

Ανοικτό Πανεπιστήμιο Κύπρου

Σχολή Θετικών και Εφαρμοσμένων Επιστημών

Μεταπτυχιακή Διατριβή στα Πληροφοριακά Συστήματα



**CARENNET – Εξαγωγή Κανόνων Αιτιότητας από Νευρωνικά
Δίκτυα**

Ανδρέας Παυλίδης

**Επιβλέπων Καθηγητής
Λοΐζος Μιχαήλ**

Σεπτέμβριος 2013

Ανοικτό Πανεπιστήμιο Κύπρου

Σχολή Θετικών και Εφαρμοσμένων Επιστημών
CARENNET – Εξαγωγή Κανόνων Αιτιότητας από Νευρωνικά
Δίκτυα

Ανδρέας Παυλίδης

Επιβλέπων Καθηγητής
Λοΐζος Μιχαήλ

Η παρούσα μεταπτυχιακή διατριβή υποβλήθηκε
προς μερική εκπλήρωση των απαιτήσεων για απόκτηση

μεταπτυχιακού τίτλου σπουδών
στα Πληροφοριακά Συστήματα

από τη Σχολή Θετικών και Εφαρμοσμένων Επιστημών
του Ανοικτού Πανεπιστημίου Κύπρου

Αύγουστος 2013

Περίληψη

Η χρησιμότητα και η διάδοση των νευρωνικών δικτύων σήμερα θεωρείται δεδομένη. Πρόκειται για μηχανισμούς που μπορεί να χρησιμοποιηθούν, μεταξύ άλλων, και ως μηχανές λήψης αποφάσεων. Ωστόσο, ο τρόπος με τον οποίο ένα νευρωνικό δίκτυο μπορεί να λάβει αποφάσεις παραμένει ένα «μαύρο κουτί» αγνοώντας ουσιαστικά τη μαθηματική λογική. Το χαρακτηριστικό αυτό αποτελεί μειονέκτημα και λόγο αποφυγής χρήσης των νευρωνικών δικτύων σε κάποιους κρίσιμους τομείς, επειδή δεν επιτρέπει στους χρήστες να ελέγξουν τη λογική με την οποία ένα νευρωνικό δίκτυο κατέληξε να λάβει συγκεκριμένες αποφάσεις.

Στο πλαίσιο της παρούσας μεταπτυχιακής διατριβής αναπτύχθηκε και εφαρμόστηκε, με την υλοποίηση του αντίστοιχου λογισμικού, η πειραματική διαδικασία CARENNET (Causal Rules Extraction from Neural Networks) για να διερευνηθεί η επίδραση συγκεκριμένων παραμέτρων, καθώς και νέων τεχνικών στην κατασκευή ποιοτικών νευρωνικών δικτύων συγκεκριμένης δομής, στην εξαγωγή ποιοτικών κανόνων αιτιότητας από αυτά, καθώς και στη σχέση της ποιότητας μεταξύ των δύο.

Από τα αποτελέσματα φάνηκε ότι η ποιότητα των εξαγόμενων ομάδων κανόνων αιτιότητας είναι άμεσα συνδεδεμένη με αυτήν των νευρωνικών δικτύων από τα οποία προκύπτουν, καθώς και ότι η ποιότητα των νευρωνικών δικτύων είναι αντιστρόφως ανάλογη του αριθμού των στοιβάδων που αυτά χρησιμοποιούν. Κάποιες από τις πρωτοδοκιμαζόμενες τεχνικές φάνηκε πως δεν έχουν να προσφέρουν κάτι ιδιαίτερο για το συγκεκριμένο σκοπό, ενώ η χρήση κόμβων ανά τιμή δυαδικών μεταβλητών φάνηκε να επηρεάζει θετικά την ποιότητα των νευρωνικών δικτύων.

Summary

The usefulness and proliferation of neural networks today are taken for granted. These mechanisms can be used, among others, for decision-making machines. However, the way in which a neural network can make decisions remains a "black box", ignoring essentially the mathematical logic. This feature is considered a disadvantage, especially in some critical areas, because it prohibits users to control the logic by which a neural network came to certain decisions.

In the context of this thesis the experimental procedure CARENNET (Causal Rules Extraction from Neural Networks) was developed and implemented with the development and utilisation of the corresponding software, to investigate the effect of specific parameters and of some new techniques in the construction of quality neural networks of certain architecture, in the extraction of quality causal rules, and in the relationship of the qualities between the two.

The results showed that the quality of exported causal rules groups is directly related to that of neural networks from which they arise, and that the quality of the neural network is inversely proportional to the number of layers they use. Some of the first-tried techniques seemed they have nothing special to offer to this purpose, while the use of nodes per value of binary variables appears to have a positive impact on the quality of neural networks.

Ευχαριστίες

Θα ήθελα εδώ να ευχαριστήσω την εταιρία BETA CAE Systems SA που μου έδωσε την ευκαιρία να εκπαιδευτώ και να εργαστώ ως προγραμματιστής, καθώς και όλους μου τους συναδέλφους που με βοήθησαν με τις γνώσεις και την υπομονή τους σε αυτό το ταξίδι.

Θα ήθελα επίσης να ευχαριστήσω τον επιβλέποντα καθηγητή κ. Λοΐζο Μιχαήλ για την εμπιστοσύνη, τη βοήθεια και την άψογη συνεργασία που έδειξε κατά την εκπόνηση αυτής της διατριβής.

Περιεχόμενα

Περίληψη.....	ii
Summary	iii
Ευχαριστίες.....	iv
1. Εισαγωγή.....	3
1.1 Τεχνητή Νοημοσύνη και Συλλογισμός.....	3
1.2 Αιτιότητα και κανόνες αιτιότητας	5
1.3 Ιστορία και εξέλιξη των νευρωνικών δικτύων	6
1.4 Στόχοι της μεταπτυχιακής διατριβής.....	7
1.5 Διάρθρωση κειμένου.....	8
2. Εξαγωγή κανόνων από νευρωνικά δίκτυα	9
2.1 Τι είναι τα νευρωνικά δίκτυα	9
2.1.1 Η διαδικασία εκπαίδευσης.....	12
2.1.2 Η διαδικασία ελέγχου.....	13
2.2 Η ανάγκη εξαγωγής κανόνων.....	14
2.3 Τεχνικές εξαγωγής κανόνων.....	14
2.3.1 Κατηγοριοποίηση τεχνικών	15
2.3.2 Συνοπτική παρουσίαση ενδεικτικών τεχνικών	17
2.4 Η τεχνική COMBO.....	22
3. Η πειραματική διαδικασία CARENNET.....	26
3.1 Περιγραφή	26
3.2 Συνοπτική περιγραφή της εφαρμογής.....	32
3.3 Αλγόριθμοι και επιλογές.....	34
3.3.1 Τυχαία επιλογή.....	34
3.3.2 Πεδίο Ορισμού (Domain).....	35
3.3.3 Αρχικές καταστάσεις και Συλλογισμός (Reasoning)	36
3.3.4 Νευρωνικό δίκτυο	38
3.3.5 Κόμβοι ανά τιμή μεταβλητής (Nodes per variable state)	40
3.3.6 Συμμετρικοποίηση βαρών	41
3.3.7 Εκτέλεση και αξιολόγηση εξαχθέντων κανόνων	44
3.4 Παράδειγμα εκτέλεσης	47
4. Σχεδιασμός και εκτέλεση πειραμάτων	52
4.1 Τιμές σταθερών παραμέτρων	52

4.1.1	Πεδίο Ορισμού και αρχικές καταστάσεις.....	53
4.1.2	Νευρωνικό δίκτυο	54
4.2	Παράμετροι προς διερεύνηση	54
4.2.1	Παράμετροι Συλλογισμού	54
4.2.2	Παράμετροι νευρωνικού δικτύου	55
4.2.3	Παράμετροι εξαγωγής κανόνων.....	57
4.3	Πειραματική διάταξη και παραγόμενα αρχεία.....	58
4.4	Αυτοματοποιημένη εκτέλεση και αντιμετώπιση προβλημάτων.....	60
5.	Αποτελέσματα.....	63
5.1	Νευρωνικά δίκτυα.....	63
5.2	Εξαγωγή κανόνων αιτιότητας.....	81
6.	Συμπεράσματα.....	94
	Βιβλιογραφία.....	98

Κεφάλαιο 1

Εισαγωγή

Στο κεφάλαιο αυτό εισάγουμε τον αναγνώστη σε βασικές έννοιες των κανόνων αιτιότητας, καθώς και μια σύντομη αναφορά στην ιστορία της εξέλιξης των νευρωνικών δικτύων και στις εφαρμογές που αυτά βρίσκουν σήμερα, ώστε να μπορέσει να κατανοήσει στη συνέχεια το σκοπό της παρούσας μεταπτυχιακής διατριβής και να την παρακολουθήσει με άνεση στο σύνολό της. Αναφέρονται ακόμα οι στόχοι της παρούσας διατριβής καθώς και πως αυτή θα διαρθρωθεί στα επόμενα κεφάλαια.

1.1 Τεχνητή Νοημοσύνη και Συλλογισμός

Πρωτεργάτης στην έρευνα γύρω από την τεχνητή νοημοσύνη, καθώς και πατέρας του όρου ήταν ο John McCarthy. Με τον όρο Τεχνητή Νοημοσύνη εννοούμε την τεχνολογία και τον κλάδο εκείνο της επιστήμης των υπολογιστών που μελετά και αναπτύσσει "έξυπνους" πράκτορες για να τους εντάξει σε μηχανές και λογισμικά. Οι έξυπνοι πράκτορες είναι συστήματα που μπορούν να αντιλαμβάνονται το περιβάλλον τους και να ενεργούν με γνώμονα τη μεγιστοποίηση της

επιτυχίας τους (Artificial intelligence). Ένας τρόπος για να το πετύχουν αυτό είναι **με την απόκτηση και χρήση γνώσης**.

Τι είναι όμως η γνώση; Πρόκειται για μια έννοια που απασχόλησε και συνεχίζει να απασχολεί τους φιλοσόφους από την αρχαιότητα έως και σήμερα. Με τον όρο γνώση, τουλάχιστον στο πεδίο της τεχνητής νοημοσύνης, αναφερόμαστε στη σχέση ενός υποκειμένου με κάποια πρόταση, δηλαδή με κάποια αφηρημένη οντότητα που μπορεί να είναι αληθής ή ψευδής (Brachman & Levesque, 2004). Για παράδειγμα "Ο Νίκος γνωρίζει ότι το αυτοκίνητό του είναι κόκκινο". Εδώ ο Νίκος, ως υποκείμενο, γνωρίζει ότι η πρόταση "το αυτοκίνητό του είναι κόκκινο" είναι αληθής. Ωστόσο, ενδέχεται να μη γνωρίζουμε αν μια πρόταση είναι πραγματικά αληθής ή ψευδής. Για παράδειγμα, στην πρόταση "Ο Νίκος πιστεύει ότι το απόγευμα θα βρέξει", δεν ξέρουμε αν η πρόταση είναι αληθής ή ψευδής, δηλαδή αν πραγματικά θα βρέξει το απόγευμα ή όχι. Αυτό που μας ενδιαφέρει, όμως, είναι ότι ο Νίκος, ως υποκείμενο (ή πράκτορας, όπως είναι ο όρος που χρησιμοποιείται) πιστεύει ότι η πρόταση είναι αληθής.

Η αντίληψη της γνώσης ως σύνολα προτάσεων που μπορεί να είναι αληθή ή ψευδή σύμφωνα με κάποιον πράκτορα αποτελεί την ουσία της **Προτασιακής Λογικής**. Εξέλιξη αυτής αποτελεί η **Πρωτοβάθμια Λογική**, η οποία δύναται να χρησιμοποιήσει ποσοτικά σύμβολα και ποσοτικοποιημένες μεταβλητές.

Το πεδίο μελέτης που χρησιμοποιεί συγκεκριμένα σύμβολα για να αναπαραστήσει μια συλλογή προτάσεων τις οποίες ένας πράκτορας γνωρίζει ή πιστεύει ότι γνωρίζει, ονομάζεται **Αναπαράσταση Γνώσης**. Ο John McCarthy ήταν πιθανότατα ο πρώτος που υποστήριξε τη χρήση της Αναπαράστασης Γνώσης ως τη βάση του αυτόματου συλλογισμού σε συστήματα τεχνητής νοημοσύνης. Υποστήριξε, επίσης, ότι η χρήση της πρωτοβάθμιας λογικής είναι αρκετή για την αναπαράσταση γνώσης.

Με τον όρο **Συλλογισμό** εννοούμε τη διαχείριση και το μετασχηματισμό συμβόλων που αναπαριστούν ένα σύνολο προτάσεων, πιστευτών από κάποιον πράκτορα, με σκοπό την ανακάλυψη και αναπαράσταση **νέων προτάσεων**. Με άλλα λόγια, μέσω του συλλογισμού ένας πράκτορας μπορεί να αποκτήσει νέες γνώσεις, τις οποίες και θα μπορέσει να χρησιμοποιήσει στο μέλλον με σκοπό να προσαρμοστεί ακόμη καλύτερα στο περιβάλλον του και να μεγιστοποιήσει την επιτυχία του, που είναι και το ζητούμενο.

1.2 Αιτιότητα και κανόνες αιτιότητας

Θεμέλιο λίθο του συλλογισμού αποτελεί η **Αιτιότητα**. Η αιτιότητα στον συλλογισμό είναι κοινή τόσο στην επιστημονική όσο και στην καθημερινή σκέψη. Για να πειστεί κάποιος για το παραπάνω αρκεί να διαβάσει ένα άρθρο, επιστημονικό ή μη, καταμετρώντας "όρους αιτιότητας", δηλαδή ρήματα και εκφράσεις όπως "το A οδηγεί στο B", "το A θα προκαλέσει το B", "το A θα αποτρέψει το B", "το A θα ενεργοποιήσει το B" κ.ο.κ. (Shoham, 1990). Είναι ακόμα γνωστή η ρήση του Hume για την αιτιότητα: αποτελεί το «τσιμέντο» του σύμπαντος και έχει τεράστια επίδραση σε τομείς όπως η μάθηση, ο έλεγχος και η αναγνώριση (Sun, 1994).

Αυτό που εννοεί ο Hume είναι ότι μεταξύ των **γεγονότων**, τα οποία αποτελούν τις βασικές οντότητες του κόσμου υπάρχουν συνδέσεις αιτιότητας. Κάποια από αυτά τα γεγονότα αποτελούν **αιτίες** και κάποια **αποτελέσματα**. Ωστόσο, οι αιτίες από μόνες τους δεν μπορούν να εγγυηθούν ένα συγκεκριμένο αποτέλεσμα. Χρειάζονται και οι ικανές συνθήκες. Η θεωρία των συνδέσεων αιτιότητας μεταξύ γεγονότων αποτελείται από **ένα σύνολο καταστάσεων αιτιότητας** (causal statements) που περιγράφουν τη σχέση μεταξύ αιτιών και αποτελεσμάτων. Αυτές οι καταστάσεις αιτιότητας δομούνται σε κανόνες.

Ανακεφαλαιώνοντας, λοιπόν, με τον όρο «κανόνες αιτιότητας» εννοούμε κανόνες που ερμηνεύουν τη **δημιουργία** ενός γεγονότος ή ενός συνόλου γεγονότων ως αποτέλεσμα της **ύπαρξης** ενός ή περισσότερων γεγονότων. Με άλλα λόγια, βλέπουν την ύπαρξη ενός ή περισσότερων γεγονότων ως αιτία της δημιουργίας κάποιου άλλου. Αυτή η θεώρηση **είναι αναπόσπαστη από την έννοια του χρόνου**, διότι αν ένα γεγονός B προκύπτει ως αιτία ενός γεγονότος A, συνεπάγεται ότι το γεγονός A ήδη υπάρχει. Οι μεταβλητές, λοιπόν, που συμμετέχουν στα δύο μέρη ενός κανόνα αιτιότητας (κεφαλή και σώμα) **παρατηρούνται σε διαφορετικές στιγμές**. Αυτή είναι και η ειδοποιός διαφορά με τους **κανόνες συσχέτισης** όπου η έννοια του χρόνου είναι αδιάφορη, αφού οι μεταβλητές εκεί παρατηρούνται την ίδια στιγμή (Karimi & Hamilton, 2001).

Παραδείγματα:

- **Κανόνας αιτιότητας:** «Αν έχει συννεφιά, Τότε θα βρέξει»
- **Κανόνας συσχέτισης:** «Αν ο ασθενής εμφανίζει τα συμπτώματα A, B, Γ, Τότε πάσχει από την ασθένεια Δ»

1.3 Ιστορία και εξέλιξη των νευρωνικών δικτύων

Η εποχή των νευρωνικών δικτύων ξεκίνησε το 1943 με την επαναστατική εργασία των McCulloch και Pitts στην οποία περιγράφεται ένας λογισμός που ενοποιεί μελέτες νευροφυσιολογίας και μαθηματικών (Haykin, 1999). Στην εργασία αυτή συνέλαβαν την ιδέα του υπολογιστικού νευρώνα με μια απλούστερη μορφή. Συγκεκριμένα θεώρησαν ότι οι μόνες αποδεκτές τιμές εισόδου και εξόδου ήταν δυαδικές, δηλαδή αληθές ή ψευδές. Κατάφεραν, όμως, να δείξουν ότι με έναν ικανοποιητικό αριθμό τέτοιων νευρώνων και κατάλληλες συνδέσεις μεταξύ τους (συνάψεις) θα ήταν δυνατός ο υπολογισμός οποιασδήποτε συνάρτησης. Η προοπτική αυτή, άκρως επαναστατική και ενδιαφέρουσα, αποτέλεσε αφετηρία για περαιτέρω διερεύνηση, καθώς και έμπνευση για άλλα, συναφή πεδία και δραστηριότητες, με χαρακτηριστικότερο εκείνο του σχεδιασμού και της κατασκευής του ENIAC, του πρώτου υπολογιστή γενικής χρήσης από τον Neumann.

Έκτοτε, οι δομές αυτές εξελίχθηκαν και τροφοδότησαν περισσότερες έρευνες και ανάπτυξη σε διάφορους τομείς, μέχρι τη δεκαετία του 1970, οπότε χάθηκε προσωρινά το ενδιαφέρον της επιστημονικής κοινότητας, λόγω της εργασίας των Minsky και Papert (1969), οι οποίοι έδειξαν με μαθηματικό τρόπο ότι υπάρχουν περιορισμοί στο εύρος των συναρτήσεων που μπορούν να υπολογιστούν από νευρωνικά δίκτυα μονής στοιβάδας, στα οποία είχε εστιαστεί η έρευνα μέχρι τότε. Χαρακτηριστικό παράδειγμα στην εργασία τους αποτέλεσε η συνάρτηση που χρησιμοποιεί μια λογική πύλη XOR, η οποία είναι αδύνατο να αναπαρασταθεί από ένα νευρωνικό δίκτυο μονής στοιβάδας.

Οι λύσεις σε τέτοιου είδους προβλήματα δόθηκαν μέσα στη δεκαετία του 1980, οπότε και αναζωπυρώθηκε το ενδιαφέρον της επιστημονικής κοινότητας για τα νευρωνικά δίκτυα **και τις μαθησιακές τους δυνατότητες**. Συγκεκριμένα, το 1983 οι Barton, Sutton και Anderson δημοσίευσαν το άρθρο τους “Reinforcement learning”, ενώ το 1986 οι Rumelhart, Hinton και Williams πρότειναν τον αλγόριθμο της οπισθόδρομης διάδοσης (back-propagation) αν και εκ των υστέρων ανακαλύφθηκε ότι η αρχική του σύλληψη είχε γίνει από τα τέλη της δεκαετίας του 1960.

Η αναγέννηση των νευρωνικών δικτύων τη δεκαετία του 1980 θεωρείται ότι οφείλεται στην τεράστια επιρροή που άσκησαν τόσο το άρθρο του Hopfield (1982), όσο και το δίτομο βιβλίο των Rumelhart και McClelland (1986). Σήμερα πια, τα νευρωνικά δίκτυα έχουν καταξιωθεί στη συνείδηση της επιστημονικής κοινότητας ως ένα διατομεακό αντικείμενο με βαθιές ρίζες στις

νευροεπιστήμες, την ψυχολογία, τα μαθηματικά, τις φυσικές επιστήμες και τη μηχανική που έχει να παρουσιάσει μια πληθώρα εφαρμογών και ένα ατελείωτο πεδίο διερεύνησης.

Τα νευρωνικά δίκτυα έχουν ήδη εφαρμοστεί επιτυχώς σε πολλούς τομείς και βιομηχανίες. Η χρήση τους αφορά κυρίως σε αναγνώριση προτύπων ή τάσεων μέσα σε σύνολα δεδομένων και γ' αυτό μπορούν να καλύψουν ανάγκες πρόβλεψης ή αναγνώρισης, όπως σε: προβλέψεις πωλήσεων, έρευνες αγορών, βιομηχανικές διαδικασίες ελέγχου, επικαιροποίηση δεδομένων, διαχείριση κινδύνου, αναγνώριση φωνής, χειρόγραφου κειμένου, προσώπων κλπ. Τα νευρωνικά δίκτυα συνεισφέρουν, επίσης, σημαντικά και σε άλλα ερευνητικά πεδία, όπως η νευρολογία και ψυχολογία, αφού χρησιμοποιούνται συνήθως στη μοντελοποίηση μερών ζωντανών οργανισμών και στη διερεύνηση των εσωτερικών μηχανισμών του εγκεφάλου.

1.4 Στόχοι της μεταπτυχιακής διατριβής

Όπως ειπώθηκε και προηγουμένως, τα νευρωνικά δίκτυα πληρούν τις προδιαγραφές ενός έξυπνου πράκτορα, αφού μπορούν να αντιλαμβάνονται το περιβάλλον τους και να εκπαιδεύονται ώστε οι αποφάσεις ή ενέργειες που λαμβάνουν να είναι οι βέλτιστες κάθε φορά. Αποτελούν, επομένως δομές τεχνητής νοημοσύνης ή μπορούν να συμμετέχουν στο σχεδιασμό και τη λειτουργία μηχανών ή λογισμικών τεχνητής νοημοσύνης. Από τη μέχρι τώρα συζήτηση, όμως, φάνηκε ότι η λειτουργία τους δε βασίζεται σε έναν ξεκάθαρο συλλογισμό, όπως συμβαίνει με άλλες δομές στο πεδίο της τεχνητής νοημοσύνης, αλλά στηρίζεται αποκλειστικά στη ρύθμιση των βαρών τους κατά τη διάρκεια της εκπαίδευσής τους. Με άλλα λόγια, λειτουργούν ως «μαύρα κουτιά», αγνοώντας ουσιαστικά τη μαθηματική λογική, προτασιακή ή πρωτοβάθμια. Ωστόσο, αν ένα νευρωνικό δίκτυο εκπαιδευθεί σωστά με δεδομένα εισόδου και εξόδου που βασίζονται σε κανόνες προτασιακής λογικής, που είναι και απλούστεροι, αναμένουμε τη γνώση αυτή να έχει «ενταχθεί» έμμεσα στο νευρωνικό δίκτυο με τη μορφή βαρών.

Βασικός στόχος της παρούσας μεταπτυχιακής διατριβής είναι να διερευνήσει τη δυνατότητα εξαγωγής κανόνων αιτιότητας προτασιακής λογικής από νευρωνικά δίκτυα συγκεκριμένης δομής, δοκιμάζοντας ένα πλήθος διαφορετικών συνδυασμών και παραμέτρων, ώστε, ύστερα από ανάλυση, να καταλήξει στον βέλτιστο. Για το λόγο αυτόν αναπτύχθηκε και υλοποιήθηκε η πειραματική διαδικασία **CARENNET (Causal Rules Extraction from Neural Networks)**, καθώς και η αντίστοιχη παραθυρική εφαρμογή. Παράλληλα, διερευνάται και ο βέλτιστος συνδυασμός

παραμέτρων και αλγορίθμων που οδηγούν στην ποιοτικότερη εκπαίδευση τέτοιων νευρωνικών δικτύων.

1.5 Διάρθρωση κειμένου

Η παρούσα μεταπτυχιακή διατριβή αναπτύσσεται σε τρία μέρη. Στο πρώτο μέρος (κεφάλαιο 2) γίνεται μια ανασκόπηση της ανάγκης και των τεχνικών εξαγωγής κανόνων συσχέτισης από νευρωνικά δίκτυα.

Στο δεύτερο μέρος (κεφάλαιο 3) παρουσιάζεται η πειραματική διαδικασία CARENNET και εξηγείται πως και γιατί οι εξαγόμενοι κανόνες μπορούν να ερμηνευθούν ως κανόνες αιτιότητας. Στο τρίτο μέρος παρουσιάζονται η σχεδίαση και εκτέλεση των πειραμάτων (κεφάλαιο 4), ενώ ακολουθούν η ανάλυση των αποτελεσμάτων και τα τελικά συμπεράσματα της εργασίας (κεφάλαια 5 και 6).

Κεφάλαιο 2

Εξαγωγή κανόνων από νευρωνικά δίκτυα


Στο κεφάλαιο αυτό παρουσιάζεται συνοπτικά η δομή και ο τρόπος λειτουργίας των νευρωνικών δικτύων, ώστε να γίνουν κατανοητές στη συνέχεια οι διάφορες τεχνικές εξαγωγής κανόνων. Παρουσιάζονται τα κριτήρια κατηγοριοποίησης των τεχνικών εξαγωγής κανόνων, καθώς και κάποιες από τις σημαντικότερες που έχουν επινοηθεί μέχρι σήμερα με σκοπό να αιτιολογηθεί η επιλογή της τεχνικής COMBO στο πλαίσιο της πειραματικής διαδικασίας CARENNET, η οποία εξηγείται με περισσότερη λεπτομέρεια.

2.1 Τι είναι τα νευρωνικά δίκτυα

Τα νευρωνικά δίκτυα είναι υπολογιστικές δομές αποτελούμενες από απλούστερες υπολογιστικές μονάδες, συνδεδεμένες μεταξύ τους, τους νευρώνες, οι οποίοι προσομοιάζουν τη λειτουργία των βιολογικών νευρώνων.

Τα νευρωνικά δίκτυα έχουν την ικανότητα να αποθηκεύουν εμπειρική γνώση και να την παρέχουν προς χρήση, αφού, όπως ο εγκέφαλος, μπορούν να (Haykin S., 1999):

- Αποκτούν γνώση από το περιβάλλον τους μέσω μιας διαδικασίας μάθησης.
- Αποθηκεύουν γνώση μεταβάλλοντας την ισχύ των διανευρωνικών συνδέσεων τους (συνάψεις).




Σχήμα 2.1: Βιολογικός νευρώνας (από <http://www.drugabuse.gov/publications/brain-power/grades-4-5/neurotransmission-module-3/background>)

Για τους λόγους αυτούς τα νευρωνικά δίκτυα αποτελούν ένα είδος έξυπνων πρακτόρων, όπως περιγράφηκαν παραπάνω.

Ένας βιολογικός νευρώνας αποτελείται από τρία δομικά στοιχεία: τους δενδρίτες, οι οποίοι είναι συνδεδεμένοι με άλλους νευρώνες και δέχονται ερεθίσματα από αυτούς, το κυτταρικό σώμα στο οποίο μεταφέρονται τα ερεθίσματα αυτά προς επεξεργασία και τον άξονα ο οποίος μεταφέρει το προϊόν της επεξεργασίας των ερεθισμάτων προς τους άλλους νευρώνες που είναι συνδεδεμένοι σε αυτόν.

Σε αυτό ακριβώς το πρότυπο βασίζεται η δομή ενός υπολογιστικού νευρώνα: Διαθέτει συνδέσεις με άλλους νευρώνες μέσω των οποίων εισάγονται σήματα προς επεξεργασία (δενδρίτες), τη μονάδα επεξεργασίας των σημάτων αυτών (κυτταρικό σώμα) και τις εξόδους του προς άλλους νευρώνες (άξονας). Στο σχήμα που ακολουθεί παρουσιάζεται με μεγαλύτερη λεπτομέρεια η δομή ενός τυπικού υπολογιστικού νευρώνα:



Σχήμα 2.2: Υπολογιστικός νευρώνας (MacLeod, 2010)

Στο σχήμα, οι τιμές εξόδου άλλων νευρώνων (ή οι τιμές εισόδου του νευρωνικού δικτύου) εισάγονται στο νευρώνα (τιμές i) αφού πρώτα ζυγιστούν με κάποιο βάρος w . Τα βάρη αυτά αντιστοιχούν στην ισχύ των βιολογικών συναπτικών συνδέσεων.

Στη συνέχεια, αθροίζονται τα γινόμενα των τιμών εισόδου με τα βάρη τους: $S = \sum_{k=1}^4 i_k w_k$.

Έπειτα, το άθροισμα S ελέγχεται αν είναι μεγαλύτερο ή μικρότερο από κάποιο προκαθορισμένο κατώφλι (threshold), ώστε να αποφασιστεί τελικά η τιμή εξόδου O του νευρώνα. Για παράδειγμα, αν το κατώφλι είναι ίσο με 0.5 (MacLeod, 2010):

- Αν $S > 0.5$ τότε $O = 1$
- Αν $S \leq 0.5$ τότε $O = 0$

Η σύγκριση της τιμής του αθροίσματος με ένα κατώφλι είναι, ουσιαστικά, μια **συνάρτηση εξόδου ή ενεργοποίησης** που δέχεται ως είσοδο το άθροισμα S και επιστρέφει τιμές 0 ή 1. Μετασχηματίζει λοιπόν το άθροισμα σε μια τιμή εξόδου. Στους κόμβους ενός νευρωνικού δικτύου μπορούμε να ορίσουμε και άλλου είδους συναρτήσεις, οι οποίες θα δίνουν μια τιμή μέσα σ' ένα συγκεκριμένο εύρος. Η πλέον δημοφιλής και χρησιμοποιημένη συνάρτηση εξόδου είναι η **σιγμοειδής** ($\varphi(v) = \frac{1}{1+e^{-a(v)}}$) η οποία δίνει τιμές στο εύρος (0,1) (Haykin S., 1999), όπου v θα είναι το άθροισμα των ζυγισμένων τιμών εισόδου, και a η επιθυμητή κλίση της συνάρτησης.

Συνοπτικότερα, λοιπόν, ένας νευρώνας δέχεται κάποιες τιμές εισόδου, τις ζυγίζει σύμφωνα με κάποια βάρη και τροποποιεί το άθροισμα των ζυγισμένων τιμών με κάποια συνάρτηση ενεργοποίησης για να το εξάγει, είτε προς άλλους κόμβους, είτε ως αποτέλεσμα του νευρωνικού δικτύου.

Σε ένα νευρωνικό δίκτυο, οι νευρώνες (ή κόμβοι) είναι οργανωμένοι σε στοιβάδες. Η παραπάνω διαδικασία υπολογισμού της εξόδου ενός νευρώνα γίνεται ταυτόχρονα για όλους τους νευρώνες μιας στοιβάδας. Στη συνέχεια, τα αποτελέσματά τους μεταδίδονται ως τιμές εισόδου στην επόμενη στοιβάδα, ενώ η διαδικασία αυτή επαναλαμβάνεται έως ότου υπολογιστούν οι τιμές εξόδου της τελευταίας στοιβάδας. Ένα νευρωνικό δίκτυο αποτελείται από τουλάχιστον μια στοιβάδα, **τη στοιβάδα εξόδου**, ενώ μπορεί να διαθέτει και έναν αριθμό από ενδιάμεσες **κρυφές** στοιβάδες. Τέλος, για λόγους συμβατότητας, χρησιμοποιείται ο όρος **στοιβάδα**

εισόδου, με τον οποίο αναφερόμαστε συλλογικά στις εισόδους του νευρωνικού δικτύου. Στη στοιβάδα αυτή οι τιμές δεν υπόκεινται σε κάποια επεξεργασία.

2.1.1 Η διαδικασία εκπαίδευσης

Αν η συνάρτηση ενεργοποίησης είναι η ίδια για κάθε νευρώνα (κάτι που αποτελεί συνήθη πρακτική), γίνεται σαφές ότι τα αποτελέσματα ενός νευρωνικού δικτύου για κάποιες τιμές εισόδου θα εξαρτώνται από τα βάρη των συνδέσεων. Η απόκτηση γνώσεων από τα νευρωνικά δίκτυα εκπληρώνεται με την **εκπαίδευσή τους**, μια διαδικασία που στόχο έχει **να μεταβάλλει τα βάρη των συνδέσεων** με τέτοιο τρόπο, ώστε για κάθε σύνολο τιμών εισόδου να δίνουν τα επιθυμητά αποτελέσματα. Η αποθήκευση της γνώσης υλοποιείται με την αποθήκευση και αντιστοίχιση των βαρών στις ίδιες συνδέσεις κάθε φορά που θέλουμε να χρησιμοποιήσουμε το δίκτυο, ενώ αυτά μπορούν να αποτελέσουν και αφετηρία για έναν νέο κύκλο εκπαίδευσης.

