



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

**Ενσωμάτωση Μεθόδων Αναπαράστασης Γνώσης
και Τεχνικών Μηχανικής Μάθησης
σε Νέες Αρχιτεκτονικές Ταξινόμησης Πληροφοριών**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΗΛΙΑΝΝΑ Σ. ΚΟΛΛΙΑ

Επιβλέπων : Ανδρέας – Γεώργιος Ν. Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

Αθήνα, Απρίλιος 2009



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ

**Ενσωμάτωση Μεθόδων Αναπαράστασης Γνώσης
και Τεχνικών Μηχανικής Μάθησης
σε Νέες Αρχιτεκτονικές Ταξινόμησης Πληροφοριών**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΗΛΙΑΝΝΑ Σ. ΚΟΛΛΙΑ

Επιβλέπων : Ανδρέας – Γεώργιος Ν. Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 27^η Απριλίου 2009

.....
Ανδρέας – Γεώργιος
Σταφυλοπάτης
Καθηγητής Ε.Μ.Π

.....
Παναγιώτης Τσανάκας
Καθηγητής Ε.Μ.Π

.....
Γιώργος Στάμου
Λέκτορας Ε.Μ.Π

Αθήνα, Απρίλιος 2009

.....
Ηλιάννα Σ. Κόλλια

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright © Ηλιάννα Σ. Κόλλια, 2009

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Στη διπλωματική αυτή εργασία παρουσιάζονται μέθοδοι της αιχμής της τεχνολογίας, οι οποίες συνδυάζουν τεχνικές αναπαράστασης γνώσης - εστιάζοντας σε εκφραστικές περιγραφικές λογικές - και τεχνικές μηχανικής μάθησης, δίνοντας έμφαση σε τεχνητά νευρωνικά δίκτυα. Η πλέξη αυτή των τεχνικών γίνεται στο πλαίσιο μιας αρχιτεκτονικής που προσομοιώνει ένα νευρωνικο-συμβολικό κύκλο επεξεργασίας, κυρίως για προβλήματα ταξινόμησης πληροφοριών. Η περιγραφόμενη αρχιτεκτονική αποτελεί τη βάση για ανάπτυξη συστημάτων που έχουν τη δυνατότητα να ενσωματώνουν διαθέσιμες οντολογίες και βάσεις γνώσης και να προσαρμόζουν τη γνώση τους σε προβλήματα του πραγματικού κόσμου, όπως είναι μεταβλητές συνθήκες χρήσης και περιβάλλοντος, διαφορετικοί χρήστες και εννοιολογικό πλαίσιο αλληλεπίδρασης. Στην παρούσα εργασία ο στόχος αυτός επιτυγχάνεται με μεταφορά της γνώσης, μέσω μεθόδων πυρήνα (kernels), στην λειτουργία του αλγορίθμου μηχανικής μάθησης μιας δομής διανυσμάτων υποστήριξης (support vectors) ή μιας μορφής kernel (multilayer) perceptrons. Η προσαρμογή της γνώσης γίνεται στο – υποσυμβολικό - επίπεδο των μεθόδων μηχανικής μάθησης και μπορεί να εξαχθεί, στη συνέχεια, στο υποσύστημα αναπαράστασης γνώσης για εμπλουτισμό της βάσης γνώσης με περιπτώσεις εφαρμογής της στον πραγματικό κόσμο. Ένα πρόβλημα ανάλυσης – ταξινόμησης και κατάτμησης – εικόνων χρησιμοποιείται για την επίδειξη των θεωρητικών αποτελεσμάτων της εργασίας.

Λέξεις κλειδιά

Συμβολική Αναπαράσταση Γνώσης, Περιγραφικές Λογικές, Υποσυμβολικές Τεχνικές Μηχανικής Μάθησης, Τεχνητά Νευρωνικά Δίκτυα, Μάθηση, Προσαρμογή, Νευρωνικο-Συμβολικές Αρχιτεκτονικές, Ανάλυση, Ταξινόμηση, Κατάτμηση Εικόνων.

Abstract

Both symbolic knowledge representation systems and artificial neural networks play a significant role in Artificial Intelligence. A recent trend in the field aims at interweaving these techniques, in order to improve robustness and performance of classification and clustering systems. Translation algorithms from a symbolic to a connectionist representation and vice-versa are employed to provide either a neural implementation of a logic, or a logical characterization of a neural system, or a hybrid system that brings together features from connectionism and symbolic artificial intelligence. In this dissertation thesis, we focus on the latter integration, realised by a neural-symbolic learning cycle for knowledge adaptation. Symbolic knowledge bases are embedded into a connectionist representation, where the knowledge is adapted and enhanced from raw data. This knowledge may in turn be extracted into symbolic form, where it can be further used. We focus on developing connectionist adaptation of ontological knowledge, in particular of tractable languages and rules. In this framework, kernel methods are introduced and used to transfer the formal knowledge to the connectionist - Support Vector Machine, Kernel (Multilayer) Perceptron – where it is appropriately adapted to real life experimental conditions (changing environments, specific context of use, user characteristics). We then show that the described architecture can improve image segment classification within a semantic image segmentation application scenario.

Keywords

Symbolic Knowledge Representation, Description Logics, Sub-symbolic Machine Learning Methods, Artificial Neural Networks, Learning, Adaptation, Neuro-Symbolic Architectures, Image Analysis, Classification, Segmentation.

Ευχαριστίες

Θέλω να ευχαριστήσω τον επιβλέποντα Καθηγητή μου κ. Ανδρέα-Γεώργιο Σταφυλοπάτη που μου εμπιστεύτηκε το θέμα και με βοήθησε όποτε χρειάστηκε στη διάρκεια εκπόνησης της διπλωματικής μου. Επίσης θέλω να ευχαριστήσω τον Λέκτορα κ. Γεώργιο Στάμου, ο οποίος - ως συνεπιβλέπων της εργασίας αυτής - με βοήθησε στην επιλογή ειδικών θεμάτων της και στην κατανόηση πολλών από τις αναφερόμενες έννοιες. Επιπλέον θέλω να ευχαριστήσω τον Υποψήφιο Διδάκτορα του Ε.Μ. Πολυτεχνείου Νικόλαο Σίμου για την βοήθεια που μου παρείχε σε θέματα μηχανών συλλογιστικής, αλλά και για τη γενικότερη υποστήριξή του κατά τη διάρκεια της εκπόνησης της εργασίας μου.

Τέλος, ευχαριστώ την οικογένειά μου, τους γονείς μου Στέφανο και Λούλα, και τον αδελφό μου Δημήτρη, για τη συνεχή ενθάρρυνση και υποστήριξη που μου παρείχαν στις σπουδές μου.

Πίνακας περιεχομένων

1. Εισαγωγή.....	1
2. Αναπαράσταση Γνώσης και Περιγραφικές Λογικές	7
2.1 Περιγραφικές Λογικές – Η Οικογένεια Γλωσσών AL	7
2.1.1 Η βασική περιγραφική λογική AL	8
2.1.2 Περιγραφική λογική ALU	9
2.1.3 Περιγραφική λογική ALE	10
2.1.4 Περιγραφική λογική ALN	10
2.1.5 Περιγραφική λογική ALQ	11
2.1.6 Περιγραφική λογική ALC	11
2.2 Ορολογίες και Ισχυρισμοί.....	12
2.2.1 Ορολογίες.....	12
2.2.2 Ισχυρισμοί.....	12
2.3 Υπηρεσίες Συλλογιστικής.....	13
2.3.1 Υπηρεσίες Σωμάτων Ορολογίας.....	14
2.3.2 Υπηρεσίες σωμάτων Ισχυρισμών	14
2.3.3 Αναγωγή Προβλημάτων σε Απλούστερα	15
2.4 Εκφραστικές Περιγραφικές Λογικές	16
2.4.1 Περιγραφική λογική ALC_R^+	16
2.4.2 Επιπλέον Τέλεστες για Αύξηση της Εκφραστικότητας.....	17
2.5 Σημασιολογία Κλειστού ή Ανοικτού Κόσμου.....	18
2.6 Η Γλώσσα Αναπαράστασης Γνώσης OWL	19
2.6.1 Περιγραφές κλάσεων	20
2.6.2 Περιγραφές Ιδιοτήτων	21
2.6.3 Αξιώματα κλάσεων	22
2.6.4 Αξιώματα Ιδιοτήτων Αντικειμένων	23
2.6.5 Αξιώματα Ιδιοτήτων Τύπων Δεδομένων	23
2.6.6 Αξιώματα Ατόμων	24
2.7 Ασαφής Περιγραφική Λογική f-SHIN.....	25
3. Τεχνικές Μηχανικής Μάθησης.....	27

3.1	Συναρτήσεις και Μηχανές Πυρήνα.....	27
3.1.1	Μέθοδοι Πυρήνα.....	27
3.1.2	Συναρτήσεις Πυρήνα	30
3.1.3	Είδη Πυρήνων	32
3.1.4	Στοιχεία Μεταβολής Πυρήνων	36
3.2	Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)	36
3.2.1	Γραμμικά Διαχωρίσιμα Προβλήματα	37
3.2.2	Μη Γραμμικά Διαχωρίσιμα Προβλήματα	39
3.2.3	Χρήση Συναρτήσεων Πυρήνα	40
3.3	Τεχνητά Νευρωνικά Δίκτυα.....	45
3.3.1	Νευρωνικά Δίκτυα Perceptrons	45
3.3.2	Πολυεπίπεδα Νευρωνικά Δίκτυα.....	45
3.3.3	Αλγόριθμοι Μάθησης Πολυεπίπεδων Perceptrons.....	46
3.3.4	Μάθηση σε Νευρωνικά Δίκτυα Perceptrons με Πυρήνα.....	50
3.3.5	Προσαρμογή των Multilayer Perceptrons.....	52
4.	Μεταφορά Συμβολικής Γνώσης σε Συστήματα Μηχανικής Μάθησης.....	59
4.1	Ορισμός πυρήνα για την περιγραφική γλώσσα ALC	59
4.1.1	Κανονική Μορφή ALC.....	61
4.1.2	Ένας πυρήνας για την ALC.....	61
4.2	Πυρήνας για τη Γλώσσα OWL	66
4.2.1	Ορισμός Πυρήνα.....	66
4.2.2	Πυρήνες Περιγραφικών Λογικών και το Πρόβλημα Ταξινόμησης.....	69
4.3	Ένας Άλλος Πυρήνας για τη Γλώσσα OWL.....	70
4.3.1	Επίπεδο Ταυτοτικού Πυρήνα.....	70
4.3.2	Πυρήνες στο Επίπεδο Κλάσεων	71
4.3.3	Πυρήνες στο Επίπεδο των Ιδιοτήτων Τύπων Δεδομένων	72
4.3.4	Πυρήνες στο Επίπεδο των Ιδιοτήτων Αντικειμένων	73
4.3.5	Συνολικός Πυρήνας από τα 4 επίπεδα	74
5.	Προσαρμογή της Γνώσης σε Πραγματικές Συνθήκες	75
5.1	Νευρωνικο-Συμβολικός Κύκλος Μηχανικής Μάθησης.....	75
5.2	Η Αρχιτεκτονική του Νευρωνικο-Συμβολικού Συστήματος.....	76
5.2.1	Περιγραφή της Αρχιτεκτονικής	76
5.2.2	Το Υποσύστημα της Τυπικής Αναπαράστασης Γνώσης	79
5.2.3	Η Μηχανή Συλλογιστικής.....	80

5.3 Ο Μηχανισμός Προσαρμογής της Γνώσης.....	82
5.3.1 Η Φάση Λειτουργίας του Συστήματος	82
5.3.2 Προσαρμογή του Υποσυμβολικού Τμήματος της Αρχιτεκτονικής.....	83
5.3.3 Προσαρμογή της Βάσης Γνώσης.....	85
6. Εφαρμογή Νευρωνικο-Συμβολικών Μεθόδων στην Ανάλυση Εικόνων	89
6.1 Σημασιολογική Ανάλυση Εικόνων	89
6.2 Κατάτμηση και Ταξινόμηση Εικόνων	91
6.3 Αναπαράσταση Γνώσης για την Ταξινόμηση Εικόνων	92
6.4 Νευρωνικο-Συμβολικές Μέθοδοι για Ταξινόμηση Εικόνων.....	97
6.4.1 Προσαρμογή Νευρωνικού Δικτύου από Εξαγωγή Συμβολικής Γνώσης.....	97
6.4.2 Προσαρμογή Συμβολικής Γνώσης από Τεχνικές Μηχανικής Μάθησης - Νευρωνικά Δίκτυα	102
7. Συμπεράσματα και Μελλοντικές Επεκτάσεις.....	106
8. Βιβλιογραφία	108

Κατάλογος Πινάκων

Πίνακας 2.1 : Περιγραφές OWL κλάσεων.....	21
Πίνακας 2.2 : Αξιώματα OWL κλάσεων.....	22
Πίνακας 2.3 : Αξιώματα Ιδιοτήτων Αντικειμένων.....	23
Πίνακας 2.4 : Αξιώματα Ιδιοτήτων Τύπων Δεδομένων.....	24
Πίνακας 2.5 : Αξιώματα Ατόμων.....	24
Πίνακας 6.1 : Ένα κομμάτι του σώματος ορολογίας.....	96
Πίνακας 6.2 : Μάθηση και Γενίκευση του νευρωνικού δικτύου.....	100
Πίνακας 6.3 : Το σώμα ορολογίας για την προσαρμογή ενός νευρωνικού δικτύου.....	101
Πίνακας 6.4 : Απόδοση του Νευρωνικού Ταξινομητή μετά την Προσαρμογής.....	102
Πίνακας 6.5 : Απόδοση του Ταξινομητή μετά την Προσαρμογή της Συμβολικής Γνώσης.....	104

Κατάλογος Σχημάτων

Σχήμα 3.1 : Η αρχιτεκτονική ενός SVM.....	44
Σχήμα 5.1 : Ο νευρωνικο-συμβολικός κύκλος μηχανικής μάθησης.....	75
Σχήμα 5.2 : Η Αρχιτεκτονική του Νευρωνικο-Συμβολικού Συστήματος.....	77
Σχήμα 6.1 : Σημασιολογική ανάλυση και δεικτοδότηση εικόνων.....	91
Σχήμα 6.2 : Αποτελέσματα σημασιολογικής κατάτμησης.....	96
Σχήμα 6.3 : Σημασιολογική προσαρμογή νευρωνικού ταξινομητή για κατάτμηση εικόνων.....	98

1. Εισαγωγή

Τόσο τα συστήματα συμβολικής αναπαράστασης γνώσης, όσο και τα τεχνητά νευρωνικά δίκτυα έχουν ένα ιδιαίτερα σημαντικό ρόλο στο επιστημονικό πεδίο της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης. Μια σύγχρονη τάση στο πεδίο είναι ο συνδυασμός των τεχνικών αυτών, με στόχο τη βελτίωση της αποτελεσματικότητας και της αποδοτικότητας των μεθόδων, ιδίως σε προβλήματα κατηγοριοποίησης και ταξινόμησης.

Η παρούσα εργασία περιγράφει την τάση αυτή, εμβαθύνοντας τόσο σε συστήματα οντολογικής αναπαράστασης της γνώσης, όσο και σε τεχνικές τεχνητών νευρωνικών δικτύων, δείχνοντας ότι οι τεχνικές αυτές μπορούν να προσαρμόσουν την γνώση σε συνθήκες του πραγματικού κόσμου, που ποικίλλουν και δεν μπορούν να περιγραφούν πλήρως από αυτές που εξαρχής ενσωματώνονται στις αναπαραστάσεις της γνώσης για τα ανωτέρω προβλήματα. Τέλος περιγράφεται και μια εφαρμογή των ανωτέρω για κατηγοριοποίηση εικόνων σε ένα σενάριο ανάλυσης πολυμεσικών πληροφοριών.

Ειδικότερα:

Τα ευφυή υπολογιστικά συστήματα που βασίζονται σε συμβολική επεξεργασία της γνώσης διαφέρουν σημαντικά από τα συστήματα υποσυμβολικής επεξεργασίας, όπως είναι τα τεχνητά νευρωνικά δίκτυα. Παρόλα αυτά και τα δύο αποτελούν τυπικές προσεγγίσεις της τεχνητής νοημοσύνης και είναι ιδιαίτερα επιθυμητό να μπορέσει να επιτευχθεί συνδυασμός της ευστάθειας των τεχνητών νευρωνικών δικτύων, π.χ., σε συνθήκες θορύβου, και της δυνατότητας μάθησης από παραδείγματα που διαθέτουν, με την εκφραστικότητα της συμβολικής αναπαράστασης της γνώσης. Αυτή είναι η αιτία που έχει διεθνώς αναγνωριστεί η ανάγκη έρευνας για σύνδεση των τεχνικών μηχανικής μάθησης και συμβολικής αναπαράστασης της γνώσης στον κλαδο της τεχνητής νοημοσύνης ([41],[42],[24]).

Ο όγκος των υβριδικών πληροφοριών, δηλαδή πληροφοριών που περιέχουν συμβολικά, αλλά και στατιστικά στοιχεία, όπως επίσης και θόρυβο, συνεχώς αυξάνεται, σε πολλές και διαφορετικές περιοχές, όπως στην βιοπληροφορική, στην επικοινωνία ανθρώπου μηχανής, στις ψηφιακές βιβλιοθήκες, στην ανάλυση και διασύνδεση πληροφοριών κειμένου, αλλά και πολυμέσων, στον παγκόσμιο ιστό. Ως αποτέλεσμα της αύξησης αυτής, η νευρωνική (υποσυμβολική) – συμβολική μάθηση αποκτά μεγαλύτερη πρακτική σημασία.

Όμως, παρόλη την πρόοδο που έχει επιτευχθεί στην περιοχή αυτή, πρέπει να τονιστεί ότι η σύνδεση των δύο τεχνολογιών δεν είναι εύκολη εργασία [44]. Η ενσωμάτωση θεωρίας (προϋπάρχουσας γνώσης) και δεδομένων (μάθησης από παραδείγματα) σε τεχνητά νευρωνικά δίκτυα έχει δείχτει να οδηγεί σε δίκτυα που είναι πιο αποτελεσματικά από ότι μόνο συμβολικές ή μόνο υποσυμβολικές μηχανές, ειδικά όταν τα δεδομένα είναι θορυβώδη [60], [45].

Τυπικά, οι αλγόριθμοι μετατροπής από συμβολική αναπαράσταση γνώσης σε αρχιτεκτονικές τεχνητών νευρωνικών δικτύων, και αντίστροφα, στοχεύουν στο να δημιουργήσουν είτε μια νευρωνική υλοποίηση μιας λογικής, είτε ένα λογικό χαρακτηρισμό ενός νευρωνικού συστήματος, ή ένα υβριδικό σύστημα, το οποίο περιλαμβάνει στοιχεία τόσο μηχανικής μάθησης, όσο και συμβολικής τεχνητής νοημοσύνης. Εντούτοις, ενώ η αναπαράσταση συμβολικής γνώσης είναι αναδρομική και καλά ορισμένη, τα νευρωνικά δίκτυα κωδικοποιούν τη γνώση μέσω των βαρών των συνδέσεων τους, όπως αυτά προκύπτουν από τη διαδικασία της μάθησης από παραδείγματα (συνήθως διανύσματα χαρακτηριστικών των δεδομένων) και της γενίκευσης (generalisation) [30,31]. Δίκτυα που χρησιμοποιούν ειδικές συναρτήσεις σε σημασιολογικούς χώρους είναι ευκολότερο να ελεγχθούν και να αναπαρασταθούν με λογικούς κανόνες με βάση την ομοιότητα [34], [40] όπως ασαφείς κανόνες (fuzzy rules).

Ενώ σημαντική θεωρητική πρόοδος έχει γίνει όσον αφορά στην αναπαράσταση γνώσης και στη συλλογιστική (reasoning) , αλλά και σε απευθείας επεξεργασία συμβολικής και δομημένης πληροφορίας με χρήση τεχνητών νευρωνικών δικτύων, η ολοκλήρωση

νευρωνικών υπολογισμών και εκφραστικών λογικών είναι ακόμα στα αρχικά στάδια μεθοδολογικής ανάπτυξης. Η προσαρμογή συμβολικής οντολογικής γνώσης σε πραγματικά δεδομένα αποτελεί ένα ιδιαίτερα σημαντικό πεδίο για την περαιτέρω ανάπτυξη νευρο-συμβολικών συστημάτων, λαμβάνοντας υπόψη και τα λογικά χαρακτηριστικά των τυπικών γλωσσών αναπαράστασης οντολογιών.

Από την πρωτοποριακή εργασία των McCulloch και Pitts [32], ένας σημαντικός αριθμός από συστήματα αναπτύχθηκε στις δεκαετίες του 1980 και του 1990, περιλαμβάνοντας τα συστήματα των Towell και Shavlik's (KBANN) [46], τις εργασίες των Pinkas [47], Hölldobler [49], και d'Avila Garcez et al. [45], [48]. Αυτά τα συστήματα, όμως, αναπτύχθηκαν για την μελέτη γενικών κανόνων, και γενικά δεν είναι κατάλληλα για εφαρμογή σε πραγματικά δεδομένα και σενάρια εφαρμογών που ξεπερνούν την προτασιακή λογική. Παρόλα αυτά, οι μελέτες αυτές αποτελούν τη βάση για την περαιτέρω ανάπτυξη εργαλείων και έρευνας στο πεδίο. Εδώ εντάσσονται και τεχνικές για την εξαγωγή λογικών κανόνων από τεχνητά νευρωνικά δίκτυα και, γενικότερα, από συστήματα μηχανικής μάθησης. Σχετικές εργασίες περιλαμβάνουν την ολοκλήρωση νευρωνικών-συμβολικών συστημάτων μάθησης και συλλογιστικής [43], [49].

Μελέτες πάνω στην νευρωνική επεξεργασία εκφραστικών λογικών δείχνουν ότι οι οντολογικές γλώσσες OWL and OWL1.1 [3], [6] μπορούν να αποτελέσουν το εργαλείο για να έλθουν τα ερευνητικά αποτελέσματα κοντά σε πρακτικές εφαρμογές. Επίσης η ανάπτυξη νέων φορμαλισμών αναπαράστασης γνώσης, μηχανών συλλογιστικής, εργαλείων σημασιολογικής ερμηνείας και διαχείρισης εξαιρετικά εκφραστικών Περιγραφικών Λογικών (Description Logics, DL) και αποτελεσματικών υλοποιήσεών τους (DL-Lite, EL++, DLP), αλλά και πλατφορμών μηχανών συλλογιστικής, όπως το σύστημα Protégé [11], το σύστημα KAON2 του Πανεπιστημίου της Καρλσρούης [21], το σύστημα FiRE του Ε.Μ. Πολυτεχνείου [22], [23], το σύστημα ONTOSEARCH2 του Πανεπιστημίου του Αμπερντίν [18], [20] και το σύστημα NeOn (<http://www.neon-toolkit.org/>).

Τεχνικές που περιλαμβάνουν νευρωνικές και συμβολικές μεθόδους μπορούν επίσης να αντιμετωπίσουν θέματα αβεβαιότητας . Μπορούν να χειριστούν ατελείς εισόδους και να δημιουργήσουν εξόδους που να εμπεριέχουν αβεβαιότητα. Μπορούν να συνδυαστούν με ασαφείς οντολογίες [9], [10], [12-14], [17], [19].

Η παρούσα διπλωματική εργασία αποτελείται από την Εισαγωγή, πέντε Κεφάλαια, και τα Συμπεράσματα.

Το Κεφάλαιο 2 κάνει μια εισαγωγή στην Συμβολική Αναπαράσταση Γνώσης, δίνοντας έμφαση στις Περιγραφικές Λογικές, που αποτελούν την βάση για τις τεχνολογίες που εξετάζονται στην παρούσα εργασία.

Το Κεφάλαιο 3 αναφέρεται στις τεχνικές Μηχανικής Μάθησης, περιγράφοντας αναλυτικά: i) τις μεθόδους Πυρήνα (Kernel Methods), τις ιδιότητές τους και τις Μηχανές Πυρήνα και Διανυσμάτων Υποστήριξης (Support Vector Machines, SVM), ii) τα τεχνητά νευρωνικά δίκτυα Perceptrons και Multilayer Perceptrons, τις μορφές τους που περιλαμβάνουν συναρτήσεις πυρήνα και τους αλγορίθμους μάθησης (learning) και προσαρμογής (adaptation) τους.

Το Κεφάλαιο 4 περιγράφει την αιχμή της τεχνολογίας που αφορά σε μεθόδους μεταφοράς συμβολικής αναπαράστασης γνώσης στις αρχιτεκτονικές μηχανικής μάθησης που περιγράφηκαν στο Κεφάλαιο 3, δηλαδή στις μηχανές SVM, Kernel (Multilayer) Perceptrons, επικεντρώνοντας σε μια κατηγορία από αυτές [38], την οποία επεξεργαζόμαστε στο πέμπτο Κεφάλαιο.

Το Κεφάλαιο 5 περιγράφει μια Αρχιτεκτονική για την Προσαρμογή της Γνώσης που αναπαριστάται με τις μεθόδους του τέταρτου Κεφαλαίου σε πραγματικές συνθήκες και εννοιολογικά πλαίσια (contexts), μέσω των αρχιτεκτονικών μηχανικής μάθησης και υποσυμβολικής επεξεργασίας που περιγράφηκαν στο τρίτο Κεφάλαιο.

Το Κεφάλαιο 6 περιγράφει μια εφαρμογή των ανωτέρω σε ένα πρόβλημα ανάλυσης και αναζήτησης εικόνων, όπου το νευρωνικό σύστημα και το σύστημα αναπαράστασης γνώσης και συλλογιστικής συνδυάζονται για να πετύχουν καλύτερη απόδοση ενός πολυμεσικού πλαισίου κατηγοριοποίησης (classification) και κατάτμησης (segmentation) εικόνων.

Συμπεράσματα και προτάσεις για μελλοντική έρευνα δίδονται τελικά στο Κεφάλαιο 7 της παρούσας εργασίας.

Στο Κεφάλαιο 8 παρατίθεται η βιβλιογραφία της παρούσας εργασίας.

2. Αναπαράσταση Γνώσης και Περιγραφικές Λογικές

Στο παρόν Κεφάλαιο γίνεται μια εκτενής εισαγωγή σε γλώσσες αναπαράστασης γνώσης (knowledge representation languages), και συγκεκριμένα στις Περιγραφικές Λογικές (Description Logics), οι οποίες αποτελούν τη βάση για την ανάπτυξη των ευφών συστημάτων που παρουσιάζονται στην εργασία αυτή. Γίνεται ανάλυση των γλωσσών περιγραφικής λογικής, που αποτελούν το μαθηματικό υπόβαθρο για σύγχρονες γλώσσες του Παγκόσμιου και του Σημασιολογικού Ιστού (Semantic Web), όπως η OWL, περιγράφοντας τη σύνταξή τους, τη σημασιολογία τους και τις υπηρεσίες συλλογιστικής που μας παρέχουν.

2.1 Περιγραφικές Λογικές – Η Οικογένεια Γλωσσών AL

Οι Περιγραφικές Λογικές [1-2,4-5,15] είναι μια οικογένεια γλωσσών αναπαράστασης γνώσης, βασισμένων στη λογική, που έχουν σχεδιαστεί για την καταγραφή της γνώσης αλλά και για τη διενέργεια εργασιών συλλογιστικής πάνω σε αυτή με ένα δομημένο και κατανοητό τρόπο. Βασίζονται σε μια ευρύτερη οικογένεια γλωσσών αναπαράστασης οι οποίες ονομάζονται γλώσσες περιγραφής (description languages).

Το αλφάβητο των περιγραφικών λογικών αποτελείται από ένα σύνολο ατομικών εννοιών (atomic concepts) $\mathbf{C}$, από ένα σύνολο ατομικών ρόλων (atomic roles) ή αλλιώς σχέσεων (relations) $\mathbf{R}$ και από ένα σύνολο ατόμων (individuals) $\mathbf{I}$.

Οι περιγραφικές λογικές μας προσφέρουν ένα σύνολο κατασκευαστών εννοιών (concept constructors) οι οποίοι επενεργούν πάνω σε έννοιες με σκοπό τη δημιουργία περίπλοκων εννοιών.

Περιγραφές εννοιών (concept descriptions) ή αλλιώς περίπλοκες ή σύνθετες έννοιες (complex concepts) μπορούμε να δημιουργήσουμε από τις πρωτογενείς έννοιες σε συνδυασμό με τους κατασκευαστές εννοιών των περιγραφικών λογικών.

Συνήθως χρησιμοποιούμε τα γράμματα A, B για να αναπαραστήσουμε ατομικές έννοιες, τα γράμματα C, D για να αναπαραστήσουμε σύνθετες έννοιες, τα γράμματα R, S για να αναπαραστήσουμε ρόλους και τα γράμματα a,b για να αναπαραστήσουμε άτομα.

2.1.1 Η βασική περιγραφική λογική AL

Οι περιγραφές εννοιών στην γλώσσα AL σχηματίζονται σύμφωνα με τον ακόλουθο συντακτικό κανόνα:

$$\begin{array}{ll}
 C, D \rightarrow A \mid & \text{(ατομική έννοια)} \\
 \top \mid & \text{(καθολική έννοια (universal concept) } \top \text{)} \\
 \perp \mid & \text{(κενή έννοια (bottom concept) } \perp \text{)} \\
 \neg A \mid & \text{(άρνηση της ατομικής έννοιας)} \\
 C \sqcap D \mid & \text{(τομή των εννοιών C και D)} \\
 \forall R.C \mid & \text{(περιορισμός τιμής (value restriction) ή αλλιώς καθολικός} \\
 & \text{περιορισμός (universal restriction))} \\
 \exists R.\top \mid & \text{(περιορισμένος υπαρξιακός περιορισμός (limited existential} \\
 & \text{restriction)}
 \end{array}
 \tag{2.1}$$

Θα πρέπει να σημειωθεί ότι στην AL η άρνηση μπορεί να εφαρμοστεί μόνο μπροστά από ατομικές έννοιες και επιτρέπεται μόνο η καθολική έννοια στο πλαίσιο ενός περιορισμένου υπαρξιακού περιορισμού σε ένα ρόλο.

Για να ορίσουμε τυπικά τη σημασιολογία των AL – εννοιών, θεωρούμε ερμηνείες I που αποτελούνται από ένα μη κενό σύνολο Δ^I που ονομάζεται χώρος ερμηνείας (domain of the interpretation) και μια συνάρτηση ερμηνείας (interpretation function) που αποδίδει σε κάθε ατομική έννοια A ένα υποσύνολο A^I του Δ^I , $A^I \subseteq \Delta^I$ και σε κάθε ατομικό ρόλο ένα υποσύνολο R^I του $\Delta^I \times \Delta^I$, $R^I \subseteq \Delta^I \times \Delta^I$.

Η συνάρτηση ερμηνείας επεκτείνεται για να δώσει ερμηνεία σε περιγραφές εννοιών από τους ακόλουθους ορισμούς :

$$\begin{aligned}
\top^I &= \Delta^I \\
\perp^I &= \emptyset \\
(\neg A)^I &= \Delta^I \setminus A^I \\
(C \sqcap D)^I &= C^I \cap D^I \\
(\forall R.C)^I &= \{a \in \Delta^I \mid \forall b \in \Delta^I. (a,b) \in R^I \rightarrow b \in C^I\} \\
(\exists R.\top)^I &= \{a \in \Delta^I \mid \exists b \in \Delta^I. (a,b) \in R^I\}
\end{aligned} \tag{2.2}$$

Προκειμένου να πάρουμε πιο εκφραστικές γλώσσες προσθέτουμε επιπλέον κατασκευαστές στη γλώσσα AL .

2.1.2 Περιγραφική λογική ALU

Η γλώσσα αυτή παρέχει τους κατασκευαστές της AL και επιπλέον τον κατασκευαστή της ένωσης (ο οποίος συμβολίζεται με το γράμμα U) με σύνταξη $C \sqcup D$ και με ερμηνεία

$$(C \sqcup D)^I = C^I \cup D^I \tag{2.3}$$

2.1.3 Περιγραφική λογική ALE

Η γλώσσα αυτή παρέχει τους κατασκευαστές της *AL* και επιπλέον τον πλήρη υπαρξιακό περιορισμό (που είναι επέκταση του περιορισμένου υπαρξιακού περιορισμού) και συμβολίζεται με το γράμμα *E* με σύνταξη $\exists R.C$ και με ερμηνεία

$$(\exists R.C)^I = \{a \in \Delta^I \mid \exists b \in \Delta^I. (a,b) \in R^I \text{ και } b \in C^I\} \quad (2.4)$$

2.1.4 Περιγραφική λογική ALN

Η γλώσσα αυτή παρέχει τους κατασκευαστές της *AL* και επιπλέον τον κατασκευαστή περιορισμού πληθυκότητας (number restriction) που συμβολίζεται με το γράμμα *N* (και αποτελείται από δύο επιμέρους κατασκευαστές),

- Τον κατασκευαστή έννοιας το-πολύ (at-most) με σύνταξη $\leq nR$ και με σημασιολογία

$$(\leq nR)^I = \{a \in \Delta^I \mid \#\{b \mid (a,b) \in R^I\} \leq n\} \quad (2.5)$$

- Τον κατασκευαστή έννοιας το-λιγότερο (at-least) με σύνταξη $\geq nR$ και σημασιολογία

$$(\geq nR)^I = \{a \in \Delta^I \mid \#\{b \mid (a,b) \in R^I\} \geq n\} \quad (2.6)$$

όπου n είναι φυσικός αριθμός και με “#” δηλώνουμε τον πληθάριθμο (cardinality) του συνόλου που ακολουθεί.

