



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΕΠΙΚΟΙΝΩΝΙΩΝ, ΗΛΕΚΤΡΟΝΙΚΗΣ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ

Υλοποίηση συστήματος μεταφόρτωσης
διεργασιών για έξυπνες εφαρμογές με τη χρήση
ασαφούς λογικής

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΜΑΤΙΑΤΟΥ ΑΛΙΚΗΣ

Επιβλέπων: Συμεών Παπαβασιλείου
Καθηγητής Ε.Μ.Π.

ΕΡΓΑΣΤΗΡΙΟ ΔΙΑΧΕΙΡΙΣΗΣ ΚΑΙ ΒΕΛΤΙΣΤΟΥ ΣΧΕΔΙΑΣΜΟΥ ΔΙΚΤΥΩΝ
Αθήνα, Νοέμβριος 2021



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Επικοινωνιών, Ηλεκτρονικής και Συστημάτων Πληροφορικής
Εργαστήριο Διαχείρισης και Βέλτιστου Σχεδιασμού Δικτύων

Υλοποίηση συστήματος μεταφόρτωσης διεργασιών για έξυπνες εφαρμογές με τη χρήση ασαφούς λογικής

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΜΑΤΙΑΤΟΥ ΑΛΙΚΗΣ

Επιβλέπων: Συμεών Παπαβασιλείου
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 8η Νοεμβρίου 2021.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Συμεών Παπαβασιλείου
Καθηγητής Ε.Μ.Π.

.....
Θεοδώρα Βαρβαρίγου
Καθηγήτρια Ε.Μ.Π.

.....
Ιωάννα Ρουσσάκη
Επικ. Καθηγήτρια Ε.Μ.Π.

Αθήνα, Νοέμβριος 2021

(Υπογραφή)

.....

ΑΛΙΚΗ ΜΑΤΙΑΤΟΥ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

© 2021 – All rights reserved



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Επικοινωνιών, Ηλεκτρονικής και Συστημάτων Πληροφορικής
Εργαστήριο Διαχείρισης και Βέλτιστου Σχεδιασμού Δικτύων

Copyright ©–All rights reserved Αλίχη Ματιάτου, 2021.

Με επιφύλαξη παντός δικαιώματος.

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.

Ευχαριστίες

Με την παρούσα διπλωματική εργασία ολοκληρώνονται οι σπουδές μου στην Σχολή Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου και κλείνει ένα σημαντικό κεφάλαιο της ζωής μου.

Θα ήθελα να ευχαριστήσω τον καθηγητή κύριο Παπαβασιλείου Συμεών για την επίβλεψη της διπλωματικής μου εργασίας καθώς επίσης ένα μεγάλο ευχαριστώ στους μεταδιδακτορικούς ερευνητές του εργαστηρίου Μάριο Αυγέρη και Δημήτρη Δεχουνιώτη για τη καθοδήγηση τους και για την υλοποίηση της παρούσας διπλωματικής εργασίας παρά τις προκλήσεις που επέβαλε ο κορονοϊός.

Τέλος οφείλω ένα μεγάλο ευχαριστώ στην οικογένειά μου και τους φίλους μου, που παρά τις όποιες δυσκολίες, με στήριξαν και με βοήθησαν σε όλη μου την πορεία και στο να φτάσω εδώ που είμαι σήμερα.

Περίληψη

Τα τελευταία χρόνια, το πλήθος των συσκευών που είναι συνδεδεμένες στο Διαδίκτυο αυξάνεται με ραγδαίο ρυθμό. Οι συσκευές αυτές, όπως είναι και το κινητό τηλέφωνο, παράγουν μεγάλο όγκο δεδομένων. Το υπολογιστικό πρότυπο του υπολογισμού στα άκρα φέρνει τους εξυπηρετητές πιο κοντά στις συσκευές και μαζί με την μεταφόρτωση διεργασιών από τις κινητές συσκευές στους κοντινούς εξυπηρετητές διευκολύνει την διαχείριση του όγκου δεδομένων.

Στο πλαίσιο της διπλωματικής εργασίας Χάρτες Ασαφούς Λογικής (Fuzzy Cognitive Maps) χρησιμοποιούνται για τη βασική μοντελοποίηση του συστήματος μεταφόρτωσης διεργασιών από κινητή συσκευή σε κοντινό εξυπηρετητή, από την πλευρά του εξυπηρετητή. Σύμφωνα με αυτή τη μέθοδο, σύνθετα συστήματα μοντελοποιούνται βάσει της υπάρχουσας γνώσης και της ανθρώπινης εμπειρίας σε ένα γράφο, μία ευνόητη αναπαράσταση γνώσης. Για την εκπαίδευση τέτοιου γράφου, εξετάζονται δύο αλγόριθμοι εκμάθησης, ο Active Hebbian Learning και ο Nonlinear Hebbian Learning και διερευνάται η επιρροή των παραμέτρων μάθησης που χρησιμοποιούν, η , γ , στα αποτελέσματα. Παρουσιάζεται η πειραματική υλοποίηση του γράφου αναπαράστασης του Χάρτη Ασαφούς Λογικής και των δύο αλγορίθμων, καθώς και τα αποτελέσματα των προσομοιώσεων. Τέλος, γίνεται μια μικρή σύγκριση μεταξύ των αλγορίθμων εκμάθησης και παρατίθενται προτάσεις για την περαιτέρω διερεύνηση και μοντελοποίηση του υπό εξέταση προβλήματος.

Λέξεις Κλειδιά

Υπολογισμός στα Άκρα, Χάρτης Ασαφούς Λογικής, Μεταφόρτωση Διεργασιών, Active Hebbian Learning, Nonlinear Hebbian Learning

Abstract

Over the past years, the number of devices connected to the Internet has grown rapidly. These types of devices (i.e. mobile phones) produce great volumes of data which require extensive processing capabilities and storage space. Edge computing brings servers closer to devices and along with computational offloading between mobile devices and edge servers, it facilitates data management operations.

In this thesis Fuzzy Cognitive Maps are used to model an offloading system between a mobile device and an edge server, on the server's side. According to this method, complex systems are modeled based on existing knowledge and human experience in an easy to understand knowledge representation using a graph.

In the training step of this method, two algorithms were tested, namely the Active Hebbian Learning and the Nonlinear Hebbian Learning, and the influence of the used learning parameters η, γ is investigated. The experimental implementation of the graph depicting the Fuzzy Cognitive Map and the two algorithms is presented, as well as the results of the simulations. Finally, a comparison is made between the learning algorithms and suggestions for further investigation and modelling of the problem are presented.