Ένας από τους πλέον διαδεδομένους αλγορίθμους εκπαίδευσης είναι αυτός της **οπισθόδρομης διάδοσης (back-propagation)**. Συνοπτικά, τα βήματα της εκπαίδευσης με αυτόν τον αλγόριθμο είναι τα εξής:

- 1 Κατά την έναρξη της εκπαίδευσης αρχικοποιούμε με τυχαίες τιμές τα βάρη κάθε σύνδεσης. Η αρχικοποίηση των τιμών είναι απαραίτητη για τον πρώτο υπολογισμό των αποτελεσμάτων.
- 2 Δίνουμε ως είσοδο στο νευρωνικό δίκτυο ένα σύνολο τιμών για το οποίο γνωρίζουμε τα επιθυμητά αποτελέσματα. Ένα ζεύγος τέτοιων γνωστών τιμών εισόδου και εξόδου ονομάζεται **παράδειγμα**.
- 3 Υπολογίζουμε τις εξόδους των κόμβων της πρώτης στοιβάδας για να τις μεταδώσουμε στους κόμβους της επόμενης. Η διαδικασία επαναλαμβάνεται μέχρι να υπολογιστούν οι τιμές εξόδου της εξωτερικής στοιβάδας.
- 4 Συγκρίνονται οι τιμές εξόδου με τα αντίστοιχα επιθυμητά αποτελέσματα. Υπολογίζεται τόσο το σφάλμα σε κάθε κόμβο εξόδου e_j , όσο και το συνολικό, για όλους τους κόμβους της εξωτερικής στοιβάδας E_n , όπου j είναι ο j -στος κόμβος της στοιβάδας εξόδου και n είναι το n -οστό

- 5 Με χρήση συγκεκριμένων τύπων και βάσει του σφάλματος e_i , υπολογίζουμε τη διαφορά βάρους Δw για κάθε σύνδεση – είσοδο του τρέχοντος κόμβου, την οποία προσθέτουμε στο τρέχον βάρος για να επιτευχθεί η διόρθωση σύμφωνα με το επιθυμητό αποτέλεσμα του κόμβου.
- 6 Επαναλαμβάνουμε τα βήματα 4 και 5 για όλες τις προηγούμενες στοιβάδες, ώσπου να επιτευχθεί η διόρθωση όλων των βαρών του δικτύου.
- 7 Επαναλαμβάνουμε τα βήματα 2 – 6 για όλα τα παραδείγματα εκπαίδευσης
- 8 Με το πέρας των δοκιμών όλων των παραδειγμάτων εκπαίδευσης έχουμε ολοκληρώσει **μια Εποχή (epoch)**. Υπολογίζουμε το μέσο σφάλμα της Εποχής $E_{av} = \frac{1}{N} \sum_{n=1}^N E_n$ όπου N είναι ο συνολικός αριθμός παραδειγμάτων εκπαίδευσης.
- 9 Αν το E_{av} είναι μεγαλύτερο από κάποιο προκαθορισμένο όριο, επαναλαμβάνουμε τα βήματα 2 – 8.

2.1.2 Η διαδικασία ελέγχου

Η εκπαίδευση ενός νευρωνικού δικτύου πρέπει να ακολουθείται και από μια διαδικασία ελέγχου, ενδεικτική του πόσο καλά έχει εκπαιδευτεί το δίκτυο. Αυτό γίνεται συνήθως ακολουθώντας την εξής διαδικασία:

- Από το σύνολο των διαθέσιμων παραδειγμάτων ξεχωρίζουμε ένα υποσύνολο που θα χρησιμοποιηθεί για έλεγχο και που δε θα έχει κανένα παράδειγμα κοινό με το υποσύνολο εκπαίδευσης.
- Δίνουμε ως είσοδο στο νευρωνικό δίκτυο τις τιμές εισόδου ενός παραδείγματος, ώστε να υπολογίσει τα αποτελέσματα με τα «εκπαιδευμένα» πια βάρη στις συνδέσεις του.
- Υπολογίζουμε τις αποκλίσεις των αποτελεσμάτων από τις επιθυμητές τιμές εξόδου του παραδείγματος με τη μετρική που έχουμε επιλέξει.
- Επαναλαμβάνουμε το ίδιο για όλα τα υπόλοιπα παραδείγματα ελέγχου και υπολογίζουμε ένα συνολικό ποσοστό σφάλματος ή επιτυχίας.

2.2 Η ανάγκη εξαγωγής κανόνων

Από τη μέχρι τώρα συζήτηση έχει γίνει κατανοητή η χρησιμότητα των νευρωνικών δικτύων σήμερα, ενώ εντυπωσιάζει η πληθώρα των διαφορετικών επιστημονικών και άλλων πεδίων στα οποία μπορούν να εφαρμοστούν, ή εφαρμόζονται ήδη. Η ευρεία αυτή χρήση τους δεν είναι τυχαία, αφού τα νευρωνικά δίκτυα ως εργαλεία συγκεντρώνουν σημαντικά πλεονεκτήματα (Andrews, Diederich, & Tickle, 1995):

- Αποτελούν έναν άμεσο και ευθύ τρόπο λήψης δεδομένων
- Παρέχουν μια συμπαγή και συνάμα δυναμική αποθήκευση γνώσης
- Δίνουν καλά αποτελέσματα ακόμα και όταν έχουμε θόρυβο στα πρωτογενή δεδομένα

Ωστόσο, το μεγάλο τους μειονέκτημα έναντι άλλων μεθόδων είναι η αδυναμία τους **να εξηγήσουν πως καταλήγουν σε συγκεκριμένες αποφάσεις ή συμπεράσματα**. Το εγγενές αυτό μειονέκτημα τα καθιστά λιγότερο προσφιλή ή και μη αποδεκτά ως λύσεις σε διάφορους τομείς στους οποίους θα μπορούσαν να χρησιμοποιηθούν, όπως σε εφαρμογές που έχουν να κάνουν με ασφάλεια ή διαχείριση κρίσιμων καταστάσεων.

Η προοπτική της εξαγωγής κατανοητών κανόνων από τα βάρη και τη δομή (τοπολογία) των νευρωνικών δικτύων φαντάζει ως ιδανική λύση στο πρόβλημα. Και αυτό γιατί οι εξαγόμενοι κανόνες θα συμπεριελάμβαναν και τα ενδιάμεσα στάδια του «κρυφού συλλογισμού» ενός εκπαιδευμένου νευρωνικού δικτύου τεκμηριώνοντας ικανοποιητικά τα αποτελέσματά τους. Έτσι, οι εξαγόμενοι κανόνες μπορούν να αποτελέσουν ένα εργαλείο ελέγχου της εγκυρότητας των αποτελεσμάτων ενός δικτύου και ταυτόχρονα, ένα εργαλείο ερμηνείας αυτών.

2.3 Τεχνικές εξαγωγής κανόνων

Το 1988 ο Gallant έκανε μια από τις πρώτες απόπειρες να καταστήσει τα νευρωνικά δίκτυα πιο κατανοητά. Στο πλαίσιο αυτής της προσπάθειας συνόδευσε κάθε αποτέλεσμα του δικτύου με έναν κανόνα που συνόψιζε το συλλογισμό βάσει του οποίου προέκυψε το αποτέλεσμα. Γρήγορα, ακολούθησαν πολλοί ερευνητές επικεντρώνοντας κυρίως τις προσπάθειές τους στην εξαγωγή

κανόνων που θα συνόψιζαν την ενσωματωμένη στην αρχιτεκτονική και βάρη ενός νευρωνικού δικτύου γνώση (Muslimi, Capretz, & Samarabandu, 2006).

2.3.1 Κατηγοριοποίηση τεχνικών

Πράγματι, το ενδιαφέρον και οι πρωτοβουλίες της διεθνούς επιστημονικής κοινότητας ήταν τόσο έντονα, ώστε μόλις το 1994 έγινε η πρώτη προσπάθεια κατηγοριοποίησης των ποικίλων τεχνικών πάνω στο ζήτημα από τους Craven και Shavlik, ενώ τον επόμενο χρόνο ακολούθησε μια πιο συστηματική προσέγγιση (Andrews, Diederich, & Tickle, 1995). Αυτή αναγνωρίζει πέντε χαρακτηριστικά στις τεχνικές βάσει των οποίων τις κατηγοριοποιεί, αλλά και τις αξιολογεί:

- 1) **Έκφραση:** Το χαρακτηριστικό αυτό πληροφορεί για το πως θα εκφραστούν οι εξαγόμενοι από μια τεχνική κανόνες. Διακρίνονται δύο κατηγορίες:
 - i) Κανόνες προτασιακής (δυναδικής) λογικής
 - ii) Κανόνες μη – συμβατικής (πιθανολογικής ή ασαφούς) λογικής.
- 2) **Διαφάνεια:** Το χαρακτηριστικό αυτό στοχεύει στο να αποκαλύψει τη σχέση μεταξύ των εξαχθέντων κανόνων και την εσωτερική αρχιτεκτονική των εκπαιδευμένων νευρωνικών δικτύων. Διακρίνονται τέσσερις κατηγορίες:
 - i) **Αποσυνθετικές τεχνικές:** Εστιάζουν στις επιμέρους μονάδες ενός δικτύου (κόμβοι ή νευρώνες) προσπαθώντας να τις ερμηνεύσουν ως επιμέρους κανόνες. Τελικά, αυτοί ενοποιούνται για να συνθέσουν τους κανόνες που διέπουν το δίκτυο.
 - ii) **Συνθετικές τεχνικές:** Εστιάζουν σε σύνολα μονάδων (κόμβων) ενός δικτύου.
 - iii) **Παιδαγωγικές τεχνικές:** Οι τεχνικές αυτές μεταχειρίζονται το νευρωνικό δίκτυο ως «μαύρο κουτί». Η εξαγωγή κανόνων αντιμετωπίζεται ως μια εργασία μάθησης όπου τόσο η προκύπτουσα συνάρτηση που αντιπροσωπεύει το ίδιο το δίκτυο, όσο και τα δεδομένα εισαγωγής του δικτύου αποτελούν τα δεδομένα εισαγωγής της εργασίας. Οι τεχνικές αυτές στοχεύουν ουσιαστικά σε εξαγωγή κανόνων που προσπαθούν να αντιστοιχίσουν άμεσα τις εισόδους σε εξόδους. Χρησιμοποιούνται σε συνδυασμό με αλγόριθμους συμβολικής μάθησης. Ενώ έχουν ενδιαφέρον εκ πρώτης όψης, είναι αρκετά

περιοριστικές ως προς τη δομή του δικτύου στο οποίο θα εφαρμοστούν και αυτό γιατί τα επιμέρους στοιχεία ενός δικτύου (κόμβοι, συνδέσεις και στοιβάδες) δεν αντιπροσωπεύουν συνήθως ξεκάθαρες λογικές οντότητες, με αποτέλεσμα να μην είναι δυνατή συνήθως μια αντιστοιχία ένα προς ένα. Η επιβολή μιας τέτοιας προϋπόθεσης θα απέκλειε τα περισσότερα υπάρχοντα δίκτυα, αφού αυτά κατασκευάστηκαν χωρίς να ληφθεί αυτή η αντιστοιχία υπόψη. Επιπλέον, μια τέτοια προϋπόθεση θα περιόριζε την ανάπτυξη νευρωνικών δικτύων τα στοιχεία των οποίων δεν αντιπροσωπεύουν συγκεκριμένες οντότητες – έννοιες, ενώ σε τέτοιου είδους δίκτυα αποδίδεται συχνά η δυνατότητα γενίκευσης (Thrun, 1995).

iv) **Εκλεκτικές τεχνικές:** Χρησιμοποιούν τη γνώση της αρχιτεκτονικής του εκπαιδευμένου δικτύου ή και τα βάρη του, ώστε να κατασκευάσουν έναν αλγόριθμο συμβολικής μάθησης.

3) **Ανάγκη για εξειδικευμένη εκπαίδευση:** Αποτελεί ουσιαστικά ένα μέτρο της φορητότητας των τεχνικών σε νευρωνικά δίκτυα που μπορεί να υποστηρίξουν διαφορετικές ανάγκες και να έχουν διαφορετική δομή. Συνήθως, συνεπάγεται την ανάγκη τροποποίησης του δικτύου για την εφαρμογή αυτής της τεχνικής.

4) **Ποιότητα εξαγόμενων κανόνων:** Το χαρακτηριστικό αυτό δείχνει πόσο καλοί είναι οι εξαγόμενοι κανόνες, βασιζόμενο σε τέσσερα βασικά κριτήρια – μετρικές:

i) **Ακρίβεια:** Η μετρική αυτή δείχνει κατά πόσο οι εξαγόμενοι κανόνες μπορούν να δώσουν σωστά αποτελέσματα.

ii) **Πιστότητα:** Δείχνει το βαθμό στο οποίο οι κανόνες μπορούν να «μμηθούν» τα αποτελέσματα του δικτύου από το οποίο εξήχθησαν.

iii) **Συνέπεια:** Δείχνει το βαθμό που, υπό διαφορετικές εκπαιδευτικές συνεδρίες του νευρωνικού δικτύου, παράγονται σύνολα κανόνων που οδηγούν σε όμοια αποτελέσματα.

iv) **Κατανόηση:** Μετράει την πολυπλοκότητα των παραγόμενων κανόνων και καθορίζεται από τον αριθμό τόσο αυτών, όσο και των μεταβλητών ανά κανόνα.

- 5) **Αλγοριθμική πολυπλοκότητα της τεχνικής:** Το χαρακτηριστικό αυτό αξιολογεί ουσιαστικά την ίδια τη διαδικασία εξαγωγής κανόνων με κριτήριο την απαίτηση σε χρόνο και πόρους. Πιο συγκεκριμένα, κατά την ανάπτυξη μιας τέτοιας διαδικασίας δίνεται ιδιαίτερη έμφαση στον περιορισμό του μεγέθους του αριθμού των πιθανών λύσεων που θα διερευνηθούν.

2.3.2 Συνοπτική παρουσίαση ενδεικτικών τεχνικών

Όπως ειπώθηκε και προηγουμένως, από τη δεκαετία του 1990 ξεκίνησε η διερεύνηση και ανάπτυξη πολλών και διαφορετικών τεχνικών εξαγωγής κανόνων από νευρωνικά δίκτυα. Εδώ θα παρουσιαστούν συνοπτικά κάποιες ενδεικτικές, ώστε ο αναγνώστης να σχηματίσει μια πιο σφαιρική αντίληψη επί του θέματος.

Η τεχνική RuleNet (McMillan, Mozer, & Smolensky, 1991): Είναι μια αποσυνθετική τεχνική που παράγει κανόνες Προτασιακής Λογικής (Οι συγγραφείς χρησιμοποιούν τον όρο «κανόνες συνθήκης – δράσης).

Πρόκειται για ένα νευρωνικό δίκτυο αποτελούμενο από 3 στοιβάδες (εισόδου, κρυφή με κόμβους που αντιστοιχούν σε συνθήκες, και εξόδου με κόμβους που αντιστοιχούν σε ενέργειες) που μαθαίνει αντιστοιχίες κείμενο – προς – κείμενο μέσα από τις οποίες μπορούν να εξαχθούν κανόνες. Ο αλγόριθμος εκπαίδευσης βασίζεται στην *Επιστημονική Μέθοδο*, δηλαδή παράγει μια υπόθεση ύστερα από παρατήρηση και στη συνέχεια με επαναλήψεις ελέγχει και βελτιώνει την υπόθεση μέχρι αυτή να μπορέσει να εξηγήσει όλες τις παρατηρήσεις. Η επαναληπτική διαδικασία συνεχίζεται έως ότου οι εξαχθέντες κανόνες να μπορούν να χαρακτηρίσουν επαρκώς το Πεδίο Ορισμού. Ο βασικός αλγόριθμος έχει ως εξής:

- 1) Εκπαίδευσε το RuleNet με ένα σύνολο παραδειγμάτων εισόδου/εξόδου.
- 2) Εξήγαγε συμβολικούς κανόνες από τα βάρη των συνδέσεων του RuleNet (ανάπτυξη μιας συγκεκριμένης υπόθεσης).
- 3) Επανείσαγε τους κανόνες στο RuleNet και συνέχισε την εκπαίδευση (έλεγχος υπόθεσης).

Ένα μειονέκτημα της τεχνικής αυτής είναι ότι έχει σχεδιαστεί για την επίλυση πολύ συγκεκριμένων προβλημάτων, αφού το ίδιο το νευρωνικό δίκτυο RuleNet είναι

κατασκευασμένο έτσι, ώστε να μπορεί να εντοπίζει αντιστοιχίες μεταξύ θέσεων χαρακτήρων μέσα σε ένα κείμενο – λέξη.

Validity Interval Analysis (VIA) (Thrun S. B., 1994): Πρόκειται για μια παιδαγωγική μέθοδο. Ο αλγόριθμος χρησιμοποιεί μια διαδικασία κατασκευής και ελέγχου για να εξάγει συμβολικούς κανόνες από οποιοδήποτε ΤΝΔ που χρησιμοποιεί back-propagation.

Η ιδέα - κλειδί αυτής της ανάλυσης βρίσκεται στην προσκόλληση διαστημάτων εγκυρότητας (validity intervals) στο εύρος ενεργοποίησης (activation range) κάθε κόμβου (ή σε ένα υποσύνολο των κόμβων, όπως οι κόμβοι εισόδου και εξόδου). Μέσα σε αυτά τα διαστήματα θα πρέπει να βρίσκονται οι ενεργοποιήσεις του δικτύου. Η VIA ελέγχει αν ένα τέτοιο σύνολο διαστημάτων είναι συνεπές, δηλαδή αν υπάρχει κάποιο σύνολο ενεργοποιήσεων μέσα σε αυτά. Το πετυχαίνει με την επαναληπτική βελτιστοποίηση των διαστημάτων, εξαιρώντας ενεργοποιήσεις που είναι ασυνεπείς με άλλα διαστήματα.

Ορολογία:

- Συνολικός αριθμός κόμβων n του Νευρωνικού Δικτύου.
- x_i είναι η ενεργοποίηση (έξοδος) του κόμβου i . Αν το i είναι κόμβος εισόδου η έξοδος του κόμβου θα είναι ίδια με την είσοδο. Διαφορετικά $x_i = \sigma_i(\text{net}_i)$ (η γνωστή είσοδος της συνάρτησης ενεργοποίησης).
- Τα διαστήματα εγκυρότητας για τις τιμές ενεργοποίησης x_i συμβολίζονται με $[a_i, b_i]$, ενώ αν χρειαστεί τα διαστήματα αυτά μπορούν να μεταφραστούν έτσι, ώστε να αναφέρονται στις τιμές εισόδου (net_i), οπότε θα αναφέρονται ως $[a'_i, b'_i]$.
- Το I είναι ένα σύνολο διαστημάτων εγκυρότητας που αναφέρονται σε όλους τους κόμβους ή σε ένα υποσύνολο αυτών (π.χ. μόνο κόμβους εισόδου και εξόδου).
- Ένα διάνυσμα ενεργοποιήσεων (x_1, \dots, x_n) θεωρείται **αποδεκτό** σε σχέση με το I αν όλες οι ενεργοποιήσεις του διανύσματος βρίσκονται εντός των αντίστοιχων διαστημάτων του I .
- Αντίστοιχα, ένα σύνολο ενεργοποιήσεων I θεωρείται **συνεπές** αν υπάρχει κάποιο αποδεκτό διάνυσμα ενεργοποιήσεων. Διαφορετικά, θεωρείται ασυνεπές.

Αλγόριθμος:

- Το I αρχικοποιείται και με επαναληπτική διαδικασία βελτιστοποιείται (γραμμικός προγραμματισμός) έτσι, ώστε εκείνες οι τιμές ενεργοποίησης που είναι ασυνεπείς με άλλα διαστήματα να εξαιρούνται.

Έστω ένα Νευρωνικό Δίκτυο όπου 2 γειτονικές στοιβάδες είναι πλήρως συνδεδεμένες μεταξύ τους και ότι στο I υπάρχει ένα διάστημα $[a_i, b_i] \subseteq [0,1]$ για κάθε κόμβο Π (σε στοιβάδα που προηγείται) και Ε (σε στοιβάδα που έπεται). Για να εφαρμόσουμε τεχνικές γραμμικού προγραμματισμού θα πρέπει η μη-γραμμικότητα των συναρτήσεων ενεργοποίησης να εξαλειφθεί. Αυτό το πετυχαίνουμε με τη μετάφραση των διαστημάτων $[a_i, b_i]$ σε διαστήματα $[a'_i, b'_i]$, τα οποία εφαρμόζουμε στις εισόδους των συναρτήσεων. Θα πρέπει να ισχύουν τα εξής:

- $\forall k \in \Pi: x_k \geq a_k \wedge x_k \leq b_k$
- $\forall i \in E: \sum_{k \in \Pi} w_{ik}x_k + \theta_i \geq a'_i \wedge \sum_{k \in \Pi} w_{ik}x_k + \theta_i \leq b'_i$
- Τα όρια των διαστημάτων εγκυρότητας μεταβάλλονται τόσο κατά τη φάση προς τα εμπρός, όσο και κατά τη φάση προς τα πίσω. Κατά την προς τα εμπρός φάση τα όρια a_i, b_i για τους κόμβους του Ε μεταβάλλονται ως εξής:

- $\hat{a}_i = \sigma(\hat{a}'_i)$ όπου $\hat{a}'_i = \text{MIN}(\text{net}_i) = \text{MIN}(\sum_{k \in \Pi} w_{ik}x_k + \theta_i)$
- $\hat{b}_i = \sigma(\hat{b}'_i)$ όπου $\hat{b}'_i = \text{MAX}(\text{net}_i) = \text{MAX}(\sum_{k \in \Pi} w_{ik}x_k + \theta_i)$

Αν $\hat{a}_i > a_i$ τότε $a_i = \hat{a}_i$. Ομοίως, αν $\hat{b}_i > b_i$ τότε $b_i = \hat{b}_i$. Δηλαδή ένα όριο μεταβάλλεται μόνο αν το νέο όριο που υπολογίζεται μικραίνει το υφιστάμενο διάστημα εγκυρότητας.

- Στην προς τα πίσω φάση τα όρια a_k, b_k όλων των κόμβων $k \in \Pi$ βελτιστοποιούνται: $\hat{a}_k = \text{MIN}x_k$ και $\hat{b}_k = \text{MAX}(x_k)$

Εν κατακλείδι, στόχος είναι να αναλυθούν διαστήματα I ώστε να ανιχνευθούν ασυνέπειες. Αν ένα I αποδειχθεί ασυνεπές, δεν υπάρχει κάποιο αποδεκτό διάνυσμα ενεργοποίησης στο I.

Εξαγωγή και τύπος κανόνων: Παράγει κανόνες τύπου "Αν ... Τότε ..." (συνεπαγωγές). Έστω ένα Νευρωνικό Δίκτυο με ένα μοναδικό κόμβο εξόδου και ότι τα δεδομένα εισόδου κατηγοριοποιούνται σε μια κλάση K αν και μόνο αν η ενεργοποίηση του κόμβου εξόδου x_{out} είναι μεγαλύτερη από ένα κατώφλι κ .

Η επιβεβαίωση ενός κανόνα γίνεται με το να δείξουμε ότι δεν υπάρχει κάποιο διάνυσμα εισόδου $\vec{x} \in I$ που να εμπίπτει στην αντίθετη κλάση $-K$. Αυτό γίνεται τεχνικά με το να συμπεριλάβουμε στο I το διάστημα $[0, \kappa]$. Αν ο κανόνας είναι σωστός το x_{out} δε θα ανήκει ποτέ στο $[0, \kappa]$. Έτσι, η ανάλυση θα βρει μια ασυνέπεια στο I_{neg} και επομένως ο κανόνας θα πρέπει να ισχύει.

Μειονεκτήματα: Η ανάλυση απαιτεί πολλές επαναλήψεις και γι' αυτό είναι χρονοβόρα. Η γλώσσα περιορίζεται σε κανόνες "Αν ... Τότε...".

Τεχνική αλγορίθμου υποσυνόλων και αλγόριθμος N of M (Towell & Shavlik, 1993):

Προσπαθεί να βρει υποσύνολα των εισερχόμενων βαρών σε έναν κόμβο που να υπερβαίνουν το bias. Έστω ο κόμβος A στον οποίο συνδέονται οι κόμβοι $B(3)$, $\Gamma(3)$, $\Delta(3)$ και $E(-3)$ (σε παρένθεση αναγράφονται τα βάρη των αντίστοιχων συνδέσεων). Εξάγουμε μέχρι β_p υποσύνολα συνδέσεων με θετικά βάρη, το άθροισμα των οποίων είναι μεγαλύτερο από το bias. Για κάθε υποσύνολο του β_p P εξάγουμε έως β_n υποσύνολα συνδέσεων με αρνητικά βάρη το άθροισμα των οποίων είναι μεγαλύτερο από το άθροισμα των βαρών του P μείον το bias. Για κάθε υποσύνολο N του β_n φτιάχνουμε τον κανόνα "Αν P και όχι N τότε (όνομα κόμβου)". Στο παραπάνω παράδειγμα, αν το bias είναι 5, τα τελικά σύνολα είναι $\{B, \Gamma, \Delta\}$, $\{B, \Gamma, -E\}$, $\{B, \Delta, -E\}$, $\{\Gamma, \Delta, -E\}$.

Οι αριθμοί β_p και β_n χρειάζονται για να περιορίσουμε τον αριθμό των εξαχθέντων κανόνων. Έτσι για κάθε κόμβο μπορούν να ανακαλυφθούν έως $\beta_p * \beta_n$ κανόνες. Ωστόσο, οι εξαχθέντες κανόνες τείνουν να κρύψουν σημαντικές δομές των εκπαιδευμένων νευρωνικών δικτύων.

Αλγόριθμος NofM για την εξαγωγή κανόνων:

1. Για κάθε κρυφό κόμβο και κόμβο εξόδου σχημάτισε ομάδες συνδέσεων με παρόμοια βάρη.
2. Σε κάθε σύνδεση μιας ομάδας εξίσωσε το βάρος της με το μέσο όρο των βαρών της ομάδας.

3. Αφαίρεσε εκείνες τις ομάδες που δεν επηρεάζουν σημαντικά αν ο κόμβος θα είναι ενεργός ή όχι.
4. Διατηρώντας όλα τα βάρη σταθερά, βελτιστοποίησε τα biases όλων των κόμβων χρησιμοποιώντας τον αλγόριθμο back-propagation.
5. Σχημάτισε έναν κανόνα ανά κόμβο με βάση το βελτιστοποιημένο bias και τις εναπομείνουσες συνδέσεις.
6. Όπου είναι δυνατό, απλοποίησε του κανόνες ώστε να εξαλειφθούν τα περιττά βάρη και κατώφλια.

Εξαγωγή κανόνα: «Αν N από τα ακόλουθα M γεγονότα είναι αληθή τότε». Θα έχουμε σύζευξη όταν $N=M$ και διάζευξη όταν $N = 1$.

Η τεχνική HERETIC (Iqbal, 2011): Η τεχνική HERETIC (Hierarchical and Eclectic Rule Extraction via Tree Induction and Combination) παράγει **δένδρα απόφασης** ανά κόμβο από τα οποία συμπεραίνει τους κανόνες. Ο αλγόριθμος που χρησιμοποιεί είναι υπολογιστικά γρήγορος και περισσότερο ακριβής από άλλους. Βασίζεται στην παραδοχή ότι ένα δένδρο απόφασης μπορεί να μάθει οποιαδήποτε συνάρτηση (universal approximator) και, αφού και ένα νευρωνικό δίκτυο μαθαίνει ουσιαστικά μια συνάρτηση, η συνάρτηση αυτή μπορεί να προσεγγιστεί από ένα δέντρο απόφασης.

Στο νευρωνικό δίκτυο στο οποίο εφαρμόστηκε, χρησιμοποίησε μόνο σιγμοειδή συνάρτηση, θεωρώντας ότι ο κάθε κόμβος μπορεί να έχει μόνο 2 πιθανές τιμές εξόδου: 0 και 1. Η υπόθεση αυτή οδηγεί σε μειωμένη ακρίβεια η οποία μπορεί να αντιμετωπιστεί με μια 'απότομη' σιγμοειδή συνάρτηση (π.χ. $\alpha = 100$). Για το λόγο αυτόν επιλέγεται πολύ χαμηλός ρυθμός μάθησης (0.002) έτσι, ώστε ο συνολικός ρυθμός μάθησης να είναι αποδεκτός (0.2).

Αλγόριθμος:

- Τα παραδείγματα εκπαίδευσης που χρησιμοποιήθηκαν για την εκπαίδευση του νευρωνικού δικτύου χρησιμοποιούνται ξανά για να δώσουν σύνολα εκπαίδευσης για κάθε κόμβο (είσοδοι - έξοδος για κάθε κόμβο).

- Βάσει αυτών των νέων συνόλων εκπαίδευσης φτιάχνουμε δέντρα απόφασης για κάθε κόμβο.
- Μετατρέπουμε κάθε δέντρο απόφασης σε δύο κανόνες - διαζεύξεις.
- Υποκαθιστούμε αναδρομικά από τους κόμβους εξόδου μέχρι τους κόμβους εισόδου όλους τους εξαχθέντες κανόνες.
- Απλοποιούμε τους κανόνες με τη χρήση κάποιου εργαλείου (π.χ. Logical Minimizer με Espresso algorithm).


Ο αλγόριθμος έχει πολύ υψηλή πιστότητα σε σχέση με άλλους. Φάνηκε επίσης ότι η εξαγωγή ενός μόνο δέντρου απόφασης από το νευρωνικό δίκτυο είναι κάτι που γίνεται με περισσότερο κόπο και συνεισφέρει ελάχιστα (κριτική στην τεχνική TREPAN (Craven & Shavlik, 1996) που δεν αναφέρεται εδώ). Επίσης φαίνεται πως μπορεί να είναι ευκολότερο και αποτελεσματικότερο αντί να εξάγουμε κανόνες απευθείας από το νευρωνικό δίκτυο, να χρησιμοποιούμε δέντρα απόφασης για να τους παράγουμε εύκολα και γρήγορα.

2.4 Η τεχνική COMBO

Η τεχνική COMBO (Krishnan, Sivakumar, & Bhattacharya, 1996) είναι μια από τις πολλές τεχνικές εξαγωγής κανόνων από νευρωνικά δίκτυα που έχουν επινοηθεί και χρησιμοποιηθεί μέχρι σήμερα. Προτιμήθηκε έναντι άλλων καταρχάς λόγω της ευελιξίας της. Η εφαρμογή της, δηλαδή, δεν απαιτεί νευρωνικά δίκτυα συγκεκριμένης δομής, αλλά μόνο δυαδικής μορφής δεδομένα εισαγωγής καθώς και μη αναδρομική λειτουργία (feedforward neural networks). Επιπλέον, οι κανόνες που εξάγει επιδεικνύουν υψηλή ακρίβεια, πιστότητα και κατανοησιμότητα (Tickle, Andrews, Golea, & Diederich, 1998). Τέλος θεωρήθηκε ευκολότερη στην υλοποίησή της σε σχέση με την τεχνική HERETIC.


Έστω το νευρωνικό δίκτυο του σχήματος 2.3 το οποίο αποτελείται από 3 κόμβους εισόδου και 3 κόμβους εξόδου, όλους συνδεδεμένους μεταξύ τους. Οι κόμβοι εισόδου αντιστοιχούν, από πάνω προς τα κάτω, στις 3 δυαδικές μεταβλητές a , b και c .

Η τεχνική COMBO εφαρμόζεται σε κόμβους κρυφής ή εξωτερικής στοιβάδας για να εξαγάγει κανόνες για αυτούς. Για κάθε κόμβο ταξινομούνται τα εισερχόμενα βάρη σε φθίνουσα σειρά και στη συνέχεια κατασκευάζεται ένα δέντρο συνδυασμών των ταξινομημένων αυτών βαρών. Στο σχήμα 2.4 παρουσιάζεται το δέντρο συνδυασμών η δομή του οποίου ισχύει και για τους 3 κόμβους εξόδου (Out1, Out2, Out3) του νευρωνικού δικτύου του σχήματος 2.1. Αυτό που ενδεχομένως να διαφέρει μεταξύ των 3 δέντρων συνδυασμών είναι η αντιστοίχιση των βαρών στους συνδυασμούς του πρώτου επιπέδου και κατ' επέκταση στους



Σχήμα 2.3: Παράδειγμα νευρωνικού δικτύου με 3 εισόδους.

συνδυασμούς των υπόλοιπων επιπέδων. Έστω τα βάρη $w(a-Out1) = 2$, $w(b-Out1) = 3$, $w(c-Out1) = 1$ που εισέρχονται στον κόμβο Out1. Μετά την ταξινόμηση η αντιστοίχιση των βαρών στο δέντρο συνδυασμών θα γίνει ως εξής: 1: $w(b-Out1)$, 2: $w(a-Out1)$, 3: $w(c-Out1)$. Εδώ γίνεται επίσης κατανοητό ότι το κάθε εισερχόμενο βάρος αντιστοιχεί σε μια μεταβλητή.



Σχήμα 2.4: Ένα δέντρο συνδυασμών για κόμβο με 3 εισερχόμενα βάρη.

Οι συνδυασμοί του δέντρου διερευνώνται ξεκινώντας από τον πρώτο συνδυασμό του πρώτου επιπέδου και ελέγχεται αν το άθροισμα των βαρών μαζί με το bias

του νευρώνα είναι μεγαλύτερο από κάποιο όριο (κατώφλι) που έχουμε υπολογίσει για τον νευρώνα. Δηλαδή, θα πρέπει:

$$\sum Wc + bias \text{ του νευρώνα} > \text{Κατώφλι νευρώνα}$$

Το κατώφλι του νευρώνα αρχικοποιείται με 0 και αυξάνεται από την ύπαρξη αρνητικών βαρών. Κάθε εισερχόμενο αρνητικό βάρος μετατρέπεται σε θετικό, ενώ το η νέα τιμή του κατωφλιού T_{new} υπολογίζεται ως εξής: $T_{\text{new}} = T_{\text{old}} - (|w|)$. Ταυτόχρονα, το άτομο της αντίστοιχης μεταβλητής που ενδέχεται να συμμετέχει στον εξαχθέντα κανόνα θα μεταπέσει σε άρνηση ($x \rightarrow \bar{x}$).

Οι συνδυασμοί βαρών που θα περάσουν επιτυχώς τον έλεγχο θα δώσουν τους πρωτεύοντες όρους του κανόνα που θα προκύψει. Οι όροι αυτοί θα αποτελούνται από σύζευξη ατόμων που αντιστοιχούν στις μεταβλητές τα βάρη των οποίων συμμετέχουν στον εκάστοτε συνδυασμό. Ο κανόνας που θα προκύψει θα είναι η διάζευξη των παραπάνω όρων. Για παράδειγμα, έστω ότι περνάνε επιτυχώς οι συνδυασμοί 1 και 23. Δεδομένου ότι τα βάρη του δέντρου συνδυασμών 1,2 και 3 αντιστοιχούν στις μεταβλητές b , a και c , ο κανόνας που θα προκύψει για τον κόμβο Out1 θα είναι $\mathbf{b \vee (a \wedge c)}$. Επειδή στην πειραματική διαδικασία CARENNET αντιστοιχούμε κάθε κόμβο σε μια μεταβλητή, ο Out1 αντιστοιχεί στη μεταβλητή a . Ο κανόνας επομένως μπορεί να εκφραστεί ως $\mathbf{a \leftarrow b \vee (a \wedge c)}$.