Σημειώνεται ότι στην περίπτωση που επιτρέπουμε μόνο τιμή πληθυκότητας 1, ο κατασκευαστής ονομάζεται συναρτησιακός περιορισμός πληθυκότητας (functional number restriction) και η ύπαρξή του συμβολίζεται με το γράμμα *F*.

2.1.5 Περιγραφική λογική ALQ

Η γλώσσα αυτή παρέχει τους κατασκευαστές της AL και επιπλέον τον προσοντούχο περιορισμό πληθυκότητας (qualified number restriction) που συμβολίζεται με το γράμμα Q και αποτελείται από δύο επιμέρους κατασκευαστές,

- Τον κατασκευαστή το-πολύ με σύνταξη $\leq nR.C$ και με σημασιολογία

$$(\leq nR.C)^I = \{a \in \Delta^I \mid \#\{b \mid (a,b) \in R^I \text{ και } b \in C^I\} \leq n\} \quad (2.7)$$

- Τον κατασκευαστή το-λιγότερο με σύνταξη $\geq nR.C$ και με σημασιολογία

$$(\geq nR.C)^I = \{a \in \Delta^I \mid \#\{b \mid (a,b) \in R^I \text{ και } b \in C^I\} \geq n\} \quad (2.8)$$

όπου n φυσικός αριθμός και με “#” δηλώνουμε τον πληθάριθμο(cardinality) του συνόλου που ακολουθεί.

Επειδή ο κατασκευαστής Q (προσοντούχος περιορισμός πληθυκότητας) έχει τέτοια εκφραστική δυνατότητα που μπορεί να περιγράψει τον πλήρη υπαρξιακό περιορισμό, γράφουμε απλώς ALQ για αυτήν την γλώσσα, αλλά ουσιαστικά εννοούμε $ALEQ$.

2.1.6 Περιγραφική λογική ALC

Η γλώσσα αυτή παρέχει τους κατασκευαστές της AL και επιπλέον επεκτείνει τον κατασκευαστή της άρνησης επιτρέποντάς του να μπαίνει μπροστά και από περίπλοκες έννοιες με σύνταξη $\neg C$ και με ερμηνεία $(\neg C)^I = \Delta^I \setminus C^I$.

Λόγω των κανόνων DeMorgan η γλώσσα ALC μας δίνει τη δυνατότητα περιγραφής των κατασκευαστών ένωσης και πλήρη υπαρξιακού περιορισμού. Με άλλα λόγια, όποτε γράφουμε ALC θα εννοούμε $ALUEC$.

2.2 Ορολογίες και Ισχυρισμοί

2.2.1 Ορολογίες

Στη συνέχεια θα αναφερθούμε στα αξιώματα ορολογίας, τα οποία μας δίνουν τη δυνατότητα να αποδίδουμε ονόματα στις σύνθετες έννοιες που θέλουμε να περιγράψουμε και να περιγράφουμε σχέσεις ανάμεσα σε αυτές. Υπάρχουν δύο κατηγορίες αξιωμάτων ορολογίας

- τα αξιώματα υπαγωγής με σύνταξη $C \sqsubseteq D$ και τα οποία διαισθητικά δηλώνουν ότι μια έννοια (D) είναι πιο γενική από μια άλλη (C) ή αλλιώς ότι μια έννοια (C) είναι υπο-έννοια μιας άλλης (D). Λέμε ότι μια ερμηνεία I ικανοποιεί ένα αξίωμα υπαγωγής $C \sqsubseteq D$ αν $C^I \subseteq D^I$.
- τα αξιώματα ισοδυναμίας με σύνταξη $C \equiv D$ τα οποία διαισθητικά δηλώνουν ότι δύο έννοιες είναι ταυτόσημες. Λέμε ότι μια ερμηνεία I ικανοποιεί ένα αξίωμα ισοδυναμίας $C \equiv D$ αν $C^I = D^I$.

Ένα σύνολο από αξιώματα υπαγωγής ή ισοδυναμίας αποτελούν το σώμα ορολογίας (TBox – Terminological Box) ή απλώς μια ορολογία (terminology), η οποία συμβολίζεται με το γράμμα T .

Λέμε ότι μια ερμηνεία I ικανοποιεί ένα σώμα ισχυρισμών T , αν ικανοποιεί όλα τα αξιώματα υπαγωγής και ισοδυναμίας που υπάρχουν στο T . Τότε λέμε ότι η I είναι μοντέλο (model) του T .

2.2.2 Ισχυρισμοί

Οι περιγραφικές λογικές εκτός από τη δυνατότητα ορισμού σχέσεων μεταξύ εννοιών, μας δίνουν επίσης τη δυνατότητα να κάνουμε υποθέσεις όσον αφορά στα άτομα του κόσμου

που μοντελοποιούμε, καθορίζοντας σχέσεις στιγμιοτύπου ανάμεσα σε ένα άτομο (ζευγάρι ατόμων) και μια έννοια (ρόλο), τα οποία ονομάζονται ισχυρισμοί (assertions).

Υπάρχουν δύο είδη ισχυρισμών

- οι ισχυρισμοί εννοιών (concept assertions) με σύνταξη $a:C$ ή $C(a)$ όπου a ένα άτομο του κόσμου που μοντελοποιούμε και C μια έννοια. Λέμε ότι μια ερμηνεία I ικανοποιεί έναν ισχυρισμό $a:C$ αν $a^I \in C^I$.
- Οι ισχυρισμοί ρόλων (role assertions) με σύνταξη $(a,b):R$ ή $R(a,b)$, όπου a,b άτομα του κόσμου που μοντελοποιούμε και R ρόλος. Λέμε ότι μια ερμηνεία I ικανοποιεί έναν ισχυρισμό $(a,b):R$ αν $(a^I, b^I) \in R^I$.

Στα παραπάνω έχουμε θεωρήσει την επέκταση της συνάρτησης ερμηνείας που ορίσαμε στην αρχή, η οποία επεκτείνεται ώστε να αντιστοιχίζει ένα άτομο a σε ένα αντικείμενο a^I του Δ^I .

Το σύνολο των ισχυρισμών αποτελεί το σώμα ισχυρισμών (ABox – Assertional Box), το οποίο συμβολίζεται με A . Έτσι λοιπόν μια βάση γνώσης (knowledge base) K ορίζεται ως ένα ζευγάρι ενός TBox T και ενός ABox A , δηλαδή $K = \langle T, A \rangle$.

Λέμε ότι μια ερμηνεία I ικανοποιεί ένα σώμα ισχυρισμών A , αν ικανοποιεί όλους τους ισχυρισμούς που περιλαμβάνονται στο A . Επίσης λέμε ότι μια ερμηνεία I ικανοποιεί ένα σώμα ισχυρισμών A με βάση το σώμα ορολογίας T , αν η I είναι μοντέλο του A και ταυτόχρονα είναι και μοντέλο του T .

2.3 Υπηρεσίες Συλλογιστικής

Παραπάνω παρουσιάσαμε τον τρόπο που χρησιμοποιούμε τα σώματα ορολογίας και ισχυρισμών των περιγραφικών λογικών για τη δημιουργία βάσεων γνώσης. Στη συνέχεια

θα παρουσιάσουμε τις υπηρεσίες εξαγωγής συμπερασμάτων (inference services) που μας παρέχουν οι περιγραφικές λογικές.

2.3.1 Υπηρεσίες Σωμάτων Ορολογίας

Εστω ένα TBox T . Ορίζουμε τα εξής:

- **Ικανοποιησιμότητα (satisfiability):** Η έννοια C είναι ικανοποιήσιμη (satisfiable) με βάση το T , αν υπάρχει μοντέλο I του T τέτοιο, ώστε $C^I \neq \emptyset$. Αντίστοιχα ορίζεται η έννοια της μη ικανοποιησιμότητας.
- **Υπαγωγή (subsumption):** Η έννοια C υπάγεται στην έννοια D (subsumed by) με βάση το T , αν $C^I \subseteq D^I$ για κάθε μοντέλο I του T . Σε αυτήν την περίπτωση γράφουμε $T \models C \sqsubseteq D$.
- **Ισοδυναμία (equivalence):** Η έννοια C είναι ισοδύναμη με την έννοια D με βάση το T , αν $C^I = D^I$, για κάθε μοντέλο I του T . Σε αυτήν την περίπτωση γράφουμε $T \models C \equiv D$.
- **Ξένες Έννοιες (disjointness):** Η έννοια C είναι ξένη με την έννοια D (disjoint with) με βάση το T , αν $C^I \cap D^I = \emptyset$ για κάθε μοντέλο I του T .

2.3.2 Υπηρεσίες σωμάτων Ισχυρισμών

Εστω ένα ABox A και ένα TBox T . Ορίζουμε τα εξής:

- **Συνέπεια (consistency):** Το A είναι συνεπές (consistent) με βάση το T , αν υπάρχει μοντέλο του T το οποίο είναι και μοντέλο του A .

- **Συνεπαγωγή (entailment):** Το A συνεπάγεται (entails) έναν ισχυρισμό ϕ με βάση το T , αν κάθε μοντέλο του A και του T ικανοποιεί τον ισχυρισμό. Σε αυτήν την περίπτωση γράφουμε $T, A \models \phi$.

2.3.3 Αναγωγή Προβλημάτων σε Απλούστερα

Όπως βλέπουμε από τα παραπάνω, για να αποδείξουμε κάποιες υπηρεσίες, όπως για παράδειγμα την υπαγωγή, την ισοδυναμία και τη συνεπαγωγή, χρειάζεται να ελέγξουμε όλα τα μοντέλα του T ή / και του A . Κάτι τέτοιο όμως είναι αδύνατο. Για το λόγο αυτό, μας δίνεται η δυνατότητα να ανάγουμε πολύπλοκα προβλήματα σε απλούστερα:

- Το πρόβλημα της συνεπαγωγής μπορεί να αναχθεί στο πρόβλημα της συνέπειας ενός ABox A . Έτσι λοιπόν έχουμε $A \models \phi$ με βάση το TBox T αν το $A \cup \{\neg\phi\}$ είναι ασυνεπές (inconsistent) με βάση το T .
- Το πρόβλημα της ικανοποιησιμότητας μιας έννοιας C με βάση το T μπορεί να αναχθεί στο πρόβλημα της συνέπειας ενός ABox A με βάση το T . Πιο συγκεκριμένα, η έννοια C είναι ικανοποιήσιμη με βάση το T , αν το $A = \{a:C\}$ είναι συνεπές με βάση το T , όπου a είναι ένα καινούργιο άτομο. Ανάλογα ορίζεται και η αναγωγή από το πρόβλημα μη ικανοποιησιμότητας μιας έννοιας με βάση το T στο πρόβλημα μη συνέπειας ενός ABox A με βάση το T .
- Το πρόβλημα της υπαγωγής μπορεί να αναχθεί στο πρόβλημα της μη ικανοποιησιμότητας και, σύμφωνα με τα προηγούμενα, στο πρόβλημα της μη συνέπειας. Πιο συγκεκριμένα, η έννοια C υπάγεται στην έννοια D με βάση το T , αν η έννοια $C \sqcap \neg D$ είναι μη-ικανοποιήσιμη, ή σύμφωνα με τα παραπάνω, αν το $A = \{a: C \sqcap \neg D\}$ είναι μη συνεπές με βάση το T (όπου a ένα καινούργιο άτομο).

- Το πρόβλημα της ισοδυναμίας μπορεί να αναχθεί στο πρόβλημα της μη ικανοποιησιμότητας και συνεπώς και στο πρόβλημα μη συνέπειας. Πιο συγκεκριμένα, οι έννοιες C και D είναι ισοδύναμες με βάση το T , αν και οι δυο έννοιες $C \sqcap \neg D$ και $\neg C \sqcap D$ είναι μη-ικανοποιήσιμες ή ισοδύναμα, αν το $A = \{a: C \sqcap \neg D, a: \neg C \sqcap D\}$ είναι μη συνεπές με βάση το T (όπου a είναι ένα καινούργιο άτομο).
- Το πρόβλημα των ξένων εννοιών μπορεί να αναχθεί στο πρόβλημα της μη ικανοποιησιμότητας και συνεπώς και στο πρόβλημα μη συνέπειας. Πιο συγκεκριμένα, οι έννοιες C και D είναι ξένες μεταξύ τους, αν η έννοια $C \sqcap D$ είναι μη-ικανοποιήσιμη, ή ισοδύναμα, αν το $A = \{a: C \sqcap D\}$ είναι μη συνεπές με βάση το T (όπου a είναι ένα καινούργιο άτομο).

2.4 Εκφραστικές Περιγραφικές Λογικές

2.4.1 Περιγραφική λογική ALC_R^+

Η γλώσσα αυτή περιέχει τους κατασκευαστές της ALC και επίσης δίνει τη δυνατότητα χρήσης αξιωμάτων μεταβατικών ρόλων (transitive role axioms). Ένας ρόλος λέγεται μεταβατικός, αν όποτε ισχύει $R(a,b)$ και $R(b,c)$, τότε ισχύει και $R(a,c)$. Η σύνταξη των αξιωμάτων μεταβατικών ρόλων είναι $\text{Tr}(R)$, όπου R ένας ρόλος και η σημασιολογία του είναι η εξής:

$$\text{αν } \{(a^I, b^I), (b^I, c^I)\} \subseteq R^I \text{ τότε } (a^I, c^I) \in R^I \quad (2.9)$$

Συχνά χρησιμοποιούμε το γράμμα S για να αναφερθούμε στη γλώσσα ALC_R^+ .

2.4.2 Επιπλέον Τέλεστες για Αύξηση της Εκφραστικότητας

Επιπλέον οι περιγραφικές λογικές μας δίνουν τη δυνατότητα περιγραφής αξιωμάτων υπαγωγής ρόλων (role inclusion axioms), με σύνταξη $R \sqsubseteq S$, όπου R και S ρόλοι και συγκεκριμένα ο R είναι υπο-ρόλος του S και με σημασιολογία $R^I \subseteq S^I$. Η ύπαρξη αξιωμάτων υπαγωγής ρόλων συμβολίζεται με το γράμμα H και μπορεί να χρησιμοποιηθεί με οποιαδήποτε από τις περιγραφικές γλώσσες που έχουμε αναφέρει παραπάνω, προσθέτοντας στο όνομα της γλώσσας το σύμβολο H .

Οι περιγραφικές λογικές μας δίνουν επίσης τη δυνατότητα ορισμού αντίστροφων ρόλων (inverse roles), με σύνταξη R^{-1} , όπου R ρόλος και με σημασιολογία που δίνεται από τη σχέση $(a,b) \in R^I$ ανν $(b,a) \in (R^{-1})^I$. Η ύπαρξη αντίστροφων ρόλων συμβολίζεται με το γράμμα I και μπορεί να χρησιμοποιηθεί με οποιαδήποτε από τις περιγραφικές γλώσσες που έχουμε αναφέρει παραπάνω προσθέτοντας στο όνομα της γλώσσας το σύμβολο I .

Ένας ιδιαίτερος τελεστής εννοιών που πρέπει να αναφερθεί είναι η ονοματική έννοια (nominal concept) η οποία δημιουργεί έννοιες απαριθμώντας τα μέλη τους. Η σημασιολογία των εννοιών αυτών είναι η ακόλουθη : Μια έννοια $\{a\}$ ερμηνεύεται ως το σύνολο του Δ^I το οποίο περιέχει ως μέλος μόνο το αντικείμενο a^I , δηλαδή $\{a\}^I = \{a^I\}$. Η ύπαρξη αυτού του κατασκευαστή σε μια περιγραφική λογική συμβολίζεται με το γράμμα O και μπορεί να χρησιμοποιηθεί με οποιαδήποτε από τις περιγραφικές γλώσσες που έχουμε αναφέρει παραπάνω προσθέτοντας στο όνομα της γλώσσας το σύμβολο O .

Θα πρέπει να σημειωθεί ότι όπως τα αξιώματα υπαγωγής και ισοδυναμίας εννοιών αλλά και τα σώματα ισχυρισμών οργανώνονται σε σώματα ορολογίας (TBox) και σε σώματα ισχυρισμών (ABox) αντίστοιχα, έτσι και τα αξιώματα ρόλων οργανώνονται στο σώμα ρόλων (RBox – Role box).

Τέλος, οι περιγραφικές λογικές μας δίνουν τη δυνατότητα ορισμού τύπων δεδομένων (data types), όπως για παράδειγμα οι ακέραιοι, οι δεκαδικοί, οι συμβολοσειρές. Στην εργασία αυτή θα χρησιμοποιήσουμε την προσέγγιση type system η οποία συμβολίζεται με το γράμμα **D**. Ένα type system ορίζεται τυπικά ως το ζευγάρι (Δ_D, Φ_D) , όπου το Φ_D αποτελεί το σύνολο των ονομάτων τύπων δεδομένων, ενώ Δ_D είναι ο χώρος ερμηνείας αυτών των ονομάτων, καθένα από τα οποία έχει μια σταθερή ερμηνεία. Προκειμένου να δημιουργήσουμε έννοιες σε μια περιγραφική λογική, τα ονόματα τύπων δεδομένων χρησιμοποιούνται με τον περιορισμό τιμής και τον υπαρξιακό περιορισμό. Αν T είναι ένας ρόλος και p ένα όνομα τύπου δεδομένων τότε τα $\forall T.p$ και $\exists T.p$ είναι έννοιες.

Η ερμηνεία του υπαρξιακού περιορισμού είναι η εξής :

$$(\exists T.p)^I = \{a \in \Delta^I \mid \exists y. (a,y) \in T^I \text{ και } y \in p^D\} \quad (2.10)$$

Και η ερμηνεία του περιορισμού τιμής είναι η εξής :

$$(\forall T.p)^I = \{a \in \Delta^I \mid \forall y. (a,y) \in T^I \rightarrow y \in p^D\} \quad (2.11)$$

2.5 Σημασιολογία Κλειστού ή Ανοικτού Κόσμου

Συχνά εγκαθίσταται μια αναλογία μεταξύ των βάσεων δεδομένων και των βάσεων γνώσης Περιγραφικής Λογικής. Το σχήμα μιας βάσης δεδομένων συγκρίνεται με το TBox και το στιγμιότυπο με τα δεδομένα συγκρίνεται με το ABox. Όμως πρέπει να τονιστεί ότι η σημασιολογία των ABoxes διαφέρει από τη συνήθη σημασιολογία των στιγμιότυπων βάσεων δεδομένων. Ενώ ένα στιγμιότυπο μιας βάσης δεδομένων αναπαριστά ακριβώς μια ερμηνεία, και συγκεκριμένα την ερμηνεία όπου οι κλάσεις και οι σχέσεις στο σχήμα ερμηνεύονται από τα αντικείμενα και τις πλειάδες στο στιγμιότυπο, ένα ABox αναπαριστά πολλές διαφορετικές ερμηνείες, που αποτελούν τα μοντέλα του.

Αυτό έχει σαν αποτέλεσμα, η έλλειψη πληροφορίας σε ένα στιγμιότυπο βάσης να ερμηνεύεται σαν αρνητική πληροφορία δηλαδή ότι κάτι δεν ισχύει, ενώ η έλλειψη

πληροφορίας σε ένα ABox δείχνει απλά έλλειψη γνώσης, δηλαδή ότι δε γνωρίζουμε αν κάποιος ισχυρισμός ισχύει ή όχι. Με άλλα λόγια, αν κάποιος ισχυρισμός δε βρίσκεται μέσα στο ABox, αυτό δε σημαίνει ότι ο ισχυρισμός δεν ισχύει, αλλά ότι δεν ξέρουμε αν ισχύει και ότι μπορούμε να δημιουργήσουμε ερμηνείες στις οποίες ο ισχυρισμός αυτός να ικανοποιείται και άλλες στις οποίες να μην ικανοποιείται. Η υπόθεση αυτή ονομάζεται *υπόθεση ανοικτού κόσμου (open-world assumption)*.

Για αυτό το λόγο η σημασιολογία των ABoxes μερικές φορές χαρακτηρίζεται ως σημασιολογία “ανοικτού κόσμου” (υπόθεση ανοικτού κόσμου – open world assumption), ενώ η παραδοσιακή σημασιολογία των βάσεων δεδομένων χαρακτηρίζεται ως “κλειστού κόσμου” σημασιολογία (υπόθεση κλειστού κόσμου – closed world assumption).

2.6 Η Γλώσσα Αναπαράστασης Γνώσης OWL

Η OWL [3,6,7,8,12] είναι μια γλώσσα αναπαράστασης για το Σημασιολογικό Ιστό. Το πρότυπο της OWL καθορίζει τρεις υπο-γλώσσες που είναι οι ακόλουθες:

- **OWL Lite** : Η γλώσσα αυτή παρέχει την ίδια εκφραστική δυνατότητα με τη περιγραφική γλώσσα *SHIF(D)*. Η γλώσσα αυτή χρησιμοποιείται σε εφαρμογές που δεν έχουν μεγάλες απαιτήσεις σε εκφραστικές δυνατότητες, είναι χρήσιμη όμως σε εφαρμογές που απαιτούν μεγάλη ταχύτητα εξαγωγής συμπερασμάτων.
- **OWL DL** : Η γλώσσα αυτή παρέχει την ίδια εκφραστική δυνατότητα με τη περιγραφική γλώσσα *SHOIN(D)*. Η γλώσσα αυτή συνδυάζει μέγιστη εκφραστική δυνατότητα και καλές υπολογιστικές ιδιότητες. Πρόκειται για μια αποφάνσιμη (decidable) γλώσσα.
- **OWL Full** : Η γλώσσα αυτή συνδυάζει τις δυνατότητες του λεξιλογίου της γλώσσας OWL DL με τα χαρακτηριστικά της γλώσσας RDF και συγκεκριμένα τη δυνατότητα μετα-μοντελοποίησης, πράγμα το οποίο σημαίνει ότι στη γλώσσα

αυτή μπορούμε να χρησιμοποιήσουμε ένα στοιχείο A και ως κλάση και ως ιδιότητα αλλά και ως άτομο ταυτόχρονα μέσα σε μια βάση γνώσης. Οι αυξημένες αυτές δυνατότητες καθιστούν τη γλώσσα μη αποφάνσιμη (undecidable).

Η σύνταξη της OWL είναι η σύνταξη RDF/XML όπως φαίνεται στο [16]. Επειδή όμως παρέχει αρκετά εκφραστικούς τελεστές και αξιώματα, η σύνταξη μερικές φορές γίνεται αρκετά μεγάλη και πολύπλοκη. Για το λόγο αυτό στην εργασία θα χρησιμοποιήσουμε μια άλλη μορφή σύνταξης που διαθέτει η OWL, την αφηρημένη σύνταξη.

Το αλφάβητο της OWL αποτελείται από :

- κλάσεις (classes) που είναι αντίστοιχες των εννοιών στις περιγραφικές λογικές. Οι ατομικές κλάσεις της OWL είναι αντίστοιχες των ατομικών εννοιών των περιγραφικών λογικών και οι περιγραφές κλάσεων (class descriptions) είναι αντίστοιχες των περιγραφών εννοιών των περιγραφικών λογικών
- ιδιότητες (properties) που είναι αντίστοιχες των ρόλων στις περιγραφικές λογικές
- άτομα (individuals).

Στη συνέχεια θα δώσουμε τις περιγραφές και αξιώματα κλάσεων και ιδιοτήτων που μας προσφέρει η γλώσσα OWL. Οι υπογλώσσες που το προσφέρουν είναι η OWL DL και η OWL Full. Η OWL Lite προσφέρει ένα περιορισμένο σύνολο περιγραφών και αξιωμάτων κλάσεων σε σύγκριση με αυτά που θα αναφέρουμε παρακάτω.

2.6.1 Περιγραφές κλάσεων

Παρακάτω δίνονται σε μορφή πίνακα οι περιγραφές των OWL κλάσεων. Στην πρώτη στήλη φαίνεται η αφηρημένη σύνταξη σε OWL και στη δεύτερη στήλη φαίνεται η σύνταξη σε περιγραφικές λογικές για να φανεί ο τρόπος γραφής των κατασκευαστών σε OWL και να γίνει η αντιστοίχιση με τους κατασκευαστές των περιγραφικών λογικών. Η

σημασιολογία των κατασκευαστών είναι η αντίστοιχη των περιγραφικών λογικών που περιγράψαμε παραπάνω για αυτό δεν την επαναλαμβάνουμε.

Πίνακας 2.1 Περιγραφές OWL κλάσεων

Αφηρημένη Σύνταξη σε OWL	Σύνταξη σε περιγραφικές λογικές
owl:Thing	$\top$
owl:Nothing	$\perp$
intersectionOf($C_1, \dots, C_n$)	$C_1 \sqcap \dots \sqcap C_n$
unionOf($C_1, \dots, C_n$)	$C_1 \sqcup \dots \sqcup C_n$
complementOf(C)	$\neg C$
one of($o_1, \dots, o_n$)	$\{o_1\} \sqcup \dots \sqcup \{o_n\}$
restriction(R someValuesFrom(C))	$\exists R.C$
restriction(R allValuesFrom(C))	$\forall R.C$
restriction(R hasValue(o))	$\exists R.\{o\}$
restriction(R minCardinality(n))	$\geq nR$
restriction(R maxCardinality(n))	$\leq nR$
restriction(R cardinality(n))	$\geq nR \sqcap \leq nR$

2.6.2 Περιγραφές Ιδιοτήτων

Στην OWL υπάρχουν δύο είδη ιδιοτήτων :

- οι ιδιότητες αντικειμένων (object properties), οι οποίες χρησιμοποιούνται για να συνδέσουν δύο άτομα μεταξύ τους

- οι ιδιότητες τύπων δεδομένων (data type properties), οι οποίες χρησιμοποιούνται για να συνδέσουν ένα άτομο με μια τιμή τύπου δεδομένων

Στη συνέχεια θα δείξουμε τον τρόπο γραφής των αξιωμάτων στην OWL δείχνοντας και την αντιστοιχία σε περιγραφικές λογικές

2.6.3 Αξιώματα κλάσεων

Στον παρακάτω πίνακα φαίνονται τα αξιώματα κλάσεων της γλώσσας OWL (πρώτη στήλη), τα οποία αντιστοιχίζονται σε αξιώματα υπαγωγής και ισοδυναμίας μεταξύ εννοιών της περιγραφικής λογικής (δεύτερη στήλη πίνακα)

Πίνακας 2.2 Αξιώματα OWL κλάσεων

Αφηρημένη Σύνταξη	Σύνταξη σε περιγραφικές λογικές
Class(A partial $C_1, \dots, C_n$)	$A \sqsubseteq C_1 \sqcap \dots \sqcap C_n$
Class(A complete $C_1, \dots, C_n$)	$A \equiv C_1 \sqcap \dots \sqcap C_n$
EnumeratedClass(A $o_1, \dots, o_n$)	$A \equiv \{o_1\} \sqcup \dots \sqcup \{o_n\}$
SubClassOf(C_1, C_2)	$C_1 \sqsubseteq C_2$
EquivalentClasses($C_1, \dots, C_n$)	$C_1 \equiv \dots \equiv C_n$
DisjointClasses($C_1, \dots, C_n$)	$C_i \sqcap C_j \sqsubseteq \perp, 1 \leq i, j \leq n$

2.6.4 Αξιώματα Ιδιοτήτων Αντικειμένων

Στον παρακάτω πίνακα φαίνεται η αντιστοιχία ανάμεσα στα αξιώματα ιδιοτήτων της OWL και τα αξιώματα ρόλων των περιγραφικών Λογικών.

Πίνακας 2.3 Αξιώματα Ιδιοτήτων Αντικειμένων

Αφηρημένη Σύνταξη	Σύνταξη σε περιγραφικές λογικές
SubPropertyOf(R_1, R_2)	$R_1 \sqsubseteq R_2$
EquivalentProperties($R_1, \dots, R_n$)	$R_1 \equiv \dots \equiv R_n$
ObjectProperty ($R \text{ super}(R_1) \dots \text{super}(R_n)$)	$R \sqsubseteq R_i, 1 \leq i \leq n$
domain($C_1) \dots \text{domain}(C_n)$	$\exists R. T \sqsubseteq C_i, 1 \leq i \leq n$
range($C_1) \dots \text{range}(C_n)$	$T \sqsubseteq \forall R. C_i, 1 \leq i \leq n$
inverseOf(S)	$R \equiv S^-$
Symmetric	$R \equiv R$
Functional	$T \sqsubseteq \leq 1R$
InverseFunctional	$T \sqsubseteq \leq 1R^-$
Transitive)	Tr (R)

2.6.5 Αξιώματα Ιδιοτήτων Τύπων Δεδομένων

Στον παρακάτω πίνακα φαίνεται η αντιστοιχία ανάμεσα στην αφηρημένη σύνταξη περιγραφών κλάσεων και αξιωμάτων ιδιοτήτων τα οποία σχετίζονται με τύπους δεδομένων.

Πίνακας 2.4 Αξιώματα Ιδιοτήτων Τύπων Δεδομένων

Αφηρημένη Σύνταξη	Σύνταξη σε περιγραφικές λογικές
restriction(T someValuesFrom(d))	$\exists T.d$
restriction(T allValuesFrom(d))	$\forall T.d$
restriction(T minCardinality(n))	$\geq nT$
restriction(T maxCardinality(n))	$\leq nT$
DatatypeProperty(T super(T_1)...super(T_n) domain(C_1)...domain(C_n) range(d_1)...range(d_n) Functional)	$T \sqsubseteq T_i, 1 \leq i \leq n$ $\exists T. T \sqsubseteq C_i, 1 \leq i \leq n$ $T \sqsubseteq \forall T.d_i, 1 \leq i \leq n$ $T \sqsubseteq \leq 1T$

Στον παραπάνω πίνακα με T συμβολίζουμε μια ιδιότητα τύπου δεδομένων και με d, d_i για $1 \leq i \leq n$ συμβολίζουμε τύπους δεδομένων.

2.6.6 Αξιώματα Ατόμων

Τέλος στον ακόλουθο πίνακα φαίνονται τα αξιώματα για τα άτομα στην OWL και η αντίστοιχη σύνταξή τους σε περιγραφικές λογικές.

Πίνακας 2.5 Αξιώματα Ατόμων

Αφηρημένη Σύνταξη	Σύνταξη σε περιγραφικές λογικές
Individual(o type(C_1)...type(C_n))	$o:C_i, 1 \leq i \leq n$

Individual(o value(R_1, o_1)...value(R_n, o_n))	$(o, o_i):R_i, 1 \leq i \leq n$
SameIndividual($o_1, \dots, o_n$)	$o_1 = \dots = o_n$
DifferentIndividuals($o_1, \dots, o_n$)	$o_i \neq o_j, 1 \leq i < j \leq n$

2.7 Ασαφής Περιγραφική Λογική f -SHIN

Στη συνέχεια θα αναφέρουμε λίγα πράγματα για την περιγραφική λογική f -SHIN [13] που είναι μια ασαφής επέκταση της περιγραφικής λογικής SHIN και η οποία αποτελείται από ένα αλφάβητο διακριτών ονομάτων εννοιών (**C**), ονομάτων ρόλων (**R**) και ονομάτων ατόμων (**I**). Η f -SHIN χρησιμοποιεί τους κατασκευαστές (άρνηση $\neg$, τομή $\sqcap$, ένωση $\sqcup$, $\exists$ πλήρη υπαρξιακό ποσοδείκτη, $\forall$ περιορισμό τιμής) μαζί με μεταβατικούς ρόλους (S), ιεραρχία ρόλων (H), αντίστροφους ρόλους (I) και περιορισμούς τιμής ($N \leq, \geq$).

Οι έννοιες της f -SHIN ορίζονται επαγωγικά ως εξής :

1. Αν $C \in \mathbf{C}$, τότε η C είναι μια f -SHIN έννοια.
2. Αν C και D είναι έννοιες, R είναι ένας ρόλος, S είναι ένας απλός ρόλος και $n \in \mathbb{N}$, τότε οι $(\neg C)$, $(C \sqcup D)$, $(C \sqcap D)$, $(\forall R.C)$, $(\exists R.C)$, $(\geq nS)$ και $(\leq nS)$ είναι επίσης f -SHIN έννοιες.

Σε αντίθεση με τις συνήθεις περιγραφικές λογικές, η σημασιολογία των ασαφών περιγραφικών λογικών δίνεται από την ασαφή ερμηνεία [10]. Μια ασαφής ερμηνεία είναι ένα ζευγάρι $I = \langle \Delta^I, \cdot^I \rangle$ όπου το Δ^I είναι ένα μη κενό σύνολο αντικειμένων και $\cdot^I$ είναι μια ασαφής συνάρτηση ερμηνείας η οποία αντιστοιχίζει ένα άτομο a στο αντικείμενο $a^I \in \Delta^I$ και μια έννοια A (ρόλο R) σε μια συνάρτηση συμμετοχής

$$A^I : \Delta^I \rightarrow [0,1] \quad (R^I : \Delta^I \times \Delta^I \rightarrow [0,1]) \quad (2.12)$$

Η θεωρία ασαφών συνόλων χρησιμοποιείται προκειμένου να επεκτείνουμε την συνάρτηση ερμηνείας και να δώσουμε σημασιολογία σε σύνθετες έννοιες, ρόλους και αξιώματα.