Keywords

Edge Computing, Fuzzy Cognitive Maps, Computational Offloading, Active Hebbian Learning, Nonlinear Hebbian Learning

Περιεχόμενα

Ευχαριστίες	1
Περίληψη	3
Abstract	5
Περιεχόμενα	8
Κατάλογος Σχημάτων	11
Κατάλογος Πινάκων	13
1 Εισαγωγή	15
1.1 Edge computing	15
1.2 Αντικείμενο της διπλωματικής	16
1.2.1 Συνεισφορά	16
1.3 Οργάνωση του τόμου	16
2 Σχετικές Εργασίες	17
2.1 Μεταφόρτωση διεργασιών (Computational Offloading)	17
2.1.1 Σύγχρονα προβλήματα και η συνεισφορά του offloading και του edge computing στις κινητές συσκευές	17
2.1.2 Σημαντικές παράμετροι προς μελέτη για το offloading	19
2.2 Χάρτης Ασαφούς Λογικής (Fuzzy Cognitive Maps)	20
2.2.1 Ενδεικτικές εργασίες χρήσης των FCMs	20
3 Θεωρητικό Υπόβαθρο	25
3.1 Αναλυτική περιγραφή FCM	25
3.1.1 Κατασκευή FCM και κατηγορίες αλγορίθμων εκμάθησης	27
3.2 Περιγραφή αλγορίθμου εκμάθησης Active Hebbian Learning (AHL)	29
3.2.1 Καθορισμός των παραμέτρων μάθησης	31
3.2.2 Κριτήρια τερματισμού	31
3.2.3 Υλοποίηση AHL σε FCM με n έννοιες-κόμβους	32

3.3	Περιγραφή αλγορίθμου εκμάθησης Nonlinear Hebbian Learning (NHL)	35
3.3.1	Καθορισμός παραμέτρων μάθησης	35
3.3.2	Κριτήρια τερματισμού	36
3.3.3	Υλοποίηση NHL σε FCM	36
4	Πειραματική Υλοποίηση και Αποτελέσματα Προσομοίωσης	39
4.1	Πειραματική Υλοποίηση	39
4.1.1	Παραγωγή Δεδομένων	39
4.1.2	Περιγραφή γράφου Fuzzy Cognitive Map	39
4.1.3	Επεξεργασία δεδομένων του FCM	40
4.1.4	Κατηγορίες γραφημάτων	42
4.1.5	Εργαλεία που χρησιμοποιήθηκαν	42
4.2	Αλγόριθμος AHL	42
4.2.1	Περιγραφή Υλοποίησης	42
4.2.2	Αποτελέσματα AHL και Αξιολόγηση	44
4.3	Αλγόριθμος NHL	62
4.3.1	Περιγραφή Υλοποίησης	62
4.3.2	Αποτελέσματα NHL και Αξιολόγηση	63
5	Επίλογος	73
5.1	Συμπεράσματα	73
5.2	Μελλοντική Εργασία	73
	Γλωσσάριο	75
	Βιβλιογραφία	76

Κατάλογος Σχημάτων

3.1	Διάγραμμα ροής αλγορίθμου εκμάθησης AHL	34
3.2	Διάγραμμα ροής προσαρμογής βαρών στον NHL	38
4.1	Διάταξη γράφου FCM υλοποίησης	40
4.2	Αρχικός τυχαίος γράφος	41
4.3	Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση η , $\lambda_1 = 0$)	46
4.4	Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση η , $\lambda_1 = 0$)	46
4.5	Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $\lambda_1 = 0$)	47
4.6	Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση η , $\lambda_1 = 0.2$)	47
4.7	Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση η , $\lambda_1 = 0.2$)	48
4.8	Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $\lambda_1 = 0.2$)	48
4.9	Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση η , $b_1 = 0.02$)	49
4.10	Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση η , $b_1 = 0.02$)	49
4.11	Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $b_1 = 0.02$)	50
4.12	Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση γ , $\lambda_2 = 0$)	52
4.13	Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση γ , $\lambda_2 = 0$)	52
4.14	Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση γ , $\lambda_2 = 0$)	53
4.15	Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση γ , $\lambda_2 = 0.2$)	53

4.16 Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση γ , $\lambda_2 = 0.2$)	54
4.17 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση γ , $\lambda_2 = 0$)	54
4.18 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση γ , $b_2 = 0.05$)	55
4.19 Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση γ , $b_2 = 0.05$)	55
4.20 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση γ , $b_2 = 0.05$)	56
4.21 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL ($\eta + \gamma = 1$ και σταθερά)	57
4.22 Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL ($\eta + \gamma = 1$ και σταθερά)	57
4.23 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, $\eta + \gamma = 1$ και σταθερά)	58
4.24 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (η , γ εκθετικά και διερεύνηση b_2)	59
4.25 Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (η , γ εκθετικά και διερεύνηση b_2)	59
4.26 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, η , γ εκθετικά και διερεύνηση b_2)	60
4.27 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (η εκθετικό και διερεύνηση γ σταθερής τιμής)	60
4.28 Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (η εκθετικό και διερεύνηση γ σταθερής τιμής)	61
4.29 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, η εκθετικό και διερεύνηση γ σταθερής τιμής)	61
4.30 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερεύνηση η)	64
4.31 Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση η)	64
4.32 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διερεύνηση η)	65
4.33 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερεύνηση γ)	66
4.34 Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση γ)	66
4.35 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διερεύνηση γ)	67
4.36 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL ($\eta = \gamma$)	68

4.37 Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL ($\eta = \gamma$)	68
4.38 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, ($\eta = \gamma$ »	69
4.39 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL ($\eta + \gamma = 1$)	69
4.40 Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL ($\eta + \gamma = 1$)	70
4.41 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, ($\eta +$ $\gamma = 1$ »	70
4.42 Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερε- ύνηση γ , $\eta = 0.01$)	71
4.43 Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση γ , $\eta = 0.01$)	71
4.44 Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διε- ρεύνηση γ , $\eta = 0.01$)	72

Κατάλογος Πινάκων

4.1	Παράμετροι μάθησης AHL η, γ βιβλιογραφίας	44
4.2	Τιμές b_1 όταν $\eta = b_1, (\lambda_1 = 0)$	45
4.3	Τιμές b_1 όταν $\eta = b_1 \cdot \exp(-0.2 \cdot c), (\lambda_1 = 0.2)$	45
4.4	Τιμές λ_1 όταν $\eta = 0.02 \cdot \exp(-\lambda_1 \cdot c), (b_1 = 0.02)$	45
4.5	Τιμές b_2 όταν $\gamma = b_2, (\lambda_2 = 0)$	51
4.6	Τιμές b_2 όταν $\gamma = b_2 \cdot \exp(-0.2 \cdot c), (\lambda_2 = 0.05s)$	51
4.7	Τιμές λ_2 όταν $\gamma = 0.05 \cdot \exp(-\lambda_2 \cdot c), (b_2 = 0.02)$	51
4.8	Τιμές η, γ για συνδυαστική αξιολόγηση AHL	56
4.9	Τιμές διερεύνησης η	63
4.10	Τιμές διερεύνησης γ	65
4.11	Τιμές η, γ για συνδυαστική αξιολόγηση NHL	67

Κεφάλαιο 1

Εισαγωγή

Η σημερινή εποχή χαρακτηρίζεται από τεχνολογική ανάπτυξη και από τον συνεχώς αυξανόμενο όγκο δεδομένων. Τα τελευταία χρόνια, τα δεδομένα αποκτούν ολοένα και περισσότερη αξία τόσο για τις επιχειρήσεις όσο και για την πλειονότητα των ανθρώπων. Συσχευές συνδεδεμένες στο Διαδίκτυο, οι οποίες αποτελούν το Διαδίκτυο των αντικειμένων (Internet of Things- IoT), παράγουν καθημερινά όγκο δεδομένων που αποθηκεύεται στις βάσεις δεδομένων των τελικών εξυπηρετητών (servers), στο υπολογιστικό νέφος (Cloud). Τέτοιες συσκευές είναι συνήθως τα κινητά τηλέφωνα, με τις πολλαπλές εφαρμογές που χρησιμοποιούνται καθημερινά, αλλά και οι αισθητήρες που συνεχώς καταγράφουν μετρήσεις και χρησιμοποιούνται κυρίως από επιχειρήσεις και βιομηχανίες. Συνεπώς, η ανάγκη για ανταλλαγή, αποθήκευση, επεξεργασία και ανάλυση αυτών των δεδομένων έχει γίνει πλέον επιτακτική για κάθε τομέα. Το φαινόμενο αυτό έχει προκαλέσει προβλήματα όπως το υψηλό εύρος ζώνης, δηλαδή ο μεγάλος ρυθμός μεταφοράς δεδομένων σε ένα κανάλι, τη γεωγραφική διασπορά των εξυπηρετητών, την καθυστέρηση επεξεργασίας αλλά και το ζήτημα της ιδιωτικότητας δεδομένων. Έτσι, προκειμένου να επιλυθούν, έχει δημιουργηθεί ένα υπολογιστικό πρότυπο που βρίσκεται πιο κοντά στις συσκευές, στην άκρη του Διαδικτύου και έχει ονομαστεί υπολογιστική ομίχλης ή υπολογισμός στα άκρα του δικτύου (fog computing/edge computing) [2].

