



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΑΤΡΩΝ**

**ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ**

**ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ Η/Υ ΚΑΙ ΠΛΗΡΟΦΟΡΙΚΗΣ**

**Χρήση Μεθόδων Εξόρυξης Δεδομένων  
στη Δημιουργία Νευρωνικών**

**ΜΕΤΑΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

**ΑΓΓΕΛΟΠΟΥΛΟΣ ΝΙΚΟΛΑΟΣ**

**A. M.: 604**

**Επιβλέπων Καθηγητής : Ιωάννης Κ. Χατζηλυγερούδης**

**ΠΑΤΡΑ 2011**



*Η εργασία αυτή δεν θα μπορούσε να έχει πραγματοποιηθεί χωρίς την αμέριστη βοήθεια και την εμπιστοσύνη του κ. Ιωάννη Χατζηλυγερούδη. Οι υποδείξεις και οι συμβουλές του υπήρξαν πάντα εύστοχες και επικουρικές για μένα και μου παρείχαν όλα εκείνα τα εφόδια που είναι απαραίτητα για την περάτωση μιας τέτοιας εργασίας. Επίσης, δεν θα μπορούσα να παραλείψω τα πολύ κοντινά μου πρόσωπα που με στήριζαν στις επιλογές που έκανα αυτά τα χρόνια...*



# ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

<b>1</b>	<b>ΕΙΣΑΓΩΓΗ</b> .....	<b>5</b>
1.1	ΠΡΟΛΟΓΟΣ – ΣΧΕΤΙΚΕΣ ΕΡΓΑΣΙΕΣ .....	5
1.2	ΑΝΤΙΚΕΙΜΕΝΟ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ .....	8
1.3	ΟΡΓΑΝΩΣΗ ΚΕΙΜΕΝΟΥ .....	9
<b>2</b>	<b>ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ</b> .....	<b>10</b>
2.1	ΑΝΑΠΑΡΑΣΤΑΣΗ ΤΗΣ ΓΝΩΣΗΣ .....	10
2.2	ΈΜΠΕΙΡΑ ΣΥΣΤΗΜΑΤΑ .....	12
2.3	ΣΥΣΤΗΜΑΤΑ ΠΑΡΑΓΩΓΗΣ (ΣΥΣΤΗΜΑΤΑ ΒΑΣΙΣΜΕΝΑ ΣΕ ΚΑΝΟΝΕΣ).....	16
2.4	ΚΑΝΟΝΕΣ ΠΑΡΑΓΩΓΗΣ (ΣΥΜΒΟΛΙΚΟΙ ΚΑΝΟΝΕΣ) .....	20
2.5	ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ .....	23
2.6	ΣΥΛΛΟΓΙΣΤΙΚΗ ΒΑΣΙΣΜΕΝΗ ΣΕ ΠΕΡΙΠΤΩΣΕΙΣ .....	25
2.7	ΕΞΟΥΣΙΑ ΓΝΩΣΗΣ .....	27
<b>3</b>	<b>ΝΕΥΡΩΚΑΝΟΝΕΣ</b> .....	<b>30</b>
3.1	ΣΥΝΤΑΞΗ ΚΑΙ ΣΗΜΑΣΙΟΛΟΓΙΑ .....	31
3.2	ΚΑΤΑΣΚΕΥΗ ΒΑΣΗΣ ΝΕΥΡΩΚΑΝΟΝΩΝ .....	33
3.2.1	<i>Κατασκευή αρχικών νευρωνικών κανόνων</i> .....	33
3.2.2	<i>Εκπαίδευση αρχικών νευρωνικών κανόνων</i> .....	34
3.3	ΕΞΑΓΩΓΗ ΣΥΜΠΕΡΑΣΜΑΤΩΝ ΒΑΣΙΣΜΕΝΗ ΣΕ ΝΕΥΡΩΚΑΝΟΝΕΣ .....	37
<b>4</b>	<b>ΥΒΡΙΔΙΚΗ ΑΡΧΙΤΕΚΤΟΝΙΚΗ</b> .....	<b>42</b>
<b>5</b>	<b>ΔΕΙΚΤΟΛΟΤΗΣΗ</b> .....	<b>44</b>
<b>6</b>	<b>ΣΥΣΤΑΔΟΠΟΙΗΣΗ</b> .....	<b>47</b>
6.1	ΕΙΣΑΓΩΓΗ.....	47
6.2	ΕΦΑΡΜΟΓΕΣ ΣΥΣΤΑΔΟΠΟΙΗΣΗΣ .....	49
6.3	ΜΕΘΟΔΟΙ ΣΥΣΤΑΔΟΠΟΙΗΣΗΣ .....	51
6.3.1	<i>Κατηγοριοποίηση με βάση την μέθοδο συσταδοποίησης</i> .....	51
6.3.2	<i>Κατηγοριοποίηση με βάση τη θεωρία ορισμού συστάδας</i> .....	52
6.3.3	<i>Κατηγοριοποίηση με βάση τον τύπο των δεδομένων</i> .....	52
6.4	ΑΛΓΟΡΙΘΜΟΙ ΣΥΣΤΑΔΟΠΟΙΗΣΗΣ .....	55
6.4.1	<i>Αλγόριθμος K-means</i> .....	55
6.4.2	<i>Αλγόριθμοι βασισμένοι στον K-means για λεκτικά δεδομένα</i> .....	58
<b>7</b>	<b>ΕΥΡΕΣΗ ΕΚΤΟΠΩΝ (OUTLIER DETECTION)</b> .....	<b>61</b>
7.1	ΕΙΣΑΓΩΓΗ.....	61
7.2	ΤΥΠΟΙ ΕΚΤΟΠΩΝ.....	63
7.3	ΟΡΙΣΜΟΙ ΕΚΤΟΠΩΝ .....	64
7.3.1	<i>Προσέγγιση Απόστασης</i> .....	65
7.3.2	<i>Προσέγγιση Συσταδοποίησης</i> .....	66
<b>8</b>	<b>ΔΗΜΙΟΥΡΓΙΑ ΝΕΥΡΩΚΑΝΟΝΩΝ ΜΕ ΜΕΘΟΔΟΥΣ ΣΥΣΤΑΔΟΠΟΙΗΣΗΣ</b> .....	<b>67</b>
8.1	ΧΡΗΣΗ ΤΡΟΠΟΠΟΙΗΜΕΝΟΥ ΑΛΓΟΡΙΘΜΟΥ K-MODES .....	68
8.2	ΧΡΗΣΗ ΔΥΝΑΜΙΚΟΥ ΑΛΓΟΡΙΘΜΟΥ K-MODES .....	69
8.3	ΧΡΗΣΗ ΜΕΘΟΔΟΥ ΕΥΡΕΣΗΣ ΕΚΤΟΠΩΝ (OUTLIER DETECTION).....	70

<b>9</b>	<b>ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ.....</b>	<b>71</b>
<b>10</b>	<b>ΕΠΙΛΟΓΟΣ.....</b>	<b>73</b>
10.1	ΣΥΝΟΨΗ ΚΑΙ ΣΥΜΠΕΡΑΣΜΑΤΑ .....	73
10.2	ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ.....	74
<b>11</b>	<b>ΒΙΒΛΙΟΓΡΑΦΙΑ .....</b>	<b>75</b>

# 1

## *Εισαγωγή*

### *1.1 Πρόλογος – Σχετικές Εργασίες*

Οι *συμβολικοί κανόνες* (symbolic rules) ή *κανόνες παραγωγής* (production rules) αποτελούν ένα δημοφιλές σχήμα αναπαράστασης της γνώσης που χρησιμοποιείται στην ανάπτυξη έμπειρων συστημάτων. Οι συμβολικοί κανόνες αναπαριστούν γενική γνώση ενός πεδίου (domain) και επιδεικνύουν έναν αριθμό από ελκυστικά χαρακτηριστικά, όπως η φυσικότητα, η τμηματοποίηση και η ευκολία παροχής επεξηγήσεων. Ένα από τα κύρια μειονεκτήματά τους είναι η δυσκολία απόκτησής τους. Οι κανόνες παραγωγής αποτελούν αντιπρόσωπο της λεγόμενης *συμβολικής αναπαράστασης* (symbolic representation).

Κατά τη διάρκεια των τελευταίων ετών, τα τεχνητά νευρωνικά δίκτυα χρησιμοποιήθηκαν αρκετά συχνά στην ανάπτυξη των έμπειρων συστημάτων (Gallant, 1993; Ghalwash 1998). Τα νευρωνικά δίκτυα αναπαριστούν μια τελείως διαφορετική προσέγγιση στο πρόβλημα της αναπαράστασης της γνώσης. Μερικά πλεονεκτήματα των νευρωνικών δικτύων είναι η ικανότητά τους να αποκτούν τη γνώση τους από πρότυπα εκπαίδευσης, το υψηλό τους επίπεδο αποδοτικότητας, και η ικανότητά τους να αναπαριστούν πολύπλοκη και ανακριβή γνώση. Τα τεχνητά νευρωνικά δίκτυα αποτελούν αντιπρόσωπο της λεγόμενης *διασυνδετικής αναπαράστασης* (connectionist representation).

Για τους λόγους αυτούς, πρόσφατα, υπήρξε εκτεταμένη ερευνητική δραστηριότητα για να συνδυαστούν (ή να ενοποιηθούν) οι συμβολικές και οι διασυνδετικές προσεγγίσεις. Πιο συγκεκριμένα, υπάρχει ένας αριθμός από προσπάθειες για να συνδυαστούν οι συμβολικοί κανόνες με τα νευρωνικά δίκτυα για την αναπαράσταση της γνώσης (Fu & Fu, 1990; Towell & Shavlik, 1994). Αυτό που κάνουν είναι ένα είδος αντιστοίχισης από τους συμβολικούς κανόνες σε ένα νευρωνικό δίκτυο. Το κύριο πλεονέκτημα αυτών των προσεγγίσεων είναι το

γεγονός ότι η εκμαίευση της γνώσης από τους εμπειρογνώμονες μειώνεται στο ελάχιστο. Ωστόσο, ένα μειονέκτημα αυτών των προσεγγίσεων είναι το γεγονός ότι τα συστήματα που προκύπτουν στερούνται τη φυσικότητα και την τμηματοποίηση των συμβολικών κανόνων. Αυτό συμβαίνει εξαιτίας του γεγονότος ότι αυτές οι προσεγγίσεις δίνουν προτεραιότητα στον *διασυνδετισμό* (connectionism). Για παράδειγμα, αυτά τα συστήματα είναι λίγο ή πολύ σαν μαύρα κουτιά, και για να εισάγει κάποιος καινούρια γνώση πρέπει να τροποποιήσει ένα μεγάλο μέρος του δικτύου. Οι διασυνδετικές βάσεις γνώσης, κατ' ουσία, δεν μπορούν να αναπτυχθούν αυξητικά.

Οι *νευρωκανόνες* (neurules) αποτελούν ένα είδος υβριδικών κανόνων που συνδυάζουν τους συμβολικούς κανόνες με τη νευρωνική υπολογιστική. Οι νευρωκανόνες επιτυγχάνουν μια ομοιόμορφη και αυστηρή ενοποίηση ενός συμβολικού τμήματος (συμβολικοί κανόνες) και ενός διασυνδετικού τμήματος (νευρώνες). Εντούτοις, δίνεται προτεραιότητα στο συμβολικό τμήμα. Η νευρωνική υπολογιστική χρησιμοποιείται μέσα στο συμβολικό πλαίσιο για να βελτιωθεί η απόδοση των συμβολικών κανόνων (Hatzilygeroudis & Prentzas, 2000). Με τον τρόπο αυτό, η βάση γνώσης που κατασκευάζεται διατηρεί την τμηματοποίηση των συμβολικών κανόνων, καθώς αποτελείται από αυτόνομες μονάδες (νευρωκανόνες), και τη φυσικότητα αυτών, καθώς οι νευρωκανόνες μοιάζουν πολύ με τους συμβολικούς κανόνες. Το μέγεθος των βάσεων νευρωκανόνων που παράγεται είναι σημαντικά μειωμένο συγκριτικά με αυτό των ισοδύναμων βάσεων συμβολικών κανόνων. Επιπροσθέτως, ο μηχανισμός εξαγωγής συμπερασμάτων είναι μια αυστηρά ολοκληρωμένη διαδικασία, που έχει σαν αποτέλεσμα πιο αποδοτικά συμπεράσματα όχι μόνο από αυτά των συμβολικών κανόνων, αλλά επίσης και από αυτά των διασυνδετικών προσεγγίσεων. Επιπλέον, ένα σύστημα που βασίζεται σε νευρωκανόνες διαθέτει έναν αλληλεπιδραστικό μηχανισμό εξαγωγής συμπερασμάτων (Hatzilygeroudis & Prentzas, 2010) και παρέχει επεξηγήσεις για συμπεράσματα που εξάχθηκαν (Hatzilygeroudis & Prentzas, 2001a). Εντούτοις, μια δυσκολία αυτής της προσέγγισης είναι η έμφυτη αδυναμία των νευρώνων να ταξινομήσουν μη διαχωρίσιμα πρότυπα εκπαίδευσης. Επιπλέον, μια αδυναμία των νευρωκανόνων είναι το γεγονός ότι προκύπτουν πολλαπλές αναπαραστάσεις της ίδιας γνώσης.

Η *συλλογιστική βασισμένη σε περιπτώσεις* (case-based reasoning) προσφέρει ορισμένα πλεονεκτήματα συγκριτικά με τους συμβολικούς κανόνες και τις άλλες μορφές αναπαράστασης της γνώσης και συλλογιστικής. Οι περιπτώσεις αναπαριστούν ειδική γνώση του πεδίου, έχουν φυσικότητα και, τις περισσότερες φορές, προκύπτουν εύκολα (Aamodt & Plaza, 1994; Kolodner, 1993; Leake, 1996). Η αυξητική μάθηση έρχεται φυσικά στη συλλογιστική βασισμένη σε περιπτώσεις. Νέες περιπτώσεις μπορούν να τοποθετηθούν σε μια



βάση γνώσης, χωρίς να γίνουν αλλαγές στην υπάρχουσα γνώση. Όσο περισσότερες περιπτώσεις είναι διαθέσιμες, τόσο καλύτερα αναπαρίσταται η *πεδιακή γνώση* (domain knowledge). Για τον λόγο αυτό, η ακρίβεια των συστημάτων που βασίζονται σε περιπτώσεις μπορεί να βελτιωθεί κατά τη διάρκεια του σταδίου λειτουργίας της, καθώς νέες περιπτώσεις γίνονται διαθέσιμες. Μια αρνητική πλευρά των περιπτώσεων συγκριτικά με τους συμβολικούς κανόνες είναι το γεγονός ότι δεν παρέχουν περιληπτικές αναπαραστάσεις της ενσωματωμένης γνώσης.

Οι προσεγγίσεις που συνδυάζουν τη συλλογιστική βασισμένη σε κανόνες και σε περιπτώσεις είχαν σαν αποτέλεσμα ενδιαφέροντα και αποδοτικά σχήματα αναπαράστασης της γνώσης (Aha & Daniels, 1998; Branting, 1999; Cercone et al., 1999; Freuder, 1998; Koton, 1988; Leake, 1995; Marling, Petot & Sterling, 1999). Το αντικείμενο αυτών των προσπαθειών είναι να προκύψουν υβριδικές αναπαραστάσεις που επαυξάνουν τις θετικές πλευρές των συνδυαστικών τύπων και ταυτόχρονα ελαχιστοποιούν τις αρνητικές πλευρές τους.

Μια πιο ενδιαφέρουσα προσέγγιση είναι ο συνδυασμός περισσότερων από δυο συλλογιστικών μεθόδων για την επίτευξη του ίδιου στόχου. Μια τέτοια προσέγγιση, που συνδυάζει τρία σχήματα αναπαράστασης, συγκεκριμένα συλλογιστική βασισμένη σε κανόνες (rule-based reasoning), νευρωνική υπολογιστική (neurocomputing) και συλλογιστική βασισμένη σε περιπτώσεις (case-based reasoning), με αποδοτικό τρόπο, εισάγεται στο (Hatzilygeroudis and Prentzas, 2004b). Για το σκοπό αυτό, συνδυάζονται οι νευρωκανόνες (neurules), ένα είδος υβριδικών κανόνων, με περιπτώσεις (cases), με παρόμοιο τρόπο όπως στο (Golding & Rosenbloom, 1996), όπου απλοί συμβολικοί κανόνες συνδυάζονται με τις περιπτώσεις. Έτσι, η προσέγγιση στο (Golding & Rosenbloom, 1996), βελτιώνεται με πολλούς τρόπους. Πρώτον, αρκετά από τα οφέλη των νευρωνικών δικτύων, όπως η απόκτηση γνώσης από εμπειρικά δεδομένα, η συλλογιστική από μερικές εισόδους και οι δυνατότητες γενίκευσης, προστίθενται στο σχήμα αναπαράστασης. Δεύτερον, το μέγεθος της βάσης γνώσης μειώνεται σημαντικά και η απόδοση της προσέγγισης βελτιώνεται. Από την άλλη πλευρά, βελτιώνονται και οι νευρωκανόνες. Οι νευρωκανόνες μπορούν να παραχθούν από συμβολικούς κανόνες, που αποτελούν την πηγή γνώσης τους. Αν η πηγή γνώσης είναι ημιτελής ή δεν καλύπτει την πλήρη πολυπλοκότητα του πεδίου, αυτό αντικατοπτρίζεται στους νευρωκανόνες που παράγονται. Συνδυάζοντας τους νευρωκανόνες με τις περιπτώσεις, η ακρίβειά τους βελτιώνεται.

## 1.2 Αντικείμενο μεταπτυχιακής εργασίας

Οι νευροκανόνες είναι μια προσέγγιση αναπαράστασης γνώσης που συνδυάζει συμβολικούς κανόνες (**symbolic rules**) και νευρωνικά δίκτυα (**neural nets**), πιο συγκεκριμένα τη νευρωνική μονάδα ADALINE (ADaptive LINear Element). Η δημιουργία των νευροκανόνων γίνεται από εμπειρικά δεδομένα προσδιορίζοντας ένα σύνολο εκπαίδευσης για κάθε νευροκανόνα, που θεωρείται ως μια μονάδα ADALINE. Μειονέκτημα της αναπαράστασης μέσω νευροκανόνων αποτελεί το γεγονός ότι κατά τη δημιουργία τους παράγονται περισσότεροι του ενός νευροκανόνες με το ίδιο συμπέρασμα μειώνοντας τη φυσικότητα της αναπαράστασης. Το γεγονός αυτό συμβαίνει διότι μια νευρωνική μονάδα δεν μπορεί να εκπαιδευτεί ώστε να αναπαριστά ένα μη γραμμικό σύνολο παραδειγμάτων. Στις περιπτώσεις, λοιπόν, όπου το σύνολο εκπαίδευσης είναι μη διαχωρίσιμο, η σχετική μέθοδος δημιουργίας νευροκανόνων βασίζεται στην έννοια της «εγγύτητας» μεταξύ των παραδειγμάτων. Πιο συγκεκριμένα, σε κάθε μη διαχωρίσιμο σύνολο εκπαίδευσης εντοπίζεται ένα ζεύγος παραδειγμάτων με την ελάχιστη «εγγύτητα» (**Least Closeness Pair**). Το μη διαχωρίσιμο σύνολο εκπαίδευσης «σπάζει» σε δύο υποσύνολα οδηγούμενο από το επιλεγμένο ζεύγος (**Least Closeness Pair**), ενώ η διαδικασία της διάσπασης συνεχίζεται αναδρομικά μέχρις ότου προκύψουν γραμμικά υποσύνολα, για κάθε ένα από τα οποία παράγεται και ένας νευροκανόνας.

Τίθεται, επομένως, το ζήτημα του βαθμού αποδοτικότητας της προηγούμενης διαδικασίας διάσπασης, δηλαδή, αν ο συνολικός αριθμός των παραγόμενων νευροκανόνων είναι ο μικρότερος δυνατός, ή αν μπορεί με κάποια άλλη διαδικασία διάσπασης να παράγονται λιγότεροι νευροκανόνες. Στα πλαίσια της παρούσας εργασίας το ενδιαφέρον μας θα στραφεί στην εξέταση της δυνατότητας διάσπασης ενός μη διαχωρίσιμου συνόλου εκπαίδευσης σε υποσύνολα με χρήση μεθόδων συσταδοποίησης (**clustering**). Αντί, λοιπόν, η διάσπαση του μη διαχωρίσιμου συνόλου εκπαίδευσης να κατευθύνεται από ζεύγη ελάχιστης «εγγύτητας» (**Least Closeness Pair**), ο αριθμός των διαφορετικών υποσυνόλων-συστάδων (**clusters**) στα οποία πρέπει αυτό να «σπάσει» προσδιορίζεται μέσα από αλγόριθμους συσταδοποίησης (**clustering**). Ειδικότερα θα προσπαθήσουμε να παρουσιάσουμε την εφαρμογή και αξιολόγηση τέτοιων τεχνικών αλλά και να τις συνδυάσουμε με μία μέθοδο εύρεσης εκτόπων (**outlier detection**) που θα εντοπίζει και θα αφαιρεί σε κάθε αρχικό σύνολο εκπαίδευσης παραδείγματα-έκτοπα (**outliers**). Τα παραδείγματα που αφαιρούνται δεικτοδοτούνται ως εξαιρέσεις των νευροκανόνων που παράγονται και αποθηκεύονται ως περιπτώσεις (**cases**). Με τον τρόπο αυτό, το όλο σύστημα παραμένει τριπλά υβριδικό έχοντας μια επιπλέον πηγή

περιπτώσεων-εξαιρέσεων. Τα πρότυπα εκπαίδευσης που αφαιρούνται είναι αυτά που «απέχουν» περισσότερο από τα υπόλοιπα στο αρχικό σύνολο εκπαίδευσης, με αυτή την «απόσταση» να ορίζεται με τη βοήθεια κάποιας μετρικής απόστασης.

### ***1.3 Οργάνωση κειμένου***

Το υπόλοιπο της διπλωματικής εργασίας οργανώνεται ως εξής. Η **Ενότητα 2** αναπτύσσει το θεωρητικό υπόβαθρο της εργασίας. Η **Ενότητα 3** παρουσιάζει τους νευροκανόνες, ενώ η **Ενότητα 4** παρουσιάζει την αρχιτεκτονική που συνδυάζει τη συλλογιστική βασισμένη σε νευροκανόνες και σε περιπτώσεις. Η **Ενότητα 5** συζητά μεθόδους για την κατασκευή του σχήματος δεικτοδότησης της βιβλιοθήκης περιπτώσεων. Ύστερα, στις **Ενότητες 6 και 7** περιγράφονται μέθοδοι συσταδοποίησης και εύρεσης εκτόπων (outlier detection). Στις **Ενότητες 8 και 9** αναλύεται η διαδικασία δημιουργίας νευροκανόνων με τη χρήση μεθόδων συσταδοποίησης και τα αποτελέσματα της εφαρμογής τους σε κάποια σύνολα εκπαίδευσης. Τέλος, η **Ενότητα 10** καταλήγει.

# 2

## Θεωρητικό υπόβαθρο

### 2.1 Αναπαράσταση της γνώσης

Η γνώση (knowledge) και η αναπαράσταση της γνώσης (knowledge representation) παίζουν κεντρικό ρόλο στην τεχνητή νοημοσύνη (artificial intelligence). Η αναπαράσταση της γνώσης είναι μια περιοχή της τεχνητής νοημοσύνης που ασχολείται με το πώς μπορεί καλύτερα και αποδοτικότερα να αναπαρασταθεί γνώση γύρω από ένα πεδίο μέσα σ' έναν Η/Υ για την επίλυση προβλημάτων (Χατζηλυγερούδης, 2004).

Η αναγκαιότητα εισαγωγής της γνώσης σε συστήματα τεχνητής νοημοσύνης διαπιστώθηκε, όταν προσπάθειες για την κατασκευή ευφυών συστημάτων που θα μπορούσαν να είναι γενικοί λύτες προβλημάτων απέτυχαν. Ένα τέτοιο παράδειγμα ήταν η προσπάθεια των Ernst & Newell (1969), που κατέληξε στο σύστημα *GPS* (General Problem Solver). Τα συμπεράσματα απ' αυτήν την προσπάθεια ήταν: α) γενικές, έστω και ισχυρές, μέθοδοι δεν είναι αρκετές για την εμφάνιση ευφυούς συμπεριφοράς, και β) είναι απαραίτητη η ύπαρξη ικανής ποσότητας εξειδικευμένης γνώσης ακόμη και για την εκδήλωση απλής ευφυούς συμπεριφοράς. Για τον λόγο αυτό, κρίθηκε απαραίτητη η ενσωμάτωση εξειδικευμένης γνώσης σε συστήματα τεχνητής νοημοσύνης, που σαν επακόλουθο είχε και το πρόβλημα της αναπαράστασής της.

Μια προφανής λύση γι' αυτήν την ενσωμάτωση θα συνιστούσε προγραμματισμό αυτής της γνώσης μέσα στο όλο σύστημα. Αυτή η προσέγγιση, όμως, θα είχε τις εξής αδυναμίες: α) σύνδεση του συστήματος με συγκεκριμένο προβληματισμό, β) αδυναμία προσδιορισμού της γενικότητας μιας λύσης, και γ) αδυναμία παροχής επεξηγήσεων της λύσης. Η προσέγγιση που κατά κανόνα χρησιμοποιεί σήμερα η τεχνητή νοημοσύνη εκφράζεται από την «Υπόθεση Αναπαράστασης της Γνώσης» που διατυπώθηκε από τον Smith(1982):


«Οποιαδήποτε μηχανικά ενσωματωμένη ευφυής διαδικασία περιλαμβάνει δομικά συστατικά τα οποία α) εξωτερικοί παρατηρητές φυσικά εκλαμβάνουν ότι αναπαριστούν μια προτασιακή έκθεση της γνώσης που η διαδικασία φανερώνει, και β) ανεξάρτητα από το τι εξωτερικοί παρατηρητές σημασιολογικά εκλαμβάνουν ότι είναι, παίζουν έναν βασικό και αιτιατό ρόλο στη γένεση της συμπεριφοράς που εκδηλώνει τη γνώση».

Η υπόθεση αυτή τονίζει δυο κρίσιμα σημεία σχετικά με την εκδήλωση ευφυούς συμπεριφοράς:

- για να αναπαριστάνουν γνώση οι συμβολικές δομές ενός συστήματος πρέπει να είναι δυνατόν να τις ερμηνεύσουμε προτασιακά, σαν εκφράσεις στις οποίες μπορούν να αποδοθούν έννοιες αλήθειας (να θεωρηθούν είτε σαν αληθείς είτε σαν ψευδείς).
- η παρουσία των δομών αυτών είναι που πρέπει να προκαλεί την ευφυή συμπεριφορά που εκδηλώνεται από το σύστημα. Για παράδειγμα, η ύπαρξη σχολίων σ' ένα πρόγραμμα δεν συνιστά ευφυή συμπεριφορά.

Συνοψίζοντας, αυτό που τελικά ισχυρίζεται η υπόθεση αναπαράστασης της γνώσης είναι ότι η γνώση πρέπει να αναπαρίσταται προτασιακά, και ότι ευφυής συμπεριφορά μπορεί να προκύψει από τον υπολογιστικό χειρισμό των αντίστοιχων συμβολικών δομών.

Επομένως, οποιοδήποτε σύστημα που εκδηλώνει ευφυή συμπεριφορά περιλαμβάνει δυο βασικά δομικά στοιχεία. Το πρώτο είναι μια *βάση γνώσης* (knowledge base) και το δεύτερο είναι μια *μηχανή εξαγωγής συμπερασμάτων* (inference engine). Η γνώση δεν προγραμματίζεται στο σύστημα αλλά περιγράφεται ρητά στη βάση γνώσης με τη βοήθεια κάποιας τυπικής (αυστηρής) γλώσσας, που ονομάζεται *γλώσσα αναπαράστασης γνώσης* (knowledge representation language). Η βάση γνώσης αποτελείται από ένα σύνολο εκφράσεων (προτάσεων) μιας γλώσσας αναπαράστασης γνώσης που περιγράφουν την ενσωματωμένη στο σύστημα γνώση. Η μηχανή εξαγωγής συμπερασμάτων διαχειρίζεται τη βάση γνώσης. Η μηχανή εξαγωγής συμπερασμάτων επεξεργάζεται τις εκφράσεις στη βάση γνώσης για να παράγει ευφυή συμπεριφορά (βλ. **Εικόνα 1**).