Μια *f-SHIN* βάση γνώσης Σ είναι μια τριπλέτα $\langle T, R, A \rangle$, όπου T είναι το ασαφές TBox, R είναι το ασαφές RBox, και A είναι το ασαφές ABox.

Το TBox είναι ένα πεπερασμένο σύνολο ασαφών αξιωμάτων εννοιών του τύπου $C \equiv D$, που ονομάζονται ασαφή αξιώματα ισοδυναμίας εννοιών, ή του τύπου $C \sqsubseteq D$, που ονομάζονται ασαφή αξιώματα υπαγωγής εννοιών.

Ομοίως το RBox είναι ένα πεπερασμένο σύνολο ασαφών αξιωμάτων ρόλων της μορφής **Trans**(R) που ονομάζονται ασαφή μεταβατικά αξιώματα ρόλων και της μορφής $R \sqsubseteq S$ που ονομάζονται ασαφή αξιώματα υπαγωγής ρόλων.

Τέλος το ABox είναι ένα πεπερασμένο σύνολο από ασαφείς ισχυρισμούς της μορφής $\langle a : C \bowtie n \rangle$, $\langle \langle a, b \rangle : R \bowtie n \rangle$ όπου το $\bowtie$ συμβολίζει τις σχέσεις $\geq, >, \leq, <$ ή $a \neq b$, για $a, b \in I$. Ο ισχυρισμός $\langle a : C \geq n \rangle$ σημαίνει ότι το a συμμετέχει στην έννοια C με ένα βαθμό συμμετοχής που είναι μεγαλύτερος ή ίσος του n .

3. Τεχνικές Μηχανικής Μάθησης

Στο παρόν Κεφάλαιο κάνουμε μια αναφορά στις τεχνικές μηχανικής μάθησης, με έμφαση στις συναρτήσεις και μηχανές πυρήνα και στα τεχνητά νευρωνικά δίκτυα. Στην αρχή του Κεφαλαίου επικεντρωνόμαστε στις συναρτήσεις και στις μηχανές πυρήνα, αναφέροντας ορισμούς και ιδιότητες που θα μας χρησιμεύσουν στο επόμενο Κεφάλαιο, ενώ περιγράφουμε σύντομα και τις Μηχανές Διανυσμάτων Υποστήριξης (support vector machines). Στη συνέχεια μεταφερόμαστε στο πεδίο των τεχνητών νευρωνικών δικτύων και ειδικότερα στις μηχανές perceptrons και στα πολυεπίπεδα (multilayer) perceptrons. Η έμφαση δίδεται στους αλγορίθμους μάθησης (learning) και προσαρμογής (adaptation) των δικτύων αυτών, και ειδικότερα στην προσαρμογή των πολυεπίπεδων perceptrons. Επίσης αποδεικνύεται ότι οι συναρτήσεις πυρήνα μπορούν να συνδυαστούν με τις ανωτέρω αρχιτεκτονικές νευρωνικών δικτύων και τους αλγορίθμους μάθησης και προσαρμογής των βαρών τους. Η απόδειξη αυτή αποτελεί τη βάση του συνδυασμού και της ανανέωσης συμβολικής γνώσης μέσω αρχιτεκτονικών νευρωνικών δικτύων που προτείνεται στο Κεφάλαιο 5.

3.1 Συναρτήσεις και Μηχανές Πυρήνα

3.1.1 Μέθοδοι Πυρήνα

Στη συνέχεια θα αναφερθούμε στις μεθόδους πυρήνα (kernel methods) και θα αναλύσουμε τα βασικότερα στοιχεία τους που θα μας χρειαστούν στη συνέχεια [25-28].

Οι μέθοδοι πυρήνα βασίζονται στον προσδιορισμό ενός θετικά ορισμένου πυρήνα στο χώρο προτύπων. Η χρήση του πυρήνα αυτού οδηγεί σε μετασχηματισμό του χώρου προτύπων σε ένα γραμμικό χώρο (συνήθως μεγάλης διάστασης), στον οποίο οι πυρήνες ζευγών προτύπων υλοποιούνται με εσωτερικά γινόμενα. Το βασικό υπολογιστικό

πλεονέκτημα των μεθόδων πυρήνα είναι ότι μπορούν να εφαρμοστούν σε χώρους χαρακτηριστικών μεγάλων διαστάσεων, χωρίς να υποφέρουν από το κόστος του ακριβούς υπολογισμού των μετασχηματισμένων δεδομένων.

Οι μέθοδοι πυρήνα αποτελούνται από δυο συστατικά, την μηχανή πυρήνα (kernel machine) και τη συνάρτηση πυρήνα (kernel function).

Διαφορετικές μηχανές πυρήνα χρησιμοποιούν διαφορετικές διαδικασίες μάθησης, όπως π.χ., τα support vector machines εμπεριέχουν επιβλεπόμενη (supervised) μάθηση, ενώ το support vector clustering εμπεριέχει μη επιβλεπόμενη (unsupervised) μάθηση. Θα πρέπει να σημειωθεί ότι η μηχανή πυρήνα περιλαμβάνει τον αλγόριθμο μάθησης και τον τρόπο που αναζητείται η λύση, ενώ η συνάρτηση πυρήνα περιλαμβάνει την γλώσσα των υποθέσεων (hypothesis language), δηλαδή τον τρόπο που φτιάχνεται το σύνολο από τις πιθανές λύσεις. Διαφορετικές συναρτήσεις πυρήνα υλοποιούν διαφορετικούς χώρους υποθέσεων, ή ακόμα και διαφορετικές αναπαραστάσεις της γνώσης μας.

Πιο συγκεκριμένα, οι μέθοδοι πυρήνα ακολουθούν τα παρακάτω βήματα:

- Τα δεδομένα μεταφέρονται σε ένα νέο διανυσματικό χώρο που αναφέρεται και ως χώρος χαρακτηριστικών (feature space).
- Αναζητούνται γραμμικές σχέσεις ανάμεσα στις αναπαραστάσεις των δεδομένων στο χώρο χαρακτηριστικών.
- Οι υπολογισμοί γίνονται με τέτοιο τρόπο, ώστε δεν χρειάζονται οι συντεταγμένες των σημείων στον (μεγαλύτερης διάστασης) διανυσματικό χώρο, πάρα μόνο τα εσωτερικά γινόμενα των σημείων αυτών ανά δύο.
- Τα εσωτερικά γινόμενα των σημείων ανά δύο μπορούν να υπολογιστούν αποτελεσματικά (efficiently) από τα αρχικά δεδομένα μέσω της συνάρτησης πυρήνα.

Μια σημαντική παρατήρηση είναι ότι ο αλγόριθμος μάθησης (inductive bias) και η επιλογή της συνάρτησης πυρήνα (language bias) είναι ανεξάρτητα μεταξύ τους.

Ειδικότερα, οι μέθοδοι πυρήνα εφαρμόζουν στα δεδομένα εισόδου μια αντιστοίχιση

$$\Phi: \mathbf{x} \in \mathbb{R}^n \mapsto \Phi(\mathbf{x}) \in H \subseteq \mathbb{R}^n \quad (3.1)$$

με στόχο να μετατρέψουν τις μη γραμμικές σχέσεις στο χώρο εισόδου σε γραμμικές στο χώρο των χαρακτηριστικών, στον οποίο να μπορεί να χρησιμοποιηθεί το εσωτερικό γινόμενο ως μέτρο ομοιότητας.

Η αντιστοίχιση των δεδομένων στο χώρο H μέσω του μετασχηματισμού Φ έχει τα ακόλουθα πλεονεκτήματα:

- Επιτρέπει τον καθορισμό ενός μέτρου ομοιότητας από το εσωτερικό γινόμενο στο χώρο H ,

$$k(\mathbf{x}, \mathbf{x}') := \langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle = \Phi^T(\mathbf{x}) \Phi(\mathbf{x}') \quad (3.2)$$

- Επιτρέπει την γεωμετρική θεώρηση των δεδομένων, και με αυτόν τον τρόπο, την μελέτη των αλγορίθμων μάθησης με βάση τη γραμμική άλγεβρα και την αναλυτική γεωμετρία.
- Η ελευθερία της επιλογής της αντιστοίχισης Φ επιτρέπει τη σχεδίαση μιας μεγάλης ποικιλίας μέτρων ομοιότητας και αλγορίθμων μάθησης. Η ελευθερία αυτή ισχύει και στην περίπτωση που οι είσοδοι $\mathbf{x}_i$ υπάρχουν ήδη σε χώρο εσωτερικού γινομένου. Στην τελευταία περίπτωση είναι μεν δυνατή η απευθείας χρήση του εσωτερικού γινομένου ως μέτρου ομοιότητας, όμως είναι δυνατή η κατ' αρχήν εφαρμογή ενός μη γραμμικού μετασχηματισμού Φ για την αλλαγή της αναπαράστασης και την μετατροπή της σε μια που είναι πλέον κατάλληλη για το συγκεκριμένο πρόβλημα.

3.1.2 Συναρτήσεις Πυρήνα

Ανωτέρω περιγράψαμε πώς προκύπτει ένας πυρήνας ως μέτρο ομοιότητας που μπορεί να θεωρηθεί σαν ένα εσωτερικό γινόμενο στο χώρο χαρακτηριστικών. Στη συνέχεια, θα μελετήσουμε την κλάση των πυρήνων k που αντιστοιχούν σε εσωτερικά γινόμενα στο χώρο χαρακτηριστικών H , μέσω του μετασχηματισμού Φ ,

$$\Phi: X \rightarrow H \quad (3.3)$$

Η κλάση αυτή ορίζεται ως:

$$k(\mathbf{x}, \mathbf{x}') := \langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle = \Phi^T(\mathbf{x}) \Phi(\mathbf{x}') \quad (3.4)$$

Η χρήση των πυρήνων μας δίνει τη δυνατότητα να υπολογίσουμε το εσωτερικό γινόμενο ανάμεσα στις αναπαραστάσεις δύο προτύπων εισόδων στο χώρο χαρακτηριστικών μεγάλης διάστασης, χωρίς να υπολογίσουμε με ακρίβεια τις αναπαραστάσεις τους.

Η συνάρτηση k , η οποία επιστρέφει το εσωτερικό γινόμενο μεταξύ των αναπαραστάσεων δύο εισόδων στο χώρο των χαρακτηριστικών, λέγεται συνάρτηση πυρήνα.

Δύο απαιτήσεις υπάρχουν για την επιλογή της συνάρτησης πυρήνα $k(\mathbf{x}, \mathbf{x}')$. Καταρχάς, θα πρέπει να εμπεριέχει το μέτρο της ομοιότητας που είναι κατάλληλη για το εκάστοτε πρόβλημα. Κατά δεύτερο λόγο, ο υπολογισμός της θα πρέπει να είναι λιγότερο πολύπλοκος από τον υπολογισμό του αντίστοιχου μετασχηματισμού $\Phi(\mathbf{x})$.

Μια συνάρτηση πυρήνα, από την μορφή της, προσδιορίζει ένα χώρο χαρακτηριστικών, τον οποίο σε πολλές περιπτώσεις δεν χρειάζεται να κατασκευάσουμε αναλυτικά. Με άλλα λόγια, μπορούμε να ορίσουμε πυρήνες χωρίς να υπολογίσουμε πλήρως τον χώρο χαρακτηριστικών. Αυτό συμβαίνει όταν η διαθέσιμη γνώση μας παρέχει έναν τρόπο να συγκρίνουμε δύο εισόδους.

Το αν υπάρχει μια συνάρτηση $k : X \times X \rightarrow \mathbb{R}$ και ένας μετασχηματισμός χαρακτηριστικών $\Phi : \mathbf{x} \rightarrow H$ (σε ένα χώρο Hilbert H), έτσι ώστε:

$$k(\mathbf{x}, \mathbf{x}') = \langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle = \Phi^T(\mathbf{x}) \Phi(\mathbf{x}') \quad (3.5)$$

για οποιαδήποτε πρότυπα $\mathbf{x}, \mathbf{x}' \in X$, μπορεί να πιστοποιηθεί ελέγχοντας ότι ο k είναι θετικά ορισμένος.

Για πληρότητα παραθέτουμε τους ορισμούς για το πότε ένας πυρήνας θεωρείται θετικά ορισμένος.

Ορισμός 1: Πίνακας Gram (Gram Matrix)

Δοθείσας μιας συνάρτησης $k : X^2 \rightarrow \mathbb{R}$, ή $k : X^2 \rightarrow \mathbb{C}$ και των προτύπων $x_1, \dots, x_m \in X$, ο $m \times m$ πίνακας K με στοιχεία $K_{ij} := k(x_i, x_j)$ ονομάζεται πίνακας Gram ή πίνακας πυρήνα (kernel matrix) του k ως προς τα $x_1, \dots, x_m$.

Ορισμός 2: Θετικά ορισμένος πίνακας (Positive Definite Matrix)

Ένας μιγαδικός $m \times m$ πίνακας K που πληροί τις σχέσεις:

$$\sum_{i,j} \overline{c_j} c_i K_{ij} \geq 0 \quad (3.6)$$

για όλα τα $c_i \in \mathbb{C}$ ονομάζεται θετικά ορισμένος. Ομοίως, ένας πραγματικός συμμετρικός $m \times m$ πίνακας K που πληροί την ως άνω σχέση, για όλα τα $c_i \in \mathbb{R}$, ονομάζεται θετικά ορισμένος.

Ορισμός 3: Θετικά ορισμένος Πυρήνας (Positive Definite Kernel)

Έστω X ένα μη κενό σύνολο. Μια συνάρτηση k στο $X \times X$, η οποία, $\forall m \in \mathbb{N}$ και $\forall x_1, \dots, x_m \in X$, οδηγεί σε θετικά ορισμένο πίνακα Gram, ονομάζεται θετικά ορισμένος πυρήνας.

Δεν είναι πάντα εύκολο να αποδείξουμε ότι ένας πυρήνας είναι θετικά ορισμένος με βάση τον ορισμό. Για το λόγο αυτό, πολλές φορές χρησιμοποιούμε την ιδιότητα του κλεισίματος (closure) της οικογένειας των θετικά ορισμένων πυρήνων. Συγκεκριμένα, οι πυρήνες είναι κλειστοί ως προς το άθροισμα, τον πολλαπλασιασμό με μια σταθερά, το γινόμενο, την επέκταση με μηδενικά και την ύψωση σε δύναμη.

Στη συνέχεια παρουσιάζουμε μια πρόταση, την οποία θα χρησιμοποιήσουμε παρακάτω για να δημιουργήσουμε θετικά ορισμένους πυρήνες από απλούστερους πυρήνες ή για να αποδείξουμε ότι ένας σύνθετος πυρήνας είναι θετικά ορισμένος.

Πρόταση

Για το σύνολο των πυρήνων (kernels) ισχύει:

- Αν οι k_1 και k_2 είναι θετικά ορισμένοι πυρήνες και $\alpha_1, \alpha_2 \geq 0$, τότε ο $\alpha_1 k_1 + \alpha_2 k_2$ ο οποίος ορίζεται ως $(\alpha_1 k_1 + \alpha_2 k_2)(x, x') := \alpha_1 k_1(x, x') + \alpha_2 k_2(x, x')$, είναι επίσης ένας θετικά ορισμένος πυρήνας.
- Αν οι k_1 και k_2 είναι θετικά ορισμένοι πυρήνες, τότε ο $k_1 k_2$ ο οποίος ορίζεται ως ακολούθως: $(k_1 k_2)(x, x') := k_1(x, x') k_2(x, x')$, είναι επίσης ένας θετικά ορισμένος πυρήνας.

3.1.3 Είδη Πυρήνων

Πριν αναλύσουμε τους πυρήνες για δομημένα δεδομένα, θα αναφέρουμε περιληπτικά τους παραδοσιακά χρησιμοποιούμενους πυρήνες σε διανυσματικούς χώρους.

Πυρήνες σε διανυσματικούς χώρους

Έστω τα διανύσματα $x, x' \in \mathbb{R}^n$ και έστω $\langle \cdot, \cdot \rangle$ το εσωτερικό γινόμενο στο $\mathbb{R}^n$. Εκτός από τον γραμμικό πυρήνα

$$k(x, x') = \langle x, x' \rangle \quad (3.7)$$

και τον κανονικοποιημένο γραμμικό πυρήνα

$$k(x, x') = \frac{\langle x, x' \rangle}{\sqrt{\|x\| \|x'\|}} \quad (3.8)$$

οι δύο πιο συχνά χρησιμοποιούμενοι πυρήνες σε διανυσματικούς χώρους είναι ο πολωνυμικός πυρήνας και ο γκαουσιανός RBF πυρήνας. Δεδομένων δύο παραμέτρων, $c \in \mathbb{R}$, $p \in \mathbb{N}^+$, ο πολωνυμικός πυρήνας ορίζεται ως

$$k(x, x') = (\langle x, x' \rangle + c)^p \quad (3.9)$$

Το σκεπτικό πίσω από αυτόν τον πυρήνα είναι ότι είναι χρήσιμο να παράγονται νέα χαρακτηριστικά σαν γινόμενα αρχικών χαρακτηριστικών. Η παράμετρος p είναι η μέγιστη τάξη των μονώνυμων που δημιουργούν το νέο χώρο χαρακτηριστικών, ενώ το c μπορεί να χρησιμοποιηθεί ως ένα βήμα προς μονώνυμα χαμηλής τάξης – για παράδειγμα αν $c = 0$, ο χώρος χαρακτηριστικών αποτελείται μόνο από μονώνυμα τάξης p των αρχικών χαρακτηριστικών.

Δεδομένης μιας παραμέτρου γ , ο γκαουσιανός RBF πυρήνας ορίζεται ως εξής :

$$k(x, x') = e^{-\gamma \|x - x'\|^2} \quad (3.10)$$

Αν χρησιμοποιήσουμε αυτόν τον πυρήνα σε μηχανές, όπως τα Support Vector Machines, είναι σαν να χρησιμοποιούμε ένα (νευρωνικό) δίκτυο με γκαουσιανούς πυρήνες, κεντραρισμένους στα διανύσματα υποστήριξης (support vectors). Οι αναπαραστάσεις των σημείων ξεκινώντας από τον διανυσματικό χώρο $\mathbb{R}^n$ μέσω του μετασχηματισμού $\Phi : \mathbb{R}^n \rightarrow H$ με $k(x, x') = \langle \Phi(x), \Phi(x') \rangle$ κείνται όλες στην επιφάνεια μιας υπερσφαίρας στον χώρο Hilbert H .

Ο ακόλουθος πυρήνας μπορεί να χρησιμοποιηθεί με διακριτά δεδομένα. Ο πυρήνας ταιριάσματος (matching) $k_d : X \times X \rightarrow \mathbb{R}$ ορίζεται ως ακολούθως:

$$k_d(x, x') = \begin{cases} 1 & \text{αν } x = x' \\ 0 & \text{αλλιώς} \end{cases} \quad (3.11)$$

Η αναπαράσταση κάθε στοιχείου του X μέσω του μετασχηματισμού $\Phi : X \rightarrow H$, με $k_d(x, x') = \langle \Phi(x), \Phi(x') \rangle$, είναι ένα διάνυσμα ορθογώνιο προς όλες τις άλλες αναπαραστάσεις των στοιχείων του X μέσω του Φ .

Πυρήνες σε δομημένα δεδομένα

Η ιδέα για τον ορισμό πυρήνων σε δομημένα δεδομένα είναι πρώτα να ορίσουμε έναν τρόπο να συγκρίνουμε συστατικά των δεδομένων και στη συνέχεια να συνδυάσουμε τους υπο-πυρήνες που αντιστοιχούν σε ένα σύνολο από διαμερίσεις των δεδομένων. Ένας τύπος δεδομένων θεωρείται δομημένος (structured), αν είναι δυνατόν να τον διαχωρίσουμε σε μικρότερα τμήματα. Η ιδέα είναι να υπολογίσουμε το γινόμενο των υπο-πυρήνων, συγκρίνοντας τα τμήματα, και να αθροίσουμε στο σύνολο όλων των επιτρεπόμενων διαμερίσεων.

Ο πιο γνωστός πυρήνας, για χώρους αναπαράστασης που δεν είναι διανυσματικής (attribute-value) μορφής, είναι ο συνελκτικός πυρήνας (convolution kernel) που προτάθηκε από τον Haussler το 1999. Η βασική ιδέα του είναι ότι η σημασιολογία σύνθετων αντικειμένων μπορεί να εκφραστεί μέσα από μια σχέση R ανάμεσα στο αντικείμενο και στα τμήματά του. Έστω ότι $x, x' \in X$ είναι τα αντικείμενα, και $\mathbf{x}, \mathbf{x}' \in X_1 \times \dots \times X_D$ είναι τμήματα αυτών των αντικειμένων. Δεδομένης της σχέσης $R : (X_1 \times \dots \times X_D) \times X$, μπορούμε να ορίσουμε τις διαμερίσεις $R^{-1}(x) = \{\mathbf{x} : R(\mathbf{x}, x)\}$. Για θετικά ορισμένους πυρήνες $k_d : X_d \times X_d \rightarrow \mathbb{R}$, ο συνελκτικός πυρήνας ορίζεται ως εξής:

$$k_{conv}(x, x') = \sum_{x \in R^{-1}(x), x' \in R^{-1}(x')} \prod_{d=1}^D k_d(x_d, x'_d) \quad (3.12)$$

Ο όρος ‘συνελικτικός πυρήνας’ αναφέρεται σε μια κλάση πυρήνων που μπορούν να σχηματιστούν με τον παραπάνω τρόπο. Το πλεονέκτημα των συνελικτικών πυρήνων είναι ότι είναι πολύ γενικοί και μπορούν να εφαρμοστούν σε πολλές διαφορετικές περιπτώσεις. Παρόλα αυτά εξαιτίας αυτής τους της γενικότητάς τους, απαιτείται αρκετή προσπάθεια για να προσαρμοστούν σε ένα συγκεκριμένο πρόβλημα, πράγμα το οποίο κάνει την επιλογή της σχέσης R σε εφαρμογές του πραγματικού κόσμου αρκετά δύσκολη εργασία.

Πυρήνες για Βασικούς Όρους

Στη συνέχεια θα ορίσουμε έναν πυρήνα για σύνολα και τον πυρήνα γινομένου.

Οι παρακάτω πυρήνες ορίζονται στα σύνολα $A, B \subseteq X$ των αντικειμένων $x \in X$

Πυρήνας τομής συνόλων ή Πυρήνας Συνόλου (set intersection kernel or set kernel)

$$k_{set}(A, B) = |A \cap B| \quad (3.13)$$

όπου με $|A \cap B|$ συμβολίζουμε τον πληθάριθμο της τομής των δύο συνόλων.

Πυρήνας Γινομένου (crossproduct kernel)

$$k_x(A, B) = \sum_{x_A \in A} \sum_{x_B \in B} k_{base}(x_A, x_B) \quad (3.14)$$

όπου $k_{base}(\cdot, \cdot)$ είναι κάθε έγκυρος πυρήνας που ορίζεται στο X .

3.1.4 Στοιχεία Μεταβολής Πυρήνων

Προκειμένου να εισάγουμε γνώση για κάποιο πεδίο στον ορισμό ενός πυρήνα, συχνά είναι απαραίτητο να μεταβάλουμε τους πυρήνες κάποιου τύπου. Παρακάτω περιγράφουμε τυπικά αυτές τις αλλαγές με τη χρήση ενός πυρήνα

$$\kappa_{\text{modifier}} : P \rightarrow (X \times X \rightarrow \mathbb{R}) \rightarrow (X \times X \rightarrow \mathbb{R}), \quad (3.15)$$

ο οποίος δεχόμενος ένα στοιχείο μεταβολής (modifier) και τις παραμέτρους του (ένα στοιχείο του χώρου παραμέτρων P), αντιστοιχίζει έναν οποιοδήποτε πυρήνα στον μεταβληθέντα πυρήνα.

$$\kappa_{\text{polynomial}}(p,l)(k)(x, x') = (k(x, x') + l)^p \quad (l \geq 0, p \in \mathbb{Z}^+) \quad (3.16)$$

$$\kappa_{\text{gaussian}}(\gamma)(k)(x, x') = e^{-\gamma[k(x, x) - 2k(x, x') + k(x', x')]} \quad (\gamma > 0) \quad (3.17)$$

$$\kappa_{\text{normalised}}(k)(x, x') = \frac{k(x, x')}{\sqrt{k(x, x)k(x', x')}} \quad (3.18)$$

3.2 Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)

Οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines) είναι μοντέλα τα οποία λύνουν προβλήματα ταξινόμησης προτύπων. Σε αντίθεση με τα δίκτυα Perceptron

που υποφέρουν από το πρόβλημα της βραδείας εκπαίδευσης, τα μοντέλα αυτά έχουν μικρούς χρόνους εκπαίδευσης.

3.2.1 Γραμμικά Διαχωρίσιμα Προβλήματα

Ας υποθέσουμε ότι αντιμετωπίζουμε το πρόβλημα ταξινόμησης δύο κλάσεων C_0 και C_1 που είναι γραμμικά διαχωρίσιμες. Έτσι υπάρχουν ένα διάνυσμα w και ένα κατώφλι w_0 τέτοια ώστε:

$$w^T x + w_0 = \begin{cases} < 0 & \text{αν } x \in C_0 \\ > 0 & \text{αν } x \in C_1 \end{cases} \quad (3.19)$$

Επειδή υπάρχουν πολλές λύσεις, δηλαδή άπειρα ζεύγη (w, w_0) για το διαχωρισμό των κλάσεων, θεωρούμε κάποιο κριτήριο αξιολόγησης των λύσεων.

Το κριτήριο αυτό είναι το περιθώριο ταξινόμησης (margin) γ μεταξύ των δύο κλάσεων το οποίο ορίζεται ως το άθροισμα $\gamma = \gamma_0 + \gamma_1$ μεταξύ των δύο παρακάτω περιθωρίων (το γ_0 για την κλάση C_0 και το γ_1 για την κλάση C_1), όπου

$$\gamma_0 = \min_{x \in C_0} \frac{-(w^T x + w_0)}{\|w\|} \quad (3.20)$$

$$\gamma_1 = \min_{x \in C_1} \frac{(w^T x + w_0)}{\|w\|} \quad (3.21)$$

Τα πρότυπα x της κλάσης C_0 καθώς και τα πρότυπα x' της κλάσης C_1 , για τα οποία επιτυγχάνεται η ελάχιστη απόσταση (η ελάχιστη απόλυτη τιμή των γ_0 και γ_1 στους παραπάνω τύπους), λέγονται διανύσματα υποστήριξης (support vectors).

Στη συνέχεια θεωρούμε το «κανονικό διαχωριστικό υπερεπίπεδο» για το οποίο

α) το κατώφλι w_0 τοποθετείται ακριβώς στη μέση ανάμεσα στις δύο κλάσεις ($\gamma_0 = \gamma_1$)

β) η κλιμάκωση των w και w_0 είναι τέτοια, ώστε:

$$\mathbf{w}^T \mathbf{x} + w_0 = \begin{cases} \leq -1 & \text{αν } \mathbf{x} \in C_0 \\ \geq 1 & \text{αν } \mathbf{x} \in C_1 \end{cases} \quad (3.22)$$

και για το οποίο προκύπτει $\gamma_0 = \gamma_1 = \frac{1}{\|\mathbf{w}\|}$ και άρα $\gamma = \frac{2}{\|\mathbf{w}\|}$.

Το πρόβλημα συνεπώς είναι ο προσδιορισμός του ελαχίστου της συνάρτησης

$$J(\mathbf{w}, w_0) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (3.23)$$

υπό τους περιορισμούς των P ανισοτήτων που δίνονται παρακάτω

$$d_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1 \quad i = 1, \dots, P \quad (3.24)$$

Για την ελαχιστοποίηση της παραπάνω συνάρτησης χρησιμοποιούνται πολλαπλασιαστές Lagrange δημιουργώντας τη συνάρτηση κόστους $L^d(\lambda_1, \dots, \lambda_p) = -L(\lambda_1, \dots, \lambda_p)$, η οποία πρέπει να ελαχιστοποιηθεί ως προς τα λ_i , όπου:

$$L(\lambda_1, \dots, \lambda_p) = \sum_{i=1}^P \lambda_i - \frac{1}{2} \sum_{i=1}^P \sum_{j=1}^P \lambda_i \lambda_j d_i d_j \mathbf{x}_i^T \mathbf{x}_j \quad (3.25)$$

Έτσι έχουμε να λύσουμε το δυϊκό του αρχικού προβλήματος, που είναι ο υπολογισμός του ελαχίστου της συνάρτησης L^d ως προς τα $\lambda_1, \dots, \lambda_p$ υπό τους περιορισμούς:

$$\sum_{i=1}^P \lambda_i d_i = 0$$

$$\lambda_i \geq 0, \quad i=1,\dots,P \quad (3.26)$$

Αποδεικνύεται ότι το διάνυσμα λύσης $\mathbf{w}$ είναι ένας θετικός γραμμικός συνδυασμός των διανυσμάτων υποστήριξης.

$$\mathbf{w} = \sum_{i \in I_{SV}} \lambda_{o,i} d_i \mathbf{x}_i \quad (3.27)$$

όπου I_{SV} είναι το σύνολο που αποτελείται από τα διανύσματα υποστήριξης, και $\lambda_{o,i}$ είναι οι βέλτιστοι πολλαπλασιαστές Lagrange που βρίσκονται από τη λύση της (3.26).

Η βέλτιστη διαχωριστική επιφάνεια είναι η ακόλουθη :

$$g^*(\mathbf{x}) = \sum_{i \in I_{SV}} \lambda_{o,i} d_i \mathbf{x}_i^T \mathbf{x} + w_0 \quad (3.28)$$

και το κατώφλι υπολογίζεται ως εξής:

$$w_0 = \frac{1}{|I_{SV}|} \sum_{i \in I_{SV}} \frac{1}{d_i} - \mathbf{w}^T \mathbf{x}_i \quad (3.29)$$

3.2.2 Μη Γραμμικά Διαχωρίσιμα Προβλήματα

Όταν έχουμε μη γραμμικά προβλήματα, δηλαδή προβλήματα στα οποία οι κλάσεις δεν είναι γραμμικά διαχωρίσιμες, το πρόβλημα, είναι ο προσδιορισμός του ελαχίστου της συνάρτησης

$$J_{ns}(\mathbf{w}, w_0) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^P \xi_i \quad (3.30)$$

υπό τους περιορισμούς των παρακάτω P ανισοτήτων

$$\begin{aligned} d_i(\mathbf{w}^T \mathbf{x}_i + w_0) &\geq 1 - \xi_i \\ \xi_i &\geq 0 \end{aligned} \quad (3.31)$$

όπου $i = 1, \dots, P$, η μεταβλητή ξ_i λέγεται μεταβλητή χαλαρότητας και η παράμετρος C επιλέγεται από το χρήστη και είναι το βάρος του κόστους των λάθος ταξινομήσεων.

Το παραπάνω πρόβλημα μετασχηματίζεται στο ακόλουθο δυϊκό πρόβλημα υπολογισμού του ελαχίστου της συνάρτησης L^d ως προς τα $\lambda_1, \dots, \lambda_P$, όπως στην (3.25)

υπό τους περιορισμούς

$$\begin{aligned} \sum_{i=1}^P \lambda_i d_i &= 0 \text{ και} \\ 0 &\leq \lambda_i \leq C, \quad i=1, \dots, P \end{aligned} \quad (3.32)$$

Το διάνυσμα λύσης βρίσκεται ότι είναι το ίδιο όπως στην (3.27).

Σε αυτή την περίπτωση, επειδή χρησιμοποιούνται γραμμικές συναρτήσεις για διαχωρισμό μη γραμμικών κλάσεων, είναι πιθανόν πολλά πρότυπα να ταξινομηθούν λανθασμένα.

3.2.3 Χρήση Συναρτήσεων Πυρήνα

Στην ενότητα αυτή θα ασχοληθούμε με την εύρεση του βέλτιστου διαχωριστικού υπερεπιπέδου, στην περίπτωση που τα πρότυπα είναι διαχωρίσιμα από μη γραμμικές επιφάνειες, αποφεύγοντας τις λάθος ταξινομήσεις. Για το σκοπό αυτό:

- Αρχικά χρησιμοποιείται κάποιος κατάλληλος μη γραμμικός μετασχηματισμός $\Phi(\cdot)$, αντιστοιχίζοντας το διάνυσμα εισόδου σε ένα χώρο χαρακτηριστικών μεγαλύτερης διάστασης στον οποίο τα πρότυπα γίνονται γραμμικά διαχωρίσιμα.

- Στη συνέχεια κατασκευάζεται στο χώρο αυτό το βέλτιστο διαχωριστικό υπερεπίπεδο, χρησιμοποιώντας τα μετασχηματισμένα πρότυπα.