1.1 Edge computing

Το edge computing γεφυρώνει το κενό μεταξύ του Cloud και των IoT συσκευών, καθώς ενεργοποιεί τον υπολογισμό, την αποθήκευση, την δικτύωση και την διαχείριση δεδομένων σε κόμβους του δικτύου σε κοντινή απόσταση από τις IoT συσκευές. Επομένως, όλες οι λειτουργίες που αφορούν τα δεδομένα δεν πραγματοποιούνται στον τελικό προορισμό, αλλά στη διαδρομή από την IoT συσκευή μέχρι τον εξυπηρετητή του Cloud. Πρόκειται για λύση που διευκολύνει τις IoT συσκευές, καθώς οι λειτουργίες και οι χρόνοι που αφορούν την επεξεργασία δεδομένων μειώνονται σημαντικά και κατ' επέκταση αυξάνονται οι διαθέσιμοι πόροι στην εκάστοτε συσκευή. Χαρακτηριστικό παράδειγμα αποτελεί η περίπτωση που η συσκευή δεν διαθέτει την απαραίτητη ισχύ ή πόρους για να διαχειριστεί και να επεξεργαστεί μεγάλο όγκο δεδομένων. Έτσι, στέλνεται μέρος αυτού του όγκου στον ενδιάμεσο κόμβο του

δικτύου και διευκολύνεται η διαδικασία διαχείρισης δεδομένων. Η διαδικασία αυτή αποτελεί την λεγόμενη μεταφόρτωση διεργασιών (computational offloading) [36].

1.2 Αντικείμενο της διπλωματικής

Προκειμένου να μην επιβαρύνεται το δίκτυο, αλλά ούτε και η ίδια η IoT συσκευή, είναι σημαντικό η μεταφόρτωση διεργασιών να γίνεται βέλτιστα και αποδοτικά. Με αυτόν τον τρόπο, θα μπορεί να αξιοποιηθεί και το edge computing πλήρως ως λύση του προβλήματος διαχείρισης των δεδομένων και των εργασιών στο Cloud. Όλα αυτά τα σύγχρονα τεχνολογικά συστήματα, όμως, είναι περίπλοκα και παράλληλα παρουσιάζουν δυναμική συμπεριφορά, πράγμα που καθιστά δύσκολη την πρόβλεψη και διαχείρισή τους.

Στα πλαίσια της διπλωματικής εργασίας χρησιμοποιήθηκε μια νέα μέθοδος μοντελοποίησης και πρόβλεψης συστημάτων, οι Χάρτες Ασαφούς Λογικής (Fuzzy Cognitive Maps - FCMs), με σκοπό να μοντελοποιηθούν τα σύγχρονα συστήματα ώστε να γίνεται αποδοτική η μεταφόρτωση διεργασιών. Υλοποιήθηκαν και δοκιμάστηκαν δύο αλγόριθμοι πρόβλεψης, με βάση τους οποίους προβλέπεται η συμπεριφορά του edge server, λαμβάνοντας ως είσοδο ορισμένες παραμέτρους που αφορούν τις γύρω IoT συσκευές. Ως IoT συσκευή στην συγκεκριμένη εργασία εξετάζεται το κινητό τηλέφωνο.

1.2.1 Συνεισφορά

Τα πειραματικά αποτελέσματα δείχνουν ότι η συγκεκριμένη μέθοδος μπορεί να μοντελοποιήσει σε ικανοποιητικό βαθμό την συμπεριφορά ενός εξυπηρετητή που βρίσκεται κοντά στα άκρα του νέφους σε συνδυασμό και με την συμπεριφορά των γύρω IoT συσκευών. Η χρήση FCMs καθιστά εύκολη την οπτικοποίηση του προβλήματος και προσιτή στον τρόπο σκέψης του ανθρώπου, ενώ παράλληλα παρουσιάζει πολλές δυνατότητες και ευελίξια ως μέθοδος μοντελοποίησης και πρόβλεψης.

1.3 Οργάνωση του τόμου

Η παρούσα διπλωματική είναι οργανωμένη σε πέντε κεφάλαια. Βασικές πληροφορίες σχετικά με την μεταφόρτωση διεργασιών και τους Χάρτες Ασαφούς Λογικής, αλλά και ενδεικτικά παραδείγματα χρήσης των FCMs για μοντελοποίηση και πρόβλεψη, παρουσιάζονται στο Κεφάλαιο 2. Στο Κεφάλαιο 3 περιγράφεται το θεωρητικό υπόβαθρο των FCMs καθώς και οι δύο αλγόριθμοι που χρησιμοποιήθηκαν ξεχωριστά για την υλοποίηση του συστήματος μεταφόρτωσης. Λεπτομέρειες υλοποίησης και τα αποτελέσματα των προσομοιώσεων παρουσιάζονται στο Κεφάλαιο 4. Στο Κεφάλαιο 5 συνοψίζονται τα συμπεράσματα και διατυπώνονται προτάσεις για περαιτέρω διερεύνηση και υλοποίηση του θέματος. Το Κεφάλαιο 5 ακολουθεί η βιβλιογραφία.

Κεφάλαιο 2

Σχετικές Εργασίες

2.1 Μεταφόρτωση διεργασιών (Computational Offloading)

Με το Internet of Things να αποτελεί πλέον κύριο στοιχείο της καθημερινότητας του ανθρώπου, η βελτίωση της ποιότητας των υπηρεσιών για εφαρμογές IoT μέσω του cloud computing καθίσταται ως σημαντικό πρόβλημα.

Η μεταφόρτωση διεργασιών από μικρές συσκευές σε απομακρυσμένους πόρους με στόχο την βελτίωση της απόδοσης και την μείωση της κατανάλωσης ενέργειας, υπάρχει ως έννοια περισσότερο από μια δεκαετία. Στις μέρες μας, αυτή η ιδέα έχει λάβει μεγαλύτερη προσοχή λόγω της σημαντικής αύξησης της πολυπλοκότητας των διεργασιών για κινητά, τη διαθεσιμότητα ισχυρών Cloud συστημάτων και τις βελτιωμένες επιλογές συνδεσιμότητας για κινητές συσκευές.