Εικόνα 1. Η βασική δομή ενός ευφυούς συστήματος

Πάνω σ' αυτήν την προσέγγιση στηρίζεται η σχεδίαση συστημάτων τεχνητής νοημοσύνης. Τα λεγόμενα *συστήματα βασισμένα στη γνώση* (knowledge based systems) είναι ακριβώς αυτά τα συστήματα που έχουν σχεδιαστεί με βάση την παραπάνω προσέγγιση. Τα *έμπειρα συστήματα* (expert systems) αποτελούν τον βασικό όγκο των συστημάτων βασισμένων στη γνώση, ώστε οι δυο όροι να χρησιμοποιούνται σαν συνώνυμοι, αν και ο δεύτερος είναι πιο γενικός.

## 2.2 Έμπειρα συστήματα

Τα *έμπειρα συστήματα* (expert systems) είναι υπολογιστικά συστήματα που εμφανίστηκαν σαν πρακτική εφαρμογή της έρευνας και των πορισμάτων της τεχνητής νοημοσύνης στα μέσα της δεκαετίας του 70. Λειτουργούν σαν προσομοιωτές της ανθρώπινης σκέψης για τη λύση προβλημάτων, οι οποίοι προσφέρουν ορισμένα πλεονεκτήματα έναντι του ανθρώπου-εμπειρογνώμονα. Τα έμπειρα συστήματα χρησιμοποιούνται κυρίως σαν σύμβουλοι των ειδικών (εμπειρογνομώνων) για τη λήψη αποφάσεων. Ένα έμπειρο σύστημα είναι ένα πρόγραμμα Η/Υ που μιμείται σε κάποιο βαθμό τις διαδικασίες λήψης αποφάσεων ενός ανθρώπου-εμπειρογνώμονα. Αυτό το επιτυγχάνει στηριζόμενο σε εκτεταμένη γνώση γύρω από ένα στενό πεδίο προβλημάτων, που το σύστημα καλείται να αντιμετωπίσει.

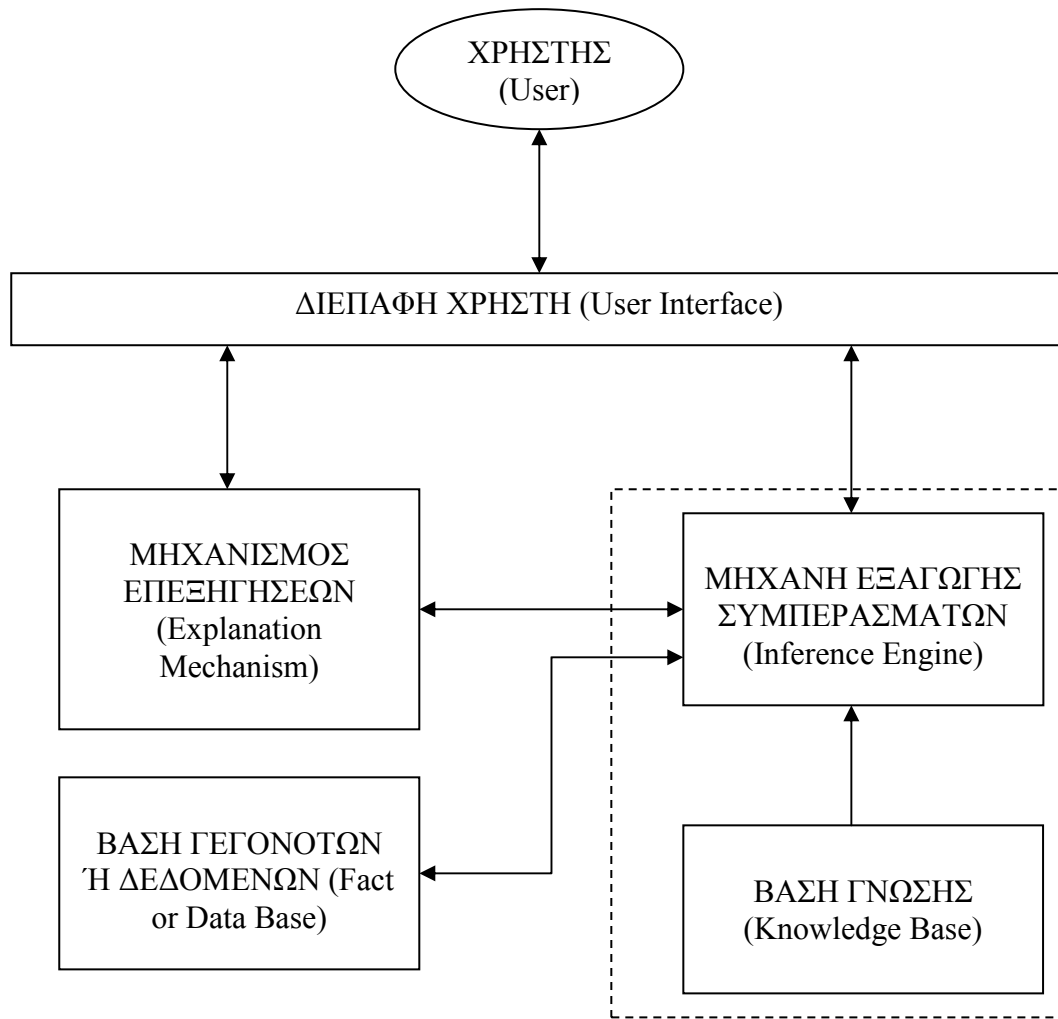
Τα βασικά φυσικά χαρακτηριστικά που ξεχωρίζουν ένα έμπειρο σύστημα από ένα συμβατικό πρόγραμμα είναι:

- μπορεί και χειρίζεται όχι μόνο αριθμούς, αλλά και σύμβολα.
- υπάρχει διαχωρισμός μεταξύ γνώσης και χρήσης της γνώσης.
- χρησιμοποιεί ευρετική γνώση (heuristic knowledge) σχετική με το πεδίο εφαρμογής.

Η ακόλουθη εξίσωση συχνά χρησιμοποιείται για την περιγραφή ενός έμπειρου συστήματος:

$$\text{Έμπειρο Σύστημα} = \text{Γνώση} + \text{Συλλογισμός}$$

Έτσι, ο πυρήνας ενός έμπειρου συστήματος αποτελείται από δύο βασικές συνιστώσες, τη *βάση γνώσης* (knowledge base) και τον *μηχανισμό ή μηχανή εξαγωγής συμπερασμάτων* (inference mechanism/engine). Πρακτικά όμως, ένα έμπειρο σύστημα συνήθως περιλαμβάνει επιπλέον μια *συνιστώσα επικοινωνίας χρήστη* (user interface), μια *βάση εργασίας* (working database), και, ίσως, έναν *μηχανισμό επεξηγήσεων* (explanation mechanism). Η δομή ενός πλήρους έμπειρου συστήματος απεικονίζεται στην **Εικόνα 2**, όπου ο βασικός πυρήνας σημειώνεται μέσα σε ορθογώνιο με διακεκομμένη γραμμογράφηση.



Εικόνα 2. Η δομή ενός έμπειρου συστήματος

*Βάση Γνώσης.* Περιέχει τη γνώση γύρω από το πεδίο εφαρμογής για το οποίο έχει σχεδιαστεί το έμπειρο σύστημα, και η οποία συνήθως αποκτάται από τη σχετική βιβλιογραφία και από εμπειρογνώμονες στο αντικείμενο της εφαρμογής. Η γνώση κωδικοποιείται σαν *γεγονότα* (facts) και *κανόνες* (rules), μέσω κάποιας γλώσσας αναπαράστασης της γνώσης, και αποτελεί τη μόνιμη γνώση του συστήματος. Η πιο διαδεδομένη γλώσσα αναπαράστασης της γνώσης στα έμπειρα συστήματα είναι οι *κανόνες παραγωγής* (production rules). Γι' αυτό και συνήθως ταυτίζονται οι όροι «προσέγγιση/ τεχνολογία έμπειρων συστημάτων» (expert system approach/ technology) και «προσέγγιση/ τεχνολογία βασισμένη σε κανόνες» (rule-based approach/ technology). Έτσι, η βάση γνώσης αποτελείται συνήθως από κανόνες και καλείται *βάση κανόνων* (rule base). Όμως, σε κάποιες περιπτώσεις, χρησιμοποιούνται και άλλες



γλώσσες αναπαράστασης της γνώσης, όπως τα πλαίσια (frames), τα σημαντικά δίκτυα (semantic nets) και η λογική πρώτης τάξεως (first-order logic). Αυτές οι γλώσσες αναπαράστασης της γνώσης χρησιμοποιούνται συνήθως μαζί με τους κανόνες παραγωγής, ως δεύτερο συστατικό υβριδικής γλώσσας αναπαράστασης της γνώσης. Είναι γεγονός ότι τα τελευταία χρόνια άρχισαν να χρησιμοποιούνται υβριδικές γλώσσες αναπαράστασης της γνώσης, δηλαδή γλώσσες που συνδυάζουν στοιχεία από δύο ή περισσότερες από τις αναφερθείσες βασικές γλώσσες αναπαράστασης της γνώσης. Μια συνήθης τέτοια περίπτωση είναι ο συνδυασμός πλαισίων και κανόνων παραγωγής.

*Βάση Εργασίας.* Η βάση εργασίας περιέχει κάθε φορά γνώση σχετική με γεγονότα που αφορούν το υπό εξέταση συγκεκριμένο πρόβλημα/ ερώτημα. Αυτή η γνώση αλλάζει όταν αλλάζει το υπό εξέταση πρόβλημα, σε αντίθεση με τη γνώση στη βάση γνώσης, που παραμένει αμετάβλητη. Στη βάση εργασίας, επομένως, καταχωρούνται πληροφορίες για την αρχική κατάσταση (αρχικές υποθέσεις/ συνθήκες) του προβλήματος, απαντήσεις του χρήστη σε ερωτήσεις του έμπειρου συστήματος, ενδιάμεσα συμπεράσματα και τελικά συμπεράσματα. Πολλές φορές η βάση εργασίας δεν αναφέρεται σαν ξεχωριστή μονάδα αλλά θεωρείται ενσωματωμένη στη βάση γνώσης.

*Μηχανισμός Εξαγωγής Συμπερασμάτων.* Ο μηχανισμός εξαγωγής συμπερασμάτων εξάγει συμπεράσματα χρησιμοποιώντας τα δεδομένα της βάσης εργασίας και τη γνώση της βάσης γνώσης. Καθορίζει το πώς θα χρησιμοποιηθεί η γνώση που βρίσκεται στη βάση γνώσης (και στη βάση εργασίας) για τη λύση του εκάστοτε προβλήματος. Για κάθε συγκεκριμένο πρόβλημα καθορίζει ποια δεδομένα θα χρησιμοποιηθούν σε ποια δεδομένη στιγμή της διαδικασίας, ποιοι κανόνες θα ενεργοποιηθούν και με ποια σειρά, για ποια δεδομένα θα ερωτηθεί ο χρήστης κ.λ.π. Ο μηχανισμός εξαγωγής συμπερασμάτων εργάζεται ανεξάρτητα από τη βάση γνώσης. Δηλαδή, υπάρχει διαχωρισμός της γνώσης (βάση γνώσης) από τον τρόπο χρήσης της (μηχανισμός εξαγωγής συμπερασμάτων). Αυτό είναι ένα από τα κύρια χαρακτηριστικά των έμπειρων συστημάτων, όπως προαναφέρθηκε. Λόγω αυτού, ο ίδιος μηχανισμός εξαγωγής συμπερασμάτων μπορεί να χρησιμοποιηθεί για περισσότερες από μια βάσεις γνώσης. Αυτό αποτελεί και τη βάση στην οποία στηρίζονται τα κελύφη (shells) έμπειρων συστημάτων.

*Συνιστώσα Επικοινωνίας Χρήστη.* Η συνιστώσα επικοινωνίας χρήστη είναι το μέσο μέσω του οποίου ο χρήστης επικοινωνεί με τις διάφορες μονάδες του έμπειρου συστήματος. Μια

βασική μορφή επικοινωνίας είναι η δυνατότητα διερεύνησης ή/ και μεταβολής του περιεχομένου της βάσης γνώσης. Μια άλλη συνήθης μορφή επικοινωνίας είναι αυτή που γίνεται μέσω ερωτήσεων-απαντήσεων κατά τη διάρκεια μιας διαδικασίας εξαγωγής κάποιου συμπεράσματος, για τη συλλογή δεδομένων προς τη λύση του υπό εξέταση προβλήματος. Τέλος, μια άλλη μορφή είναι η δυνατότητα παροχής επεξηγήσεων για την εξαγωγή κάποιου συμπεράσματος.

*Συνιστώσα Επεξηγήσεων.* Η συνιστώσα επεξηγήσεων είναι υπεύθυνη για την παροχή επεξηγήσεων όσον αφορά το πώς (how) εξήχθη κάποιο συμπέρασμα ή το γιατί (why) γίνεται κάποια ερώτηση ή το ποιο θα ήταν το συμπέρασμα σε περίπτωση που διαφορετικά δεδομένα είχαν δοθεί, γνωστή σαν «τι εάν» (what if) διαδικασία.

Τα βασικά λειτουργικά χαρακτηριστικά ενός έμπειρου συστήματος είναι τα εξής:

- *Εξαγωγή συμπερασμάτων (inference), χωρίς να είναι απαραίτητη όλη η διαθέσιμη πληροφορία-γνώση.* Για την εξαγωγή κάποιου συμπεράσματος δεν απαιτείται να έχουμε γνώση/ πληροφορία για τις τιμές όλων των μεταβλητών του συστήματος, αλλά μόνο για αυτές που αφορούν τη συγκεκριμένη εξαγωγή συμπεράσματος.
- *Διαδραστική καθοδήγηση της εισόδου δεδομένων στο σύστημα.* Αυτό συνδέεται με το προηγούμενο, καθώς το σύστημα ζητά από τον χρήστη την απαιτούμενη γνώση/ πληροφορία κατά τη διάρκεια της λειτουργίας του.
- *Επεξήγηση των συμπερασμάτων.* Ένα έμπειρο σύστημα πρέπει να είναι ικανό να δίνει εξηγήσεις για τα συμπεράσματα που εξάγει με απλό και κατανοητό τρόπο.
- *Τμηματοποίηση.* Η τμηματοποίηση αναφέρεται σε δύο επίπεδα. Πρώτον, η βάση γνώσης έχει τμηματοποίηση αναπαράστασης, δηλαδή η γνώση αποτελείται από ανεξάρτητες μονάδες γνώσης (π.χ. κανόνες) που συνδέονται μεν μεταξύ τους εννοιολογικά, αλλά όχι συντακτικά. Αυτό δημιουργεί μια ευελιξία στην αναπαράσταση γνώσης και στη δημιουργία της βάσης γνώσης. Δεύτερον, υπάρχει τμηματοποίηση στη δομή ενός έμπειρου συστήματος. Αυτό συνδέεται με το διαχωρισμό της γνώσης από τη χρήση της, που αναφέρθηκε πιο πάνω.

### **2.3 Συστήματα παραγωγής (Συστήματα βασισμένα σε κανόνες)**

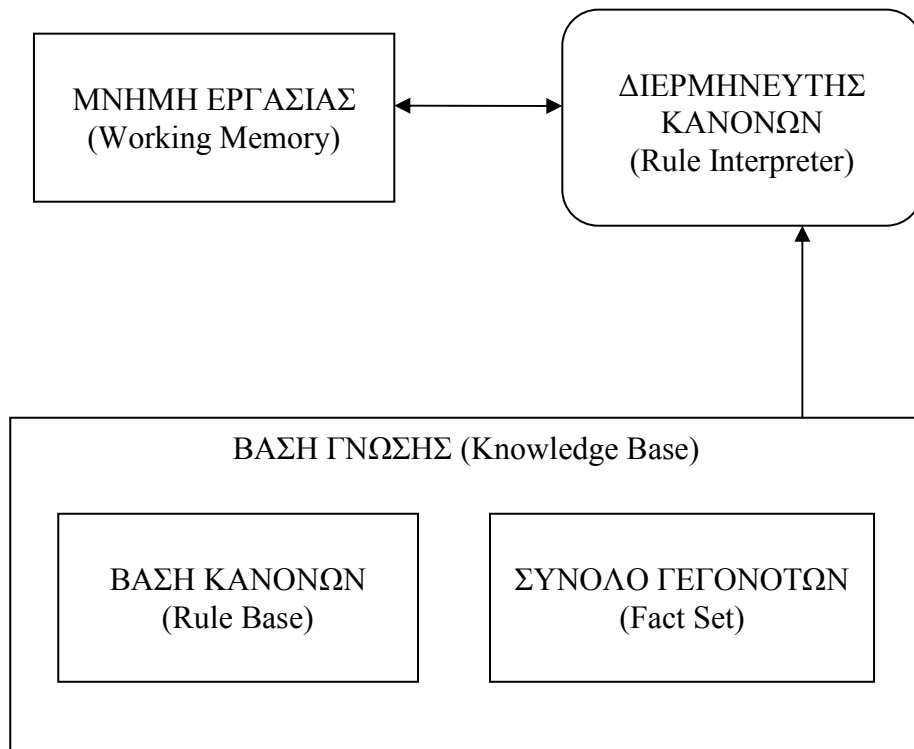
Η πρώτη νύξη για τα συστήματα παραγωγής προήλθε από τον Post το 1943 ο οποίος και τα παρουσίασε σαν έναν γενικό μηχανισμό υπολογισμού. Με την πάροδο του χρόνου, όμως,

αναπτύχθηκαν διάφορες θεωρίες, και τα συστήματα παραγωγής εφαρμόστηκαν στη λύση προβλημάτων εντελώς διαφορετικών μεταξύ τους. Στις αρχές της δεκαετίας του 70 μελετήθηκε για πρώτη φορά και εφαρμόστηκε από τους A.Newell και H.A.Simon, η έννοια του συστήματος παραγωγής, ως ένα ψυχολογικό μοντέλο περιγραφής της ανθρώπινης συμπεριφοράς στο σύστημα GPS (General Problem Solver). Σε αυτό το μοντέλο οι γνώσεις του ανθρώπου για τη λύση των προβλημάτων αναπαρίστανται με ένα σύνολο διακεκριμένων γνωστικών μονάδων, που καλούνται *κανόνες παραγωγής* (production rules). Οι διακεκριμένες αυτές μονάδες περιέχουν πληροφορίες σχετικά με τις πράξεις (ενέργειες) τις οποίες πρέπει να εκτελέσει ένας άνθρωπος αντιδρώντας στα διάφορα ερεθίσματα τα οποία δέχεται από το περιβάλλον του. Οι ενέργειες αυτές είναι δυνατόν να επηρεάσουν τον τρόπο με τον οποίο αντιλαμβάνεται την πραγματικότητα γύρω του, είτε διότι οι συνέπειες που προκύπτουν από τις πράξεις οδηγούν σε αναθεώρηση προηγούμενων αξιωμάτων και υποθέσεων, είτε διότι μπορεί να οδηγήσουν σε παραγωγή μιας νέας μορφής πραγματικότητας, που απαιτεί νέα έρευνα.

Το μοντέλο των Newell και Simon έχει ομοιότητες με μια θεωρία της ψυχολογίας της νόησης, που αναλύει τη μνήμη σε δυο στάδια. Σύμφωνα με αυτήν τη θεωρία υπάρχουν δύο διαφορετικά είδη μηχανισμών για την αποθήκευση της πληροφορίας που καταγράφεται από τα αισθητήρια όργανα του ανθρώπου, η βραχυπρόθεσμη και η μακροπρόθεσμη μνήμη. Η βραχυπρόθεσμη μνήμη περιέχει μια περιορισμένη ποσότητα πληροφορίας, η οποία μειώνεται με γρήγορο ρυθμό, και συνδέεται με το τμήμα συστήματος παραγωγής στο οποίο κρατούνται τα δεδομένα εισόδου καθώς και τα παραγόμενα δεδομένα, και το οποίο ονομάζεται μνήμη εργασίας. Η μακροπρόθεσμη μνήμη χρησιμοποιείται για τη μόνιμη αποθήκευση πληροφοριών και αντιστοιχεί στη βάση κανόνων του συστήματος παραγωγής. Η μορφή των κανόνων παραγωγής έχει υιοθετηθεί και από άλλους ερευνητές εκτός των Newell και Simon. Οι περισσότεροι, όμως, από αυτούς χρησιμοποιούν τη μορφή των κανόνων παραγωγής απλώς σαν μια τυπική γλώσσα για την έκφραση ορισμένων τύπων γνώσης.

Πολλά έμπειρα συστήματα χρησιμοποιούν τη μορφή των κανόνων παραγωγής σαν έναν τρόπο αναπαράστασης γνώσης. Από πρακτική εμπειρία έχει αποδειχτεί ότι ο τρόπος αυτός είναι κατάλληλος για τη λύση προβλημάτων κατηγοριοποίησης (classification) στα οποία η διαθέσιμη γνώση παίρνει τη μορφή «κανόνων του αντίχειρα». Για παράδειγμα, έχει χρησιμοποιηθεί στο DENDRAL, ένα έμπειρο σύστημα για την πρόβλεψη της μοριακής δομής μιγμάτων. Ένα μέρος της απαραίτητης γνώσης, που εξυπηρετεί τους σκοπούς του συστήματος αυτού έχει κωδικοποιηθεί με κανόνες παραγωγής. Η μεγαλύτερη όμως επιτυχία της μορφής των κανόνων παραγωγής έγκειται στη χρήση της στα συστήματα MYCIN και

EMYCIN για τη δημιουργία διαγνωστικών έμπειρων συστημάτων, καθώς και στο σύστημα OPS5.



Εικόνα 3. Η δομή ενός συστήματος βασισμένου σε κανόνες

Η βασική δομή ενός συστήματος βασισμένου σε κανόνες απεικονίζεται στην **Εικόνα 3**. Ένα σύστημα βασισμένο σε κανόνες (σύστημα παραγωγής) αποτελείται από τρία βασικά μέρη: μια *βάση γνώσης* (knowledge base), έναν *διερμηνευτή κανόνων* (rule interpreter) και μια *μνήμη εργασίας* (working memory). Η δομή αυτή είναι παρόμοια με τη βασική δομή ενός έμπειρου συστήματος, αφού τα συστήματα βασισμένα σε κανόνες αποτελούν τον κύριο όγκο των έμπειρων συστημάτων, όπου η μνήμη εργασίας αντιστοιχεί στη βάση εργασίας, και ο διερμηνευτής κανόνων στον μηχανισμό εξαγωγής συμπερασμάτων. Στη συνέχεια αναλύονται το περιεχόμενο και ο ρόλος του κάθε μέρους.

Η βάση γνώσης αποτελείται από μια *βάση κανόνων* (rule base) και ένα *σύνολο γεγονότων* (fact set). Οι *κανόνες* (rules) είναι υποθετικές εκφράσεις που έχουν ένα τμήμα *υποθέσεων* (conditions) και ένα τμήμα *επακόλουθων* (consequences). Η ερμηνεία ενός κανόνα γίνεται ως

εξής: αν οι υποθέσεις ικανοποιούνται, τότε και τα επακόλουθα ικανοποιούνται επίσης. Ένα επακόλουθο μπορεί να προσδιορίζει είτε μια ενέργεια είτε ένα συμπέρασμα. Στην πρώτη περίπτωση οι ενέργειες εκτελούνται, όταν οι υποθέσεις ικανοποιούνται, στη δεύτερη περίπτωση εξάγονται τα συμπεράσματα. Οι κανόνες μπορεί να εκφράζουν διάφορα είδη γνώσης, όπως π.χ. λογικές σχέσεις μεταξύ οντοτήτων για εύρεση λύσεων που απαιτούν επαγωγική διαδικασία ή αιτιακές σχέσεις μεταξύ τους για τον προσδιορισμό των αιτιών για κάποια συμβάντα κ.λ.π.

Τα γεγονότα (facts) εκφράζουν ισχυρισμούς που αφορούν ιδιότητες, σχέσεις, προτάσεις κ.λ.π. Σε αντίθεση με τους κανόνες, που αποτελούν εν δυνάμει γνώση αποκαλυπτόμενη κατά τη διάρκεια της αναζήτησης λύσεων, τα γεγονότα είναι στατική γνώση, αδρανής, που δεν απαιτεί κάποια ενεργοποίηση κατά τη διάρκεια χρήσης του συστήματος.

Ένα σύστημα βασισμένο σε κανόνες, εκτός από τη βάση γνώσης, που αποτελεί τη στατική ή μόνιμη μνήμη (γνώση) του, διαθέτει και μια προσωρινή μνήμη (γνώση), τη μνήμη εργασίας, όπου κρατούνται προσωρινοί ισχυρισμοί (γεγονότα). Οι ισχυρισμοί αυτοί είναι είτε δεδομένα εισόδου, είτε ενδιάμεσα συμπεράσματα που εξάγονται κατά τη λειτουργία του συστήματος για την εύρεση λύσης σε ένα πρόβλημα. Επομένως, το περιεχόμενο της μνήμης εργασίας αντανακλά κάθε στιγμή την παρούσα κατάσταση της διαδικασίας λύσης ενός προβλήματος. Παρακολουθώντας δηλαδή τις μεταβολές στη μνήμη εργασίας είναι σαν να παρακολουθούμε τις διάφορες καταστάσεις (φάσεις) που περνά το σύστημα κατά τη διάρκεια επίλυσης του προβλήματος. Οι ισχυρισμοί της μνήμης εργασίας έχουν συνήθως την ίδια μορφή με τα γεγονότα στη βάση γνώσης.

Τέλος, ο διερμηνευτής κανόνων αποτελεί τον μηχανισμό εξαγωγής συμπερασμάτων (συλλογισμού) του συστήματος βασισμένου σε κανόνες. Γι' αυτόν τον σκοπό χρησιμοποιεί το περιεχόμενο της μνήμης εργασίας, και τους κανόνες και τα γεγονότα από τη βάση γνώσης. Το περιεχόμενο της μνήμης εργασίας αντιπροσωπεύει την παρούσα κατάσταση του προβλήματος και ο διερμηνευτής κανόνων καλείται να ανιχνεύσει ποιοι κανόνες μπορούν να βοηθήσουν στην περαιτέρω λύση του προβλήματος και να τους εφαρμόσει έτσι ώστε καλύτερα να οδηγηθεί το σύστημα σε λύση του προβλήματος μέσω διαδοχικών καταστάσεων. Τα ενδιάμεσα συμπεράσματα που εξάγονται κατά την προσπάθεια αυτή χρησιμοποιούνται για ενημέρωση της μνήμης εργασίας.

## 2.4 Κανόνες παραγωγής (Συμβολικοί κανόνες)

Οι *συμβολικοί κανόνες* (symbolic rules) ή *κανόνες παραγωγής* (production rules) είναι μια γλώσσα αναπαράστασης γνώσης που χρησιμοποιείται ευρέως στην κατασκευή έμπειρων συστημάτων. Ένας κανόνας παραγωγής έχει την εξής γενική μορφή:

```
if <συνθήκες>  
then <συμπεράσματα>
```

Σε κάθε κανόνα παραγωγής ξεχωρίζει κάποιος, όπως είναι φανερό, δυο τμήματα: το if-τμήμα (if-part) ή τμήμα συνθηκών (conditions) ή αριστερό (left hand side) τμήμα του κανόνα ή προϋποθέσεις (premises), και το then-τμήμα (then-part) ή τμήμα συμπερασμάτων (conclusions) ή δεξί (right hand side) τμήμα του κανόνα ή επακόλουθα (consequences). Το τμήμα <συνθήκες> αποτελείται από έναν αριθμό συνθηκών και το τμήμα <συμπεράσματα> αποτελείται από έναν αριθμό συμπερασμάτων (ενεργειών) που συνδέονται μεταξύ τους με λογικά συνδετικά. Αν πληρούνται οι συνθήκες, τότε εκτελούνται οι ενέργειες.