Χάρη στη φθίνουσα ταξινόμηση των βαρών μπορούμε να αποκλείσουμε πολλούς συνδυασμούς ως εξής:

- **Συνδυασμοί στο ίδιο επίπεδο:** Αν κάποιος συνδυασμός σε κάποιο επίπεδο αποτύχει τότε μπορεί να αποκλειστεί μαζί με όλους τους υπόλοιπους συνδυασμούς του ίδιου επιπέδου, χάρη στη διάταξη των βαρών σε φθίνουσα σειρά. Π.χ. αν αποτύχει ο συνδυασμός 12 (σχήμα 2.2) μπορούμε να αποκλείσουμε και τους συνδυασμούς 13 και 23 αφού αυτοί θα έχουν εγγυημένα μικρότερο άθροισμα βαρών και θα αποτύχουν στον έλεγχο.
- **Συνδυασμοί σε βαθύτερα επίπεδα του δέντρου:** Αν κάποιος συνδυασμός περάσει τον έλεγχο, τότε δε χρειάζεται να εξετάσουμε και αυτούς για τους οποίους αποτελεί «ρίζα», γιατί ενώ αυτοί θα περάσουν τον έλεγχο, δε θα έχουν να προσφέρουν κάτι στον εξαγόμενο κανόνα. Αντίθετα θα τον εξειδικεύσουν και θα τον κάνουν περισσότερο πολύπλοκο χωρίς λόγο. Π.χ. Αν ο συνδυασμός 1 περάσει τον έλεγχο (σχήμα 2.2), τότε δε χρειάζεται να εξετάσουμε τους συνδυασμούς 12, 13 και 123.

Σημειώνεται εδώ ότι η παραπάνω διαδικασία δίνει κανόνες με κεφαλή σε κατάφαση. Για να πάρουμε κανόνες με την κεφαλή σε άρνηση (αρνητικούς κανόνες) η διαδικασία που ακολουθούμε είναι η ίδια με τις εξής διαφορές:

- Στο πρώτο στάδιο μετατρέπουμε όλα τα βάρη σε αρνητικά. Κάθε θετικό βάρος αφαιρείται από το κατώφλι.
- Στο δεύτερο στάδιο, τα βάρη ταξινομούνται σε αύξουσα σειρά.

- Η εξίσωση ελέγχου για κάθε συνδυασμό του δέντρου συνδυασμών γίνεται $\sum Wc + bias \text{ του νευρώνα} < \text{Κατώφλι νευρώνα}$. Δηλαδή, για να περάσει επιτυχώς ένας συνδυασμός τον έλεγχο, θα πρέπει το άθροισμα των βαρών και του bias να είναι μικρότερο από το υπολογισμένο κατώφλι.

Κεφάλαιο 3

Η πειραματική διαδικασία CARENNET

Στο κεφάλαιο αυτό παρουσιάζεται η πειραματική διαδικασία CARENNET που επινοήθηκε και εφαρμόστηκε στο πλαίσιο της παρούσας μεταπτυχιακής διατριβής για τη μελέτη της εξαγωγής κανόνων αιτιότητας από νευρωνικά δίκτυα. Δίνεται ιδιαίτερη έμφαση στους κομβικούς αλγόριθμους που χρησιμοποιεί, ενώ ακολουθεί μια συνοπτική περιγραφή της εφαρμογής CARENNET που αναπτύχθηκε και χρησιμοποιήθηκε για την επιλογή και διεξαγωγή των πειραμάτων.

3.1 Περιγραφή

Η πειραματική διαδικασία CARENNET στοχεύει στη διερεύνηση της εξαγωγής κανόνων αιτιότητας από νευρωνικά δίκτυα συγκεκριμένης δομής βάσει της ακόλουθης αλληλουχίας ενεργειών:

Αρχικά κατασκευάζεται ένα Πεδίο Ορισμού (Domain), δηλαδή ένα σύνολο τυχαίων μεταβλητών και κανόνων. Τα αποτελέσματα των κανόνων αυτών υπολογίζονται για ένα σύνολο ομάδων αρχικών τιμών των μεταβλητών, ενώ είναι δυνατόν να επανεισαχθούν ως δεδομένα σε ενδεχόμενους επαναληπτικούς υπολογισμούς των ίδιων κανόνων. Με τον τρόπο αυτόν φτιάχνουμε τα **παραδείγματα** τα οποία αποτελούνται από τουλάχιστον 2 ομάδες τιμών των μεταβλητών: τις αρχικές και τελικές τιμές, ενώ μπορεί να υπάρχουν και ενδιάμεσες, ανάλογα με τον αριθμό των επαναλήψεων που υπολογίστηκαν οι κανόνες. Αυτή η αλληλουχία ομάδων τιμών σε κάθε παράδειγμα αντιπροσωπεύει τη μεταβολή των τιμών των μεταβλητών από τη μια χρονική στιγμή στην επόμενη.

Στη συνέχεια, επιλέγονται 2 υποσύνολα παραδειγμάτων ώστε να χρησιμοποιηθούν για την εκπαίδευση και τον έλεγχο του νευρωνικού δικτύου που κατασκευάζεται αμέσως μετά. Το νευρωνικό αυτό δίκτυο έχει μια συγκεκριμένη δομή ενώ υπάρχουν δυνατότητες μερικής παραμετροποίησής του, όπως η συμμετρικοποίηση των βαρών του κατά τη διάρκεια της εκπαίδευσης, ώστε να εξαχθούν συμπεράσματα για τη χρήση διαφορετικών τεχνικών.

Το εκπαιδευμένο πια νευρωνικό δίκτυο δοκιμάζεται με το υποσύνολο παραδειγμάτων ελέγχου, και αξιολογείται η ακρίβειά του ως προς τα αποτελέσματα των αρχικών κανόνων αιτιότητας του Πεδίου Ορισμού, τόσο για τα παραδείγματα εκπαίδευσης, όσο και για τα παραδείγματα ελέγχου.

Τέλος, από τους κόμβους και τα βάρη του εκπαιδευμένου νευρωνικού δικτύου εξάγονται κανόνες αιτιότητας με βάση την τεχνική COMBO (Krishnan, Sivakumar, & Bhattacharya, 1996). Οι εξαχθέντες κανόνες αποτελούνται από μεταβλητές που αντιστοιχούν σε εκείνες του Πεδίου Ορισμού. Αρχικοποιούμε τις μεταβλητές με τις αρχικές τιμές των παραδειγμάτων εκπαίδευσης και ελέγχου και «τρέχουμε» τους κανόνες με διάφορους τρόπους για να πάρουμε τα αποτελέσματα, δηλαδή τις τελικές τιμές των μεταβλητών. Τις τελικές αυτές τιμές τις αξιολογούμε συγκρίνοντάς τες τόσο με τις τελικές τιμές των παραδειγμάτων (ακρίβεια εξαχθέντων κανόνων), όσο και με τις αντίστοιχες τελικές τιμές που υπολογίζονται από το νευρωνικό δίκτυο (πιστότητα εξαχθέντων κανόνων).

Παρακάτω περιγράφονται αναλυτικότερα τα στάδια της πειραματικής διαδικασίας:

1. Κατασκευή του **Πεδίου Ορισμού (Domain)**. Αυτό περιλαμβάνει:

- την κατασκευή συγκεκριμένου αριθμού **δυναμικών μεταβλητών**, βάσει των επιλογών του χρήστη.
- την κατασκευή συγκεκριμένου αριθμού **τυχαίων κανόνων αιτιότητας** με τη χρήση των μεταβλητών, αλλά και των προδιαγραφών που έχει ορίσει ο χρήστης.

Οι κανόνες αυτοί έχουν **ακριβώς 1** άτομο (atom) στην κεφαλή τους και **μια σύζευξη** από έναν τυχαίο (σε προκαθορισμένα πλαίσια όμως) αριθμό ατόμων στο σώμα τους.

Κάθε άτομο εκφράζει μια και μόνο μεταβλητή, **είτε σε άρνηση, είτε σε κατάφαση**.

Κάθε μεταβλητή μπορεί να εμφανιστεί το πολύ 1 φορά στο σώμα ενός κανόνα, ενώ μπορεί να επαναληφθεί στην κεφαλή του.

Παράδειγμα κανόνα: **+a <-- -b Λ +e Λ +k**. Δηλαδή «Αν ΔΕΝ ισχύει το b ΚΑΙ ισχύει το e ΚΑΙ ισχύει το k, τότε θα ισχύσει το a». Η κεφαλή του κανόνα γράφεται στην αρχή για λόγους ευκολότερης ανάγνωσης.

2. Καθορισμός όλων των πιθανών **αρχικών καταστάσεων** των δυναμικών μεταβλητών. Ο μέγιστος αριθμός πιθανών αρχικών καταστάσεων, σε περίπτωση που δεν ισχύουν άλλοι περιορισμοί, θα είναι v^2 , όπου v ο αριθμός των μεταβλητών. Κάθε αρχική κατάσταση τιμών αποτελεί την αφετηρία για ένα **παράδειγμα**, ενώ η αρχική κατάσταση, όπως οι ενδιάμεσες (βλέπε συλλογισμό), αλλά και η τελική κατάσταση τιμών ενός παραδείγματος θα ορίζονται στο εξής ως **ομάδες τιμών**. Σημειώνεται εδώ ότι οι τιμές σε κάθε ομάδα διατάσσονται πάντα με τον ίδιο τρόπο και σύμφωνα με τη διάταξη των μεταβλητών, όπως αυτή προκύπτει με αλφαβητική σειρά.

a	b	c	d	e	f	g	h	i	j
0	0	1	0	0	1	1	1	0	1

Πίνακας 3.1: Παράδειγμα αρχικών καταστάσεων

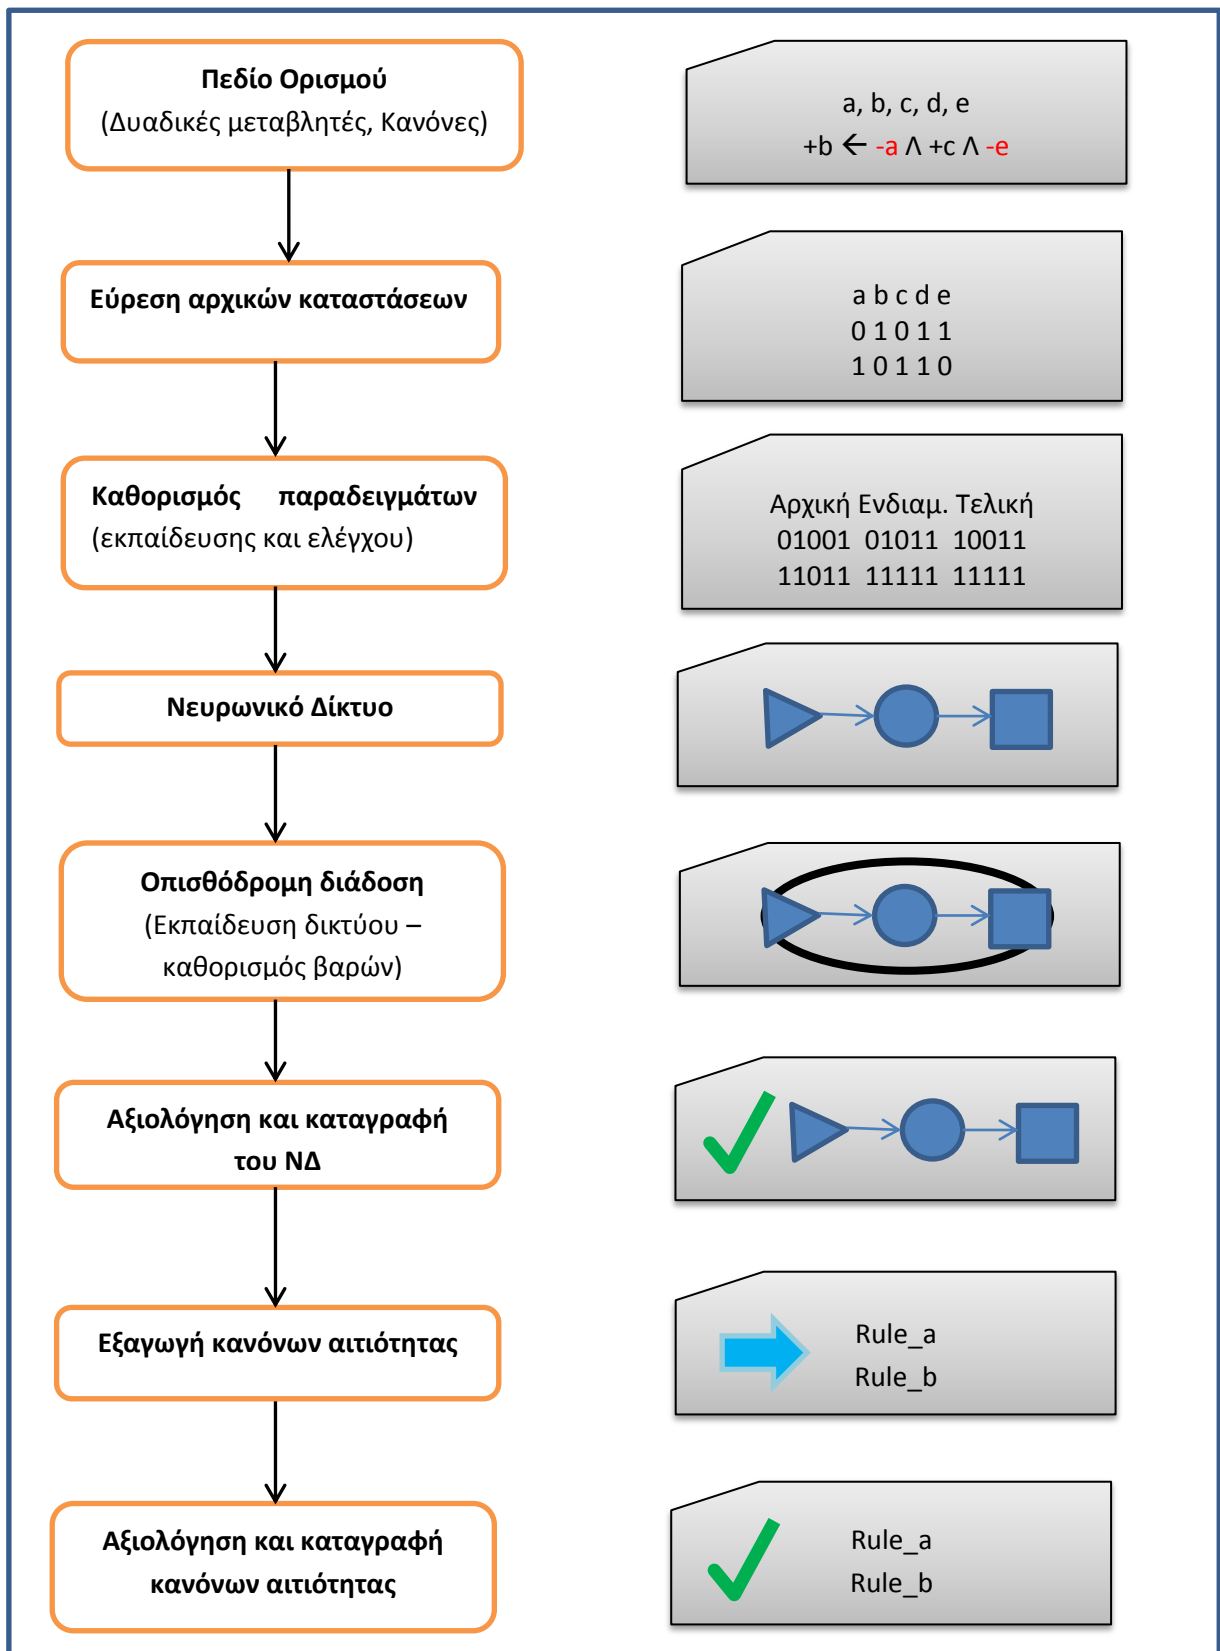
3. Καθορισμός των παραδειγμάτων **εκπαίδευσης** και **ελέγχου** για το Νευρωνικό Δίκτυο. Τα παραδείγματα αυτά είναι υποσύνολα των παραδειγμάτων, όπως αυτά καθορίστηκαν στο προηγούμενο βήμα και επιλέγονται με τυχαίο τρόπο και βάσει κάποιων κριτηρίων προκαθορισμένων από τον χρήστη. Για παράδειγμα, τα παραδείγματα εκπαίδευσης

μπορεί να είναι το 70% των συνολικών, ενώ τα παραδείγματα ελέγχου το υπόλοιπο 30%. Κάθε παράδειγμα αποτελείται από την ομάδα αρχικών τιμών την οποία ακολουθούν ένας αριθμός ομάδων τιμών ίδιος με αυτόν που έχει οριστεί στον Συλλογισμό. Έτσι, αν στον Συλλογισμό έχουν οριστεί 2 επαναλήψεις η δεύτερη ομάδα τιμών των μεταβλητών θα προκύψει από τα αποτελέσματα των κανόνων όπως αυτοί θα τα υπολογίσουν με βάση τις αρχικές τιμές των μεταβλητών. Η τρίτη ομάδα τιμών θα προκύψει από τα αποτελέσματα των κανόνων όπως αυτοί θα τα υπολογίσουν με βάση τις τιμές της δεύτερης ομάδας τιμών που υπολογίστηκαν προηγουμένως. Κάθε ομάδα τιμών συνοψίζει την κατάσταση των μεταβλητών σε συγκεκριμένη χρονική στιγμή.

4. Κατασκευή του **Νευρωνικού Δικτύου προκαθορισμένης δομής** και βάσει κριτηρίων ορισμένων από τον χρήστη. Με τον όρο 'προκαθορισμένη δομή' εννοούμε ότι **σε κάθε στοιβάδα** (εισαγωγής, κρυφή, εξωτερική), ο αριθμός των κόμβων θα είναι πάντα ο ίδιος και θα αντιστοιχεί είτε στον αριθμό των μεταβλητών, είτε στον αριθμό των πιθανών τιμών της κάθε μεταβλητής (0 ή 1). Η διάταξη των κόμβων σε κάθε στοιβάδα είναι πάντα η ίδια. Π.χ. ο πρώτος κόμβος θα αντιστοιχεί στην πρώτη μεταβλητή, ο δεύτερος στη δεύτερη κ.ο.κ. Κάθε στοιβάδα (πλην αυτής της εισαγωγής) έχει ως στόχο να υπολογίσει την κατάσταση των μεταβλητών την επόμενη χρονική στιγμή. Κανονικά, λοιπόν, ο αριθμός των στοιβάδων του νευρωνικού δικτύου εξαρτάται από τον αριθμό των επαναλήψεων όπως αυτός ορίζεται κάθε φορά στον Συλλογισμό. Για λόγους διερεύνησης, όμως, υπάρχει η δυνατότητα να οριστεί διαφορετικός αριθμός στοιβάδων. Τέλος, υπάρχει η επιλογή για τη δημιουργία κόμβου bias.
5. Εκπαίδευση (καθορισμός των βαρών) του Νευρωνικού Δικτύου βάσει του κλασικού αλγορίθμου της **οπισθόδρομης διάδοσης (back propagation)**. Εδώ υπάρχει η δυνατότητα να παρέμβουμε συμμετρικοποιώντας τα βάρη σε διάφορα στάδια της διάδοσης, ανάλογα με τον επιλεγμένο τύπο συμμετρικοποίησης.
6. Αξιολόγηση των αποτελεσμάτων του εκπαιδευμένου ΝΔ σε σχέση με τα αναμενόμενα – ορθά αποτελέσματα των κανόνων του Πεδίου Ορισμού. Πιο συγκεκριμένα, συγκρίνονται οι τιμές της τελευταίας ομάδας κάθε παραδείγματος (αναμενόμενα αποτελέσματα) με τις τιμές που δίνουν οι κόμβοι της στοιβάδας εξόδου και αντιστοιχούν στις ίδιες μεταβλητές (π.χ. ο πρώτος κόμβος αντιστοιχεί στην μεταβλητή a, ο δεύτερος στην b κ.ο.κ.). Οι συγκρίσεις αυτές οδηγούν στον υπολογισμό της ακρίβειας του νευρωνικού δικτύου. Χρησιμοποιούνται 3 μετρικές για την ακρίβεια: η πραγματική (actual), η ανά τιμή και η

ανά ομάδα τιμών. Ωστόσο, κατά τη διεξαγωγή των πειραμάτων και την ανάλυση των αποτελεσμάτων χρησιμοποιείται μόνο η τελευταία (ακρίβεια ανά ομάδα τιμών) που είναι και η αυστηρότερη. Αυτή υπολογίζεται ως εξής: για κάθε παράδειγμα, ελέγχεται αν η ομάδα τιμών που υπολογίζεται από το νευρωνικό δίκτυο είναι ακριβώς ίδια με την αναμενόμενη. Αν όχι, θεωρούμε ότι το νευρωνικό δίκτυο απέτυχε να αναπαράγει σωστά το συγκεκριμένο παράδειγμα. Η ακρίβεια που υπολογίζεται είναι το ποσοστό των παραδειγμάτων που κατάφερε το νευρωνικό δίκτυο να αναπαράγει σωστά προς το σύνολο των παραδειγμάτων που δοκιμάστηκαν. Η ακρίβεια υπολογίζεται χωριστά για τα παραδείγματα εκπαίδευσης και ελέγχου.

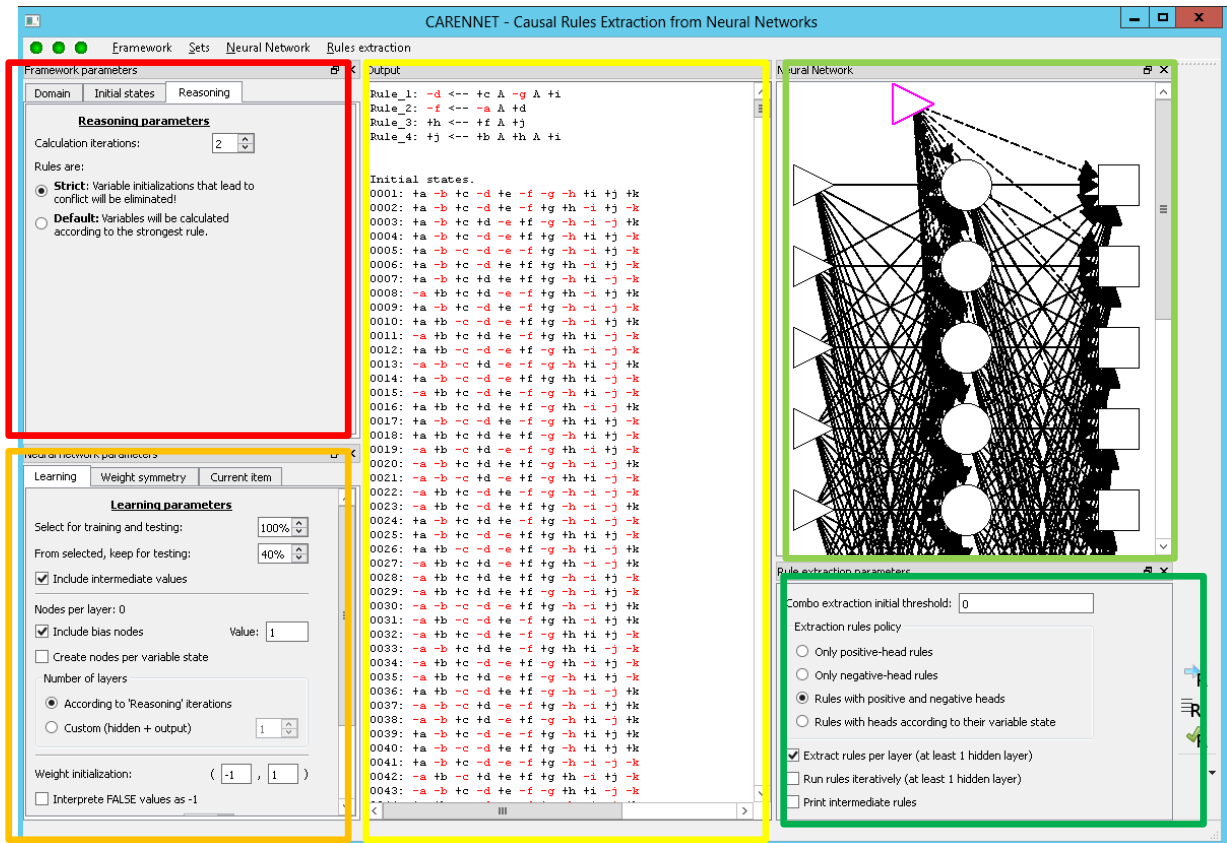
7. Εξαγωγή κανόνων από το ΝΔ με βάση την τεχνική COMBO (Krishnan, Sivakumar, & Bhattacharya, 1996). Διευκρινίζεται εδώ ότι οι κανόνες που εξαγονται από αυτήν την τεχνική κανονικά δεν είναι κανόνες αιτιότητας, αλλά κανόνες συσχέτισης προτασιακής λογικής. Ωστόσο, χάρη στη συγκεκριμένη δομή που δίνουμε κάθε φορά στο νευρωνικό δίκτυο, αντιστοιχώντας ουσιαστικά την κάθε στοιβάδα με μια χρονική στιγμή, καθώς και τους κόμβους κάθε στοιβάδας στην κατάσταση των μεταβλητών στη συγκεκριμένη χρονική στιγμή, θεωρούμε ότι είναι λογικό να ερμηνεύσουμε και τους εξαγόμενους κανόνες συσχέτισης ως κανόνες αιτιότητας **που συνδέουν τα γεγονότα της προηγούμενης χρονικής στιγμής (μεταβλητές) με αυτά της επόμενης.**
8. Αξιολόγηση των εξαχθέντων κανόνων ως προς τα ορθά αποτελέσματα των κανόνων του Πεδίου Ορισμού (ακρίβεια) και ως προς τα αποτελέσματα του ΝΔ (πιστότητα). Χρησιμοποιούνται 2 χαρακτηριστικά: η ακρίβεια και η πιστότητα. Η ακρίβεια υπολογίζεται με τον ίδιο ακριβώς τρόπο που υπολογίζεται και για το νευρωνικό δίκτυο. Δηλαδή, «τρέχουμε» τους κανόνες για να υπολογίσουμε τις τελικές τιμές των μεταβλητών και να τις συγκρίνουμε με τις αναμενόμενες, όπως προέκυψαν από τους κανόνες αιτιότητας του Πεδίου Ορισμού. Η πιστότητα υπολογίζεται συγκρίνοντας τις υπολογισμένες από τους εξαχθέντες κανόνες τελικές τιμές με τις αντίστοιχες του νευρωνικού δικτύου. Μετράμε δηλαδή πόσο «πιστοί» είναι οι κανόνες στο νευρωνικό δίκτυο από το οποίο προέκυψαν. Και εδώ χρησιμοποιείται η μετρική της ανά ομάδας τιμών. Η πιστότητα είναι το ποσοστό των παραδειγμάτων που κατάφεραν να αναπαράγουν οι εξαχθέντες κανόνες σύμφωνα με τα αποτελέσματα του νευρωνικού δικτύου προς το σύνολο των παραδειγμάτων που δοκιμάστηκαν. Τόσο η ακρίβεια, όσο και η πιστότητα των εξαχθέντων κανόνων υπολογίζονται χωριστά για τα παραδείγματα εκπαίδευσης και ελέγχου.



Σχήμα 3.1: Σύνοψη των σταδίων της πειραματικής διαδικασίας CARENNET.

3.2 Συνοπτική περιγραφή της εφαρμογής

Με σκοπό την καλύτερη κατανόηση της πειραματικής διαδικασίας παρουσιάζουμε εδώ την παραθυρική εφαρμογή CARENNET με τα βασικά της πλαίσια και χειριστήρια.



Σχήμα 3.2: Γενική άποψη της παραθυρικής εφαρμογής CARENNET.

- Πλαίσιο Framework ■: Περιλαμβάνει χειριστήρια παραμέτρων για την κατασκευή του Πεδίου Ορισμού, των Αρχικών Καταστάσεων και του Συλλογισμού.
- Πλαίσιο Νευρωνικού Δικτύου ■: Περιλαμβάνει χειριστήρια παραμέτρων για το διαμερισμό του συνόλου των παραδειγμάτων σε υποσύνολα εκπαίδευσης και ελέγχου, για την κατασκευή και τον υπολογισμό του Νευρωνικού Δικτύου, τη Συμμετρικοποίηση των Βαρών καθώς και πίνακα πληροφοριών των επιμέρους στοιχείων του Νευρωνικού Δικτύου που ανανεώνεται με κάθε νέα επιλογή από το αντίστοιχο παράθυρο (■).
- Παράθυρο αποτελεσμάτων ■: Εδώ τυπώνονται τα αποτελέσματα κατά τη διάρκεια ή στο τέλος κάθε σταδίου της πειραματικής διαδικασίας.


- Παράθυρο Νευρωνικού Δικτύου ■: Σε αυτόν το χώρο σχεδιάζεται γραφικά το Νευρωνικό Δίκτυο, σύμφωνα με τις παραμέτρους του χρήστη. Οι κόμβοι της στοιβάδας εισόδου συμβολίζονται με τρίγωνα, των κρυφών στοιβάδων με κύκλους, ενώ αυτοί της στοιβάδας εξόδου με τετράγωνα. Ο bias κόμβος, αν υπάρχει, συμβολίζεται με τρίγωνο χρώματος ματζέντα. Τέλος, στην περίπτωση που ο χρήστης απαιτήσει κόμβους ανά τιμή μεταβλητής, οι κόμβοι σε όλες τις στοιβάδες θα ζωγραφιστούν με λεπτή μαύρη γραμμή, αν αναφέρονται στη θετική τιμή μιας μεταβλητής και με κόκκινη αν αναφέρονται στην αρνητική.
- Πλαίσιο εξαγόμενων κανόνων ■: Αυτός ο χώρος περιλαμβάνει τα χειριστήρια των παραμέτρων της εξαγωγής κανόνων

Η κεντρική γραμμή των μενού (menubar), απαρτίζεται από 4 μενού, ένα για κάθε διακριτή οντότητα της πειραματικής διαδικασίας:

- i. Framework (Πεδίο Ορισμού και Αρχικές Καταστάσεις)
- ii. Sets (Υποσύνολα παραδειγμάτων εκπαίδευσης και ελέγχου)
- iii. Νευρωνικό Δίκτυο
- iv. Εξαγωγή Κανόνων

Τα μενού αυτά παρέχουν βασικές εντολές για τη διαχείριση (κατασκευή, επαναφορά, φόρτωση, αποθήκευση κλπ) όσο και για τη λειτουργία της κάθε οντότητας.

Στα αριστερό κομμάτι της γραμμής των μενού παρέχονται 3 σηματοδότες προς ενημέρωση του χρήστη για την τρέχουσα κατάσταση του Framework, των Sets και του Νευρωνικού Δικτύου καθώς και τη μεταξύ τους σχέση. Και αυτό γιατί κάθε μια από αυτές τις οντότητες εξαρτάται από την προηγούμενή της, ενώ ταυτόχρονα η διαχείρισή τους είναι ανεξάρτητη.



Σχήμα 3.3: Η κεντρική γραμμή των μενού της εφαρμογής CARENNET. Η κόκκινη λάμπα του Νευρωνικού Δικτύου υποδηλώνει ότι αυτό δεν είναι κατασκευασμένο. Η κίτρινη λάμπα του Framework υποδηλώνει ότι αυτό υπάρχει, αλλά ενδέχεται να είναι «ασύνδετο» με τα Sets τα οποία φορτώθηκαν εκ των υστέρων (πράσινη λάμπα) και δεν προέκυψαν άμεσα από το ίδιο το Framework.

3.3 Αλγόριθμοι και επιλογές

Όπως ενδεχομένως να έχει γίνει κατανοητό μέχρι τώρα, η CARENNET είναι μια αρκετά σύνθετη διαδικασία, ενώ ως πειραματική θα πρέπει να εξασφαλίσει τόσο την τυχαιότητα επιλογής οντοτήτων (π.χ. επιλογή μεταβλητών για την κατασκευή κανόνων, επιλογή παραδειγμάτων κλπ), όσο και τη δυνατότητα εφαρμογής διαφορετικών επιλογών σε διάφορα στάδια. Με αυτόν τον τρόπο εξασφαλίζουμε αφενός αντικειμενικότερα αποτελέσματα, αφετέρου τη διερεύνηση διαφορετικών επιλογών με σκοπό να βρούμε το βέλτιστο συνδυασμό αυτών.

Στο τμήμα αυτό θα αναφερθούμε στους αλγόριθμους που αναπτύχθηκαν για να στηρίξουν τόσο την τυχαία επιλογή όσο και τις διαθέσιμες επιλογές που υλοποιήθηκαν για τα διάφορα στάδια της διαδικασίας, δίνοντας έμφαση σε αυτές που εφαρμόστηκαν τελικά στη διεξαγωγή των πειραμάτων.

3.3.1 Τυχαία επιλογή

Όπου χρειάστηκε η τυχαία επιλογή οντοτήτων εφαρμόστηκε ο ίδιος ακριβώς αλγόριθμος, ο οποίος μπορεί να συνοψιστεί στα εξής 3 βήματα:

1. Συλλέγουμε όλες τις δυνατές και έγκυρες οντότητες σε μια λίστα.
2. Ανακατεύουμε τη λίστα
3. Επιλέγουμε τις n πρώτες οντότητες της λίστας, όπου n είναι ο απαιτούμενος αριθμός τυχαίων οντοτήτων που θέλουμε να επιλέξουμε για κάποιον σκοπό.