2.1.1 Σύγχρονα προβλήματα και η συνεισφορά του offloading και του edge computing στις κινητές συσκευές

Τα κινητά τηλέφωνα αντιμετωπίζουν ακόμα και σήμερα προκλήσεις λόγω των περιορισμένων πόρων τους, όπως επεξεργαστή (CPU), αποθηκευτικού χώρου και ισχύος μπαταρίας. Ωστόσο, αυτοί οι πόροι δεν θα μπορούν να ικανοποιήσουν τις περισσότερες από τις σύγχρονες εφαρμογές κινητών που απαιτούν χαμηλή καθυστέρηση (latency) στους χρήστες, δηλαδή μικρό χρόνο αποστολής δεδομένων μεταξύ συσκευής και δικτύου, ενώ παράγουν ή καταναλώνουν συνεχώς δεδομένα. Για τον λόγο αυτό, η χρησιμότητα του offloading εντοπίζεται στην ικανότητα επίτευξης υψηλών επιταχύνσεων υπολογισμού με μικρές καθυστερήσεις στην επικοινωνία.

Παρά τις μεγάλες δυνατότητες, μια βασική πρόκληση του offloading έγκειται στην αναντιστοιχία μεταξύ του τρόπου με τον οποίο οι μεμονωμένες κινητές συσκευές απαιτούν και έχουν πρόσβαση σε υπολογιστικούς πόρους και στον τρόπο με τον οποίο τους προσφέρουν οι πάροχοι Cloud. Τα αιτήματα μεταφόρτωσης από μια κινητή συσκευή απαιτούν γρήγορη απόκριση και μπορεί να μην είναι συχνά. Επομένως, οι ιδανικοί υπολογιστικοί πόροι κατάλληλοι για offloading θα πρέπει να είναι άμεσα διαθέσιμοι κατόπιν αιτήματος και να απελευθερώνονται

γρήγορα μετά την εκτέλεση. Αντίθετα, οι πόροι υπολογιστικού νέφους έχουν μεγάλο χρόνο εγκατάστασης και μισθώνονται για μεγάλα χρονικά διαστήματα.

Λύση στα παραπάνω αποτελεί η ενσωμάτωση πλατφορμών cloud computing και ειδικότερα του edge computing, δεδομένου ότι παρέχει ισχυρούς υπολογιστικούς και αποθηκευτικούς πόρους σε κοντινή απόσταση από την κινητή συσκευή. Με αυτόν τον τρόπο, μετριάζεται η επιβάρυνση του offloading και συνεπώς μειώνεται ο χρόνος επεξεργασίας και η κατανάλωση ενέργειας στην συσκευή.

Στα πλαίσια του edge computing έχουν γίνει πολλές εργασίες που διερευνούν και παρέχουν διάφορες τεχνικές offloading με σκοπό την βέλτιστη μεταφόρτωση εργασιών τόσο από την μεριά του κινητού, όσο και από την μεριά του ακραίου (edge) εξυπηρετητή [43]. Ενδεικτικά, κάποιες αξιοσημείωτες προσεγγίσεις αναγράφονται παρακάτω.

Στο [15] παρουσιάζεται σύστημα συνεργατικού offloading μεταξύ συσκευών με πρόσβαση στο Cloud που λαμβάνει υπόψη και την γνώση της τοποθεσίας, με κύριο στόχο την μείωση του latency. Κάθε κόμβος έχει επίγνωση των γειτονικών κόμβων και του φόρτου εργασίας τους και σε περιπτώσεις υπερφόρτωσης αξιοποιεί αυτές τις πληροφορίες ώστε να γίνει διαμοιρασμός του δικού του φόρτου. Ενδιαφέρον παρουσιάζει και μια εργασία [9] που επισημαίνει ότι η μεταφόρτωση εργασιών με απαιτητικούς υπολογισμούς, όπως είναι η αναγνώριση εικόνας, μπορεί να μην είναι πάντα συμφέρουσα. Το latency του δικτύου στο τέλος της διαδρομής λόγω της ασύρματης επικοινωνίας, μπορεί να μην είναι ανεκτό για ορισμένες εφαρμογές. Παράλληλα, οι ίδιοι οι κόμβοι του Cloud μπορεί να αποτελέσουν εμπόδιο της επεξεργασίας σε περίπτωση που πλήθος εργασιών μεταφορτιστεί σε αυτούς. Ως λύση παρουσιάζεται η συνεργασία των ακραίων υπολογιστικών εξυπηρετητών για κατανομή του φόρτου επεξεργασίας μεταξύ τους, όπως και στο πρώτο άρθρο.

Υπάρχουν περιπτώσεις που τα δίκτυα δεν έχουν καθορισμένη τοπολογία, αλλά μεταβάλλονται και είναι δυναμικά, όπως φαίνεται και στο άρθρο [18]. Δεδομένου ότι η τοπολογία των κόμβων του νέφους είναι δυναμική, γίνεται χρήση μιας προσέγγισης που να λαμβάνει γρήγορα την σχετική πληροφορία και να μειώνει το υπολογιστικό latency. Όμοια, το άρθρο [39] εξετάζει το offloading σε αβέβαια δίκτυα του Cloud, καθώς αφορούν την υποκειμενική συμπεριφορά των χρηστών των κινητών συσκευών. Αντίστοιχα, στο άρθρο [37] προτείνονται στρατηγικές μεταφόρτωσης διεργασιών για τις υπηρεσίες σχεδιασμού διαδρομής και εντοπισμού κινητών ρομπότ που βασίζονται στην αβεβαιότητα της θέσης του ρομπότ. Μια ακόμη περίπτωση χρήσης του offloading σε δυναμική τοπολογία, όπως παρουσιάζεται στο άρθρο [3], είναι στην έγκαιρη ανίχνευσης πυρκαγιάς. Προτείνεται αρχιτεκτονική τριών επιπέδων, με το κατώτερο να περιλαμβάνει συσκευές IoT που επιβλέπουν δασικές εκτάσεις και μεταφορτώνουν δεδομένα για επεξεργασία στους κοντινούς εξυπηρετητές.

Στο [12] εξετάζεται μια άλλη πρόκληση της μεταφόρτωσης διεργασιών, η προστασία δεδομένων και της ιδιωτικότητας του χρήστη. Οι συγγραφείς προτείνουν μια ευριστική μετρική ιδιωτικότητας που ποσοτικοποιεί από κοινού ευαίσθητες πληροφορίες και συγκεκριμένα την τοποθεσία και τις συνήθειες χρήσης του κινητού, για να επιλυθούν τα αντίστοιχα ζητήματα.

Τέλος, μια ιδιαίτερη προσέγγιση παρουσιάζεται στο άρθρο [20] και αφορά στην μείωση της ποιότητας των αποτελεσμάτων κατά το offloading σε εφαρμογές που το τέλειο αποτέλεσμα

δεν είναι απαραίτητο. Με αυτόν τον τρόπο, μειώνεται ο απαιτούμενος υπολογιστικός φόρτος εργασίας και επιτυγχάνεται σημαντική μείωση του χρόνου απόκρισης και της κατανάλωσης ενέργειας της συσκευής.

2.1.2 Σημαντικές παράμετροι προς μελέτη για το offloading

Στις περισσότερες εργασίες που αφορούν το offloading διεργασιών από μια κινητή συσκευή σε κάποιο κοντινό εξυπηρετητή, υπάρχουν κάποιες συγκεκριμένες παράμετροι τόσο από την μεριά της συσκευής και του δικτύου, όσο και από του εξυπηρετητή οι οποίες εξετάζονται είτε προς βελτίωση είτε προς αξιοποίηση ως δεδομένο.