Στη συνέχεια, παρουσιάζεται σε μορφή BNF (Backus Naur Form) μια απλή γλώσσα βασισμένη σε κανόνες παραγωγής:

```
<κανόνας> ::= if <συνθήκες> then <συμπεράσματα>  
<συνθήκες> ::= <συνθήκη> { and <συνθήκη> } *  
<συμπεράσματα> ::= <συμπέρασμα> { and <συμπέρασμα> } *  
<συνθήκη> ::= <μεταβλητή> <κατηγορήμα> <σταθερά>  
<συμπέρασμα> ::= <μεταβλητή> <κατηγορήμα> <σταθερά>
```

Στον ορισμό αυτό, κάθε <μεταβλητή> αναπαριστά μια αφηρημένη έννοια του πεδίου γνώσης, κάθε <σταθερά> αναπαριστά μια συγκεκριμένη οντότητα του πεδίου γνώσης, ενώ κάθε <κατηγορήμα> αναπαριστά μια σχέση μεταξύ μιας έννοιας και μιας οντότητας. Παραλλαγές του παραπάνω ορισμού μπορεί να περιλαμβάνουν και το συνδετικό *or* μεταξύ των συνθηκών ή τη χρήση μεταβλητών στη θέση <σταθερά>.

Τα πλεονεκτήματα των κανόνων παραγωγής σαν γλώσσα αναπαράστασης γνώσης μπορούν να συνοψιστούν στα εξής.

- *Φυσικότητα έκφρασης*. Η γνώση ενός ειδικού εκφράζεται πολύ φυσικά μέσω των κανόνων παραγωγής. Οι κανόνες παραγωγής διαιρούν τη γνώση σε φυσικά και

εύκολα κατανοητά τμήματα που έχουν το σωστό μέγεθος για την αναπαράσταση της γνώσης που χρησιμοποιούν οι ειδικοί.

- *Τμηματοποίηση (modularity) της γνώσης.* Οι κανόνες παραγωγής είναι κατασκευαστικά ανεξάρτητοι μεταξύ τους. Κάθε κανόνας παραγωγής αναπαριστά ένα κομμάτι γνώσης ανεξάρτητα από τους υπόλοιπους κανόνες παραγωγής. Επίσης, υπάρχει διαχωρισμός μόνιμης (βάση γνώσης) και προσωρινής (μνήμη εργασίας) γνώσης. Τέλος, ο διερμηνευτής είναι ανεξάρτητος και από τη βάση γνώσης και από την μνήμη εργασίας. Αυτή η τμηματοποίηση και διαχωριστικότητα της γνώσης οδηγεί σε ορισμένα πλεονεκτήματα. Πρώτον, η κατασκευή και η συντήρηση της βάσης γνώσης γίνεται πολύ πιο εύκολα. Επίσης, η ενημέρωση της βάσης γνώσης γίνεται σχεδόν απ' ευθείας. Επιπλέον, διευκολύνεται η αυξητική κατασκευή της βάσης γνώσης. Αυτό είναι ιδιαίτερα σημαντικό στην κατασκευή έμπειρων συστημάτων, όπου το σύστημα σχεδιάζεται, αρχικά, για τη λύση ενός συγκεκριμένου προβλήματος και ύστερα γενικεύεται για τη λύση και άλλων προβλημάτων. Τέλος, η διαδικασία εύρεσης λαθών στο πρόγραμμα γίνεται ευκολότερα.
- *Περιοριστική σύνταξη.* Η περιοριστική σύνταξη των κανόνων παραγωγής, αν και έχει μειονεκτήματα, εντούτοις δημιουργεί και ορισμένα πλεονεκτήματα. Πρώτον, γίνεται εφικτή η σχεδίαση προγράμματος που να μπορεί να ελέγχει την ασυνέπεια των κανόνων παραγωγής της βάσης γνώσης έτσι ώστε να μη μπορεί να εξαχθούν αλληλοσυγκρουόμενα συμπεράσματα. Αυτό θα ήταν πολύ δύσκολο να γίνει αν υπήρχαν πολλοί τρόποι έκφρασης της ίδιας γνώσης. Δεύτερον, γίνεται εύκολη η σχεδίαση προγράμματος που να βοηθά το σύστημα στην απόκτηση γνώσης από έναν ειδικό.
- *Καθοδήγηση της διαδικασίας λύσης.* Κατά τη διάρκεια της διαδικασίας λύσης ενός προβλήματος, το σύστημα εξετάζει το περιεχόμενο της μνήμης εργασίας πολλές φορές. Με τον τρόπο αυτό, επιτυγχάνει συνεχή εστίαση της διαδικασίας σε γνώση που σχετίζεται με το πρόβλημα.
- *Εύκολη παροχή επεξηγήσεων.* Η παροχή επεξηγήσεων μιας λύσης είναι σε πολλές περιπτώσεις απαραίτητη, κυρίως σε συστήματα που κάνουν διάγνωση και προτείνουν κάποιες ενέργειες. Η παροχή επεξηγήσεων σε συστήματα παραγωγής διευκολύνεται σε μεγάλο βαθμό λόγω των κανόνων παραγωγής. Κάνοντας ανάκληση των κανόνων που χρησιμοποιήθηκαν για την εύρεση της λύσης, και δεδομένου ότι η σύνταξή τους

είναι πολύ κοντά στη φυσική γλώσσα και τον τρόπο σκέψης, έχουμε σχετικά εύκολα παροχή επεξηγήσεων.

Όπως κάθε γλώσσα αναπαράστασης γνώσης έτσι και οι κανόνες παραγωγής παρουσιάζουν, εκτός από πλεονεκτήματα και μειονεκτήματα ή προβλήματα.

- *Προβλήματα επεξηγήσεων.* Ενώ οι κανόνες παραγωγής μπορούν να παράγουν εύκολα επεξηγήσεις όσον αφορά στην πεδιακή γνώση του ειδικού, δεν μπορούν να το κάνουν όσον αφορά στην ελεγκτική γνώση, τουτέστιν τις στρατηγικές ελέγχου που ακολουθήθηκαν κατά την εύρεση μιας λύσης. Για παράδειγμα, δεν είναι δυνατό να εξηγηθούν αποφάσεις όσον αφορά στο γιατί ένας κανόνας επελέγη να πυροδοτηθεί πρώτος από άλλους, καθώς αυτό το είδος της γνώσης δεν περιγράφεται ρητά, αλλά είναι ενσωματωμένο στη στρατηγική ελέγχου. Επίσης, οι κανόνες παραγωγής δεν μπορούν να παρέχουν επεξηγήσεις όσον αφορά στη γνώση υποστήριξης (support knowledge). Η γνώση υποστήριξης είναι αυτή που δικαιολογεί την ύπαρξη ενός κανόνα παραγωγής. Για παράδειγμα, για τον κανόνα παραγωγής «αν τα φώτα του αυτοκινήτου φωτίζουν αμυδρά, τότε η μπαταρία έχει αποφορτιστεί», γνώση υποστήριξης είναι αυτή που δικαιολογεί την ύπαρξη αυτού του κανόνα, τουτέστιν ότι τα φώτα για να φωτίζουν ισχυρά χρειάζονται ηλεκτρικό ρεύμα που παρέχεται από την μπαταρία.
- *Προβλήματα αναποτελεσματικότητας.* Ο τρόπος με τον οποίο επιτυγχάνεται η εξαγωγή συμπερασμάτων μπορεί να οδηγήσει σε χαμηλή αποδοτικότητα. Δυο είναι οι πηγές αυτής της πιθανής αναποτελεσματικότητας. Πρώτον, σε κάθε κύκλο αναγνώρισης ενεργειών πρέπει να ερευνηθεί όλη η βάση γνώσης για να βρεθούν οι κανόνες που ικανοποιούν την παρούσα κατάσταση της μνήμης εργασίας. Σε μια μεγάλη βάση γνώσης ο καθορισμός αυτών των κανόνων παραγωγής μπορεί να είναι υπολογιστικά χρονοβόρος. Δεύτερον, αν οι κανόνες που ικανοποιούνται από τις συνθήκες της μνήμης εργασίας είναι πολλοί, τότε η απόφαση για το ποιος θα επιλεγεί για πυροδότηση μπορεί να είναι επίσης χρονοβόρα.
- *Προβλήματα εκφραστικότητας.* Ενώ η περιοριστική σύνταξη των κανόνων παραγωγής δημιουργεί ορισμένα πλεονεκτήματα, ταυτόχρονα δημιουργεί και ορισμένα προβλήματα. Τα προβλήματα σχετίζονται με την εκφραστικότητα της γνώσης, πιο συγκεκριμένα με τη δυσκολία αναπαράστασης ορισμένων τύπων γνώσης.



## 2.5 Τεχνητά νευρωνικά δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (artificial neural nets) ή νευρωνικά δίκτυα αποτελούν μια προσπάθεια προσέγγισης της λειτουργίας του ανθρώπινου εγκεφάλου από μια μηχανή. Έχουν την ικανότητα να εκτελούν υπολογισμούς παράλληλα. Η αρχιτεκτονική τους βασίζεται στην αρχιτεκτονική των βιολογικών νευρωνικών δικτύων. Τα τεχνητά νευρωνικά δίκτυα είναι μια συλλογή από νευρώνες, οι οποίοι συνδέονται μεταξύ τους. Κάθε νευρώνας έχει πολλές εισόδους, αλλά μόνο μία έξοδο που με τη σειρά της μπορεί να αποτελέσει είσοδο για άλλους νευρώνες. Οι συνδέσεις μεταξύ των νευρώνων διαφέρουν ως προς τη σημαντικότητά τους, η οποία και προσδιορίζεται από τον συντελεστή βάρους. Η επεξεργασία κάθε νευρώνα καθορίζεται από τη συνάρτηση μεταφοράς, η οποία καθορίζει την κάθε έξοδο σε σχέση με τις εισόδους και τους συντελεστές βάρους.

Για να χρησιμοποιηθεί ένα τεχνητό νευρωνικό δίκτυο πρέπει πρώτα να εκπαιδευτεί για να μάθει. Η μάθηση συνίσταται στον προσδιορισμό των κατάλληλων συντελεστών βάρους, έτσι ώστε το τεχνητό νευρωνικό δίκτυο να εκτελεί τους επιθυμητούς υπολογισμούς, και πραγματοποιείται με τη βοήθεια αλγορίθμων που είναι γνωστοί ως *αλγόριθμοι εκπαίδευσης* (training algorithms). Ο ρόλος των συντελεστών βάρους μπορεί να ερμηνευτεί ως αποθήκευση γνώσης, η οποία παρέχεται μέσω παραδειγμάτων. Με αυτόν τον τρόπο τα νευρωνικά δίκτυα μαθαίνουν το περιβάλλον τους, δηλαδή το φυσικό μοντέλο που παρέχει τα δεδομένα.

Ένας νευρώνας είναι μια μονάδα επεξεργασίας πληροφορίας που είναι θεμελιακή για τη λειτουργία ενός νευρωνικού δικτύου. Στην **Εικόνα 4** φαίνεται το μοντέλο ενός νευρώνα. Τα τρία βασικά στοιχεία αυτού του μοντέλου είναι:

- Ένα σύνολο από *συναψεις*, κάθε μια από τις οποίες χαρακτηρίζεται από ένα βάρος. Συγκεκριμένα, ένα σήμα  $x_j$  στην είσοδο της σύναψης  $j$  που συνδέεται στον νευρώνα  $k$ , πολλαπλασιάζεται με το συναπτικό βάρος  $w_{kj}$ . Το βάρος  $w_{kj}$  είναι θετικό, αν η σύναψη είναι διεγερτική (ωθεί τον νευρώνα να αποκριθεί στη διέγερση), και αρνητικό, αν σύναψη είναι απαγορευτική (αποτρέπει τον νευρώνα να παράγει μια απόκριση).
- Έναν *αθροιστή* για την πρόσθεση των σημάτων εισόδου, που παίρνουν βάρος από την αντίστοιχη σύναψη. Αυτές οι λειτουργίες αποτελούν τον γραμμικό συνδυαστή.
- Μια *συνάρτηση ενεργοποίησης* για τη μείωση του εύρους της εξόδου του νευρώνα.


Το μοντέλο, επίσης, περιλαμβάνει ένα εξωτερικά εφαρμοζόμενο *κατώφλι*  $\theta_k$ , που έχει

επίδραση στην ελάττωση της εισόδου στην εφαρμοζόμενη συνάρτηση ενεργοποίησης που ακολουθεί. Στη βιβλιογραφία, το κατώφλι αναφέρεται και σαν *πόλωση* (bias). Με μαθηματικούς όρους, ένας νευρώνας  $k$  περιγράφεται από τις παρακάτω εξισώσεις:

$$u_k = \sum_{j=0}^n w_{kj} x_j$$

$$y_k = \phi(u_k)$$

όπου  $x_j$  είναι τα σήματα εισόδου ( $x_0 = +1$ ),  $w_{kj}$  είναι τα συναπτικά βάρη του  $k$ ,  $w_{k0}$  είναι το κατώφλι, και  $\phi()$  είναι η συνάρτηση ενεργοποίησης.



Εικόνα 4. Το μοντέλο ενός τεχνητού νευρώνα

Το  $u_k$  είναι η γραμμική συνδυαστική έξοδος του νευρώνα, και  $y_k$  είναι το σήμα εξόδου του νευρώνα, που αναφέρεται και σαν πραγματική έξοδος. Η χρήση του κατωφλίου  $\theta_k$  έχει σαν αποτέλεσμα την εφαρμογή ενός εγγενούς (affine) μετασχηματισμού της εξόδου  $u_k$  του γραμμικού συνδυαστή της **Εικόνας 4**.

Τα βασικότερα πλεονεκτήματα των νευρωνικών δικτύων είναι:

- *Δυνατότητα εκμάθησης από πρότυπα εκπαίδευσης.* Τα νευρωνικά δίκτυα μπορούν εύκολα να αποκτήσουν γνώση από πρότυπα εκπαίδευσης, που βρίσκονται συνήθως σε αφθονία για τα περισσότερα πεδία εφαρμογής.

- *Υψηλό επίπεδο απόδοσης.* Η έξοδος ενός νευρωνικού δικτύου υπολογίζεται αρκετά αποδοτικά, καθώς βασίζεται σε αριθμητικούς υπολογισμούς.
- *Ικανότητα γενίκευσης.* Τα νευρωνικά δίκτυα είναι πολύ αποδοτικά στην παραγωγή συμπερασμάτων και μπορούν να φτάνουν σε συμπεράσματα βασιζόμενα σε μερικά γνωστές εισόδους.

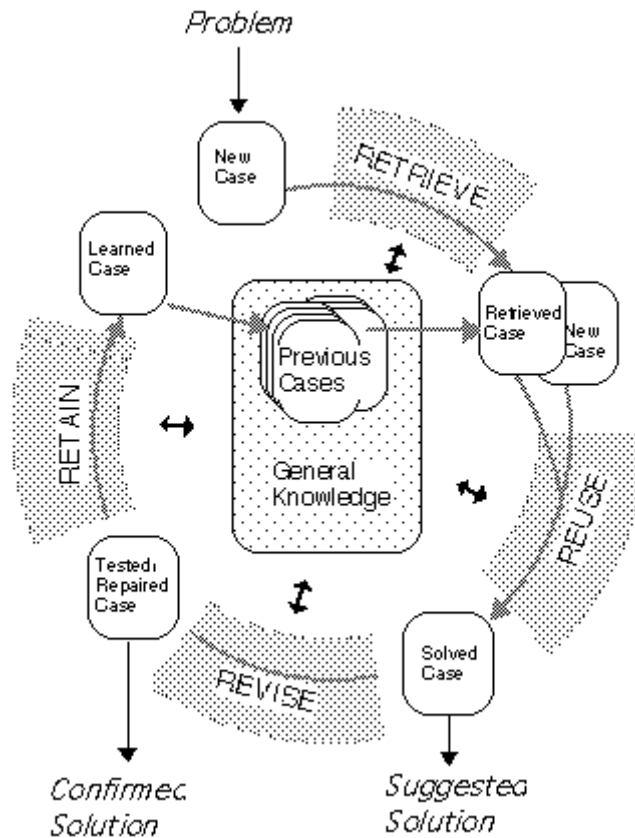
Τα μειονεκτήματα των νευρωνικών δικτύων προέρχονται από το γεγονός ότι αποτελούν συστήματα εμπειρικής μάθησης και από την ιδιαίτερη φύση τους.

- *Δεν διαθέτουν φυσικότητα.*
- *Δεν παρέχονται επεξηγήσεις.* Η γνώση που περικλείεται τις περισσότερες περιπτώσεις είναι δύσκολο να κατανοηθεί, και δεν παρέχονται επεξηγήσεις για τα συμπεράσματα που εξάγονται.
- *Δεν αναλύονται σε επιμέρους τμήματα.* Είναι δύσκολο να ενημερωθούν συγκεκριμένα τμήματα του νευρωνικού δικτύου, και οι αλλαγές που γίνονται συνήθως επηρεάζουν ολόκληρο το νευρωνικό δίκτυο.

## **2.6 Συλλογιστική βασισμένη σε περιπτώσεις**

Η *συλλογιστική βασισμένη σε περιπτώσεις* (case-based reasoning) βασίζεται στη χρήση καταγεγραμμένης εμπειρίας για την επίλυση νέων προβλημάτων. Στη συλλογιστική βασισμένη σε περιπτώσεις χρησιμοποιούνται περιπτώσεις ή παραδείγματα προβλημάτων που αντιμετωπίστηκαν επιτυχώς στο παρελθόν προκειμένου να επιλυθεί το τρέχον πρόβλημα με παραπλήσιο τρόπο. Η επιλογή των κατάλληλων *περιπτώσεων* (cases) βασίζεται στην ομοιότητά τους με την τρέχουσα.

Ένα σύστημα που χρησιμοποιεί συλλογιστική βασισμένη σε περιπτώσεις αποτελείται από τα εξής βασικά τμήματα (Aamodt & Plaza, 1994) (βλ. **Εικόνα 5**):



Εικόνα 5. Ο κύκλος λειτουργίας της συλλογιστικής βασισμένης σε περιπτώσεις

- Μια βιβλιοθήκη από παλιές περιπτώσεις (case library).
- Μια μέθοδο για το ταίριασμα και την ανάκληση από τη βιβλιοθήκη (case retrieval) της περίπτωσης που είναι περισσότερο όμοια με την τωρινή, ταιριάζοντας τα κυριότερα χαρακτηριστικά του προβλήματος.
- Στην περίπτωση που η τωρινή περίπτωση δεν είναι ακριβώς ίδια με την παλιά, χρειάζεται μια μέθοδος για την προσαρμογή της λύσης που δόθηκε στο παρελθόν (case adaptation) έτσι ώστε αυτή, με κάποιες τροποποιήσεις, να επαναχρησιμοποιηθεί.
- Μια μέθοδο για τη δοκιμή, επαλήθευση και επιδιόρθωση της προσαρμοσμένης λύσης (case verification). Η επαλήθευση μπορεί να γίνει είτε με προσομοίωση στον υπολογιστή, είτε με δοκιμή της λύσης στον πραγματικό κόσμο. Η επαλήθευση των λύσεων βρίσκεται σε ερευνητικό στάδιο και συνήθως, τα συστήματα που βασίζονται σε περιπτώσεις δεν έχουν τέτοιο τμήμα.
- Αν η νέα περίπτωση μαζί με τη λύση που τελικά υιοθετήθηκε συνιστούν μια πολύ διαφορετική περίπτωση από αυτές που βρίσκονται στη βιβλιοθήκη, τότε η νέα περίπτωση προστίθεται στη βιβλιοθήκη προκειμένου να χρησιμοποιηθεί στο μέλλον. Χρειάζεται δηλαδή μια μέθοδος για την εκμάθηση της λύσης (case learning), που θα

κρίνει αν η νέα περίπτωση και η προσαρμοσμένη λύση της πρέπει ή όχι να προστεθούν στη βιβλιοθήκη.

Τα βασικότερα πλεονεκτήματα της συλλογιστικής βασισμένης σε περιπτώσεις είναι:

- *Φυσικότητα.* Οι περιπτώσεις βρίσκονται πιο κοντά στον τρόπο σκέψης των ανθρώπων.
- *Η γνώση δεν αλλοιώνεται.*
- *Η απόκτηση γνώσης απλουστεύεται.* Η γνώση υπάρχει ήδη σε παλαιότερα έγγραφα ή σε παλαιότερες βάσεις δεδομένων.

Ενώ, κάποια μειονεκτήματα της συλλογιστικής βασισμένης σε περιπτώσεις είναι:

- *Υψηλό υπολογιστικό κόστος αναζήτησης στη βιβλιοθήκη των περιπτώσεων.*
- Η απόδοση και η ποιότητα των λύσεων επηρεάζεται από την ορθή δόμηση της βιβλιοθήκης και από την ποιότητα και την ποσότητα των περιπτώσεων που βρίσκονται στη βιβλιοθήκη.
- *Δυσκολία προσαρμογής της λύσης.* Κυρίως, όταν απαιτούνται εμπειρικές σχέσεις.

## 2.7 Εξόρυξη Γνώσης

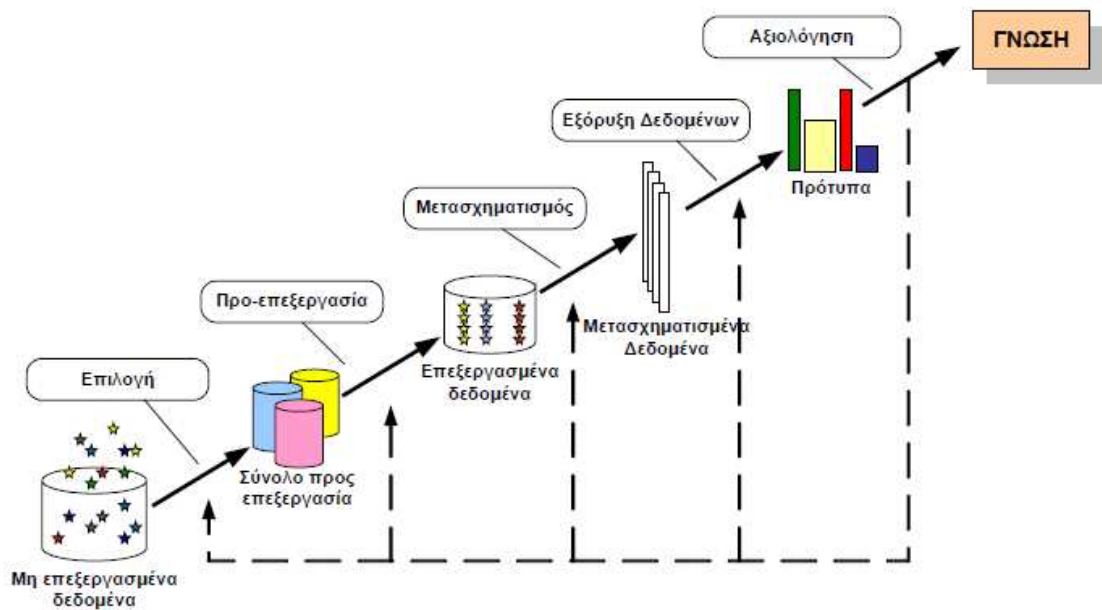
Η εξόρυξη γνώσης από μεγάλες αποθήκες δεδομένων έχει εξελιχθεί σε ένα από τα βασικότερα ερευνητικά ζητήματα στον τομέα των βάσεων δεδομένων, των μηχανών γνώσης και της στατιστικής. Η πρόοδος στην τεχνολογία των βάσεων δεδομένων παρέχει νέες τεχνικές για την αποδοτική και αποτελεσματική συλλογή, αποθήκευση και διαχείριση των δεδομένων. Επίσης, η δυνατότητα ανάλυσης και ερμηνείας των συνόλων δεδομένων, και η εξαγωγή «χρήσιμης» γνώσης από αυτά έχει ξεπεράσει κάθε όριο και η ανάγκη για μία νέα γενιά εργαλείων και τεχνικών για ευφυή ανάλυση βάσεων δεδομένων έχει δημιουργηθεί. Αυτή η ανάγκη έχει προσελκύσει την προσοχή των ερευνητών από διάφορες περιοχές και ένας νέος ερευνητικός τομέας δημιουργείται, γνωστός ως *εξόρυξη δεδομένων και γνώσης (Data and Knowledge Mining)*.

Η ανακάλυψη γνώσης από βάσεις δεδομένων (*Knowledge Discovery in Databases*) αναφέρεται στη διεργασία εξόρυξης γνώσης από τις μεγάλες αποθήκες δεδομένων. Ο όρος *εξόρυξη δεδομένων* χρησιμοποιείται ως συνώνυμο της ανακάλυψης γνώσης από βάσεις δεδομένων αλλά κυρίως για αναφορά στις πραγματικές τεχνικές που χρησιμοποιούνται για την ανάλυση και την εξαγωγή της από διάφορα σύνολα δεδομένων. Χαρακτηρίζει την διαδικασία της εύρεσης των δομών γνώσης οι οποίες περιγράφουν με ακρίβεια μεγάλα σύνολα πρωτογενών δεδομένων. Οι δομές αυτές αναδεικνύουν γνώση (συσχετίσεις ή

κανόνες) που είναι κρυμμένη μέσα στα δεδομένα και δεν μπορούν να εξαχθούν από τον άνθρωπο-χρήστη της βάσης δεδομένων με «γυμνό» μάτι.

Η *εξόρυξη γνώσης* από μια βάση δεδομένων είναι μια επαναληπτική διαδικασία που αναφέρεται σε ολόκληρη την διαδικασία ανακάλυψης «χρήσιμης» πληροφορίας από μεγάλα σύνολα δεδομένων και αποτελείται από τα ακόλουθα βήματα (βλ. **Εικόνα 6**):

- ❖ **Ανάπτυξη και κατανόηση της περιοχής της εφαρμογής**, της προγενέστερης γνώσης του προς εξέταση τομέα καθώς και των στόχων του τελικού χρήστη.
- ❖ **Ολοκλήρωση των δεδομένων**. Εξετάζεται ο βαθμός «πολύπλεξης» πολλαπλών πηγών δεδομένων ώστε η όποια διαδικασία να εφαρμοστεί στον συνδυασμό τους.
- ❖ **Δημιουργία του στόχου-συνόλου δεδομένων**. Επιλογή του συνόλου στο οποίο θα εφαρμοστεί η διαδικασία εξόρυξης.
- ❖ **Καθαρισμός και προ-επεξεργασία δεδομένων**. Εδώ αναφερόμαστε κυρίως στην αφαίρεση του «θορύβου» που περιέχουν τα δεδομένα (όποια μορφή και να έχει).
- ❖ **Μετασχηματισμός των δεδομένων**. Οι αλλαγές που μπορούν να υποστούν τα δεδομένα για να εφαρμόσουμε τις τεχνικές μας πιο εύκολα.
- ❖ **Επιλογή των στόχων και των αλγορίθμων εξόρυξης δεδομένων**.
- ❖ **Εξόρυξη δεδομένων**. Εφαρμογή μεθόδων και αλγορίθμων με στόχο την ανακάλυψη προτύπων γνώσης. Τα πρότυπα θα μπορούσαν να περιγραφούν από ένα σύνολο από διεργασίες με κυριότερες τις εξής:
  - **Κατηγοριοποίηση**, όπου κάθε νέο αντικείμενο εντάσσεται, με βάση τα χαρακτηριστικά του, σε μια από τις προκαθορισμένες κατηγορίες.
  - **Συσταδοποίηση**, όπου γίνεται καταμερισμός των αντικειμένων σε ομάδες ανάλογα με τις ομοιότητες τους. Η διαφορά εδώ είναι ότι δεν υπάρχουν έτοιμες κατηγορίες.
  - **Κανόνες συσχέτισης**, όπου ανακαλύπτονται συσχετίσεις μεταξύ των γνωρισμάτων ενός συνόλου δεδομένων.
  - **Πρότυπα ακολουθιών**, τα οποία ομοιάζουν πολύ με τους κανόνες συσχέτισης με την προσθήκη όμως της παραμέτρου του χρόνου.
  - **Παλινδρόμηση**, η οποία αναφέρεται στην εκμάθηση μιας λειτουργίας που εκχωρεί τα δεδομένα σε μια μεταβλητή πρόβλεψης, η οποία παίρνει πραγματικές τιμές.
- ❖ **Αξιολόγηση των προτύπων**. Διαδικασία «απομόνωσης» των πραγματικά χρήσιμων προτύπων.
- ❖ **Παρουσίαση της γνώσης**.



Εικόνα 6. Τα βήματα της διαδικασίας εξόρυξης γνώσης.