Στον ψευδοκώδικα που ακολουθεί περιγράφεται το ανακάτεμα των οντοτήτων της λίστας:

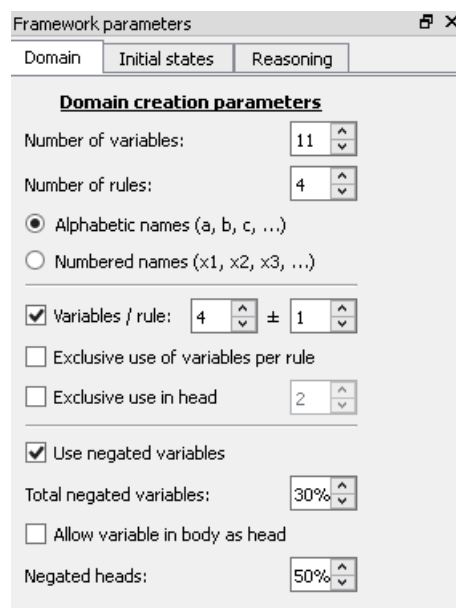
```
shuffleList( list )
{
    i = list.count()
    WHILE (i > 0)
        j = rand() % i+1
        list.swap(i, j)
        --i

    IF (list.count() > 2) THEN
        idxForFirst = rand() % (list.count() - 1)
        list.swap(0, idxForFirst)
}
```

3.3.2 Πεδίο Ορισμού (Domain)

Όπως αναφέρθηκε προηγουμένως, το Πεδίο Ορισμού απαρτίζεται από τις μεταβλητές και τους κανόνες αιτιότητας (Michael, 2011), ο αριθμός των οποίων πρέπει να οριστεί από τον χρήστη. Στο πλαίσιο της ανάπτυξης της πειραματικής διαδικασίας CARENNET υλοποιήθηκαν διάφορες επιλογές για τον καθορισμό ενός πλαισίου μέσα στο οποίο θα κατασκευάζονται οι κανόνες αιτιότητας με τυχαίο πάντα τρόπο. Κάποιες από τις επιλογές αυτές ήταν:

- Χρήση μεταβλητών ανά κανόνα: $X \pm Y$, όπου X είναι ο βασικός αριθμός μεταβλητών ανά κανόνα και Y η επιθυμητή απόκλιση. Ο αριθμός των μεταβλητών που θα χρησιμοποιηθούν τελικά σε έναν κανόνα επιλέγεται με τυχαίο τρόπο.
- Αποκλειστική χρήση μεταβλητών ανά κανόνα. Αυτό σημαίνει ότι αν μια μεταβλητή εμφανίζεται με κάποιο άτομο σε έναν κανόνα, θα αποκλειστεί η χρήση της από οποιονδήποτε άλλον κανόνα.
- Αποκλειστική χρήση στην κεφαλή του κανόνα X μεταβλητών. Γίνεται τυχαία επιλογή X μεταβλητών από το σύνολο που έχει καθορίσει ο χρήστης και αποκλειστική χρήση τους στις κεφαλές των κανόνων. Η επιλογή αυτή υπονοεί και την απαγόρευση της χρήσης οποιωνδήποτε άλλων μεταβλητών στις κεφαλές των κανόνων.
- Χρήση αρνήσεων. Η επιλογή αυτή επιτρέπει γενικά τη χρήση ατόμων σε άρνηση. Ακόμα, συνεπάγεται τον ορισμό του συνολικού ποσοστού αρνήσεων σε όλους τους κανόνες καθώς και τον ορισμό του ποσοστού των αρνητικών κεφαλών.



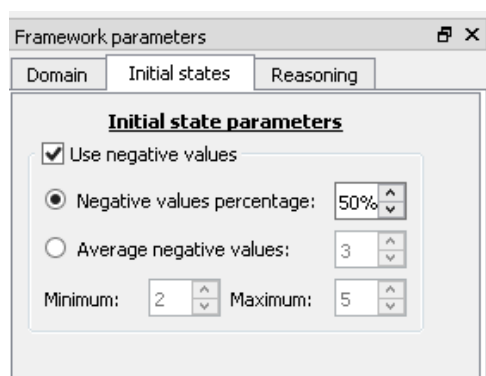
Σχήμα 3.4: Καρτέλα επιλογών για την κατασκευή του Πεδίου Ορισμού.

Αναφέρουμε εδώ ότι κατά την εκτέλεση των πειραμάτων οι παράμετροι αυτές παρέμειναν σταθερές αφού η διερεύνησή τους θα απαιτούσε πολύ περισσότερους πόρους (χρόνο, υπολογιστική δύναμη και μνήμη) από όσους θα μπορούσαν να δικαιολογηθούν στο πλαίσιο της εκπόνησης μιας μεταπτυχιακής διατριβής. Ωστόσο, προκαταρκτικά πειράματα έδειξαν τις τιμές που θα μπορούσαν να χρησιμοποιηθούν ώστε τα πειράματα να έχουν νόημα και να καταλήξουν σε ενδιαφέροντα συμπεράσματα.

3.3.3 Αρχικές καταστάσεις και Συλλογισμός (Reasoning)

Τόσο οι επιλογές για τις αρχικές καταστάσεις όσο και αυτές για τον Συλλογισμό καθορίζουν ουσιαστικά το πλήθος και τη δομή των παραδειγμάτων που θα προκύψουν σε επόμενο στάδιο και θα χρησιμοποιηθούν στην εκπαίδευση, έλεγχο και αξιολόγηση του νευρωνικού δικτύου, καθώς και στην αξιολόγηση των υπό εξαγωγή κανόνων αιτιότητας.

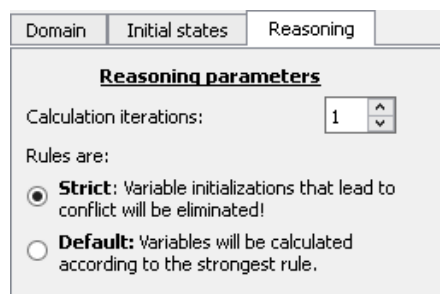
Με τον όρο «αρχική κατάσταση» αναφερόμαστε σε μια ομάδα αρχικών τιμών για όλες τις μεταβλητές του Πεδίου Ορισμού. Οι επιλογές που διατίθενται αφορούν αποκλειστικά τη διαμόρφωση του ποσοστού των αρνητικών τιμών. Και σε αυτήν την περίπτωση οι παράμετροι παραμένουν σταθερές κατά την εκτέλεση των πειραμάτων. Συγκεκριμένα επιλέχθηκε το ποσοστό των αρνητικών τιμών να είναι το 50% του συνόλου, ώστε το πλήθος των παραδειγμάτων να μην περιοριστεί από αυτήν την παράμετρο.



Σχήμα 3.5: Καρτέλα επιλογών για τις αρχικές καταστάσεις των μεταβλητών.

Με τον όρο «Συλλογισμός» αναφερόμαστε σε αρχές και παραμέτρους που θα καθορίσουν τα τελικά αποτελέσματα των κανόνων αιτιότητας.

Μια βασική παράμετρος, που συμπεριλήφθηκε και στον πειραματικό σχεδιασμό, είναι ο αριθμός των **κύκλων υπολογισμών ή επαναλήψεων** βάσει του οποίου θα «τρέξουν» οι κανόνες αιτιότητας υπολογίζοντας κάθε φορά τις τιμές για τις κεφαλές τους, οι οποίες και θα επανεισαχθούν στον επόμενο υπολογισμό. Σημειώνεται εδώ ότι οι τιμές των κεφαλών θα επηρεαστούν **μόνο στην περίπτωση που το σώμα του κανόνα είναι αληθές**. Για να γίνει σε μεγαλύτερο βάθος αντιληπτός ο αλγόριθμος είναι καλό να εξετάσουμε ένα απλό παράδειγμα:



Σχήμα 3.6: Καρτέλα επιλογών για τον Συλλογισμό.

Έστω ένα Πεδίο Ορισμού αποτελούμενο από τις 3 μεταβλητές **a**, **b**, **c** και τους παρακάτω 2 κανόνες:

- Rule_1: $a \leftarrow b \wedge c$

- Rule_2: $b \leftarrow \neg a$

Θεωρώντας ότι στον Συλλογισμό έχουν οριστεί 2 επαναλήψεις, θα εξετάσουμε την πορεία των μεταβλητών μετά από κάθε επανάληψη για την ομάδα τιμών 011, δηλαδή για $a = 0, b = 1, c = 1$.

1) 1^η Επανάληψη

- Υπολογισμός Rule_1: Το σώμα του κανόνα ορίζει $b \wedge c$, δηλαδή «Αν ισχύει το b ΚΑΙ ισχύει το c ». Στην περίπτωσή μας αυτό ισχύει, επομένως η μεταβλητή a θα πάρει την τιμή **1 για τον επόμενο κύκλο υπολογισμών (2^η επανάληψη)**.
- Υπολογισμός Rule_2: Ο κανόνας ορίζει ότι «Αν ΔΕΝ ισχύει το a , τότε θα ισχύσει το b ». Και ο κανόνας αυτός είναι αληθής ($a = 0$ σε αυτόν τον κύκλο υπολογισμών), επομένως το b θα γίνει 1 στον επόμενο κύκλο υπολογισμών λόγω πια του δεύτερου κανόνα.

2) 2^η Επανάληψη: Τώρα πια η νέα ομάδα τιμών είναι 111 ($a = 1, b = 1, c = 1$)

- Υπολογισμός Rule_1: Ο κανόνας είναι αληθής, επομένως η νέα τιμή του a θα είναι πάλι 1.
- Υπολογισμός Rule_2: Ο κανόνας είναι ψευδής ($a = 1$). Επομένως **η τιμή του b θα μείνει ως έχει**.

Άρα με το πέρας και του δεύτερου κύκλου υπολογισμών η τελική πια ομάδα τιμών θα είναι 111. Η μεταβολή των τιμών μπορεί να συνοψιστεί ως εξής:

011 (αρχικές τιμές) \rightarrow **111** (τέλος πρώτης επανάληψης) \rightarrow **111** (τέλος δεύτερης επανάληψης)

Ας σκεφτούμε τώρα την εξής περίπτωση: έστω ότι το σύστημα μαζί με τους πιο πάνω κανόνες κατασκεύασε (τυχαία πάντα) και τον εξής:

- Rule_3: $\neg a \leftarrow b$

Γίνεται αμέσως φανερό ότι στις περιπτώσεις που οι μεταβλητές b και c γίνονται ταυτόχρονα αληθείς, είτε κατά την αρχικοποίηση (αρχική ομάδα τιμών), είτε με το πέρας του υπολογισμού μιας ενδιάμεσης ομάδας τιμών (π.χ. στο τέλος του πρώτου κύκλου υπολογισμών), θα έχουμε 2 κανόνες (τον 1^ο και τον 3^ο) που θα δίνουν διαφορετική τιμή στη μεταβλητή a (1 και 0,

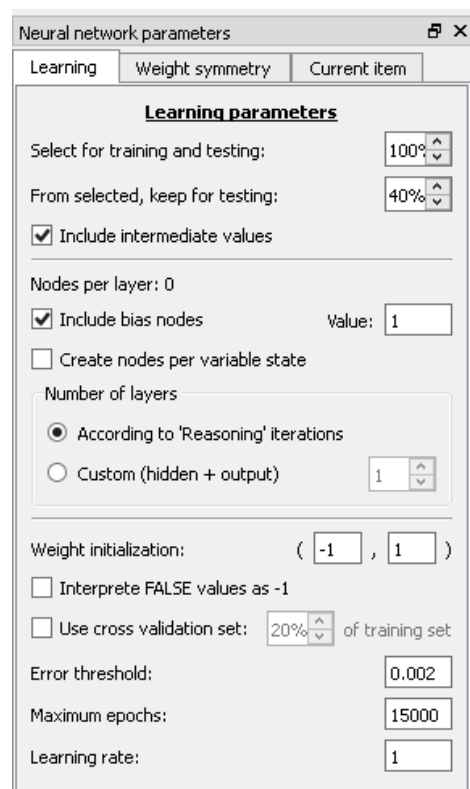
αντίστοιχα). Ο τρόπος του Συλλογισμού που θα επιλέξουμε καλείται να λύσει τέτοιου είδους αντιφάσεις. Στο πλαίσιο της πειραματικής διαδικασίας CARENNET διατίθενται 2 τρόποι (Michael, 2011):

- **Αυστηρός συλλογισμός (Strict reasoning):** Με αυτόν τον τρόπο απλά απορρίπτονται όλες οι αρχικές ομάδες τιμών που μπορεί να οδηγήσουν σε τέτοιες αντιφάσεις με αποτέλεσμα να μην κατασκευάζονται τα αντίστοιχα παραδείγματα.
- **Κανονικός συλλογισμός (Default reasoning):** Εδώ οι αντιφάσεις αντιμετωπίζονται με την ιεράρχηση των κανόνων αιτιότητας σύμφωνα με τη σειρά με την οποία έχουν κατασκευαστεί. Οι κανόνες που κατασκευάζονται πρώτοι θεωρούνται **ισχυρότεροι** έναντι των υπολοίπων. Έτσι, λοιπόν, αν 2 κανόνες οδηγούν σε αντίφαση θα κυριαρχήσει ο ισχυρότερος, δηλαδή αυτός που φτιάχτηκε πρώτος. Στο προαναφερθέν παράδειγμα, θεωρώντας ότι οι κανόνες φτιάχτηκαν με τη σειρά που αναφέρονται, θα κυριαρχήσει ο πρώτος κανόνας. Επομένως, στις περιπτώσεις όπου οι μεταβλητές b και c είναι ταυτόχρονα αληθείς, το a θα πάρει τιμή 1 (αληθές).

3.3.4 Νευρωνικό δίκτυο

Τόσο η κατασκευή ενός νευρωνικού δικτύου, όσο η εκπαίδευση και ο έλεγχός του είναι ενέργειες σύνθετες που ενδέχεται να διαφοροποιηθούν σημαντικά από τη μια περίπτωση στην άλλη, ανάλογα με τις εκάστοτε ανάγκες του χρήστη. Για τις ανάγκες της πειραματικής διαδικασίας CARENNET υλοποιήθηκε η διαθεσιμότητα κάποιων βασικών επιλογών. Εδώ θα αναφερθούν επιγραμματικά οι περισσότερες δίνοντας περισσότερη έμφαση σε αυτές που εντάχθηκαν τελικά στον πειραματικό σχεδιασμό, ενώ οι υπόλοιπες (κόμβοι ανά τιμή μεταβλητής και συμμετρικοποίηση βαρών) θα παρουσιαστούν διεξοδικότερα στη συνέχεια.

Τα νευρωνικά δίκτυα που κατασκευάζονται κατά την πειραματική διαδικασία αποτελούνται πάντα από τη



Σχήμα 3.7: Καρτέλα επιλογών για την κατασκευή και εκπαίδευση του νευρωνικού δικτύου

στοιβάδα εισόδου, τη στοιβάδα εξόδου και προαιρετικά από έναν αριθμό κρυφών στοιβάδων.

Κάθε στοιβάδα αποτελείται από κόμβους που αντιπροσωπεύουν όλες τις μεταβλητές και βρίσκονται πάντα στην ίδια διάταξη: ξεκινώντας από πάνω προς τα κάτω, ο πρώτος κόμβος αντιπροσωπεύει την πρώτη μεταβλητή, ο δεύτερος τη δεύτερη κ.ο.κ.

Κάθε κόμβος μιας στοιβάδας συνδέεται με όλους τους κόμβους της επόμενης.

Τέλος, το νευρωνικό δίκτυο είναι μη-αναδρομικό (feedforward) και εκπαιδεύεται με τον αλγόριθμο της οπισθόδρομης διάδοσης (back propagation). Για την οπισθόδρομη διάδοση, ως συνάρτηση εξόδου των κόμβων χρησιμοποιήθηκε η απλή σιγμοειδής συνάρτηση. Υπήρχε όμως και η επιλογή για την υπερβολική εφαπτομένη (tanh) (Haykin, 1999).

Οι διαθέσιμες επιλογές, που εντάχθηκαν και στον πειραματικό σχεδιασμό είναι:

- **Χρήση κόμβου bias:** Ο κόμβος αυτός, όταν χρησιμοποιείται, διευκολύνει την εκπαίδευση του δικτύου και τείνει να δίνει καλύτερα αποτελέσματα. Συνδέεται με όλους τους κόμβους των κρυφών στοιβάδων και της στοιβάδας εξόδου. Τέλος, δίνεται η επιλογή καθορισμού της τιμής του, η οποία, για τις περισσότερες ανάγκες είναι 1 (Haykin, 1999).
- **Καθορισμός αριθμού στοιβάδων (κρυφών + εξόδου):** Η αρχική σύλληψη προέβλεπε την αντιστοιχία των στοιβάδων του νευρωνικού δικτύου με τους κύκλους υπολογισμού που ορίστηκαν στο Συλλογισμό. Ωστόσο, φάνηκε αρκετά ενδιαφέρουσα η διερεύνηση της χρήσης ενός αριθμού στοιβάδων, ανεξάρτητου από τους κύκλους υπολογισμού. Έτσι, π.χ. είναι δυνατόν να κατασκευάσουμε ένα νευρωνικό δίκτυο με μόνο μια στοιβάδα (εξόδου), για ένα Πεδίο Ορισμού με 3 κύκλους υπολογισμών ορισμένους στο Συλλογισμό του.

Οι υπόλοιπες διαθέσιμες επιλογές είναι οι εξής:

- Καθορισμός εύρους τιμών για την αρχικοποίηση των βαρών
- Ερμηνεία των ψευδών τιμών ως -1 και όχι ως 0. Η τεχνική αυτή είναι αρκετά διαδεδομένη στη χρήση των νευρωνικών δικτύων. Ωστόσο, στη δική μας περίπτωση και για λόγους που δεν στάθηκε δυνατό να διερευνηθούν, φάνηκε να δίνει κατώτερης

ποιότητας εκπαιδευμένα νευρωνικά δίκτυα. Η επιλογή αυτή έθετε ως συνάρτηση εξόδου των κόμβων την υπερβολική εφαπτομένη (\tanh).

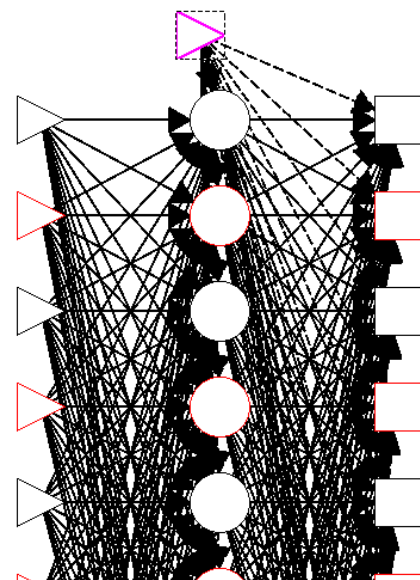
- Χρήση cross-validation set. Αφορά στην εκπαίδευση του νευρωνικού δικτύου.
- Καθορισμός ορίου σφάλματος ελάχιστων τετραγώνων (MSE threshold).
- Καθορισμός μέγιστου αριθμού epochs κατά την εκπαίδευση. Η επιλογή αυτή είναι ιδιαίτερα χρήσιμη στην περίπτωση των αυτοματοποιημένων εκτελέσεων της πειραματικής διαδικασίας (batch execution).
- Καθορισμός ρυθμού μάθησης. Χρησιμοποιείται κατά την εκπαίδευση του δικτύου.

3.3.5 Κόμβοι ανά τιμή μεταβλητής (Nodes per variable state)

Μια ιδέα που θεωρήθηκε αξιόλογη και φάνηκε να δίνει καλής ποιότητας εκπαιδευμένα νευρωνικά δίκτυα ήταν η αντιστοίχιση των κόμβων του νευρωνικού δικτύου, όχι με τις μεταβλητές του Πεδίου Ορισμού, αλλά με τις πιθανές τιμές που αυτές μπορούσαν να πάρουν. Στην πειραματική διαδικασία CARENNET οι μεταβλητές που χρησιμοποιούνται είναι δυαδικές (αληθές – ψευδές ή 1 – 0). Συνεπώς, η εφαρμογή αυτής της ιδέας δίνει στοιβάδες με αριθμό κόμβων διπλάσιο από τον αριθμό των μεταβλητών, ενώ παράλληλα απαιτεί τη διαφοροποίηση των παραδειγμάτων εκπαίδευσης και ελέγχου ως εξής:

Έστω ότι κατασκευάζουμε ένα Πεδίο Ορισμού με 3 μεταβλητές a , b , c και ότι παράγουμε, μεταξύ άλλων, το ακόλουθο παράδειγμα με μια ομάδα αρχικών τιμών και μια ομάδα τελικών τιμών:

001 (αρχική ομάδα τιμών) \rightarrow **101** (τελική ομάδα τιμών).



Σχήμα 3.8: Νευρωνικό δίκτυο στο οποίο έχουν δημιουργηθεί κόμβοι ανά τιμή μεταβλητής. Οι κόμβοι με μαύρο χρώμα αντιπροσωπεύουν τις αληθείς τιμές των μεταβλητών, ενώ αυτοί με κόκκινο τις ψευδείς.

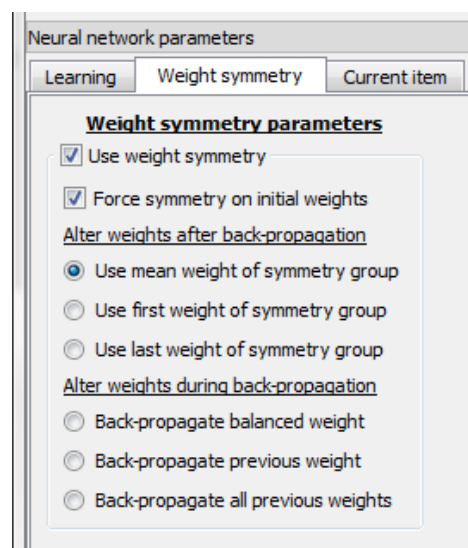
Η επιλογή των κόμβων ανά τιμή μεταβλητής θα κατασκευάσει 6 κόμβους στη στοιβάδα εισόδου, με την εξής σειρά από πάνω προς τα κάτω: +a_in, -a_in, +b_in, -b_in, +c_in, -c_in. Αντίστοιχα, η σειρά των κόμβων στη στοιβάδα εξόδου θα είναι: +a_out, -a_out, +b_out, -b_out, +c_out, -c_out. Οι +x κόμβοι αντιστοιχούν στις θετικές τιμές της x μεταβλητής, ενώ οι -x στις αρνητικές. Η αρχική ομάδα τιμών του παραδείγματος θα πρέπει να μετατραπεί από **001** (για τις a,b,c μεταβλητές) σε **010110** για τους κόμβους +a_in, -a_in, +b_in, -b_in, +c_in, -c_in εισαγωγής του δικτύου. Πιο απλά, αν η τιμή μιας μεταβλητής είναι ψευδής (0) τότε ο κόμβος που αντιστοιχεί στην ψευδή τιμή της μεταβλητής γίνεται αληθής, ενώ ταυτόχρονα ο κόμβος που αντιστοιχεί στην αληθή τιμή της μεταβλητής γίνεται ψευδής (01). Αντίστροφα, αν μια μεταβλητή έχει αληθή τιμή (1) ο κόμβος που αντιστοιχεί στην αληθή τιμή θα γίνει αληθής, ενώ εκείνος που αντιστοιχεί στην ψευδή θα γίνει ψευδής (10). Με παρόμοιο τρόπο θα πρέπει να μετατραπούν και όλες οι υπόλοιπες ομάδες τιμών. Η τελική ομάδα τιμών του παραδείγματος θα μετατραπεί σε **100110**. Κατά τα άλλα η διαδικασίες εκπαίδευσης, ελέγχου και αξιολόγησης του δικτύου παραμένουν ίδιες.

Δυστυχώς, η επιλογή αυτή, αν και πολλά υποσχόμενη για την εκπαίδευση του νευρωνικού δικτύου, δεν έδινε καλά αποτελέσματα κατά την εξαγωγή κανόνων, ενώ λόγω του διπλασιασμού των κόμβων αυξάνονταν η πολυπλοκότητα των υπολογισμών και κατ' επέκταση οι απαιτήσεις σε πόρους (χρόνο, υπολογιστική δύναμη και μνήμη). Εντούτοις, πιστεύουμε ότι η συγκεκριμένη υλοποίηση θα μπορούσε ίσως να βελτιωθεί, όσον αφορά στο στάδιο της εξαγωγής κανόνων και γι' αυτό αξίζει να διερευνηθεί μελλοντικά.

3.3.6 Συμμετρικοποίηση βαρών

Πριν παρουσιάσουμε τους αλγόριθμους της συμμετρικοποίησης βαρών θα ήταν καλό να αναφερθούμε στις σκέψεις πάνω στις οποίες βασίστηκε.


Αυτό που θέλουμε να διερευνήσουμε με την πειραματική διαδικασία CARENNET είναι η δυνατότητα να εξαγάγουμε τους ίδιους ή ισοδύναμους κανόνες αιτιότητας από ένα νευρωνικό δίκτυο το οποίο έχει εκπαιδευτεί με αυτούς. Η εκπαίδευση του δικτύου γίνεται με παραδείγματα τα οποία έχουν εξαχθεί από τους κανόνες αιτιότητας του Πεδίου Ορισμού. Έστω, λοιπόν, ένα παράδειγμα με 3 ομάδες τιμών: την αρχική, την τελική και μια ενδιάμεση. Τόσο η ενδιάμεση ομάδα τιμών, όσο και



Σχήμα 3.9: Καρτέλα συμμετρικοποίησης βαρών

η τελική προέκυψαν ως αποτελέσματα των **ίδιων κανόνων** που ενδεχομένως να έτρεξαν με διαφορετικές τιμές για τις μεταβλητές των σωμάτων τους και γι' αυτό ενδέχεται να έδωσαν διαφορετικές ομάδες τιμών. Ωστόσο, οι κανόνες αιτιότητας **εκφράζουν μια σχέση μεταξύ των μεταβλητών του σώματος και της κεφαλής**. Ταυτόχρονα, η δομή του νευρωνικού δικτύου εξαρτάται, όπως έχουμε πει, από τον αριθμό των μεταβλητών του Πεδίου Ορισμού και προσπαθεί να αναπαραστήσει τη σχέση όλων των μεταβλητών μεταξύ τους από τη μια χρονική στιγμή στην επόμενη (στοιβάδες), αφού όλοι οι κόμβοι μιας στοιβάδας συνδέονται με όλους τους κόμβους της επόμενης. Η ισχύς των συνδέσεων αυτών, ως γνωστόν, εκφράζεται με βάρη. Χονδρικά, όσο μεγαλύτερη είναι η απόλυτη τιμή των βαρών, τόσο ισχυρότερη είναι και η σχέση μεταξύ των συνδεδεμένων κόμβων. Δηλαδή, η τιμή του πρώτου κόμβου θα επηρεάσει σημαντικά την τιμή του άλλου με τον οποίο συνδέεται, είτε θετικά (θετικό βάρος), είτε αρνητικά (αρνητικό βάρος). Έτσι, λοιπόν, **είναι λογικό να περιμένουμε ότι η σχέση μεταξύ 2 οποιωνδήποτε συνδεδεμένων κόμβων θα παραμένει σταθερή σε όλα τα ζεύγη γειτονικών στοιβάδων**.

Για παράδειγμα, ας υποθέσουμε ένα Πεδίο Ορισμού με 3 μεταβλητές a, b, c , έναν κανόνα $b \leftarrow -a$, καθώς και 2 κύκλους υπολογισμών ορισμένους στον Συλλογισμό. Από ένα τέτοιο Πεδίο Ορισμού μπορεί να προκύψει ένα νευρωνικό δίκτυο με 3 στοιβάδες και 3 κόμβους σε κάθε στοιβάδα: $[a_{in}, b_{in}, c_{in}]$, $[a_m, b_m, c_m]$ και $[a_{out}, b_{out}, c_{out}]$. Άσχετα με τις αρχικές τιμές, ο κανόνας αναμένουμε να δημιουργεί την ίδια δυνατή σχέση μεταξύ του a και του b , τόσο μεταξύ της πρώτης και της ενδιάμεσης ομάδας τιμών, όσο και μεταξύ της ενδιάμεσης και της τελικής. Πιο συγκεκριμένα, λοιπόν, αναμένουμε τη σύνδεση a_{in} και b_m όπως και τη



Σχήμα 3.10: Νευρωνικό δίκτυο στο οποίο έχει εφαρμοστεί συμμετρικοποίηση κόμβων. Οι συνδέσεις με τα συμμετρικά βάρη φαίνονται με το ίδιο χρώμα. Η συμμετρικοποίηση των βαρών εφαρμόζεται και στις συνδέσεις του bias κόμβου προς τους κόμβους που αντιστοιχούν στην ίδια μεταβλητή (διακεκομμένες γραμμές).

συμμετρική της, a_m και b_{out} να εμφανίζουν μεγάλο, αρνητικό βάρος. Οι δύο αυτές συνδέσεις, όπως και τα βάρη τους, λέμε ότι **ανήκουν στην ίδια ομάδα συμμετρίας**.

Ωστόσο, ο τρόπος που εκπαιδεύεται ένα νευρωνικό δίκτυο δεν μπορεί σε καμία περίπτωση να εξασφαλίσει μια τέτοιου είδους συμμετρία, αφού δε γνωρίζει τίποτα για αυτήν τη σχέση των κόμβων. Με την τεχνική της συμμετρικοποίησης των βαρών ουσιαστικά επιβάλλουμε στο δίκτυο ένα είδος ομοιομορφίας στα βάρη μεταξύ συμμετρικών κόμβων. Για τον λόγο αυτόν επινοήθηκαν 6 διαφορετικοί αλγόριθμοι που μπορούν να ομαδοποιηθούν σε δύο κατηγορίες (σχήμα 3.9): Στην επιβολή των βαρών **μετά** από κάθε εκτέλεση οπισθόδρομης διάδοσης και στην επιβολή των βαρών **κατά τη διάρκεια** της εκτέλεσής τους. Ακολουθεί αναλυτικότερη περιγραφή των αλγορίθμων, ενώ για κάθε αλγόριθμο αναφέρεται και ο κωδικός που θα χρησιμοποιήσουμε στο εξής μέσα σε παρένθεση.

Εννοείται ότι η τεχνική της συμμετρικοποίησης εφαρμόζεται μόνο κατά την εκπαίδευση και όχι κατά τον έλεγχο του δικτύου. Επίσης, εννοείται ότι η τεχνική αυτή έχει νόημα μόνο για τα νευρωνικά δίκτυα που διαθέτουν τουλάχιστον μια κρυφή στοιβάδα και όχι για εκείνα που αποτελούνται μόνο από τις στοιβάδες εισόδου και εξόδου.

1) Μεταβολή βαρών στο τέλος της οπισθόδρομης διάδοσης

- i) Χρήση της μέσης τιμής των βαρών της ομάδας συμμετρίας (S1): Υπολογίζουμε τη μέση τιμή των βαρών που ανήκουν στην ίδια ομάδα συμμετρίας και την επιβάλλουμε σε όλες τις συνδέσεις της ομάδας.
- ii) Χρήση του πρώτου βάρους της ομάδας συμμετρίας (S2): Επιβάλλουμε το υπολογισθέν βάρος της πρώτης σύνδεσης σε όλες τις υπόλοιπες συνδέσεις της ίδιας ομάδας. Με τον όρο «πρώτη» εννοούμε τη σύνδεση από κόμβο της στοιβάδας εισόδου. Στο προαναφερθέν παράδειγμα πρώτη θεωρείται η σύνδεση του a_{in} προς τον b_m .
- iii) Χρήση του τελευταίου βάρους της ομάδας συμμετρίας (S3): Αντίστοιχα, επιβάλλουμε το υπολογισθέν βάρος της τελευταίας σύνδεσης σε όλες τις υπόλοιπες της ίδιας ομάδας. Στο προαναφερθέν παράδειγμα θα επιβάλλαμε το βάρος της σύνδεσης (a_m, b_{out}) στη σύνδεση (a_{in}, b_m).

2) Μεταβολή βαρών κατά τη διάρκεια της οπισθόδρομης διάδοσης

- i) Διάδοση συμμετρικοποιημένου βάρους (S4): Μόλις υπολογιστεί το βάρος μιας σύνδεσης και πριν η οπισθόδρομη διάδοση προχωρήσει στη σύνδεση που προηγείται, επιβάλλουμε

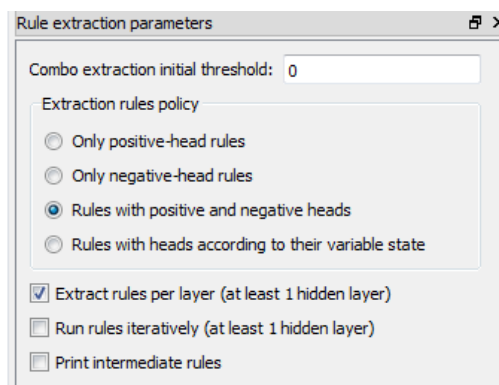
στην τρέχουσα σύνδεση τη μέση τιμή του υπολογισθέντος βάρους και αυτού της σύνδεσης που έπεται. Γίνεται κατανοητό πως με αυτόν τον αλγόριθμο τα βάρη των συνδέσεων προς την τελευταία στοιβάδα δε θα επηρεαστούν. Για παράδειγμα, έστω μια ομάδα συνδέσεων συμμετρίας $\sigma_1, \sigma_2, \sigma_3$, όπου σ_3 η σύνδεση προς κόμβο της στοιβάδας εξόδου, με τα αντίστοιχα βάρη $\beta_1, \beta_2, \beta_3$, όπως αυτά θα υπολογίζονταν χωρίς την επιβολή συμμετρικοποίησης, καθώς και τα βάρη $\beta'_1, \beta'_2, \beta'_3$, όπως αυτά υπολογίζονται με τον αλγόριθμο S5. Όπως και στην προηγούμενη περίπτωση θα ισχύει $\beta'_3 = \beta_3$. Στη συνέχεια, το β'_2 θα υπολογίζονταν ως $\beta'_2 = (\beta_2 + \beta'_3)/2$. Ομοίως και για την πρώτη σύνδεση θα ισχύει $\beta'_1 = (\beta_1 + \beta'_2)/2$.

ii) Διάδοση του προηγούμενου βάρους (S5): Ο αλγόριθμος αυτός δουλεύει όπως ακριβώς και ο προηγούμενος (S4) με την εξής όμως διαφορά: το βάρος της σύνδεσης που έπεται είναι αυτό που είχε υπολογιστεί **πριν να επιβληθεί η συμμετρικοποίηση**. Στο προηγούμενο παράδειγμα τα βάρη θα υπολογίζονταν ως $\beta'_3 = \beta_3$, $\beta'_2 = (\beta_2 + \beta_3)/2$ και $\beta'_1 = (\beta_1 + \beta_2)/2$. Γίνεται αντιληπτό ότι διαφορά μεταξύ των αλγορίθμων S4 και S5 θα υπάρχει μόνο σε νευρωνικά δίκτυα με τουλάχιστον 2 κρυφές στοιβάδες, δηλαδή τουλάχιστον 3 συνδέσεις σε κάθε ομάδα συμμετρίας.

iii) Διάδοση όλων των προηγούμενων βαρών (S6): Και αυτός ο αλγόριθμος, όπως ο S5, κάνει χρήση των **μη-συμμετρικοποιημένων βαρών**. Η διαφορά με τον προηγούμενο είναι ότι εδώ παίρνουμε τη μέση τιμή όλων των προηγούμενων μη-συμμετρικοποιημένων βαρών. Η εφαρμογή αυτού του αλγορίθμου στο προαναφερθέν παράδειγμα θα δώσει τα εξής αποτελέσματα: $\beta'_3 = \beta_3$, $\beta'_2 = (\beta_2 + \beta_3) / 2$, $\beta'_1 = (\beta_1 + \beta_2 + \beta_3)/3$.