Ειδικότερα, από την μεριά του κινητού και του δικτύου δίνεται βάση στα εξής:

- καθυστέρηση (latency) που αφορά τον χρόνο που μεσολαβεί μέχρι να ξεκινήσει η μεταφόρτωση μιας εφαρμογής. Έτσι, η συγκεκριμένη παράμετρος θα πρέπει να είναι σχετικά μικρή, ώστε να έχουμε γρήγορη μεταφόρτωση διεργασιών. Το latency εξαρτάται από την απόσταση μεταξύ της συσκευής και του εξυπηρετητή, τον χρόνο απόκρισης των δύο πλευρών και την σύνδεση στο διαδίκτυο.
- παρεμβολές (interference) που υπάρχει μεταξύ του κινητού και του εξυπηρετητή, όπως ο θόρυβος στο κανάλι ή η ύπαρξη περισσότερων συσκευών που αιτούνται επικοινωνία με τον εξυπηρετητή. Πρόκειται για παράμετρο που επηρεάζει την επικοινωνία των δύο συσκευών και γι'αυτό είναι σημαντικό να είναι σχετικά μικρή. Εξαρτάται από την ισχύ μετάδοσης και το interference από την μεριά του κινητού, την ισχύ του εξυπηρετητή και το κέρδος καναλιού (channel gain) [14].
- μέση κατανάλωση ενέργειας (average residual energy) από την μεριά του κινητού, δηλαδή πόση ενέργεια καταναλώνεται για την εκτέλεση της εφαρμογής στην συσκευή. Συγκεκριμένα, η κατανάλωση αυτή καθορίζεται από την χρήση του επεξεργαστή (CPU), την χρήση του ασύρματου δικτύου (WiFi) και την χρήση της οθόνης (LCD usage) του κινητού [42].

Οι πιο σημαντικές παράμετροι που αφορούν τον εξυπηρετητή είναι οι παρακάτω:

- μερίδιο υπολογιστικής ισχύος που παραχωρείται (assigned CPU share) για την διαδικασία επεξεργασίας. Κάθε εξυπηρετητής διαθέτει ορισμένο πλήθος επεξεργαστών και σε κάθε διαδικασία που τρέχει ή σε κάθε αίτημα που δέχεται από κοντινή συσκευή παραχωρεί συγκεκριμένους πόρους.
- πλήθος δεδομένων που αποστέλλονται και λαμβάνονται ανά μονάδα χρόνου (throughput). Ειδικότερα, αποτελεί δείκτη των ολοκληρωμένων αιτημάτων στον εξυπηρετητή σε συγκεκριμένο χρονικό διάστημα.
- μέσος χρόνος απόκρισης (average response time) του εξυπηρετητή όταν δέχεται κάποιο αίτημα από συσκευή για (offloading). Ο επιθυμητός μέσος χρόνος απόκρισης συνήθως είναι γύρω στα 4 milliseconds.

Για την υλοποίηση του αλγορίθμου μοντελοποίησης του συστήματος μεταφόρτωσης διεργασιών, χρησιμοποιήθηκαν οι τελευταίες από τις παραπάνω παραμέτρους, οι οποίες αφορούν τον εξυπηρετητή, δηλαδή το assigned CPU share, το throughput και το average response time. Αυτό οφείλεται στο γεγονός ότι στην υλοποίηση εξετάζεται η πλευρά του ακραίου (edge) εξυπηρετητή μέσα στο σύστημα, καθώς ως πρώτη προσέγγιση του θέματος, δημιουργήθηκε μια βασική και απλοποιημένη μορφή του συστήματος.

2.2 Χάρτης Ασαφούς Λογικής (Fuzzy Cognitive Maps)

Στην εποχή που το διαδίκτυο και τα δεδομένα κυριαρχούν, τα σύγχρονα τεχνολογικά συστήματα καθίστανται περίπλοκα και αποτελούνται συνήθως από πλήθος υποσυστημάτων ή στοιχείων που αλληλεπιδρούν μεταξύ τους. Αυτά τα συστήματα έχουν μη γραμμική και μη σταθερή συμπεριφορά και δεν μπορούν να προσομοιωθούν από το άθροισμα των μεμονωμένων αναλύσεων συμπεριφοράς του εκάστοτε στοιχείου τους. Στην περίπτωση των σύνθετων δυναμικών συστημάτων, οι συμβατικές μέθοδοι μοντελοποίησης, ελέγχου και πρόβλεψης εμφανίζουν περιορισμούς. Η μοντελοποίηση σύνθετων συστημάτων απαιτεί νέες μεθόδους που να μπορούν να αξιοποιήσουν την υπάρχουσα γνώση και την ανθρώπινη εμπειρία. Επιπλέον, αυτές οι μέθοδοι πρέπει να είναι εξοπλισμένες με εξελιγμένα χαρακτηριστικά, όπως ανίχνευση βλαβών, βελτιστοποίηση και ιδιότητες αναγνώρισης.

Η πιο διαδεδομένη μέθοδος στον τομέα των προβλέψεων είναι τα νευρωνικά δίκτυα. Τα τελευταία χρόνια, όμως, έχει αναδειχθεί ακόμα μια, όχι τόσο διαδεδομένη, τεχνική, ένας συνδυασμός ασαφούς λογικής και νευρωνικών δικτύων, οι Χάρτες Ασαφούς Λογικής, τα λεγόμενα Fuzzy Cognitive Maps (FCMs) [22]. Διακρίνονται κυρίως για την απλότητα, την ευελιξία στο σχεδιασμό του μοντέλου, την προσαρμοστικότητα σε διαφορετικές καταστάσεις και την ευκολία χρήσης τους. Πρόκειται ουσιαστικά για μία μέθοδο η οποία μοντελοποιεί τα σύνθετα συστήματα, χρησιμοποιώντας υπάρχουσα γνώση και την ανθρώπινη εμπειρία. Επίσης, ως τεχνική συλλογισμού και αναπαράσταση γνώσης, απεικονίζει ένα σύστημα με μια μορφή που αντιστοιχεί κατά πολύ στον τρόπο που το αντιλαμβάνονται οι άνθρωποι. Τα Fuzzy Cognitive Maps εισήχθησαν από τον Kosko (1986) [16], ως επέκταση των Cognitive Maps [4], παρέχοντας έναν ισχυρό μηχανισμό για την μοντελοποίηση και ποιοτική ανάλυση δυναμικών συστημάτων.

2.2.1 Ενδεικτικές εργασίες χρήσης των FCMs

Τα Fuzzy Cognitive Maps παρουσιάζουν μια ενδιαφέρουσα διάδοση στον κλάδο της μοντελοποίησης και πρόβλεψης συστημάτων σε πολλούς τομείς. Οι βασικές κατηγορίες προβλημάτων που βρίσκουν εφαρμογή τα FCMs είναι τα προβλήματα ελέγχου, πρόβλεψης χρονοσειρών και ταξινόμησης [31]:

- Προβλήματα ελέγχου: πρόκειται για προβλήματα που αφορούν έλεγχο συγκεκριμένων μεταβλητών ενός συστήματος ώστε είτε να παίρνουν τιμές εντός κάποιων προκαθορισμένων ορίων, είτε να μην ξεπερνούν μια οριακή τιμή. Παράδειγμα αποτελεί ο έλεγχος

της θερμοκρασίας εξόδου του νερού μέσω χειρισμού της ροής του αέρα σε έναν εναλλακτική θερμότητας, τυπικό μηχάνημα στην χημική βιομηχανία [38].