Βλέπουμε λοιπόν ότι η εξόρυξη δεδομένων αποτελεί ένα βήμα της εξόρυξης γνώσης το οποίο είναι στις περισσότερες περιπτώσεις και ο βασικός κορμός όλης της παραπάνω διαδικασίας. Οι αλγόριθμοι που χρησιμοποιούνται σε αυτό το βήμα έχουν σχεδιαστεί με έμφαση στην εξελιξιμότητα όσον αφορά το μέγεθος του συνόλου δεδομένων εισαγωγής και μπορούν να αντιμετωπισθούν ως σύνθεση των τριών ακόλουθων συστατικών (Fayyad, Piatetsky-Shapiro, Smuth & Uthurusamy, 1996):

- ❖ **Περιγραφή του μοντέλου.** Καθορισμός των βασικών στόχων της διαδικασίας εξόρυξης (π.χ. κατηγοριοποίηση ή συσταδοποίηση), και απόφαση τρόπου απεικόνισης του μοντέλου.
- ❖ **Αξιολόγηση του μοντέλου.** Εξετάζεται η εγκυρότητα των προτύπων και η αξιολόγηση της ακρίβειας και της χρησιμότητας του μοντέλου.
- ❖ **Αλγόριθμοι αναζήτησης.** Υπάρχουν δύο είδη αλγορίθμων:
  - Αυτοί που αναζητούν παραμέτρους βελτιστοποίησης κριτηρίων αξιολόγησης του μοντέλου.
  - Αυτοί που αναζητούν μοντέλα.

# 3

## Νευροκανόνες

Οι νευροκανόνες (νευρωνικοί κανόνες) αποτελούν ένα είδος υβριδικών κανόνων (Hatzilygeroudis and Prentzas, 2000). Κάθε νευροκανόνας θεωρείται σαν ένας νευρώνας (**Εικόνα 7α**). Οι εισόδοι  $C_i (i = 1, \dots, n)$  του νευρώνα συνιστούν τις συνθήκες του κανόνα. Σε κάθε συνθήκη  $C_i$  ανατίθεται ένας αριθμός  $sf_i$ , που καλείται συντελεστής βαρύτητας, ο οποίος αντιστοιχεί στο βάρος της αντίστοιχης εισόδου του νευρώνα. Επιπλέον, σε κάθε κανόνα ανατίθεται ένας αριθμός  $sf_0$ , που καλείται συντελεστής πόλωσης, ο οποίος αντιστοιχεί στο κατώφλι του νευρώνα.


Κάθε συνθήκη λαμβάνει μια τιμή από το ακόλουθο σύνολο διακριτών τιμών: [1 (αληθής), 0 (ψευδής), 0.5 (απροσδιόριστη)]. Το γεγονός αυτό δίνει την ευκαιρία να διακρίνει κάποιος το ψεύδος ( $C_i = 0$ ) από την απουσία ( $C_i = 0.5$ ) μιας συνθήκης, σε αντίθεση με τους συμβολικούς κανόνες. Η επιλογή του συγκεκριμένου συνόλου τιμών σχετίζεται άμεσα με τα ευρετικά εξαγωγής συμπερασμάτων, που εισάγονται στην **Ενότητα 3.3**. Αυτό σημαίνει ότι αν αυτό αλλάξει, τα ευρετικά μπορεί να μην είναι έγκυρα πλέον.

Η έξοδος  $D$ , που αναπαριστά το συμπέρασμα του κανόνα, υπολογίζεται με τους συνήθεις τύπους:

$$D = f(a), \quad a = sf_0 + \sum_{i=1}^n sf_i C_i$$

όπου  $a$  είναι η τιμή ενεργοποίησης και  $f(x)$  είναι η συνάρτηση ενεργοποίησης, που είναι μια συνάρτηση κατωφλίου (**Εικόνα 7β**). Επομένως, η έξοδος μπορεί να λάβει μια από τις τιμές “-1” και “1”, αντιπροσωπεύοντας την αποτυχία και την επιτυχία του κανόνα, αντίστοιχα.





Εικόνα 7. (α) ένας νευροκανόνας ως ένας νευρώνας (β) η συνάρτηση ενεργοποίησης

### 3.1 Σύνταξη και σημασιολογία

Η γενική σύνταξη ενός κανόνα είναι:

$\langle \text{rule} \rangle ::= [(\langle \text{bias-factor} \rangle)] \text{ if } \langle \text{conditions} \rangle \text{ then } \langle \text{conclusions} \rangle$

$\langle \text{conditions} \rangle ::= \langle \text{condition} \rangle \{, \langle \text{condition} \rangle\}$

$\langle \text{conclusions} \rangle ::= \langle \text{conclusion} \rangle \{, \langle \text{conclusion} \rangle\}$

$\langle \text{condition} \rangle ::= \langle \text{variable} \rangle \langle \text{l-predicate} \rangle \langle \text{value} \rangle [(\langle \text{significance-factor} \rangle)]$

$\langle \text{conclusion} \rangle ::= \langle \text{variable} \rangle \langle \text{r-predicate} \rangle \langle \text{value} \rangle$

Το  $\langle \text{variable} \rangle$  υποδηλώνει μια μεταβλητή, τουτέστιν ένα σύμβολο που αναπαριστά μια έννοια σε ένα γνωστικό πεδίο, π.χ. «φύλο», «πόνος», κτλ. στον τομέα της Ιατρικής. Οι μεταβλητές διακρίνονται σε τρεις κατηγορίες:

- *μεταβλητές εισόδου*, τουτέστιν μεταβλητές για τις οποίες ζητείται από το χρήστη να προσδιορίσει μια τιμή.
- *μεταβλητές εξόδου*, τουτέστιν μεταβλητές που συνιστούν τους στόχους της διαδικασίας εξαγωγής συμπερασμάτων.
- *ενδιάμεσες μεταβλητές*, τουτέστιν μεταβλητές που αποτελούν ενδιάμεσους στόχους της διαδικασίας εξαγωγής συμπερασμάτων.

Μια μεταβλητή σε μια συνθήκη μπορεί να είναι είτε μια μεταβλητή εισόδου είτε μια ενδιάμεση μεταβλητή είτε και μια μεταβλητή εξόδου ακόμα, ενώ μια μεταβλητή σε ένα συμπέρασμα μπορεί να είναι είτε μια ενδιάμεση μεταβλητή είτε μια μεταβλητή εξόδου. Μια μεταβλητή εισόδου λαμβάνει τιμές από το χρήστη (δεδομένα εισόδου), ενώ οι ενδιάμεσες μεταβλητές και οι μεταβλητές εξόδου λαμβάνουν τιμές κατά τη διάρκεια της εξαγωγής συμπερασμάτων, αφού αναπαριστούν ενδιάμεσα και τελικά συμπεράσματα, αντίστοιχα. Όλες

οι μεταβλητές είναι μονής τιμής, τουτέστιν μπορούν να λάβουν μόνο μια τιμή κάθε φορά, και οι τιμές τους είναι ξένες μεταξύ τους, τουτέστιν η μια αποκλείει τις άλλες.

Το *<l-predicate>* υποδηλώνει ένα συμβολικό ή ένα αριθμητικό κατηγορήμα. Τα *συμβολικά κατηγορήματα* είναι {είναι, δεν-είναι}, ενώ τα *αριθμητικά κατηγορήματα* είναι {<, >, =}. Οι συνθήκες που περιέχουν το «είναι» (αντίστοιχα το «δεν-είναι») λέγονται *είναι-συνθήκες* (αντίστοιχα *δεν-είναι-συνθήκες*). Όπου *<r-predicate>* μπορεί μόνο να είναι ένα συμβολικό κατηγορήμα. Όπου *<value>* υποδηλώνει μια τιμή. Μια τιμή μπορεί να είναι ένα σύμβολο ή ένας αριθμός. Τέλος, *<bias-factor>* και *<significance-factor>* είναι πραγματικοί αριθμοί. Ο συντελεστής βαρύτητας μιας συνθήκης αναπαριστά τη σπουδαιότητα (τη βαρύτητα) της συνθήκης για να φτάσει κάποιος σε συμπέρασμα. Επομένως, η σημασιολογία των συντελεστών βαρύτητας είναι αρκετά διαφορετική από αυτή των συντελεστών βεβαιότητας ή αυτή των πιθανοτήτων.

Οι συντελεστές βαρύτητας και ο συντελεστής πόλωσης είναι προαιρετικοί σε έναν κανόνα (κάτι που υποδηλώνεται από τις “[ ]”). Έτσι, οι νευροκανόνες (με συντελεστές) και οι συμβολικοί κανόνες (χωρίς συντελεστές) υποστηρίζονται εξίσου από το συμβολισμό αναπαράστασης. (Το τερματικό σύμβολο “,” στην περίπτωση ενός συμβολικού κανόνα υποδηλώνει σύζευξη). Δυο παραδείγματα κανόνων, ενός συμβολικού κανόνα και ενός νευροκανόνα, παρουσιάζονται στην **Εικόνα 8**.

<p><b>R<sub>1</sub>:</b>  <b>if</b> sex <b>is</b> man ,            age &gt; 20 ,            age &lt; 36  <b>then</b> patient_class <b>is</b> man21_35</p> <p style="text-align: center;">(a)</p>	<p><b>N<sub>1</sub>:</b>  <b>(-8) if</b> pain <b>is</b> continuous (5) ,            patient_class <b>isnot</b> man36_55 (2.5) ,            fever <b>is</b> medium (2) ,            fever <b>is</b> high (2)  <b>then</b> disease_type <b>is</b> inflammation</p> <p style="text-align: center;">(b)</p>
--	---

**Εικόνα 8. Παράδειγμα (α) ενός συμβολικού κανόνα και (β) ενός νευροκανόνα**

Οι νευροκανόνες διακρίνονται σε ενδιάμεσους νευροκανόνες και νευροκανόνες εξόδου. Ένας *ενδιάμεσος νευροκανόνας* είναι ένας νευροκανόνας που περιέχει μια ενδιάμεση μεταβλητή στο συμπέρασμά του. Ένας *νευροκανόνας εξόδου* είναι ένας νευροκανόνας που περιέχει μια μεταβλητή εξόδου στο συμπέρασμά του. Οι νευροκανόνες, επιπλέον,

διακρίνονται σε νευροκανόνες με αρνητικό συντελεστή πόλωσης ( $sf_0 < 0$ ) και νευροκανόνες με θετικό συντελεστή πόλωσης ( $sf_0 > 0$ ).

### **3.2 Κατασκευή βάσης νευροκανόνων**

Οι νευροκανόνες μπορούν να παραχθούν είτε από συμβολικούς κανόνες, χρησιμοποιώντας βάσεις συμβολικών κανόνων που υπάρχουν εκ των προτέρων, είτε από εμπειρικά δεδομένα. Στην εργασία αυτή μας ενδιαφέρει η δεύτερη περίπτωση, την οποία και παρουσιάζουμε.

Ο αλγόριθμος κατασκευής μιας βάσης νευροκανόνων από εμπειρικά δεδομένα περιγράφεται παρακάτω:

1. Προσδιόρισε τις μεταβλητές εισόδου, τις ενδιάμεσες μεταβλητές και τις μεταβλητές εξόδου και χρησιμοποίησε πληροφορίες εξαρτήσεων για να κατασκευαστεί ένας αρχικός νευροκανόνας για κάθε ενδιάμεση μεταβλητή και μεταβλητή εξόδου.
2. Προσδιόρισε το σύνολο εκπαίδευσης για κάθε αρχικό κανόνα από τα εμπειρικά δεδομένα, εκπαίδευσε κάθε αρχικό νευροκανόνα χρησιμοποιώντας το σύνολο εκπαίδευσής του και παράγαγε τους αντίστοιχους νευροκανόνες.
3. Τοποθέτησε τους νευροκανόνες που παράχθηκαν στη βάση νευροκανόνων.

Στη συνέχεια, αναπτύσσεται διεξοδικά κάθε βήμα του αλγόριθμου.

#### **3.2.1 Κατασκευή αρχικών νευροκανόνων**

Έτσι ώστε να κατασκευάσει κάποιος αρχικούς νευροκανόνες, πρώτα χρειάζεται να ξέρει ή να προσδιορίσει τις μεταβλητές εισόδου, τις ενδιάμεσες μεταβλητές και τις μεταβλητές εξόδου. Ύστερα, χρειάζεται πληροφορίες εξαρτήσεων. Οι πληροφορίες εξαρτήσεων υποδηλώνουν από ποιες μεταβλητές (έννοιες) εξαρτώνται οι ενδιάμεσες μεταβλητές και οι μεταβλητές εξόδου. Αν λείπουν οι πληροφορίες εξαρτήσεων, τότε οι μεταβλητές εξόδου εξαρτώνται μόνον από μεταβλητές εισόδου, όπως υποδηλώνεται από τα εμπειρικά δεδομένα.

Στην κατασκευή ενός αρχικού νευροκανόνα, όλες οι συνθήκες που περιέχουν τις μεταβλητές εισόδου, τις ενδιάμεσες μεταβλητές και τις μεταβλητές εξόδου, που συνεισφέρουν για να φτάσει κάποιος σε συμπέρασμα, συνιστούν τις εισόδους του αρχικού νευροκανόνα και το συμπέρασμα την έξοδό του. Επομένως, ένας νευροκανόνας έχει τόσες συνθήκες όσα τα πιθανά ζεύγη μεταβλητή-τιμή. Επιπλέον, πρέπει να παραχθούν τόσοι

αρχικοί νευροκανόνες όσες οι διαφορετικές ενδιάμεσες μεταβλητές και μεταβλητές εξόδου που καθορίστηκαν.

Σε ένα απλό παράδειγμα μιας ιατρικής διάγνωσης υπάρχουν τέσσερα συμπτώματα και δυο ασθένειες. Τα συμπτώματα εκφράζονται από τις συνθήκες  $C_1, C_2, C_3$  και  $C_4$ , και οι ασθένειες από τα συμπεράσματα  $D_1$  και  $D_2$ . Η ασθένεια  $D_1$  εξαρτάται από τα συμπτώματα  $C_1, C_2$  και  $C_3$ , ενώ η ασθένεια  $D_2$  από τα συμπτώματα  $C_3$  και  $C_4$ . Έπειτα, κατασκευάζονται η εξής αρχικοί νευροκανόνες: “(0) **if**  $C_1(0), C_2(0), C_3(0)$  **then**  $D_1$ ”, “(0) **if**  $C_3(0), C_4(0)$  **then**  $D_2$ ”. Οι τιμές των συντελεστών αρχικοποιούνται εξ ορισμού με μηδέν, εκτός αν ο χρήστης αναθέσει μη μηδενικές τιμές.

### 3.2.2 Εκπαίδευση αρχικών νευροκανόνων

Τα εμπειρικά δεδομένα δίνονται με τη μορφή προτύπων γνώσης. Ένα πρότυπο γνώσης συσχετίζει έναν αριθμό μεταβλητών με μια πλειάδα τιμών. Κάθε μεταβλητή λαμβάνει τιμές από ένα σύνολο διακριτών τιμών. Από τα αρχικά εμπειρικά δεδομένα, εξάγονται τόσα (υπό)σύνολα όσοι και οι αρχικοί νευροκανόνες. Κάθε τέτοιο σύνολο, που καλείται σύνολο εκπαίδευσης, περιέχει πρότυπα γνώσης της μορφής  $[v_1 \ v_2 \ \dots \ v_n \ d]$ , όπου  $d$  είναι η τιμή μιας ενδιάμεσης μεταβλητής ή μιας μεταβλητής εξόδου και  $v_i (i = 1, \dots, n)$  είναι οι τιμές των μεταβλητών από τις οποίες εξαρτάται. Κάθε σύνολο εκπαίδευσης χρησιμοποιείται για να εκπαιδευτεί ο αντίστοιχος αρχικός νευροκανόνας και να υπολογιστούν οι συντελεστές του. Ο αλγόριθμος μάθησης που χρησιμοποιείται είναι ο κλασσικός αλγόριθμος ελάχιστου μέσου τετραγωνικού λάθους (least mean square).

Για παράδειγμα, ο Πίνακας 1 περιέχει δέκα πρότυπα γνώσης που αφορούν την ενδιάμεση μεταβλητή “mark-level” και τις μεταβλητές από τις οποίες εξαρτάται (“solution-attempts”, “requested-examples”, “assistance-times”), σε ένα σύστημα διδασκαλίας.

Solution-attempts	Requested-examples	Assistance-times	Mark-level
1	0	1	High
2	1	1	Average
1	>1	0	High
2	0	1	Average
>2	1	>1	Low

1	>1	>1	Average
>2	0	1	Low
2	1	0	Average
2	>1	>1	Low
>2	0	0	Average

Πίνακας 1. Πρότυπα γνώσης για την μεταβλητή "mark-level"

NR1  
 (-0.5) **if** assistance-times is 0 (-4.6),  
 solution-attempts is 1 (-3.8),  
 solution-attempts is >2 (3.0),  
 assistance-times is >1 (2.8),  
 requested-examples is 0 (-2.0),  
 requested-examples is 1 (0.9),  
 requested-examples is >1 (-0.7),  
 solution-attempts is 2 (-0.3),  
 assistance-times is 1 (-0.3)  
**then** mark-level is low

NR2  
 (-1.0) **if** assistance-times is >1 (-4.1),  
 solution-attempts is >2 (-2.8),  
 requested-examples is >1 (-2.2),  
 assistance-times is 1 (1.6),  
 requested-examples is 1 (1.5),  
 solution-attempts is 2 (1.3),  
 assistance-times is 0 (1.3),  
 requested-examples is 0 (-0.6),  
 solution-attempts is 1 (-0.4)  
**then** mark-level is average

NR3  
 (-2.6) **if** solution-attempts is 2 (-6.2),  
 requested-examples is 1 (-6.0),  
 assistance-times is 1 (-5.7),  
 assistance-times is >1 (4.7),  
 requested-examples is 0 (3.2),  
 assistance-times is 0 (-2.7),  
 solution-attempts is >2 (2.6),  
 solution-attempts is 1 (-1.0),  
 requested-examples is >1 (-0.2)  
**then** mark-level is average

NR4  
 (-0.8) **if** solution-attempts is 1 (3.2),  
 assistance-times is >1 (-2.7),  
 solution-attempts is 2 (-2.6),  
 requested-examples is 1 (-2.6),  
 solution-attempts is >2 (-2.5),  
 requested-examples is 0 (1.4),  
 assistance-times is 1 (1.0),  
 requested-examples is >1 (-0.7),  
 assistance-times is 0 (-0.3)  
**then** mark-level is high

Πίνακας 2. Οι νευροκανόνες που παράχθηκαν από τα πρότυπα γνώσης του Πίνακα 1

Εντούτοις, υπάρχουν περιπτώσεις όπου ο κλασικός αλγόριθμος ελάχιστου μέσου τετραγωνικού λάθους (least mean square) αποτυγχάνει να προσδιορίσει τους σωστούς συντελεστές βαρύτητας για έναν αριθμό από νευρωνικές. Τούτέστιν, οι αντίστοιχοι νευρώνες αυτών των κανόνων δεν ταξινομούν σωστά μερικά από τα δείγματα εκπαίδευσης των συνόλων εκπαίδευσής τους. Αυτό σημαίνει ότι τα δείγματα εκπαίδευσης αντιστοιχούν σε μια μη διαχωρίσιμη συνάρτηση.

Για παράδειγμα, οι νευρωνικές που παράγονται από τα πρότυπα γνώσης του **Πίνακα 1** παρουσιάζονται στον **Πίνακα 2** (Hatzilygeroudis and Prentzas, 2004a). Παρατηρεί κάποιος ότι, αν και υπάρχει ένας μόνο νευρωνικός για τις τιμές “low” και “high” της μεταβλητής “mark-level” ( $NR_1$ ,  $NR_4$ ), υπάρχουν δυο νευρωνικές για την τιμή “average” ( $NR_2$ ,  $NR_3$ ). Αυτό συμβαίνει καθώς τα πρότυπα του αντίστοιχου συνόλου εκπαίδευσης για την τιμή “average” σχηματίζουν ένα μη γραμμικό σύνολο.

Για να ξεπεραστεί το πρόβλημα αυτό, το σύνολο εκπαίδευσης του αρχικού νευρωνικού διαιρείται σε υποσύνολα με τέτοιο τρόπο ώστε κάθε υποσύνολο να περιέχει δείγματα επιτυχίας, που είναι «κοντινά» το ένα με το άλλο σε κάποιο βαθμό. Η εγγύτητα μεταξύ των δυο δειγμάτων ορίζεται ως ο αριθμός των κοινών τιμών των συνιστωσών τους. Για παράδειγμα, η εγγύτητα του  $[1 \ 0 \ 1 \ 1 \ 1]$  και του  $[1 \ 1 \ 0 \ 1 \ 1]$  είναι “3”. Επίσης, ορίζεται σαν ζεύγος ελάχιστης εγγύτητας, ένα ζεύγος δειγμάτων επιτυχίας με την ελάχιστη εγγύτητα σε ένα σύνολο εκπαίδευσης. Είναι πιθανό να υπάρχουν περισσότερα από ένα ζεύγη ελάχιστης εγγύτητας σε ένα σύνολο εκπαίδευσης.

Αρχικά, βρίσκεται ένα ζεύγος ελάχιστης εγγύτητας στο σύνολο εκπαίδευσης και δημιουργούνται δυο υποσύνολα, με το κάθε υποσύνολο να περιέχει σαν αρχικό του στοιχείο το ένα από τα δυο δείγματα επιτυχίας του ζεύγους, που καλείται *οδηγούν στοιχείο*. Κάθε ένα από τα εναπομένοντα δείγματα επιτυχίας κατανέμονται στα δυο υποσύνολα με βάση την εγγύτητά τους στα οδηγούντα στοιχεία αυτών. Πιο συγκεκριμένα, κάθε υποσύνολο περιέχει τα δείγματα επιτυχίας που βρίσκονται πιο κοντά στο οδηγούν στοιχείο του. Έπειτα, τα δείγματα αποτυχίας του αρχικού συνόλου προστίθενται και στα δυο υποσύνολα. Ύστερα, δυο αντίγραφα του αρχικού νευρωνικού, ένα για κάθε υποσύνολο, εκπαιδεύονται. Αν οι συντελεστές ενός αντίγραφου δεν ταξινομήσουν σωστά κάποια από τα δείγματά του, το αντίστοιχο υποσύνολο διαιρείται περαιτέρω σε δυο άλλα υποσύνολα με βάση ένα από τα ζεύγη ελάχιστης εγγύτητάς του. Αυτό συνεχίζεται μέχρι να ταξινομηθούν όλα τα δείγματα. Αυτό σημαίνει ότι από έναν αρχικό νευρωνικό μπορεί να παραχθούν περισσότεροι από ένας τελικοί νευρωνικοί, που λέγονται *αδελφοί νευρωνικοί*.

Έτσι, το βήμα 2 του αλγόριθμου για κάθε αρχικό νευρωνικό αναλύεται ως εξής:

**2.1** Από τα αρχικά εμπειρικά δεδομένα, παράγαγε τόσα αρχικά σύνολα εκπαίδευσης όσος είναι ο αριθμός των αρχικών νευρωνικών.

**2.2** Εκπαίδευσε κάθε αρχικό νευρωνικό, εφαρμόζοντας τον κλασικό αλγόριθμο ελάχιστου μέσου τετραγωνικού λάθους (least mean square) στο αρχικό του σύνολο εκπαίδευσής. Αν οι συντελεστές που υπολογίστηκαν ταξινομήσουν σωστά όλα τα δείγματα, παράγαγε τον αντίστοιχο νευρωνικό. Αλλιώς, βρες ένα ζεύγος ελάχιστης εγγύτητας και παράγαγε δυο υποσύνολα του αρχικού συνόλου. Σε κάθε υποσύνολο τοποθέτησε το οδηγούν στοιχείο του, τα δείγματα επιτυχίας του αρχικού συνόλου εκπαίδευσης που βρίσκονται πιο κοντά στο οδηγούν στοιχείο, και όλα τα δείγματα αποτυχίας. Στην κατασκευή των υποσυνόλων, τα δείγματα επιτυχίας που βρίσκονται το ίδιο κοντά και στα δυο οδηγούντα στοιχεία τοποθετούνται στο υποσύνολο που περιέχει ένα δείγμα επιτυχίας που βρίσκεται πιο κοντά σε αυτό, αλλιώς σε εκείνο που περιέχει τα λιγότερα δείγματα επιτυχίας.

**2.3** Για κάθε υποσύνολο κάνε τα παρακάτω:

**2.3.1** Εκπαίδευσε ένα αντίγραφο του αντίστοιχου αρχικού νευρωνικού και υπολόγισε τους συντελεστές του.

**2.3.2** Αν οι συντελεστές που υπολογίστηκαν δεν ταξινομήσουν σωστά τα δείγματα που ανήκουν στο υποσύνολο, διαίρεσε περαιτέρω το υποσύνολο σε μικρότερα υποσύνολα όπως στο βήμα **2.2** και εφάρμοσε το βήμα **2.3**.

**2.3.3** Παράγαγε τον αντίστοιχο νευρωνικό.

### ***3.3 Εξαγωγή συμπερασμάτων βασισμένη σε νευρωνικές***

Η μηχανή εξαγωγής συμπερασμάτων βασισμένη σε νευρωνικές προκρίνει τη συμβολική συλλογιστική, που βασίζεται στη στρατηγική πίσω αλυσίδωσης. Η μηχανή εξαγωγής συμπερασμάτων χρησιμοποιεί τη μνήμη εργασίας, που περιέχει γεγονότα τα οποία προήλθαν από το χρήστη πριν από τη διαδικασία εξαγωγής συμπερασμάτων (αρχικά δεδομένα εισόδου) και/ ή παράχθηκαν κατά τη διάρκεια της διαδικασίας εξαγωγής συμπερασμάτων. Ένα γεγονός έχει την ίδια μορφή όπως μια συνθήκη/ ένα συμπέρασμα ενός συμβολικού κανόνα.

Μόλις δοθούν τα αρχικά δεδομένα εισόδου και τοποθετηθούν στη μνήμη εργασίας, εξετάζονται οι νευρωνικές εξόδου. Ένας από αυτούς επιλέγεται για εκτίμηση. Η επιλογή

βασίζεται στη σειρά με την οποία είναι αποθηκευμένοι. Ένας νευροκανόνας πυροδοτείται αν η έξοδος του αντίστοιχου νευρώνα υπολογίζεται “1” μετά την εκτίμηση των συνθηκών του. Ένας νευροκανόνας λέγεται ότι μπλοκάρεται αν η έξοδος του αντίστοιχου νευρώνα υπολογίζεται “-1” μετά την εκτίμηση των συνθηκών του.

Μια συνθήκη εκτιμάται «αληθής», αν ταυτίζεται με ένα γεγονός στη μνήμη εργασίας, τουτέστιν, υπάρχει ένα γεγονός με την ίδια μεταβλητή, το ίδιο κατηγορημα και την ίδια τιμή. Μια συνθήκη (που περιέχει μια μεταβλητή εισόδου) εκτιμάται «απροσδιόριστη», αν υπάρχει ένα γεγονός με την ίδια μεταβλητή, το ίδιο κατηγορημα και «απροσδιόριστη» τιμή (που παρέχεται από το χρήστη). Μια συνθήκη δεν μπορεί άμεσα να εκτιμηθεί αν δεν υπάρχει κάποιο γεγονός στην μνήμη εργασίας με την ίδια μεταβλητή. Σε αυτή την περίπτωση, είτε ζητείται από το χρήστη να παρέχει δεδομένα για την μεταβλητή, στην περίπτωση μιας μεταβλητής εισόδου, είτε εξετάζεται ένας ενδιάμεσος νευροκανόνας με συμπέρασμα που να περιέχει την μεταβλητή, στην περίπτωση μιας ενδιάμεσης μεταβλητής. Μια συνθήκη που περιέχει μια μεταβλητή εισόδου εκτιμάται «ψευδής», αν υπάρχει γεγονός στη μνήμη εργασίας με την ίδια μεταβλητή, το ίδιο κατηγορημα και διαφορετική τιμή. Μια συνθήκη που περιέχει μια ενδιάμεση μεταβλητή εκτιμάται «ψευδής» αν, επιπροσθέτως, δεν υπάρχει ενδιάμεσος νευροκανόνας με συμπέρασμα που περιέχει τη μεταβλητή, ο οποίος να μην έχει εκτιμηθεί. Η εξαγωγή συμπερασμάτων σταματά είτε όταν ένας ή περισσότεροι νευροκανόνες εξόδου πυροδοτούνται (επιτυχία) είτε όταν δεν εκτελείται καμία επιπλέον ενέργεια (αποτυχία).