Η ιδέα για το πρώτο βήμα έρχεται από το θεώρημα του Cover το οποίο είναι το ακόλουθο:

Θεώρημα Cover

Ένα σύνθετο πρόβλημα ταξινόμησης προτύπων το οποίο μετασχηματίζεται μη γραμμικά σε ένα χώρο μεγάλης διάστασης είναι πιο πιθανό να είναι στο χώρο αυτό γραμμικά διαχωρίσιμο από ότι σε ένα χώρο μικρής διάστασης.

Με άλλα λόγια, το θεώρημα του Cover λέει ότι ο αρχικός χώρος μπορεί να μετασχηματιστεί σε ένα νέο χώρο χαρακτηριστικών, όπου τα πρότυπα είναι γραμμικά διαχωρίσιμα με μεγάλη πιθανότητα δεδομένου ότι ικανοποιούνται δύο συνθήκες:

- ο μετασχηματισμός είναι μη γραμμικός
- η διάσταση του χώρου χαρακτηριστικών είναι αρκετά μεγάλη.

Το δεύτερο βήμα είναι σε αντιστοιχία με τη θεωρία που αναφέραμε για γραμμικά δεδομένα, με τη διαφορά ότι το διαχωριστικό υπερεπίπεδο τώρα ορίζεται σαν γραμμική συνάρτηση των διανυσμάτων που παίρνουμε από το χώρο χαρακτηριστικών και όχι από τον αρχικό χώρο εισόδου.

Ας συμβολίσουμε με $\mathbf{x}$ ένα διάνυσμα από το χώρο εισόδου, που έστω ότι είναι διάστασης m_0 και με $\{\varphi_j(\mathbf{x})\}_{j=1}^{m_1}$ το σύνολο των μη γραμμικών μετασχηματισμών από τον αρχικό χώρο στο χώρο χαρακτηριστικών διάστασης m_1 . Ορίζουμε το ακόλουθο υπερεπίπεδο:

$$\sum_{j=0}^{m_1} w_j \varphi_j(\mathbf{x}) = 0 \quad (\text{έχουμε υποθέσει } \varphi_0(\mathbf{x}) = 1 \text{ για κάθε } \mathbf{x}) \quad (3.33)$$

Η παραπάνω εξίσωση γράφεται σε συμπαγή μορφή

$$\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}) = 0 \quad (3.34)$$

Προσαρμόζοντας τον τύπο της περίπτωσης των γραμμικά διαχωρίσιμων προτύπων παίρνουμε:

$$\mathbf{w} = \sum_{i=1}^P \lambda_i d_i \boldsymbol{\varphi}(\mathbf{x}_i) \quad (3.35)$$

όπου το διάνυσμα $\boldsymbol{\varphi}(\mathbf{x}_i)$ αντιστοιχεί στο πρότυπο εισόδου $\mathbf{x}_i$.

Η διαχωριστική επιφάνεια στο χώρο χαρακτηριστικών είναι η ακόλουθη :

$$\sum_{i=1}^P \lambda_i d_i \boldsymbol{\varphi}^T(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{x}) = 0 \quad (3.36)$$

Ο όρος $\boldsymbol{\varphi}^T(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{x})$ είναι το εσωτερικό γινόμενο δύο διανυσμάτων στο χώρο χαρακτηριστικών που δημιουργήθηκε από τον μετασχηματισμό του διανύσματος εισόδου $\mathbf{x}$ και του προτύπου εισόδου $\mathbf{x}_i$.

Ορίζουμε τον πυρήνα εσωτερικού γινομένου (inner-product kernel) ως εξής:

$$k(\mathbf{x}, \mathbf{x}_i) = \boldsymbol{\varphi}^T(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{x}) = \sum_{j=0}^{m_1} \varphi_j(\mathbf{x}) \varphi_j(\mathbf{x}_i) \quad \text{για } i = 1, 2, \dots, P \quad (3.37)$$

Από τον ορισμό αυτό βλέπουμε ότι ο πυρήνας εσωτερικού γινομένου είναι μια συμμετρική συνάρτηση ως προς τα ορίσματά της, δηλαδή:

$$k(\mathbf{x}, \mathbf{x}_i) = k(\mathbf{x}_i, \mathbf{x}) \quad \text{για κάθε } i \quad (3.38)$$

Με βάση τα παραπάνω, το βέλτιστο διαχωριστικό υπερεπίπεδο δίνεται από την ακόλουθη εξίσωση:

$$\sum_{i=1}^P \lambda_i d_i k(\mathbf{x}_i, \mathbf{x}) = 0 \quad (3.39)$$

Η εξίσωση (3.37) επιτρέπει την κατασκευή ενός διαχωριστικού υπερεπίπεδου που είναι μη γραμμικό στο χώρο εισόδου, αλλά η εικόνα του στο χώρο χαρακτηριστικών είναι γραμμική. Το δυικό πρόβλημα για την εύρεση της βέλτιστης διαχωριστικής επιφάνειας από μια μηχανή διανυσμάτων υποστήριξης ορίζεται ως εξής :

Δεδομένων των προτύπων $\{(\mathbf{x}_i, d_i)\}$ για $i=1, \dots, P$, υπολογίζονται οι πολλαπλασιαστές Lagrange λ_i για $i=1, \dots, P$, που μεγιστοποιούν την αντικειμενική συνάρτηση

$$Q(\lambda) = \sum_{i=1}^P \lambda_i - \frac{1}{2} \sum_{i=1}^P \sum_{j=1}^P \lambda_i \lambda_j d_i d_j k(\mathbf{x}_i, \mathbf{x}_j) \quad (3.40)$$

υπό τους περιορισμούς

$$1) \sum_{i=1}^P \lambda_i d_i = 0$$

$$2) 0 \leq \lambda_i \leq C \quad \text{για } i=1, 2, \dots, P$$


Θα πρέπει να σημειωθεί ότι μπορούμε να δούμε το $k(\mathbf{x}_i, \mathbf{x}_j)$ σαν το ij -στοιχείο ενός συμμετρικού $N \times N$ πίνακα $\mathbf{k}$ ως εξής:

$$\mathbf{k} = \left\{ k(\mathbf{x}_i, \mathbf{x}_j) \right\}_{(i,j)=1}^P \quad (3.41)$$

Έχοντας βρει τους βέλτιστους πολλαπλασιαστές Lagrange $\lambda_{o,i}$ η βέλτιστη λύση για το διάνυσμα βαρών $\mathbf{w}$ είναι

$$\mathbf{w} = \sum_{i=1}^P \lambda_{o,i} d_i \varphi(\mathbf{x}_i) \quad (3.42)$$

Στο επόμενο Σχήμα φαίνεται η υλοποίηση μιας αρχιτεκτονικής διανυσμάτων υποστήριξης (SVM).



Σχήμα 3.1 Η Αρχιτεκτονική ενός SVM

Μπορεί να αναφερθεί ότι η διάσταση του χώρου χαρακτηριστικών καθορίζεται από το πλήθος των διανυσμάτων υποστήριξης τα οποία λαμβάνονται από τα πρότυπα εκπαίδευσης με τη λύση του ανωτέρω προβλήματος βελτιστοποίησης.

3.3 Τεχνητά Νευρωνικά Δίκτυα

3.3.1 Νευρωνικά Δίκτυα Perceptrons

Στη συνέχεια θα αναφερθούμε στην επέκταση της χρήσης μη γραμμικών πυρήνων στο μοντέλο Perceptron, με την προκύπτουσα μέθοδο να ονομάζεται kernel Perceptron. Το μοντέλο Perceptron είναι η πλέον απλή αρχιτεκτονική τεχνητών νευρωνικών δικτύων και η μελέτη της εκπαίδευσής του, όσο και της σύγκλισής του αλγορίθμου μάθησης, μπορούν να βρεθούν σε οποιοδήποτε σύγγραμμα νευρωνικών δικτύων (για παράδειγμα, [30]).

Θεωρούμε ότι έχουμε P πρότυπα εκπαίδευσης στο χώρο m_0 διαστάσεων, μαζί με τους αντίστοιχους δυαδικούς στόχους. Η εκπαίδευση του Perceptron θα γίνει με τα μετασχηματισμένα πρότυπα τα οποία ανήκουν σε κάποιο μεγαλύτερο χώρο m_1 διαστάσεων, όπου $m_1 > m_0$. Ο αλγόριθμος εκπαίδευσης του kernel perceptron είναι παρόμοιος με αυτόν του απλού perceptron, με εκμετάλλευση της ιδιότητας των συναρτήσεων πυρήνα (3.37) για την αποφυγή εκτέλεσης των πράξεων στον χώρο m_1 διαστάσεων [31].

3.3.2 Πολυεπίπεδα Νευρωνικά Δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) είναι αρχιτεκτονικές αποτελούμενες από πλήθος δια-συνδεδεμένων μονάδων - νευρώνων. Κάθε νευρώνας δέχεται στην είσοδό του σήματα, από το περιβάλλον αν είναι νευρώνας εισόδου, ή από τις εξόδους των άλλων νευρώνων, περιλαμβάνει μια συνάρτηση ενεργοποίησης, μέσω της οποίας παράγει ένα σήμα, με το οποίο τροφοδοτεί τους άλλους νευρώνες ή την έξοδο του δικτύου. Κάθε σύναψη μεταξύ δύο νευρώνων χαρακτηρίζεται από μια τιμή βάρους. Οι τιμές των βαρών των συνάψεων αποτελούν τη γνώση που είναι αποθηκευμένη στο δίκτυο και καθορίζουν τη λειτουργία του.

Το υπολογιστικό μοντέλο ενός νευρωνικού δικτύου πολλαπλασιάζει τα σήματα-εισόδους κάθε νευρώνα με τα συναπτικά βάρη των συνδέσεων από τις οποίες αυτά διέρχονται και υπολογίζει το άθροισμα των γινομένων αυτών. Το άθροισμα που προκύπτει αποτελεί την είσοδο της συνάρτησης ενεργοποίησης του νευρώνα. Εάν x_i είναι η i -οστή είσοδος του k νευρώνα, w_{ki} : το i -οστό συναπτικό βάρος του k νευρώνα (από έναν αριθμό N συνδέσεων) και ϕ η συνάρτηση ενεργοποίησης του νευρώνα, τότε η έξοδος y_k του νευρώνα δίδεται από την εξίσωση:

$$y_k = \phi\left(\sum_{i=0}^{N-1} x_i w_{ki}\right) \quad (3.43)$$

Οι πλέον συνήθεις μορφές της συνάρτησης ενεργοποίησης είναι η βηματική, η συνάρτηση προσήμου, η ταυτοτική συνάρτηση - στην περίπτωση γραμμικών νευρώνων – και η σιγμοειδής συνάρτηση.

Ένας από τους πλέον συνήθεις τύπους νευρωνικών δικτύων είναι τα πολυεπίπεδα δίκτυα εμπρόσθιας τροφοδότησης (feedforward multilayer neural networks). Στα δίκτυα αυτά οι νευρώνες κατανέμονται σε επίπεδα (στρώματα). Ένα δίκτυο N επιπέδων εμπρόσθιας τροφοδότησης είναι ένας ακυκλικός γράφος. Αποτελείται από N επίπεδα, κάθε ένα από τα οποία περιλαμβάνει κάποιο αριθμό από νευρώνες. Συνδέσεις υπάρχουν μόνο μεταξύ νευρώνων διαφορετικών (συνήθως διαδοχικών) επιπέδων, με το πρώτο επίπεδο να είναι το επίπεδο εισόδου και τους υπολογισμούς των εξόδων των νευρώνων να γίνονται από το επίπεδο εισόδου, στα ενδιάμεσα επίπεδα (κρυφά) και τελικά στο επίπεδο εξόδου (εμπρόσθια τροφοδότηση των πληροφοριών – από την είσοδο στην έξοδο, δίχως ανατροφοδότηση).

3.3.3 Αλγόριθμοι Μάθησης Πολυεπίπεδων Perceptrons

Η μηχανική μάθηση (machine learning), στην περίπτωση νευρωνικών δικτύων σταθερής δομής, δηλαδή με συγκεκριμένο αριθμό νευρώνων, επιπέδων, συνδέσεων, συνίσταται στον υπολογισμό των ανεξάρτητων παραμέτρων – βαρών των συνδέσεων που αυτά περιέχουν, ώστε να εκτελούν μια συγκεκριμένη λειτουργία. Ο πλέον συνήθης αλγόριθμος εκπαίδευσης των πολυεπίπεδων νευρωνικών δικτύων εμπρόσθιας

τροφοδότησης είναι ο αλγόριθμος της ανάστροφης διάδοσης σφάλματος (Error Back-Propagation ή απλά back-propagation). Ο αλγόριθμος αυτός, προκύπτει εφαρμόζοντας τις τεχνικές της θεωρίας βελτιστοποίησης (optimisation theory) πάνω στην αρχιτεκτονική ενός πολυεπίπεδου δικτύου και αποτελεί επέκταση του αλγορίθμου μάθησης των perceptrons στην περίπτωση των πολυεπίπεδων αρχιτεκτονικών (multilayer perceptrons). Η βελτιστοποίηση (ελαχιστοποίηση μιας συνάρτησης κόστους) επιτυγχάνεται στο στάδιο της εκπαίδευσης του δικτύου, οπότε αυτό μαθαίνει να προσεγγίζει, με τις εξόδους που παρέχει, ένα σύνολο από επιθυμητές τιμές (desired outputs) που του παρέχονται από ένα εξωτερικό δάσκαλο (supervised training) μαζί με το αντίστοιχο σύνολο από δεδομένα – πρότυπα εισόδου (training data set).

Έστω ότι έχουμε ένα σύνολο εκπαίδευσης που αποτελείται από N ζεύγη της μορφής $[\bar{x}, \bar{d}]$, όπου $\bar{x}$ συμβολίζει το διάνυσμα (πρότυπο) εισόδου και $\bar{d}$ το διάνυσμα της επιθυμητής εξόδου όταν εφαρμοσθεί ως είσοδος το πρότυπο $\bar{x}$. Ας αναφερθούμε σε έναν από τους νευρώνες του επιπέδου εξόδου του δικτύου. Το σφάλμα στην έξοδο του νευρώνα j , όταν στην είσοδο του δικτύου παρουσιάζεται το πρότυπο $\bar{x}(n)$, όπου $n = 1, 2, \dots, N$, δίδεται από τον τύπο:

$$e_j(n) = d_j(n) - y_j(n) \quad (3.44)$$

όπου d_j και y_j η επιθυμητή και η πραγματική έξοδος αντίστοιχα του νευρώνα j για είσοδο την $\bar{x}(n)$.

Η στιγμιαία τιμή του τετραγωνικού σφάλματος για τον νευρώνα j ορίζεται ως:

$$\frac{1}{2} e_j^2(n) \quad (3.45)$$

και το άθροισμα των τετραγωνικών σφαλμάτων όλων των νευρώνων εξόδου, στην n -οστή επανάληψη-παρουσίαση ενός προτύπου στην είσοδό του δίδεται από τη σχέση:

$$G(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (3.46)$$

Η συνάρτηση $G(n)$ αποτελεί τη συνάρτηση κόστους, η οποία ελαχιστοποιείται, συσσωρευτικά για όλα τα n , μέσω του αλγόριθμου back propagation. Ειδικότερα, ο αλγόριθμος της ανάστροφης διάδοσης προβαίνει, σε κάθε επανάληψη, n , σε μια ανανέωση (διόρθωση) $\Delta w_{ji}(n)$ στο βάρος $w_{ji}(n)$ της σύνδεσης μεταξύ του νευρώνα j κάποιου επιπέδου (έστω m) του δικτύου και του νευρώνα i του προηγούμενου ($m-1$) επιπέδου, $m=1, \dots, N$. Η ανανέωση γίνεται πρώτα για τα βάρη των συνδέσεων στο επίπεδο εξόδου, και στη συνέχεια, ανάστροφα, για τα βάρη των κρυμμένων επιπέδων, μέχρι το επίπεδο εισόδου. Η ανανέωση κάθε βάρους είναι ανάλογη της κλίσης $\frac{\partial G(n)}{\partial w_{ji}(n)}$,

δηλαδή της παραγώγου του σφάλματος ως προς το συγκεκριμένο βάρος σύνδεσης, κατά την επεξεργασία του n -οστού προτύπου, και προσδιορίζεται, σύμφωνα με τη μέθοδο της βαθύτατης καθόδου (steepest descent) [30,31] ως εξής :

$$\Delta w_{ji}(n) = -\eta \frac{\partial G(n)}{\partial w_{ji}(n)} \quad (3.47)$$

Επειδή η μέθοδος της βαθύτατης καθόδου είναι μια προσέγγιση της μεθόδου του Newton, η οποία δείχνει μεν την κατεύθυνση της ανανέωσης των βαρών, δηλαδή την κλίση της συνάρτησης σφάλματος, αλλά όχι το ακριβές βήμα της ανανέωσης (που το δείχνει η δεύτερη παράγωγος – ο πίνακας Hessian της συνάρτησης), η κλίση της συνάρτησης πολλαπλασιάζεται με μια παράμετρο, η , η οποία καθορίζει την ταχύτητα σύγκλισης, δηλαδή τον ρυθμό μάθησης (learning rate) του δικτύου.

Αποδεικνύεται ότι η ανανέωση των βαρών γράφεται ως εξής:

$$\Delta w_{ji}(n) = -\eta \delta_j(n) y_i(n) \quad (3.48)$$

όπου δ_j είναι το σφάλμα στην έξοδο του νευρώνα j του επιπέδου - έστω m - και y_i είναι η έξοδος του νευρώνα i του επιπέδου ($m-1$), ή το i -οστό στοιχείο του διανύσματος εισόδου, αν $m=1$.

Οι τιμές δ_j υπολογίζονται με βάση τις τιμές των εξόδων y των νευρώνων του δικτύου και τις τιμές των βαρών των συνδέσεων του κατά την επανάληψη n . Ειδικότερα, αν το m αναφέρεται στο επίπεδο της εξόδου, ισχύει (για βηματική σιγμοειδή συνάρτηση ενεργοποίησης των νευρώνων) για τον k -οστό νευρώνα:

$$\delta_k(n) = y_k(n)[1 - y_k(n)][d_k(n) - y_k(n)] \quad (3.49)$$

Ενώ, αν το m αναφέρεται σε κρυμμένα επίπεδα, τότε ισχύει:

$$\delta'_k(n) = y_k(n)[1 - y_k(n)] \sum_j \delta_j(n) w_{jk} \quad (3.50)$$

Στον υπολογισμό των σφαλμάτων δ'_k , στην περίπτωση αυτή, το άθροισμα του δεύτερου μέλους της εξίσωσης αφορά σε όλα τα σφάλματα δ_j του ανωτέρου $(m+1)$ επιπέδου. Αναλυτικές εξισώσεις για την ανανέωση των βαρών δίδονται, για παράδειγμα, στις αναφορές [30,31].

Σε συνέχεια των ανωτέρω, η εφαρμογή του αλγορίθμου Back-Propagation κι αφού αρχικοποιηθούν τα βάρη των συνδέσεων του δικτύου σε μικρές τυχαίες τιμές, γίνεται, για κάθε πρότυπο εισόδου, σε δύο φάσεις, στην *ορθή φορά* (forward pass) και στην *ανάστροφη φορά* (reverse pass). Η πρώτη φάση ξεκινά από το επίπεδο εισόδου με την παρουσίαση του διανύσματος εισόδου στο δίκτυο, περιλαμβάνει υπολογισμό των εξόδων όλων των νευρώνων, με βάση τις εξισώσεις (3.43), προχωρώντας στα επόμενα επίπεδα του δικτύου, ώσπου να φτάσει τελικά στο τελευταίο επίπεδο (εξόδου) και να υπολογίσει το διάνυσμα εξόδου του δικτύου, καθώς και το σφάλμα του κάθε νευρώνα αυτού του επιπέδου από τις εξισώσεις (3.49).

Η δεύτερη φάση, στη συνέχεια, ξεκινά από το επίπεδο εξόδου, διαδίδοντας τα σήματα σφάλματος, ακολουθιακά, προς τα προηγούμενα (κρυμμένα) επίπεδα - με βάση τις εξισώσεις (3.50) - και υπολογίζοντας την ανανέωση του κάθε βάρους του δικτύου, ώσπου να φτάσει τελικά στο επίπεδο εισόδου του δικτύου.

3.3.4 Μάθηση σε Νευρωνικά Δίκτυα Perceptrons με Πυρήνα

Οι αλγόριθμοι μάθησης των νευρωνικών δικτύων τύπου perceptron και multilayer perceptron μπορούν να μετατραπούν ώστε να εφαρμόζονται σε δεδομένα που έχουν μετασχηματιστεί μέσω ενός μετασχηματισμού Φ σε ένα χώρο H , μεγαλύτερης διάστασης.

$$\Phi: \mathbf{x} \rightarrow H \quad (3.51)$$

Ο χώρος αυτός χαρακτηρίζεται από τις συναρτήσεις πυρήνα:

$$k(\mathbf{x}, \mathbf{x}') := \langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle = \Phi^T(\mathbf{x}) \Phi(\mathbf{x}') \quad (3.52)$$

Εφόσον ο χώρος H είναι γραμμικά διαχωρίσιμος, μια μηχανή διανυσμάτων υποστήριξης μπορεί να εφαρμοστεί στα μετασχηματισμένα πρότυπα $\Phi(\mathbf{x})$ για την κατηγοριοποίησή τους σε διάφορες κλάσεις. Το ίδιο μπορεί να επιτευχθεί μέσω μιας μηχανής perceptron, που πλέον λαμβάνει τη μορφή kernel perceptron.

Στην συνέχεια θα δείξουμε ότι κατηγοριοποίηση σε ένα χώρο που έχει θεωρηθεί γραμμικά διαχωρίσιμος, αλλά σε πραγματικές συνθήκες δεν είναι (όπως περιγράφεται στο Κεφάλαιο 5 της διπλωματικής), μπορεί να επιτευχθεί, αν εφαρμόσουμε ένα ταξινομητή πολυεπίπεδου perceptron και βασίσουμε τη μάθησή του στον αλγόριθμο ανάστροφης διάδοσης.

Η μορφή που λαμβάνει ο αλγόριθμος backpropagation – ανάλογα με αυτήν του kernel perceptron, προκύπτει ως εξής:

Η σχέση (3.48), που επαναλαμβάνεται εδώ,

$$\Delta w_{ji}(n) = -\eta \delta_j(n) y_i(n)$$

αν συσσωρευτεί, πάνω σε όλα τα πρότυπα εισόδου n , δίνει τον υπολογισμό του βάρους w_{ji} του δικτύου, ως εξής:

$$w_{ji} = \sum_n \Delta w_{ji}(n) = -\eta \sum_n \delta_j(n) y_i(n) \quad (3.53)$$

Στην περίπτωση του επιπέδου εισόδου, το σήμα $y_i(n)$ συμβολίζει το πρότυπο εισόδου $x_i(n)$. Αν, επομένως, το πρότυπο εισόδου έχει μετασχηματιστεί σύμφωνα με την σχέση (3.51), τότε η (3.53) γράφεται ως εξής:

$$w_{ji} = -\eta \sum_n \delta_j(n) \Phi(x_i(n)) \quad (3.54)$$

Ο τύπος (3.54) θα υπολόγιζε τα βάρη των συνδέσεων μεταξύ του πρώτου κρυμμένου επιπέδου και του επιπέδου εισόδου του νευρωνικού δικτύου. Επειδή όμως η διάσταση του Φ είναι συνήθως πολύ μεγάλη, δεν χρησιμοποιείται ο τύπος αυτός, αλλά υπολογίζουμε κατευθείαν τις αντίστοιχες εξόδους του πρώτου κρυμμένου επιπέδου από τη σχέση

$$y_k = \phi\left(\sum_{i=0}^{N-1} x_i w_{ki}\right) = \phi\left(-\eta \sum_n \delta_k(n) \sum_{i=0}^{N-1} \Phi^T(x_i(n)) \Phi(x_k(n))\right) \quad (3.55)$$

Χρησιμοποιώντας τον ορισμό των συναρτήσεων πυρήνα

$$k(\mathbf{x}, \mathbf{x}') = \Phi^T(\mathbf{x}) \Phi(\mathbf{x}') \quad (3.56)$$

προκύπτει ο υπολογισμός των εξόδων y_k του πρώτου κρυμμένου επιπέδου ως εξής:

$$y_k = \phi\left(-\eta \sum_n \delta_k(n) \sum_{i=0}^{N-1} k(x_k, x_i)\right) \quad (3.57)$$

Τα υπόλοιπα βάρη και οι εξόδοι των νευρώνων των επόμενων κρυμμένων επιπέδων (αν υπάρχουν) και του επιπέδου εξόδου του νευρωνικού δικτύου υπολογίζονται με τον συνήθη αλγόριθμο backpropagation ή τις παραλλαγές του.

3.3.5 Προσαρμογή των Multilayer Perceptrons

Το στάδιο της μάθησης των νευρωνικών δικτύων είναι ένα από τα σημαντικότερα για την μετέπειτα εφαρμογή τους σε πραγματικά προβλήματα κατηγοριοποίησης και ταξινόμησης, πρόβλεψης, ανάλυσης πληροφοριών. Το στάδιο της μάθησης πρέπει να αποφύγει προβλήματα υπερ-εκπαίδευσης (overtraining) και να συντελέσει στην καλή γενίκευση (generalisation) της συμπεριφοράς του δικτύου. Αυτόματη δόμηση του δικτύου με τεχνικές κλαδέματος (pruning) ή κατασκευαστικές (constructive) [30] χρησιμοποιούνται σε συνδυασμό με τον αλγόριθμο μάθησης για το σκοπό αυτό.

Παρά την προσεκτική σχεδίαση, η απόδοση των τεχνητών νευρωνικών δικτύων, όπως και όλων των μηχανών αναπαράστασης γνώσης, σε πραγματικές συνθήκες λειτουργίας θα επηρεάζεται από τα συγκεκριμένα χαρακτηριστικά – συνθήκες του περιβάλλοντος, χαρακτηριστικά των χρηστών – τα οποία δεν είναι δυνατόν να έχουν προβλεφθεί στο στάδιο της σχεδίασης. Στο πλαίσιο αυτό αποκτά ιδιαίτερη σημασία η προσαρμογή (adaptation) των αρχιτεκτονικών των νευρωνικών δικτύων στις συνθήκες λειτουργίας.

Ενα σημαντικό χαρακτηριστικό των πολυεπίπεδων νευρωνικών δικτύων εμπρόσθιας τροφοδότησης (multilayer, feedforward networks – perceptrons) είναι ότι μπορούν να προσαρμόσουν την γνώση τους στον χώρο λειτουργίας τους, με ημι-αυτόματο τρόπο. Δεν απαιτείται, δηλαδή, η προσεκτική και χρονοβόρα επανασχεδιάσή τους, όπως, για παράδειγμα, θα χρειαζόταν μια μηχανή τεχνητής νοημοσύνης για την πιθανή επαν-διατύπωση των κανόνων, των αξιωμάτων που περιλαμβάνει. Απλά, στο συγκεκριμένο περιβάλλον, ο χρήστης, ή κάποια τοπική βάση γνώσης, ή κάποια μηχανή ανάλυσης των πληροφοριών, δίνει στο νευρωνικό δίκτυο την πληροφόρηση ότι σε κάποιες περιπτώσεις

αυτό έκανε λάθος εκτίμηση, αναφέροντας και την σωστή (επιθυμητή) απόκριση που θα περίμενε σε αυτές.

Ένα επιπλέον χαρακτηριστικό των multilayer perceptrons είναι ότι μπορούν να πετύχουν την προσαρμογή, ανεξάρτητα αν το πρόβλημα συνεχίζει να παραμένει γραμμικά διαχωρίσιμο, ή έχει γίνει μη-γραμμικά διαχωρίσιμο, σε αντίθεση με τις τεχνικές των απλών (kernel) perceptrons ή των support vector machines. Παραμένει βέβαια το πρόβλημα ότι η συμπεριφορά των δικτύων αυτών (απόδοση, προσαρμογή) παραμένει υπο-συμβολική, δηλαδή δεν επιδέχεται άμεσα σημασιολογική ερμηνεία.

Στη συνέχεια περιγράφουμε την τεχνική προσαρμογής των multilayer perceptrons [57, 52] σε πραγματικές συνθήκες, οι οποίες απαιτούν επανεκπαίδευση του δικτύου, λαμβάνοντας υπόψη πρότυπα-δεδομένα από το συγκεκριμένο περιβάλλον και συνθήκες λειτουργίας.

Ας υποθέσουμε ότι προσπαθούμε να κατηγοριοποιήσουμε, σε μια από, έστω, p κλάσεις ω , τα πρότυπα – διανύσματα εισόδου $\bar{x}_i$, τα οποία περιλαμβάνουν τα δεδομένα μας κάθε χρονική στιγμή. Το νευρωνικό δίκτυο δημιουργεί στην έξοδό του ένα διάνυσμα p -διάστατο, έστω $\bar{y}(\bar{x}_i)$

$$\bar{y}(\bar{x}_i) = \begin{bmatrix} p_{\omega_1}^i & p_{\omega_2}^i & \dots & p_{\omega_p}^i \end{bmatrix}^T \quad (3.58)$$

όπου $p_{\omega_j}^i$ συμβολίζει την πιθανότητα η i -οστή έξοδος να ανήκει στην j -οστή κατηγορία.

Ας υποθέσουμε καταρχήν ότι το νευρωνικό δίκτυο έχει εκπαιδευτεί με ένα συγκεκριμένο – μεγάλου μεγέθους – σύνολο δεδομένων (training set), έστω, $S_b = \{ (\bar{x}_1', \bar{d}_1'), \dots, (\bar{x}_{m_b}', \bar{d}_{m_b}') \}$, όπου τα διανύσματα $\bar{x}_i'$ και $\bar{d}_i'$ με $i=1,2,\dots,m_b$ συμβολίζουν το i -ιστό διάνυσμα εκπαίδευσης στην είσοδο του δικτύου και το αντίστοιχο διάνυσμα επιθυμητής εξόδου που αποτελείται από p στοιχεία.

Στη συνέχεια, ας υποθέσουμε ότι $\bar{y}(\bar{x}_i)$ συμβολίζει την έξοδο του δικτύου όταν αυτό εφαρμόζεται – σε συνθήκες λειτουργίας – στο νέο σύνολο δεδομένων. Εστω το i -οστό

δείγμα – από το νέο σύνολο δεδομένων, που έχουν συλλεγεί για επανεκπαίδευση του δικτύου, και που πιθανόν αντιστοιχούν σε κάποιο νέο χρήστη, τα χαρακτηριστικά του οποίου διαφέρουν από αυτά των χρηστών που χρησιμοποιήθηκαν στο στάδιο της αρχικής εκπαίδευσης, ή σε κάποια αλλαγή των συνθηκών του περιβάλλοντος. Για να αντιμετωπιστούν τα νέα δεδομένα, το δίκτυο πρέπει να επανεκπαιδευτεί, διατηρώντας την προηγούμενη γνώση του και προσαρμόζοντάς την στα νέα δεδομένα.

Ας υποθέσουμε ότι το διάνυσμα $\bar{w}_b$ περιλαμβάνει όλα τα βάρη του δικτύου, όπως ήταν πριν την επανεκπαίδευση, και ότι το διάνυσμα $\bar{w}_a$ περιλαμβάνει τα νέα βάρη που προήλθαν μετά την επανεκπαίδευση.

Για να γίνει η επανεκπαίδευση, ένα σύνολο επανεκπαίδευσης S_c εξάγεται από τις νέες συνθήκες, αποτελούμενο από, έστω, m_c πρότυπα εισόδου:

$$S_c = \left\{ (\bar{x}_1, \bar{d}_1), \dots, (\bar{x}_{m_c}, \bar{d}_{m_c}) \right\} \quad (3.59)$$

όπου $\bar{x}_i$ και $\bar{d}_i$ με $i=1,2,\dots,m_c$ αντιστοιχούν στο i -οστό πρότυπο εισόδου και επιθυμητή έξοδο από τα δεδομένα επανεκπαίδευσης.

Ο αλγόριθμος επανεκπαίδευσης – προσαρμογής του δικτύου – θα υπολογίσει τα νέα βάρη των συνδέσεων του δικτύου $\bar{w}_a$, ελαχιστοποιώντας την επόμενη συνάρτηση σφάλματος ως προς τα βάρη,

$$E_a = E_{c,a} + \eta E_{f,a} \quad (3.60)$$

$$E_{c,a} = \frac{1}{2} \sum_{i=1}^{m_c} \left\| \bar{z}_a(\bar{x}_i) - \bar{d}_i \right\|_2 \quad (3.61)$$

$$E_{f,a} = \frac{1}{2} \sum_{i=1}^{m_b} \left\| \bar{z}_a(\bar{x}'_i) - \bar{d}'_i \right\|_2 \quad (3.62)$$

Η συνάρτηση σφάλματος, που ελαχιστοποιείται, αποτελείται από δύο όρους: ο $E_{c,a}$ συμβολίζει το σφάλμα που εμφανίζεται πάνω στο – τωρινό – σύνολο επανεκπαίδευσης S_c , ενώ ο $E_{f,a}$ συμβολίζει το αντίστοιχο σφάλμα που δημιουργείται στην αρχική γνώση του δικτύου, δηλαδή στο σύνολο εκπαίδευσης S_b .

