks*, vol. 1, no. 1, pp. 4-27, 1990.
20. P.S. Sastry, G. Santharam, and K.P. Unnikrishnan, "Memory Neuron Networks for Identification and Control of Dynamical Systems," *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 306-319, 1994.
21. P. Frasconi, M. Gori, and G. Soda, "Local Feedback Multilayered Networks," *Neural Computation*, vol. 4, pp. 120-130, 1992.
22. E. Khan, "Recurrent Fuzzy Logic in Speech Recognition," *Proceedings of WESCON*, pp. 602-607, 1995.
23. S.A. Billings and C.F. Fung, "Recurrent Radial Basis Function Networks for Adaptive Noise Cancellation," *Neural Networks*, vol. 8, no. 2, pp. 273-290, 1995.
24. H.T. Su and T.J. McAvoy, "Identification of Chemical Processes Using Recurrent Networks," *Proceedings of American Control Conference*, pp. 2314-2319, 1991.
25. J.J. Hopfield, "Neural networks and physical systems with emergent collective computational capabilities," *Proceedings of the National Academy of Sciences*, vol. 79, pp. 2554-2558, 1982.
26. R.J. Williams and D. Zisper, "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," *Neural Computation*, vol. 1, pp. 270-280, 1989.
27. J.L. Elman, "Finding structures in time," *Cognitive Science*, vol. 14, pp. 179-211, 1990.
28. M.I. Jordan, "Supervised learning and systems with excess degrees of freedom," *COINS Technical report 88-27*, Massachusetts Institute of Technology, 1988.
29. A.C. Tsoi and A.D. Back, "Locally Recurrent Globally Feedforward Networks: A Critical Review of Architectures," *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 229-239, 1994.

30. A.D. Back and A.C. Tsoi, "FIR and IIR Synapses, a New Neural Network Architecture for Time Series Modeling," *Neural Computation*, vol. 3, pp. 375-385, 1991.
31. E.A. Wan, "Temporal Backpropagation for FIR Neural Networks," *Proceedings of 1990 International Joint Conference on Neural Networks*, pp. 575-580.
32. A. Weibel, T. Hanazawa, G. Hinton, K. Shikano, and K.J. Lang, "Phoneme Recognition Using Time-Delay Neural Networks," *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 37, no. 3, pp. 328-339, 1989.
33. P. Poddar and K.P. Unnikrishnan, "Nonlinear prediction of speech signals using memory neuron networks," *Neural Networks for Signal Processing*, IEEE Press, 1991.
34. X. Ye and N.K. Loh, "Dynamic System Identification Using Recurrent Radial Basis Function Network," *Proceedings of American Control Conference*, pp. 2912-2916, 1993.
35. J.-S.R. Jang, "Self-Learning Fuzzy Controllers Based on Temporal Back Propagation," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 714-723, 1992.
36. V. Gorrini and H. Bersini, "Recurrent Fuzzy Systems," *Proceedings of Third IEEE International Conference on Fuzzy Systems*, pp. 193-198, 1994.
37. J. Theocharis and G. Vachtsevanos, "Identification of Discrete-Time Dynamical Systems via Recurrent Fuzzy Models," *Journal of Intelligent and Fuzzy Systems*, vol. 5, is. 3, pp. 167-191, 1997.
38. H. Takagi and I. Hayashi, "Nn-driven fuzzy reasoning," *International Journal of Approximate Reasoning*, vol. 5, no. 3, pp. 191-212, 1991.
39. H. Takagi, N. Suzuki, T. Koda, and Y. Kojima, "Neural Networks Designed on Approximate Reasoning Architecture and their Application," *IEEE Transactions on Neural Networks*, vol. 3, no. 5, pp. 752-759, 1992.
40. R.J. Kuo, P.H. Kohen, and R.T. Kumara, "Neural Network driven fuzzy inference system," *Proceedings of IEEE International Conference on Neural Networks*, pp. 1532-1536, 1994.
41. E. Stefanis, J. Theocharis, and G. Vachtsevanos, "A Hybrid Fuzzy Neural System as a Nonlinear System Identifier," *Proceedings of IEEE Industrial Automation and Control Conference*, pp. 472-478, 1995.
42. N. Imasaki et al., "Elevator group control system tuned by a fuzzy neural network," *Proceedings of IEEE International Conference on Fuzzy Systems*, pp. 1735-1740, 1995.

43. E. Mizutani et al., "Coactive neural networks with adjustable fuzzy membership functions and their applications," *Proceedings of the International Conference on Fuzzy Logic and Neural Networks*, pp. 581-582, 1994.
44. E. Mizutani and J.-S.R. Jang, "Coactive neural fuzzy modeling," *Proceedings of the International Conference on Neural Networks*, pp. 760-765, 1995.
45. B. Srinivasan, U.R. Prasad, and N.J. Rao, "Back Propagation Through Adjoints for the Identification of Nonlinear Dynamic Systems Using Recurrent Neural Models," *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 213-227, 1994.
46. O. Nerrand, P. Roussel-Ragot, L. Personnaz, and G. Dreyfus, "Neural Networks and Nonlinear Adaptive Filtering: Unifying Concepts and New Algorithms," *Neural Computation*, vol. 5, pp. 165-199, 1993.
47. S. Piche, "Steepest Descent Algorithms for Neural Network Controllers and Filters," *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 198-221, 1994.
48. P.J. Werbos, *Beyond Regression: new tools for prediction and analysis in the behavioral sciences*, Ph.D. Thesis, Harvard Univ., Cambridge, MA, 1974.
49. P.J. Werbos, "Backpropagation Through Time: What It Does and How to Do It," *IEEE Proceedings*, vol. 78, no. 2, pp. 1550-1560, 1990.
50. P. Zarchan, "Strategic and tactical missile guidance," *AIAA Publication*, vol. 124, 1990.
51. C. Igel and H. Husken, Empirical evaluation of the improved RPROP learning algorithms, *Neurocomputing*, 50 (2003), 105-123.
52. P.A. Mastorocostas, Resilient back propagation learning algorithm for recurrent fuzzy neural networks, *Electronics Letters*, 40 (2004), 57-58.
53. P.A. Mastorocostas and J.B. Theocharis, A recurrent fuzzy-neural model for dynamic system identification, *IEEE Trans. Systems, Man, and Cybernetics - Part B*, 32 (2002), 176-190.
54. M. Riedmiller and H. Braun, A direct adaptive method for faster backpropagation learning: The RPROP algorithm, *Proc. IEEE IJCNN 1993*, 586-591.
55. N. Treadgold and T. Gedeon, Simulated annealing and weight decay in adaptive learning: The SARPROP algorithm, *IEEE Trans. Neural Networks*, 9 (1998), 662-668.
56. Π. Μαστοροκώστας, *Ανάπτυξη μεθόδων ασαφούς μοντελοποίησης και εφαρμογή σε πραγματικά προβλήματα αναγνώρισης μη γραμμικών συστημάτων*, Διδακτορική διατριβή, Αριστοτέλειο Πανεπιστήμιο, Θεσσαλονίκη 1999.