Οι συνθήκες ενός νευροκανόνα οργανώνονται κατά φθίνουσα σειρά της απόλυτης τιμής των συντελεστών βαρύτητας. Αυτό διευκολύνει την εξαγωγή συμπερασμάτων. Έτσι, όταν ένας νευροκανόνας εξετάζεται στη διαδικασία εξαγωγής συμπερασμάτων, δε χρειάζεται να εκτιμηθούν όλες οι συνθήκες του. Για να επιτευχθεί αυτό, ορίζει κάποιος για κάθε νευροκανόνα το γνωστό άθροισμα και το εναπομένον άθροισμα ως εξής:

$$kn\_sum = sf_0 + \sum_{cond_i \in E} sf_i C_i$$

$$rem\_sum = \sum_{cond_i \in U} |sf_i|$$

όπου  $E$  είναι το σύνολο των συνθηκών που εκτιμήθηκαν,  $U$  είναι το σύνολο των συνθηκών που δεν έχουν εκτιμηθεί, και  $C_i$  είναι η τιμή της συνθήκης  $cond_i$ . Επομένως, το «γνωστό άθροισμα» είναι το σταθμισμένο άθροισμα των τιμών των ήδη γνωστών (που εκτιμήθηκαν) συνθηκών (εισόδων) του αντίστοιχου νευροκανόνα, και το «εναπομένον άθροισμα»



αντιπροσωπεύει το μέγιστο πιθανό σταθμισμένο άθροισμα των υπολοίπων (που δεν έχουν εκτιμηθεί) συνθηκών (εισόδων) του νευροκανόνα.

Όταν ένας νευροκανόνας βρίσκεται υπό εκτίμηση, το γνωστό άθροισμα και το εναπομένον άθροισμα υπολογίζονται (ξανά) μετά την εκτίμηση κάθε συνθήκης του νευροκανόνα. Όταν  $|kn\_sum| > rem\_sum$ , για ένα συγκεκριμένο νευροκανόνα, τότε η εκτίμηση των συνθηκών του σταματά, γιατί η έξοδος του μπορεί να εξαχθεί ανεξάρτητα από τις τιμές των συνθηκών που δεν έχουν εκτιμηθεί. Σε αυτή την περίπτωση, η έξοδος του είναι εξασφαλισμένο ότι είναι είτε “-1”, αν  $kn\_sum < 0$ , είτε “1”, αν  $kn\_sum > 0$ . Η συνθήκη μετά την εκτίμηση της οποίας η έξοδος του νευροκανόνα μπορεί να εξαχθεί καλείται *κρίσιμη συνθήκη*.

Επίσης, εισάγονται τα παρακάτω ευρετικά που βελτιώνουν περαιτέρω την απόδοση των νευροκανόνων. Πρώτα, αν μια συνθήκη εκτιμάται «αληθής», τότε οι συνθήκες με την ίδια μεταβλητή που δεν έχουν εκτιμηθεί, που καλούνται ομώνυμες συνθήκες, δε συνεισφέρουν στο εναπομένον άθροισμα, καθώς σίγουρα εκτιμώνται «ψευδείς». Σε κάθε άλλη περίπτωση, από τις συνθήκες που δεν έχουν εκτιμηθεί με την ίδια μεταβλητή, μόνον αυτή με τον μέγιστο συντελεστή βαρύτητας κατ’ απόλυτη τιμή συνεισφέρει στο εναπομένον άθροισμα. Για παράδειγμα, μετά την εκτίμηση της συνθήκης “assistance-times is >1 (2.8)” στον νευροκανόνα  $NR_1$  (Πίνακας 2), μόνο η συνθήκη “requested-examples is 0 (-2.0)” συνεισφέρει στο εναπομένον άθροισμα, καθώς οι ομώνυμες συνθήκες της, “requested-examples is 1 (0.9)” και “requested-examples is >1 (0.7)”, έχουν μικρότερους συντελεστές βαρύτητας κατ’ απόλυτη τιμή, και αυτές οι τρεις συνθήκες δεν μπορεί να είναι ταυτόχρονα αληθείς. Επίσης, οι δυο τελευταίες συνθήκες δε συνεισφέρουν, καθώς είναι σίγουρα ψευδείς (μια από τις ομώνυμες συνθήκες τους έχει ήδη εκτιμηθεί «αληθής»).

Για να διευκρινιστεί πώς γίνεται η εξαγωγή συμπερασμάτων, παρουσιάζεται το παρακάτω παράδειγμα. Ας υποθέσει κάποιος ότι υπάρχει μια βάση γνώσης που περιέχει τους τέσσερις νευροκανόνες του Πίνακα 2 και μια μνήμη εργασίας με τα παρακάτω γεγονότα: {“solution-attempts is 1”, “requested-examples is >1”, “assistance-times is >1”}. Η μηχανή εξαγωγής συμπερασμάτων ξεκινά εξετάζοντας κάθε νευροκανόνα για να βρει αν κάποιος από αυτούς πυροδοτείται (επιτυγχάνει). Όπως αναφέρθηκε, οι νευροκανόνες εκτιμώνται με τη σειρά με την οποία αποθηκεύονται. Τα γνωστά και τα εναπομένοντα αθροίσματα υπολογίζονται για κάθε νευροκανόνα μετά την εκτίμηση κάθε συνθήκης (ας θυμηθεί κάποιος ότι η τιμή μιας συνθήκης είναι “1”, αν είναι αληθής, και “0”, αν είναι ψευδής). Τα γνωστά και τα

εναπομένοντα αθροίσματα κάθε νευροκανόνα μετά την εκτίμηση της κρίσιμης συνθήκης είναι ως εξής:

$NR_1$  (μετά την εκτίμηση της πέμπτης συνθήκης του):  $ks_1 = -1.5$ ,  $rs_1 = 0.9$  (αποτυχία, αφού  $|ks_1| = 1.5 > rs_1$  και  $ks_1 < 0$ ).

$NR_2$  (μετά την εκτίμηση της τρίτης συνθήκης του):  $ks_2 = -7.3$ ,  $rs_2 = 1.6$  (αποτυχία, αφού  $|ks_2| = 7.3 > rs_2$  και  $ks_2 < 0$ ).

$NR_3$  (μετά την εκτίμηση της έβδομης συνθήκης του):  $ks_3 = 2.1$ ,  $rs_3 = 1.2$  (αποτυχία, αφού  $|ks_3| = 2.1 > rs_3$  και  $ks_3 > 0$ ).

Επειδή ο νευροκανόνας  $NR_3$  επιτυγχάνει, η διαδικασία εξαγωγής συμπερασμάτων σταματά και παράγεται το συμπέρασμα “mark-level is average” και τοποθετείται στη μνήμη εργασίας. Παρατηρεί κάποιος ότι δεν έχουν εκτιμηθεί όλες οι συνθήκες των νευροκανόνων για να φτάσει κάποιος σε συμπέρασμα.

Πειραματικά αποτελέσματα έχουν δείξει ότι η εξαγωγή συμπερασμάτων που βασίζεται σε νευροκανόνες είναι πιο αποδοτική από την αντίστοιχη εξαγωγή συμπερασμάτων που βασίζεται σε συμβολικούς κανόνες (Hatzilygeroudis and Prentzas, 2000). Ο κύριος λόγος γι’ αυτό είναι το γεγονός ότι ένας νευροκανόνας είναι μια συγχώνευση συνήθως περισσότερων από ένα συμβολικών κανόνων που έχουν το ίδιο συμπέρασμα, και, επομένως, ο συνολικός αριθμός κανόνων και συνθηκών στη βάση κανόνων είναι μειωμένος. Με τον τρόπο αυτό, ο αριθμός των κανόνων και των συνθηκών που συμμετέχουν στη διαδικασία εξαγωγής συμπερασμάτων είναι μειωμένος. Αυτό εντείνεται εξαιτίας των ευρετικών που παρουσιάστηκαν παραπάνω.

Ένα άλλο πλεονέκτημα της συλλογιστικής βασισμένης σε νευροκανόνες σε σύγκριση με τη συλλογιστική βασισμένη σε συμβολικούς κανόνες είναι η ικανότητα να φτάσει κάποιος σε συμπεράσματα από νευροκανόνες ακόμη κι αν κάποιες από τις συνθήκες είναι απροσδιόριστες. Αυτό δεν είναι εφικτό στη συλλογιστική βασισμένη σε συμβολικούς κανόνες. Ένας συμβολικός κανόνας χρειάζεται όλες οι συνθήκες του να είναι γνωστές έτσι ώστε να παραχθεί κάποιο συμπέρασμα.

Για παράδειγμα, αν το γεγονός “solution-attempts is unknown” βρίσκεται στην μνήμη εργασίας (αντί για το γεγονός “solution-attempts is 1”) στο παραπάνω παράδειγμα, τότε και πάλι ο νευροκανόνας  $NR_3$  επιτυγχάνει, ενώ οι νευροκανόνες  $NR_1$  και  $NR_2$  αποτυγχάνουν. Η πολιτική που ακολουθεί κάποιος όταν η τιμή μιας μεταβλητής είναι «απροσδιόριστη» είναι

ως εξής: η συνεισφορά στο γνωστό άθροισμα είναι η μέση τιμή των συντελεστών βαρύτητας όλων των ομώνυμων συνθηκών της μεταβλητής. Στην περίπτωση μας, η μέση τιμή των συντελεστών βαρύτητας των ομώνυμων συνθηκών της μεταβλητής “solution-attempts” είναι  $(-6.2 + 2.6 - 1.0)/3 = -1.5$ . Επίσης, μετά από αυτή τη συνεισφορά, που συμβαίνει όταν μια από τις ομώνυμες συνθήκες της μεταβλητής συναντηθεί, οι υπόλοιπες ομώνυμες συνθήκες δε συνεισφέρουν πια ούτε στο γνωστό ούτε στο εναπομένον άθροισμα. Για να διευκρινιστεί η διαδικασία εκτίμησης, παρουσιάζεται η εκτίμηση του νευρωκανόνα  $NR_3$  λεπτομερώς:

Συνθήκη	$kn\_sum$	$rem\_sum$
1	$-2.6 + (-1.5) = -4.1$	$6.0 + 5.7 = 11.7$
2	$-4.1 + 0 = -4.1$	$4.7 + 3.2 = 7.9$
3	$-4.1 + 0 = -4.1$	$4.7 + 3.2 = 7.9$
4	$-4.1 + 4.7 = 0.6$	3.2
5	$0.6 + 0 = 0.6$	0.2

Επειδή, μετά την εκτίμηση της πέμπτης συνθήκης (της κρίσιμης συνθήκης),  $|ks| = 0.6 > rs = 0.2$  και  $ks > 0$ , ο νευρωκανόνας  $NR_3$  επιτυγχάνει και το συμπέρασμά του προστίθεται στην μνήμη εργασίας. Αυτό δε συμβαίνει με τους συμβολικούς κανόνες, όπου η εκτίμηση σταματά σε τέτοιες περιπτώσεις.

# 4

## *Υβριδική αρχιτεκτονική*

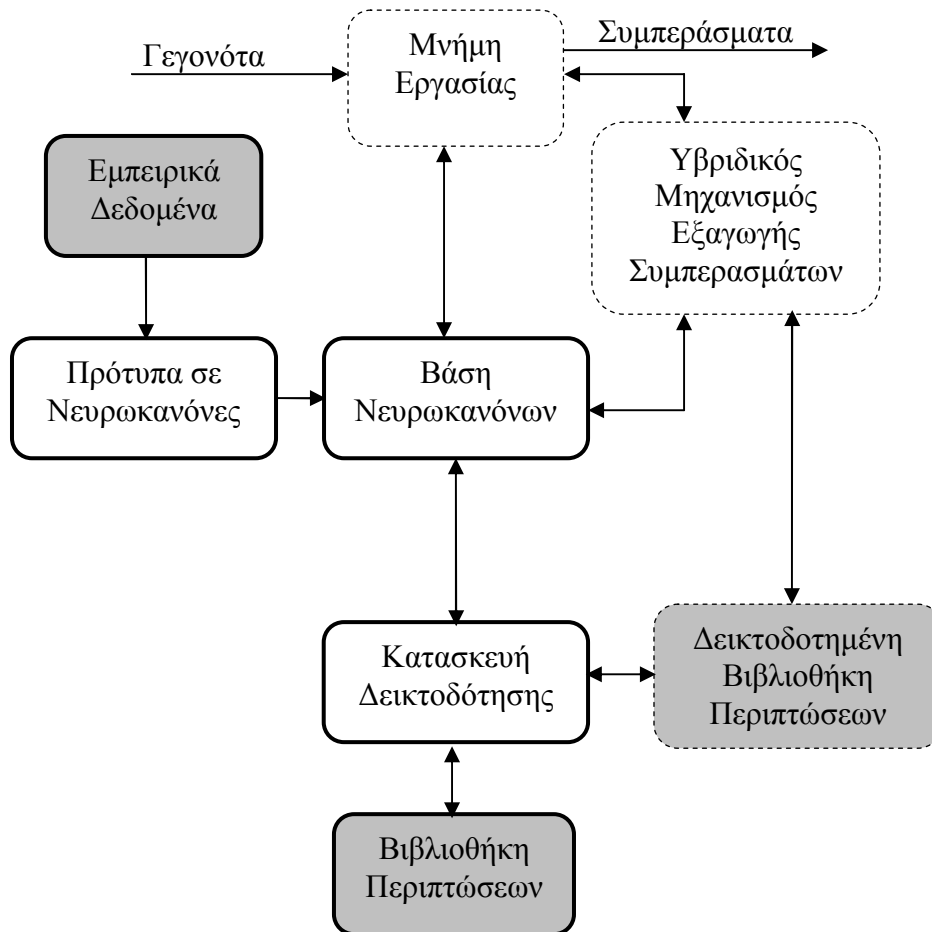
Στην **Εικόνα 9**, παρουσιάζεται η αρχιτεκτονική του υβριδικού συστήματος που υλοποιεί τη συνδυαστική μέθοδο συλλογιστικής που είναι βασισμένη σε νευρωνικούς και περιπτώσεις. Το σύστημα εκτέλεσης (μέσα στο πλαίσιο με διακεκομμένες γραμμές) αποτελείται από τα παρακάτω τμήματα: τη μνήμη εργασίας, τον υβριδικό μηχανισμό εξαγωγής συμπερασμάτων, τη βάση νευρωνικών και τη δεικτοδοτημένη βιβλιοθήκη περιπτώσεων.

Η βάση νευρωνικών περιέχει νευρωνικούς που αναπαριστούν γενική γνώση. Οι νευρωνικοί προκύπτουν από ένα σύνολο παραδειγμάτων-προτύπων εκπαίδευσης, όπως περιγράφεται στην **Ενότητα 3.2**. Η διαδικασία αυτή εκτελείται από το τμήμα «πρότυπα σε νευρωνικούς».

Η βάση νευρωνικών χρησιμοποιείται για να δεικτοδοτήσει μια βιβλιοθήκη περιπτώσεων. Με τον τρόπο αυτό, προκύπτει η δεικτοδοτημένη βιβλιοθήκη περιπτώσεων. Οι περιπτώσεις στη δεικτοδοτημένη βιβλιοθήκη περιπτώσεων λειτουργούν ως εξαιρέσεις στους νευρωνικούς της βάσης νευρωνικών. Κάθε περίπτωση τυποποιείται σαν ένα σύνολο ζευγών χαρακτηριστικού-τιμής. Σε μια περίπτωση, διακρίνουμε τα χαρακτηριστικά εισόδου και το χαρακτηριστικό εξόδου αυτής. Το χαρακτηριστικό εξόδου είναι αυτό που αναπαριστά την απόφαση που λαμβάνεται σε μια περίπτωση και ταυτίζεται με τη μεταβλητή του συμπεράσματος του σχετικού νευρωνικού. Τα υπόλοιπα χαρακτηριστικά μιας περίπτωσης είναι τα χαρακτηριστικά εισόδου της. Επομένως, μια περίπτωση αναπαρίσταται σαν μια πλειάδα της παρακάτω μορφής:

$$[i_1 \ i_2 \ \dots \ i_m \ o]$$

όπου  $i_j (j = 1, \dots, m)$  είναι οι τιμές των χαρακτηριστικών εισόδου και  $o$  είναι η τιμή του χαρακτηριστικού εξόδου της περίπτωσης. Η διαδικασία της δημιουργίας μιας δεικτοδότησης μεταξύ νευροκανόνων και περιπτώσεων εκτελείται εκτός σύνδεσης από το τμήμα «κατασκευή δεικτοδότησης» και παρουσιάζεται στην **Ενότητα 5**.



**Εικόνα 9. Η υβριδική αρχιτεκτονική**

Ο υβριδικός μηχανισμός εξαγωγής συμπερασμάτων εξάγει συμπεράσματα συνδυάζοντας συλλογιστική βασισμένη σε νευροκανόνες και περιπτώσεις. Λαμβάνει υπόψη του τα γεγονότα που περιέχονται στη μνήμη εργασίας, τους νευροκανόνες στη βάση νευροκανόνων και τις περιπτώσεις στη δεικτοδοτημένη βιβλιοθήκη περιπτώσεων.

# 5

## Δεικτοδότηση

Η δεικτοδότηση αφορά την οργάνωση των διαθέσιμων κανόνων έτσι ώστε να εκτελεστεί η συνδυαστική συλλογιστική. Οι νευροκανόνες που περιέχονται στη βάση νευροκανόνων χρησιμοποιούνται για να δεικτοδοτήσουν περιπτώσεις που αποτελούν εξαιρέσεις. Μια περίπτωση αποτελεί εξαίρεση σε έναν νευροκανόνα αν οι τιμές των χαρακτηριστικών της ικανοποιούν έναν ικανό αριθμό συνθηκών του νευροκανόνα (έτσι ώστε να πυροδοτηθεί), αλλά το συμπέρασμα του νευροκανόνα αντικρούει την αντίστοιχη τιμή του χαρακτηριστικού της περίπτωσης. Περιπτώσεις που αποτελούν εξαιρέσεις σε νευροκανόνες είναι πολύ σημαντικές, καθώς γεμίζουν κενά στη γνώση που αναπαρίσταται με νευροκανόνες. Κατά την εξαγωγή συμπερασμάτων, οι εξαιρέσεις βοηθούν να καταλήξει κάποιος στο σωστό συμπέρασμα.

Η επιδίωξη της διαδικασίας της άμεσης δεικτοδότησης είναι η αντιστοίχιση των διαθέσιμων νευροκανόνων με τις διαθέσιμες περιπτώσεις, που αποτελούν τις εξαιρέσεις τους. Η άμεση διαδικασία είναι ως εξής:

Για κάθε περίπτωση, μέχρις ότου όλες οι τιμές των χαρακτηριστικών εισόδου έχουν εξεταστεί,

1. Εκτέλεσε συλλογιστική βασισμένη σε νευροκανόνες παίρνοντας ως δεδομένα εισόδου τις τιμές των χαρακτηριστικών εισόδου της περίπτωσης.
2. Αν κάποιος νευροκανόνας πυροδοτηθεί, εξέτασε αν το συμπέρασμά του ταιριάζει με την αντίστοιχη τιμή του χαρακτηριστικού εξόδου της περίπτωσης, δεδομένου ότι η μεταβλητή του συμπεράσματος ταυτίζεται με το χαρακτηριστικό εξόδου. Αν δεν ταιριάζει, σημείωσε την περίπτωση σαν εξαίρεση στον νευροκανόνα.

Σαν παράδειγμα, για να δείξουμε πώς λειτουργεί η διαδικασία της δεικτοδότησης, χρησιμοποιείται ο νευροκανόνας  $NR_2$  (παράχθηκε παρόμοια με τον νευροκανόνα  $NR_1$ ), που

παρουσιάζεται στον **Πίνακα 3**, και οι δυο περιπτώσεις παραδείγματα στον **Πίνακα 4**. Μόνο τα πιο σημαντικά χαρακτηριστικά των περιπτώσεων φαίνονται στον **Πίνακα 4**. Οι περιπτώσεις, εντούτοις, έχουν κι άλλα χαρακτηριστικά.

NR2  
 (-13.1) if pain is continuous (6.9),  
 fever is high (5.2),  
 fever is medium (4.8),  
 patient-class is human21-35 (2.7),  
 patient-class is human0-20 (1.6)  
**then** disease-type is inflammation

**Πίνακας 3. Ένας νευροκανόνας παράδειγμα**

Case	Patient-class	Pain	Fever	Ant-reaction	Joints-pain	Disease-type
1	Human21-35	continuous	medium	high	yes	special-arthritis
2	Human0-20	continuous	high	high	no	inflammation

**Πίνακας 4. Περιπτώσεις παραδείγματα**

Condition no.	Case 1		Case 2	
	$ks_1$	$rs_1$	$ks_2$	$rs_2$
1	$-13.1+6.9= -6.2$	$5.2+2.7= 7.9$	$-13.1+6.9= -6.2$	$5.2+2.7= 7.9$
2	$-6.2+0= -6.2$	$4.8+2.7= 7.5$	$-6.2+5.2= -1.0$	2.7
3	$-6.2+4.8= -1.4$	2.7	$-1.0+0= -1.0$	2.7
4	$-1.4+2.7= 1.3$	0	$-1.0+0= -1.0$	1.6
5			$-1.0+1.6= 0.6$	0

**Πίνακας 5. Η ακολουθία εκτίμησης του νευροκανόνα για τις περιπτώσεις του Πίνακα 5**

“disease-type” είναι το χαρακτηριστικό εξόδου που αντιστοιχεί στη μεταβλητή του συμπεράσματος του νευροκανόνα. Έστω  $ks_1$  και  $rs_1$  το γνωστό και εναπομένον άθροισμα, αντίστοιχα, για την πρώτη περίπτωση. Επίσης, έστω  $ks_2$  και  $rs_2$  το γνωστό και εναπομένον άθροισμα, αντίστοιχα, για τη δεύτερη περίπτωση. Η εκτίμηση των συνθηκών για την πρώτη (δεύτερη) περίπτωση συνεχίζεται έως ότου  $|ks_1| > |rs_1|$  ( $|ks_2| > |rs_2|$ ). Ας θυμηθούμε ότι όταν μια συνθήκη εκτιμάται «αληθής», λαμβάνει την τιμή «1», ενώ όταν είναι «ψευδής» την τιμή

«0». Η ακολουθία της εκτίμησης του νευρωκανόνα  $NR_2$  για τις δυο περιπτώσεις του **Πίνακα 4** παρουσιάζονται στον **Πίνακα 5**.

Έτσι, οι τιμές των χαρακτηριστικών εισόδου και των δυο περιπτώσεων δίνουν θετικό γνωστό άθροισμα για τις συνθήκες του νευρωκανόνα. Το γεγονός ότι τα γνωστά αθροίσματα είναι θετικά σημαίνει ότι και οι δυο περιπτώσεις αφορούν τον τύπο ασθένειας “inflammation”. Εντούτοις, μόνο η τιμή του χαρακτηριστικού εξόδου για τον τύπο ασθένειας της δεύτερης περίπτωσης ταιριάζει με το συμπέρασμα του νευρωκανόνα. Η αντίστοιχη τιμή του χαρακτηριστικού εξόδου της πρώτης περίπτωσης αντικρούει το συμπέρασμα, επομένως αυτή η περίπτωση δεικτοδοτείται σαν εξαίρεση στον νευρωκανόνα  $NR_2$ .



# 6

## Συσταδοποίηση

### 6.1 Εισαγωγή

Η **συσταδοποίηση** (clustering) είναι μία από τις πιο χρήσιμες διεργασίες στη διαδικασία εξόρυξης γνώσης για την ανακάλυψη συστάδων και για τον προσδιορισμό κατανομών ή προτύπων (patterns) που παρουσιάζουν ενδιαφέρον στα υπό μελέτη δεδομένα. Το πρόβλημα της συσταδοποίησης σχετίζεται με την τμηματοποίηση (partitioning) ενός συνόλου δεδομένων σε συστάδες έτσι ώστε τα στοιχεία του συνόλου δεδομένων που ανήκουν σε μία συστάδα να είναι περισσότερο όμοια μεταξύ τους από ότι είναι με τα στοιχεία των άλλων συστάδων ή με τα στοιχεία που δεν ανήκουν σε καμία συστάδα. Για παράδειγμα, έστω μία βάση δεδομένων με εγγραφές πωλήσεων. Μία διαδικασία συσταδοποίησης θα ομαδοποιούσε τους πελάτες με τέτοιο τρόπο ώστε οι πελάτες που παρουσιάζουν όμοια αγοραστικά πρότυπα να ανήκουν στην ίδια συστάδα (cluster). Έτσι, το βασικό μέλημα της διαδικασίας συσταδοποίησης είναι να αποκαλύψει την οργάνωση προτύπων σε «λογικές» συστάδες, οι οποίες θα μας επιτρέψουν να ανακαλύψουμε ομοιότητες και διαφορές, καθώς επίσης και να αποκομίσουμε χρήσιμα συμπεράσματα για αυτά. Η συσταδοποίηση μπορεί να βρεθεί με διαφορετικά ονόματα σε διαφορετικά πεδία, όπως *μη εποπτευόμενη μάθηση* (*unsupervised learning*) στην αναγνώριση προτύπων, *αριθμητική ταξινόμια* (*numerical taxonomy*) στην βιολογία και στην οικολογία, *τυπολογία* (*typology*) στις κοινωνικές επιστήμες και *τμηματοποίηση* (*partitioning*) στη θεωρία των γράφων.

Στη διαδικασία της συσταδοποίησης δεν υπάρχουν προκαθορισμένες κατηγορίες ούτε κάποιο παράδειγμα που θα έδειχνε ποιες επιθυμητές σχέσεις θα ήταν έγκυρες μεταξύ των δεδομένων. Για τον λόγο αυτό είναι γνωστή ως διαδικασία μη εποπτευόμενης μάθησης. Από

την άλλη πλευρά, η κατηγοριοποίηση (classification) είναι μια διαδικασία ανάθεσης ενός αντικειμένου από το σύνολο των δεδομένων σε μία προκαθορισμένη κατηγορία. Η συσταδοποίηση παράγει τις αρχικές κατηγορίες στις οποίες οι τιμές ενός συνόλου δεδομένων μπορούν να κατηγοριοποιηθούν κατά τη διαδικασία της κατηγοριοποίησης.

Η διαδικασία συσταδοποίησης μπορεί να οδηγήσει σε διαφορετικές τμηματοποιήσεις ενός συνόλου δεδομένων, ανάλογα με το κριτήριο που χρησιμοποιείται για την συσταδοποίηση. Κατά συνέπεια, υπάρχει ανάγκη προ-επεξεργασίας των δεδομένων προτού να εφαρμοστεί η διεργασία της συσταδοποίησης σε ένα σύνολο δεδομένων. Τα βασικά βήματα για την ανάπτυξη της διαδικασίας της συσταδοποίησης μπορούν να συνοψιστούν ως εξής:

- ❖ Επιλογή χαρακτηριστικών γνωρισμάτων. Ο στόχος είναι να επιλεγούν κατάλληλα τα γνωρίσματα (attributes) στα οποία πρόκειται να εφαρμοστεί η συσταδοποίηση ώστε να κωδικοποιηθεί όσο το δυνατόν περισσότερη πληροφορία σχετικά με την εργασία που μας ενδιαφέρει. Κατά συνέπεια, η προ-επεξεργασία των δεδομένων μπορεί να είναι απαραίτητη πριν από τη χρησιμοποίησή τους στη διαδικασία της συσταδοποίησης.
- ❖ Αλγόριθμος συσταδοποίησης. Αυτό το βήμα αναφέρεται στην επιλογή ενός αλγορίθμου που οδηγεί στον καθορισμό ενός καλού σχήματος συσταδοποίησης (clustering scheme) για ένα σύνολο δεδομένων. Το μέτρο γειτνίασης (ομοιότητας) και το κριτήριο συσταδοποίησης που θα χρησιμοποιηθούν χαρακτηρίζουν ουσιαστικά τον αλγόριθμο συσταδοποίησης καθώς και τη δυνατότητά του να καθορίσει ένα σχήμα συσταδοποίησης που να ταιριάζει στο σύνολο δεδομένων. Συνεπώς το βήμα αυτό βασίζεται στα εξής:
  - Στο **μέτρο γειτνίασης** (proximity measure) το οποίο προσδιορίζει πόσο «όμοια» είναι δύο αντικείμενα (δηλαδή διανύσματα γνωρισμάτων). Στις περισσότερες από τις περιπτώσεις πρέπει να εξασφαλίσουμε ότι όλα τα επιλεγμένα γνωρίσματα συμβάλλουν εξίσου στον υπολογισμό του και δεν υπάρχει κανένα γνώρισμα που να υπερισχύει των άλλων.
  - Στο **κριτήριο συσταδοποίησης**. Σε αυτό το βήμα, πρέπει να καθορίσουμε το κριτήριο συσταδοποίησης το οποίο μπορεί να εκφραστεί μέσω μιας συνάρτησης κόστους ή κάποιου άλλου τύπου κανόνων. Πρέπει να τονίσουμε ότι πρέπει να λάβουμε υπόψη τον τύπο των συστάδων που αναμένονται να εμφανιστούν στο σύνολο δεδομένων. Κατά συνέπεια, πρέπει να καθορίσουμε ένα «καλό» κριτήριο συσταδοποίησης που να οδηγεί σε μία τμηματοποίηση

που να ταιριάζει καλά στο σύνολο δεδομένων.