Τα $\bar{z}_a(\bar{x}_i)$ και $\bar{z}_a(\bar{x}'_i)$ συμβολίζουν τις εξόδους του δικτύου μετά την επανεκπαίδευση, που αντιστοιχούν στα πρότυπα εισόδου $\bar{x}_i$ και $\bar{x}'_i$, ενώ τα βάρη του δικτύου αποτελούν το διάνυσμα $\bar{w}_a$. Ομοίως το $\bar{z}_b(\bar{x}_i)$ αναπαριστάνει την έξοδο του δικτύου με βάρη συνδέσεων $\bar{w}_b$, όταν το πρότυπο εισόδου είναι το $\bar{x}_i$. Την πρώτη φορά που γίνεται προσαρμογή της γνώσης, δηλ. των βαρών των συνδέσεων, του δικτύου, το $\bar{z}_b(\bar{x}_i)$ είναι ίσο με το $\bar{y}(\bar{x}_i)$. Η παράμετρος η εδώ αποτελεί έναν παράγοντα που καθορίζει τη σημασία του τωρινού συνόλου δεδομένων (επανεκπαίδευσης) σε σύγκριση με το αρχικό σύνολο δεδομένων εκπαίδευσης, ενώ το $\|\cdot\|_2$ συμβολίζει την L_2 - νόρμα.

Ο σκοπός της επανεκπαίδευσης είναι η ελαχιστοποίηση της παραπάνω συνάρτησης σφάλματος και ο υπολογισμός των νέων βαρών $\bar{w}_a$. Ο αλγόριθμος έχει προταθεί στην αναφορά [57].

Ας υποθέσουμε ότι αρκεί μια μικρή μεταβολή των (αρχικών) βαρών των συνδέσεων του δικτύου $\bar{w}_b$ για την επίτευξη καλής απόδοσης του δικτύου στις νέες συνθήκες που χρησιμοποιείται. Τότε θα είναι:

$$\bar{w}_a = \bar{w}_b + \Delta \bar{w} \quad (3.63)$$

όπου τα $\Delta \bar{w}$ θα είναι μικρές ποσότητες. Αυτή η υπόθεση οδηγεί σε μια αναλυτική και βολική επίλυση του προβλήματος της εκτίμησης του διανύσματος $\bar{w}_a$, επειδή επιτρέπει γραμμικοποίηση της μη γραμμικής συνάρτησης σφάλματος γύρω από την τωρινή θέση των τιμών των βαρών στον χώρο ελαχιστοποίησης, με ανάπτυξη σε σειρά Taylor πρώτης τάξης.

Οι εξισώσεις (3.60) – (3.62) υποδηλώνουν ότι τα νέα βάρη του δικτύου υπολογίζονται λαμβάνοντας υπόψη τόσο την παρούσα κατάσταση, όσο και την προηγούμενη γνώση του δικτύου. Για να τονιστεί η σημασία του συνόλου δεδομένων επανεκπαίδευσης (το οποίο γενικά είναι μικρής διάστασης, πολύ μικρότερης από τη διάσταση του συνόλου των δεδομένων της αρχικής εκπαίδευσης του δικτύου), ο πρώτος όρος της συνάρτησης σφάλματος μπορεί να αντικατασταθεί από τον περιορισμό οι πραγματικές εξοδοι του δικτύου να είναι ίσες με τις επιθυμητές, δηλαδή:

$$z_a(\bar{x}_i) = d_i \quad i = 1, \dots, m_c \quad (3.64)$$

για όλα τα πρότυπα του συνόλου S_c .

Μέσω της γραμμικοποίησης, η επίλυση των εξισώσεων (3.64) ως προς τις ανανεώσεις των βαρών του δικτύου αποδεικνύεται ότι είναι ισοδύναμη με την επίλυση ενός συστήματος γραμμικών εξισώσεων

$$\bar{c} = \mathbf{A} \cdot \Delta \bar{w} \quad (3.65)$$

όπου το διάνυσμα $\bar{c}$ και ο πίνακας $\mathbf{A}$ περιλαμβάνουν εκφράσεις των προηγούμενων τιμών των βαρών των συνδέσεων του δικτύου.

Ειδικότερα,

$$\bar{c} = \left[d_1 \cdots d_{m_c} \right]^T - \left[z_b(\bar{x}_1) \cdots z_b(\bar{x}_{m_c}) \right]^T \quad (3.66)$$

Επιπλέον, η ελαχιστοποίηση του δεύτερου όρου της συνάρτησης σφάλματος, ο οποίος εκφράζει την επίδραση των νέων βαρών του δικτύου στο αρχικό σύνολο εκπαίδευσης του δικτύου S_b , ισοδυναμεί με ελαχιστοποίηση του απολύτου της διαφοράς των σφαλμάτων - πάνω στο σύνολο δεδομένων εκπαίδευσης S_b - που προκύπτουν από την εφαρμογή σε αυτό του αρχικού και του επανεκπαιδευμένου δικτύου. Ισοδύναμα αυτό σημαίνει ότι οι ανανεώσεις των βαρών προκύπτουν από την ελαχιστοποίηση της επόμενης συνάρτησης σφάλματος

$$E_S = \|E_{f,a} - E_{f,b}\|_2 \quad (3.67)$$

Όπου το σφάλμα $E_{f,b}$ ορίζεται όμοια με το σφάλμα $E_{f,a}$, με το σήμα $\bar{z}_a$ να αντικαθίσταται με το $\bar{z}_b$.

Μπορεί να αποδειχτεί ότι η ανωτέρω συνάρτηση σφάλματος γράφεται ως εξής:

$$E_S = \frac{1}{2} (\Delta \bar{w})^T \cdot \mathbf{K}^T \cdot \mathbf{K} \cdot \Delta \bar{w} \quad (3.68)$$

όπου τα στοιχεία του πίνακα $\mathbf{K}$ εκφράζονται με βάση τα προηγούμενα βάρη του δικτύου $\bar{w}_b$ και τα πρότυπα εισόδου στο S_b . Η συνάρτηση σφάλματος που ορίζεται ανωτέρω

είναι κυρτή, επειδή έχει τετραγωνική μορφή. Επομένως, οι ανανεώσεις των βαρών μπορούν να υπολογιστούν με ελαχιστοποίηση της (3.68), με τους περιορισμούς που τίθενται από την (3.65) στο πλαίσιο της ελαχιστοποίησης της (3.60). Η μέθοδος gradient projection [57] μπορεί να χρησιμοποιηθεί στο πλαίσιο αυτό για να υπολογίσει τις ανανεώσεις των βαρών.

Οι επόμενες παρατηρήσεις δίνουν μερικές επιπλέον πληροφορίες για τη διαδικασία προσαρμογής των βαρών του νευρωνικού δικτύου:

- 1) Απαραίτητη προϋπόθεση για την προσαρμογή του δικτύου σε νέες συνθήκες είναι η δημιουργία ενός νέου συνόλου δεδομένων – επανεκπαίδευσης S_c .
- 2) Οι ανανεώσεις των βαρών των συνδέσεων του δικτύου υπολογίζονται, λαμβάνοντας υπόψη τόσο την τωρινή πληροφορία (τα δεδομένα στο σύνολο S_c) όσο και την προηγούμενη γνώση (τα δεδομένα στο σύνολο S_b).
- 3) Επειδή το σύνολο δεδομένων S_c περιέχει πληροφορίες μόνο για τις συγκεκριμένες (νέες) συνθήκες της εφαρμογής, δεν μπορεί να θεωρηθεί χαρακτηριστικό γενικά για το πρόβλημα το οποίο εξετάζεται. Μπορεί, επομένως, να χρησιμοποιηθεί για ανανέωση της γνώσης που έχουμε για το πρόβλημα - στις συγκεκριμένες συνθήκες - αλλά όχι να αποτελέσει προϋπάρχουσα γενική γνώση για την επίλυση του προβλήματος.
- 4) Αντιθέτως, το σύνολο των αρχικών δεδομένων εκπαίδευσης S_b , το οποίο έχει σχεδιαστεί με εκτενή πειραματισμό, μπορεί να αποτελεί αρχική συνθήκη για την επίλυση του προβλήματος σε οποιεσδήποτε συνθήκες. Επομένως, σε κάθε νέα προσαρμογή του νευρωνικού δικτύου, εφόσον ελεγχθεί ότι είναι διαφορετική από τις προηγούμενες, δημιουργείται ένα νέο σύνολο επανεκπαίδευσης S_c , διαγράφοντας το παλαιό και τα νέα βάρη εκτιμώνται με βάση το νέο σύνολο δεδομένων S_c και το παλαιό S_b , το οποίο παραμένει σταθερό κατά τη λειτουργία του νευρωνικού δικτύου.

4. Μεταφορά Συμβολικής Γνώσης σε Συστήματα Μηχανικής Μάθησης

Στο κεφάλαιο αυτό παρουσιάζονται μεθοδολογίες που οδηγούν στη σύνδεση αναπαραστάσεων γνώσης με συστήματα μηχανικής μάθησης, βασισμένες στα προαναφερθέντα στα Κεφάλαια 2 και 3 και ειδικότερα στις αρχές κατασκευής πυρήνων.

Βασικός στόχος είναι ο ορισμός πυρήνων που εμπεριέχουν την ομοιότητα μεταξύ των ατόμων μιας οντολογίας, με εκμετάλλευση περισσότερο σημασιολογικών χαρακτηριστικών της γλώσσας που χρησιμοποιείται για αναπαράσταση, παρά συντακτικών.

4.1 Ορισμός πυρήνα για την περιγραφική γλώσσα ALC

Μια πρώτη μέθοδος [35] δίνεται για την περιγραφική γλώσσα ALC η οποία στηρίζεται τόσο στη σύνταξη, όσο και στη σημασιολογία που προκύπτει από το ABox.

Αρχικά δίδονται κάποιοι επιπλέον ορισμοί που θα χρειαστούν στη συνέχεια για τον υπολογισμό των πυρήνων για τη γλώσσα ALC.

Στη μέθοδο αυτή χρησιμοποιούνται ονόματα από το σύνολο $N_C = \{P, P_1, \dots\}$ για τις ατομικές έννοιες και ονόματα από το σύνολο $N_R = \{R, S, \dots\}$ για τους ατομικούς ρόλους.

Ορισμός – Πιο Συγκεκριμένη Έννοια (Most Specific Concept)

Δεδομένου ενός ABox A και ενός ατόμου a , η πιο συγκεκριμένη έννοια (most specific concept) του a με βάση το A είναι η έννοια C , η οποία γράφεται ως $MSC_A(a)$, τέτοια ώστε για $A \models C(a)$ και $\forall D$ τέτοιο ώστε $A \models D(a)$, ισχύει ότι $C \sqsubseteq D$.

Σε γενικευμένα κυκλικά ABoxes που αναπαριστώνται σε μια εκφραστική Περιγραφική Λογική που έχει τον υπαρξιακό περιορισμό, το MSC δεν μπορεί να εκφραστεί σαν πεπερασμένη περιγραφή, γι' αυτό μπορεί μόνο να προσεγγιστεί. Δεδομένου ότι η ύπαρξη του MSC για ένα άτομο με βάση ένα ABox δεν είναι εγγυημένη, γενικά θεωρούμε μια προσέγγιση του MSC μέχρι κάποιο βάθος k , που γράφεται MSC^k . Έχει αποδειχτεί ότι το μέγιστο βάθος k αντιστοιχεί στο βάθος του ABox που χρησιμοποιούμε. Στα ακόλουθα θα συμβολίζουμε μια προσέγγιση στο μέγιστο βάθος με MSC^* .

Γενικά μπορούν να δοθούν πολλές σημασιολογικά ισοδύναμες περιγραφές (που όμως διαφέρουν συντακτικά) για την ίδια έννοια. Παρόλα αυτά, οι ταυτόσημες σημασιολογικά έννοιες μπορούν να περιοριστούν σε μια κανονική μορφή χρησιμοποιώντας κανόνες που διατηρούν την ισοδυναμία, όπως για παράδειγμα $\forall R.C_1 \sqcap \forall R.C_2 \equiv \forall R.(C_1 \sqcap C_2)$.

Παρακάτω θα χρησιμοποιήσουμε τους ακόλουθους συμβολισμούς:

- $\text{prim}(C)$: συμβολίζει το σύνολο όλων των ατομικών εννοιών (και των αρνήσεών τους) που εμφανίζονται στο αξίωμα ορισμού μιας έννοιας C και δεν είναι φωλιασμένες σε κάποιον υπαρξιακό ή καθολικό ποσοδείκτη.
- $\text{val}_R(C) = C_1 \sqcap \dots \sqcap C_n$ αν υπάρχει ένας περιορισμός τιμής $\forall R.(C_1 \sqcap \dots \sqcap C_n)$, που εμφανίζεται στο αξίωμα ορισμού της έννοιας C (και δεν είναι φωλιασμένος σε κάποιο άλλο καθολικό ή σε κάποιον υπαρξιακό ποσοδείκτη), αλλιώς $\text{val}_R(C) = \top$.
- $\text{ex}_R(C)$: είναι το σύνολο των περιγραφών C' που εμφανίζονται σε υπαρξιακούς περιορισμούς $\exists R.C'$, οι οποίοι εμφανίζονται στον ορισμό της έννοιας C και δεν είναι φωλιασμένοι σε άλλους υπαρξιακούς ή καθολικούς ποσοδείκτες.

Ακολούθως, φαίνεται η μετατροπή μιας έννοιας σε κανονική ALC μορφή.

4.1.1 Κανονική Μορφή ALC

Μια περιγραφή D είναι σε ALC κανονική μορφή, αν $D \equiv \perp$ ή $D = \top$ ή

$D = C_1 \sqcup \dots \sqcup C_n$ με,

$$C_i = \prod_{P \in \text{prim}(C_i)} P \sqcap \prod_{R \in N_R} (\forall R. \text{val}_R(C_i)) \sqcap \prod_{E \in \text{ex}_R(C_i)} \exists R.E \quad (4.1)$$

όπου, για όλα τα $i = 1, \dots, n$, $C_i \not\equiv \perp$ και για κάθε $R \in N_R$, $\text{val}_R(C_i)$ και κάθε υπο-περιγραφή στο $\text{ex}_R(C_i)$ είναι σε κανονική μορφή.

Δεδομένης μιας ALC περιγραφής σε κανονική μορφή, ένα ALC δέντρο περιγραφής (description tree) είναι ένα AND-OR δέντρο. Εναλλάσσει διαζευκτικούς ($\sqcup$) και συζευκτικούς ($\sqcap$) κόμβους και έχει τη ρίζα του σε ένα διαζευκτικό κόμβο (σύμφωνα με την κανονική μορφή).

Οι διαζευκτικοί κόμβοι του δέντρου αυτού έχουν ως ετικέτα ένα σύνολο $\text{prim}(\cdot)$ και:

- για κάθε $R \in N_R$, διακλαδίζεται μια ακμή με ετικέτα $\forall R$ στο υπο-δέντρο του $\text{val}_R(\cdot)$,
- για κάθε $E \in \text{ex}_R(\cdot)$ διακλαδίζεται μια ακμή με ετικέτα $\exists R$ στο υπο-δέντρο που σχετίζεται με το E .

Μια άδεια ετικέτα σε έναν κόμβο είναι ισοδύναμη με την καθολική έννοια ($\top$).

4.1.2 Ένας πυρήνας για την ALC

Ο ορισμός ενός πυρήνα για ALC περιγραφές βασίζεται στην AND-OR δενδρική δομή των περιγραφών, όπως γίνεται για τους κλασσικούς δέντρα-πυρήνες, όπου η ομοιότητα

μεταξύ των δέντρων στηρίζεται στον αριθμό των παρόμοιων υποδέντρων. Ένας πυρήνας βασισμένος στο AND-OR δέντρο, όμως, θα αποτελούσε ένα συντακτικό μέτρο για τον υπολογισμό της ομοιότητας μεταξύ των ατόμων της οντολογίας μας και, επομένως, θα εξαρτιόταν από τη συγκεκριμένη περιγραφική γλώσσα που χρησιμοποιούμε. Ένας τέτοιος πυρήνας δεν εμπεριέχει τη σημασιολογική φύση εκφραστικών περιγραφικών γλωσσών όπως είναι η *ALC*. Ξεκινώντας από την ιδέα του συνελκτικού πυρήνα (convolution kernel) χρησιμοποιείται η κανονική μορφή για να αποσυντεθούν σύνθετες περιγραφές, σε κάθε επίπεδο, σε υπο-περιγραφές. Τρεις περιπτώσεις είναι δυνατές για κάθε επίπεδο. Το επίπεδο να:

- είναι μια ένωση εννοιών,
- είναι μια τομή εννοιών,
- να αποτελείται από ατομικές έννοιες.

Στη συνέχεια δίδουμε τον ορισμό του *ALC* πυρήνα:

Δοθέντων δύο περιγραφών σε κανονική μορφή $D_1 = \prod_{i=1}^n C_i^1$ και $D_2 = \prod_{j=1}^m C_j^2$ και μιας ερμηνείας I , ο *ALC* πυρήνας που βασίζεται στο I είναι η συνάρτηση $k_I: X \times X \mapsto \mathbb{R}$ η οποία ορίζεται επαγωγικά ως εξής:

- σε επίπεδο ένωσης :

$$k_I(D_1, D_2) = \lambda \sum_{i=1}^n \sum_{j=1}^m k_I(C_i^1, C_j^2) \quad (4.2)$$

με $\lambda \in [0,1]$.

- σε επίπεδο τομής :

$$k_I(C^1, C^2) = \prod_{\substack{P_1 \in \text{prim}(C^1) \\ P_2 \in \text{prim}(C^2)}} k_I(P_1, P_2) \cdot \prod_{R \in N_R} k_I(\text{val}_R(C^1), \text{val}_R(C^2)) \cdot$$

$$\prod_{R \in N_R} \sum_{\substack{C_i^1 \in ex_R(C^1) \\ C_j^2 \in ex_R(C^2)}} k_I(C_i^1, C_j^2) \quad (4.3)$$

- για ατομικές έννοιες :

$$k_I(P_1, P_2) = k_{set}(P_1^I, P_2^I) = |P_1^I \cap P_2^I| \quad (4.4)$$

όπου k_{set} είναι ο πυρήνας που έχει οριστεί παραπάνω για δομές συνόλων (4.2). Αυτή η περίπτωση περιέχει επίσης την άρνηση ατομικών εννοιών χρησιμοποιώντας τη σχέση

$$(\neg P)^I = \Delta^I \setminus P^I. \quad (4.5)$$

Το σκεπτικό στον ορισμό του πυρήνα είναι ότι η ομοιότητα μεταξύ των περιγραφών σε επίπεδο ένωσης βρίσκεται παίρνοντας το άθροισμα των τιμών ομοιότητας μεταξύ όλων των ζευγών των εννοιών που είναι σε διαζευκτική μορφή από κάθε περιγραφή. Ο όρος λ χρησιμοποιείται για να μειώσουμε την ομοιότητα των υπο-περιγραφών ανάλογα με το επίπεδο στο οποίο βρίσκονται. Με άλλα λόγια, η τάξη του όρου λ αυξάνεται όταν μια έννοια είναι φωλιασμένη σε έναν υπαρξιακό ή καθολικό ποσοδείκτη και άρα η τιμή του μειώνεται αφού το λ έχει τιμή μεταξύ του μηδέν και του ένα.

Ο πυρήνας σε επίπεδο τομής βρίσκεται υπολογίζοντας την ομοιότητα μεταξύ δύο περιγραφών που του δίνονται σαν ορίσματα, διαφοροποιώντας τις ατομικές έννοιες από αυτές που αναφέρονται σε περιορισμούς τιμής και από αυτές που αναφέρονται σε υπαρξιακούς περιορισμούς. Αυτές οι τιμές ομοιότητας πολλαπλασιάζονται μεταξύ τους και αυτό γίνεται γιατί πρέπει να ικανοποιούνται όλοι οι περιορισμοί σε συζευκτικό επίπεδο. Η ομοιότητα μεταξύ ατομικών εννοιών μετριέται ως η τομή των ερμηνειών τους (που είναι σύνολα) χρησιμοποιώντας τον πυρήνα τομής συνόλων.

Ο πυρήνας μπορεί να επεκταθεί και στην περίπτωση των ατόμων $a, b \in \text{Ind}(A)$, όπου $\text{Ind}(A)$ είναι το σύνολο των ατόμων στο A , λαμβάνοντας υπόψη τις προσεγγίσεις των πιο συγκεκριμένων εννοιών (most specific concepts):

$$k_I(a, b) = k_I(MSC^*(a), MSC^*(b)) \quad (4.6)$$

Στη συνέχεια θα αποδειχτεί ότι ο παραπάνω πυρήνας είναι έγκυρος (θετικά ορισμένος) για το χώρο των ALC περιγραφών.

Πέρα από τον ορισμό που έχουμε δώσει στο Κεφάλαιο 3 για θετικά ορισμένους πυρήνες, μπορούμε να εκμεταλλευτούμε και τις ιδιότητες κλεισίματος της κλάσης των θετικά ορισμένων πυρήνων, όπως έχει αναφερθεί στο Κεφάλαιο 3. Κάποιες από τις ιδιότητες αυτές τις οποίες επαναλαμβάνουμε εδώ είναι ο πολλαπλασιασμός ενός έγκυρου (θετικά ορισμένου) πυρήνα με μια σταθερά, ο πολλαπλασιασμός και η πρόσθεση δύο έγκυρων πυρήνων.

Στη συνέχεια αποδεικνύεται ότι ο παραπάνω πυρήνας είναι έγκυρος στο χώρο υποθέσεων μας. Επισημαίνεται ότι ο βασικός πυρήνας είναι ορισμένος σε ερμηνείες ατομικών εννοιών.

Πρόταση

Η συνάρτηση k_I είναι ένας έγκυρος πυρήνας για το χώρο X των ALC περιγραφών.

Απόδειξη

Η εγκυρότητα επαληθεύεται αποδεικνύοντας ότι η συνάρτηση πυρήνα k_I είναι συμμετρική και θετικά ορισμένη. Πράγματι η συνάρτηση πυρήνα k_I είναι συμμετρική, αφού οι τελεστές που εμπλέκονται στον υπολογισμό της από τις τρεις συναρτήσεις είναι αντιμεταθετικοί (commutative). Επίσης είναι θετικά ορισμένη και αυτό αποδεικνύεται με επαγωγή στο βάθος d των περιγραφών (μέγιστο αριθμό επιπέδων ή μέγιστο βάθος φωλιάσματος) :

- **$d=0$:** Αυτή η περίπτωση σχετίζεται με τη συνάρτηση για ατομικές έννοιες. Πρόκειται για συνέλιξη που στηρίζεται στον πυρήνα συνόλου ανάμεσα σε απλές ατομικές ερμηνείες εννοιών και η οποία είναι θετικά ορισμένη. Ο πολλαπλασιασμός με τη σταθερά λ δεν επηρεάζει αυτήν την ιδιότητα.
- **$d > 0$:** Από υπόθεση θεωρούμε ότι η k_1 είναι θετικά ορισμένη για περιγραφές βάθους $d-1$. Αν οι περιγραφές είναι σε κανονική μορφή, το k_1 μπορεί να υπολογιστεί, αν στηριχτούμε στη διαζευκτική ή συζευκτική έκδοση στο ανώτερο επίπεδο (χωρίς να λαμβάνουμε υπόψιν έννοιες που είναι φωλιασμένες σε υπαρξιακούς ή καθολικούς ποσοδείκτες). Στην πρώτη περίπτωση (δηλαδή στο επίπεδο ένωσης) η συνάρτηση είναι συνέλιξη μιας συνάρτησης από πιο απλές περιγραφές (μέγιστο βάθος μικρότερο από d) και είναι θετικά ορισμένη με βάση την υπόθεση της επαγωγής, από το κλείσιμο των θετικά ορισμένων συναρτήσεων. Στη δεύτερη περίπτωση (δηλαδή στο επίπεδο τομής), η συνάρτηση είναι γινόμενο θετικά ορισμένων συναρτήσεων για ατομικές έννοιες, ή αποτελείται από αθροίσματα θετικά ορισμένων συναρτήσεων για απλούστερες περιγραφές (μέγιστο βάθος μικρότερο από d), και είναι θετικά ορισμένη από την υπόθεση της επαγωγής, από το κλείσιμο των θετικά ορισμένων πυρήνων.

Έτσι αποδεικνύεται επαγωγικά ότι η συνάρτηση είναι θετικά ορισμένη για περιγραφές οποιουδήποτε βάθους.

Στη συνέχεια θα ορίσουμε πυρήνες που εμπεριέχουν την ομοιότητα μεταξύ των ατόμων μιας οντολογίας εκμεταλλευόμενοι μόνο σημασιολογικές ιδιότητες της γλώσσας που χρησιμοποιούμε για αναπαράσταση (που στη συγκεκριμένη περίπτωση είναι η OWL) και όχι συντακτικές, όπως κάναμε στον ορισμό για τη γλώσσα ALC - στον οποίο, είναι φανερό η εξάρτηση του πυρήνα από τη σύνταξη της γλώσσας ALC - πράγμα το οποίο περιορίζει τη γενικότητα του πυρήνα αυτού κάνοντάς τον ικανό να εφαρμοστεί μόνο στη συγκεκριμένη περιγραφική γλώσσα (ALC) και σε υπογλώσσες της και όχι σε πιο εκφραστικές περιγραφικές γλώσσες.

4.2 Πυρήνας για τη Γλώσσα OWL

Η ιδέα πίσω από αυτούς τους πυρήνες [38] είναι ότι σε σημασιολογικό επίπεδο, παρόμοια άτομα θα συμπεριφέρονται παρόμοια ως προς τις ίδιες έννοιες. Αυτή η ιδέα θα αναλυθεί περισσότερο παρακάτω.

4.2.1 Ορισμός Πυρήνα

Έστω ότι με $K = \langle T, A \rangle$ συμβολίζουμε τη βάση γνώσης μας, όπου T είναι το TBox και A το ABox αυτής και έστω ότι $\text{Ind}(A)$ είναι το σύνολο των ατόμων στο A . Δεδομένου του ακόλουθου συνόλου περιγραφών εννοιών $F = \{ F_1, F_2, \dots, F_m \}$ στο T , μια οικογένεια συναρτήσεων πυρήνα $k_p^F : \text{Ind}(A) \times \text{Ind}(A) \mapsto [0,1]$ ορίζεται ως ο L_p μέσος απλούστερων συναρτήσεων, ως ακολούθως:

$$\forall a, b \in \text{Ind}(A) \quad k_p^F(a, b) := \left[\sum_{i=1}^m \left| \frac{\kappa_i(a, b)}{m} \right|^p \right]^{1/p} \quad (4.7)$$

όπου $p > 0$ και, $\forall i \in \{1, \dots, m\}$, η αντίστοιχη (απλούστερη) συνάρτηση πυρήνα κ_i ορίζεται ως εξής, $\forall a, b \in \text{Ind}(A)$:

$$\kappa_i(a, b) = \begin{cases} 1 & (F_i(a) \in A \wedge F_i(b) \in A) \vee (\neg F_i(a) \in A \wedge \neg F_i(b) \in A) \\ 0 & (F_i(a) \in A \wedge \neg F_i(b) \in A) \vee (\neg F_i(a) \in A \wedge F_i(b) \in A) \\ 1/2 & \text{Αλλιώς} \end{cases} \quad (4.8)$$

ή μοντελο-θεωρητικά:

$$\kappa_i(a,b) = \begin{cases} 1 & (K \models F_i(a) \wedge K \models F_i(b)) \vee (K \models \neg F_i(a) \wedge K \models \neg F_i(b)) \\ 0 & (K \models F_i(a) \wedge K \models \neg F_i(b)) \vee (K \models \neg F_i(a) \wedge K \models F_i(b)) \\ 1/2 & \text{Αλλιώς} \end{cases} \quad (4.9)$$

Από τον παραπάνω τύπο βλέπουμε ότι, επιλέγοντας τις βέλτιστες περιγραφές εννοιών, δηλαδή αυτές που συμβάλλουν στη διαφοροποίηση των ατόμων της Βάσης Γνώσης, για κάθε συνδυασμό δυο ατόμων από το ABox η συνάρτηση ομοιότητας κ_i για την F_i περιγραφή έννοιας επιστρέφει 1 (μονάδα): αν και τα δύο άτομα είναι στιγμιότυπα της έννοιας F_i , ή της άρνησης της έννοιας F_i , είτε αυτό προκύπτει ρητά από το ABox, είτε προκύπτει χρησιμοποιώντας τα αξιώματα του TBox μέσα από τη διαδικασία συλλογιστικής. Η συνάρτηση ομοιότητας επιστρέφει 0 (μηδέν): αν το ένα άτομο, π.χ., το a είναι στιγμιότυπο της έννοιας F_i , ενώ το b δεν είναι (είναι στιγμιότυπο της έννοιας $\neg F_i$), ή και το αντίστροφο.

Το σκεπτικό για τα ανωτέρω είναι ότι η ομοιότητα μεταξύ των ατόμων καθορίζεται από την ομοιότητά τους με βάση κάθε έννοια από ένα δεδομένο αριθμό χαρακτηριστικών. Δύο άτομα είναι όμοια - σε μέγιστο βαθμό - με βάση μια έννοια F_i , αν έχουν την ίδια συμπεριφορά, με άλλα λόγια είτε και τα δύο είναι στιγμιότυπα της έννοιας F_i , ή και τα δύο είναι στιγμιότυπα της άρνησης της έννοιας αυτής. Αντίστοιχα, δύο άτομα είναι όμοια - σε ελάχιστο βαθμό - όταν το ένα είναι στιγμιότυπο της έννοιας F_i και το άλλο της άρνησης αυτής της έννοιας και αντίστροφα.

Τέλος εξαιτίας της υπόθεσης ανοικτού κόσμου, όταν η μηχανή συλλογιστικής δεν μπορεί να συμπεράνει για το αν ένα άτομο είναι στιγμιότυπο μιας έννοιας - επομένως και οι δύο δυνατότητες είναι ανοιχτές - η συνάρτηση ομοιότητας κ_i παίρνει την τιμή $1/2$, μια ενδιάμεση τιμή, δηλαδή, που αντανακλά αυτήν την αβεβαιότητα.

Όπως αναφέρθηκε, ο έλεγχος στιγμιότυπου (instance checking), ο οποίος αφορά την εύρεση αν ένα άτομο είναι στιγμιότυπο μιας έννοιας, χρησιμοποιείται για να βρούμε την τιμή των απλών συναρτήσεων ομοιότητας k_i . Ο έλεγχος αυτός, όμως, είναι υπολογιστικά πολύπλοκος (εξαρτάται και από την συγκεκριμένη περιγραφική γλώσσα που χρησιμοποιείται). Εναλλακτικά, ειδικά για οντολογίες οι οποίες είναι πλούσιες σε ισχυρισμούς που δηλώνονται ρητά στο ABox, ένα απλό κοίταγμα μπορεί να είναι αρκετό, όπως προτείνεται από τον πρώτο ορισμό (4.8) των k_i συναρτήσεων.

Αξίζει να σημειωθεί ότι η παραπάνω οικογένεια πυρήνων είναι παραμετροποιημένη ως προς την επιλογή των χαρακτηριστικών. Συγκεκριμένα, οι πυρήνες αυτοί μπορούν να παραμετροποιηθούν σε κάθε σύνολο σύνθετων περιγραφών εννοιών, συμπεριλαμβανομένων των εννοιών με άρνηση. Επίσης λαμβάνουν υπόψη τους την περίπτωση που δεν είναι σίγουρο αν ένα άτομο είναι στιγμιότυπο μιας έννοιας ή όχι, όπως φαίνεται στις (4.8) - (4.9). Η επιλογή των εννοιών που θα συμπεριληφθούν στην ομάδα χαρακτηριστικών F είναι σημαντική και μπορεί να είναι το αντικείμενο ενός αρχικού προβλήματος μάθησης (επιλογή χαρακτηριστικών).

Θα πρέπει να σημειωθεί ότι οι παραπάνω πυρήνες δεν εξαρτώνται από τη γλώσσα αναπαράστασης που χρησιμοποιείται, αφού είναι ο έλεγχος στιγμιότυπου που αποφαίνεται για το αν ένα άτομο είναι στιγμιότυπο κάποιας έννοιας.

Η πιο σημαντική ιδιότητα μιας συνάρτησης πυρήνα είναι - όπως έχει προαναφερθεί - η εγκυρότητά της (αν είναι δηλαδή θετικά ορισμένη).

Πρόταση

Δεδομένου ενός ακεραίου $p > 0$ και μιας ομάδας χαρακτηριστικών F , η συνάρτηση k_p^F είναι ένας έγκυρος (θετικά ορισμένος) πυρήνας.