3.3.7 Εκτέλεση και αξιολόγηση εξαχθέντων κανόνων

Με την τεχνική COMBO, λοιπόν, ως βασικό εργαλείο προχωράμε στην εξαγωγή κανόνων από το νευρωνικό δίκτυο. Όπως ειπώθηκε και προηγουμένως, υπάρχει η δυνατότητα να εξαγάγουμε τόσο θετικούς, όσο και αρνητικούς κανόνες, δηλαδή κανόνες με την κεφαλή τους σε κατάφαση ή άρνηση,



Σχήμα 3.11: Καρτέλα επιλογών για την εξαγωγή των κανόνων

αντίστοιχα. Δίνονται λοιπόν 3 έγκυρες επιλογές για τον τύπο των εξαγόμενων κανόνων:

- Εξαγωγή μόνο θετικών κανόνων
- Εξαγωγή μόνο αρνητικών κανόνων
- Εξαγωγή θετικών και αρνητικών κανόνων

Οι κανόνες που θα εξάγουμε θα αξιολογηθούν **συνολικά** ως προς την ακρίβεια και την πιστότητά τους. Υπενθυμίζουμε εδώ ότι η εξαγωγή των κανόνων γίνεται σε επίπεδο κόμβου. Ωστόσο, οι εξαχθέντες κανόνες ομαδοποιούνται ανά στοιβάδα.

Εκτός από την επιλογή του τύπου κανόνων, παρέχονται και 2 επιλογές που παίζουν καθοριστικό ρόλο τόσο στην εξαγωγή, όσο και στην εκτέλεση των κανόνων. Αυτές είναι:

- Εξαγωγή κανόνων ανά στοιβάδα: Υπάρχει η δυνατότητα να εξαχθούν κανόνες από τους κόμβους όλων των στοιβάδων, κρυφών και εξόδου. Αν αυτή δεν επιλεγεί, η εξαγωγή των κανόνων γίνεται μόνο από τους κόμβους της στοιβάδας εξαγωγής.
- Προσπέλαση κανόνων: Η χρήση αυτής της επιλογής προσομοιάζει την αντίστοιχη λειτουργία που υποχρεωτικά λαμβάνει μέρος στους κανόνες αιτιότητας του Πεδίου Ορισμού. Οδηγεί, δηλαδή, στην εισαγωγή των αποτελεσμάτων των κανόνων μιας στοιβάδας ως δεδομένα για τον υπολογισμό των κανόνων της επόμενης.

Φυσικά, αυτές οι επιλογές έχουν νόημα μόνο για νευρωνικά δίκτυα με τουλάχιστον μια κρυφή στοιβάδα. Ας δούμε, όμως, αναλυτικότερα την επίδρασή τους, καταρχάς στην εξαγωγή των κανόνων. Όπως προαναφέρθηκε, η επιλογή της εξαγωγής κανόνων ανά στοιβάδα οδηγεί στην εξαγωγή κανόνων από τους κόμβους όλων των στοιβάδων. Διαφορετικά, οι κανόνες εξάγονται μόνο από τη στοιβάδα εξόδου.

Μετασχηματισμός κανόνων: Στην περίπτωση που η εξαγωγή κανόνων είναι επιλεγμένη, χωρίς όμως να έχουμε επιλέξει και την προσπέλαση των κανόνων, είμαστε υποχρεωμένοι να εκμεταλλευτούμε την πληροφορία των εξαχθέντων κανόνων από όλες τις στοιβάδες χωρίς όμως να τους προσπελάσουμε, εκτελώντας μόνο τους κανόνες της στοιβάδας εξόδου. Πρέπει, λοιπόν, να μετασχηματίσουμε τους κανόνες όλων των κόμβων μιας μεταβλητής σε έναν μόνο. Η

διαδικασία αυτή γίνεται χωριστά για τους θετικούς και τους αρνητικούς κανόνες με την εξής λογική:

Έστω ένα νευρωνικό δίκτυο βασισμένο σε 3 μεταβλητές και με μια κρυφή στοιβάδα hl και τη στοιβάδα εξόδου ol. Στον παρακάτω πίνακα φαίνεται πως ακριβώς θα μετασχηματιστούν οι κανόνες της στοιβάδας εξόδου με βάση τους κανόνες της κρυφής στοιβάδας.

Κόμβος hl	Κανόνας hl	Κόμβος ol	Κανόνας ol	Μετασχηματισμένος κανόνας ol
hl_a	$a1 \leftarrow b0 \vee c0$	ol_a	$a2 \leftarrow b1$	$a2 \leftarrow b0$
hl_b	$b1 \leftarrow b0$	ol_b	$b2 \leftarrow c1$	$b2 \leftarrow b0$
hl_c	$c1 \leftarrow b0$	ol_c	$c2 \leftarrow a1 \wedge b1$	$c2 \leftarrow (b0 \vee c0) \wedge b0$

Πίνακας 3.2: Παράδειγμα μετασχηματισμού κανόνων

Τι ακριβώς συμβαίνει εδώ; Όπως έχουμε ήδη πει, κάθε κόμβος σε μια στοιβάδα αντιπροσωπεύει ουσιαστικά μια μεταβλητή και έχει στόχο να υπολογίσει την τιμή της σε συγκεκριμένη χρονική στιγμή (συγκεκριμένος κύκλος υπολογισμού). Έτσι, οι a0, a1 και a2 αντιπροσωπεύουν ουσιαστικά την ίδια μεταβλητή a. Ας θυμηθούμε, επίσης ότι η εξαγωγή κανόνων γίνεται βάσει των εισερχόμενων βαρών σε έναν κόμβο. Άρα, ο κανόνας που προκύπτει από τον κόμβο hl_a θα εξαρτάται από τις συνδέσεις των κόμβων εισόδου προς αυτόν (a0, b0, c0). Ομοίως και για τον κόμβο ol_a. Επειδή ο κάθε κόμβος φτιάχνει τον δικό του κανόνα για τη μεταβλητή που αντιπροσωπεύει (κεφαλή) με βάσει τις μεταβλητές που αντιπροσωπεύουν οι κόμβοι της προηγούμενης στοιβάδας μπορούμε να προχωρήσουμε σε έναν τέτοιο μετασχηματισμό ώστε τελικά **να εξαρτήσουμε τα αποτελέσματα των κόμβων εξόδου από τα δεδομένα εισαγωγής των κόμβων εισόδου.**

Εκτέλεση κανόνων: Στην περίπτωση που η προσπέλαση των κανόνων δεν έχει επιλεγεί εκτελούνται μόνο οι κανόνες της στοιβάδας εξόδου, μετασχηματισμένοι ή όχι. Διαφορετικά, αν δεν είναι επιλεγμένη η εξαγωγή ανά στοιβάδα, οι κανόνες της στοιβάδας εξόδου θα εκτελεστούν επαναληπτικά, με επανεισαγωγή αποτελεσμάτων, όπως συμβαίνει και με τους κανόνες αιτιότητας του Πεδίου Ορισμού, τόσες φορές, όσος είναι και ο αριθμός των στοιβάδων, κρυφών και εξόδου. Τέλος, αν και οι δύο επιλογές είναι ενεργές, υπολογίζονται τα αποτελέσματα των κανόνων, ξεκινώντας από αυτούς της πρώτης κρυφής στοιβάδας, τα οποία εισάγονται ως δεδομένα για τον υπολογισμό των αποτελεσμάτων των κανόνων της επόμενης.

3.4 Παράδειγμα εκτέλεσης

Για να γίνει περισσότερο κατανοητή η διαδικασία, αλλά και για να αποκτήσει ο αναγνώστης μια καλύτερη εικόνα της λειτουργίας και των αποτελεσμάτων που δίνει το λογισμικό, παρατίθεται ένα απλό παράδειγμα με εικόνες.

Στο παράδειγμα αυτό κατασκευάζεται ένα Πεδίο Ορισμού με 5 μεταβλητές και 3 κανόνες αιτιότητας, ενώ για τον Συλλογισμό έχουν οριστεί 2 κύκλοι υπολογισμών.

The screenshot shows the CARENNET - Causal Rules Extraction software interface. The window title is "CARENNET - Causal Rules Extraction". The interface is divided into several panels:

- Framework parameters:**
 - Domain creation parameters:**
 - Number of variables: 5
 - Number of rules: 3
 - Alphabetic names (a, b, c, ...) selected
 - Numbered names (x1, x2, x3, ...) unselected
 - Variables / rule: 4 ± 1
 - Exclusive use of variables per rule unselected
 - Exclusive use in head unselected (set to 2)
 - Use negated variables checked
 - Total negated variables: 30%
 - Allow variable in body as head unselected
 - Negated heads: 50%
 - Neural network parameters:**
 - Learning parameters:**
 - Select for training and testing: 100%
 - From selected, keep for testing: 40%
 - Include intermediate values checked
 - Nodes per layer: 0
- Output:**
 - Rule_2: +a <-- +b ^ -d
 - Rule_3: -b <-- +a ^ +d ^ +e
 - Rule_1: +e <-- +a ^ -b ^ +d
 - Initial states (01-32):
 - 01: +a +b +c +d -e
 - 02: -a +b -c -d -e
 - 03: -a +b -c +d -e
 - 04: -a -b +c +d +e
 - 05: -a -b +c +d -e
 - 06: -a -b -c -d +e
 - 07: +a +b +c -d -e
 - 08: -a +b +c -d -e
 - 09: +a +b +c -d +e
 - 10: +a +b -c -d +e
 - 11: -a -b +c -d -e
 - 12: +a +b -c +d -e
 - 13: -a -b -c -d -e
 - 14: -a +b +c +d +e
 - 15: -a -b +c -d +e
 - 16: +a -b -c -d +e
 - 17: -a +b +c -d +e
 - 18: +a +b +c +d +e
 - 19: -a -b -c +d +e
 - 20: +a -b -c +d -e
 - 21: -a -b -c +d -e
 - 22: +a -b +c -d -e
 - 23: +a -b +c -d +e
 - 24: +a -b +c +d -e
 - 25: +a -b -c +d +e
 - 26: -a +b -c +d +e
 - 27: -a +b -c -d +e
 - 28: +a +b -c -d -e
 - 29: +a -b +c +d +e
 - 30: +a -b -c -d -e
 - 31: +a +b -c +d +e
 - 32: -a +b +c +d -e
 - Negative Variables:80 Total Variables:160 Ratio:50% N

Σχήμα 3.12: Κατασκευή Πεδίου Ορισμού (κανόνες Rule_2, Rule_1, Rule_3) και εύρεση όλων των δυνατών αρχικών καταστάσεων (32 αρχικές καταστάσεις). Διευκρινίζεται ότι στις αρχικές καταστάσεις με κόκκινο χρώμα και το πρόσημο (-) γράφονται οι μεταβλητές που αρχικοποιούνται ως ψευδείς (τιμή 0 ή false).

Exclusive use of variables per rule

Exclusive use in head 2

Use negated variables

Total negated variables: 30%

Allow variable in body as head

Negated heads: 50%

```

27: -a +b -c -d +e
28: +a +b -c -d -e
29: +a -b +c +d +e
30: +a -b -c -d -e
31: +a +b -c +d +e
32: -a +b +c +d -e
Negative Variables:80 Total Variables:1

#Variables: 5

#Training: 20
00011 00011 00011
10101 10101 10101
00100 00100 00100
11010 11010 11010
10110 10111 10111
11011 10011 10011
01101 11101 11101
00010 00010 00010
01110 01110 01110
00000 00000 00000
01111 01111 01111
10111 10111 10111
10010 10011 10011
01011 01011 01011
11110 11110 11110
10100 10100 10100
01001 11001 11001
01100 11100 11100
11001 11001 11001
11100 11100 11100

#Testing: 12
01000 11000 11000
11101 11101 11101
00101 00101 00101
00110 00110 00110
11000 11000 11000
00001 00001 00001
11111 10111 10111
00111 00111 00111
01010 01010 01010
10000 10000 10000
10001 10001 10001
10011 10011 10011

```

Neural network parameters

Learning Weight symmetry Current item

Learning parameters

Select for training and testing: 100%

From selected, keep for testing: 40%

Include intermediate values

Nodes per layer: 0

Include bias nodes Value: 1

Create nodes per variable state

Number of layers

According to 'Reasoning' iterations

Custom (hidden + output) 1

Weight initialization: (-1 , 1)

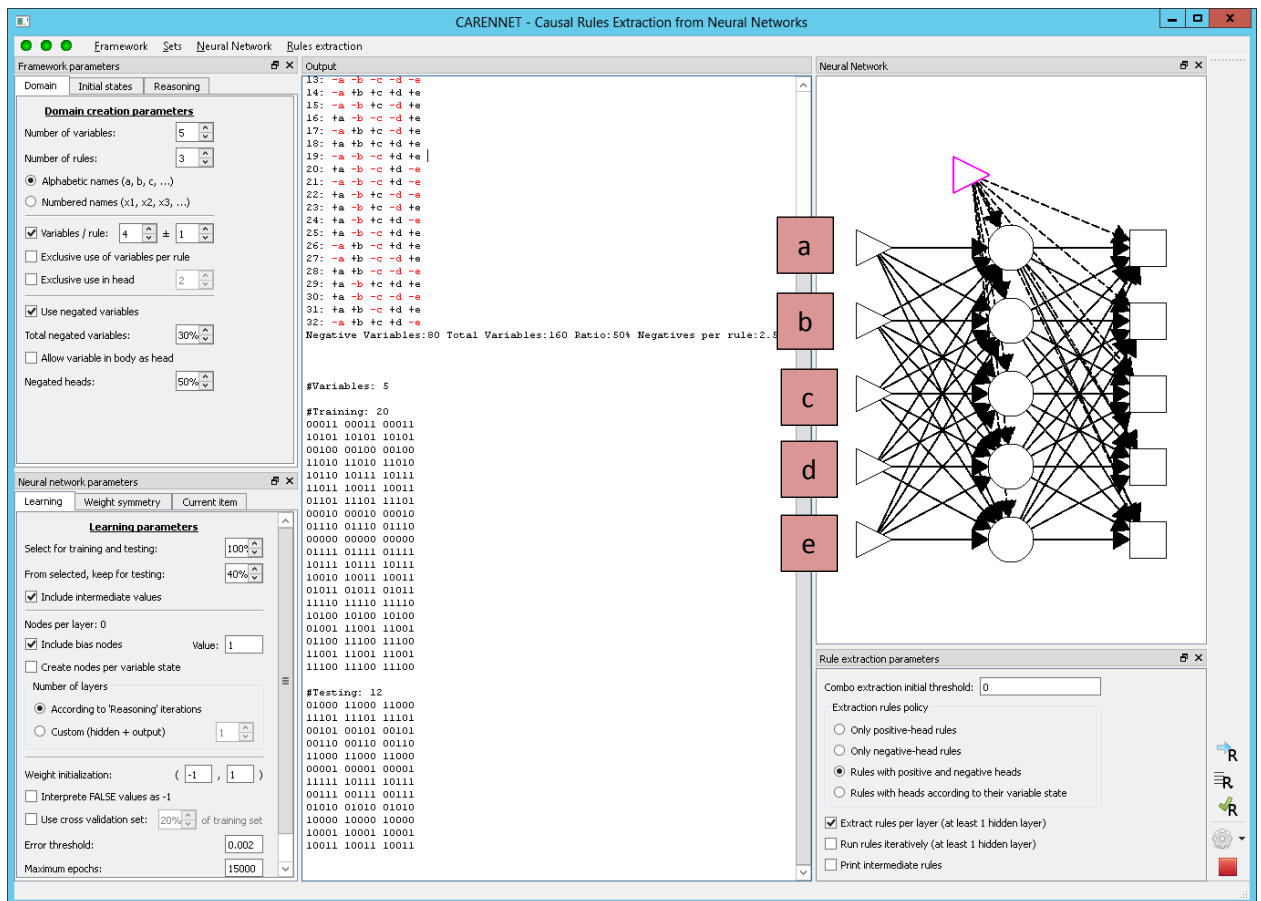
Interpret FALSE values as -1

Use cross validation set: 20% of training set

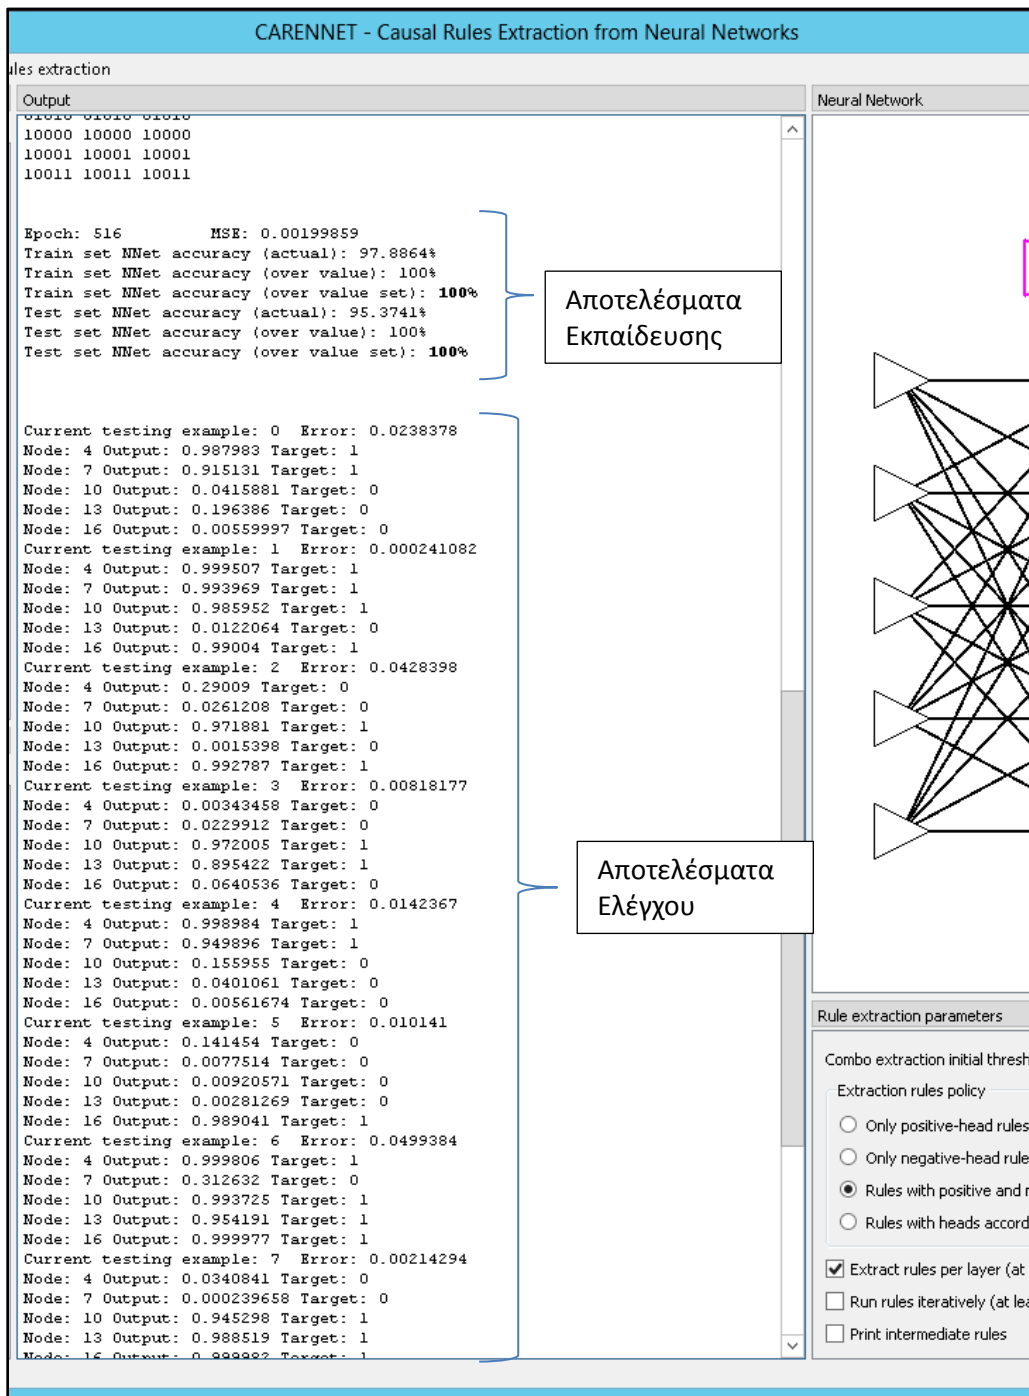
Error threshold: 0.002

Maximum epochs: 15000

Σχήμα 3.13: Οι 32 αρχικές καταστάσεις μετατράπηκαν σε παραδείγματα, δηλαδή σε ομάδες τιμών για την αρχική κατάσταση (πρώτη στήλη), μετά τον πρώτο κύκλο υπολογισμών (δεύτερη στήλη) και μετά τον δεύτερο κύκλο υπολογισμών (τρίτη στήλη). Σε κάθε ομάδα τιμών, οι τιμές είναι διατεταγμένες σύμφωνα με τη σειρά των μεταβλητών: ο πρώτος αριθμός αντιστοιχεί στη μεταβλητή a, ο δεύτερος στην b κ.ο.κ. Η τιμή μηδέν αντιστοιχεί σε ψευδή τιμή (false), ενώ η τιμή 1 σε αληθή (true). Τα παραδείγματα, επίσης, έχουν μοιραστεί με τυχαίο τρόπο σε εκπαίδευσης (20) και ελέγχου (12 ή το 40% των 32 συνολικά παραδειγμάτων).



Σχήμα 3.14: Κατασκευή του νευρωνικού δικτύου (παράθυρο πάνω δεξιά), βάσει των τιμών των παραμέτρων που έχουν οριστεί από τον χρήστη. Εδώ, ο αριθμός των στοιβάδων ακολουθεί τον αριθμό κύκλων υπολογισμών του Συλλογισμού, ενώ έχει ζητηθεί και κατασκευή κόμβου bias (τρίγωνο με χρώμα ματζέντα). Οι συνδέσεις του κόμβου bias προς τους άλλους κόμβους ζωγραφίζονται με διακεκομμένη γραμμή. Κάθε γραμμή κόμβων αντιστοιχεί και σε μια μεταβλητή. Η αντιστοιχία ακολουθεί τη σειρά των κόμβων, από τον πρώτο (a) στον τελευταίο (e). Ακόμα, στο συγκεκριμένο παράδειγμα εκτέλεσης της πειραματικής διαδικασίας CARENNET όπου δεν έχουμε αριθμό στοιβάδων ορισμένων από τον χρήστη, κάθε στοιβάδα αντιστοιχεί και σε έναν κύκλο υπολογισμών, ενώ η στοιβάδα εισόδου αντιστοιχεί στην ομάδα αρχικών τιμών.



Σχήμα 3.15: Αποτελέσματα εκπαίδευσης και ελέγχου του νευρωνικού δικτύου με την εκτέλεση των αντίστοιχων παραδειγμάτων. Τα αποτελέσματα ελέγχου εμφανίζονται λεπτομερώς για κάθε παράδειγμα. Οι κόμβοι 4, 7, 10, 13 και 16 είναι οι κόμβοι εξόδου. Στον κόμβο bias δίνεται ο αριθμός ταυτότητας 1, ενώ η αρίθμηση των κόμβων συνεχίζεται από αριστερά προς δεξιά και από πάνω προς τα κάτω. Η αρίθμηση συνεχίζεται για τις συνδέσεις των κόμβων, με την ίδια σειρά.

```

+Rule_aOut: 52 atom(s) 24 term(s) 5 variable(s)
-Rule_aOut: 68 atom(s) 32 term(s) 5 variable(s)
+Rule_bOut: 50 atom(s) 24 term(s) 5 variable(s)
-Rule_bOut: 88 atom(s) 42 term(s) 5 variable(s)
+Rule_cOut: 1 atom(s) 1 term(s) 1 variable(s)
-Rule_cOut: 1 atom(s) 1 term(s) 1 variable(s)
+Rule_dOut: 77 atom(s) 36 term(s) 5 variable(s)
-Rule_dOut: 58 atom(s) 29 term(s) 5 variable(s)
+Rule_eOut: 13 atom(s) 5 term(s) 4 variable(s)
-Rule_eOut: 13 atom(s) 7 term(s) 4 variable(s)

```

**Χαρακτηριστικά
Εξαχθέντων κανόνων**

```

Rule_aOut: +aOut <-- +(+(-d) V +(ta A +b A +e)) A +(+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) V
+((+(-d) V +(ta A +b A +e)) A +(+(-b) A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) V
+((+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) A +(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) V
Rule_aOut: -aOut <-- +(-(+(-d) A -a) V +(td A -b) V +(td A -e)) A -(+(-b A -a) V +(-b A +c A +d A +e)) V
+(-(+(-d) A -a) V +(td A -b) V +(td A -e)) A -(+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) V
+(-(+(-b A -a) V +(-b A +c A +d A +e)) A -(+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A +(+(-
+(-(-b A -a) V +(-b A +c A +d A +e)) A -(+(-b A -a) V +(-b A -d) V +(-b A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A +(+(-
Rule_bOut: +bOut <-- +(-(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) A +(+(-b) V +(ta A -c) V +(ta A
+(-(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) A -(+(-d) V +(ta A +b A +e)) A -(+(-c)) A +(+(-e))
+((+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) A -(+(-d) V +(ta A +b A +e)) A -(+(-c)) A +(+(-e))
Rule_bOut: -bOut <-- +(+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A -(+(-b A -a) V +(-b A +
+((+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A +(+(-d) A -a) V +(td A -b) V +(td A -e)) V
+((+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A +(+(-c)) V
+((+(-b A -a) V +(-b A +c A +d A +e)) A +(+(-d) A -a) V +(td A -b) V +(td A -e)) V
+(-(+(-b A -a) V +(-b A +c A +d A +e)) A +(+(-c)) V +(-(+(-b A -a) V +(-b A +c A +d A +e)) A -(+(-e))
Rule_cOut: +cOut <-- +(-(+(-c))
Rule_cOut: -cOut <-- +(+(-c))
Rule_dOut: +dOut <-- +(-(+(-d) V +(ta A +b A +e)) A +(+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) V
+(-(+(-d) V +(ta A +b A +e)) A +(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) V
+(-(+(-d) V +(ta A +b A +e)) A +(+(-c)) V
+(-(+(-d) V +(ta A +b A +e)) A -(+(-e)) V
+((+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) A +(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) A
+((+(-b) V +(ta A -c) V +(ta A -d) V +(ta A -e)) A +(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e)) A
Rule_dOut: -dOut <-- +(+(-d) A -a) V +(td A -b) V +(td A -e)) A -(+(-b A -a) V +(-b A +c A +d A +e)) V
+((+(-d) A -a) V +(td A -b) V +(td A -e)) A -(+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) V
+((+(-d) A -a) V +(td A -b) V +(td A -e)) A -(+(-c)) A +(+(-e)) V
+(-(+(-b A -a) V +(-b A +c A +d A +e)) A -(+(-b A -a) V +(td A -d) V +(td A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e)) A -(+(-
Rule_eOut: +eOut <-- +(+(-e)) V +(+(-b A +a A +d) V +(-b A +a A +e) V +(-b A +d A +e) V +(ta A +d A +e))
Rule_eOut: -eOut <-- +(-(+(-e)) A -(+(-b A -a) V +(-b A -d) V +(-b A -e) V +(-a A -d) V +(-a A -e) V +(-d A -e))

```

**Εξαχθέντες
κανόνες**

Σχήμα 3.16: Εξαγωγή κανόνων. Στην περιοχή πληροφοριών τυπώνονται πληροφορίες για τα χαρακτηριστικά του κάθε κανόνα αιτιότητας (αριθμός ατόμων, όρων και μεταβλητών), ενώ στη συνέχεια τυπώνονται οι εξαχθέντες κανόνες. Στο συγκεκριμένο παράδειγμα πειραματικής διαδικασίας επιλέχθηκε η εξαγωγή κανόνων τόσο με θετική, όσο και με αρνητική κεφαλή. Έτσι π.χ. ο Rule_aOut (δηλαδή η ομάδα κανόνων που αντιστοιχούν στη μεταβλητή a) αποτελείται από 2 κανόνες, έναν με κεφαλή +aOut και έναν με κεφαλή -aOut.

```

Train set accuracy (over value): 96%
Train set accuracy (over value set): 80%
Test set accuracy (over value): 96.6667%
Test set accuracy (over value set): 83.3333%
-----
Train set fidelity (actual): 46%
Train set fidelity (over value): 96%
Train set fidelity (over value set): 80%
Test set fidelity (actual): 53.3333%
Test set fidelity (over value): 96.6667%
Test set fidelity (over value set): 83.3333%
<

```

Σχήμα 3.17: Αξιολόγηση εξαχθέντων κανόνων αιτιότητας. Τυπώνονται συνοπτικά τα αποτελέσματα τόσο της ακρίβειας, όσο και της πιστότητας, χωριστά για τα παραδείγματα εκπαίδευσης και ελέγχου.

Κεφάλαιο 4

Σχεδιασμός και εκτέλεση πειραμάτων

Στο κεφάλαιο αυτό παρουσιάζεται ο σχεδιασμός και οι στόχοι των πειραμάτων που εκτελέστηκαν στο πλαίσιο της παρούσας μεταπτυχιακής διατριβής. Συγκεκριμένα, γίνεται αναφορά στις τιμές των παραμέτρων που επιλέχθηκαν να παραμείνουν σταθερές καθώς και στις τιμές εκείνων που αποφασίστηκε να διερευνηθούν. Τέλος διευκρινίζεται ο τρόπος που εκτελέστηκαν τα πειράματα καθώς και οι πληροφορίες που καταγράφηκαν σε αρχεία ώστε να αναλυθούν στη συνέχεια.

4.1 Τιμές σταθερών παραμέτρων

Όπως φάνηκε στο προηγούμενο κεφάλαιο, η πειραματική διαδικασία CARENNET είναι αρκετά σύνθετη, με πολλές παραμέτρους να επηρεάζουν τα επιμέρους στάδια (κατασκευή Πεδίου Ορισμού, αρχικοποίηση τιμών, κατασκευή και εκτέλεση νευρωνικού δικτύου κλπ). Θα ήταν

αδύνατο στο πλαίσιο μιας μεταπτυχιακής διατριβής να εξεταστούν όλοι οι συνδυασμοί των διαθέσιμων από το λογισμικό παραμέτρων, όχι μόνο λόγω του συνεπαγόμενου μεγέθους της διατριβής, αλλά και των απαιτήσεων σε χρόνο και υπολογιστικούς πόρους (μνήμη και ισχύ). Έτσι, θεωρήθηκε αναγκαία μια επιλογή παραμέτρων απ' όλα τα στάδια της πειραματικής διαδικασίας, δίνοντας προτεραιότητα σε αυτές που αφορούν τόσο στον Συλλογισμό και στην εξαγωγή κανόνων, όσο και στις καινοτομίες που εφαρμόζονται εδώ.

Πριν προχωρήσουμε σε μια λεπτομερέστερη παρουσίαση των προς διερεύνηση παραμέτρων, θα ήταν καλό να αναφερθούμε στις τιμές εκείνων που αποφασίστηκε να παραμείνουν αμετάβλητες καθ' όλη τη διάρκεια των πειραμάτων. Οι τιμές των σταθερών αυτών παραμέτρων παρατίθενται παρακάτω, ομαδοποιημένες ανά στάδιο της διαδικασίας.

4.1.1 Πεδίο Ορισμού και αρχικές καταστάσεις

Παράμετρος	Τιμή
Αριθμός μεταβλητών	11
Αριθμός κανόνων	4
Αριθμός μεταβλητών ανά κανόνα	4 ± 1
Χρήση μεταβλητών σε άρνηση	ΝΑΙ
Αποκλειστική χρήση μεταβλητών ανά κανόνα	ΟΧΙ
Αποκλειστική χρήση μεταβλητών ως κεφαλές	ΟΧΙ
Συνολικό ποσοστό μεταβλητών σε άρνηση	30%
Ποσοστό κεφαλών σε άρνηση	50%
Χρήση ίδιων μεταβλητών σε σώμα και κεφαλή	ΟΧΙ
Χρήση αρνητικών τιμών	ΝΑΙ
Ποσοστό αρνητικών τιμών	50%

Πίνακας 4.1: Τιμές παραμέτρων του Πεδίου Ορισμού και των αρχικών καταστάσεων

Ο παραπάνω συνδυασμός τιμών επιλέχθηκε με κριτήριο την επίτευξη του μεγαλύτερου δυνατού αριθμού παραδειγμάτων, βάσει των οποίων θα εκπαιδεύονταν το δίκτυο και θα αξιολογούνταν οι εξαχθέντες κανόνες αιτιότητας.