- ❖ Επικύρωση αποτελεσμάτων. Η ακρίβεια των αποτελεσμάτων του αλγορίθμου συσταδοποίησης εξακριβώνεται χρησιμοποιώντας τα κατάλληλα κριτήρια και τεχνικές. Εφόσον οι αλγόριθμοι συσταδοποίησης καθορίζουν τις συστάδες που δεν είναι γνωστές εκ των προτέρων, ανεξάρτητα από τις μεθόδους συσταδοποίησης, η τελική τμηματοποίηση των δεδομένων απαιτεί κάποιου είδους αξιολόγηση στις περισσότερες εφαρμογές.
- ❖ Ερμηνεία των αποτελεσμάτων. Σε πολλές περιπτώσεις, οι εμπειρογνώμονες στην περιοχή της εφαρμογής που αναφέρεται η συσταδοποίηση πρέπει να ενσωματώσουν τα αποτελέσματα της συσταδοποίησης με άλλα πειραματικά στοιχεία καθώς και αποτελέσματα προηγούμενης ανάλυσης των υπό μελέτη στοιχείων, προκειμένου να προκύψει το σωστό συμπέρασμα.

## 6.2 Εφαρμογές συσταδοποίησης

Η συσταδοποίηση είναι ένα σημαντικό εργαλείο με ποικίλες εφαρμογές σε πολλά πεδία τόσο στο χώρο των επιστημών όσο και των επιχειρήσεων. Στην παράγραφο αυτή, συνοψίζουμε μερικά από τα πεδία εφαρμογής της συσταδοποίησης.

- ❖ Μείωση δεδομένων. Η συσταδοποίηση μπορεί να συμβάλει στη συμπίεση της πληροφορίας των δεδομένων. Σε διάφορες περιπτώσεις, ο όγκος των διαθέσιμων δεδομένων είναι πολύ μεγάλος και η επεξεργασία τους γίνεται πολύ απαιτητική. Η συσταδοποίηση μπορεί να χρησιμοποιηθεί για τον χωρισμό του συνόλου δεδομένων σε έναν αριθμό συστάδων που παρουσιάζουν «ενδιαφέρον». Κατόπιν, αντί της επεξεργασίας των δεδομένων ως οντότητες, υιοθετούμε τους αντιπροσώπους των συστάδων στη διαδικασία μας. Κατά συνέπεια, η συμπίεση δεδομένων έχει επιτευχθεί.
- ❖ Παραγωγή υπόθεσης. Η συσταδοποίηση χρησιμοποιείται σε αυτήν την περίπτωση προκειμένου να προκύψουν μερικές υποθέσεις για τα δεδομένα. Για παράδειγμα μπορούμε να βρούμε σε μια βάση δεδομένων πωλήσεων ότι υπάρχουν δυο σημαντικές συστάδες πελατών με βάση την ηλικία τους και τη χρονική στιγμή που κάνουν τις αγορές τους. Κατόπιν, μπορούν να προκύψουν μερικές υποθέσεις για τα δεδομένα, όπως «οι νέοι πηγαίνουν για ψώνια το βράδυ», «οι μεγαλύτεροι σε ηλικία άνθρωποι πηγαίνουν για ψώνια το πρωί».

- ❖ **Έλεγχος υπόθεσης.** Σε αυτήν την περίπτωση, η ανάλυση συστάδων (cluster analysis) χρησιμοποιείται για την επαλήθευση της εγκυρότητας μιας συγκεκριμένης υπόθεσης. Παραδείγματος χάριν, θεωρούμε την υπόθεση ότι «οι νέοι πηγαίνουν για ψώνια το βράδυ». Ένας τρόπος να ελεγχθεί εάν αυτό είναι αληθινό είναι να εφαρμοστεί η διαδικασία της συσταδοποίησης σε ένα αντιπροσωπευτικό σύνολο καταστημάτων. Υποθέτοντας ότι κάθε κατάστημα αντιπροσωπεύεται από πληροφορίες για τους πελάτες του (ηλικία, εργασία, κτλ.) και το χρόνο των συναλλαγών τους. Εάν, μετά την εφαρμογή της συσταδοποίησης, δημιουργηθεί μια συστάδα που αντιστοιχεί στο «οι νέοι πηγαίνουν για ψώνια το βράδυ», τότε η υπόθεση υποστηρίζεται από την ανάλυση συστάδων.
- ❖ **Πρόβλεψη βασισμένη σε συστάδες.** Η συσταδοποίηση εφαρμόζεται σε σύνολα δεδομένων και οι συστάδες που προκύπτουν χαρακτηρίζονται από τα χαρακτηριστικά των προτύπων που ανήκουν σε αυτές τις συστάδες. Κατόπιν, τα άγνωστα πρότυπα μπορούν να ταξινομηθούν στις προσδιοριζόμενες συστάδες σύμφωνα με την ομοιότητά τους στα χαρακτηριστικά των συστάδων. Συνεπώς χρήσιμη γνώση που αφορά τα στοιχεία μας μπορεί να εξαχθεί. Παραδείγματος χάριν, έστω ότι η διαδικασία της συσταδοποίησης εφαρμόζεται σε ένα σύνολο δεδομένων που αφορούν ασθενείς που μολύνονται από την ίδια νόσο. Το αποτέλεσμα είναι διάφορες ομάδες ασθενών, σύμφωνα με την αντίδρασή τους σε συγκεκριμένα φάρμακα. Κατόπιν για έναν νέο ασθενή, προσδιορίζουμε τη συστάδα στην οποία μπορεί να κατηγοριοποιηθεί και βασιζόμενοι σε αυτήν την απόφαση μπορούμε να καθορίζουμε τη φαρμακευτική του αγωγή.

Πιο συγκεκριμένα, μερικές χαρακτηριστικές εφαρμογές συσταδοποίησης αφορούν τα ακόλουθα πεδία:

- ❖ ***Επιχειρήσεις.*** Σε μια επιχείρηση, η συσταδοποίηση μπορεί να βοηθήσει τους εμπόρους να ανακαλύψουν σημαντικές συστάδες στη βάση δεδομένων των πελατών τους και να τις χαρακτηρίσουν με βάση τα αγοραστικά πρότυπα.
- ❖ ***Βιολογία.*** Στη βιολογία, μπορεί να χρησιμοποιηθεί για να καθορίσει τις ταξινομίες (taxonomies), να κατηγοριοποιήσει τα γονίδια με παρόμοια λειτουργία και να μελετηθούν σε βάθος οι υπό μελέτη δομές των πληθυσμών.
- ❖ ***Χωρική ανάλυση στοιχείων.*** Εξαιτίας του τεράστιου όγκου χωρικών δεδομένων που μπορούν να ληφθούν από τις δορυφορικές εικόνες, ιατρικό εξοπλισμό, γεωγραφικά συστήματα πληροφοριών, εξερεύνηση βάσεων δεδομένων εικόνας, κτλ., είναι ακριβό

και δύσκολο για τους χρήστες να εξετάσουν τα χωρικά στοιχεία λεπτομερώς. Η συσταδοποίηση μπορεί να βοηθήσει στην αυτοματοποίηση της διαδικασίας ανάλυσης και κατανόησης των χωρικών δεδομένων. Χρησιμοποιείται για να προσδιορίσει και να εξάγει τα ενδιαφέροντα χαρακτηριστικά και τα πρότυπα που μπορούν να υπάρξουν σε μεγάλες χωρικές βάσεις δεδομένων.

- ❖ *Εξόρυξη στον παγκόσμιο ιστό.* Σε αυτήν την περίπτωση, η συσταδοποίηση χρησιμοποιείται για να ανακαλύψει τις σημαντικές συστάδες εγγράφων στην τεράστια συλλογή ημιδομημένων εγγράφων του παγκόσμιου ιστού. Αυτή η κατηγοριοποίηση των εγγράφων του παγκόσμιου ιστού βοηθά στην ανακάλυψη χρήσιμης πληροφορίας.

Γενικά, η συσταδοποίηση μπορεί να χρησιμεύσει ως βήμα προ-επεξεργασίας για άλλους αλγορίθμους, όπως στην κατηγοριοποίηση η οποία θα λειτουργούσε πάνω στις προσδιοριζόμενες συστάδες από την διαδικασία της συσταδοποίησης.

## **6.3 Μέθοδοι συσταδοποίησης**

Οι αλγόριθμοι συσταδοποίησης μπορούν γενικά να ταξινομηθούν σύμφωνα με:

- Τον τύπο δεδομένων που εισάγονται στον αλγόριθμο.
- Τη μέθοδο που καθορίζει τη συσταδοποίηση του συνόλου των δεδομένων.
- Τη θεωρία και τις θεμελιώδεις έννοιες στις οποίες είναι βασισμένες οι τεχνικές ανάλυσης συστάδων.

### **6.3.1 Κατηγοριοποίηση με βάση την μέθοδο συσταδοποίησης**

Σύμφωνα με τη μέθοδο που υιοθετείται για τον καθορισμό των συστάδων, οι αλγόριθμοι μπορούν να ταξινομηθούν στους ακόλουθους τύπους:

- ❖ *Διαιρετική συσταδοποίηση* (Partitional clustering), που βασίζεται στην άμεση αποσύνθεση του συνόλου των δεδομένων σε ένα σύνολο μη σχετιζόμενων συστάδων. Η συνάρτηση που ο αλγόριθμος συσταδοποίησης προσπαθεί να ελαχιστοποιήσει μπορεί να δίνει έμφαση στην τοπική δομή των δεδομένων, αναθέτοντας συστάδες στα άκρα της συνάρτησης, ή στη γενική δομή των δεδομένων. Το γενικό κριτήριο είναι η ελαχιστοποίηση κάποιων μέτρων ανομοιότητας μεταξύ των δειγμάτων μέσα σε κάθε

μία από τις συστάδες, καθώς και η μεγιστοποίηση της ανομοιότητας μεταξύ των διαφορετικών συστάδων.

- ❖ **Ιεραρχική συσταδοποίηση** (Hierarchical clustering), που βασίζεται στη διαδοχική σύνδεση μικρότερων συστάδων σε μεγαλύτερες ή στη διάσπαση μεγαλύτερων συστάδων σε μικρότερες. Οι μέθοδοι συσταδοποίησης διαφέρουν στον κανόνα με βάση τον οποίο αποφασίζεται ποιες από τις μικρότερες συστάδες θα συγχωνευτούν για τη δημιουργία κάποιας μεγαλύτερης, ή ποια μεγάλη συστάδα θα διασπαστεί. Το τελικό αποτέλεσμα είναι ένα δέντρο από συστάδες το οποίο καλείται *δενδρόγραμμα* και το οποίο παρουσιάζει τον τρόπο με τον οποίο οι συστάδες σχετίζονται μεταξύ τους.
- ❖ **Ασαφής συσταδοποίηση** (Fuzzy clustering), που χρησιμοποιεί τεχνικές ασαφούς λογικής για να ομαδοποιήσει δεδομένα και θεωρεί ότι ένα αντικείμενο μπορεί να ταξινομηθεί σε περισσότερες από μία συστάδες. Αυτός ο τύπος αλγορίθμων οδηγεί σε σχήματα συσταδοποίησης τα οποία είναι συμβατά με την εμπειρία μας από την καθημερινή ζωή δεδομένου ότι χειρίζονται την αβεβαιότητα πραγματικών δεδομένων.
- ❖ **Μη ασαφής συσταδοποίηση** (Crisp clustering), που θεωρεί μη επικαλυπτόμενα χωρίσματα σημαίνοντας ότι ένα στοιχείο του συνόλου δεδομένων είτε ανήκει σε μια κατηγορία είτε όχι. Οι περισσότεροι από τους αλγορίθμους συσταδοποίησης οδηγούν σε σαφείς συστάδες και μπορούν έτσι να κατηγοριοποιηθούν στην κατηγορία της μη ασαφούς συσταδοποίησης.
- ❖ **Συσταδοποίηση βασισμένη στην πυκνότητα** (Density-based clustering), όπου η βασική ιδέα αυτού του τύπου συσταδοποίησης είναι η οργάνωση γειτονικών αντικειμένων ενός συνόλου δεδομένων σε συστάδες με βάση κάποια κριτήρια πυκνότητας.

### 6.3.2 Κατηγοριοποίηση με βάση τη θεωρία ορισμού συστάδας

Ένα άλλο κριτήριο κατηγοριοποίησης των αλγορίθμων είναι ο τρόπος που η συσταδοποίηση χειρίζεται την αβεβαιότητα από την άποψη της επικάλυψης των συστάδων.

### 6.3.3 Κατηγοριοποίηση με βάση τον τύπο των δεδομένων

Ένα άλλο κριτήριο με βάση το οποίο κατηγοριοποιούμε τους αλγορίθμους είναι το είδος των δεδομένων που έχουμε να μελετήσουμε (δηλαδή, αριθμητικά, κατηγορικά κτλ.).

- ❖ **Συσταδοποίηση αριθμητικών δεδομένων.** Οι αλγόριθμοι παράγουν συστάδες με βάση κάποια μέτρα αριθμητικής ομοιότητας μεταξύ των αντικειμένων. Περιορίζεται δηλαδή στο ότι μπορεί να εφαρμοστεί σε βάσεις δεδομένων με τύπο γνωρισμάτων αριθμητικές τιμές.

Κάθε αντικείμενο περιγράφεται από ένα σύνολο γνωρισμάτων, των οποίων οι τιμές είναι αριθμητικές. Ορισμένες τυπικές εγγραφές (αντικείμενα) που αφορούν στην περιγραφή κάποιων ατόμων μπορεί να είναι οι εξής:

Attribute	Height	Weight	IQ
Object1	1.85	180.0	100
Object2	1.75	195.0	80
Object3	1.45	135.0	155

Η περιγραφή ενός αντικειμένου μπορεί να αναπαρασταθεί με τη βοήθεια ενός διανύσματος ως εξής:

**Object1**(1.85, 180.0, 100)

**Object2**(1.75, 195.0, 80)

**Object3**(1.45, 135.0, 155)

Προκειμένου να μετρήσουμε την ομοιότητα ή την απόσταση μεταξύ των αντικειμένων θα πρέπει να χρησιμοποιήσουμε κάποιο μέτρο απόστασης. Ένα τέτοιο μέτρο μπορεί να είναι η Ευκλείδεια απόσταση ή η απόσταση Manhattan, οι οποίες δίνονται από τις παρακάτω εξισώσεις:

$$\text{Ευκλείδεια απόσταση} = \sqrt{\sum (x_i - y_i)^2}$$

$$\text{Απόσταση Manhattan} = \sum |x_i - y_i|,$$

όπου  $x_i$  και  $y_i$  είναι τα στοιχεία των δύο διανυσμάτων που αντιστοιχούν στα αντικείμενα X και Y.

- ❖ **Εννοιολογική συσταδοποίηση.** Αντίθετα με τη συσταδοποίηση αριθμητικών τιμών, η εννοιολογική συσταδοποίηση μπορεί να εφαρμοστεί σε βάσεις δεδομένων με τύπο

γνωρισμάτων μόνο κείμενο. Συνεπώς, η εννοιολογική συσταδοποίηση μπορεί να εφαρμοστεί σε αντικείμενα που έχουν την εξής μορφή:

Attribute	Height	Weight	IQ
Object1	Tall	Heavy	Average
Object2	Tall	Heavy	Low
Object3	Short	Light	High

Οι γεωμετρικές αποστάσεις δεν είναι κατάλληλες στην περίπτωση αυτή προκειμένου να εκτιμηθεί η απόσταση μεταξύ αντικειμένων της παραπάνω μορφής. Μια εναλλακτική μετρική που μπορεί να χρησιμοποιηθεί είναι η απόσταση Hamming, δηλαδή ο αριθμός των γνωρισμάτων που δεν είναι κοινά στα δυο αντικείμενα.

$$\text{Απόσταση Hamming} = \sum_{j=1}^m \delta(x_j, y_j),$$

$$\text{όπου } \delta(x_j, y_j) = \begin{cases} 0, & x_j = y_j \\ 1, & x_j \neq y_j \end{cases}.$$

Για παράδειγμα έστω τα αντικείμενα:

**Object1**(Tall, Heavy, Average)

**Object2**(Tall, Heavy, Low)

**Object3**(Short, Light, High)

Η απόσταση Hamming μεταξύ του Object1 και του Object2 είναι 1 καθώς διαφέρουν μόνο στην τιμή του γνωρίσματος IQ. Η απόσταση Hamming μεταξύ του Object1 και του Object3 είναι 3 καθώς έχουν διαφορετικές τιμές και για τα τρία γνωρίσματα.

Γενικά, οι αλγόριθμοι συσταδοποίησης είναι βασισμένοι σε ένα κριτήριο αξιολόγησης της ποιότητας μιας δεδομένης τμηματοποίησης. Πιο συγκεκριμένα, παίρνουν ως είσοδο μερικές παραμέτρους (π.χ. αριθμός συστάδων, πυκνότητα συστάδων) και προσπαθούν να καθορίσουν την καλύτερη τμηματοποίηση ενός συνόλου δεδομένων για τις δεδομένες παραμέτρους. Κατά συνέπεια, καθορίζουν την τμηματοποίηση ενός συνόλου δεδομένων με βάση ορισμένες υποθέσεις και όχι απαραίτητα την «καλύτερη» που ταιριάζει στο σύνολο δεδομένων.

Εφόσον οι αλγόριθμοι συσταδοποίησης ανακαλύπτουν συστάδες που δεν είναι γνωστές εκ των προτέρων, ο τελικός χωρισμός ενός συνόλου δεδομένων απαιτεί κάποιο είδος



αξιολόγησης στις περισσότερες εφαρμογές. Παραδείγματος χάριν, ερωτήσεις όπως «πόσες συστάδες υπάρχουν σε ένα σύνολο δεδομένων;», «το σχήμα συσταδοποίησης που προκύπτει ταιριάζει στο σύνολο δεδομένων;», «υπάρχει καλύτερη τμηματοποίηση για το σύνολο δεδομένων μας;» διερευνούν την εγκυρότητα των αποτελεσμάτων της συσταδοποίησης και είναι τα θέματα των μεθόδων που συζητούνται στη βιβλιογραφία. Στοχεύουν στην ποσοτική αξιολόγηση των αποτελεσμάτων των αλγορίθμων συσταδοποίησης και είναι γνωστοί κάτω από τον γενικό όρο μέθοδοι εγκυρότητας συστάδων (cluster validity methods).

## 6.4 Αλγόριθμοι συσταδοποίησης

Πρόσφατα, πολλοί αλγόριθμοι συσταδοποίησης έχουν προταθεί και είναι διαθέσιμοι στη βιβλιογραφία.

### 6.4.1 Αλγόριθμος K-means

Ο αλγόριθμος K-means είναι από τους πιο γνωστούς αλγορίθμους συσταδοποίησης και αποτελεί τη βάση για πολλές παραλλαγές αλγορίθμων αυτής της κατηγορίας. Ανήκει στην κατηγορία της διαιρετικής συσταδοποίησης (partitional clustering) καθώς βασίζεται στην άμεση αποσύνθεση του συνόλου των δεδομένων σε ένα σύνολο ασυσχέτιστων συστάδων. Η αντικειμενική συνάρτηση την οποία προσπαθεί να ελαχιστοποιήσει ο αλγόριθμος είναι η μέση τετραγωνική απόσταση των δεδομένων από τα πλησιέστερα κέντρα των συστάδων και δίνεται από την εξίσωση:

$$E = \sum_{i=1}^c \sum_{x \in C_i} d(x, m_i)$$

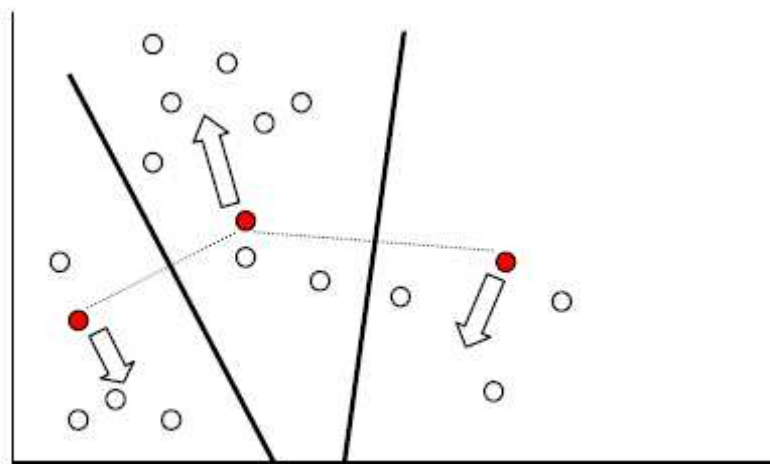
Στην παραπάνω εξίσωση,  $m_i$  είναι το κέντρο της συστάδας  $C_i$ , ενώ  $d(x, m_i)$  είναι η Ευκλείδεια απόσταση μεταξύ ενός στοιχείου  $x$  και του κέντρου  $m_i$ . Κατά συνέπεια, το κριτήριο - συνάρτηση  $E$  προσπαθεί να ελαχιστοποιήσει την απόσταση κάθε σημείου από το κέντρο της συστάδας στο οποίο το σημείο ανήκει. Πιο συγκεκριμένα, ο αλγόριθμος ξεκινά με την αρχικοποίηση των κέντρων των  $c$  συστάδων. Κατόπιν, αναθέτει κάθε στοιχείο (αντικείμενο) του συνόλου δεδομένων στη συστάδα της οποίας το κέντρο είναι πιο κοντά και υπολογίζει ξανά-υπολογίζει τα κέντρα. Η διαδικασία συνεχίζει έως ότου τα κέντρα των

συστάδων σταματήσουν να αλλάζουν.

Ο βασικός αλγόριθμος για να ελαχιστοποιήσει την αντικειμενική συνάρτηση αρχίζει θεωρώντας ένα σύνολο από  $k$  σημεία σαν κέντρα των  $k$  συστάδων. Αν η σειρά των δεδομένων δεν έχει κάποια ιδιαίτερη σημασία, τότε παίρνουμε τις πρώτες  $k$  εγγραφές. Αλλιώς επιλέγουμε σημεία αντιπροσωπευτικά για τις θεωρούμενες συστάδες. Καθένα από τα κέντρα αντιπροσωπεύει μία συστάδα. Στο δεύτερο βήμα, κάθε σημείο αντιστοιχείται στην συστάδα της οποίας το κέντρο βρίσκεται πιο κοντά.

Στη συνέχεια υπολογίζονται τα νέα κέντρα των συστάδων με χρήση του μέσου όρου των σημείων τους. Για άλλη μια φορά, αντιστοιχείται κάθε σημείο στην συστάδα της οποίας το κέντρο είναι πιο κοντά. Η διαδικασία επαναλαμβάνεται συνεχώς έως ότου τα όρια των συστάδων παύουν να μεταβάλλονται, ή η συνάρτηση  $E$  δεν μεταβάλλεται σημαντικά.

Ο αλγόριθμος K-means χρησιμοποιεί σταθερό και δεδομένο εξ αρχής αριθμό συστάδων που θα δημιουργηθούν (όσα και τα κέντρα).



Σχήμα 3-2. Ο αλγόριθμος K-Means.

Στην παράγραφο αυτή περιγράφονται τα βασικά βήματα του αλγορίθμου K-means. Ο αλγόριθμος ξεκινά καθορίζοντας με τυχαίο τρόπο  $c$  κέντρα που θα αντιπροσωπεύουν τις  $c$  συστάδες. Στην συνέχεια προσδιορίζεται η απόσταση κάθε στοιχείου του συνόλου δεδομένων από το κέντρο κάθε συστάδας και κάθε στοιχείο τοποθετείται στην συστάδα από την οποία απέχει λιγότερο. Τα κέντρα των νέων συστάδων υπολογίζονται σαν ο μέσος όρος των στοιχείων που ανήκουν μέχρι στιγμής σε κάθε συστάδα. Η διαδικασία επαναλαμβάνεται μέχρις ότου οι συστάδες να σταματήσουν να μεταβάλλονται. Αυτό σημαίνει ότι η απόκλιση μεταξύ των κέντρων των συστάδων που προέκυψαν τελευταία από αυτά της προηγούμενης επανάληψης είναι κοντά στο μηδέν (τα κέντρα ταυτίζονται). Πιο αναλυτικά ο αλγόριθμος

αποτελείται από τα παρακάτω βήματα:

- **Βήμα 1.** Επίλεξε  $k$  σημεία σαν τα αρχικά κέντρα των συστάδων.
- **Βήμα 2.** Ανάθεσε κάθε στοιχείο του συνόλου δεδομένων στη συστάδα της οποίας το κέντρο είναι πιο κοντά του σύμφωνα με το μέτρο ομοιότητας που χρησιμοποιείται.
- **Βήμα 3.** Αφού έχει γίνει η ανάθεση όλων των στοιχείων σε κάποια από τις συστάδες, υπολόγισε ξανά τις θέσεις των  $k$  κέντρων.
- **Βήμα 4.** Επανάλαβε τα βήματα 2 και 3 μέχρι να ικανοποιηθεί κάποιο κριτήριο τερματισμού. Τα συνήθη κριτήρια τερματισμού είναι: να μην είναι δυνατή η μετακίνηση της θέσης των κέντρων ή η μετακίνηση να είναι ελάχιστη και να μην είναι δυνατή η περεταίρω ελαχιστοποίηση του τετραγωνικού σφάλματος ή η μεταβολή του να είναι ελάχιστη.

#### Ψευδοκώδικας

1. Εύρεση των αρχικών κέντρων,  $v_i, i = 1..c$ , για τις  $c$  συστάδες.

Για κάθε επανάληψη  $r = 1..r_{\max}$ :

2. Υπολογισμός της απόστασης κάθε στοιχείου του συνόλου δεδομένων από το κέντρο κάθε συστάδας

$$d_{ki} = (x_k - v_i)^2 \quad k=1..n \quad i=1..c$$

3. Κάθε στοιχείο  $x_k$  αντιστοιχίζεται στη συστάδα για την οποία ισχύει

$$\min_{k,i} (d_{ki}), \forall i, k$$

4. Υπολογισμός των νέων κέντρων των συστάδων

$$m_i^{(r+1)} = \frac{\sum_{k=1}^{n_i} x_k}{n_i}$$

όπου  $n_i$ , ο αριθμός των στοιχείων που ανήκουν στην  $i$  συστάδα μέχρι στιγμής.

5. If  $\|m_i^{(r)} - m_i^{(r+1)}\| < \varepsilon$  then stop

Else  $r = r + 1$ , goto2.