Απόδειξη

Ένας τρόπος απόδειξης είναι να δείχτεί ότι η συνάρτηση k_p^F είναι θετικά ορισμένη σύμφωνα με τον ορισμό του Κεφαλαίου 3 (δηλαδή τη σχέση 3.6). Ένας πιο εύκολος τρόπος για να δείχτεί αυτή η ιδιότητα, είναι να δείχτεί ότι η συνάρτηση μπορεί να σχηματιστεί ως σύνθεση απλούστερων έγκυρων πυρήνων, χρησιμοποιώντας τελεστές που εγγυώνται το κλείσιμο (closure) όσον αφορά σε αυτήν την ιδιότητα. Συγκεκριμένα, δεδομένου ότι οι απλές συναρτήσεις πυρήνα k_i ($i = 1, \dots, n$) αντιστοιχούν σε πυρήνες ταιριάσματος (matching kernels), η συνάρτηση k_p^F είναι θετικά ορισμένη αφού προκύπτει από αυτές χρησιμοποιώντας τους τελεστές του αθροίσματος, του πολλαπλασιασμού με μια σταθερά και του πολλαπλασιασμού μεταξύ τους έγκυρων πυρήνων.

4.2.2 Πυρήνες Περιγραφικών Λογικών και το Πρόβλημα Ταξινόμησης

Όπως έχει αναφερθεί και στη θεωρία οι μηχανές SVMs που στηρίζονται σε συναρτήσεις πυρήνα μπορούν, με αποτελεσματικό τρόπο, να αντιστοιχίσουν τα στιγμιότυπα σε ένα χώρο χαρακτηριστικών, στον οποίο αυτά μπορούν να διαχωριστούν με τη βοήθεια ενός γραμμικού ταξινομητή. Με τη χρήση της συνάρτησης πυρήνα, που ορίστηκε ανωτέρω, σχεδιάζεται στη συνέχεια μια μηχανή SVM η οποία μπορεί να λύσει το πρόβλημα που διατυπώνεται τυπικά κατωτέρω:

Έστω ότι $K = \langle T, A \rangle$ είναι η βάση γνώσης, $Ind(A)$ το σύνολο όλων των ατόμων που εμφανίζονται στο A και $C = \{C_1, \dots, C_s\}$ είναι το σύνολο (ατομικών και σύνθετων) εννοιών στο K .

Το πρόβλημα ταξινόμησης ορίζεται ως ακολούθως:

Δεδομένου ενός ατόμου $a \in Ind(A)$,

προσδιόρισε τα $\{C_1, \dots, C_t\} \subseteq C$, ούτως ώστε $K \models C_i(a) \forall i \in \{1, \dots, t\}$ (4.10)

4.3 Ένας Άλλος Πυρήνας για τη Γλώσσα OWL

Ένας άλλος ορισμός πυρήνα για την γλώσσα OWL [36] στηρίζεται στην παρατήρηση ότι η πιθανότητα δύο στιγμιότυπα να είναι όμοια αυξάνεται όσο περισσότερα κοινά χαρακτηριστικά έχουν. Εστω I το σύνολο των ατόμων σε μια οντολογία O , B το σύνολο των ατομικών κλάσεων $C \subseteq I$, P_O το σύνολο των ιδιοτήτων αντικειμένων $p \subseteq I \times I$ και P_D το σύνολο των ιδιοτήτων τύπων δεδομένων $p \subseteq I \times \text{range}(d)$, όπου d τύπος δεδομένων.

Στη συνέχεια παρουσιάζονται τέσσερα επίπεδα ομοιότητας των στιγμιοτύπων, κάθε ένα από τα οποία ορίζεται χρησιμοποιώντας ένα συγκεκριμένο πυρήνα συνόλου (set kernel) ή πυρήνα γινομένου (crossproduct kernel).

Πιο αναλυτικά, το *επίπεδο ταυτοτικού πυρήνα* (Identity Layer Kernel) απλά λαμβάνει υπόψη του αν δύο στιγμιότυπα ταυτίζονται. *Ο πυρήνας στο επίπεδο κλάσης* (Class Layer Kernel) λαμβάνει υπόψη του τις ομοιότητες των στιγμιοτύπων, στηριζόμενος στις κλάσεις στις οποίες τα ορίσματα του πυρήνα είναι στιγμιότυπα. *Οι πυρήνες στα επίπεδα ιδιοτήτων* (property layers) λαμβάνουν υπόψη τους τις ομοιότητες των στιγμιοτύπων, στηριζόμενοι στις ιδιότητες τύπων δεδομένων και/ή στις ιδιότητες αντικειμένων, στις οποίες τα ορίσματα είναι στιγμιότυπα.

Στη συνέχεια περιγράφεται κάθε ένα από αυτά τα επίπεδα.

4.3.1 Επίπεδο Ταυτοτικού Πυρήνα

Σε αυτό το επίπεδο χρησιμοποιείται ένας απλός πυρήνας, ο ταυτοτικός πυρήνας, ο οποίος ελέγχει αν τα δύο ορίσματα της συνάρτησης πυρήνα ταυτίζονται. Αν ταυτίζονται επιστρέφει μονάδα στην έξοδό του, αλλιώς επιστρέφει μηδέν.

Τυπικά ο ταυτοτικός πυρήνας ορίζεται ως εξής:

Δεδομένων δύο στιγμιοτύπων x, z και μιας οντολογίας O , ο ταυτοτικός πυρήνας είναι ο εξής:

$$k_{\text{identity}}(x, z) := \delta(x, z) \quad (4.11)$$

όπου

$$\delta(x, z) = \begin{cases} 1 & \text{αν } O \models (x \equiv z) \\ 0 & \text{Αλλιώς} \end{cases}$$

Από τα παραπάνω είναι εμφανής η αντιστοιχία αυτού του πυρήνα με τον πυρήνα ταιριάσματος (matching kernel). Ο πυρήνας έχει τιμή 0, εκτός εάν υπολογίζεται σε ένα στιγμιότυπο με τον εαυτό του, ή αν η οντολογία περιέχει ένα ρητά εκφρασμένο αξίωμα ισοδυναμίας για τα δύο ορίσματα-στιγμιότυπα x και z , οπότε ο πυρήνας παίρνει τιμή ίση με τη μονάδα.

4.3.2 Πυρήνες στο Επίπεδο Κλάσεων

Σε αυτό το επίπεδο εξετάζονται οι κλάσεις στις οποίες δύο άτομα είναι στιγμιότυπα ως ένα βασικό στοιχείο για τη σύγκρισή τους. Αυτό το κριτήριο ομοιότητας είναι χρήσιμο στις περιπτώσεις που υπάρχει κάποια διαφοροποίηση στις κλάσεις από τις οποίες δημιουργούνται στιγμιότυπα.

Δεδομένων δύο στιγμιοτύπων x, z και μιας οντολογίας O , ορίζουμε τον κοινό πυρήνα κλάσης (common class kernel) ως εξής:

$$k_{\text{class}}(x, z) := |\{C \in B \mid O \models C(x)\} \cap \{C \in B \mid O \models C(z)\}| \quad (4.12)$$

Ο παραπάνω πυρήνας τομής κλάσεων (class intersection kernel) είναι έγκυρος (θετικά ορισμένος), αφού είναι ένα συγκεκριμένο στιγμιότυπο του πυρήνα τομής συνόλων (set intersection kernel). Μπορεί να ερμηνευτεί, αν προσδιορίσουμε την αντιστοίχιση $\varphi(\cdot)$, ως ένα μετασχηματισμό σε ένα διανυσματικό χώρο του οποίου οι διαστάσεις αντιστοιχούν στις ατομικές κλάσεις που ορίζονται στην οντολογία. Η τιμή του πυρήνα κλάσης αυξάνεται ανάλογα με τον αριθμό των ατομικών κλάσεων από τις οποίες, ταυτόχρονα, προέρχονται τα δύο ορίσματα - στιγμιότυπα

Πιο αναλυτικά, ο κοινός πυρήνας κλάσης μετράει το πλήθος των ατομικών κλάσεων σε κάθε μια από τις οποίες και τα δύο ορίσματα είναι στιγμιότυπα. Αν δεν υπάρχει καμιά κοινή κλάση, ο πυρήνας παίρνει τιμή μηδέν. Μπορούμε να επεκτείνουμε αυτόν τον πυρήνα με βάση ένα σχήμα με βάρη $\mu : C \rightarrow \mathbb{R}^+$ ως εξής:

Δεδομένων δύο στιγμιοτύπων x, z και μιας οντολογίας O , ορίζουμε τον κοινό πυρήνα κλάσης με βάρη (weighted common class kernel) ως εξής :

$$k_{\text{class}}'(x, z) := \sum_{c \in \{C \in B|O|=C(x)\} \cap \{C \in B|O|=C(z)\}} \mu(c) \quad (4.13)$$

4.3.3 Πυρήνες στο Επίπεδο των Ιδιοτήτων Τύπων Δεδομένων

Στη συνέχεια καθορίζεται ένα ακόμα συστατικό στοιχείο της ομοιότητας μεταξύ δύο ατόμων λαμβάνοντας υπόψη τις ιδιότητές τους. Η γενική δομή αυτού του πυρήνα είναι ένα άθροισμα των τιμών των πυρήνων όλων των συμβατών ζευγών ιδιοτήτων.

Δεδομένων δύο στιγμιοτύπων x, z , μιας ιδιότητας τύπου δεδομένων $p \in P_D$ και μιας οντολογίας O , ορίζουμε τον πυρήνα των ιδιοτήτων τύπων δεδομένων ως εξής :

$$k_{DP}^p(x, z) := \sum_{\{d|O|=p(x,d)\}} \sum_{\{e|O|=p(z,e)\}} k_p(d, e) \quad (4.14)$$

όπου k_p είναι ένας έγκυρος πυρήνας στον τύπο δεδομένων που προσδιορίζεται από την αντίστοιχη ιδιότητα.

Η εγκυρότητα του πυρήνα επαληθεύεται από το γεγονός ότι ο πυρήνας είναι ένα στιγμιότυπο του πυρήνα γινομένου. Ο παραπάνω πυρήνας χρησιμοποιεί ένα βασικό πυρήνα που ορίζεται στον αντίστοιχο τύπο δεδομένων, στον οποίο υπολογίζει την ομοιότητα ζευγών δεδομένων. Πιο αναλυτικά, ο πυρήνας ιδιοτήτων τύπων δεδομένων ισούται με τα αθροίσματα των απλών πυρήνων, για όλους τους συνδυασμούς των τύπων δεδομένων με τους οποίους σχετίζονται τα δύο στιγμιότυπα x και z μέσω της ιδιότητας p .

4.3.4 Πυρήνες στο Επίπεδο των Ιδιοτήτων Αντικειμένων

Με το ίδιο σκεπτικό με τον πυρήνα ιδιοτήτων τύπων δεδομένων ορίζεται ο πυρήνας ιδιοτήτων αντικειμένων.

Δεδομένων δύο στιγμιοτύπων x, z , μιας ιδιότητας αντικειμένου $p \in P_O$ και μιας οντολογίας O , ορίζονται οι πυρήνες ιδιοτήτων αντικειμένων ως πυρήνες γινομένου:

$$k_{OP}^p(x, z) := \sum_{\{v|O|=p(v,x)\}} \sum_{\{w|O|=p(w,z)\}} k_p(v, w) \quad (4.15)$$

$$k_{OP}^p(x, z) := \sum_{\{v|O|=p(v,x)\}} \sum_{\{w|O|=p(w,z)\}} k_p(v, w) \quad (4.16)$$

όπου ο k_p είναι ένας έγκυρος πυρήνας.

Θα πρέπει να επισημανθούν δύο στοιχεία:

- Για κάθε ιδιότητα αντικειμένου πρέπει να προσδιοριστούν δύο ξεχωριστοί πυρήνες, ανάλογα με το αν τα ορίσματα-στιγμιότυπα τους θεωρηθούν ως στοιχεία του πεδίου ορισμού, ή του πεδίου τμών της ιδιότητας αντικειμένου.

- Ο ορισμός με βάση τον πυρήνα γινομένου χρησιμοποιεί έναν βασικό πυρήνα k_p , που αυτή τη φορά ορίζεται σε στιγμιότυπα, όπως και ο συνολικός πυρήνας. Ενώ αυτή η προσέγγιση φαίνεται ελαστική, μπορεί να είναι δύσκολη, καθώς πρέπει να αποφευχθούν κύκλοι κατά τον υπολογισμό του πυρήνα. Ένας κύκλος προκύπτει αν ένας πυρήνας που ορίζεται σε υψηλότερο επίπεδο χρησιμοποιείται επίσης σαν πυρήνας πάνω στον οποίο αυτός στηρίζεται, είτε άμεσα είτε έμμεσα.

4.3.5 Συνολικός Πυρήνας από τα 4 επίπεδα


Όλοι οι τελεστές, που εφαρμόζονται σε έγκυρους (θετικά ορισμένους) πυρήνες και δημιουργούν πυρήνες που είναι επίσης έγκυροι, μπορούν να εφαρμοστούν για το συνδυασμό των 4 πυρήνων, δηλαδή των πυρήνων των διαφόρων επιπέδων. Ένα παράδειγμα είναι ο τελεστής γινομένου. Επίσης, οποιαδήποτε μορφή σταθμισμένου αθροίσματος μπορεί να χρησιμοποιηθεί για το συνδυασμό των αποτελεσμάτων των διαφόρων επιπέδων. Η πιο διαισθητική προσέγγιση είναι η χρήση ενός αθροιστικού συνδυασμού με βάρη, όπου τα βάρη θα χρησιμοποιηθούν για να καθορίσουν τη συνεισφορά των πυρήνων στα διάφορα επίπεδα.

5. Προσαρμογή της Γνώσης σε Πραγματικές Συνθήκες

Στο παρόν Κεφάλαιο περιγράφουμε μια Αρχιτεκτονική συστήματος για την προσαρμογή υπάρχουσας γνώσης, που περιγράφει κάποια εφαρμογή, σε πραγματικές συνθήκες. Η Αρχιτεκτονική περιλαμβάνει συστήματα που ενσωματώνουν τόσο μεθόδους αναπαράστασης γνώσης, οντολογίες περιγραφής της και μεθόδους συλλογιστικής, όσο και μηχανές μηχανικής μάθησης που μπορούν να αποτυπώσουν τη γνώση αυτή στην δομή τους και να την προσαρμόσουν στις συγκεκριμένες συνθήκες και στο συγκεκριμένο πλαίσιο λειτουργίας. Στην αρχή δίδεται η περιγραφή της Αρχιτεκτονικής, στη συνέχεια αναφέρονται οι τρόποι μεταφοράς και προσαρμογής της γνώσης στο υποσυμβολικό τμήμα της Αρχιτεκτονικής και στο τέλος αναφέρονται τρόποι αναπροσαρμογής της γνώσης στη Βάση Γνώσης, με βάση την προσαρμογή της γνώσης που επετεύχθη στο υποσυμβολικό τμήμα της.

5.1 Νευρωνικο-Συμβολικός Κύκλος Μηχανικής Μάθησης

Ο συνδυασμός νευρωνικών δικτύων και συμβολικής αναπαράστασης γνώσης μπορεί να



Σχήμα 5.1 Ο νευρωνικο-συμβολικός κύκλος μηχανικής μάθησης

πραγματοποιηθεί μέσω ενός διαγράμματος ροής για προσαρμογή της γνώσης.

Συμβολικές αναπαραστάσεις γνώσης (symbolic system) μπορούν να ενσωματωθούν (embedding) σε αρχιτεκτονικές νευρωνικών δικτύων (connectionist system), μέσω των οποίων η γνώση προσαρμόζεται (trainable) και βελτιώνεται σε συγκεκριμένα δεδομένα του τωρινού περιβάλλοντος. Η νέα γνώση, με τη σειρά της, μπορεί να εξαχθεί (extraction) σε συμβολική αναπαράσταση (γλώσσες περιγραφής γνώσης, κανόνες) και να χρησιμοποιηθεί περαιτέρω (readable, writable). Αυτό το διάγραμμα ροής είναι γενικά γνωστό [43,45] ως Νευρωνικο-Συμβολικός Κύκλος Μάθησης (neuro-symbolic learning cycle), όπως φαίνεται στο Σχήμα 5.1.

Ο κύκλος αυτός αποτελεί τη βάση για την ανάπτυξη της Αρχιτεκτονικής που περιγράφεται στο επόμενο εδάφιο για την αποτελεσματική ολοκλήρωση των τεχνολογιών συμβολικής αναπαράστασης γνώσης και μεθόδων μηχανικής μάθησης.

5.2 Η Αρχιτεκτονική του Νευρωνικο-Συμβολικού Συστήματος


5.2.1 Περιγραφή της Αρχιτεκτονικής

Το Σχήμα 5.2 δείχνει την Αρχιτεκτονική του Νευρωνικο-Συμβολικού Συστήματος, αποτελούμενη από δυο βασικά υποσυστήματα: το υποσύστημα της Τυπικής Γνώσης (Formal Knowledge) και αυτό της Προσαρμογής της Γνώσης (Knowledge Adaptation).

Η Τυπική Γνώση περιέχει, στην κατάλληλη αναπαράσταση γνώσης την ορολογία, τα αξιώματα, τους ισχυρισμούς, τους περιορισμούς που περιγράφουν το υπό ανάλυση πρόβλημα.

Ειδικότερα:

Το τμήμα των Οντολογιών (*Ontologies*) περιλαμβάνει την τυπική περιγραφή της γενικής γνώσης για το πρόβλημα. Αναπαριστάνει τις έννοιες του προβλήματος και τις σχέσεις τους, παρέχοντας τυπικούς ορισμούς και αξιώματα που ισχύουν σε κάθε παρόμοιο περιβάλλον. Αποτελεί τη Γνώση του Συστήματος, η οποία δημιουργήθηκε κατά τη Φάση Ανάπτυξης (*Development Phase*) από μηχανικούς Γνώσης (*knowledge engineers*) και ειδικούς (*experts*) στο πεδίο.



Σχήμα 5.2 Η Αρχιτεκτονική του Νευρωνικο-Συμβολικού Συστήματος

Επιπλέον η Τυπική Γνώση περιλαμβάνει την Περιγραφή του Κόσμου (*World Description*) η οποία είναι μια αναπαράσταση όλων των αντικειμένων και ατόμων (individuals) του κόσμου, όπως επίσης και των ιδιοτήτων τους και των σχέσεων μεταξύ τους στο πλαίσιο της Οντολογίας.

Αυτή η γνώση μπορεί να εξαχθεί με τεχνικές επεξεργασίας και ανάλυσης των δεδομένων που λαμβάνονται στην είσοδο του συστήματος (system input). Είναι δυνατό τα δεδομένα εισόδου να περιλαμβάνουν διαφόρους βαθμούς αβέβαιης πληροφορίας. Η γνώση αυτή μπορεί επομένως, στη γενική περίπτωση, να περιλαμβάνει και ασαφείς (fuzzy) ισχυρισμούς περιγραφικής λογικής που να συνδέουν τα αντικείμενα και τα άτομα του κόσμου με τις έννοιες και τις σχέσεις της Οντολογίας. Η γνώση αυτή γενικά προσφέρεται στο Σύστημα από το τμήμα Σημασιολογικής Ερμηνείας (*Semantic Interpretation*).

Η δυνατότητα αυτή της Τυπικής Γνώσης να περιλαμβάνει περιγραφή όλων των αντικειμένων, ατόμων, ιδιοτήτων και σχέσεων στον κόσμο είναι πολύ φιλόδοξη. Σε πραγματικά περιβάλλοντα, υπάρχουν πολλές αιτίες που μπορούν να προκαλέσουν ασυνέπειες στην Τυπική Γνώση. Για παράδειγμα, δεν είναι δυνατόν να μοντελοποιηθούν όλα τα ειδικά περιβάλλοντα χρήσης των τεχνολογιών, οπότε μπορεί να εμφανιστούν κάποιοι συγκρουόμενοι ισχυρισμοί. Σε μια εφαρμογή αλληλεπίδρασης ανθρώπου – υπολογιστή, η προσωπικότητα, οι τρόποι έκφρασης ενός συγκεκριμένου χρήστη μπορεί να είναι τόσο διαφορετικοί από αυτές του γενικού τύπου χρήστη ή χρηστών, ώστε κάποιοι από τους ισχυρισμούς και περιορισμούς της Οντολογίας να μην ισχύουν ή να οδηγούν σε λανθασμένα συμπεράσματα. Παρόλη την παρουσία της Μηχανής Συλλογιστικής (*Reasoner*), η εφαρμογή της Τυπικής Γνώσης σε αυτές τις περιπτώσεις είναι ιδιαίτερα προβληματική.

Η χρησιμοποίηση του υποσυστήματος της Προσαρμογής της Γνώσης (*Knowledge Adaptation*) προσπαθεί να λύσει την ασυνέπεια, μέσα από μια διαδικασία προσαρμογής – επανεκπαίδευσης.

Η Προσαρμογή της Γνώσης ανανεώνει την Γνώση του συστήματος, μεταβάλλοντας την περιγραφή του κόσμου (world description) και πιθανώς σε κάποιο βαθμό τα αξιώματα της ορολογίας του συστήματος. Η νέα πληροφορία, λαμβάνεται από το συγκεκριμένο περιβάλλον, και σε συνδυασμό με πληροφορίες που δίδει – ως ανάδραση – ο χρήστης (User Feedback), ή/και εξάγονται από το στρώμα Σημασιολογικής Ερμηνείας (Semantic Interpretation) παρουσιάζονται στο τμήμα της Μηχανικής Μάθησης (π.χ. το Νευρωνικό Δίκτυο), το οποίο με τη βοήθεια του αλγορίθμου επανεκπαίδευσης-προσαρμογής (*Connectionist learning*) υλοποιεί την προσαρμογή της υποσυμβολικής γνώσης. Η νέα γνώση μπορεί να επανεισαχθεί στο Υποσύστημα Τυπικής Γνώσης μέσω της διαδικασίας Εξαγωγής της Γνώσης (*Knowledge Extraction*), η οποία επιτρέπει την ανανέωση της λειτουργίας του συστήματος, το οποίο μέσω του Συστήματος Ερμηνείας, παρέχει στην Εξοδό του (System Output) την απόκρισή του.

5.2.2 Το Υποσύστημα της Τυπικής Αναπαράστασης Γνώσης

Για να επιτευχθεί η ολοκλήρωση της συμβολικής αναπαράστασης γνώσης και των τεχνολογιών μηχανικής μάθησης, χρησιμοποιούνται τα πρόσφατα θεωρητικά αποτελέσματα που αναφέρθηκαν στα Κεφάλαια 3 και 4 της παρούσας εργασίας. Ειδικότερα ενσωματώνεται η μεταφορά της τυπικής γνώσης σε αρχιτεκτονικές μηχανικής μάθησης, μέσω των μεθόδων πυρήνα, και η προσαρμογή της γνώσης των υποσυμβολικών μεθόδων μέσω τεχνικών επανεκπαίδευσης στο νέο περιβάλλον.

Στο πλαίσιο αυτό, η εξαγωγή συναρτήσεων πυρήνα είναι η κύρια συνεισφορά του υποσυστήματος της Τυπικής Γνώσης – σε συνεργασία με την Μηχανή Συλλογιστικής, με τις οποίες τροφοδοτεί το υποσύστημα Προσαρμογής της Γνώσης.

Οπως έχει ήδη περιγραφεί στο Κεφάλαιο 4, δημιουργούμε μια οικογένεια έγκυρων (valid) συναρτήσεων πυρήνα $k_p^F : \text{Ind}(A) \times \text{Ind}(A) \mapsto [0,1]$, για μια βάση γνώσης $K = \langle T, A \rangle$ αποτελούμενη από το TBox T (σύνολο των αξιωμάτων για τις περιγραφές των εννοιών) και το ABox A (σύνολο των ισχυρισμών). Εστω ότι το $\text{Ind}(A)$ συμβολίζει το

σύνολο των ατόμων που εμφανίζονται στο A , και το $\{ F_1, F_2, \dots, F_m \}$ είναι ένα σύνολο από περιγραφές εννοιών. Οι συναρτήσεις αυτές ορίζονται [37-39], ως ο L_p μέσος των, έστω m , απλών συναρτήσεων πυρήνα των εννοιών, κ_i , $i=1, \dots, m$, όπου, για κάθε δυο άτομα a, b , και για $p > 0$, είναι:

$$\kappa_i(a, b) = \begin{cases} 1 & (F_i(a) \in A \wedge F_i(b) \in A) \vee (\neg F_i(a) \in A \wedge \neg F_i(b) \in A) \\ 0 & (F_i(a) \in A \wedge \neg F_i(b) \in A) \vee (\neg F_i(a) \in A \wedge F_i(b) \in A) \\ 1/2 & \text{Αλλιώς} \end{cases} \quad (5.1)$$

$$\forall a, b \in \text{Ind}(A) \quad k_p^F(a, b) := \left[\sum_{i=1}^m \left| \frac{\kappa_i(a, b)}{m} \right|^p \right]^{1/p} \quad (5.2)$$

Το σκεπτικό της χρήσης των πυρήνων αυτών είναι ότι η ομοιότητα μεταξύ των ατόμων προσδιορίζεται από την ομοιότητά τους ως προς κάθε έννοια F_i , δηλαδή από το αν είναι και τα δύο στιγμιότυπα μιας έννοιας ή της άρνησής της. Εξαιτίας της Υπόθεσης Ανοικτού Κόσμου για την σημασιολογία των ισχυρισμών, μια πιθανή ασάφεια αναπαριστάται με μια ενδιάμεση τιμή της συνάρτησης πυρήνα. Η τιμή $p = 1$ γενικά χρησιμοποιείται στις υπάρχουσες υλοποιήσεις της (5.2).

5.2.3 Η Μηχανή Συλλογιστικής

Η μηχανή συλλογιστικής της Αρχιτεκτονικής του Σχήματος 5.2 έχει ιδιαίτερη σημασία για την λειτουργία του συστήματος, συμμετέχοντας στις περισσότερες επιμέρους διεργασίες.

Καταρχήν, κατά τη φάση ανάπτυξης της γνώσης, η μηχανή συλλογιστικής εμπλουτίζει τη – χειροκίνητη (από τους ειδικούς) – δημιουργία των εννοιών και των συσχετίσεων,

ούτως ώστε ο υπολογισμός των συναρτήσεων πυρήνα στις (5.1)-(5.2) να περιλαμβάνει όσο το δυνατό λιγότερες ασάφειες ή ασυμβατότητες.

Η μηχανή αυτή επίσης χρησιμοποιείται στον υπολογισμό των συσχετίσεων κάθε ζεύγους ατόμων με κάθε έννοια της βάσης γνώσης στις ανωτέρω εξισώσεις.

Στη φάση λειτουργίας, η μηχανή συλλογιστικής επικοινωνεί με το τμήμα σημασιολογικής ερμηνείας και με τη μηχανή μηχανικής μάθησης για την πραγματοποίηση της προσαρμογής της γνώσης σε συγκεκριμένες συνθήκες και περιβάλλοντα.

Είναι δυνατόν να χρησιμοποιηθούν συνήθειες (crisp) αλλά και ασαφείς (fuzzy) μηχανές συλλογιστικής στο πλαίσιο αυτό. Στην εργασία αυτή χρησιμοποιήσαμε την μηχανή FIRE [12], που έχει αναπτυχθεί στο Εργαστήριο Εικόνων του Ε.Μ.Πολυτεχνείου, και βασίζεται σε ασαφή λογική, αλλά μπορεί να χρησιμοποιηθεί και σε μη ασαφή περιβάλλοντα.

Το σύστημα FIRE [22,23] βασίζεται στην Περιγραφική Λογική *f-SHIN* [14] που είναι μια ασαφής επέκταση της DL *SHIN* όπως αναφέραμε και στο Κεφάλαιο 2.

Οι βασικές λειτουργίες των απλών συλλογιστικών μηχανών όσον αφορά στο *Abox* είναι η συνέπεια, η συνεπαγωγή και η υπαγωγή. Στη μηχανή *FiRE* επιπλέον ορίζονται και επερωτήματα (queries) μέγιστου κάτω φράγματος (greatest lower bound, GLB), ενσωματώνοντας και το ασαφές στοιχείο [10]. Επειδή, στην παρούσα εργασία, δεν χρησιμοποιούμε ασαφείς σχέσεις για τον υπολογισμό των συναρτήσεων πυρήνα, ο υπολογισμός των εξισώσεων (5.1) – (5.2) έγινε ως εξής: αν το GLB για το $F_i(a) > 0$, τότε $F_i(a) \in A$, ενώ αν το GLB για το $F_i(a) = 0$, then $\neg F_i(a) \in A$. Στις μελλοντικές επεκτάσεις της παρούσας εργασίας θα ενσωματωθούν ασαφείς τελεστές στον υπολογισμό των συναρτήσεων πυρήνα, όπως ασαφείς συσσωρευτές (fuzzy aggregation) και ασαφείς βαθμισμένες νόρμες (fuzzy weighted norms).

5.3 Ο Μηχανισμός Προσαρμογής της Γνώσης

5.3.1 Η Φάση Λειτουργίας του Συστήματος

Ας υποθέσουμε ότι στην αρχιτεκτονική του Σχήματος 5.2, ένα εκτενές σύνολο από άτομα (individuals), μαζί με τις ιδιότητές τους και τις συσχετίσεις τους, έχει χρησιμοποιηθεί κατά την φάση ανάπτυξης της Τυπικής Γνώσης του συστήματος για τη δημιουργία των συναρτήσεων πυρήνα (5.1-5.2). Τα άτομα αυτά, μαζί με τα χαρακτηριστικά τους, και τις συναρτήσεις πυρήνα προωθούνται στο υποσύστημα Προσαρμογής της Γνώσης, ως σύνολο δεδομένων εκπαίδευσης, ώστε να ενσωματωθούν σε αυτό, και στη συνέχεια το υποσύστημα να είναι σε θέση να προσαρμοστεί σε συγκεκριμένα (νέα) χαρακτηριστικά που θα παρουσιαστούν στην είσοδό του κατά την πλήρη λειτουργία του.

Όπως αναπτύχθηκε στο Κεφάλαιο 3, οι μηχανές διανυσμάτων υποστήριξης (SVM) μπορούν να χρησιμοποιήσουν τις συναρτήσεις πυρήνα και να μεταφέρουν τα άτομα-στιγμιότυπα σε ένα χώρο χαρακτηριστικών, όπου γραμμικοί ταξινομητές μπορούν να τα κατηγοριοποιήσουν με αποτελεσματικό τρόπο. Μπορούν, επομένως, να εφαρμοστούν στις συναρτήσεις πυρήνα που δημιουργήθηκαν ανωτέρω από την εφαρμογή των (5.1) – (5.2) και να εκπαιδευτούν κατάλληλα ώστε να ταξινομήσουν τα άτομα - που χρησιμοποιήθηκαν για να υπολογιστούν οι συναρτήσεις πυρήνα - στις διαφορετικές εννοιολογικές κατηγορίες που περιλαμβάνονται στην αναπαράσταση της Τυπικής Γνώσης του συστήματος.

Με τον ίδιο τρόπο μπορούν να εκπαιδευτούν Kernel Perceptrons ώστε να ταξινομήσουν τα άτομα, σε αυτό το γραμμικά διαχωρίσιμο, πρόβλημα κατηγοριοποίησης.

Ας υποθέσουμε τώρα ότι το σύστημα βρίσκεται στην κατάσταση λειτουργίας του σε πραγματικές συνθήκες. Εδώ το σύστημα δέχεται νέα άτομα, με τα αντίστοιχα – πιθανόν πολυμεσικά – χαρακτηριστικά τους (low-level features) να παρουσιάζονται στην είσοδό του, μέσω του στρώματος Σημασιολογικής Ερμηνείας, για ταξινόμηση σε κάποια συγκεκριμένη έννοια ή κατηγορία.

Έχει ήδη επισημανθεί ότι, λόγω των συγκεκριμένων (διαφορετικών) συνθηκών - περιβάλλοντος λειτουργίας, συμπεριφοράς ή χαρακτηριστικών χρήστη, ή εννοιολογικού πλαισίου αλληλεπίδρασης - τα χαρακτηριστικά αυτά μπορεί να διαφέρουν από αυτά των ατόμων που χρησιμοποιήθηκαν στην φάση της δημιουργίας της γνώσης του συστήματος. Επομένως, κάποια νέα άτομα μπορεί να μην αναπαριστώνται ικανοποιητικά από την υπάρχουσα Τυπική Γνώση. Στη συνέχεια περιγράφουμε το στάδιο προσαρμογής του συστήματος στην τοπική αυτή πληροφορία, μέσω του υποσυστήματος Προσαρμογής της Γνώσης.

5.3.2 Προσαρμογή του Υποσυμβολικού Τμήματος της Αρχιτεκτονικής

Για να μπορέσει το σύστημα να αναλύσει – για παράδειγμα, να κατατάξει ανάλογα, ένα νέο άτομο – πρότυπο που παρουσιάζεται στην είσοδό του, θα υπολογίσει, μέσω της συνάρτησης πυρήνα, την συσχέτισή του με κάθε άτομο της Βάσης (Τυπικής) Γνώσης, ως προς κάθε έννοια ή κατηγορία που υπάρχει στη Βάση αυτή.

Η διαδικασία αυτή έχει αρκετά ανοιχτά θέματα που πρέπει να καθοριστούν:

1) Ο αριθμός των ατόμων (individuals) της Βάσης Γνώσης μπορεί να είναι πολύ μεγάλος, ώστε η μεταφορά τους κάθε φορά, μαζί με το σύστημα, στο συγκεκριμένο (real-life) περιβάλλον (π.χ., του χρήστη) να μην είναι δυνατή. Εφαρμογή της Ανάλυσης Πρωτογενών Συνιστωσών (Principal Component Analysis, PCA) [29] εν γένει ελαττώνει τον αριθμό των ατόμων, ώστε να είναι εφικτή η χρησιμοποίηση προσεγγιστικής συλλογιστικής (approximate reasoning).