4.1.2 Νευρωνικό δίκτυο

Παράμετρος	Τιμή
Ποσοστό παραδειγμάτων προς χρήση	100%
Ποσοστό, επί των επιλεγμένων, παραδειγμάτων για έλεγχο	40%
Καταγραφή ενδιάμεσων ομάδων τιμών	ΝΑΙ
Τιμή bias κόμβου, όταν αυτός χρησιμοποιείται	1
Εύρος αρχικοποίησης βαρών	(-1, 1)
Ερμηνεία ψευδών τιμών ως -1	ΟΧΙ
Χρήση cross-validation set	ΟΧΙ
Ποσοστό κεφαλών σε άρνηση	50%
Κατώφλι σφάλματος	0.002
Μέγιστος αριθμός Εποχών	15000
Ρυθμός μάθησης	1

Πίνακας 4.1: Τιμές παραμέτρων κατασκευής και εκπαίδευσης του νευρωνικού δικτύου

Συνοπτικά, αναφέρουμε ότι επιλέγονται όλα τα διαθέσιμα παραδείγματα. Από αυτά, το 60% χρησιμοποιείται για την εκπαίδευση του νευρωνικού δικτύου και το υπόλοιπο 40% για τον έλεγχο. Τα ίδια παραδείγματα χρησιμοποιούνται για την αξιολόγηση των εξαχθέντων κανόνων αιτιότητας.

4.2 Παράμετροι προς διερεύνηση

Ακολουθεί η παράθεση των παραμέτρων που επιλέχθηκαν, με τις αντίστοιχες τιμές και κωδικούς τους, ομαδοποιημένες ανά στάδιο. Στην ανάλυση των αποτελεσμάτων που θα ακολουθήσει θα αναφερόμαστε στις παραμέτρους και τις αντίστοιχες τιμές τους με τους αντίστοιχους κωδικούς.

4.2.1 Παράμετροι Συλλογισμού

- **Αριθμός κύκλων υπολογισμών:** Εξετάζεται η αποτελεσματικότητα της πειραματικής διαδικασίας με χρήση διαφορετικού αριθμού κύκλων υπολογισμών. Οι τιμές που εξετάζονται είναι 1, 2 και 3 κύκλοι υπολογισμών. **Κωδικοί - τιμές:**
 - **IT1:** Χρήση ενός κύκλου υπολογισμών
 - **IT2:** Χρήση δύο κύκλων υπολογισμών

- **IT3:** Χρήση τριών κύκλων υπολογισμών
- **Τρόπος συλλογισμού:** Εξετάζεται η αποτελεσματικότητα της πειραματικής διαδικασίας τόσο για τον αυστηρό όσο και για τον κανονικό συλλογισμό. **Κωδικοί - τιμές:**
 - **S:** αυστηρός τρόπος συλλογισμού
 - **D:** κανονικός τρόπος συλλογισμού

4.2.2 Παράμετροι νευρωνικού δικτύου

- **Τύπος συμμετρικοποίησης:** Λόγω έλλειψης χρόνου, εξετάζονται μόνο 2 τύποι συμμετρικοποίησης: ο S1 (μεταβολή βαρών στο τέλος της οπισθόδρομης διάδοσης με χρήση της μέσης τιμής των βαρών της ομάδας συμμετρίας) και ο S4 (Μεταβολή βαρών κατά τη διάρκεια της οπισθόδρομης διαδικασίας με διάδοση συμμετρικοποιημένου βάρους). Οι συγκεκριμένοι τύποι επιλέχθηκαν γιατί φάνηκε σε προκαταρκτικά πειράματα ότι δίνουν τα πιο ενδιαφέροντα αποτελέσματα στην κατηγορία τους (στο τέλος και κατά τη διάρκεια της οπισθόδρομης διάδοσης). Εννοείται ότι εξετάζεται και η μη εφαρμογή της συμμετρικοποίησης βαρών. **Κωδικοί - τιμές:**
 - **S0:** μη εφαρμογή συμμετρικοποίησης βαρών
 - **S1:** εφαρμογή του τύπου συμμετρικοποίησης S1
 - **S4:** εφαρμογή του τύπου συμμετρικοποίησης S4
- **Κόμβος bias:** Εξετάζεται η αποτελεσματικότητα τόσο του νευρωνικού δικτύου όσο και της εξαγωγής κανόνων με τη χρήση ή όχι κόμβου bias στο νευρωνικό δίκτυο. **Κωδικοί - τιμές:**
 - **B0:** μη χρήση κόμβου bias
 - **B1:** χρήση κόμβου bias

- **Κόμβοι ανά τιμή μεταβλητής:** Επειδή η επιλογή αυτή φάνηκε να οδηγεί σε καλά εκπαιδευμένα νευρωνικά δίκτυα, αλλά αποδείχθηκε προβληματική για την εξαγωγή κανόνων, αποφασίστηκε η διερεύνησή της μόνο για την ποιότητα των εκπαιδευμένων δικτύων και όχι για την ποιότητα των εξαγόμενων κανόνων. Εξετάζεται, λοιπόν, η αποτελεσματικότητα των νευρωνικών δικτύων με και χωρίς τη χρήση αυτής της επιλογής. **Κωδικοί - τιμές:**
 - **PVS0:** μη χρήση της επιλογής κόμβων ανά τιμή μεταβλητής
 - **PVS1:** χρήση της επιλογής κόμβων ανά τιμή μεταβλητής
- **Προσαρμοσμένος αριθμός στοιβάδων:** Όπως εξηγήθηκε προηγουμένως, ο αριθμός των στοιβάδων καθορίζεται κανονικά από τον αριθμό των κύκλων υπολογισμών του Συλλογισμού. Υπάρχει όμως η δυνατότητα να καθοριστεί από το χρήστη (προσαρμοσμένος αριθμός). Φάνηκε ενδιαφέρον να εξετάσουμε τις εξής περιπτώσεις:
 - Χρήση μιας μόνο στοιβάδας (εξόδου)
 - Χρήση IT-1 αριθμού στοιβάδων, όπου IT ο αριθμός των κύκλων υπολογισμών του Συλλογισμού
 - Χρήση IT+1 αριθμού στοιβάδων, όπου IT ο αριθμός των κύκλων υπολογισμών του Συλλογισμού

Εννοείται ότι αν κάποια από τις περιπτώσεις δεν είχε νόημα για ένα συγκεκριμένο αριθμό κύκλων υπολογισμών τότε δεν πραγματοποιούνταν.

Κωδικοί – τιμές: Ο κωδικός των προσαρμοσμένων αριθμών στοιβάδων σχηματίζεται με τα γράμματα **CL** ακολουθούμενο από τον αριθμό των προσαρμοσμένων στοιβάδων που επιθυμούμε κάθε φορά. Στην περίπτωση που δε θέλουμε να χρησιμοποιήσουμε προσαρμοσμένο αριθμό στοιβάδων, αλλά να είμαστε σύμφωνοι με τον αριθμό των κύκλων υπολογισμών χρησιμοποιούμε το **CL0**. Για τις 3 διαφορετικές τιμές κύκλων υπολογισμών εξετάζονται οι παρακάτω αριθμοί προσαρμοσμένων στοιβάδων:

- **IT1:** CL0, CL2

- **IT2:** CL0, CL1, CL3
- **IT3:** CL0, CL1, CL2, CL4

4.2.3 Παράμετροι εξαγωγής κανόνων

- **Τύποι εξαγόμενων κανόνων:** Όπως αναφέρθηκε προηγουμένως, διατίθενται 3 έγκυρες επιλογές για τους προς εξαγωγή κανόνες. **Κωδικοί – τιμές:**
 - **P0_N1:** Εξαγωγή και αξιολόγηση μόνο αρνητικών κανόνων
 - **P1_N0:** Εξαγωγή και αξιολόγηση μόνο θετικών κανόνων
 - **P1_N1:** Εξαγωγή και αξιολόγηση θετικών και αρνητικών κανόνων
- **Εξαγωγή κανόνων ανά στοιβάδα:** Εξετάζεται η ποιότητα των εξαγόμενων κανόνων με τη χρήση ή όχι της εξαγωγής κανόνων ανά στοιβάδα. **Κωδικοί – τιμές:**
 - **RPL0:** μη χρήση της επιλογής εξαγωγής κανόνων ανά στοιβάδα. Οι κανόνες εξάγονται μόνο από τη στοιβάδα εξόδου
 - **RPL1:** εξάγονται κανόνες από τους κόμβους κάθε στοιβάδας
- **Προσπέλαση κανόνων:** Εξετάζεται η ποιότητα των εξαγόμενων κανόνων με τη χρήση ή όχι της προσπέλασης των κανόνων. **Κωδικοί – τιμές:**
 - **RIT0:** δε γίνεται χρήση αυτής της επιλογής
 - **RIT1:** Οι κανόνες αξιολογούνται με τη χρήση προσπέλασης

Διευκρινίζεται εδώ ότι μόνο 3 από τους 4 πιθανούς συνδυασμούς των δύο παραπάνω παραμέτρων έχουν νόημα σε κάθε περίπτωση: **RPL0_RIT1, RPL1_RIT0, RPL1_RIT1.**

Επίσης, υπενθυμίζεται ότι οι συνδυασμοί RPL1_RIT0 και RPL1_RIT1 έχουν νόημα μόνο για νευρωνικά δίκτυα με τουλάχιστον μια κρυφή στοιβάδα.

4.3 Πειραματική διάταξη και παραγόμενα αρχεία

Όπως έχει αναφερθεί επανειλημμένως, βασικός στόχος της παρούσας μεταπτυχιακής διατριβής είναι αφενός να διερευνήσει συνδυασμούς τιμών παραμέτρων στο πλαίσιο της πειραματικής διαδικασίας CARENNET και αφετέρου να καταλήξει στον βέλτιστο, σε αυτόν δηλαδή που θα δίνει ακριβέστερους κανόνες αιτιότητας, όσο το δυνατόν αποτελεσματικότερα. Γίνεται κατανοητό ότι οι πιθανοί συνδυασμοί προς διερεύνηση αυξάνονται γεωμετρικά με τον αριθμό των τιμών των παραμέτρων προς διερεύνηση.

Για τις ανάγκες της διερεύνησης και στατιστικής ανάλυσης όλων των επιλεχθέντων παραμέτρων καταλήξαμε στο εξής σχήμα:

Στο στάδιο του Συλλογισμού έχουμε 6 δυνατούς συνδυασμούς: **IT1_S, IT1_D, IT2_S, IT2_D, IT3_S** και **IT3_D**. Για κάθε έναν από αυτούς τους συνδυασμούς εκτελούμε **5** πειράματα, π.χ. **IT2_S_01, IT2_S_02, IT2_S_03, IT2_S_04, IT2_S_05**. Σε κάθε πείραμα παράγεται ένα Πεδίο Ορισμού με τις αρχικές καταστάσεις του σύμφωνα με τους αντίστοιχους προς διερεύνηση συνδυασμούς τιμών (π.χ. 2 κύκλοι υπολογισμών και αυστηρός Συλλογισμός). Το Πεδίο Ορισμού με τις αντίστοιχες τιμές αρχικοποίησης καταγράφονται για λόγους αναφοράς, αλλά όχι μόνο, όπως θα φανεί στη συνέχεια, σε ένα ομώνυμο .sys αρχείο, π.χ. **IT2_S_03.sys**.

Για κάθε ένα πείραμα από τα παραπάνω, δηλαδή για κάθε παραγόμενο Πεδίο Ορισμού εκτελούμε **5** πειράματα για κάθε δυνατό συνδυασμό τιμών των παραμέτρων του νευρωνικού δικτύου. Για παράδειγμα, σύμφωνα με αυτά που έχουμε πει, για ένα παράδειγμα Συλλογισμού τύπου IT1_D, θα έχουμε του εξής 8 συνδυασμούς τιμών παραμέτρων νευρωνικού δικτύου: **S0_B0_PVS0_CL0, S0_B0_PVS0_CL2, S0_B0_PVS1_CL0, S0_B0_PVS1_CL2, S0_B1_PVS0_CL0, S0_B1_PVS0_CL2, S0_B1_PVS1_CL0** και **S0_B1_PVS1_CL2**. Όπως είπαμε, για κάθε έναν συνδυασμό θα τρέξουμε **5** διαφορετικά πειράματα, π.χ. **S0_B0_PVS0_CL2_01, S0_B0_PVS0_CL2_02, S0_B0_PVS0_CL2_03, S0_B0_PVS0_CL2_04** και **S0_B0_PVS0_CL2_05**. Για κάθε τέτοιο πείραμα κατασκευάζεται ένα νευρωνικό δίκτυο σύμφωνα με τις αντίστοιχες τιμές των παραμέτρων. Για παράδειγμα, ο συνδυασμός S0_B0_PVS0_CL2 θα κατασκευάσει ένα νευρωνικό δίκτυο χωρίς συμμετρία (S0), χωρίς κόμβο bias (B0), χωρίς κόμβους ανά τιμή μεταβλητής (PVS0) και με 2 στοιβάδες, 1 κρυφή και 1 εξόδου (CL2).

Σε κάθε παράδειγμα, πριν κατασκευαστεί το νευρωνικό δίκτυο, επιλέγονται πρώτα τυχαία τα παραδείγματα που θα συμμετέχουν στην εκπαίδευση και τον έλεγχο του νευρωνικού δικτύου

και αποθηκεύονται στο ομώνυμο .sets αρχείο, ενώ το νευρωνικό δίκτυο αποθηκεύεται στο ομώνυμο .net αρχείο. Για παράδειγμα, τα σύνολα εκπαίδευσης του πειράματος S0_B0_PVS0_CL2_04 θα αποθηκευτούν στο S0_B0_PVS0_CL2_04.sets, ενώ το κατασκευασμένο νευρωνικό δίκτυο θα αποθηκευτεί στο S0_B0_PVS0_CL2_04.net.

Στη συνέχεια το νευρωνικό δίκτυο εκπαιδεύεται και αξιολογείται. Τα αποτελέσματα αυτά καταγράφονται σε ένα κοινό αρχείο, το nnet.results, σε μια γραμμή για κάθε νευρωνικό δίκτυο, η οποία περιέχει τις παρακάτω πληροφορίες:

Κωδικός πειράματος Πεδίου Ορισμού, Κωδικός πειράματος νευρωνικού δικτύου, Αριθμός Εποχών που χρειάστηκαν για την εκπαίδευση, Σφάλμα με το οποίο ολοκληρώθηκε η εκπαίδευση, Ακρίβεια νευρωνικού δικτύου στα παραδείγματα εκπαίδευσης και Ακρίβεια νευρωνικού δικτύου στα παραδείγματα ελέγχου.

Domain	NNet	Epochs	MSE	Tr .Acc . %	Te .Acc . %
IT1D_01	S0_B0_PVS0_CL0_01	15000	0.0114	96.9081	94.5055

Πίνακας 4.2: Παράδειγμα εγγραφής στο αρχείο nnet.results

Για κάθε εκπαιδευμένο νευρωνικό δίκτυο, εκτός από τις περιπτώσεις που κατασκευάστηκαν κόμβοι ανά τιμή μεταβλητής (PVS1), γίνεται εξαγωγή κανόνων με όλους τους δυνατούς συνδυασμούς. Για παράδειγμα, στην περίπτωση που έχουμε Συλλογισμό με 1 κύκλο υπολογισμών (IT1), οι δυνατοί συνδυασμοί είναι **P0_N1_RPL1_RIT0**, **P1_N0_RPL1_RIT0** και **P1_N1_RPL1_RIT0**. Τα αποτελέσματα της κάθε εξαγωγής καταγράφονται σε ένα κοινό αρχείο, το rules.results, ως μια εγγραφή. Οι πληροφορίες που καταγράφονται είναι η εγγραφή του νευρωνικού δικτύου από το οποίο έγινε η εξαγωγή των κανόνων αιτιότητας, όπως περιγράφηκε παραπάνω, καθώς και πληροφορίες για τους ίδιους τους κανόνες όπως ο συνδυασμός τιμών που χρησιμοποιήθηκε, η ακρίβεια και πιστότητα βάσει των παραδειγμάτων εκπαίδευσης και ελέγχου και τέλος ο αριθμός των ατόμων, όρων και μεταβλητών ανά εξαχθέντα κανόνα.

Συμπεραίνεται λοιπόν ότι για κάθε συνδυασμό τιμών παραμέτρων νευρωνικού δικτύου και εξαγωγής κανόνων αιτιότητας θα εκτελεστούν 25 διαφορετικά πειράματα, τα οποία μάλιστα θα προκύπτουν από 5 διαφορετικά Πεδία Ορισμού. Θεωρούμε ότι ο αριθμός αυτός των δειγμάτων με χρήση μη – παραμετρικής ανάλυσης διασποράς των επιμέρους μεταβλητών είναι ικανός να μας δείξει αν υπάρχει συνάφεια μεταξύ των αποτελεσμάτων που προκύπτουν από την εκτέλεση

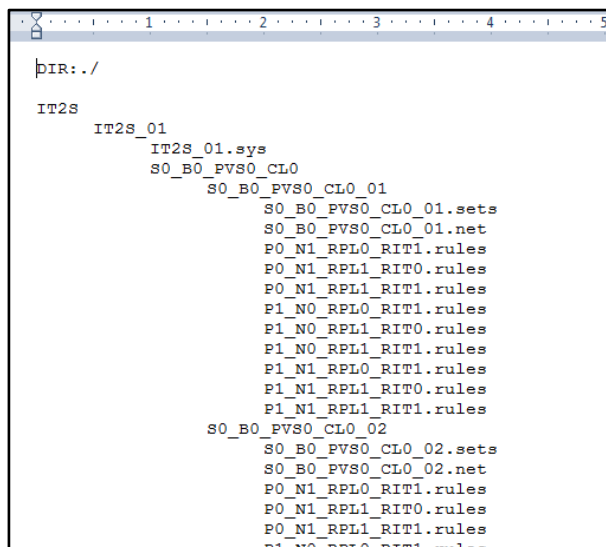
της πειραματικής διαδικασίας για τις ίδιες τιμές παραμέτρων. Έτσι θα βεβαιωθούμε σε πρώτη φάση ότι ένας συγκεκριμένος συνδυασμός τιμών δίνει την ίδια ποιότητα αποτελεσμάτων. Στην περίπτωση που θα ισχύει αυτό, θα μπορούμε να δουλέψουμε ευκολότερα με τις μέσες τιμές των μετρικών, όπως αυτές θα προκύπτουν από τα εκτελεσθέντα πειράματα, ώστε να αναζητήσουμε το βέλτιστο συνδυασμό τιμών.

Τα αρχεία .sys, .net και .sets είναι αρχεία τύπου xml, ενώ τα αρχεία nnet.results και rules.results είναι απλά αρχεία τύπου txt. Ο λόγος που καταγράφονται σε ξεχωριστό αρχείο τα αποτελέσματα του νευρωνικού δικτύου είναι ότι στις περιπτώσεις PVS1 δε γίνεται εξαγωγή κανόνων και επομένως δε γίνεται εγγραφή στο αρχείο rules.results.

4.4 Αυτοματοποιημένη εκτέλεση και αντιμετώπιση προβλημάτων

Βάσει του πειραματικού σχεδιασμού που περιγράφηκε παραπάνω προβλέπεται η κατασκευή 4600 νευρωνικών δικτύων, ενώ από το καθένα προβλέπεται η εξαγωγή και αξιολόγηση κανόνων αιτιότητας με 3 ή 9 διαφορετικούς συνδυασμούς παραμέτρων, ανάλογα αν υπάρχει μια ή παραπάνω στοιβάδες. Γίνεται αντιληπτό ότι η δουλειά αυτή είναι υπερβολικά κοπιαστική για να υλοποιηθεί χειρωνακτικά και να επιβλέπεται σε μόνιμη βάση από κάποιον χειριστή. Γι' αυτό η αυτοματοποίηση των εκτελέσεων όλων αυτών των πειραμάτων είναι εκ των ων ουκ άνευ.

Για το λόγο αυτόν σχεδιάστηκε η αυτοματοποίηση όλων των εκτελέσεων βάσει αρχείου (.batch) το οποίο θα περιέχει όλες τις απαραίτητες εντολές. Δείγμα του αρχείου φαίνεται στο σχήμα 4.1. Η εκτέλεση ενός



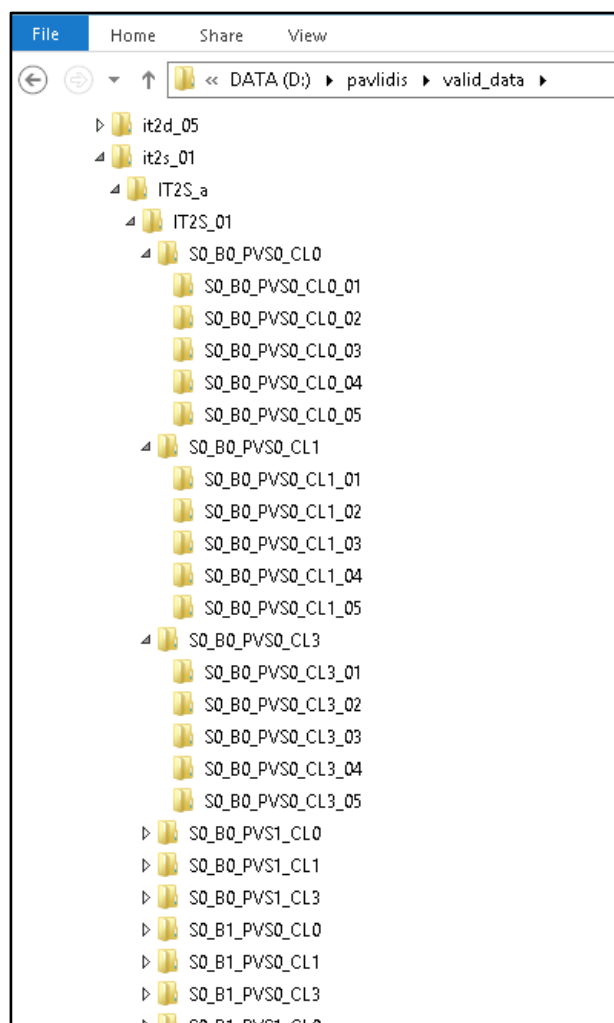
```
DIR:./

IT2S
  IT2S_01
    IT2S_01.sys
    SO_B0_PVS0_CLO
      SO_B0_PVS0_CLO_01
        SO_B0_PVS0_CLO_01.sets
        SO_B0_PVS0_CLO_01.net
        P0_N1_RPL0_RIT1.rules
        P0_N1_RPL1_RIT0.rules
        P0_N1_RPL1_RIT1.rules
        P1_N0_RPL0_RIT1.rules
        P1_N0_RPL1_RIT0.rules
        P1_N0_RPL1_RIT1.rules
        P1_N1_RPL0_RIT1.rules
        P1_N1_RPL1_RIT0.rules
        P1_N1_RPL1_RIT1.rules
      SO_B0_PVS0_CLO_02
        SO_B0_PVS0_CLO_02.sets
        SO_B0_PVS0_CLO_02.net
        P0_N1_RPL0_RIT1.rules
        P0_N1_RPL1_RIT0.rules
        P0_N1_RPL1_RIT1.rules
        P1_N0_RPL0_RIT1.rules
```

Σχήμα 4.1: Εικόνα αρχείου .batch για την αυτοματοποιημένη εκτέλεση εντολών του πειράματος IT2S_01. Η ιεραρχική δομή που ακολουθείται αντικατοπτρίζει την τελική διάταξη και δομή των φακέλων και αρχείων που θα δημιουργηθούν. Οι γραμμές που έχουν κατάληξη αρχείου είναι εντολές που θα εκτελεστούν και θα αποθηκεύσουν τα αποτελέσματά τους στο αντίστοιχο αρχείο. Οι γραμμές χωρίς κατάληξη οδηγούν στη δημιουργία φακέλων, ενώ η πρώτη εντολή DIR: ορίζει την τοποθεσία του μητρικού φακέλου και των .results αρχείων.

αρχείου .batch οδηγεί στην καταγραφή των αποτελεσμάτων στα προαναφερθέντα αρχεία και στην οργάνωσή τους σε φακέλους όπως φαίνεται στο σχήμα 4.2.

Όπως αναφέρθηκε προηγουμένως, πέρα από τα .results αρχεία, είχε σχεδιαστεί η αποθήκευση και των αρχείων που περιγράφουν το κάθε Πεδίο Ορισμού, τα σύνολα εκπαίδευσης και ελέγχου, καθώς και τα νευρωνικά δίκτυα, βασικά για λόγους αναφοράς και τεκμηρίωσης. Η αποθήκευση αυτών των αρχείων αποδείχθηκε σωτήρια στις περιπτώσεις όπου η εκτέλεση όλων των εντολών ενός .batch αρχείου δεν ολοκληρώνονταν επιτυχώς διότι η εφαρμογή «έσπαγε», είτε λόγω έλλειψης μνήμης, είτε για άλλους τεχνικούς λόγους. Χάρη όμως στα αποθηκευμένα βοηθητικά αρχεία, η εκτέλεση μπορούσε να συνεχιστεί ουσιαστικά από εκεί όπου είχε σταματήσει.



Σχήμα 4.2: Οργάνωση των παραγόμενων αρχείων σε φακέλους κατά την αυτοματοποιημένη εκτέλεση.

Εδώ πρέπει ακόμα να αναφερθεί ότι για λόγους οικονομίας χρόνου και καλύτερης εκμετάλλευσης των διαθέσιμων υπολογιστικών πόρων (24 πυρήνες στα 2.39 GHz, 96 GB RAM), δε χρησιμοποιήθηκε ένα .batch αρχείο με όλες τις εντολές που προβλέπονταν από τον πειραματικό σχεδιασμό, το οποίο θα έτρεχε από ένα στιγμιότυπο της εφαρμογής CARENNET. Αντίθετα, όλες οι εντολές μοιράστηκαν σε 30 .batch αρχεία, ένα για κάθε πείραμα Πεδίου Ορισμού. Με τον τρόπο αυτόν στάθηκε δυνατή η παράλληλη εκτέλεση από διαφορετικά στιγμιότυπα της εφαρμογής.

Τέλος, πρέπει να επισημανθεί εδώ η παράλειψη όλων των συνδυασμών που περιέχουν την τιμή CL4 στα πειράματα με Συλλογισμό IT3. Και αυτό γιατί φάνηκε στην πράξη ότι τα νευρωνικά δίκτυα με 4 στοιβάδες είναι ιδιαίτερα απαιτητικά σε πόρους και χρόνο, τουλάχιστον σε συνδυασμό με κάποιες τιμές άλλων παραμέτρων. Έτσι αποφασίστηκε να τρέξουμε στο τέλος

των υπόλοιπων πειραμάτων, από μια σειρά πειραμάτων με όλους τους συνδυασμούς που αναφέρουν το S4, ώστε να παρουσιάσουμε τουλάχιστον κάποια ενδεικτικά στοιχεία.

Κεφάλαιο 5

Αποτελέσματα

Στο κεφάλαιο παρουσιάζονται τα αποτελέσματα των πειραμάτων και η ανάλυσή τους. Στόχος της ανάλυσης είναι να καταλήξουμε στους βέλτιστους δυνατούς συνδυασμούς τιμών παραμέτρων, τόσο για την κατασκευή ποιοτικών νευρωνικών δικτύων όσο και για την εξαγωγή έγκυρων κανόνων αιτιότητας.


5.1 Νευρωνικά δίκτυα

Όπως αναφέρθηκε προηγουμένως, τα κατασκευαζόμενα νευρωνικά δίκτυα μελετήθηκαν ως προς τον αριθμό των Εποχών που χρειάστηκαν κάθε φορά για να εκπαιδευτούν, καθώς και ως προς τα ποσοστά ακρίβειας που έδωσαν, τόσο κατά την εκπαίδευσή τους, όσο και κατά τον έλεγχο.



Και για τις 3 μετρικές χρησιμοποιήθηκαν οι μέσες τιμές ανά τύπο Πεδίου Ορισμού και νευρωνικού δικτύου (5 διαφορετικά Πεδία Ορισμού για τις ίδιες τιμές παραμέτρων x 5

νευρωνικά δίκτυα για κάθε Πεδίο Ορισμού = 25). Εδώ πρέπει να διευκρινιστεί ότι η ανάλυση διασποράς που προηγήθηκε (Kruskal-Wallis ANOVA) έδειξε ότι σε κάποιες περιπτώσεις κάποια από τα 5 δείγματα της ίδιας ομάδας διέφεραν στατιστικά σημαντικά μεταξύ τους. Με άλλα λόγια, η επαναληψιμότητα των ίδιων αποτελεσμάτων νευρωνικού δικτύου για κάποιους συνδυασμούς τιμών παραμέτρων **δεν μπορεί να θεωρηθεί δεδομένη**.

Στα παρακάτω σχήματα, για κάθε συνδυασμό τιμών (άξονας X) εμφανίζεται είτε η μέση τιμή του μετρούμενου μεγέθους, είτε η μέγιστη και η ελάχιστη στις περιπτώσεις όπου εντοπίστηκαν στατιστικά σημαντικές διαφορές για το μετρούμενο μέγεθος μεταξύ δύο τουλάχιστον διαφορετικών δειγμάτων (δείγματα από διαφορετικά Πεδία Ορισμού). Σημειώνεται εδώ ότι τα διαγράμματα αυτά αναφέρονται σε 160 συνδυασμούς, γεγονός που δυσχεραίνει την αναγραφή όλων αυτών στον άξονα των X. Σκοπός των διαγραμμάτων αυτών είναι να δώσει μια γενική εικόνα για το πλήθος των συνδυασμών που έδωσαν χαμηλές και υψηλές τιμές, καθώς και το πλήθος των συνδυασμών που εμφανίζουν επαναληψιμότητα. Το χαρακτηριστικό αυτό θα συζητηθεί λεπτομερέστερα για τους συνδυασμούς στους οποίους θα εστιάσουμε στη συνέχεια.




Σχήμα 5.1: Μέσες, ελάχιστες και μέγιστες τιμές Εποχών ανά συνδυασμό τιμών παραμέτρων Πεδίου Ορισμού και νευρωνικού δικτύου



Σχήματα 5.2 και 5.3: Μέσες, ελάχιστες και μέγιστες τιμές των ακριβειών εκπαίδευσης και ελέγχου


Στο εξής, επειδή οι παράμετροι είναι πολλές, τα αποτελέσματα των νευρωνικών δικτύων θα μελετηθούν ανά τιμή κύκλων υπολογισμού. Παρακάτω δίνεται το ιστόγραμμα των αποτελεσμάτων ακρίβειας εκπαίδευσης και ελέγχου για όλους τους συνδυασμούς τιμών των νευρωνικών δικτύων που βασίζονται σε Συλλογισμό με έναν κύκλο υπολογισμών.



Σχήμα 5.4: Ιστόγραμμα μέσω των τιμών ακρίβειας για παραδείγματα εκπαίδευσης και ελέγχου ανά συνδυασμό τιμών για έναν κύκλο υπολογισμών

Παρατηρούμε γενικά ότι όλοι οι δυνατοί συνδυασμοί για έναν κύκλο υπολογισμών δίνουν αρκετά καλές ακρίβειες (πάνω από 85%), τόσο κατά την εκπαίδευση, όσο και κατά τον έλεγχο, ενώ σε αρκετές περιπτώσεις η ακρίβεια που υπολογίστηκε από τα παραδείγματα ελέγχου ήταν ελαφρώς καλύτερη από αυτήν που υπολογίστηκε κατά την εκπαίδευση. Επίσης φαίνεται πως η χρήση κόμβων ανά τιμή μεταβλητής (PVS1) δίνει ελαφρώς καλύτερα αποτελέσματα. Τέλος, δε φαίνεται να υπάρχουν σημαντικές διαφορές μεταξύ των δικτύων με μια στοιβάδα (CL0) και δύο στοιβάδες (CL2), αλλά ούτε μεταξύ κανονικού (D) και αυστηρού (S) Συλλογισμού.

Στα παρακάτω ιστογράμματα φαίνονται οι ακρίβειες εκπαίδευσης και ελέγχου για νευρωνικά δίκτυα που βασίστηκαν σε Συλλογισμό με 2 κύκλους υπολογισμών κατά την εκπαίδευση των οποίων δεν εφαρμόστηκε συμμετρικοποίηση βαρών (S0).





Σχήματα 5.5 και 5.6: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων δύο κύκλων υπολογισμών, χωρίς εφαρμογή συμμετρικοποίησης βαρών, χωρίς και με χρήση PVS.

Με μια πρώτη ματιά φαίνεται πως η χρήση κόμβων ανά τιμή μεταβλητής δίνει καλύτερα εκπαιδευμένα νευρωνικά δίκτυα. Ιδιαίτερη δε εντύπωση κάνει το γεγονός ότι σε όλες τις περιπτώσεις η ακρίβεια που υπολογίστηκε από τα παραδείγματα ελέγχου αγγίζει το 100%, κάτι που δε συμβαίνει ιδιαίτερα για $PVS = 0$.



Επίσης, για $PVS = 0$, ο συνδυασμός κανονικού Συλλογισμού (D) και καθορισμένου αριθμού στοιβάδων (CL1, CL3) φαίνεται να οδηγεί σε χαμηλότερες ακρίβειες. Ωστόσο η χρήση του κόμβου bias (B1) φαίνεται να δίνει καλύτερα αποτελέσματα, ιδιαίτερα στις περιπτώσεις που δε χρησιμοποιήθηκαν κόμβοι ανά τιμή μεταβλητής ($PVS = 0$).

Παρόμοια αποτελέσματα φαίνεται να έχουμε και με την εφαρμογή συμμετρικοποίησης των βαρών τύπου S1 κατά την οπισθόδρομη διάδοση (σχήματα 5.7, 5.8). Ωστόσο, πρέπει να σημειωθεί ότι για κάποιους συνδυασμούς τιμών παραμέτρων η υπολογιζόμενη ακρίβεια, τόσο για $PVS = 0$, όσο και για $PVS = 1$ είναι χαμηλότερη (κάτω από 60%) από ότι στις αντίστοιχες περιπτώσεις που δε χρησιμοποιήσαμε συμμετρικοποίηση.