- **Πρόβλεψη χρονοσειρών:** Τα FCMs μπορούν να χρησιμοποιηθούν σε όλες τις κατηγορίες των χρονοσειρών. Ειδικότερα, μοντελοποιούν συστήματα που αφορούν χρονοσειρές με μία (univariate) ή και περισσότερες μεταβλητές (multivariate). Παράλληλα, χρησιμοποιούνται για πρόβλεψη των κατά προσέγγιση χρονοσειρών (approximated time-series), όπως χρονοσειρές με διαστήματα (interval-valued time-series) αλλά και κοκκώδεις χρονοσειρές (granular time-series), δηλαδή χρονοσειρές που βασίζονται σε τμήματα- 'κόκκους' πληροφορίας (information granules).
- **Ταξινόμηση:** Το πρόβλημα της ταξινόμησης προτύπων (pattern classification) αφορά την αντιστίχιση κάθε στοιχείου ενός συνόλου με βάση κάποια χαρακτηριστικά του (attributes) σε μία από τις διαθέσιμες τάξεις απόφασης (decision class). Η αντιστοίχιση γίνεται συνήθως με επιβλεπόμενο τρόπο (supervised), με άλλα λόγια βασίζεται σε κάποιο υπάρχον σύνολο δεδομένων που έχει ήδη ταξινομηθεί και χρησιμοποιείται για την εκπαίδευση του μοντέλου. Η διαδικασία εκμάθησης ελέγχεται από την ελαχιστοποίηση μιας συνάρτησης κόστους/σφάλματος (cost/error function). Υπάρχουν πολλές διαδεδομένοι μέθοδοι ταξινόμησης προτύπων, με πιο γνωστά τα νευρωνικά δίκτυα (neural networks), οι οποίες παρά την μεγάλη τους επιτυχία, παρουσιάζουν το μειονέκτημα ότι συχνά συμπεριφέρονται ως 'μαύρα κουτιά' χωρίς να παρέχουν κάποιο μηχανισμό ή κατανόηση για τον τρόπο εξαγωγής του συμπεράσματος. Τα Fuzzy Cognitive Maps αποτελούν την ιδανική λύση σε αυτά τα προβλήματα, καθώς όχι μόνο αποτελούν καλούς ταξινομητές, αλλά επίσης παρέχουν έναν εύκολο και κατανοητό τρόπο μοντελοποίησης του συστήματος.

Σε κάθε τομέα εμφανίζονται ένα ή παραπάνω από τα προαναφερόμενα είδη προβλημάτων που τα FCMs επιλύουν. Πιο συγκεκριμένα, κάποιες σημαντικές εργασίες σε ορισμένους τομείς αναφέρονται στη συνέχεια [26].

Τα Fuzzy Cognitive Maps έχουν χρησιμοποιηθεί με επιτυχία για την μοντελοποίηση κοινωνικών, πολιτικών και στρατηγικών καταστάσεων, όπως και για την υποστήριξη στη διαδικασία λήψης μιας απόφασης ενόψει επικείμενης κρίσης. Ειδικότερα, οι Andreou et al. πρότειναν τον συνδυασμό των FCMs με κάποιον γενετικό αλγόριθμο με σκοπό να ξεπεραστούν κάποιες αδυναμίες των Certainty Neuron Fuzzy Cognitive Maps (CNFCMs) [1]. Η τεχνική χρησιμοποιήθηκε επιτυχώς σε ένα μοντέλο που περιγράφει το Κυπριακό ζήτημα, λαμβάνοντας υπόψη την πολιτική και στρατηγική περιπλοκότητά του και ανέδειξαν την ικανότητα του υβριδικού FCM να προτείνει βέλτιστη λύση, εφόσον οι απαιτήσεις έχουν σαφώς οριστεί. Μια άλλη εργασία στον τομέα των επιστημών συμπεριφοράς είναι του Carvalho, στην οποία προτείνονται τα FCMs ως εργαλείο μοντελοποίησης και προσομοίωσης σύνθετων κοινωνικών, οικονομικών και πολιτικών συστημάτων [7].

Μεγάλη δυνατότητα εφαρμογής των FCMs εμφανίζεται στην ιατρική, σε διαγνώσεις και στην υποστήριξη λήψης αποφάσεων. Στο άρθρο [28] χρησιμοποιείται FCM στην λήψη απόφασης σχετικά με την προγραμματισμό διαχείρισης ακτινοθεραπείας. Οι Rodin et al. [34]

μοντελοποίησαν την κυτταρική συμπεριφορά στην βιολογία συστημάτων. Το προτεινόμενο μοντέλο εφαρμόστηκε στην σηματοδότηση κυττάρων πολλαπλού μυελώματος και απέδωσε αποτελέσματα κοντινά σε εκείνα που βγάζουν οι διαφορικές εξισώσεις.

Στην μηχανική, τα FCMs χρησιμοποιούνται κυρίως σε προβλήματα ελέγχου και πρόβλεψης. Οι Papageorgiou et al. [32] εφάρμοσαν τεχνικές εκμάθησης που βασίζονται σε Hebbian μη γραμμικό κανόνα για την μοντελοποίηση προβλημάτων ελέγχου στις διαδικασίες των βιομηχανιών. Σε μια άλλη εργασία [17], χρησιμοποιείται FCM για την κατασκευή ενός ανιχνευτή σημείου μέγιστης ισχύος, ο οποίος μπορεί να λειτουργήσει συνδυαστικά και με έναν αντίστοιχο ελεγκτή. Το προτεινόμενο σύστημα δίνει καλύτερα αποτελέσματα από αρκετούς αναφερόμενους αντίστοιχους ανιχνευτές, υπό διάφορες συνθήκες.

Στον τομέα των επιχειρήσεων και της διοίκησης τα FCMs έχουν μεγάλη εφαρμογή και συγκεκριμένα στον προγραμματισμό προϊόντων, στην ανάλυση και την υποστήριξη λήψης αποφάσεων. Όσον αφορά στην λήψη αποφάσεων βάσει αποτελεσμάτων, οι Yaman και Polat πρότειναν την κατασκευή FCM για την μοντελοποίηση συστήματος που εφαρμόστηκε σε ένα σενάριο στρατιωτικού προγραμματισμού [41]. Σε ένα άλλο άρθρο [40], αναφέρεται η χρήση FCM ως 'έξυπνο' εργαλείο μεθοδολογίας υποστήριξης αποφάσεων που λειτουργεί ως back end στον οικονομικό σχεδιασμό.

Τα FCMs εφαρμόζονται και στον τομέα της παραγωγής ως λύση αξιολόγησης των παραγόντων που επηρεάζουν την ανθρώπινη αξιοπιστία στα συστήματα παραγωγής. Συγκεκριμένα, στο άρθρο [21] τα FCMs χρησιμοποιούνται στην διερεύνηση των διαδικασιών που εφαρμόζονται από ομάδες ανάπτυξης λογισμικού, για την διαχείριση διφορούμενων καταστάσεων κατά το στάδιο καθορισμού των απαιτήσεων του προϊόντος. Σε ένα άλλο άρθρο [23], χρησιμοποιούνται για τον σχεδιασμό συστημάτων μάθησης που βασίζονται σε παιχνίδια, καθώς έχουν εξαιρετική ικανότητα αναπαράστασης εννοιών και λογικής.