Ο αλγόριθμος K-means έχει πολυπλοκότητα χρόνου  $O(n)$  όπου  $n$  είναι ο αριθμός των προτύπων που περιέχονται στο σύνολο δεδομένων. Αυτό τον καθιστά ιδιαίτερα γρήγορο, δουλεύει επίσης πολύ καλά σε περιπτώσεις όπου η φυσική ομαδοποίηση των δεδομένων είναι συμπαγής, δηλαδή τα πρότυπα μέσα στις συστάδες βρίσκονται κοντά μεταξύ τους και οι συστάδες είναι απομακρυσμένες. Από την άλλη πλευρά όμως, ο K-means έχει κάποια μειονεκτήματα:

- ❖ Είναι πολύ ευαίσθητος στην αρχικοποίηση της θέσης των κέντρων των ομάδων με αποτέλεσμα να συγκλίνει σε τοπικό ελάχιστο της αντικειμενικής συνάρτησης αν δεν έχει επιλεγεί η σωστή αρχικοποίηση.
- ❖ Είναι δυνατόν το σύνολο των προτύπων που είναι πιο κοντά σε ένα από τα αρχικά κέντρα των ομάδων που έχουν επιλεγεί να είναι κενό, στην ουσία δηλαδή να έχει επιλεγεί ένα απομονωμένο σημείο σαν αρχικό κέντρο για κάποια από τις ομάδες, τότε αυτό θα έχει σαν αποτέλεσμα να μην είναι δυνατή η αλλαγή αυτού του κέντρου από τις επόμενες επαναλήψεις.
- ❖ Τα αποτελέσματα εξαρτώνται άμεσα από το μέτρο ομοιότητας που έχει χρησιμοποιηθεί. Συνήθης πρακτική είναι η κανονικοποίηση των δεδομένων πριν από την εισαγωγή τους στον αλγόριθμο.
- ❖ Επειδή είναι ένας αλγόριθμος με επίβλεψη, τα αποτελέσματα εξαρτώνται από την τιμή του  $k$ , δηλαδή τον αριθμό των συστάδων που θεωρούμε ότι έχουν τα δεδομένα. Λάθος επιλογή της τιμής του  $k$  μπορεί να οδηγήσει σε λανθασμένη συσταδοποίηση.

Ο K-means όπως προαναφέρθηκε αποτελεί μια ευρέως αποδεκτή τεχνική συσταδοποίησης, η οποία έχει χρησιμοποιηθεί αποτελεσματικά για συσταδοποίηση σε διάφορα πεδία ορισμού. Ωστόσο, ο αλγόριθμος δεν είναι η μοναδική τεχνική, υπάρχουν διάφορες εκδόσεις και πλήθος παραλλαγών αυτής. Οι παραλλαγές αυτές διαφέρουν κυρίως στον τρόπο επιλογής των αρχικών  $k$  κέντρων των συστάδων, στον υπολογισμό της ομοιότητας και στη στρατηγική που χρησιμοποιούν για τον υπολογισμό των κέντρων των συστάδων.

#### **6.4.2 Αλγόριθμοι βασισμένοι στον K-means για λεκτικά δεδομένα**

Σε σχέση με άλλους αλγορίθμους ο K-means και οι παραλλαγές του προσαρμόζεται καλά στη διαδικασία εξόρυξης γνώσης λόγω της αποδοτικότητάς του στην επεξεργασία μεγάλων συνόλων δεδομένων. Ωστόσο, η χρήση τους περιορίζεται συχνά σε αριθμητικά δεδομένα

λόγω του ότι αυτοί οι αλγόριθμοι ελαχιστοποιούν τη συνάρτηση κόστους υπολογίζοντας τους «μέσους» των συστάδων. Για τον σκοπό αυτό, τα τελευταία χρόνια έχουν γίνει κάποιες προσπάθειες για ανάπτυξη αλγορίθμων συσταδοποίησης που θα επεκτείνουν τη βασική λογική του K-means ώστε να υποστηρίζει συσταδοποίηση σε γνωρίσματα με κατηγορικές τιμές (Huang, 1997). Οι κυριότεροι αλγόριθμοι συσταδοποίησης που βασίζονται στον αλγόριθμο K-means είναι ο K-prototypes και ο K-modes. Οι αλγόριθμοι αυτοί έχουν αποδειχθεί αποτελεσματικοί για μεγάλα σύνολα λεκτικών δεδομένων σε σχέση με άλλους αλγορίθμους κυρίως ιεραρχικούς οι οποίοι λόγω της πολυπλοκότητάς τους καθίστανται μη αποδοτικοί για μεγάλα σύνολα δεδομένων.

#### 6.4.2.1 Αλγόριθμος K-modes

Ο αλγόριθμος K-modes λαμβάνει υπόψη του μόνο γνωρίσματα με λεκτικές τιμές. Γενικά, ο αλγόριθμος K-modes βασίζεται στον K-means στον οποίο όμως έχουν γίνει οι εξής τροποποιήσεις:

- ❖ Χρησιμοποιούνται διαφορετικά μέτρα ομοιότητας έτσι ώστε να μπορούν να εφαρμοστούν σε λεκτικές τιμές, και
- ❖ Αντικαταστάθηκαν τα  $k$  κέντρα με τα  $k$  modes.

Στη συνέχεια παρουσιάζουμε με μεγαλύτερη λεπτομέρεια τις τροποποιήσεις αυτές.

- ❖ **Μέτρα Ομοιότητας.** Έστω ότι  $X, Y$  είναι δυο αντικείμενα με  $m$  λεκτικά γνωρίσματα. Το μέτρο ομοιότητας μεταξύ του  $X$  και του  $Y$  μπορεί να οριστεί με βάση τη συνολική ανομοιότητα μεταξύ των λεκτικών γνωρισμάτων των δυο αντικειμένων (απόσταση Hamming). Όσο πιο μικρός είναι ο αριθμός των αταίριαστων τιμών των αντίστοιχων γνωρισμάτων των δύο αντικειμένων, τόσο περισσότερο όμοια μπορούν να θεωρηθούν τα δύο αντικείμενα. Τυπικά,

$$d(X, Y) = \sum_{j=1}^m \delta(x_j, y_j)$$

$$\text{όπου } \delta(x_j, y_j) = \begin{cases} 0, & x_j = y_j \\ 1, & x_j \neq y_j \end{cases}.$$

Το  $d(X, Y)$  δίνει ίση σημαντικότητα σε κάθε κατηγορία ενός γνωρίσματος.

Έστω ότι  $X$  είναι ένα σύνολο αντικειμένων που περιγράφονται από τα λεκτικά γνωρίσματα  $A_1, A_2, \dots, A_m$ . Το mode ενός αντικειμένου  $X$  είναι ένα διάνυσμα

$Q = [q_1, q_2, \dots, q_m]$  το οποίο ελαχιστοποιεί την εξίσωση

$$D(X, Q) = \sum_{i=1}^n d(X_i, Q)$$

όπου  $\mathbf{X} = \{X_1, X_2, \dots, X_n\}$  και  $d()$  η απόσταση Hamming. Εδώ, το  $Q$  δεν είναι απαραίτητο να είναι στοιχείο του  $X$ .

Έστω  $\{S_1, S_2, \dots, S_k\}$  είναι μια συσταδοποίηση του  $X$ , όπου  $S_i \neq \emptyset$  για  $1 \leq i \leq k$  και  $\{Q_1, Q_2, \dots, Q_k\}$  τα modes του  $\{S_1, S_2, \dots, S_k\}$ . Το συνολικό κόστος της συσταδοποίησης ορίζεται ως εξής:

$$E = \sum_{i=1}^k \sum_{l=1}^n d(X_l, Q_i),$$

όπου  $d()$  η απόσταση Hamming.

Παρόμοια με τον k-means αλγόριθμο, ο αντικειμενικός σκοπός της συσταδοποίησης είναι να βρούμε ένα σύνολο  $\{Q_1, Q_2, \dots, Q_k\}$  το οποίο μπορεί να ελαχιστοποιήσει το  $E$ . Τα βασικά βήματα του αλγορίθμου K-modes είναι τα ακόλουθα:

- **Βήμα 1.** Επιλογή  $k$  αρχικών modes, ένα για κάθε συστάδα.
- **Βήμα 2.** Ανάθεση ενός αντικειμένου στη συστάδα της οποίας το mode είναι πιο κοντά στο αντικείμενο σύμφωνα με την απόσταση Hamming. Ενημέρωση του mode της συστάδας μετά από κάθε ανάθεση.
- **Βήμα 3.** Αφού όλα τα αντικείμενα έχουν τοποθετηθεί σε συστάδες, γίνεται επανέλεγχος της ανομοιότητας των αντικειμένων ως προς τα τρέχοντα modes. Εάν για ένα αντικείμενο βρεθεί ότι βρίσκεται πιο κοντά στο mode μιας άλλης συστάδας από ότι στο mode της τρέχουσας συστάδας, τοποθετείται στην άλλη συστάδα και ενημερώνονται τα modes των συστάδων.
- **Βήμα 4.** Επανάληψη του βήματος 3 μέχρις ότου κανένα αντικείμενο να μην αλλάζει συστάδες μετά από πλήρη έλεγχο όλου του συνόλου δεδομένων.

Όπως και ο K-means έτσι και ο αλγόριθμος K-modes παράγει βέλτιστες λύσεις οι οποίες εξαρτώνται από τα αρχικά modes και τη διάταξη των αντικειμένων στο σύνολο των δεδομένων.

# 7

## *Εύρεση Εκτόπων (Outlier Detection)*

### *7.1 Εισαγωγή*

Η Εύρεση Έκτοπων είναι η πλέον συγγενής εφαρμογή από τη γενική διαδικασία εξόρυξης γνώσης ως προς την έννοια της ανακάλυψης χρήσιμων και αξιοποιήσιμων πληροφοριών σε βάσεις δεδομένων. Σύμφωνα με τον Hawkins (1980), που πρώτος έδωσε έστω έναν διαισθητικό ορισμό:

*«Έκτοπη είναι μία παρατήρηση που αποκλίνει τόσο πολύ από τις άλλες παρατηρήσεις, ώστε να μας εγείρει υποψίες ότι δημιουργήθηκε από διαφορετικό μηχανισμό.»*

Ο χαρακτηρισμός μίας παρατήρησης ως έκτοπης πρέπει να θεωρηθεί μονάχα σε ένα πλαίσιο ενός συγκεκριμένου συνόλου δεδομένων. Ένα από παράδειγμα είναι η παρουσία ενός σκύλου μέσα σε ένα κοπάδι από πρόβατα ή ένα διώροφο οίκημα σε ένα δρόμο της Νέας Υόρκης γεμάτο ουρανοξύστες. Παρόμοια, η ύπαρξη ενός προβάτου σε μία αγέλη σκύλων θα ήταν επίσης έκτοπο. Η διαφορά τόσο στα χαρακτηριστικά όσο και στις ποιότητες από την πλειονότητα του δείγματος σηματοδοτεί την διαφορετικότητα που εδώ ονομάζουμε έκτοπες παρατηρήσεις. Λόγω του ότι κάποιος θα θεωρούσε την εύρεση έκτοπων ως υποδιαδικασία της ομαδοποίησης ενός δείγματος πρέπει να αποσαφηνίσουμε περαιτέρω την έννοια της εύρεσης έκτοπων.

Στο παράδειγμα που αναφέραμε πριν, η εύρεση έκτοπων είναι υπεύθυνη για τον εντοπισμό του σκύλου σε ένα κοπάδι από πρόβατα. Αντίθετα η διαδικασία της ομαδοποίησης στο ίδιο δείγμα θα ομαδοποιούσε τα λευκά πρόβατα, τα μαύρα πρόβατα και ίσως δημιουργούσε μία νέα ομάδα μόνο για το σκύλο. Ενδεχομένως, να τον χαρακτήριζε ως μία παρατήρηση που δεν ανήκει σε καμία από τις δύο τάξεις. Επίσης, αν ένα πρόβατο είχε τρία πόδια η ομαδοποίηση ίσως το αγνοούσε και απλά ομαδοποιούσε το δείγμα με βάση το χρώμα. Αντιθέτως, η εύρεση έκτοπων δεν γίνεται με βάση κάποιο χαρακτηριστικό αλλά ο χώρος αναζήτησης (search space) εκτείνεται σε όλα τα χαρακτηριστικά. Επομένως, παρατηρώντας την ομοιότητα και τις διαφορές ανάμεσα σε αυτές τις δύο τεχνικές, μπορούμε να θεωρήσουμε ότι η ομαδοποίηση έχει τη δυνατότητα εύρεσης έκτοπων σε περιορισμένο πεδίο μιας και επικεντρώνεται στην δημιουργία ομάδων, αλλά η εύρεση έκτοπων αναγνωρίζει, για όλα τα χαρακτηριστικά, ακόμη και για ομάδες αυτών, τις διαφορές από μία γενικότερη εικόνα που έχει διαμορφωθεί για το δείγμα. Μην έχοντας, λοιπόν, περιορισμό στις δυνατότητες αναζήτησης, ανακαλύπτεται αρκετή και ενδιαφέρουσα γνώση για τα δεδομένα μας, η οποία δεν θα μπορούσε ενδεχομένως να ανακαλυφθεί διαφορετικά. Τέλος για να ξεκαθαρίσουμε περαιτέρω την κατάσταση αναφέρουμε ότι υπάρχουν πολλοί τρόποι για να εφαρμόσουμε την εύρεση έκτοπων και ένας τρόπος είναι η ομαδοποίηση. Τελευταίες έρευνες έχουν παράγει αλγόριθμους που ενσωματώνουν ομαδοποίηση με ταυτόχρονη σήμανση έκτοπων.

Ο δειγματοχώρος με τα χαρακτηριστικά γνωρίσματα είναι η αναπαράσταση του παρατηρούμενου πραγματικού κόσμου που ουσιαστικά επιτρέπει την εύρεση έκτοπων δίνοντας έμφαση σε συγκεκριμένα χαρακτηριστικά. Η εξαγωγή χαρακτηριστικών γνωρισμάτων είναι η αντιστοίχιση του παρατηρούμενου δείγματος στον δειγματοχώρο με βάση τα σημαντικότερα χαρακτηριστικά του. Αυτή η διαδικασία μπορεί να καταστεί αρκετά πολύπλοκη ή αρκετά απλή ανάλογα το περιβάλλον αναζήτησης. Παραδείγματος χάριν, στο παράδειγμα με το κοπάδι από πρόβατα θα πρέπει να αποφασίσουμε πώς θα αναπαραστήσουμε ένα πρόβατο καθώς και τον τρόπο συλλογής δεδομένων. Η πολυπλοκότητα του μετασχηματισμού αυτού εξαρτάται από τον ορισμό του έκτοπου. Ο ορισμός του έκτοπου σε έναν συγκεκριμένο δειγματοχώρο αποτελείται από μία περιγραφή του τι καθιστά μία παρατήρηση ως έκτοπη. Μπορούν να υπάρξουν και πλέον της μίας περιγραφής έκτοπων σε ένα δειγματοχώρο.

Τέλος, σημειώνουμε ότι μία άλλη ορολογία που επισυνάπτεται του αγγλικού outlier detection, είναι η *ανίχνευση ανωμαλιών*. Στην ελληνική βιβλιογραφία και επιστημονική κοινότητα δεν υπάρχει μία καθορισμένη μετάφραση. Συνεπώς, θα χρησιμοποιήσουμε τον όρο



έκτοπο αντί ανωμαλίας μιας και η ανωμαλία προϋποθέτει γνώση και οριοθέτηση φυσιολογικής συμπεριφοράς, κάτι που ίσως απουσιάζει στα παραδείγματα εξόρυξης γνώσης από βάσεις δεδομένων. Απεναντίας ο όρος έκτοπο ίσως μας καθοδηγεί οπτικά καθώς και γλωσσικά να καταλάβουμε απ' ευθείας την έννοια του outlier στα ελληνικά. Είναι μία παρατήρηση που διαφέρει από την ομοιομορφία της πλειοψηφίας των δειγμάτων των αντικειμένων εντός καθορισμένου τύπου.

*Η Εύρεση Έκτοπων είναι η αυτοματοποιημένη ή η ημιαυτοματοποιημένη διαδικασία ανεύρεσης έκτοπων. Η διαδικασία αυτή είναι σημαντική διότι τα έκτοπα υποδεικνύουν ότι κάποιου είδους ενέργεια ή δράση είναι απαραίτητη.*

Σκοπός της Εύρεσης Έκτοπων είναι η αποκάλυψη των μηχανισμών που γεννούν, καθορίζουν ή διέπουν την ύπαρξη των έκτοπων. Οι μηχανισμοί αυτοί είναι εύλογο ότι δεν θα συμβαδίζουν πλήρως με τους μηχανισμούς γένεσης ή ύπαρξης των παρατηρήσεων που δεν λογίζονται ως έκτοπα. Το επόμενο βήμα εάν ανακαλύψουμε τους μηχανισμούς δημιουργίας έκτοπων είναι να δημιουργήσουμε έναν ταξινομητή που θα είναι σε θέση να μάθει και να δημιουργήσει ομάδες από τα δείγματα έκτοπων. Στην πραγματικότητα όμως τέτοιοι μηχανισμοί είναι υπερβολικά πολύπλοκοι για να καθοριστούν σύμφωνα με την τρέχουσα επιστημονική γνώση. Τα αίτια παραγωγής έκτοπων συνήθως είναι εγγενή σε συμπεριφορές φυσικών μηχανισμών ή ανθρώπινης συμπεριφοράς. Αυτό καθιστά σχεδόν αδύνατο το λογικό καθορισμό των μηχανισμών αυτών και συνήθως οι ειδικοί του χώρου για τον οποίον γίνεται η εύρεση έκτοπων είναι εκείνοι που επιβαρύνονται με την εξήγηση τέτοιων μηχανισμών.

Για το σκοπό μας, όποτε αναφερόμαστε σε δεδομένα θα θεωρούμε ότι αυτά είναι ένα σύνολο παρατηρήσεων από ένα χώρο με  $n$  διαστάσεις (διάνυσμα  $n$  διαστάσεων). Η κάθε παρατήρηση αναπαρίσταται στα δεδομένα από μία εγγραφή (πλειάδα) με τα ανάλογα χαρακτηριστικά γνωρίσματα. Η σειρά (ακολουθία) των πλειάδων δεν είναι σημαντική. Κάθε χαρακτηριστικό αποθηκεύει και έναν τύπο δεδομένων.

## **7.2 Τύποι Εκτόπων**

Η πρώτη ταξινόμηση των τύπων των έκτοπων έχει ρίζες στην στατιστική. Ο διαχωρισμός γίνεται σε καταφανείς (gross) και δομικούς (structural). Τα καταφανή έκτοπα ενυπάρχουν σε ένα ή και περισσότερα χαρακτηριστικά. Τα δομικά έκτοπα συνήθως αφορούν το γενικότερο

σύνολο των δεδομένων και δεν μπορεί να εντοπιστεί το αίτιο της εκτοπικότητας (outlierness) σε ένα ή μία μικρή ομάδα χαρακτηριστικών.

Μία άλλη στατιστική προσέγγιση θέλει τρεις τύπους έκτοπων. Ο διαχωρισμός γίνεται βάση τον παράγοντα μέτρησης. Έτσι υπάρχει το έκτοπο βάση μίας συστάδας (cluster outlier), το περιφερειακό έκτοπο (radial outlier), και το διασκορπισμένο έκτοπο (scattered outlier) (Williams, 2002). Έκτοπο βάση μίας ομάδας δεδομένων παρατηρείται σε μικρές ομάδες δεδομένων που έχουν χαμηλή διακύμανση αναφορικά με το μέγεθος του δείγματος. Έκτοπο βάση ακτίνας (radial outlier) θεωρείται η παρατήρηση εκείνη που βρίσκεται σε ένα διάστημα έξω από το κεντρικό άξονα της διασποράς των δεδομένων. Διασκορπισμένο έκτοπο θεωρείται η παρατήρηση που είναι τυχαία διασκορπισμένη σχετικά με την πλειοψηφία του δείγματος. Παρατηρούμε λοιπόν ότι πέραν της στατιστικής προσέγγισης παρουσιάστηκε και η προσέγγιση κατανομής.

### **7.3 Ορισμοί Εκτόπων**

Στη βιβλιογραφία φαίνεται ότι υπάρχουν αρκετές προσεγγίσεις σχετικά με τον ορισμό έκτοπων. Οι πιο σημαντικές από αυτές καθορίζονται με βάση τα εξής στοιχεία:

- Κατανομή (distribution)
- Βάθος (depth)
- Συσταδοποίηση (clustering)
- Απόσταση (distance)
- Πυκνότητα (density)
- Γενετικοί Αλγόριθμοι (genetic algorithms)

Παρόλο που η λίστα αυτή δεν είναι ταξινομημένη χρονικά, οι προσεγγίσεις κατανομής και βάθους είναι οι παλαιότερες αλλά και οι πιο παραδοσιακές μέθοδοι που έχουν τη βάση τους στη Στατιστική και στην Υπολογιστική Γεωμετρία.

Η συσταδοποίηση όπως αναφέραμε είναι μία από τις πλέον παραδοσιακές μεθόδους εξόρυξης δεδομένων. Η προσέγγιση αυτή θέλει τα έκτοπα ως παρατηρήσεις που βρίσκονται εκτός των συστάδων (clusters). Η προσέγγιση αυτή παρομοιάζει τα έκτοπα ως θόρυβο εντός του οποίου βρίσκονται οι συστάδες. Σε γενικές γραμμές, η δυναμική της προσέγγισης αυτής είναι περιορισμένη σε πολυδιάστατα δεδομένα. Η έννοια των έκτοπων είναι φυσικώς συνδεδεμένη και αδιαίρετη με την αλγοριθμική προσέγγιση του αλγορίθμου συσταδοποίησης.

Η προσέγγιση με κριτήριο την απόσταση είναι αρκετά δημοφιλής διότι είναι πολύ εύκολο να κατανοηθούν και να υλοποιηθούν οι παράμετροι που καθορίζουν την μέτρηση απόστασης. Τέλος, η προσέγγιση με βάση την πυκνότητα εισήγαγε την έννοια των τοπικών έκτοπων καθώς επίσης και των ολικών έκτοπων έχοντας δανειστεί την τελευταία θεώρηση από τη προσέγγιση της απόστασης.

Ο ορισμός ενός έκτοπου πρέπει:

- Να είναι διαισθητικός και εύκολος στην κατανόηση μιας και οι χρήστες θα είναι οι ειδικοί ενός τομέα και όχι ειδικοί στην Εύρεση Έκτοπων.
- Να μπορεί να εφαρμόζεται ευρέως και να παρέχει μία λογική άνεση χρήσης. Μπορεί να υπάρχουν πολλές απόψεις ως προς το τι συνιστά ένα έκτοπο.
- Να είναι ευπροσάρμοστο σε γρήγορους υπολογισμούς. Ο όγκος της πληροφορίας προς επεξεργασία ενδέχεται να είναι αρκετά μεγάλος.

Βέβαια πρέπει να σημειώσουμε ότι οι κανόνες αυτοί δεν είναι απαραίτητο να ακολουθούνται κατά γράμμα. Μπορεί για μία συγκεκριμένη περίπτωση μία συγκεκριμένη θεώρηση του όρου έκτοπο να λειτουργεί καλύτερα από μία γενική και κάπως πιο αφαιρετική προσέγγιση. Στη συνέχεια, θα ασχοληθούμε μόνο με τις προσεγγίσεις συσταδοποίησης και απόστασης που βρίσκουν εφαρμογή σε πολλές μεθόδους συσταδοποίησης

### 7.3.1 Προσέγγιση Απόστασης

Στην προσέγγιση με βάση την απόσταση, ο ορισμός ενός έκτοπου στηρίζεται στην λεγόμενη γειτονιά. Γειτονιά είναι οι  $k$  πιο κοντινές παρατηρήσεις δοθείσας μιας συνάρτησης απόστασης  $d(\cdot)$ . Αν οι παρατηρήσεις αυτές (*γείτονες*) είναι κοντά, τότε η αρχική παρατήρηση θεωρείται «κανονική». Αντίθετα, αν οι γείτονες είναι μακριά, τότε η παρατήρηση χαρακτηρίζεται «έκτοπη». Δημοφιλείς ορισμοί βασισμένοι στην απόσταση είναι οι ακόλουθοι:

- Έκτοπα είναι οι  $n$  παρατηρήσεις με τη μεγαλύτερη απόσταση από τον  $k$ -οστό γείτονα.
- Έκτοπα είναι οι  $n$  παρατηρήσεις με τη μεγαλύτερη μέση απόσταση από τον  $k$ -οστό γείτονα.

Ένα σημείο-κλειδί στη προσέγγιση αυτή είναι ότι για να μπορούμε να ορίσουμε ένα έκτοπο βάση της απόστασης πρέπει πρώτα να είμαστε σε θέση να μετρήσουμε την όποια απόσταση, δημιουργώντας μία συνάρτηση απόστασης. Έτσι εισάγεται και εδώ μία δυσκολία όσον αφορά την ενασχόληση τέτοιων αλγορίθμων με δεδομένα πολλών διαστάσεων. Πρέπει να καθορίσουμε με τόσο ακρίβεια την απόσταση  $d$ , διότι εάν είναι πολύ μικρή τότε πολλά

δεδομένα θα θεωρηθούν έκτοπα, ενώ αν είναι πολύ μεγάλη τότε θα δυσκολευτούμε να τα εντοπίσουμε.

### **7.3.2 Προσέγγιση Συσταδοποίησης**

Η συσταδοποίηση είναι ένα σύνολο τεχνικών κατά τις οποίες ένα σύνολο δεδομένων διασπάται σε συστάδες με βάση ένα ή περισσότερα χαρακτηριστικά. Μπορούμε να εξάγουμε διάφορα συμπεράσματα από αυτές τις τεχνικές, όπως το αν ένα αντικείμενο ανήκει σε κάποια συστάδα ή δεν ανήκει πουθενά. Αυτό το αντικείμενο μπορεί αμέσως να χαρακτηριστεί ως έκτοπο. Κάτι τέτοιο δεν είναι απαραίτητο, όμως, διότι μπορούν να συντρέχουν διάφοροι παράγοντες που λέγονται παράγοντες «θορύβου». Αντί για ένα αντικείμενο, μία ομάδα αντικειμένων μπορεί να χαρακτηριστεί ολόκληρη ως έκτοπη. Συνήθως στις τεχνικές συσταδοποίησης τέτοια αντικείμενα (έκτοπα, «θόρυβος») αφαιρούνται από το σύνολο δεδομένων και η επεξεργασία συνεχίζεται δίχως αυτά. Σε άλλες περιπτώσεις απλά αναφέρονται, αλλά εν γένει δεν είναι και η πλέον αξιόπιστη προσέγγιση στην εύρεση έκτοπων. Ας μην ξεχνάμε, τέλος, ότι οι υπόλοιπες προσεγγίσεις έχουν δημιουργηθεί ουσιαστικά για να καλύψουν τα λειτουργικά κενά αυτής της προσέγγισης.

# 8

## *Δημιουργία Νευροκανόνων*

### *με μεθόδους Συσταδοποίησης*

Όπως υπογραμμίστηκε παραπάνω, υπάρχουν περιπτώσεις όπου ο κλαστικός αλγόριθμος ελάχιστου μέσου τετραγωνικού λάθους (least mean square) αποτυγχάνει να προσδιορίσει τους σωστούς συντελεστές βαρύτητας για κάποιους νευροκανόνες. Αυτό σημαίνει ότι τα πρότυπα γνώσης του συνόλου εκπαίδευσης αυτών των κανόνων αντιστοιχούν σε μια *μη διαχωρίσιμη συνάρτηση*. Με άλλα λόγια, κάποια από τα πρότυπα γνώσης των συνόλων εκπαίδευσης αυτών των κανόνων δεν ταξινομούνται σωστά, καθώς είναι γνωστό ότι ο νευρώνας δεν μπορεί να αναπαραστήσει πλήρως τέτοιες συναρτήσεις.

Για να ξεπεραστεί το πρόβλημα αυτό, το σύνολο εκπαίδευσης του αρχικού νευροκανόνα διαιρείται σε υποσύνολα με τέτοιο τρόπο ώστε κάθε υποσύνολο να περιέχει δείγματα επιτυχίας, που είναι «κοντινά» το ένα με το άλλο σε κάποιο βαθμό. Αυτό σημαίνει ότι από έναν αρχικό νευροκανόνα μπορεί να παραχθούν περισσότεροι από ένας τελικοί νευροκανόνες, που λέγονται *αδελφοί νευροκανόνες*.