Όσον αφορά στην εφαρμογή συμμετρικοποίησης βαρών τύπου S4, η εικόνα των αποτελεσμάτων είναι σαφώς χειρότερη από τις προηγούμενες, με μεγάλες αποκλίσεις μεταξύ των ακριβειών εκπαίδευσης και ελέγχου για τον ίδιο συνδυασμό τιμών. Η μόνη περίπτωση στην οποία έχουμε ακρίβειες που αγγίζουν το 100% είναι ο συνδυασμός αυστηρού Συλλογισμού (S) με χρήση κόμβου bias (B1), κόμβων ανά μεταβλητή (PVS1) και μιας μόνο (εξωτερική) στοιβάδα (σχήμα 5.8, IT2S_S4_B1_PVS1_CL1).



Σχήματα 5.5 και 5.6: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων δύο κύκλων υπολογισμών, με εφαρμογή συμμετρικοποίησης βαρών τύπου S1, χωρίς και με χρήση PVS.

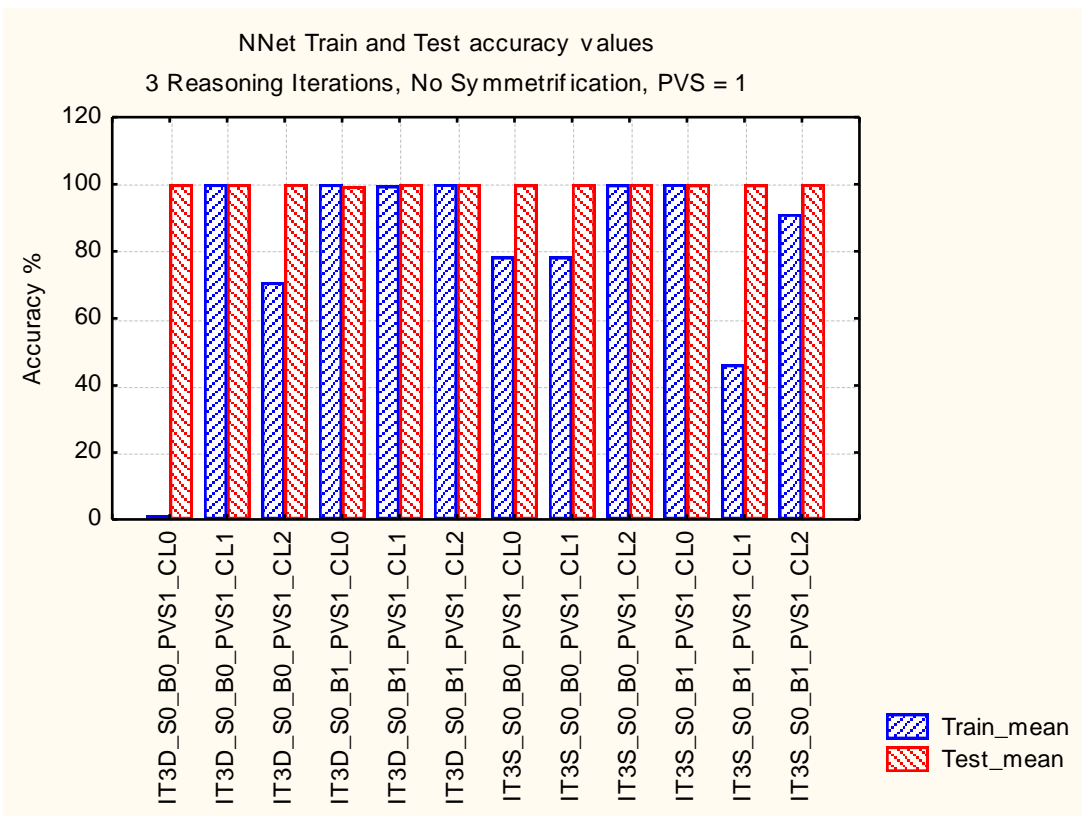
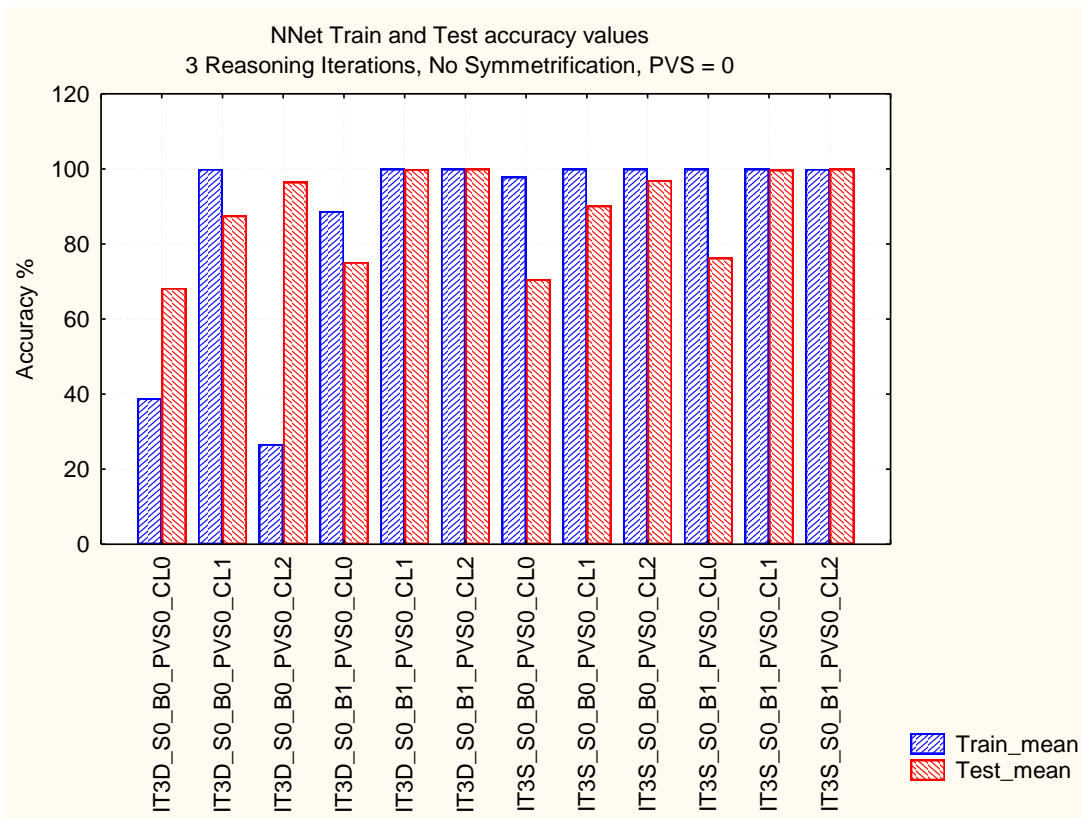


Σχήματα 5.7 και 5.8: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων δύο κύκλων υπολογισμών, με εφαρμογή συμμετρικοποίησης βαρών τύπου S4, χωρίς και με χρήση PVS.


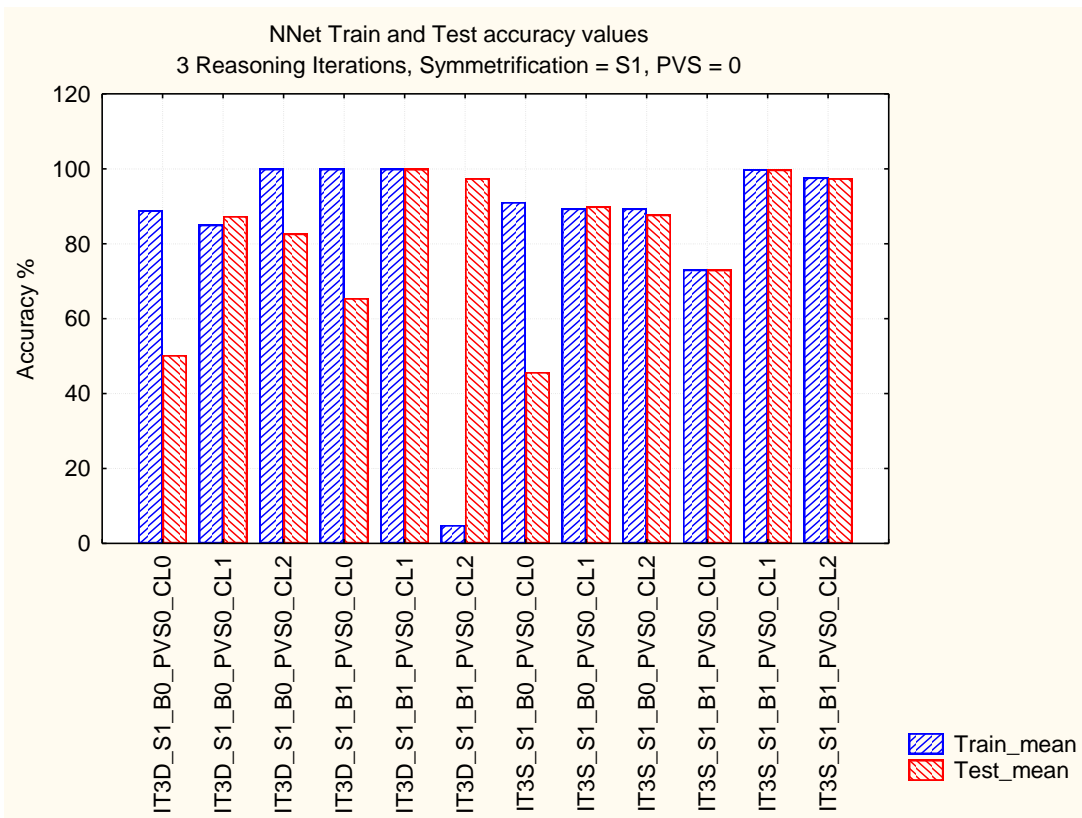
Συνεχίζοντας την προσπάθεια ανίχνευσης της επίδρασης των διαφορετικών τιμών των παραμέτρων στις υπολογιζόμενες ακρίβειες των νευρωνικών δικτύων, προχωρούμε στη μελέτη των αντίστοιχων ιστογραμμάτων για τρεις κύκλους υπολογισμών. Και εδώ η εικόνα των αποτελεσμάτων μοιάζει με αυτήν των δύο κύκλων εκπαίδευσης.

Η χρήση κόμβων ανά τιμή μεταβλητής φαίνεται να δίνει περισσότερους επιτυχημένους συνδυασμούς. Επίσης, η χρήση μιας μόνο στοιβάδας (CL1) φαίνεται να δίνει καλύτερα αποτελέσματα. Αυτό είναι ιδιαίτερα έντονο στην περίπτωση εφαρμογής συμμετρικοποίησης τύπου S4, χωρίς χρήση κόμβων ανά μεταβλητή (σχήμα 5.13). Ακολουθούν τα νευρωνικά δίκτυα με 2 στοιβάδες (CL2) και 3 στοιβάδες (CL0).



Ακόμα, η χρήση κόμβου bias φαίνεται να δίνει περισσότερο επιτυχημένους συνδυασμούς, όπως επίσης και η χρήση αυστηρού Συλλογισμού.



Σχήματα 5.9 και 5.10: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων τριών κύκλων υπολογισμών, χωρίς εφαρμογή συμμετρικοποίησης βαρών, χωρίς και με χρήση PVS.



Σχήματα 5.11 και 5.12: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων τριών κύκλων υπολογισμών, με εφαρμογή συμμετρικοποίησης βαρών τύπου S1, χωρίς και με χρήση PVS.



Σχήματα 5.13 και 5.14: Ιστογράμματα αποτελεσμάτων ακρίβειας νευρωνικών δικτύων τριών κύκλων υπολογισμών, με εφαρμογή συμμετρικοποίησης βαρών τύπου S4, χωρίς και με χρήση PVS.

Μετά την πρώτη αυτή παρουσίαση των αποτελεσμάτων φάνηκε ότι η χρήση κόμβων ανά τιμή μεταβλητής φαίνεται να οδηγεί σε περισσότερους συνδυασμούς που δίνουν πολύ καλά αποτελέσματα. Επειδή όμως η περαιτέρω ανάλυση αυτών των συνδυασμών δεν έχει νόημα, αφού δε στάθηκε δυνατή η εξαγωγή κανόνων από τέτοιου είδους νευρωνικά δίκτυα, στο εξής θα περιοριστούμε στους συνδυασμούς τιμών παραμέτρων όπου $PVS = 0$.

Για να εντοπίσουμε τους καλύτερους δυνατούς συνδυασμούς τιμών επιλέξαμε εκείνους που έδωσαν ακρίβεια τόσο κατά την εκπαίδευση, όσο και κατά τον έλεγχο μεγαλύτερη του 95%. Επιλέχθηκαν τελικά 29 συνδυασμοί, οι οποίοι φαίνονται στον παρακάτω πίνακα, ταξινομημένοι ανά τύπο Συλλογισμού, τύπο συμμετρικοποίησης, χρήση κόμβου bias και αριθμό στοιβάδων (καθορισμένων από τον χρήστη ή όχι).

	IT	R	S	B	L	Epochs	Train Accuracy	Test Accuracy
1	1	D	0	0	2	4320,60	98,25	97,55
2	2	D	0	0	2	8348,82	97,18	95,95
3	3	D	0	0	2	4952,40	97,82	96,51
4	1	D	0	1	1	26,80	100,00	100,00
5	2	D	0	1	1	27,04	100,00	100,00
6	3	D	0	1	1	49,24	99,96	99,91
7	1	D	0	1	2	30,92	99,94	99,94
8	2	D	0	1	2	27,84	100,00	100,00
9	3	D	0	1	2	32,04	99,99	100,00
	1	D	0	1	1	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 4		
10	2	D	1	1	1	27,04	100,00	100,00
11	3	D	1	1	1	49,80	99,97	99,95
	1	D	0	1	2	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 7		
12	2	D	1	1	2	7376,80	98,20	97,92
13	3	D	1	1	2	8430,32	97,65	97,47
	1	D	0	1	1	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 4		
14	2	D	4	1	1	27,00	100,00	100,00
15	3	D	4	1	1	49,92	99,95	99,91
16	1	S	0	0	2	4685,16	97,51	96,96
17	3	S	0	0	2	7279,44	97,88	96,97
18	1	S	0	1	1	25,16	100,00	100,00
19	2	S	0	1	1	67,48	99,95	99,89
20	3	S	0	1	1	67,68	99,87	99,75
21	1	S	0	1	2	28,88	100,00	100,00
22	2	S	0	1	2	37,20	99,99	99,97
23	3	S	0	1	2	42,04	100,00	99,98
	1	S	0	1	2	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 21		
24	2	S	1	1	2	7732,76	98,16	97,99
25	3	S	1	1	2	8040,60	97,68	97,44
	1	S	1	1	1	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 18		
26	2	S	1	1	1	68,16	99,97	99,95
27	3	S	1	1	1	67,52	99,86	99,76
	1	S	0	1	1	Για IT1 αντιστοιχούμε το συνδυασμό της γραμμής 18		
28	2	S	4	1	1	67,32	99,97	99,92
29	3	S	4	1	1	66,80	99,82	99,77

Πίνακας 5.1: Συνδυασμοί τιμών παραμέτρων που πέτυχαν ακρίβειες εκπαίδευσης και ελέγχου μεγαλύτερες από 95%. Αναγράφονται οι μέσες τιμές για κάθε μετρική.

Στην προηγούμενη παρουσίαση των αποτελεσμάτων φάνηκε ότι όσο αυξάνεται ο αριθμός των στοιβάδων τόσο λιγότερο επιτυχημένος είναι ο συνδυασμός. Αυτό φαίνεται και από τον παραπάνω πίνακα, όπου δεν υπάρχει κανένας συνδυασμός τιμών με 3 στοιβάδες (είτε λόγω Συλλογισμού, είτε καθορισμένων από τον χρήστη).

Από τους παραπάνω 29 συνδυασμούς ανιχνεύθηκαν και εντοπίστηκαν εκείνοι που δίνουν καλά αποτελέσματα για όλες τις τιμές κύκλων υπολογισμών και είναι οι εξής πέντε:

- D_S0_B0_L2
- D_S0_B1_L1
- D_S0_B1_L2
- D_S1_B1_L1
- D_S1_B1_L2
- D_S4_B1_L1
- S_S0_B1_L1
- S_S0_B1_L2
- S_S1_B1_L1
- S_S1_B1_L2
- S_S4_B1_L1

Υπενθυμίζεται εδώ ότι οι συνδυασμοί με έναν κύκλο υπολογισμών ($IT = 1$), συμμετείχαν μόνο σε ομάδες χωρίς εφαρμογή συμμετρικοποίησης, γι' αυτό και εμφανίζονται μόνο εκεί. Από τους υπόλοιπους συνδυασμούς, με εφαρμογή συμμετρικοποίησης S1 ή S4, επιλέχθηκαν εκείνοι που ήταν επιτυχείς τόσο για δύο, όσο και για 3 κύκλους υπολογισμών.

Λίγοι ήταν οι συνδυασμοί των οποίων τα δείγματα διέφεραν στατιστικά σημαντικά μεταξύ τους ως προς την ακρίβεια εκπαίδευσης ή ελέγχου και φαίνονται στον πίνακα 5.2. Αντίθετα, στην πλειονότητα των συνδυασμών με εξαίρεση τους D-0-1-2, D-1-1-2 και S-0-1-2, βρέθηκαν στατιστικά σημαντικές διαφορές μεταξύ των δειγμάτων ως προς τον αριθμό των Εποχών που χρειάστηκαν για να εκπαιδευτούν. Με άλλα λόγια, αν επαναληφθούν πειράματα με τις παραπάνω τιμές παραμέτρων είναι πολύ πιθανό να κατασκευάσουμε νευρωνικά δίκτυα με παρόμοιες ακρίβειες, τα οποία όμως να χρειαστούν διαφορετικό αριθμό Εποχών για να εκπαιδευτούν.



Από τις 11 αυτές ομάδες συνδυασμών επιβεβαιώνονται οι προηγούμενες παρατηρήσεις, ότι δηλαδή είναι πιθανότερο να οδηγηθούμε σε καλά εκπαιδευμένα δίκτυα χρησιμοποιώντας:


- Κόμβο bias.
- Μικρό αριθμό στοιβάδων, ανεξάρτητα από τον κύκλο υπολογισμών του Συλλογισμού.

Ωστόσο, ως προς τον τύπο του Συλλογισμού, δε φαίνεται ο αυστηρός να υπερτερεί του κανονικού, αφού όποιος συνδυασμός τιμών εντοπίζεται για αυστηρό Συλλογισμό, υπάρχει και για τον κανονικό. Επιπλέον, για κανονικό Συλλογισμό εμφανίζεται ο συνδυασμός D-0-0-2.

Τέλος, ενδιαφέρον παρουσιάζει και η συμμετρία που εμφανίζεται μεταξύ των συνδυασμών S1 και S4, κάτι που δε φάνηκε στις αρχικές μας παρατηρήσεις. Φαίνεται, λοιπόν, ότι και με τη συμμετρικοποίηση βαρών τύπου S1 και S4 είναι πιθανό να πετύχουμε καλά αποτελέσματα.

Οι παραπάνω παρατηρήσεις γίνονται καλύτερα αντιληπτές από την ανάγνωση των παρακάτω γραφημάτων.





Γραφήματα 5.1, 5.2 και 5.3: Πετυχημένοι συνδυασμοί τιμών των παραμέτρων IT, R, S, B, L για τύπο συμμετρικοποίησης S0, S1 και S4 αντίστοιχα. Για λόγους ευκρίνειας με διακεκομμένη γραμμή παρουσιάζονται οι συνδυασμοί που αναφέρονται σε κανονικό Συλλογισμό, ενώ με συνεχόμενη αυτοί που αναφέρονται σε αυστηρό. Επιπλέον, παρόλο που εμφανίζονται σε διαφορετικά γραφήματα, τα διαφορετικά χρώματα αναφέρονται σε διαφορετικό τύπο συμμετρικοποίησης.

Ωστόσο, ο S1 έδωσε καλά αποτελέσματα και για νευρωνικά δίκτυα με 2 στοιβάδες, σε αντίθεση με το S4, τόσο για αυστηρό, όσο και για κανονικό Συλλογισμό. Πρέπει, όμως, να σημειωθεί ότι οι καλές ακρίβειες του S1 για 2 στοιβάδες προέκυψαν ύστερα από «σκληρή» εκπαίδευση (περίπου 8000 Εποχές) σε αντίθεση με τη μη εφαρμογή συμμετρικοποίησης (S0, περίπου 35 Εποχές). Αντίθετα, για 1 στοιβάδα ο αριθμός των Εποχών είναι πολύ μικρός για όλους τους τύπους συμμετρικοποίησης.


	IT	R	S	B	L	Epochs	Train Accuracy	Test Accuracy
1	1	D	0	0	2	X		
2	2	D	0	0	2		X	X
3	3	D	0	0	2			
4	1	D	0	1	1	X		
5	2	D	0	1	1	X		
6	3	D	0	1	1	X		
7	1	D	0	1	2			
8	2	D	0	1	2			
9	3	D	0	1	2			
10	2	D	1	1	1	X		
11	3	D	1	1	1	X		
12	2	D	1	1	2			
13	3	D	1	1	2			
14	2	D	4	1	1	X		
15	3	D	4	1	1	X		
16	1	S	0	0	2	X		X
17	3	S	0	0	2	X	X	X
18	1	S	0	1	1	X		
19	2	S	0	1	1	X		
20	3	S	0	1	1	X		
21	1	S	0	1	2			
22	2	S	0	1	2			
23	3	S	0	1	2			
24	2	S	1	1	1	X		
25	3	S	1	1	1	X		
26	2	S	1	1	2	X		
27	3	S	1	1	2			
28	2	S	4	1	1	X		
29	3	S	4	1	1	X		

Πίνακας 5.2: Συνδυασμοί τιμών παραμέτρων που εμφάνισαν στατιστικά σημαντικές διαφορές μεταξύ των δειγμάτων τους.


5.2 Εξαγωγή κανόνων αιτιότητας

Από τη μέχρι τώρα ανάλυση αποκτήσαμε μια γενική εικόνα για το πως επηρεάζεται η ακρίβεια από τις διαφορετικές παραμέτρους της δομής και της λειτουργίας των νευρωνικών δικτύων. Η ποιότητα των κανόνων αιτιότητας που εξάγονται από ένα νευρωνικό δίκτυο δεν μπορεί να είναι ανεξάρτητη από αυτήν του ίδιου του νευρωνικού δικτύου. Προς επιβεβαίωση του παραπάνω ισχυρισμού ετοιμάστηκαν διαγράμματα ανά τιμή κύκλων υπολογισμών, τύπο συμμετρικοποίησης και τύπο ακρίβειας (εκπαίδευσης και ελέγχου) στα οποία παρατίθενται οι ακρίβειες των νευρωνικών δικτύων και αυτές των εξαχθέντων κανόνων για κάθε συνδυασμό τιμών παραμέτρων.

Τα σχήματα 5.15 και 5.16 που ακολουθούν αφορούν στις ακρίβειες νευρωνικών δικτύων και εξαχθέντων κανόνων για Συλλογισμό με έναν κύκλο υπολογισμών και στις αντίστοιχες ακρίβειες των διαφορετικού τύπου εξαχθέντων κανόνων.



Σχήμα 5.15: Συσχέτιση ακριβειών εκπαίδευσης νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 1 κύκλο υπολογισμών με αυτές των 3 διαφορετικών τύπων εξαχθέντων κανόνων.



Σχήμα 5.16: Συσχέτιση ακριβειών ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 1 κύκλο υπολογισμών με αυτές των 3 διαφορετικών τύπων εξαχθέντων κανόνων.

Όπως αναφέρθηκε και προηγουμένως, για τα νευρωνικά δίκτυα με 1 κύκλο υπολογισμών έχει νόημα μόνο ο συνδυασμός RPL1_RIT0. Έτσι έχουμε 3 πιθανούς τύπους εξαχθέντων κανόνων: α) μόνο με αρνητικές κεφαλές (P0_N1), β) μόνο με θετικές κεφαλές (P1_N0) και με θετικές και αρνητικές κεφαλές (P1_N1). Τα αποτελέσματα και για τους δύο τύπους ακρίβειας φαίνεται να ακολουθούν ακριβώς το ίδιο πρότυπο. Συγκεκριμένα:

- Η ακρίβεια των εξαχθέντων κανόνων, στην καλύτερη περίπτωση αγγίζει αυτήν του νευρωνικού δικτύου, δεν την ξεπερνάει όμως ουσιαστικά.
- Οι κανόνες με θετικές και αρνητικές κεφαλές δίνουν πάντα καλύτερα αποτελέσματα από ότι οι κανόνες με μόνο θετικές ή μόνο αρνητικές κεφαλές
- Οι εξαχθέντες κανόνες δίνουν καλά αποτελέσματα όταν ο αριθμός των στοιβάδων των νευρωνικών δικτύων συμπίπτει με αυτόν του κύκλου υπολογισμών του Συλλογισμού στον οποίο βασίστηκε (1 στοιβάδα). Διαφορετικά, οι κανόνες με μόνο αρνητικές κεφαλές δίνουν θεαματικά χειρότερα αποτελέσματα.

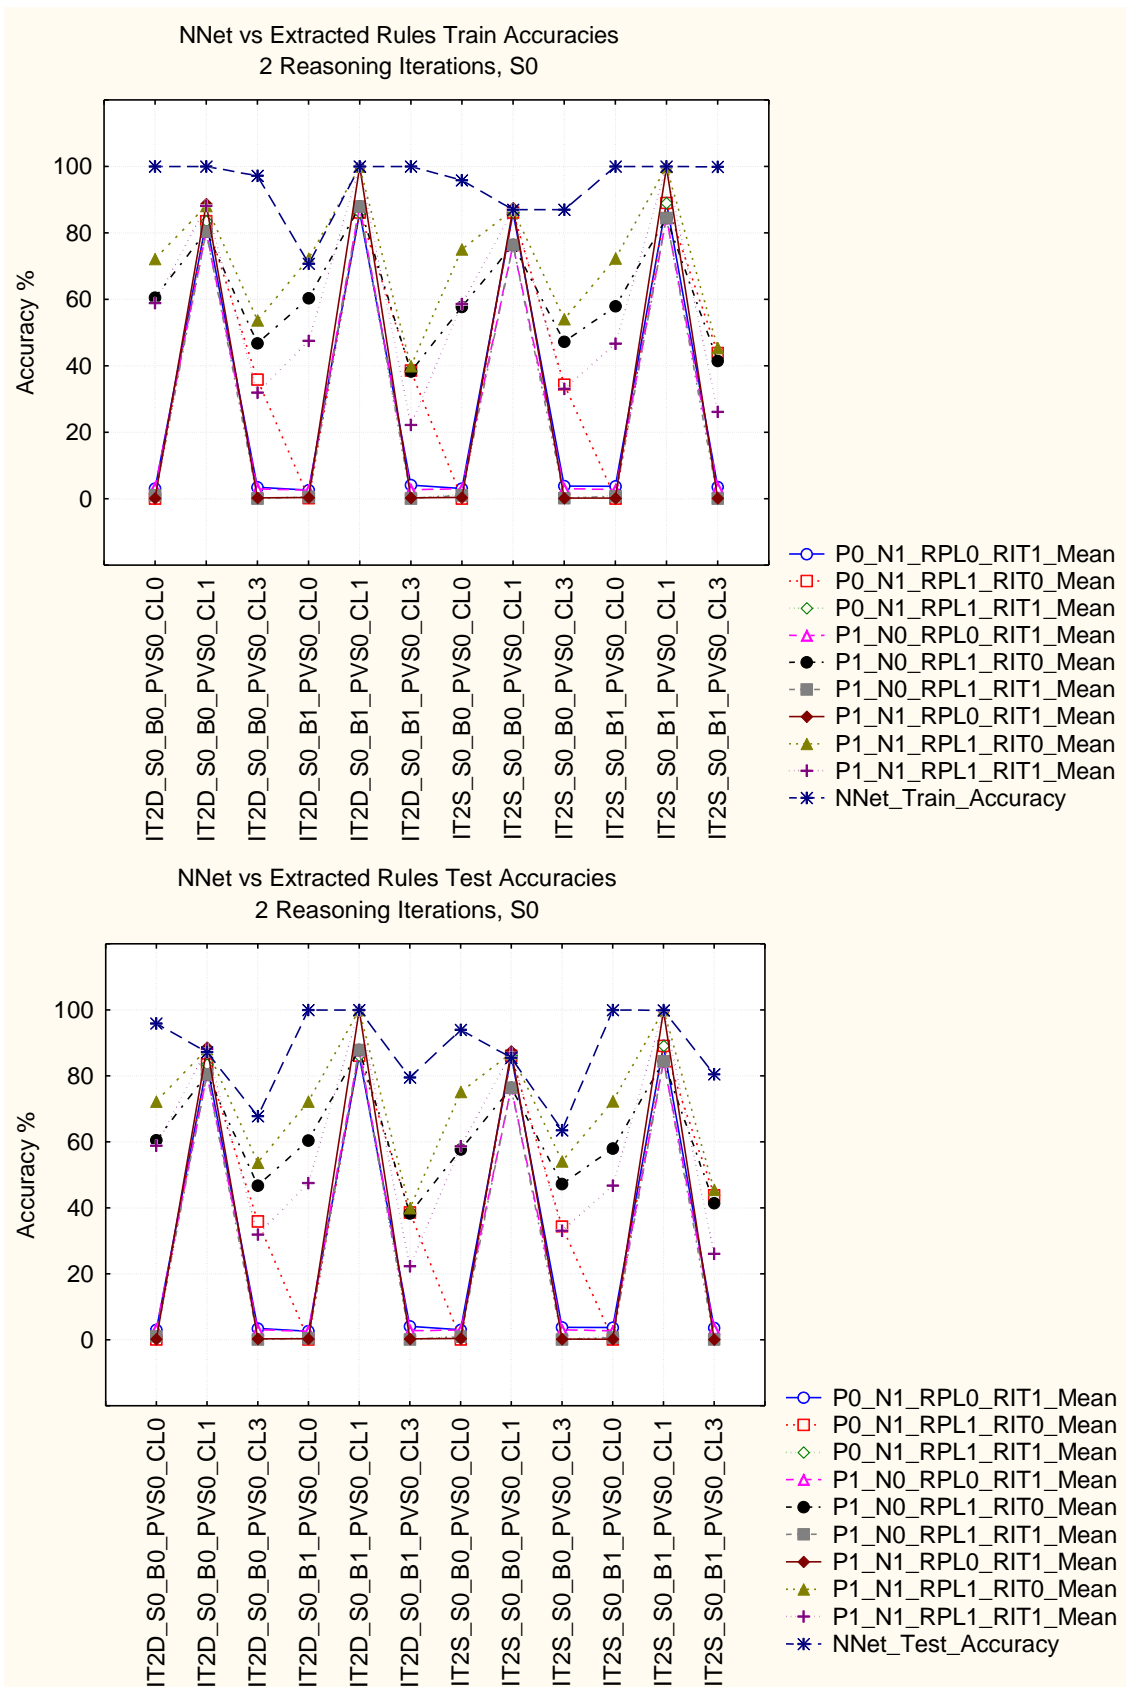
Οι παρατηρήσεις αυτές επιβεβαιώνονται και για τα νευρωνικά δίκτυα βασισμένα σε Συλλογισμό με 2 κύκλους υπολογισμών (σχήματα 5.17 – 5.22). Εδώ πια, φαίνεται καθαρά ότι οι εξαχθέντες κανόνες δίνουν καλή ακρίβεια όταν έχουμε μια μόνο στοιβάδα στα νευρωνικά δίκτυα. Διαφορετικά, η ακρίβεια ανέρχεται σε αρκετά χαμηλά επίπεδα ($< 60\%$), ακόμα και όταν η ακρίβεια του νευρωνικού δικτύου είναι υψηλή.

Επιπλέον, όσον αφορά στους συνδυασμούς RPL-RIT την καλύτερη απόδοση φαίνεται να δίνει ο RPL1_RIT0, δηλαδή ο μετασχηματισμός των κανόνων μιας στοιβάδας με βάση τους κανόνες που εξήχθησαν στην προηγούμενη στοιβάδα.

Ωστόσο, παρατηρούνται και εξαιρέσεις για κάποιους συνδυασμούς που κάνουν χρήση συμμετρικοποίησης. Συγκεκριμένα, στο σχήμα 5.19 (ακρίβειες εκπαίδευσης) και για τον συνδυασμό IT2D_S1_B1_PVS0_CL1, ενώ η ακρίβεια του νευρωνικού δικτύου υπολογίστηκε χαμηλότερη του 80%, οι ακρίβειες των εξαχθέντων κανόνων όλων των τύπων ήταν μεγαλύτερη του 80%. Μάλιστα οι ακρίβειες των P1_N1_RPL1_RIT0 και P1_N1_RPL1_RIT1 έφτανε το 100%.