Ένας ακόμη τομέας εφαρμογής των FCMs είναι το περιβάλλον και η γεωργία. Έχουν χρησιμοποιηθεί στην μοντελοποίηση ενός οικοσυστήματος ξηράς στη Νέα Ζηλανδία για την πρόβλεψη των αποτελεσμάτων στη διαχείριση παρασίτων [33]. Στη γεωργία, τα FCMs χρησιμοποιήθηκαν για να αναπαραστήσουν τη γνώση και να αξιολογήσουν την πρόβλεψη της απόδοσης βαμβακιού στη γεωργία ακριβείας. Συνέδεσαν παραμέτρους που καθορίζουν την απόδοση με την απόδοση στη Βαμβακοπαραγωγή στην Κεντρική Ελλάδα, πράγμα που αποτέλεσε βάση για την δημιουργία συστήματος υποστήριξης λήψης αποφάσεων [25].

Στα πληροφοριακά συστήματα (Information Systems (IS)) και την πληροφορική (Information Technology (IT)), τα FCMs συνεισφέρουν στην επιτυχή μοντελοποίηση. Οι τρέχουσες μεθοδολογίες και τα εργαλεία που χρησιμοποιούνται για τον εντοπισμό, την ταξινόμηση και την αξιολόγηση των δεικτών επιτυχίας σε έργα IS/IT έχουν αρκετούς περιορισμούς. Θα μπορούσαν, όμως, να αντιμετωπιστούν με τη χρήση των FCMs για τη χαρτογράφηση της επιτυχίας, τη μοντελοποίηση της αντίληψης των κρίσιμων παραγόντων επιτυχίας και των σχέσεων μεταξύ τους [35]. Οι Bueno και Salmeron [5] πρότειναν την αξιοποίηση FCMs στον τομέα του Enterprise Resource Planning (ERP) (εταιρικού προγραμματισμού πόρων).

Στις τηλεπικοινωνίες χρησιμοποιήθηκαν FCMs σε κατανεμημένα ασύρματα peer-to-peer (P2P) συστήματα.[19] Οι P2P τεχνολογίες εμφανίζουν μεγάλο ερευνητικό ενδιαφέρον χάρη

στην επιτυχή τους εφαρμογή στα ενσύρματα δίκτυα. Γνωστές εμπορικές εφαρμογές είναι το Skype και το Napster. Στο άρθρο προτείνεται ένα σύστημα επιλογής peer βασισμένο σε FCM που για την επιλογή λαμβάνει υπόψη πολλαπλά κριτήρια των ενσύρματων P2P δικτύων.

Τέλος και στον τομέα της εκπαίδευσης είναι αρκετά τα άρθρα που αναδεικνύουν την χρήση των FCMs. Ενδεικτικά, στο άρθρο [6] χρησιμοποιούνται σε ένα σοβαρό παιχνίδι, μέσω του οποίου τα παιδιά μαθαίνουν για διάφορες ασθένειες μέσω της εκερεύνησης σε έναν εικονικό κόσμο. Αξιοσημείωτο χαρακτηριστικό του προτεινόμενου FCM είναι ότι παρουσιάζει την εξέλιξη των καταστάσεων σε πραγματικό χρόνο. Ένα άλλο άρθρο [8], αναφέρει τους Πρόχειρους Χάρτες Ασαφούς Λογικής (Rough Cognitive Maps) ως επέκταση των FCMs που είναι ικανοί να μοντελοποιήσουν σύνολο σχέσεων μεταξύ δύο εννοιών του πραγματικού κόσμου, ακόμη και όταν υπάρχει ασαφής σχέση, βελτιώνοντας έτσι την απόδοση των προσομοιώσεων.

Κεφάλαιο 3

Θεωρητικό Υπόβαθρο

Τα Fuzzy Cognitive Maps έχουν αναδειχθεί χάρη στην επιτυχία τους στην μοντελοποίηση και πρόβλεψη σε διάφορους τομείς. Στο πλαίσιο της παρούσας εργασίας προτείνεται η αξιοποίηση τους στον τομέα του offloading. Στην ενότητα αυτή, αναλύονται τα FCMs και οι δύο αλγόριθμοι εκμάθησης που δοκιμάστηκαν για την παραγωγή του πίνακα βαρών του FCM, ο Active Hebbian Learning (AHL) και ο Nonlinear Hebbian Learning (NHL)

3.1 Αναλυτική περιγραφή FCM

Τα Fuzzy Cognitive Maps είναι τρόπος αναπαράστασης συστημάτων τα οποία χαρακτηρίζονται από αβεβαιότητα και πολύπλοκες διαδικασίες. Παρέχουν έναν πιο ευέλικτο και φυσικό μηχανισμό για την αναπαράσταση της γνώσης και συλλογισμού που είναι απαραίτητος για τα ευφυή συστήματα.

Ένα FCM μπορεί να εκφραστεί μέσω ενός πίνακα γειτνίασης για διευκόλυνση στους υπολογισμούς, αλλά συνήθως, για καλύτερη οπτικοποίηση του μοντέλου, εκφράζεται με ένα γράφο που αποτελείται από κόμβους και κατευθυνόμενες ακμές με βάρη. Οι κόμβοι αντιπροσωπεύουν τις βασικές έννοιες και χαρακτηριστικά του συστήματος που χρησιμοποιούν οι ειδικοί για να το περιγράψουν, όπως είναι είσοδοι, έξοδοι, μεταβλητές, καταστάσεις, γεγονότα, ενέργειες και στόχοι. Παράλληλα, οι ακμές του γράφου εκφράζουν τις αιτιατές σχέσεις μεταξύ των εννοιών.

Κάθε κόμβος παίρνει ασαφείς (fuzzy) τιμές που συμβολίζονται A_i , οι οποίες προκύπτουν από τον μετασχηματισμό της πραγματικής τιμής της έννοιας που αντιπροσωπεύει, στο διάστημα $[0,1]$ ή στο $[-1,1]$. Όσον αφορά στις κατευθυνόμενες ακμές, απεικονίζουν την επιρροή ενός κόμβου-έννοιας στους συνδεδεμένους με αυτόν κόμβους και τα βάρη W_{ij} των ακμών υποδηλώνουν την ένταση της επιρροής και παίρνουν τιμές στο διάστημα $[-1,1]$. Υπάρχουν τρεις πιθανοί τύποι αλληλεπίδρασης [10]:

- θετική αιτιότητα μεταξύ των κόμβων-εννοιών ($W_{ij} > 0$), όταν η αύξηση της τιμής της έννοιας i προκαλεί αύξηση της τιμής της έννοιας j ,
- αρνητική αιτιότητα ($W_{ij} < 0$), όταν η αύξηση της τιμής της έννοιας i , προκαλεί μείωση

της τιμής της έννοιας j και

- καμία σχέση ($W_{ij} = 0$) μεταξύ της έννοιας i και j

Η συνολική μαθηματική περιγραφή ενός FCM που αποτελείται από n έννοιες μπορεί να δωθεί με ένα $1 \times n$ διάνυσμα κατάστασης A , στο οποίο περιλαμβάνονται οι ενεργοποιημένες (Activated) τιμές των n εννοιών και ενός $n \times n$ πίνακα βαρών W_0 , ο οποίος περιλαμβάνει τις τιμές των βαρών W_{ij} μεταξύ των εννοιών C_i και C_j και έχει μηδενική διαγώνιο.