Ως αποτέλεσμα του ανωτέρω σταδίου, υποθέτουμε, ότι με χρήση μιας τεχνικής συσταδοποίησης (clustering) [28,29] τα άτομα της βάσης γνώσης αποτελούν κέντρα των συστάδων (clusters), σε κάποια από τις οποίες το νέο άτομο – στιγμιότυπο θα ενταχθεί, με εφαρμογή των (5.1) – (5.2).

2) Οι συναρτήσεις πυρήνα στις (5.1) – (5.2) δεν είναι συνεχείς συναρτήσεις ως προς τα άτομα, αλλά ορίζονται μόνο για τα άτομα της Βάσης Γνώσης. Ως αποτέλεσμα, οι τιμές των συναρτήσεων πυρήνα κατά την συσχέτιση του κάθε νέου ατόμου με κάθε άτομο της Βάσης Γνώσης πρέπει να υπολογιστούν με βάση τις αρχικά ορισμένες διακριτές τιμές των ορισμάτων των συναρτήσεων.

Για να αντιμετωπιστεί το πρόβλημα αυτό, γίνεται η παραδοχή ότι οι σημασιολογικές σχέσεις που εκφράζονται, για τα άτομα, μέσω των συναρτήσεων πυρήνα, ισχύουν επίσης και για τις συντακτικές σχέσεις των ατόμων, όπως αυτές εκφράζονται μέσω των low-level χαρακτηριστικών τους, όπως τα επόμενα: σχήμα, χρώμα, υφή αντικειμένων, κίνηση κινούμενων αντικειμένων, F0 συχνότητα (pitch), χροιά φωνής, κλπ. Με αυτήν την παραδοχή, ένας αλγόριθμος, όπως ο k-means [28,29], ή οι ασαφείς επεκτάσεις του, συσχετίζει το νέο άτομο με κάθε ένα από τα κέντρα των συστάδων που προαναφέρθηκαν, με βάση το διάνυσμα των low-level χαρακτηριστικών τους.

Διάφοροι αλγόριθμοι μπορούν να χρησιμοποιηθούν για να προσδιορίσουν τις τιμές των συναρτήσεων πυρήνα για τα προκύπτοντα ζεύγη ατόμων. Ένας αλγόριθμος τύπου κβαντισμού διανυσμάτων (vector quantization [29]), όπου κάθε νέο άτομο αντιστοιχίζεται με το πλέον κοντινό, στο πεδίο των χαρακτηριστικών τους, άτομο – γείτονα, κατά τον υπολογισμό της τιμής της συνάρτησης πυρήνα, είναι μια πρώτη επιλογή. Σε ένα πλαίσιο ασαφούς αναπαράστασης, μπορούν να χρησιμοποιηθούν βαθμισμένοι μέσοι όροι (weighted averages) και γκαουσιανές συναρτήσεις (Gaussian functions) γύρω από τα κέντρα των συστάδων, για τον υπολογισμό των τιμών των συναρτήσεων πυρήνα, που περιλαμβάνουν σε ένα από τα ορίσματά τους τα νέα άτομα - στιγμιότυπα.

Στις περιπτώσεις όπου, το πρόβλημα, μετά τον εμπλουτισμό του με νέα άτομα – στιγμιότυπα, από το συγκεκριμένο (τοπικό) περιβάλλον ή από τις συγκεκριμένες συμπεριφορές ή χαρακτηριστικά των χρηστών του, παραμένει γραμμικά διαχωρίσιμο, μια μηχανή SVM ή Kernel Perceptron μπορεί να επανεκπαιδευτεί – με βάση τα νέα πρότυπα εισόδου που συλλέγονται στο συγκεκριμένο περιβάλλον, και τις αντίστοιχες

επιθυμητές αποκρίσεις που παρέχονται είτε από ανάδραση του Χρήστη (*User Feedback*), είτε από το *Στρώμα Σημασιολογικής Ερμηνείας* (*Semantic Interpretation Layer*) σε συνεργασία με την Μηχανή Συλλογιστικής (*Reasoning Machine*). Ως αποτέλεσμα, το σύστημα θα προσαρμόσει την έξοδό του στο συγκεκριμένο πλαίσιο χρησιμοποίησής του.

Είναι όμως πιθανό, η μεταβολή αυτή των χαρακτηριστικών του πλαισίου λειτουργίας να μετατρέψει το πρόβλημα σε μη γραμμικά διαχωρίσιμο, οπότε η εφαρμογή των μηχανών SVM ή kernel perceptron να μην μπορεί να δώσει την επιθυμητή προσαρμογή του συστήματος. Σε αυτές τις περιπτώσεις, η χρησιμοποίηση του πολυεπίπεδου (multilayer) perceptron και η προσαρμογή των βαρών του με τον αλγόριθμο που περιγράφηκε στο Κεφάλαιο 3 μπορεί να αντιμετωπίσει αποτελεσματικά το πρόβλημα, λαμβάνοντας υπόψη, τόσο τα χαρακτηριστικά των ατόμων – κέντρων των συστάδων, όσο και τα χαρακτηριστικά των νέων ατόμων – προτύπων του συγκεκριμένου περιβάλλοντος [57]. Ως αποτέλεσμα της προσαρμογής του δικτύου, αυτό θα συνεχίσει να αποδίδει ικανοποιητικά στο συγκεκριμένο περιβάλλον λειτουργίας του.

Το πρόβλημα, παράλληλα, θα αναφερθεί από το τμήμα της Σημασιολογικής Ερμηνείας στο Υποσύστημα αναπαράστασης Τυπικής Γνώσης, ενώ όποια Γνώση μπορεί να εξαχθεί από την Νευρωνική αρχιτεκτονική θα αποσταλεί μέσω του τμήματος της Εξαγωγής Γνώσης (*Knowledge Extraction*) στο ανωτέρω Υποσύστημα και στη Μηχανή Συλλογιστικής. Τα τελευταία θα ανανεώσουν και την Τυπική Γνώση του συστήματος για το συγκεκριμένο πλαίσιο χρήσης του, ώστε να μπορεί στο μέλλον να αντιμετωπίζει και παρόμοιες χρήσεις. Τρόποι με τους οποίους μπορεί να υλοποιηθεί η ανανέωση αυτή αναφέρονται στο επόμενο εδάφιο.

5.3.3 Προσαρμογή της Βάσης Γνώσης

Η εξαγωγή της γνώσης από εκπαιδευμένα νευρωνικά δίκτυα αποτελεί ένα πεδίο εκτεταμένης έρευνας [46,48,50]. Μια σειρά από μεθόδους αυτής της κατηγορίας μπορούν να χρησιμοποιηθούν για την μεταφορά της γνώσης από το νευρωνικό δίκτυο στο υποσύστημα της αναπαράστασης της Γνώσης. Η διερεύνηση τέτοιων μεθόδων δεν

εμπίπτει στην παρούσα εργασία, αλλά αποτελεί θέμα περαιτέρω έρευνας. Στην παρούσα εργασία θεωρούμε ότι τα πλέον χαρακτηριστικά νέα άτομα – στιγμιότυπα, με τις αντίστοιχες ιδιότητες – ταξινομήσεις, μεταφέρονται στην Βάση Γνώσης, όπου με τη βοήθεια της Μηχανής Συλλογιστικής ανανεώνεται τόσο το TBox, όσο και το ABox, για το συγκεκριμένο πλαίσιο λειτουργίας.

Προκειμένου να ανανεωθεί μια έννοια F_i της Βάσης Γνώσης, πρέπει να ελεγχθούν όλες οι σχετικές με αυτήν έννοιες, τις οποίες ας συμβολίσουμε ως $R_{F_i} F_1 \dots R_{F_i} F_i$.

Έστω ότι:

- $|R_{F_i} F_j|$ συμβολίζει τον αριθμό των ατόμων του ABox που είναι στιγμιότυπα της έννοιας $R_{F_i} F_j$.
- t συμβολίζει ένα κατώφλι, η τιμή του οποίου ορίζεται ανάλογα με τον αριθμό των δεδομένων.
- $\text{Axiom}(F_i)$ συμβολίζει το αξίωμα που είναι ορισμένο για την έννοια F_i στη Βάση Γνώσης ($\text{Axiom}(F_i) \in T$).
- $R_{F_i} F_j \in \text{Axiom}(F_i)$ σημαίνει ότι η έννοια $R_{F_i} F_j$ χρησιμοποιείται στον ορισμό της έννοιας F_i και $R_{F_i} F_j \notin \text{Axiom}(F_i)$ σημαίνει ότι δεν χρησιμοποιείται.

Η προσαρμογή της γνώσης γίνεται σύμφωνα με το ακόλουθο κριτήριο :

$$|R_{F_i} F_j| = \begin{cases} 0 - t / 4 & \text{αν } R_{F_i} F_j \in \text{Axiom}(F_i) \rightarrow \text{Αφαίρεσε το } R_{F_i} F_j \text{ από το } \text{Axiom}(F_i) \\ t / 4 - t & \text{καμία προσαρμογή στη βάση γνώσης} \\ > t & \text{αν } R_{F_i} F_j \notin \text{Axiom}(F_i) \rightarrow \text{Axiom}(F_i) \cup R_{F_i} F_j \end{cases} \quad (5.3)$$

για όλες τις έννοιες F_i .

Το σκεπτικό για την παραπάνω σχέση είναι το ακόλουθο :

Για κάθε έννοια F_i του TBox και για κάθε σχετική με αυτή έννοια $R_{F_i}F_j$, μετράμε το πλήθος των ατόμων - στιγμιότυπων της έννοιας $R_{F_i}F_j$ που υπάρχουν στο ABox (και τα οποία είναι ουσιαστικά τα πρότυπα - άτομα που ανήκουν στη συγκεκριμένη έννοια σύμφωνα με την έξοδο του νευρωνικού δικτύου).

Τότε:

- Αν το πλήθος των ατόμων αυτών είναι μικρό, τότε, αν η έννοια $R_{F_i}F_j$ είναι μέρος του ορισμού της έννοιας F_i , την αφαιρούμε από τον ορισμό, αφού ουσιαστικά δεν συνεισφέρει σε αυτόν - όπως προέκυψε μετά την προσαρμογή του νευρωνικού δικτύου.
- Αν το πλήθος των ατόμων αυτών είναι συγκρίσιμο με το πλήθος των προτύπων - ατόμων που χρησιμοποιούμε συνολικά, δεν γίνεται καμία προσαρμογή στη βάση γνώσης μας.
- Αν το πλήθος των ατόμων αυτών είναι μεγάλο, τότε, αν η έννοια $R_{F_i}F_j$ δεν εμφανίζεται στον ορισμό της έννοιας F_i , την προσθέτουμε στον ορισμό. Αυτό, διότι, σύμφωνα με την έξοδο του νευρωνικού δικτύου, υπάρχουν πολλά άτομα που δείχνουν ότι η έννοια $R_{F_i}F_j$ αποτελεί μέρος του ορισμού της έννοιας F_i .

Με άλλα λόγια, η παραπάνω σχέση υπονοεί ότι για την προσαρμογή του TBox της βάσης γνώσης μας χρησιμοποιούνται οι σχετιζόμενες έννοιες με τη μεγαλύτερη συχνότητα εμφάνισης, ενώ αυτές που δεν είναι σημαντικές αφαιρούνται.

6. Εφαρμογή Νευρωνικο-Συμβολικών Μεθόδων στην Ανάλυση Εικόνων

6.1 Σημασιολογική Ανάλυση Εικόνων

Οι δισδιάστατες εικόνες, αλλά και οι κινούμενες εικόνες, δηλαδή το βίντεο, είναι μορφές πολυμεσικής πληροφορίας που κατακλύζει το διαδίκτυο στις μέρες μας, μια και είναι πολύ εύκολο κάποιος να τραβήξει μια φωτογραφία ή ένα βίντεο και να τα ανεβάσει στο διαδίκτυο. Οντας το πολυπλοκότερο είδος πληροφοριών, οι εικόνες απαιτούν πολύπλοκες τεχνικές επεξεργασίας, αποθήκευσης, μετάδοσης και αναζήτησης. Η ανάπτυξη τεχνολογιών σημασιολογικής ανάλυσης των εικόνων αποτελεί ένα από τα σημαντικότερα πεδία έρευνας και ανάπτυξης διεθνώς σήμερα [51].

Στην παρούσα εργασία θα μας απασχολήσει μια προσέγγιση σημασιολογικής κατάτμησης (segmentation) και κατηγοριοποίησης (classification) εικόνων και βίντεο. Σύμφωνα με την προσέγγιση αυτή, εξάγονται τμήματα (segments), από μια εικόνα ή ένα καρέ του βίντεο, τα οποία αναπαριστούν μια περιοχή ή ένα αντικείμενο. Η εξαγωγή βασίζεται σε κριτήρια όπως το χρώμα, η υφή και το σχήμα της εικόνας [56]. Στη συνέχεια, τα τμήματα αυτά επεξεργάζονται από ένα σύστημα ερμηνείας (interpretation), που τα κατηγοριοποιεί σημασιολογικά σε κάποια έννοια, όπως για παράδειγμα στην έννοια θάλασσα, ουρανός, άνθρωπος, μπάλα, κλπ. [58]. Με σκοπό τη βελτίωση της απόδοσης των αλγορίθμων ερμηνείας ή αναγνώρισης, έχει προταθεί στη βιβλιογραφία η εισαγωγή γνώσης στους αλγορίθμους αυτούς.

Η πρώτη απόπειρα έγινε από τους Meghini et al [53,59] που παρουσίασαν ένα μοντέλο το οποίο χρησιμοποιεί τις Περιγραφικές Λογικές με σκοπό την αναπαράσταση και αναζήτηση πολυμεσικής πληροφορίας. Η μέθοδός τους επικεντρώνεται στην αναζήτηση εικόνων με βάση τον χαρακτηρισμό τους που έχει γίνει χειρωνακτικά από ειδικούς. Μια


παρόμοια προσέγγιση για την ανάκτηση εικόνων, η οποία όμως στηρίζεται στο σχήμα των αντικειμένων έχει αναπτυχθεί και από τους Sciascio et al [55]. Επιπλέον χρησιμοποιώντας Περιγραφικές Λογικές έχει αναπτυχθεί μια γνώση της οποίας τα αξιώματα βασίζονται σε χωρικές σχέσεις, όπως για παράδειγμα ότι μια πόλη δε μπορεί να βρίσκεται μέσα σε μια λίμνη κ.α., για την αναγνώριση και ερμηνεία αεροφωτογραφιών.

Στο πλαίσιο αυτό, προτείνεται η επέκταση των Περιγραφικών Λογικών με χωρικές σχέσεις, όπως και με πολύ συγκεκριμένες επεκτάσεις που θα επέτρεπαν την αναπαράσταση του περιγράμματος (contour) και της μορφής (shape) μιας εικόνας. Ο Meghini από την άλλη αναγνωρίζοντας ότι η επεξεργασία πολυμεσικών κειμένων είναι μια διαδικασία η οποία περιέχει εγγενή αβέβαιη (uncertain) και ασαφή (fuzzy) πληροφορία, προτείνει την επέκταση της Περιγραφικής Λογικής ALC με τη χρήση ασαφών συνόλων.

Οι περισσότερες προσεγγίσεις στη σημασιολογική ανάλυση και δεικτοδότηση (indexing) εικόνων στηρίζονται στην ανίχνευση εννοιών [61,68]. Επιπλέον, η *κατάτμηση εικόνας* (image segmentation) και η *αναγνώριση αντικειμένων* (object recognition) έχουν χρησιμοποιηθεί ταυτόχρονα πάνω σε δεδομένα, αντί ακολουθιακά, στοχεύοντας στη βελτίωση της απόδοσης και των δυο διαδικασιών. Διάφορες προσεγγίσεις έχουν αναπτυχθεί, περιλαμβάνοντας τον *ασαφή χαρακτηρισμό περιοχής* (fuzzy region labeling) για την *αύξηση της σημασιολογικής περιοχής* (semantic region growing) [63,67], όπως και αντιστοιχίσεις χαμηλού επιπέδου οπτικών χαρακτηριστικών γνωρισμάτων με μεσαίου επιπέδου έννοιες [60,52], μέσω τεχνικών τεχνητών νευρωνικών δικτύων και μηχανών διανυσμάτων υποστήριξης.

6.2 Κατάτμηση και Ταξινόμηση Εικόνων

Το Σχήμα 6.1 δείχνει μια αρχιτεκτονική για σημασιολογική δεικτοδότηση (indexing) και ανάκτηση εικόνων, που έχει αναπτυχθεί στο ΕΜΠ και είναι βασισμένη στις τεχνικές αναπαράστασης γνώσης των προηγούμενων Κεφαλαίων [64,65,66].



Σχήμα 6.1 : Σημασιολογική ανάλυση και δεικτοδότηση εικόνων

Αρχικά μια εικόνα υφίσταται κατάτμηση, σύμφωνα με κριτήρια χρώματος και σχήματος, ενώ στη συνέχεια εξάγονται οπτικοί περιγράφοι βάσει των οποίων ταξινομούνται οι περιοχές της εικόνας που δημιουργήθηκαν. Επειδή, όμως, συνήθως με βάση τα κριτήρια αυτά, οι αλγόριθμοι κατάτμησης εικόνας αποτυγχάνουν να εξάγουν σημασιολογικό

χαρακτηρισμό για τα σημαντικά αντικείμενα, χρησιμοποιείται μια μέθοδος *σημασιολογικής αύξησης περιοχών* (semantic region growing), που ενσωματώνει την ανίχνευση αντικειμένων με τη συγχώνευση περιοχών, παρέχοντας έτσι πολύ καλά αποτελέσματα για την ταξινόμηση της περιοχής (Semantic Recursive Shortest Spanning Tree - S-RSST [62,65]).

Για να βελτιώσουμε περαιτέρω αυτήν την λειτουργία, χρησιμοποιούμε μια μηχανή συλλογιστικής, μαζί με ένα σώμα ορολογίας, που ορίστηκε προκειμένου να βελτιώσει την ταξινόμηση των περιοχών-τμημάτων (segments) χρησιμοποιώντας χωρικές σχέσεις και σχέσεις γειτονικών τμημάτων. Το προηγούμενο βήμα παρέχει έναν κατάλογο εννοιών, μαζί με τους βαθμούς συμμετοχής καθενός τμήματος της εικόνας στις έννοιες αυτές, το οποίο αποτελεί το (ασαφές) σώμα ισχυρισμών. Ο στόχος είναι να χρησιμοποιηθούν αυτές οι πληροφορίες προκειμένου να εξαχθεί πρόσθετη, υπονοούμενη γνώση που μπορεί να είναι χρήσιμη για εφαρμογές ανάκτησης εικόνων [54].

6.3 Αναπαράσταση Γνώσης για την Ταξινόμηση Εικόνων

Προκειμένου να ταξινομηθούν αποτελεσματικά οι εικόνες και να βελτιωθεί η διαδικασία σημασιολογικής κατάταξης, δημιουργήθηκε ένα εκφραστικό σώμα ορολογίας. Η ορολογία ορίζει έννοιες που επεξεργάζονται περαιτέρω τις πληροφορίες που εξάγονται κατά την ταξινόμηση, συνδυάζοντας τις χωρικές σχέσεις των χαρακτηρισμένων περιοχών.

Για την καλύτερη κατανόηση του σώματος ορολογίας που δημιουργήθηκε, αρχικά παρουσιάζουμε τις έννοιες και τους ρόλους που εξάγονται από το κομμάτι της ανάλυσης και αποτελούν το αλφάβητο της Βάσης Γνώσης:

$C = \{Person, Sand, Building, Pavement, Sea, Sky, Wave, Dried_Plant, Grass, Tree, Trunk, Ground\}$

$R = \{above-of, below-of, left-of, right-of\}$ (6.1)

Το σύνολο των ατόμων αποτελείται από τα τμήματα που ανιχνεύθηκαν για κάθε εικόνα όπως φαίνεται στο παρακάτω απόσπασμα του σώματος ισχυρισμών για μια εικόνα:

$$\begin{aligned}
 & \text{image1_seg01} : \text{Sky} \geq 0.744 \\
 & \text{image1_seg01} : \text{Person} \geq 0.514 \\
 & \text{image1_seg03} : \text{Sky} \geq 0.831 \\
 & \text{image1_seg09} : \text{Sea} \geq 0.557 \\
 & \text{image1_seg12} : \text{Person} \geq 0.510 \\
 & \dots \\
 & \text{image1_seg01, image1_seg09} : \text{above-of} \geq 1
 \end{aligned} \tag{6.2}$$

Επειδή το FiRE μπορεί και συλλογίζεται με ασαφή δεδομένα, οι ισχυρισμοί εκφράζονται με κάποιον βαθμό συμμετοχής. Ένα απόσπασμα από το σώμα ορολογίας, το οποίο περιέχει τις έννοιες που θα χρησιμοποιηθούν για την προσαρμογή του νευρωνικού δικτύου στο πρώτο πείραμα και στις οποίες θα γίνει προσαρμογή στο δεύτερο πείραμα, παρουσιάζεται στον Πίνακα 6.1. Τα αξιώματα του σώματος ορολογίας που φαίνονται στον Πίνακα 6.1 χρησιμοποιούνται για τον επαναπροσδιορισμό των αντίστοιχων εννοιών σύμφωνα με τις χωρικές σχέσεις και τον χαρακτηρισμό γειτονικών τμημάτων. Το κομμάτι αυτό του σώματος ορολογίας χρησιμοποιείται μονάχα σε συνεργασία με τον αλγόριθμο S-RSST με σκοπό να βελτιωθεί η διαδικασία της σημασιολογικής κατάτμησης και χαρακτηρισμού.

Αφού αρχικά ο ταξινομητής έχει εκπαιδευτεί, θεωρούμε ότι η εκτίμησή του θα είναι σωστή, με πιθανόν λανθασμένη εκτίμηση του βαθμού συμμετοχής. Για παράδειγμα η έννοια SEA επαναπροσδιορίστηκε ως ένα τμήμα της εικόνας που έχει χαρακτηριστεί με την έννοια Sea από τον ταξινομητή, ενώ τα γειτονικά του τμήματα μπορούν να έχουν χαρακτηριστεί με μια από τις έννοιες Wave, Sea ή Sky. Με άλλα λόγια, θεωρούμε ότι κάποιες έννοιες χαρακτηρίζουν γειτονικά τμήματα και ως εκ τούτου, για ένα τμήμα που έχει χαρακτηριστεί με μια έννοια και οι γείτονές του είναι κάποιες συγκεκριμένες έννοιες, μπορούμε να αυξάνουμε το βαθμό συμμετοχής του σύμφωνα με τους βαθμούς που έχουν τα γειτονικά του τμήματα.

Για να γίνει αυτό χρησιμοποιούμε μια μικρή παραλλαγή της υπηρεσίας συλλογιστικής του μέγιστου κάτω φράγματος με σκοπό να αλλάξουμε τον αρχικό βαθμό συμμετοχής που έχει υπολογιστεί από τον ταξινομητή. Έτσι αρχικά υπολογίζεται το μέγιστο κάτω φράγμα του τμήματος ενδιαφέροντος στην έννοια ενδιαφέροντος (π.χ. SEA). Έπειτα υπολογίζεται το μέγιστο κάτω φράγμα του τμήματος ενδιαφέροντος στη έννοια που αποτελεί το κριτήριο για το γειτονικό τμήμα (εάν η έννοια ενδιαφέροντος είναι η SEA, τότε η έννοια που ορίζει το κριτήριο για το γειτονικό τμήμα είναι η

$$(\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sea} \sqcup \text{Wave} \sqcup \text{Sky})) \quad (6.3)$$

Εάν αυτό το μέγιστο κάτω φράγμα (δηλαδή της έννοιας που ορίζει το κριτήριο για το γειτονικό τμήμα) είναι μεγαλύτερο από το μέγιστο κάτω φράγμα της έννοιας ενδιαφέροντος, τότε ο βαθμός συμμετοχής του τμήματος ενδιαφέροντος μετατρέπεται σε αυτόν του μέγιστου κάτω φράγματος της έννοιας κριτήριο για το γειτονικό τμήμα, διαφορετικά παραμένει όπως αρχικά υπολογίστηκε.

Ένα παράδειγμα υπολογισμού του βαθμού συμμετοχής του τμήματος που εξετάζουμε σε σχέση με το αξίωμα που υπάρχει στη βάση γνώσης φαίνεται παρακάτω :


Παράδειγμα 1: Ας θεωρήσουμε το σώμα ισχυρισμών της (6.2) και ας εξετάσουμε το τμήμα image1_seg09 που έχει κατηγοριοποιηθεί στην έννοια Sea με βαθμό μεγαλύτερο του 0.557. Το τμήμα image1_seg01 συνδέεται με το ρόλο above-of με το τμήμα image1_seg09 και επειδή ο ρόλος above-of έχει σαν αντίστροφο το ρόλο below-of (Πίνακας 6.1) ο παραπάνω ισχυρισμός είναι ισοδύναμος με τον ισχυρισμό ότι το τμήμα image1_seg09 σχετίζεται με το ρόλο below-of με το τμήμα image1_seg01. Το τμήμα image1_seg01 έχει κατηγοριοποιηθεί στην έννοια Sky με βαθμό μεγαλύτερο του 0.744. Παρατηρούμε ότι το κριτήριο για να συμμετέχει το image1_seg09 στην έννοια SEA ικανοποιείται και το μέγιστο κάτω φράγμα του είναι 0.577, ίσο με το βαθμό συμμετοχής που αρχικά απέδωσε ο ταξινομητής. Αυτό σημαίνει ότι η έννοια που ορίζει τα κριτήρια για τους γείτονες, δηλαδή

$$((\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sea} \sqcup \text{Wave} \sqcup \text{Sky}))) \quad (6.4)$$

της ορισμένης στο σώμα ορολογίας έννοιας SEA ικανοποιείται με βαθμό τουλάχιστον 0.557. Στη συνέχεια υπολογίζουμε το μέγιστο κάτω φράγμα του τμήματος image1_seg09 στην έννοια που αποτελεί το κριτήριο για τους γείτονες το οποίο είναι 0.744 (όσο το μέγιστο κάτω φράγμα του τμήματος image1_seg01 στην έννοια Sky) και αλλάζουμε το βαθμό συμμετοχής του τμήματος image1_seg09 στην έννοια SEA σε αυτή την τιμή. Με άλλα λόγια, θέτουμε ως μέγιστο κάτω φράγμα του τμήματος ενδιαφέροντας το μέγιστο κάτω φράγμα της έννοιας ενδιαφέροντος ή το μέγιστο κάτω φράγμα της έννοιας που ορίζει το κριτήριο για το γειτονικό τμήμα αναλόγως ποιο από τα δύο είναι μεγαλύτερο.

Το Σχήμα 6.2 παρουσιάζει τον τρόπο που επιτυγχάνονται τα αποτελέσματα της σημασιολογικής τμηματοποίησης. Η πρώτη στήλη παρουσιάζει την αρχική τμηματοποίηση και τον αρχικό χαρακτηρισμό, έπειτα τον τρόπο που αλλάζουν οι βαθμοί κάνοντας χρήση της υπηρεσίας συλλογιστικής μέγιστου κάτω φράγματος του FiRE και η τρίτη στήλη παρουσιάζει την τελική σημασιολογική τμηματοποίηση που επιτυγχάνεται από το S-RSST.

Για κάθε εικόνα πραγματοποιείται η υπηρεσία συλλογιστικής του μεγίστου κάτω φράγματος για όλες τις έννοιες που έχουν οριστεί στο σώμα ορολογίας και τα αποτελέσματα αποθηκεύονται σε έναν κεντρικό υπολογιστή.



Σχήμα 6.2. Αποτελέσματα σημασιολογικής κατάτμησης

Πίνακας 6.1 Ένα κομμάτι του σώματος ορολογίας

$$\begin{aligned}
 T = \{ & \text{SEA} \equiv \text{Sea} \sqcap ((\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave})) \\
 & \sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sea} \sqcup \text{Wave} \sqcup \text{Sky}))) \\
 & \text{SAND} \equiv \text{Sand} \sqcap ((\exists \text{right-of.}(\text{Sand} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sand} \sqcup \text{Wave})) \\
 & \sqcup (\exists \text{above-of.}(\text{Sand} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sand} \sqcup \text{Wave} \sqcup \text{Sea}))) \\
 & \text{WAVE} \equiv \text{Wave} \sqcap ((\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave})) \\
 & \sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Wave} \sqcup \text{Sea}))) \\
 & \}
 \end{aligned}$$

$$R = \{\text{left-of}^{\sim} = \text{right-of}, \text{above-of}^{\sim} = \text{below-of}\}$$

6.4 Νευρωνικο-Συμβολικές Μέθοδοι για Ταξινόμηση Εικόνων

Όπως περιγράφηκε ανωτέρω, η χρήση της αναπαράστασης γνώσης και της συμβολικής ανάλυσης στις εφαρμογές πολυμέσων έχει ιδιαίτερη σημασία. Επιπλέον, σημαντικό ρόλο σε αυτή παίζουν και οι τεχνικές μηχανικής μάθησης, που χρησιμοποιούνται σε αυτό το πεδίο με σκοπό την πολυμεσική ταξινόμηση. Στο πλαίσιο αυτό εφαρμόσαμε μια μορφή της αρχιτεκτονικής του Κεφαλαίου 5 για την επίτευξη βελτιωμένης απόδοσης στη κατάτμηση στατικών ή κινούμενων εικόνων [52].

6.4.1 Προσαρμογή Νευρωνικού Δικτύου από Εξαγωγή Συμβολικής Γνώσης

Η πρώτη τεχνική που αναπτύχθηκε για νευρωνικο-συμβολική κατάτμηση εικόνων, βασισμένη στη Γενική Αρχιτεκτονική του Σχήματος 5.2, φαίνεται στο Σχήμα 6.3.

Αρχικά μια εικόνα, υποβάλλεται σε επεξεργασία από έναν αλγόριθμο κατάτμησης [56] που την χωρίζει σε διάφορες περιοχές, οι οποίες επιδέχονται συμβολικής ερμηνείας. Ειδικότερα, εφαρμόζεται ένας σημασιολογικός αλγόριθμος κατάτμησης (S-RSST), ο οποίος στοχεύει στο να καθορίσει τις αρχικές ετικέτες και τις παραγόμενες μάσκες κατάτμησης της εικόνας σε περιοχές - τμήματα.


Ταυτόχρονα, από αυτή τη διαδικασία εξάγονται οπτικά χαρακτηριστικά, χαμηλού επιπέδου, για τις περιοχές – σύμφωνα με το πρότυπο ISO MPEG-7 -, διαμορφώνοντας τα διανύσματα εισόδου του συστήματος, και ειδικότερα του προσαρμόσιμου νευρωνικού δικτύου - ταξινομητή που αποτελεί το Υποσύστημα Προσαρμογής της Γνώσης. Το νευρωνικό δίκτυο έχει εκπαιδευτεί έτσι ώστε να ορίζει μια σημασιολογική ετικέτα μαζί με ένα βαθμό εμπιστοσύνης για κάθε περιοχή.

Επιπρόσθετα εξάγονται οι χωρικές σχέσεις των περιοχών, που μαζί με τα αποτελέσματα ταξινόμησης, αποτελούν το σώμα ισχυρισμών του Υποσυστήματος Αναπαράστασης

Τυπικής Γνώσης (βάσης γνώσης). Ο σκοπός της βάσης γνώσης, στο συγκεκριμένο πρόβλημα, είναι να επαναπροσδιορίσει κάποιες από τις κατηγορίες που εξάγονται από τους ταξινομητές, προσαρμόζοντας τις εξόδους τους σε νέα γνώση που συλλέγεται από τη συγκεκριμένη εφαρμογή.

Η νέα αυτή γνώση αποτελεί το σύνολο ατόμων – δεδομένων, που θα χρησιμοποιηθεί για περαιτέρω προσαρμογή του νευρωνικού δικτύου, βάσει του αλγορίθμου που περιγράφηκε στο Κεφάλαιο 3. Έπειτα από κάποια βήματα, δεν θα είναι δυνατή η περαιτέρω τροποποίηση των εξόδων του δικτύου, και αυτό θα σηματοδοτήσει και το τέλος της διαδικασίας προσαρμογής του δικτύου.

Στη συνέχεια, τα αποτελέσματα (ετικέτες ταξινόμησης) του δικτύου θα αποτελέσουν την είσοδο στο σημασιολογικό αλγόριθμο κατάτμησης, ο οποίος θα συγχωνεύσει τις γειτονικές περιοχές, που μοιράζονται κοινές σημασιολογικές ετικέτες, για να δημιουργήσει μια βελτιωμένη κατάτμηση της εικόνας.



Σχήμα 6.3 Σημασιολογική προσαρμογή νευρωνικού ταξινομητή για κατάτμηση εικόνων

Το πεδίο εφαρμογής που επιλέχθηκε για την αξιολόγηση του συστήματος αφορά σε φωτογραφίες παρμένες από διακοπές.