Η παραγωγή περισσότερων από έναν νευροκανόνων με το ίδιο συμπέρασμα αποτελεί μειονέκτημα των νευροκανόνων, καθώς με αυτόν τον τρόπο η ίδια γνώση αναπαρίσταται περισσότερες από μια φορές. Η βασική επιδίωξη της διαδικασίας είναι να προκύψει ένας νευροκανόνας για κάθε διακριτή τιμή κάθε ενδιάμεσης μεταβλητής ή μεταβλητής εξόδου του πεδίου.

Για να ξεπεραστεί το πρόβλημα αυτό, το σύνολο εκπαίδευσης του αρχικού νευροκανόνα διαιρείται σε υποσύνολα με τέτοιο τρόπο ώστε κάθε υποσύνολο να περιέχει δείγματα επιτυχίας, που είναι «κοντινά» το ένα με το άλλο σε κάποιο βαθμό. Αρχικά, λοιπόν,

επιλέγεται ένα ζεύγος ελάχιστης εγγύτητας και το αρχικό σύνολο εκπαίδευσης «σπάζει» σε δυο υποσύνολα με τη διαδικασία της διάσπασης πάντοτε να κατευθύνεται από το επιλεγμένο ζεύγος.

Η διαδικασία της διάσπασης ενός μη διαχωρίσιμου συνόλου εκπαίδευσης σε υποσύνολα «κοντινών» μεταξύ τους παραδειγμάτων μοιάζει αρκετά με μεθόδους συσταδοποίησης (clustering). Για να διαπιστωθεί αν τελικά παράγονται λιγότεροι νευρωνικοί συγκριτικά με τη μέθοδο διάσπασης ενός μη διαχωρίσιμου συνόλου εκπαίδευσης που κατευθύνεται από ένα ζεύγος ελάχιστης εγγύτητας, εφαρμόζονται εναλλακτικά μέθοδοι συσταδοποίησης (clustering). Η εφαρμογή των μεθόδων συσταδοποίησης (clustering) θα αφορά την επιλογή προτύπων επιτυχίας καθώς όλα τα πρότυπα αποτυχίας θα εντάσσονται σε κάθε υποσύνολο.

## **8.1 Χρήση Τροποποιημένου Αλγορίθμου K-modes**

Η φιλοσοφία του αλγορίθμου είναι ότι το αρχικό μη διαχωρίσιμο σύνολο δεδομένων διασπάται πάντοτε σε  $K$  υποσύνολα (συστάδες), όπου  $K$  είναι είσοδος στον αλγόριθμο και δίνεται από τον χρήστη. Η αρχικοποίηση των  $K$  modes δεν γίνεται τυχαία αλλά επιλέγονται παραδείγματα τα οποία απέχουν πολύ μεταξύ τους και επομένως είναι πολύ διαφορετικά. Στην συνέχεια προσδιορίζεται η απόσταση Hamming κάθε στοιχείου του συνόλου δεδομένων από το mode κάθε συστάδας και κάθε στοιχείο τοποθετείται στην συστάδα από την οποία απέχει λιγότερο. Τα modes των συστάδων που δημιουργήθηκαν ενημερώνονται και επιλέγονται τα παραδείγματα που απέχουν λιγότερο από τα υπόλοιπα στοιχεία της κάθε συστάδας. Στη συνέχεια, προσδιορίζεται ξανά η απόσταση Hamming κάθε στοιχείου από τα τρέχοντα modes και αν βρεθεί κάποιο στοιχείο να βρίσκεται πιο κοντά στο mode άλλης συστάδας, τοποθετείται στην άλλη συστάδα και ενημερώνονται εκ νέου τα modes των συστάδων. Η διαδικασία επαναλαμβάνεται μέχρις ότου οι συστάδες να σταματήσουν να μεταβάλλονται.

Πιο αναλυτικά, τα βήματα της παραλλαγής του αλγορίθμου K-modes είναι τα ακόλουθα:

- **Βήμα 1.** Επιλέγονται  $k$  αρχικά modes, ένα για κάθε συστάδα. Υπολογίζονται και ταξινομούνται όλες οι αποστάσεις Hamming ανά δύο όλων των προτύπων του συνόλου δεδομένων. Αν  $k = 2$ , επιλέγεται το ζεύγος παραδειγμάτων για το οποίο υπολογίστηκε ότι απέχουν περισσότερο το ένα από το άλλο (ζεύγος ελάχιστης εγγύτητας). Αν  $k > 2$ , τότε επιλέγονται αρχικά τα παραδείγματα του ζεύγους ελάχιστης εγγύτητας και ύστερα επιλέγεται επαναληπτικά το αμέσως επόμενο

παράδειγμα που απέχει περισσότερο από κάποιο από τα ήδη επιλεγμένα modes.

- **Βήμα 2.** Κάθε αντικείμενο τοποθετείται στη συστάδα της οποίας το mode είναι πιο κοντά στο αντικείμενο σύμφωνα με την απόσταση Hamming. Ενημερώνονται τα modes κάθε συστάδας με την επιλογή του παραδείγματος που έχει την μικρότερη μέση απόσταση από τα παραδείγματα που ανήκουν στη συστάδα.
- **Βήμα 3.** Αφού όλα τα αντικείμενα έχουν τοποθετηθεί σε συστάδες, γίνεται ξανά έλεγχος της ανομοιότητας των αντικειμένων ως προς τα τρέχοντα modes. Αν για ένα αντικείμενο βρεθεί ότι βρίσκεται πιο κοντά στο mode μιας άλλης συστάδας από ότι στο mode της τρέχουσας συστάδας, τοποθετείται στην άλλη συστάδα και ενημερώνονται πάλι τα modes των συστάδων.
- **Βήμα 4.** Επανάληψη του βήματος 3 μέχρις ότου κανένα αντικείμενο να μην αλλάζει συστάδες μετά από πλήρη έλεγχο όλου του συνόλου δεδομένων.

## 8.2 Χρήση Δυναμικού Αλγορίθμου K-modes

Αντί, λοιπόν, ένα μη διαχωρίσιμο σύνολο εκπαίδευσης να «σπάζει» πάντα σε  $k$  υποσύνολα όπως περιγράφηκε στην προηγούμενη παράγραφο, ο αριθμός των υποσυνόλων στα οποία θα «σπάσει» το μη διαχωρίσιμο σύνολο θα μπορούσε να υπολογίζεται δυναμικά ανάλογα με τον βαθμό επιτυχίας κάθε προσπάθειας διάσπασής του. Αυτό επιτυγχάνεται δοκιμάζοντας «σπασίματα» με διαφορετικά  $k$  που ανήκουν σε ένα συγκεκριμένο διάστημα τιμών και εφαρμόζοντας τελικά αυτό για το οποίο περισσότερα παραδείγματα άνηκαν σε διαχωρίσιμο (διαχωρίσιμα) υποσύνολο (υποσύνολα).

Επομένως, τα βήματα του δυναμικού αλγορίθμου K-modes τροποποιούνται ως εξής:

- **Βήμα 0.** Για  $k = 2..5$  εκτελούνται τα παρακάτω βήματα δοκιμαστικά και τελικά επιλέγεται και εφαρμόζεται εκείνο το  $k$  για το οποίο περισσότερα παραδείγματα κατανεμήθηκαν σε διαχωρίσιμα υποσύνολα (ήταν πιο επιτυχημένο).
- **Βήμα 1.** Επιλέγονται  $k$  αρχικά modes, ένα για κάθε συστάδα. Υπολογίζονται και ταξινομούνται όλες οι αποστάσεις Hamming ανά δύο όλων των προτύπων του συνόλου δεδομένων. Αν  $k = 2$ , επιλέγεται το ζεύγος παραδειγμάτων για το οποίο υπολογίστηκε ότι απέχουν περισσότερο το ένα από το άλλο (ζεύγος ελάχιστης εγγύτητας). Αν  $k > 2$ , τότε επιλέγονται αρχικά τα παραδείγματα του ζεύγους ελάχιστης εγγύτητας και ύστερα επιλέγεται επαναληπτικά το αμέσως επόμενο παράδειγμα που απέχει περισσότερο από κάποιο από τα ήδη επιλεγμένα modes.

- **Βήμα 2.** Κάθε αντικείμενο τοποθετείται στη συστάδα της οποίας το mode είναι πιο κοντά στο αντικείμενο σύμφωνα με την απόσταση Hamming. Ενημερώνονται τα modes κάθε συστάδας με την επιλογή του παραδείγματος που έχει την μικρότερη μέση απόσταση από τα παραδείγματα που ανήκουν στη συστάδα.
- **Βήμα 3.** Αφού όλα τα αντικείμενα έχουν τοποθετηθεί σε συστάδες, γίνεται ξανά έλεγχος της ανομοιότητας των αντικειμένων ως προς τα τρέχοντα modes. Εάν για ένα αντικείμενο βρεθεί ότι βρίσκεται πιο κοντά στο mode μιας άλλης συστάδας από ότι στο mode της τρέχουσας συστάδας, τοποθετείται στην άλλη συστάδα και ενημερώνονται πάλι τα modes των συστάδων.
- **Βήμα 4.** Επανάληψη του βήματος 3 μέχρις ότου κανένα αντικείμενο να μην αλλάζει συστάδες μετά από πλήρη έλεγχο όλου του συνόλου δεδομένων.

### ***8.3 Χρήση Μεθόδου Εύρεσης Εκτόπων (Outlier Detection)***

Και οι δύο μέθοδοι συσταδοποίησης που περιγράφηκαν παραπάνω μπορούν να συνδυαστούν με μια μέθοδο εύρεσης έκτοπων (outlier detection) που θα εντοπίζει στο αρχικό σύνολο δεδομένων παραδείγματα που «απέχουν» περισσότερο από τα υπόλοιπα. Πιο συγκεκριμένα, υπολογίζεται για κάθε παράδειγμα του συνόλου εκπαίδευσης η μέση «απόστασή» του από τα υπόλοιπα παραδείγματα του συνόλου με τη βοήθεια κάποιας μετρικής απόστασης. Κατόπιν, εντοπίζονται τα παραδείγματα που υπερβαίνουν κατά ένα ανώτατο ποσοστό (κατώφλι) την μέση τιμή των μέσων «αποστάσεων» που βρέθηκαν στο προηγούμενο βήμα. Τα παραδείγματα αυτά τίθενται εκτός συνόλου κατά τη διαδικασία εκπαίδευσης, καθώς ίσως αποτελούν αιτία της μη διαχωρισιμότητας του συνόλου, και αποτελούν εξαιρέσεις των παραγόμενων νευρωνικών του συγκεκριμένου συνόλου, ενώ αποθηκεύονται σε ξεχωριστό αρχείο εξόδου.



# 9

## Πειραματικά Αποτελέσματα

Εκτελέσαμε έναν αριθμό πειραμάτων για να συγκρίνουμε την απόδοση των αλγορίθμων συσταδοποίησης που παρουσιάστηκαν στις ενότητες 8.1 & 8.2. Για τον σκοπό αυτό χρησιμοποιήσαμε σύνολα δεδομένων από τη βιβλιοθήκη **UCI Machine Learning Repository**. Η σύγκριση βασίζεται στον συνολικό αριθμό νευροκανόνων, καθώς όσο λιγότεροι νευροκανόνες παράγονται τόσο καλύτερη είναι η απόδοσή τους όσον αφορά την αποδοτικότητα χώρου και χρόνου στην εξαγωγή συμπερασμάτων.

Σύνολο Δεδομένων	LCP	K-modes				Dynamic K-modes
		K=2	K=3	K=4	K=5	
Post-operation Patients (65 patterns)	20	15	24	24	30	16
Cars (1728 patterns)	152	177	195	185	190	150
Nursery (12960 patterns)	830	730	999	1152	1259	648

Πίνακας 6. Σύγκριση απόδοσης αλγορίθμων συσταδοποίησης

Το πρώτα αποτελέσματα των πειραμάτων μας παρουσιάζονται στον **Πίνακα 6**. Δίνεται ο συνολικός αριθμός των νευροκανόνων που παράγονται από κάθε ένα από τα τρία σύνολα δεδομένων της πρώτης στήλης με τη χρήση των αλγορίθμων συσταδοποίησης που παρουσιάστηκαν για τη διάσπαση ενός μη διαχωρίσιμου συνόλου σε υποσύνολα αλλά και με

τη χρήση της διαδικασίας που βασίζεται σε ζεύγη ελάχιστης «εγγύτητας» (*Least Closeness Pair*).

Από τα παραπάνω αποτελέσματα είναι φανερό ότι δυναμικός αλγόριθμος K-modes, εν γένει, δίνει καλύτερα αποτελέσματα από τις άλλες δυο λογικές «σπασίματος» ενός μη γραμμικού συνόλου δεδομένων σε υποσύνολα. Επιπροσθέτως, ο τροποποιημένος αλγόριθμος K-modes για μικρά  $k$  εμφανίζει παρόμοια σχεδόν, αν όχι καλύτερα, αποτελέσματα συγκριτικά με την μέθοδο διάσπασης που κατευθύνεται από ζεύγη ελάχιστης «εγγύτητας» (*Least Closeness Pair*), όμως, όσο μεγαλώνει ο αριθμός των υποσυνόλων  $k$  στα οποία «σπάζει» το μη διαχωρίσιμο σύνολο τόσο μεγαλώνει και ο αριθμός των παραγόμενων νευρωνικών. Το γεγονός αυτό μπορεί να οφείλεται στην αυξημένη πιθανότητα ύπαρξης λίγων προτύπων επιτυχίας στα υποσύνολα που προκύπτουν.

Σύνολο Δεδομένων	LCP	K-modes				Dynamic K-modes
		K=2	K=3	K=4	K=5	
Post-operation Patients (65 πρότυπα)	20	15/ 5	18/ 5	25/ 5	32/ 5	13/ 5
Cars (1728 πρότυπα)	152	145/ 54	185/ 25	182/ 20	183/ 8	131/ 35
Nursery (12960 πρότυπα)	830	502/ 131	918/ 101	1163/ 100	1276/ 101	648/ 141

**Πίνακας 7. Σύγκριση απόδοσης αλγορίθμων συσταδοποίησης με outlier detection**

Το δεύτερο σύνολο αποτελεσμάτων φαίνεται στον **Πίνακα 7** και αφορά την εφαρμογή των αλγορίθμων συσταδοποίησης που παρουσιάστηκαν για τη διάσπαση ενός μη διαχωρίσιμου συνόλου σε υποσύνολα αφού προηγήθηκε η χρησιμοποίηση της μεθόδου εύρεσης εκτόπων (outlier detection) που αναλύθηκε στην ενότητα 8.3. Δίνεται ο συνολικός αριθμός των νευρωνικών που παράγονται μαζί με τον αριθμό των παραδειγμάτων που εντοπίστηκαν ως έκτοπα (outliers) στα σύνολα δεδομένων της πρώτης στήλης. Η δεύτερη στήλη παραμένει ως είχε στον προηγούμενο πίνακα. Είναι φανερό ότι σημειώνεται μια περαιτέρω μείωση στον αριθμό των παραγόμενων νευρωνικών και για τις δυο λογικές «σπασίματος» έχοντας χρειαστεί να αφαιρέσουμε ένα πλήθος προτύπων που δεν ξεπερνούν το 7-8% του αρχικού συνόλου.

# 10

## *Επίλογος*

### *10.1 Σύνοψη και συμπεράσματα*

Στην εργασία αυτή παρουσιάζεται μια εναλλακτική διαδικασία διάσπασης ενός μη διαχωρίσιμου συνόλου εκπαίδευσης για την παραγωγή τελικών νευροκανόνων. Η υπάρχουσα διαδικασία παρήγαγε νευροκανόνες από μη γραμμικά σύνολα εκπαίδευσης διασπώντας τα με τρόπο επαναληπτικό σε δύο υποσύνολα με βάση την «απόσταση» των προτύπων μέχρις ότου να καταλήξει σε γραμμικά υποσύνολα. Αυτό είχε σαν αποτέλεσμα την παραγωγή συνήθως περισσότερων του ενός νευροκανόνων που αφορούσαν το ίδιο συμπέρασμα. Το γεγονός αυτό δεν είναι επιθυμητό διότι καταλήγει σε πολλαπλή αναπαράσταση της ίδιας γνώσης, μειώνοντας τη φυσικότητα της αναπαράστασης.

Με την παρούσα εργασία διερευνάται η δυνατότητα της διάσπασης ενός μη διαχωρίσιμου συνόλου εκπαίδευσης σε  $k$  υποσύνολα με χρήση μεθόδων συσταδοποίησης (**clustering**). Το  $k$  μπορεί είτε να αποτελεί είσοδο της διαδικασίας και να παραμένει σταθερό κατά τη διάρκεια της εκπαίδευσης του αρχικού συνόλου είτε να υπολογίζεται δυναμικά από ένα συγκεκριμένο εύρος τιμών κάθε φορά που προκύπτει κάποιο μη διαχωρίσιμο σύνολο εκπαίδευσης. Η δεύτερη στρατηγική διάσπασης (**δυναμικός αλγόριθμος k-modes**) φαίνεται να έχει και τα καλύτερα αποτελέσματα, δηλαδή την παραγωγή τελικά λιγότερων νευροκανόνων, συγκριτικά με την πρώτη αλλά και σε σχέση με την προηγούμενη λογική που κατευθυνόταν από ζεύγη προτύπων με την ελάχιστη «εγγύτητα». Αντίθετα, η πρώτη στρατηγική διάσπασης (**τροποποιημένος αλγόριθμος k-modes**) παρουσιάζει για μικρά  $k$  συγκρίσιμα αποτελέσματα με την υπάρχουσα μέθοδο, αλλά ο συνολικός αριθμός παραγόμενων νευροκανόνων αυξάνει γραμμικά για μεγαλύτερα  $k$ .

Επιπλέον, και οι δύο λογικές «σπασίματος», πριν την εφαρμογή τους, μπορούν να συνδυαστούν με μία μέθοδο εύρεσης εκτόπων (**outlier detection**) που αφαιρεί από το αρχικό σύνολο εκπαίδευσης μεμονωμένα παραδείγματα που αποκλίνουν «περισσότερο» από τα υπόλοιπα. Ο εντοπισμός αυτών των προτύπων στηρίζεται στην υπόθεση ότι πρότυπα που βρίσκονται σε μεγαλύτερη «απόσταση» από τα υπόλοιπα στον διανυσματικό χώρο αποτελούν πιθανή αιτία της μη διαχωρισιμότητας ενός συνόλου εκπαίδευσης. Τα πειραματικά αποτελέσματα έδειξαν την εφικτότητα και την αποτελεσματικότητα μιας τέτοιας μεθόδου μειώνοντας ακόμη περισσότερο τον συνολικό αριθμό νευρωνικών που παράγονται αλλά και δεικτοδοτώντας αυτά τα πρότυπα σαν εξαιρέσεις των παραγόμενων νευρωνικών του αρχικού συνόλου εκπαίδευσης.

## **10.2 Μελλοντικές επεκτάσεις**

Παρά τα ενθαρρυντικά αποτελέσματα της μεθόδου, απαιτείται περαιτέρω διερεύνηση ορισμένων σημείων ούτως ώστε η μέθοδος να γίνει αποτελεσματικότερη. Ένα τέτοιο σημείο θα ήταν η εύρεση μιας διαδικασίας για τον υπολογισμό μιας «εκλεπτυσμένης» συνθήκης εκκίνησης (των αρχικών «κέντρων») του αλγορίθμου **k-modes**, ειδικότερα για  $k > 2$ , που θα επέτρεπε στον αλγόριθμο να συγκλίνει σε ένα «καλύτερο» τοπικό ελάχιστο.

Επιπλέον, αρκετό ενδιαφέρον θα είχε η επιλογή ενός «καλύτερου» ευρετικού για τον δυναμικό αλγόριθμο **k-modes** που θα προσδιόριζε πιο αποδοτικά τον αριθμό των υποσυνόλων στα οποία διασπάται ένα μη διαχωρίσιμο σύνολο, ή, ακόμη πιο ριζικά, η χρησιμοποίηση, πάντοτε με την απαιτούμενη προσοχή ούτως ώστε να διατηρούνται τα εγγενή χαρακτηριστικά του αρχικού συνόλου εκπαίδευσης, αλγορίθμων συσταδοποίησης που βασίζονται σε άλλες μεθόδους. Επίσης, μελλοντικής έρευνας χρήζει η διερεύνηση προσεγγίσεων εύρεσης εκτόπων (**outlier detection**) που δεν θα βασίζονται αποκλειστικά στην «απόσταση» των παραδειγμάτων από τη «γειτονιά» τους αλλά και στην «πυκνότητα» των συστάδων που δημιουργούνται.

Τέλος, ένα άλλο σημείο προς διερεύνηση θα ήταν η επιλογή πιο κατάλληλων μετρικών για τον υπολογισμό της «απόστασης» μεταξύ των προτύπων.

# 11

## Βιβλιογραφία

Aamodt, A., & Plaza, E. (1994). Case-based reasoning: foundational issues, methodological variations and system approaches. *Artificial Intelligence Communications*, 7(1), 39–59.

Aha, D., & Daniels, J. J. (Eds.) (1998). *Case-based reasoning integrations: Papers from the AAAI workshop. Technical Report WS-98-15*, Menlo Park, CA: AAAI Press.

Βλαχάβας, Ι., Κεφάλας, Π., Βασιλειάδης, Ν., Κόκκορας, Φ., & Σακελλαρίου, Η. (2005). Τεχνητή Νοημοσύνη (2<sup>η</sup> έκδ.). Θεσσαλονίκη: Εκδόσεις Γαρταγάνη.

Boutsinas, B., & Vrahatis, M. N. (1998). *Nonmonotonic Connectionist Expert Systems*. Proceedings of the 2<sup>nd</sup> IMACS International Conference on Circuits, Systems and Computers, Athens.

Branting, L. K. (1999). *Reasoning with rules and precedents*. Dordrecht: Kluwer Academic Publishers.

Cercone, N., An, A., & Chan, C. (1999). Rule-induction and case-based reasoning: hybrid architectures appear advantageous. *IEEE Transactions on Knowledge and Data Engineering*, 11(1), 164–174.

Ernst, G. W., & Newell, A. (1969). *GPS: A case study in generality and problem solving*. Academic Press.

Freuder, E. (Ed.) (1998). *Multimodal reasoning: Papers from the 1998 AAAI spring symposium*. Technical Report SS-98-04. Menlo Park, CA: AAAI Press.

Fu, L. M. (1994). *Proceedings of the International Symposium on Integrating Knowledge and Neural Heuristics (ISIKNH'94)*. Pensacola, FL.

Fu, L. M., & Fu, L. C. (1990). Mapping rule-based systems into neural architecture. *Knowledge-Based Systems*, 3, 48–56.

Gallant, S. I. (1988). Connectionist expert systems. *Communications of the ACM*, 31(2), 152–169.

Gallant, S. I. (1993). *Neural network learning and expert systems*. Cambridge, MA: MIT Press.

Ghalwash, A. Z. (1998). A recency inference engine for connectionist knowledge bases. *Applied Intelligence*, 9(3), 201–215.

Golding, A. R., & Rosenbloom, P. S. (1996). Improving accuracy by combining rule-based and case-based reasoning. *Artificial Intelligence*, 87(1/2), 215–254.

Gonzalez, A. J., & Dankel, D. D. (1993). *The engineering of knowledge based systems, theory and practice*. Englewood Cliffs, NJ: Prentice Hall.

Hatzilygeroudis, I. (1994). *Integrating rules and neurocomputing for knowledge representation*. Proceedings of the International Symposium on Integrating Knowledge and Neural Heuristics (ISIKNH'94) (pp. 40–46). Pensacola, FL.

Hatzilygeroudis, I., & Prentzas, J. (2000). Neurules: Improving the performance of symbolic rules. *International Journal on Artificial Intelligence Tools*, 9(1), 113–130.

Hatzilygeroudis, I. & Prentzas, J. (2000). Neurules: Integrating Symbolic Rules and Neurocomputing, in Fotiadis D. & Nikolopoulos S. (Eds.). *Advances in Informatics* (pp. 122–133). World Scientific Pub.

Hatzilygeroudis, I. & Prentzas, J. (2000). *Producing Modular Hybrid Rule Bases for Expert Systems*. Proceedings of the 13<sup>th</sup> International FLAIRS Conference (pp. 181–185).

Hatzilygeroudis, I., & Prentzas, J. (2001a). *An efficient hybrid rule-based inference engine with explanation capability*. Proceedings of the 14<sup>th</sup> International FLAIRS Conference (pp. 227–231). Menlo Park, CA: AAAI Press.

Hatzilygeroudis, I., & Prentzas, J. (2001b). Constructing modular hybrid knowledge bases for expert systems. *International Journal on Artificial Intelligence Tools*, 10, 87–105.

I. Hatzilygeroudis and J. Prentzas (2004a) Using a Hybrid Rule-Based Approach in Developing an Intelligent Tutoring System with Knowledge Acquisition and Update Capabilities. *Journal of Expert Systems with Applications*, 26(4), 477-492.

Hatzilygeroudis, I., & Prentzas, J. (2004b). Integrating (rules, neural networks) and cases for knowledge representation and reasoning in expert systems. *Journal of Expert Systems with Applications*, 27(1), 63–75.

Hatzilygeroudis I., & Prentzas J. (2010). Integrated Rule-Based Learning and Inference. *IEEE Transactions on Knowledge and Data Engineering*, 22(11), 1549-1562.

Hilario, M. (1997). *An Overview of Strategies for Neurosymbolic Integration*.

Keller, J. M., & Tahani, H. (1992). Implementation of conjunctive and disjunctive fuzzy logic rules with neural networks. *International Journal of Approximate Reasoning*, 6(2), 221–240.

- Kolodner, J. (1993). *Case-based reasoning*. San Mateo, CA: Morgan Kaufmann Publishers.
- Koton, P. (1988). *Reasoning about evidence in causal explanations*. Proceedings of the AAAI-88. Menlo Park, CA: AAAI Press.
- Leake, D. B. (1995). *Combining rules and cases to learn case adaptation*. Proceedings of the 17th annual conference of the cognitive science society.
- Leake, D. B. (Ed.) (1996). *Case-based reasoning: Experiences, lessons and future directions*. Menlo Park, CA: AAAI Press/MIT Press.
- Letz, R., Bayerl, S., & Bibel, W. (1992). Setheo: A high-performance theorem prover. *Journal of Automated Reasoning*, 8(2), 183–212.
- Λυκοθανάσης, Σ., & Γεωργόπουλος, Ε. (2006). *Νευρωνικά Δίκτυα. Θεμελιώσεις και Εφαρμογές*. Πάτρα: Εκδόσεις Πανεπιστημίου Πατρών.
- Marling, C. R., Petot, G. J., & Sterling, L. S. (1999). Integrating case-based and rule-based reasoning to meet multiple design constraints. *Computational Intelligence*, 15(3), 308–332.
- Medsker, L. R. (1994). *Hybrid Neural Networks and Expert Systems*. Kluwer Academic Publishers, Boston.
- Smith, B. (1982). *Reflection and semantics in a procedural language*. PhD Thesis, MIT.
- Sun, R. & Alexandre, E. (Eds.) (1997). *Connectionist-Symbolic Integration: From Unified to Hybrid Approaches*. Lawrence Erlbaum.
- Sun, R. (1994). *Integrating Rules and Connectionism for Robust Commonsense Reasoning*. Sixth-Generation Computer Technology. John Wiley & Sons.
- Sun, R., & Bookman L. (Eds.) (1992). *The Working Notes of the AAAI Workshop on Integrating Neural and Symbolic Processes: The Cognitive Dimension*. San Jose, California.
- Towell, G., & Shavlik, J. (1993). Extracting refined rules from knowledge based neural networks. *Machine Learning*, 13(1), 71–101.
- Towell, G., & Shavlik J. W. (1994). Knowledge-based artificial neural networks. *Artificial Intelligence*, 70(1/2), 119–165.
- Χατζηλυγερούδης, Ι. (2004). *Αναπαράσταση Γνώσης και Αυτόματος Συλλογισμός*. Πάτρα: Εκδόσεις Πανεπιστημίου Πατρών.
- Χατζηλυγερούδης, Ι., & Κουτσογιάννης, Κ. (2006). *Ευφύης Προγραμματισμός*. Πάτρα: Εκδόσεις Πανεπιστημίου Πατρών.
- Yager R. (1994). Modeling and formulating fuzzy knowledge bases using neural networks. *Neural Networks*, 7(8), 1273–1283.