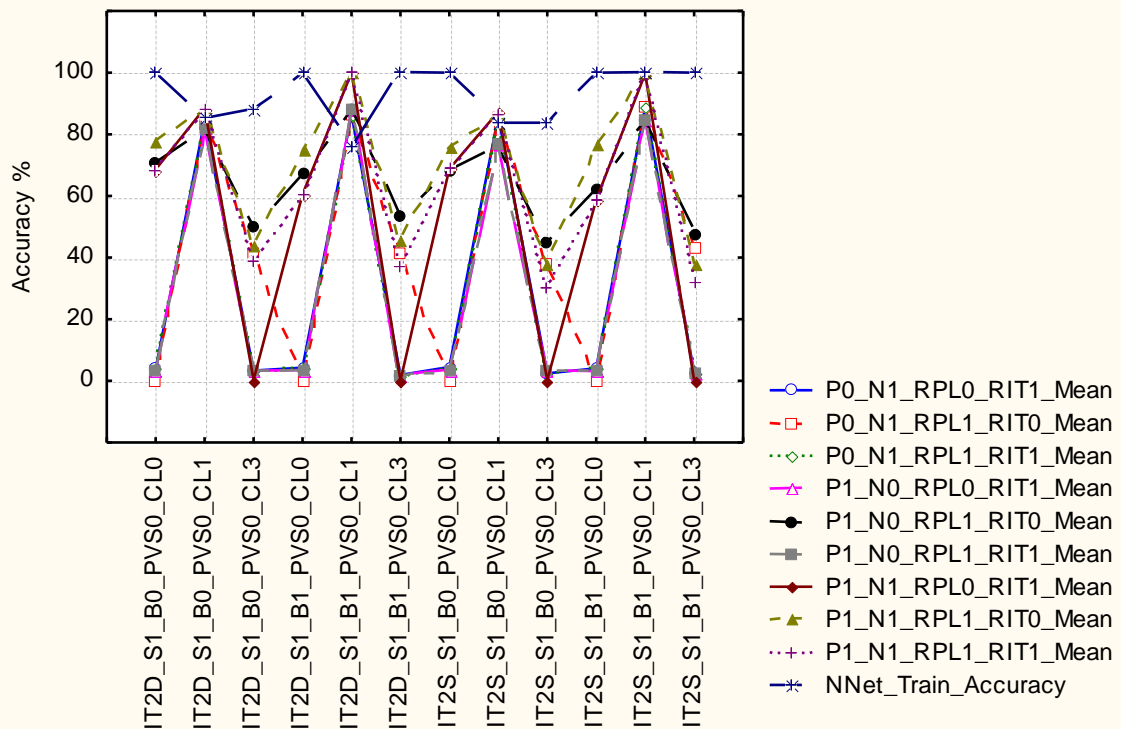
Δύο ακόμα θεαματικότερες περιπτώσεις εμφανίζονται στο σχήμα 5.21 (ακρίβειες εκπαίδευσης) για τους συνδυασμούς IT2D_S4_B0_PVS0_CL1 και IT2D_S4_B1_PVS0_CL1. Ειδικά στη δεύτερη περίπτωση πάλι οι ακρίβειες των κανόνων P1_N1_RPL1_RIT0 και P1_N1_RPL1_RIT1 φτάνουν στο 100%.

Παρόμοια ευρήματα προκύπτουν και από τα σχήματα 5.23 – 5.28 τα οποία αναφέρονται σε νευρωνικά δίκτυα βασισμένα σε Συλλογισμό με 3 κύκλους υπολογισμών. Και εδώ εμφανίζονται συνδυασμοί για τους οποίους οι ακρίβειες των εξαχθέντων κανόνων είναι σημαντικά υψηλότερη από αυτές των νευρωνικών δικτύων. Ένας τέτοιος συνδυασμός είναι ο, χωρίς εφαρμογή συμμετρικοποίησης, IT3D_S0_B0_PVS0_CL2 (ακρίβειες εκπαίδευσης, σχήμα 5.23). Συνδυασμοί με παρόμοιο προφίλ είναι και οι IT3D_S1_B1_PVS0_CL2, IT3D_S4_B0_PVS0_CL2, IT3D_S4_B1_PVS0_CL0 και IT3D_S4_B1_PVS0_CL2. Εντυπωσιάζει το γεγονός ότι όχι μόνο αναφέρονται στην εφαρμογή κάποιου τύπου συμμετρικοποίησης, αλλά και σε νευρωνικά δίκτυα με 2 (CL2) ή 3 (CL0) στοιβάδες. Βέβαια, ειδικά στην περίπτωση του S4 οι ακρίβειες των εξαχθέντων κανόνων είναι πολύ χαμηλές (μέχρι 40%).

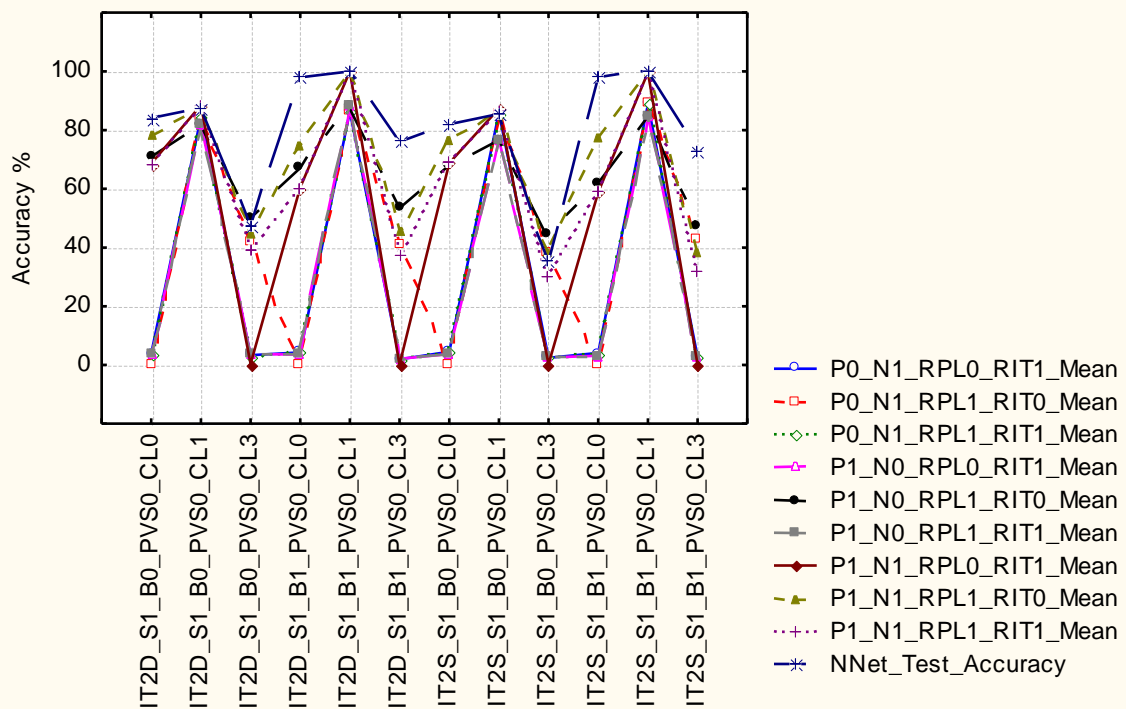


Σχήματα 5.17 και 5.18: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 2 κύκλους υπολογισμών και χωρίς εφαρμογή συμμετρικοποίησης.



NNet vs Extracted Rules Train Accuracies
2 Reasoning Iterations, S1





NNet vs Extracted Rules Test Accuracies
2 Reasoning Iterations, S1



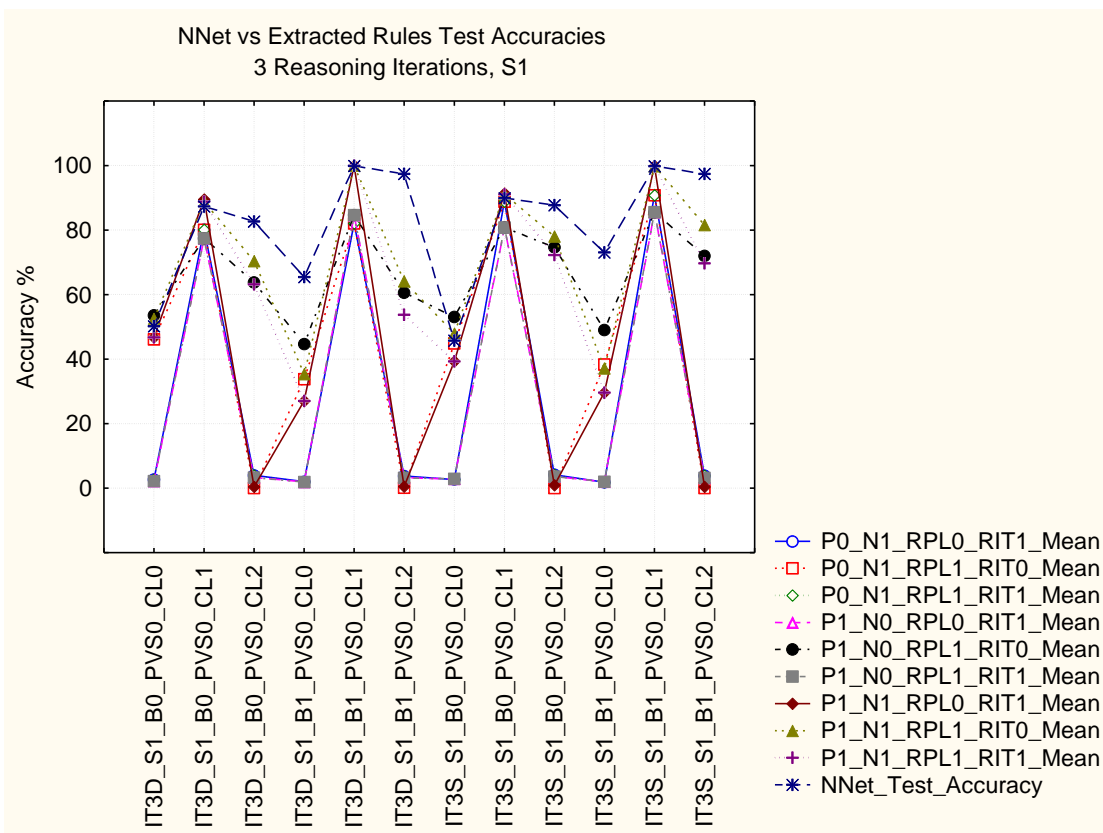
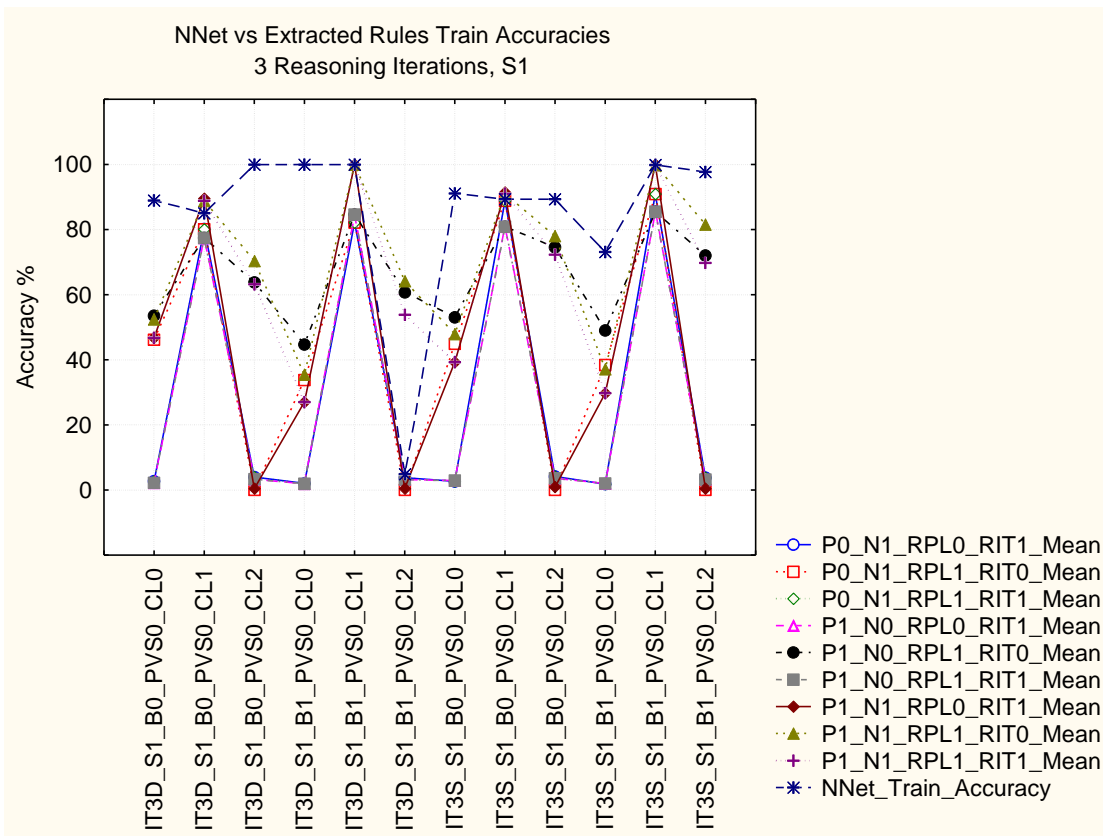
Σχήματα 5.19 και 5.20: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 2 κύκλους υπολογισμών και με εφαρμογή συμμετρικοποίησης τύπου S1.





Σχήματα 5.21 και 5.22: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 2 κύκλους υπολογισμών και με εφαρμογή συμμετρικοποίησης τύπου S4.



Σχήματα 5.23 και 5.24: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 3 κύκλους υπολογισμών και χωρίς εφαρμογή συμμετρικοποίησης.



Σχήματα 5.25 και 5.26: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 3 κύκλους υπολογισμών και με εφαρμογή συμμετρικοποίησης τύπου S1.



Σχήματα 5.27 και 5.28: Συσχέτιση ακριβειών εκπαίδευσης και ελέγχου νευρωνικών δικτύων βασισμένων σε Συλλογισμό με 3 κύκλους υπολογισμών και με εφαρμογή συμμετρικοποίησης τύπου S4.

Όπως στην ανάλυση των ακριβειών των νευρωνικών δικτύων, έτσι και εδώ εντοπίζονται και παρουσιάζονται οι συνδυασμοί εκείνοι που έδωσαν κανόνες αιτιότητας με ακρίβεια τόσο για τα παραδείγματα εκπαίδευσης, όσο και για τα παραδείγματα ελέγχου μεγαλύτερη του 95%.

	IT	R	S	B	L	Pos	Neg	RPL	RIT	Train Accuracy (mean)	Test Accuracy (mean)	Train Fidelity (mean)	Test Fidelity (mean)
1	1	D	0	1	1	1	1	1	0	100,00	100,00	100,00	100,00
2	2	D	0	1	1	1	1	0	1	100,00	100,00	100,00	100,00
3	3	D	0	1	1	1	1	0	1	99,98	99,95	99,98	99,96
4	2	D	0	1	1	1	1	1	0	100,00	100,00	100,00	100,00
5	3	D	0	1	1	1	1	1	0	99,96	99,91	100,00	100,00
6	2	D	0	1	1	1	1	1	1	100,00	100,00	100,00	100,00
7	3	D	0	1	1	1	1	1	1	99,96	99,91	100,00	100,00
8	2	D	1	1	1	1	1	0	1	100,00	100,00	100,00	100,00
9	3	D	1	1	1	1	1	0	1	100,00	100,00	99,97	99,95
10	2	D	1	1	1	1	1	1	0	100,00	100,00	100,00	100,00
11	3	D	1	1	1	1	1	1	0	99,97	99,95	100,00	100,00
12	2	D	1	1	1	1	1	1	1	100,00	100,00	100,00	100,00
13	3	D	1	1	1	1	1	1	1	99,97	99,95	100,00	100,00
14	2	D	4	1	1	1	1	0	1	100,00	100,00	100,00	100,00
15	3	D	4	1	1	1	1	0	1	100,00	100,00	99,95	99,91
16	2	D	4	1	1	1	1	1	0	100,00	100,00	100,00	100,00
17	3	D	4	1	1	1	1	1	0	99,95	99,91	100,00	100,00
18	2	D	4	1	1	1	1	1	1	100,00	100,00	100,00	100,00
19	3	D	4	1	1	1	1	1	1	99,95	99,91	100,00	100,00
20	1	S	0	1	1	1	1	1	0	100,00	100,00	100,00	100,00
21	2	S	0	1	1	1	1	0	1	99,69	99,67	99,64	99,57
22	3	S	0	1	1	1	1	0	1	99,99	99,96	99,88	99,78
23	2	S	0	1	1	1	1	1	0	99,95	99,89	100,00	100,00
24	3	S	0	1	1	1	1	1	0	99,87	99,75	100,00	100,00
25	2	S	0	1	1	1	1	1	1	99,95	99,89	100,00	100,00
26	3	S	0	1	1	1	1	1	1	99,87	99,75	100,00	100,00
27	2	S	1	1	1	1	1	0	1	99,68	99,68	99,66	99,64
28	3	S	1	1	1	1	1	0	1	99,93	99,86	99,92	99,89
29	2	S	1	1	1	1	1	1	0	99,97	99,95	100,00	100,00
30	3	S	1	1	1	1	1	1	0	99,86	99,76	100,00	100,00
31	2	S	1	1	1	1	1	1	1	99,97	99,95	100,00	100,00
32	3	S	1	1	1	1	1	1	1	99,86	99,76	100,00	100,00
33	2	S	4	1	1	1	1	0	1	99,70	99,65	99,68	99,57
34	3	S	4	1	1	1	1	0	1	99,97	99,94	99,85	99,83
35	2	S	4	1	1	1	1	1	0	99,97	99,92	100,00	100,00
36	3	S	4	1	1	1	1	1	0	99,82	99,77	100,00	100,00
37	2	S	4	1	1	1	1	1	1	99,97	99,92	100,00	100,00
38	3	S	4	1	1	1	1	1	1	99,82	99,77	100,00	100,00

Πέρα από τα δεδομένα ακρίβειας, παρατίθενται και τα δεδομένα πιστότητας των κανόνων στο νευρωνικό δίκτυο από το οποίο προέκυψαν. Τα στοιχεία είναι ταξινομημένα βάσει των παραμέτρων R-RIT, ώστε να εντοπιστούν εύκολα οι κοινοί συνδυασμοί για όλες τις τιμές κύκλων υπολογισμών. Παρατηρούμε τα εξής:



- Για έναν κύκλο υπολογισμών ($IT = 1$) έχουμε μόνο 2 επιτυχημένους συνδυασμούς (κίτρινο χρώμα), οι οποίοι μάλιστα είναι ίδιοι με τη διαφορά ότι ο πρώτος αναφέρεται σε κανονικό Συλλογισμό, ενώ ο δεύτερος σε αυστηρό. Συγκεκριμένα πρόκειται για τους D/S-S0-B1-CL0-P1-N1-RPL1-RIT0.
- Κάθε συνδυασμός, με εξαίρεση τους δύο που αναφέρθηκαν προηγουμένως αναφέρονται τόσο σε 2, όσο και σε 3 κύκλους υπολογισμών.
- Όλοι οι συνδυασμοί είναι ισοκατανεμημένοι ως προς τον τύπο του Συλλογισμού: 19 αναφέρονται σε αυστηρό Συλλογισμό και 19 σε κανονικό.
- Όλοι οι συνδυασμοί, εξαιρουμένων των δύο που αναφέρονται σε 1 κύκλο υπολογισμών, **είναι ισοκατανεμημένοι ως προς τον τύπο συμμετρικοποίησης**: 12 για καθένα από τους S0, S1, S4.
- Όλοι οι συνδυασμοί αναφέρονται σε χρήση κόμβου bias.
- Όλοι οι συνδυασμοί αναφέρονται σε νευρωνικά δίκτυα με **μια στοιβάδα**.
- Όλοι οι συνδυασμοί αναφέρονται σε εξαγωγή κανόνων με θετικές και αρνητικές κεφαλές.
- Όλοι οι συνδυασμοί είναι ισοκατανεμημένοι ως προς τις τιμές των παραμέτρων RPL και RIT.
- Όλοι οι συνδυασμοί εμφανίζουν πιστότητα όμοια με την αντίστοιχη ακρίβεια. Με άλλα λόγια, είναι πολύ αποτελεσματικοί ακολουθώντας παράλληλα πιστά και τα αποτελέσματα των νευρωνικών δικτύων από τα οποία προέκυψαν. Αυτό σημαίνει ότι τα νευρωνικά δίκτυα ήταν εξαιρετικά εκπαιδευμένα, με ακρίβειες εκπαίδευσης και ελέγχου μεγαλύτερες από 95%.

Πέρα από αυτές τις παρατηρήσεις, θα πρέπει να αναφερθεί ότι κανένας συνδυασμός δεν εμφάνισε στατιστικά σημαντικές διαφορές μεταξύ των 5 διαφορετικών δειγμάτων ως προς κάποια από τις τέσσερις μετρικές (πιστότητας και ακρίβειας). Εξαιρέση αποτέλεσαν 3 συνδυασμοί που εμφάνισαν στατιστικά σημαντικές διαφορές ως προς όλες τις μετρικές. Οι συνδυασμοί αυτοί είναι:

- IT2S_S0_B1_PVS0_CL1_P1_N1_RPL0_RIT1
- IT2S_S1_B1_PVS0_CL1_P1_N1_RPL0_RIT1
- IT2S_S4_B1_PVS0_CL1_P1_N1_RPL0_RIT1

Όπως φαίνεται, αναφέρονται μόνο σε 2 κύκλους υπολογισμών και σε **RPL0_RIT1**, αλλά σε **κάθε τύπο συμμετρικοποίησης**.

Όσον αφορά στην πολυπλοκότητα των παραπάνω κανόνων, τα αποτελέσματα είναι δύσκολο να παρουσιαστούν αναλυτικά εδώ. Ωστόσο, αξίζει να αναφερθεί ότι τα επίπεδα παρέμειναν σχετικά χαμηλά με τους κανόνες να αποτελούνται ως επι το πλείστον από 1 έως 6 άτομα ενώ ο μέγιστος αριθμός ατόμων που παρατηρήθηκε ανά κανόνα ήταν 57. Φάνηκε επίσης ότι ο αυστηρός Συλλογισμός δίνει πιο πολύπλοκους κανόνες από ότι ο κανονικός (σχήματα 5.29 και 5.30). Και στις δύο περιπτώσεις οι διακυμάνσεις του αριθμού των ατόμων ακολουθούν αυτές των όρων, κάτι που είναι αναμενόμενο, αφού ένας όρος μπορεί να περιέχει ένα ή περισσότερα άτομα.



Σχήματα 5.29 και 5.30: Μέγιστοι αριθμοί ατόμων και όρων ανά τύπο εξαχθέντων κανόνων για κανονικό και αυστηρό Συλλογισμό, αντίστοιχα.

Κεφάλαιο 6

Συμπεράσματα

Στο κεφάλαιο αυτό συνοψίζονται τα συμπεράσματα που προκύπτουν από την ανάλυση των στοιχείων, τη γενικότερη εμπειρία από τη λειτουργία της πειραματικής διαδικασίας CARENNET, καθώς επίσης σκέψεις και ιδέες για μελλοντική εργασία.

Βασικός στόχος της πειραματικής διαδικασίας CARENNET ήταν να διερευνήσει ταυτόχρονα μια πληθώρα παραμέτρων για την κατασκευή και λειτουργία των Πεδίων Ορισμού, των νευρωνικών δικτύων και των μεθόδων εξαγωγής κανόνων, ώστε αφενός να εντοπίσει τις σημαντικότερες και αφετέρου να καταλήξει στους βέλτιστους συνδυασμούς τιμών τους ως προς την ποιότητα των κατασκευαζόμενων νευρωνικών δικτύων, αλλά και των εξαχθέντων κανόνων αιτιότητας.

Με τον όρο «ποιοτικά» νευρωνικά δίκτυα εννοούμε τα δίκτυα εκείνα τα οποία μπορούν να δίνουν **κατ' εξακολούθηση** αποτελέσματα **υψηλής ακρίβειας** και για τα δύο σύνολα παραδειγμάτων (εκπαίδευσης και ελέγχου), με **το μικρότερο δυνατό κόστος**.

Ομοίως, με τον όρο «ποιοτικοί» κανόνες αιτιότητας εννοούμε τους κανόνες εκείνους που μπορούν να δίνουν **κατ' εξακολούθηση** αποτελέσματα **υψηλής ακρίβειας** και για τα δύο σύνολα παραδειγμάτων (εκπαίδευσης και ελέγχου), με **τη μικρότερη δυνατή πολυπλοκότητα**.

Το όριο της ακρίβειας τέθηκε στο 95%, ενώ η επαναληψιμότητα των αποτελεσμάτων των συνδυασμών διερευνήθηκε με μη παραμετρική ανάλυση διασποράς (ανάλυση Kruskal-Wallis).

Από την ανάλυση των αποτελεσμάτων προέκυψε ότι τα ποιοτικότερα νευρωνικά δίκτυα έδωσαν και τους ποιοτικότερους κανόνες αιτιότητας.

Ο τύπος του Συλλογισμού (κανονικός ή αυστηρός) των Πεδίων Ορισμών δε φάνηκε να επηρεάζει τις ακρίβειες των παραγόμενων νευρωνικών δικτύων, αλλά ούτε και αυτές των εξαχθέντων κανόνων. Φάνηκε, ωστόσο, να τείνει να δίνει περισσότερο πολύπλοκους κανόνες. Αυτό θα μπορούσε να εξηγηθεί από το γεγονός ότι ο αυστηρός Συλλογισμός λόγω της φύσης του δίνει αφενός λιγότερα παραδείγματα (αφού αυτά που αποτυγχάνουν στον έλεγχο ακυρώνονται), αφετέρου δημιουργεί μια πιο συγκεκριμένη και πολύπλοκη σχέση μεταξύ των μεταβλητών την οποία ενδέχεται να «δυσκολεύεται» ένα νευρωνικό δίκτυο να την εντοπίσει μέσα από έναν αριθμό παραδειγμάτων.

Η εφαρμογή συμμετρικοποίησης στα βάρη των νευρωνικών δικτύων δε φάνηκε να επηρεάζει θετικά, ούτε την ποιότητα των παραγόμενων νευρωνικών δικτύων, ούτε αυτήν των εξαχθέντων κανόνων. Στην καλύτερη περίπτωση, η συμμετρικοποίηση τύπου S1 έδωσε παρόμοια αποτελέσματα ακρίβειας με την S0 (μη εφαρμογή), ενώ ο S4 φάνηκε να είναι πιο «αδύνατος» αφού δεν έδωσε καλά αποτελέσματα για νευρωνικά δίκτυα με 2 στοιβάδες. Ωστόσο, τα νευρωνικά δίκτυα με 2 στοιβάδες και εφαρμογή του S1, φάνηκαν να «δυσκολεύονται» στην εκπαίδευση αφού ο μέσος αριθμός των Εποχών που χρειάστηκαν ήταν 2 τάξεις μεγέθους μεγαλύτερος από τη μη εφαρμογή του. Ακόμα, η χρήση συμμετρικοποίησης στα βάρη δημιουργεί επιπλέον φόρτο κατά την εκπαίδευση (επιπλέον υπολογισμοί).

Συμπερασματικά, λοιπόν, μπορούμε να πούμε ότι δεν έχει νόημα η περαιτέρω διερεύνηση της συμμετρικοποίησης των βαρών, τόσο για τη λειτουργία ποιοτικών νευρωνικών δικτύων, όσο και για την εξαγωγή κανόνων από αυτά, αφού ούτε εκεί φάνηκε να παίζει κάποιο ρόλο.

Ο αριθμός των στοιβάδων φαίνεται να είναι καίριας σημασίας για την ποιότητα των νευρωνικών δικτύων, φάνηκε γενικότερα ότι όσο λιγότερες είναι οι στοιβάδες, τόσο πιθανότερο είναι να κατασκευάσουμε ένα ποιοτικό νευρωνικό δίκτυο. Επίσης, φάνηκε ότι ο αριθμός των στοιβάδων μπορεί να είναι ανεξάρτητος των κύκλων υπολογισμών του Συλλογισμού του Πεδίου Ορισμού από το οποίο εκπορεύονται τα παραδείγματα εκπαίδευσης των νευρωνικών δικτύων. Εδώ πρέπει να σημειωθεί πως αναμέναμε διαφορετικά αποτελέσματα. Συγκεκριμένα, είχε θεωρηθεί αρχικά ότι ένα νευρωνικό δίκτυο όπου η κάθε στοιβάδα θα αντιπροσώπευε έναν κύκλο υπολογισμών του Συλλογισμού στον οποίο βασίζονταν θα λειτουργούσε βέλτιστα, αφού η κάθε στοιβάδα θα αναλάμβανε τους αντίστοιχους «υπολογισμούς», όπως ακριβώς συμβαίνει και στον υπολογισμό των παραδειγμάτων από το Πεδίο Ορισμού. Παράλληλα όμως, ο αυξημένος αριθμός στοιβάδων αυξάνει και την πολυπλοκότητα του δικτύου. Αυτό είναι ένα αρκετά ενδιαφέρον εύρημα αφού, αν και καταρρίπτει την αρχική μας υπόθεση, σημαίνει ότι η μελλοντική έρευνα ή και χρήση τέτοιων δικτύων θα μπορούσε να περιοριστεί σε δομές με μια μόνο στοιβάδα. Αυτό θα μείωνε και τις ανάγκες των ερευνητών – χρηστών τόσο σε χρόνο, όσο και σε υπολογιστικούς πόρους. Εδώ πρέπει να αναφέρουμε ότι όσο πολυπλοκότερο ήταν ένα νευρωνικό δίκτυο, τόσο μεγαλύτερες ανάγκες είχε σε πόρους για να εκπαιδευτεί.

Ο κόμβος bias φάνηκε να παίζει σημαντικό ρόλο και να είναι απαραίτητος για την κατασκευή ποιοτικών νευρωνικών δικτύων, αφού ήταν παρόν σε όλους τους επιτυχημένους συνδυασμούς. Το εύρημα αυτό ήταν κάπως αναμενόμενο αφού ο ρόλος αυτών των κόμβων είναι ουσιαστικά να επιταχύνουν και να βελτιώνουν την εκπαίδευση των νευρωνικών δικτύων (Haykin, 1999).

Τέλος, η τεχνική «κόμβοι ανά τιμή μεταβλητής» (PVS) που χρησιμοποιήσαμε φάνηκε να δίνει πολύ καλές ακρίβειες. Δυστυχώς όμως, δε στάθηκε δυνατό να εξάγουμε κανόνες αιτιότητας από δίκτυα κατασκευασμένα με αυτόν τον τρόπο. Η τεχνική αυτή θα μπορούσε να διερευνηθεί περαιτέρω στο μέλλον.

Όσον αφορά στις εξαγόμενες ομάδες κανόνων έγινε σαφές ότι για να πετύχουμε καλή ακρίβεια είναι απαραίτητο να εξάγουμε κανόνες τόσο με θετική, όσο και με αρνητική κεφαλή, όπως ακριβώς δηλαδή πρωτοκατασκευάζονταν οι κανόνες αιτιότητας στα Πεδία Ορισμού. Από τη στιγμή που μας ενδιέφερε να εκφράσουμε τέτοιους κανόνες θα έπρεπε και να τους εξάγουμε.

Τέλος δε φάνηκε κάποια διαφορά στην κατασκευή ποιοτικών κανόνων, τουλάχιστον στο επίπεδο ακρίβειας που ορίσαμε, μεταξύ των χρήσεων διαφορετικών τεχνικών όπως ο μετασχηματισμός κανόνων (RPL1-RIT0), η προσπέλαση των κανόνων (RPL0-RIT1) και η εξαγωγή κανόνων ανά στοιβάδα (RPL1-RIT1) με ταυτόχρονη φυσικά προσπέλαση των κανόνων. Και αυτό το εύρημα είναι ενδιαφέρον, αφού για μελλοντική χρήση θα μπορούσαμε να χρησιμοποιήσουμε την πιο «οικονομική», δηλαδή την πιο γρήγορη με τις λιγότερες απαιτήσεις σε υπολογιστικούς πόρους. Αυτή είναι σίγουρα η απλή προσπέλαση των κανόνων (RPL0-RIT1), σε αντίθεση με τον μετασχηματισμό που είναι μια αρκετά ακριβότερη τεχνική.

Βιβλιογραφία

- Andrews, R., Diederich, J., & Tickle, A. B. (1995). Survey and critique of techniques for extracting rules from trained artificial neural networks. *Knowl.-Based Syst.*, 373-389.
- Artificial intelligence*. (n.d.). Ανάκτηση από Wikipedia:
https://en.wikipedia.org/wiki/Artificial_intelligence
- Brachman, R. J., & Levesque, H. J. (2004). *Knowledge Representation and Reasoning*. Elsevier.
- Craven, M. W., & Shavlik, J. W. (1996). Extracting Tree - Structured Representations of Trained Network. Στο D. S. Touretzky, M. C. Mozer, & M. E. Hasselmo, *Advances in Neural Information Processing Systems* (σσ. 24 - 30). Cambridge: MIT Press.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation* (Second εκδ.). Hamilton, Ontario, Canada: Pearson Prentice Hall.
- Iqbal, R. A. (2011). Eclectic Extraction of Propositional Rules from Neural Networks. *CoRR*, *abs/1110.0214*.
- Karimi, K., & Hamilton, H. J. (2001). *Learning causal rules*. University of Regina, Department of Computer Science. Saskatchewan, Canada: University of Regina.
- Krishnan, R., Sivakumar, G., & Bhattacharya, P. (1996). A search technique for rule extraction from trained neural networks. *NIPS'97 Rule Extraction From Trained Artificial Neural Networks Wkshp.* (σσ. 38-45). Queensland Univ. Technol.
- MacLeod, C. (2010). *An Introduction to Practical Neural Networks and Genetic Algorithms For Engineers and Scientists*. Aberdeen: Robert Gordon University.
- McMillan, C., Mozer, M. C., & Smolensky, P. (1991). The connectionist scientist game: rule extraction and refinement in a neural network. *Thirteenth Annual Conference of the Cognitive Science Society*. Hillsdale, NJ, USA.
- Michael, L. (2011). Causal Learnability. *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence*.
- Muslimi, B., Capretz, M. A., & Samarabandu, J. (2006). An Efficient Technique for Extracting Fuzzy Rules from Neural Networks. *World Academy of Science, Engineering and Technology*, 16, 296-302.
- Shoham, Y. (1990). Nonmonotonic reasoning and causation. *Cognitive Science*, 14, 213-252.
- Sun, R. (1994). A Neural Network Model of Causality. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 5.
- Thrun, S. (1995). Extracting rules from artificial neural networks with distributed representations. *ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 7* (σσ. 505-512). MIT Press.
- Thrun, S. B. (1994). *Extracting provably correct rules from artificial neural networks*. Technical Report IAI-TR-93-5, Institut for Informatik III, Univarsitat Bonn, Germany.

Tickle , A. B., Andrews , R., Golea , M., & Diederich, J. (1998). The truth will come to light: directions and challenges in extracting the knowledge embedded within trained artificial neural networks. *IEEE Transactions on Neural Networks*, 9(6), 1057-1068.

Towell, G., & Shavlik, J. (1993). The extraction of refined rules from knowledge based neural networks. *Machine Learning*, 131, 71-101.