Το νευρωνικό δίκτυο που κατασκευάστηκε είναι τύπου multilayer perceptron και δέχεται ένα διάνυσμα εισόδου αποτελούμενο από 45 στοιχεία, που περιλαμβάνουν περιγραφείς MPEG της κάθε περιοχής που προκύπτει από την κατάτμηση των εικόνων.

Τα 45 αυτά στοιχεία προέκυψαν από εφαρμογή ανάλυσης πρωτογενών συνιστωσών (principal component analysis, [29]) σε ένα μεγαλύτερο σύνολο από 400 χαρακτηριστικά κάθε περιοχής, που περιλαμβάνουν τους εξής περιγραφείς (descriptors):

- Περιγραφέα κλιμακούμενου χρώματος (Scalable Color), που είναι ένα χρωματικό ιστόγραμμα στον χώρο Hue, Saturation, Value (HSV), κωδικοποιημένο μέσω ενός μετασχηματισμού Haar.
- Περιγραφέα Ομογενούς Υφής (Homogeneous Texture), που περιλαμβάνει ένα μωσαϊκό των μορφών υφής κάθε περιοχής.
- Περιγραφέα της μορφής του σχήματος (Region Shape), που είναι ιδιαίτερα χρήσιμος εφόσον εμφανίζονται συγκεκριμένα σχήματα στις εικόνες.
- Περιγραφέα Ιστογράμματος Ακμών (Edge Histogram), που κωδικοποιεί τις ακμές που εμφανίζονται στις εικόνες.

Το δίκτυο έχει 12 εξόδους, που αντιστοιχούν στις δώδεκα έννοιες που αποτελούν το αλφάβητο εννοιών της μηχανής συλλογιστικής, οι οποίες είναι οι εξής:

$$C = \{Person, Sand, Building, Pavement, Sea, Sky, Wave, Dried_Plant, Grass, Tree, Trunk, Ground\} \quad (6.5)$$

Με βάση την τεχνική του κλαδέματος (pruning), διαμορφώθηκε μια αρχιτεκτονική με δύο κρυμμένα επίπεδα, αποτελούμενα από 30 και 12 νευρώνες αντίστοιχα, χωρίς πλήρεις συνδέσεις μεταξύ των επιπέδων.

Η κατάτμηση 200 εικόνων οδήγησε σε ένα σύνολο 4000 περιοχών (και σε αντίστοιχο αριθμό διανυσμάτων εισόδου) που χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου, ενώ τα τμήματα από 50 διαφορετικές εικόνες χρησιμοποιήθηκαν για την αξιολόγηση της απόδοσής (γενίκευσής) του.

Τα μέτρα – δείκτες που χρησιμοποιούμε προκειμένου να κρίνουμε την επίδοση του ταξινομητή μας είναι η ακρίβεια (precision) και η ανάκληση (recall) :

$$\text{Precision} = \frac{\text{Σωστά ταξινομημένα τμήματα στην κατηγορία}}{\text{Ταξινομημένα τμήματα στην κατηγορία}} \quad (6.6)$$

$$\text{Recall} = \frac{\text{Σωστά ταξινομημένα τμήματα στην κατηγορία}}{\text{Σύνολο τμημάτων στην κατηγορία}} \quad (6.7)$$

Το μέτρο precision μας δίνει το λόγο του πλήθους των προτύπων που ταξινομήθηκαν σωστά σε κάθε κατηγορία προς το πλήθος όλων των προτύπων που ταξινομήθηκαν στη συγκεκριμένη κατηγορία. Το μέτρο recall μας δίνει το πλήθος των προτύπων που ταξινομήθηκαν σωστά σε κάθε κατηγορία προς το πλήθος όλων των προτύπων που πραγματικά ανήκουν σε αυτή την κατηγορία. Όπως φαίνεται από τα παραπάνω για κάθε κατηγορία θα έχουμε μια τιμή precision και μια τιμή recall.

Πίνακας 6.2 Μάθηση και Γενίκευση του νευρωνικού δικτύου

Label	Training			Test		
	Regions	Precision	Recall	Regions	Precision	Recall
Person	136	100%	100%	38	56.25%	47.3%
Sand	114	100%	96.4%	58	75%	51.7%
Building	126	100%	96.8%	54	58.8%	37%
Pavement	104	80.95%	98%	32	25%	18%
Sea	136	100%	97%	40	68.1%	75%
Sky	138	100%	98.5%	44	64.7%	50%
Wave	94	100%	100%	18	33.3%	66.6%
Dried Plant	162	100%	97.5%	32	50%	37.5%
Grass	150	100%	100%	40	53.3%	55%

Tree	138	97.14%	98.5%	46	63.1%	52,1%
Trunk	66	100%	96.9%	36	57.1%	22.2%
Ground	124	100%	96.7%	56	24.5%	53.5%

Ο νευρωνικός ταξινομητής δέχεται στην είσοδό του τα (45) χαρακτηριστικά κάθε περιοχής, και ταξινομεί την περιοχή σε μια από τις 12 έννοιες, ανεξάρτητα από τις υπόλοιπες περιοχές που αποτελούν την κάθε εικόνα εισόδου.

Στη συνέχεια, χρησιμοποιούμε χωρικές συσχετίσεις ανάμεσα στις περιοχές μιας εικόνας, για να βελτιώσουμε την απόδοση του νευρωνικού ταξινομητή, και ως αποτέλεσμα αυτής και τη συνολική κατάτμηση των εικόνων.

Για να γίνει αυτό δυνατό, ορίστηκε μια Βάση Γνώσης, η οποία σύμφωνα με τις χωρικές σχέσεις μεταξύ των περιοχών, επαναπροσδιορίζει κάποιες έννοιες. Η αναπαράσταση της γνώσης καθώς και η συλλογιστική έγινε με παρόμοιο τρόπο με αυτό που περιγράφηκε στην προηγούμενη ενότητα και πιο συγκεκριμένα στο Παραδειγμα 1. Το σώμα ορολογίας που χρησιμοποιήσαμε είναι αυτό του Πίνακα 6.1 και επαναλαμβάνεται στον παρακάτω πίνακα.

Πίνακας 6.3 Το σώμα ορολογίας για την προσαρμογή ενός νευρωνικού δικτύου

$T = \{ \text{SEA} \equiv \text{Sea} \sqcap ((\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave}))$	
$\sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sea} \sqcup \text{Wave} \sqcup \text{Sky}))$	
$\text{SAND} \equiv \text{Sand} \sqcap ((\exists \text{right-of.}(\text{Sand} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sand} \sqcup \text{Wave}))$	
$\sqcup (\exists \text{above-of.}(\text{Sand} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sand} \sqcup \text{Wave} \sqcup \text{Sea}))$	
$\text{WAVE} \equiv \text{Wave} \sqcap ((\exists \text{right-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{left-of.}(\text{Sea} \sqcup \text{Wave}))$	
$\sqcup (\exists \text{above-of.}(\text{Sea} \sqcup \text{Wave})) \sqcup (\exists \text{below-of.}(\text{Sea} \sqcup \text{Wave}))$	
$\}$	
$R = \{ \text{left-of}^- = \text{right-of}, \text{above-of}^- = \text{below-of} \}$	

Διορθώνοντας τις επιθυμητές εξόδους του νευρωνικού, με βάση το Υποσύστημα Γνώσης, που περιλαμβάνει τη Βάση Γνώσης, και τη μηχανή Συλλογιστικής, το νευρωνικό δίκτυο προσαρμόζεται - επανεκπαιδεύεται με βάση τον αλγόριθμο του Κεφαλαίου 3, η δε απόδοσή του βελτιώνεται, όσον αφορά στις 3 ως άνω έννοιες, όπως δείχνει ο παρακάτω πίνακας.

Πίνακας 6.4 Απόδοση του Νευρωνικού Ταξινομητή μετά την Προσαρμογή του

Label	Regions	NN Performance		Adapted NN	
		Precision	Recall	Precision	Recall
Person	38	56.25%	47.3%	56.25%	47.3%
Sand	58	75%	51.7%	79.1%	65.5%
Building	54	58.8%	37%	58.8%	37%
Pavement	32	25%	18%	25%	18%
Sea	40	68.1%	75%	85%	77.2%
Sky	44	64.7%	50%	64.7%	50%
Wave	18	33.3%	66.6%	46.4%	72.2%
Dried Plant	32	50%	37.5%	50%	37.5%
Grass	40	53.3%	55%	53.3%	55%
Tree	46	63.1%	52,1%	63.1%	52,1%
Trunk	36	57.1%	22.2%	57.1%	22.2%
Ground	56	24.5%	53.5%	24.5%	53.5%

6.4.2 Προσαρμογή Συμβολικής Γνώσης από Τεχνικές Μηχανικής Μάθησης - Νευρωνικά Δίκτυα

Στη συνέχεια, εφαρμόζουμε τη μέθοδο του Κεφαλαίου 5 (Σχήμα 5.2) για την ταξινόμηση και κατάτμηση εικόνων, εστιάζοντας στην προσαρμογή της Νευρωνικο-Συμβολικής Αρχιτεκτονικής στην παρούσα εφαρμογή.

Τα δεδομένα μας είναι τα ίδια με αυτά της προηγούμενης παραγράφου. Οι έννοιες της Βάσης Γνώσης είναι πάλι αυτές που φαίνονται στην (6.5). Οι ρόλοι που αναπαριστούν τις χωρικές συσχετίσεις είναι οι ακόλουθοι: above – of, below – of, left – of and right – of και αφορούν σε γειτονικά τμήματα και παρέχονται από τον αλγόριθμο κατάτμησης

που στο Σχήμα 5.2 περιλαμβάνεται στο Στρώμα Σημασιολογικής Ερμηνείας. Τα άτομα της Βάσης Γνώσης είναι τα τμήματα (segments) που αποτέλεσαν το σύνολο εκπαίδευσης του νευρωνικού δικτύου στην προηγούμενη εφαρμογή.

Χρησιμοποιήσαμε τις σχέσεις (5.1) - (5.2) για να υπολογίσουμε τις συναρτήσεις πυρήνα για όλα τα άτομα – τμήματα εικόνων της Βάσης Γνώσης.

Τα νέα άτομα, της συγκεκριμένης εφαρμογής, είναι τα τμήματα του συνόλου που χρησιμοποιήθηκε για τον έλεγχο της απόδοσης του νευρωνικού δικτύου στο προηγούμενο εδάφιο.

Ακολουθώντας τη μέθοδο που αναπτύχθηκε στο εδάφιο 5.3, μεταφέραμε τις τιμές των συναρτήσεων πυρήνα στη δομή του νευρωνικού δικτύου kernel multilayer perceptron (που περιγράφηκε στο Κεφάλαιο 3) με δύο επίπεδα, όπως στο προηγούμενο εδάφιο, και εκπαιδεύσαμε το δίκτυο με όλα τα άτομα της βάσης γνώσης. Στη συνέχεια ελέγξαμε την απόδοση του δικτύου τόσο στο σύνολο εκπαίδευσης, όσο και στο σύνολο των νέων ατόμων. Η απόδοση του δικτύου ήταν παρεμφερής με αυτήν του Πίνακα 6.4 που επαληθεύει την δυνατότητα των τεχνικών μηχανικής μάθησης να ενσωματώνουν αναπαραστάσεις γνώσης αποτελεσματικά.

Στη συνέχεια όμως, επιλέξαμε ορισμένα τμήματα και εικόνες, στα οποία η μέθοδος δίδει λανθασμένες ετικέτες και μεταφέραμε τα άτομα αυτά στο ABox της Βάσης Γνώσης. Η προσαρμογή του Υποσυστήματος Τυπικής Γνώσης, δηλαδή της Βάσης Γνώσης, θα γίνει με την δημιουργία νέων αξιωμάτων που περιγράφουν τις ιδιαιτερότητες των ατόμων σε σχέση με τις χωρικές συσχετίσεις τους, όπως περιγράφηκε στο εδάφιο 5.3.3.

Τα νέα αξιώματα αφορούσαν πάλι τις έννοιες Sea, Sand, and Wave. Για παράδειγμα, θεωρώντας ότι Sea είναι η έννοια F_1 οι έννοιες που σχηματίζονται από τον συνδυασμό των χωρικών συσχετίσεων με τις υπόλοιπες έννοιες της Γνώσης είναι οι ακόλουθες:

$\exists below - of .Sea, \exists below - of .Sky, \exists below - of .Sand, \dots, \exists above - of .Sea$,

οι οποίες σχηματίζουν το σύνολο των σχετιζόμενων εννοιών $R_{F_1}F_1 \dots R_{F_1}F_i$.

Ένα προσαρμοσμένο αξίωμα ήταν

$$\begin{aligned} Sea \equiv & \exists below - of .Sky \sqcup \exists above - of .Sand \sqcup \exists above - of .Wave \sqcup \exists right - of .Wave \\ & \sqcup \exists left - of .Wave \sqcup \exists left - of .Sea \sqcup \exists right - of .Sea \sqcup \exists above - of .Sea \sqcup \\ & \exists below - of .Sea \end{aligned}$$

(6.8)

Η προσαρμοσμένη γνώση μεταφέρθηκε και πάλι με τη βοήθεια των συναρτήσεων πυρήνα (5.1) – (5.2) από τη βάση γνώσης στο kernel multilayer perceptron, το οποίο ήταν σε θέση να βελτιώσει την απόδοσή του στην ταξινόμηση των τμημάτων εικόνων ως προς τις τρεις έννοιες, όπως φαίνεται στον επόμενο Πίνακα

Πίνακας 6.5 Απόδοση του Ταξινομητή μετά την Προσαρμογή της Συμβολικής Γνώσης

		NN Performance		Adapted KB	
Label	Regions	Precision	Recall	Precision	Recall
Person	38	56.25%	47.3%	56.25%	47.3%
Sand	58	75%	51.7%	83.1%	72.1%
Building	54	58.8%	37%	58.8%	37%
Pavement	32	25%	18%	25%	18%
Sea	40	68.1%	75%	88%	79.2
Sky	44	64.7%	50%	64.7%	50%
Wave	18	33.3%	66.6%	64.7	80.1
Dried Plant	32	50%	37.5%	50%	37.5%
Grass	40	53.3%	55%	53.3%	55%
Tree	46	63.1%	52,1%	63.1%	52,1%
Trunk	36	57.1%	22.2%	57.1%	22.2%
Ground	56	24.5%	53.5%	24.5%	53.5%

Θα πρέπει να σημειωθεί ότι η παραπάνω μέθοδος μπορεί να προτείνει νέες πληροφορίες και αξιώματα για τα άτομα στον μηχανικό γνώσης, ο οποίος θα έχει την ευθύνη να τα κάνει δεκτά και να τα ενσωματώσει στη Βάση Γνώσης.

7. Συμπεράσματα και Μελλοντικές Επεκτάσεις

Στην παρούσα εργασία μελετήθηκε μια σύγχρονη ερευνητική περιοχή της Τεχνητής Νοημοσύνης, η ανάπτυξη συστημάτων που εμπεριέχουν τόσο τεχνικές αναπαράστασης γνώσης - εστιάζοντας σε εκφραστικές περιγραφικές λογικές - όσο και τεχνικές μηχανικής μάθησης, δίδοντας έμφαση σε τεχνητά νευρωνικά δίκτυα. Η ανάπτυξη αυτή βασίζεται σε μια νέα αρχιτεκτονική που προσομοιώνει ένα νευρωνικο-συμβολικό κύκλο επεξεργασίας, περιλαμβάνοντας ένα υποσύστημα αναπαράστασης τυπικής γνώσης και ένα υποσύστημα προσαρμογής της γνώσης, μέσω μιας δομής τεχνητού νευρωνικού δικτύου. Χρησιμοποιούνται σύγχρονες τεχνολογίες για μεταφορά της γνώσης από το υποσύστημα της βάσης γνώσης στο νευρωνικό δίκτυο και αντίστροφα. Μέθοδοι και συναρτήσεις πυρήνα χρησιμοποιούνται στο πλαίσιο αυτό, ενώ οι τεχνικές μηχανικής μάθησης περιλαμβάνουν μηχανές διανυσμάτων υποστήριξης, απλά και πολυεπίπεδα perceptrons. Η προσαρμογή της γνώσης γίνεται στο – υποσυμβολικό - επίπεδο των μεθόδων μηχανικής μάθησης, και μπορεί να εξαχθεί, στη συνέχεια, στο υποσύστημα αναπαράστασης γνώσης, για εμπλουτισμό της βάσης γνώσης με περιπτώσεις εφαρμογής της στον πραγματικό κόσμο.

Στην εργασία αυτή χρησιμοποιείται ένα πρόβλημα ανάλυσης – ταξινόμησης και κατάταξης – εικόνων για την επίδειξη των θεωρητικών αποτελεσμάτων της εργασίας. Η περιγραφόμενη αρχιτεκτονική, όμως, αποτελεί μια γενική δομή για ανάπτυξη συστημάτων που έχουν τη δυνατότητα να ενσωματώνουν διαθέσιμες οντολογίες και βάσεις γνώσης, και να προσαρμόζουν τη γνώση τους σε προβλήματα του πραγματικού κόσμου όπως είναι μεταβλητές συνθήκες χρήσης και περιβάλλοντος, διαφορετικοί χρήστες και εννοιολογικό πλαίσιο αλληλεπίδρασης.

Η διπλωματική αυτή εργασία αφορά σε ένα ερευνητικό πεδίο ιδιαίτερης σημασίας για την τεχνητή νοημοσύνη και γι' αυτό η βασική της αρχιτεκτονική, όπως και τα

αποτελέσματά της υποβλήθηκαν σε δυο διεθνή συνέδρια του σημασιολογικού ιστού και των τεχνητών νευρωνικών δικτύων [69, 70].

Μια σειρά από ανοικτά θέματα αποτελούν μελλοντικά πεδία έρευνας, όπως είναι τα εξής:

- Η επέκταση των τρόπων μεταφοράς της αναπαράστασης γνώσης στις αρχιτεκτονικές μηχανικής μάθησης.
- Η χρήση μεθόδων ασαφούς λογικής στην μεταφορά αυτή.
- Η μελέτη διαφορετικών τρόπων εξαγωγής της γνώσης από τις αρχιτεκτονικές μηχανικής μάθησης και την μετέπειτα ανανέωση της αναπαράστασης γνώσης.
- Η εφαρμογή των μεθόδων σε μια σειρά από προβλήματα, όπως η επικοινωνία ανθρώπου μηχανής, η αναζήτηση και ανάκτηση πολυμεσικών πληροφοριών, κá.
- Η ανάπτυξη συστημάτων κατανόησης και ανάπτυξης συλλογισμών (perception και cognition).

Η παρούσα διπλωματική εργασία θέτει τα θεμέλια για την επέκταση της περιγραφόμενης μεθοδολογίας και των τεχνικών που αναπτύχθηκαν στις ανωτέρω περιοχές έρευνας, οι οποίες αναμένεται να παρουσιάσουν πληθώρα νέων αποτελεσμάτων τα επόμενα χρόνια.

8. Βιβλιογραφία

- [1] F. Baader, D. McGuinness, D. Nardi, and P. Patel-Schneider. The Description Logic Handbook: Theory, implementation and applications, Cambridge University Press, 2002.
- [2] R. Branchman, H. Levesque. Knowledge Representation and Reasoning, Elsevier, 2004.
- [3] S. Bechhofer, F. van Harmelen, J. Hendler, I. Horrocks, D. L. McGuinness, P. F. Patel-Schneider and L. A. Stein eds. OWL Web Ontology Language Reference, 2004.
- [4] Γ. Στοϊλος. Εισαγωγή στις Περιγραφικές Λογικές, Σημειώσεις 2007
- [5] Γ. Στοϊλος. Γλώσσες Αναπαράστασης Γνώσης στο Σημασιολογικό Ιστό, Σημειώσεις 2007
- [6] P. F. Patel-Schneider, and I. Horrocks. OWL 1.1 Web Ontology Language Overview, <http://webont.org/owl/1.1/overview.html>.
- [7] P. F. Patel-Schneider, P. Hayes, and I. Horrocks. OWL Web Ontology Language Semantics and Abstract Syntax. Tech. rep., W3C, Feb. 2004. W3C Recommendation, URL <http://www.w3.org/TR/2004/REC-owl-semantics-20040210/>.
- [8] B. C. Grau, and B. Motik. OWL 1.1 web ontology language: Model-theoretic semantics. <http://www.w3.org/Submission/owl11-semantics/>, 2006.
- [9] G. Stoilos, G. Stamou, J.Z. Pan, V. Tzouvaras, and I. Horrocks. Reasoning with very expressive fuzzy description logics, Journal of Artificial Intelligence Research, 30(8) pp. 273–320, 2007.
- [10] U. Straccia. Reasoning within fuzzy description logics, Journal of Artificial Intelligence Research, 14, pp. 137–166, 2001.
- [11] H. Knublauch, R. W. Ferguson, N. F. Noy, and M. A. Musen. The protégé owl plugin: An open development environment for semantic web applications, Third International Semantic Web Conference - ISWC 2004 (Hiroshima, Japan, 2004).
- [12] G. Stoilos, G. Stamou, V. Tzouvaras, J.Z. Pan and I. Horrocks. Fuzzy OWL: Uncertainty and the Semantic Web. In Proceedings of the 1st International Workshop of OWL: Experiences and Directions, Galway, Ireland, 2005.

- [13] G. Stoilos, N. Simou, G. Stamou and S. Kollias. Uncertainty and the Semantic Web, IEEE Intelligent Systems, 21(5), pp. 84-87, 2006.
- [14] G. Stoilos, G. Stamou, V. Tzouvaras, J.Z. Pan, and I. Horrocks. The Fuzzy Description Logic f-SHIN. In Proceedings of the 1st International Workshop on Uncertainty Reasoning for the Semantic Web (URSW 05), Galway, 2005
- [15] I. Horrocks, U. Sattler, and S. Tobies. Reasoning with Individuals for the Description Logic SHIQ. In David MacAllester, editor, CADE-2000, number 1831 in LNAI, pp. 482–496, Springer-Verlag, 2000.
- [16] I. Horrocks, P. F. Patel-Schneider and F. van Harmelen. From SHIQ and RDF to OWL: The making of a web ontology language, Journal of Web Semantics 1, 2003.
- [17] N. Simou, G. Stoilos, V. Tzouvaras, G. Stamou, and S. Kollias. Storing and querying fuzzy knowledge in the semantic web, 7th International Workshop on Uncertainty Reasoning For the Semantic Web, Karlsruhe, Germany, October 2008.
- [18] J. Z. Pan, E. Thomas and D. Sleeman. *ONTOSEARCH2*: Searching and Querying Web Ontologies, Proc. of the IADIS International Conference WWW/Internet 2006.
- [19] F. Bobillo, M. Delgado, and J. Gómez-Romero. A Crisp Representation for Fuzzy SHOIN with Fuzzy Nominals and General Concept Inclusions, 2006.
- [20] The *ONTOSEARCH2* search and query engine for ontologies, <http://dipper.csd.abdn.ac.uk/OntoSearch/about.jsp>.
- [21] The *KAON2* ontology and rule reasoned, <http://kaon2.semanticweb.org/>.
- [22] The *FiRE* fuzzy DL reasoning and query engine, <http://www.image.ece.ntua.gr/~nsimou>.
- [23] The *fuzzyDL* fuzzy DL and fuzzy datatype reasoning engine, <http://gaia.isti.cnr.it/~straccia/software/fuzzyDL/fuzzyDL.html>.
- [24] A. Chortaras, G. Stamou, A. Stafylopatis, Adaptation of Weighted Fuzzy Programs, Lecture Notes in Computer Science, 4132, pp. 45-54, 2006.
- [25] B. Schoelkopf, A. Smola Learning with Kernels, The MIT Press, Cambridge, 2002.
- [26] T. Gartner, J. Lloyd, P. Flach. Kernels and distances for structured data. Machine Learning, 57, pp. 205-232, 2004.
- [27] J. Shawe-Taylor, N. Cristianini. Kernel Methods for Pattern Analysis, Cambridge University Press, 2004.
- [28] C. Bishop. Pattern Recognition and Machine Learning, Springer, 2006.
- [29] R. Duda, P. Hart, D. Stork. Pattern Classification, John Wiley & Sons, Inc, 2001.

- [30] S. Haykin. *Neural Networks: A Comprehensive Foundation*, Prentice Hall International, Inc, 1999.
- [31] Κ. Διαμαντάρας. *Τεχνητά Νευρωνικά Δίκτυα*, Κλειδάριθμος, 2007.
- [32] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, pp. 115–133, 1943.
- [33] E. Kolman and M. Margaliot. Are artificial neural networks white boxes? *IEEE Trans. on Neural Networks*, 16(4), pp. 844–852, 2005.
- [34] W. Duch. Similarity based methods: a general framework for classification, approximation and association, *Control and Cybernetics* 29 (4), pp. 937-968, 2000.
- [35] N. Fanizzi, C. d' Amato. A declarative kernel for ALC concept descriptions. In : F. Esposito, Z. W. Ras, D. Malerba, G. Semeraro (eds) *ISMIS 2006. LNCS (LNAI)* Springer, vol. 4203, pp. 322-331, 2006.
- [36] S. Bloehdorn and Y. Sure. Kernel methods for mining instance data in ontologies. In *Proceedings of the 6th International Semantic Web Conference (ISWC)*, 2007.
- [37] N. Fanizzi, C. d' Amato, and F. Esposito. Randomized metric induction and evolutionary conceptual clustering for semantic knowledge bases. In *Proceedings of CIKM 07*, 2007.
- [38] N. Fanizzi, C. d' Amato, and F. Esposito. Statistical learning for inductive query answering on owl ontologies. In *Proceedings of the 7th International Semantic Web Conference (ISWC)*, pp. 195–212, 2008.
- [39] N. Fanizzi, C. d' Amato. Inductive concept retrieval and query answering with semantic knowledge bases through kernel methods. In: B. Apolloni, R. J. Howlett, L. Jain (eds) *KES2007, Part I. LNCS (LNAI)*, vol. 4692, pp. 148-155, 2007.
- [40] M. Ehrig, P. Haase, M. Hefke, N. Stojanovic. Similarity for ontologies – a comprehensive framework. In : *Proceedings of the 13th European Conference on Information Systems, ECIS 2005*.
- [41] Sebastian Bader, Pascal Hitzler, Steffen Hölldobler. ‘Connectionist Model Generation: A First-Order Approach,’ *Neurocomputing*, Elsevier, 2008.
- [42] B. Hammer, P. Hitzler (eds.). *Perspectives of Neural-Symbolic Integration. Studies in Computational Intelligence*, Vol. 77. Springer, ISBN 978-3-540-73952-1, 2007.
- [43] A. S. d'Avila Garcez, L. C. Lamb and D. M. Gabbay. *Neural-Symbolic Cognitive Reasoning*, Cognitive Technologies, Springer, ISBN 978-3-540-73245-7, 2008.

- [44] S. Bader, P. Hitzler, S. Hölldobler. The Integration of Connectionism and First-Order Knowledge Representation and Reasoning as a Challenge for Artificial Intelligence, *Information* 9 (1), 2006.
- [45] A. S. d'Avila Garcez, K. Broda and D. M. Gabbay. *Neural-Symbolic Learning Systems: Foundations and Applications*, Perspectives in Neural Computing, Springer-Verlag, ISBN 1-85233-512-2, 2002.
- [46] G. G. Towell and J. W. Shavlik. Knowledge-based artificial neural networks. *Artificial Intelligence*, 70(1-2):119– 165, 1994.
- [47] G. Pinkas. Propositional non-monotonic reasoning and inconsistency in symmetric neural networks. In John Mylopoulos and Raymond Reiter, editors, *Proceedings of the 12th International Joint Conference on Artificial Intelligence*, pp. 525–530. Morgan Kaufmann, 1991.
- [48] A. S. d'Avila Garcez, K. Broda, and D. M. Gabbay. Symbolic knowledge extraction from trained neural networks: A sound approach. *Artificial Intelligence*, 125, pp. 155–207, 2001.
- [49] S. Hölldobler, Y. Kalinke, and H. Störr. Approximating the semantics of logic programs by recurrent neural networks. *Applied Intelligence*, 11, pp. 45–58, 1999.
- [50] W. Duch. Towards comprehensive foundations of computational intelligence. In: W. Duch and J. Mandziuk, *Challenges for Computational Intelligence*. Springer Studies in Computational Intelligence, Vol. 63, pp. 261-316, 2007.
- [51] G. Stamou and S. Kollias, (eds). “Multimedia Content and the Semantic Web: Methods, Standards and Tools”, John Wiley & Sons Ltd, 414 pages, May, 2005.
- [52] N. Simou, Th. Athanasiadis, S. Kollias, G. Stamou, and A. Stafylopatis. Semantic adaptation of neural network classifiers in image segmentation. *18th International Conference on Artificial Neural Networks (ICANN 2008)*, pp. 907-916, September 2008, Prague, Czech Republic, 2008.
- [53] C. Meghini, F. Sebastiani, and U. Straccia. Reasoning about the form and content for multimedia objects (extended abstract). In *Proceedings of AAAI 1997 Spring Symposium on Intelligent integration and Use of Text, Image, Video and Audio* (Stanford University, California, 1997), pp. 89–94, 1997.
- [54] M. Christel and A. Hauptmann. The use and utility of high-level semantic features in video retrieval, *Proceedings of 4th International Conference on Image and Video Retrieval, CIVR 2005*.
- [55] E. Sciascio, and F. Donini. Description logics for image recognition: a preliminary proposal. In *Proceedings of the International Workshop on Description Logics (DL 99)*, 1999.

- [56] P. Salembier, and F. Marqués. Region-based representations of image and video: Segmentation tools for multimedia services. *IEEE Transactions on Circuits and Systems for Video Technology* 9, 8, pp. 1147–1169, 1999.
- [57] N. Doulamis, A. Doulamis, and S. Kollias. On-line retrainable neural networks: Improving performance of neural networks in image analysis problems. *IEEE Transactions on Neural Networks* 11, pp. 1-20, 2000.
- [58] J. Hunter. Adding multimedia to the semantic web - building an Mpeg-7 ontology. *Proceedings of the First Semantic Web Working Symposium*, pp. 261–281, 2001.
- [59] C. Meghini, F. Sebastiani, and U. Straccia. A model of multimedia information retrieval. *Journal of the ACM* 48, 5, pp. 909–970, 2001.
- [60] L. Zhang, F. Lin, and B. Zhang. Support vector machine learning for image retrieval. *Image Processing, 2001. Proceedings. 2001 International Conference on* 2, 2001.
- [61] M. Naphade and T. Huang. A probabilistic framework for semantic video indexing, filtering and retrieval, *IEEE Trans. on Multimedia* 3, 1, pp. 144–151, 2001.
- [62] S. Bloehdorn, N. Simou, V. Tzouvaras, K. Petridis, S. Handschuh, Y. Avrithis, I. Kompatsiaris, S. Staab, and M. Strintzis. Knowledge representation for semantic multimedia content analysis and reasoning. *Proc. of European Workshop on the Integration of Knowledge, Semantics and Digital Media Technology (EWIMT)*, London, U.K., November 25-26, 2004.
- [63] G. Stoilos, G. Stamou, V. Tzouvaras, J. Pan, and I. Horrocks. A fuzzy description logic for multimedia knowledge representation. In *Proc. of the International Workshop on Multimedia and the Semantic Web*, 2005.
- [64] N. Simou, C. Saathoff, S. Dasiopoulou, E. Spyrou, N. Voisine, V. Tzouvaras, I. Kompatsiaris, Y. Avrithis, and S. Staab. An ontology infrastructure for multimedia reasoning. *International Workshop VLBV05, Sardinia, Italy, 15-16 September 2005*.
- [65] T. Athanasiadis, V. Tzouvaras, K. Petridis, F. Precioso, Y. Avrithis, and Y. Kompatsiaris. Using a multimedia ontology infrastructure for semantic annotation of multimedia content. In *Proceedings of the 5th International Workshop on Knowledge Markup and Semantic Annotation*, 2005.
- [66] N. Simou, V. Tzouvaras, Y. Avrithis, G. Stamou, and S. Kollias. A visual descriptor ontology for multimedia reasoning. In *Proc. of Workshop on Image Analysis for Multimedia Interactive Services (WIAMIS '05)*, Montreux, Switzerland, April 13-15, 2005.
- [67] T. Athanasiadis, P. Mylonas, Y. Avrithis, and S. Kollias. Semantic image segmentation and object labeling. *IEEE Trans. on Circuits and Systems for Video Technology* 17, 3, pp. 298–312, 2007.

- [68] P. Mylonas, E. Spyrou, Y. Avrithis and S. Kollias. Using Visual Context and Region Semantics for High-Level Concept Detection, *IEEE Trans. on Multimedia*, 11, 2, pp. 229-243, 2009.
- [69] I. Kollia, N. Simou, G. Stamou and A. Stafylopatis. Interweaving Knowledge Representation and Adaptive Neural Networks, (position paper), *European Semantic Web Conference, IRMLeS Workshop*, Crete, June 2009.
- [70] I. Kollia, N. Simou, G. Stamou and A. Stafylopatis. Connectionist Models For Formal Knowledge Adaptation, *International Conference on Artificial Neural Networks*, Cyprus, September 2009.