Ο κανόνας υπολογισμού, ή αλλιώς κανόνας ενεργοποίησης (activation rule), που εισήχθη αρχικά από τον Kosko για τον υπολογισμό της τιμής του κάθε κόμβου την στιγμή $t + 1$ βασίζεται μόνο στην επιρροή των αλληλένδετων κόμβων-εννοιών. Η εξίσωση ορίζεται ως εξής:

$$A_i^{(t+1)} = f\left(\sum_{\substack{j=1 \\ i \neq j}}^M w_{ij} A_j^{(t)}\right), \quad (3.1)$$

με το $A^{(0)}$ να είναι η αρχική διαμόρφωση (διάνυσμα ενεργοποίησης- activation vector), το w_{ij} η τιμή της αιτιώδους σχέσης που συνδέει την έννοια C_j με την έννοια C_i , ενώ το A_i^t δηλώνει την τιμή ενεργοποίησης (activation value) της έννοιας C_i στο βήμα της χρονικής στιγμής t . Αυτός ο κανόνας ενεργοποίησης επαναλαμβάνεται συνεχόμενα μέχρι να ικανοποιηθεί μια συνθήκη τερματισμού (stop condition) ή να φτάσει το σύστημα σε μια σταθερή κατάσταση. Αξιοσημείωτο είναι το γεγονός ότι το FCM θα παράγει ένα διάνυσμα ενεργοποίησης σε κάθε ξεχωριστό χρονικό βήμα, το οποίο περιλαμβάνει τον βαθμό ενεργοποίησης (activation degree) όλων των εννοιών.

Η παραπάνω εξίσωση περιγράφει έναν κανόνα ανανέωσης και χρησιμοποιείται σε πολλές εφαρμογές FCMs, αλλά δεν είναι μοναδικός. Υπάρχουν και άλλοι κανόνες ενεργοποίησης που έχουν προταθεί με βάση τον τρόπο που χρειάζεται να γίνεται η ενημέρωση των τιμών των εννοιών στην εκάστοτε περίπτωση. Οι Stylios και Groupos (2004) πρότειναν έναν αρκετά διαδεδομένο κανόνα ανανέωσης, στον οποίο οι έννοιες λαμβάνουν υπόψη και τις δικές τους προηγούμενες τιμές ενεργοποίησης, πέρα από τα αντίστοιχα βάρη και τιμές ενεργοποίησης που προέρχονται από άλλες έννοιες. Ειδικότερα, ο συγκεκριμένος κανόνας προτιμάται όταν γίνεται ανανέωση σε έννοιες που δεν επηρεάζονται από άλλες. Βασική διαφοροποίηση είναι η έμμεση αφαίρεση του περιορισμού $i \neq j$ από την εξίσωση του Kosko [16]:

$$A_i^{(t+1)} = f\left(\sum_{\substack{j=1 \\ i \neq j}}^M w_{ij} A_j^{(t)} + A_i^{(t)}\right). \quad (3.2)$$

Στους κανόνες ανανέωσης (3.1), (3.2), η $f(x)$ είναι μια συνάρτηση κατωφλίου (threshold function) (ενεργοποίησης), η οποία μπορεί να είναι συνεχής ή διακριτή. Στα πλαίσια των Fuzzy Cognitive Maps χρησιμοποιούνται κυρίως συνεχείς συναρτήσεις κατωφλίου, καθώς έχει αποδειχθεί ότι προσδίδουν στο FCM μεγαλύτερη συμπερασματική ικανότητα και επί το πλείστον δύο συγκεκριμένες συναρτήσεις. Η πρώτη είναι η σιγμοειδής συνάρτηση (sigmoid

function), όπου το $\lambda > 0$ καθορίζει πόσο απότομη θα είναι η κλίση της συνεχούς συνάρτησης $f(x)$ και συμπιέζει το εύρος τιμών της συνάρτησης στο διάστημα $[0,1]$:

$$f(x) = \frac{1}{1 + e^{-\lambda x}}. \quad (3.3)$$

Μια άλλη συνεχής συνάρτηση κατωφλίου που χρησιμοποιείται εξίσου και περιορίζει το περιεχόμενο της συνάρτησης στο διάστημα $[-1,1]$ είναι η υπερβολική συνάρτηση (hyperbolic function):

$$f(x) = \tanh = \frac{e^{2x} - 1}{e^{2x} + 1}. \quad (3.4)$$

Η επιλογή της συνάρτησης f εξαρτάται από την μέθοδο που χρησιμοποιείται για την περιγραφή των εννοιών. Συγκεκριμένα, υπάρχει μια μέθοδος που θεωρεί δύο αντίθετους κόμβους-έννοιες στο FCM οι οποίοι παίρνουν τιμές στο διάστημα $[0,1]$, όπως οι κόμβοι ‘λάθος απόφαση’, ‘σωστή απόφαση’. Από την άλλη, η δεύτερη μέθοδος επιτρέπει και αρνητικές τιμές σε έναν κόμβο-έννοια και στο προαναφερόμενο παράδειγμα μεταφράζεται ως έννοια ‘απόφαση’, στην οποία η αρνητική τιμή συμβολίζει την λάθος, ενώ η θετική την σωστή απόφαση.

Όπως αναφέρθηκε, το FCM παράγει ένα νέο διάνυσμα κατάστασης σε κάθε χρονική στιγμή μέχρι να σταθεροποιηθεί το σύστημα ή να πληρεί ένα κριτήριο τερματισμού, όπως για παράδειγμα ένα καθορισμένο πλήθος μέγιστων επαναλήψεων. Το πρώτο υπονοεί την ύπραξη ενός μοτίβου, ενώ το δεύτερο υποδηλώνει ότι τα αποτελέσματα του FCM είναι είτε κυκλικά είτε χαοτικά. Έτσι, χωρίζονται σε τρεις κατηγορίες ως προς το είδος τερματισμού [10]:

- Σταθερού σημείου (fixed-point): το οποίο μεταφράζεται στο ότι το FCM παράγει το ίδιο διάνυσμα κατάστασης A_i μετά από την χρονική στιγμή t_a .
- Κύκλος ορίου (limit-cycle): όταν το FCM παράγει περιοδικά το ίδιο διάνυσμα κατάστασης μετά από την χρονική στιγμή t_a .
- Χάος (chaos): όπου το FCM παράγει διαφορετικό διάνυσμα κατάστασης σε κάθε επανάληψη-χρονική στιγμή. Με άλλα λόγια, το σύστημα δεν συγκλίνει και επομένως δεν είναι ούτε σταθερό ούτε κυκλικό.

3.1.1 Κατασκευή FCM και κατηγορίες αλγορίθμων εκμάθησης

Η μέθοδος που ακολουθείται για την ανάπτυξη και την κατασκευή ενός Fuzzy Cognitive Map είναι μεγάλης σημασίας για τη δυνατότητά του να μοντελοποιήσει ικανοποιητικά ένα σύστημα.

Η διαδικασία ξεκινάει πάντα με μια ομάδα επιστημόνων που καθορίζουν τον αριθμό και το είδος των εννοιών που θα αποτελέσουν το FCM. Καθένας από τους ειδικούς γνωρίζει από εμπειρία τις βασικές παραμέτρους που περιγράφουν την συμπεριφορά ενός συστήματος. Αυτές είναι και οι παράμετροι που θα αναπαρασταθούν από τις έννοιες-κόμβους του FCM. Τα δεδομένα των εννοιών περνούν από ένα ή δύο στάδια επεξεργασίας για την καλύτερη αναπαράσταση και τα οποία είναι η κανονικοποίηση (normalisation) και το fuzzyfication, δηλαδή

η μετατροπή των αρχικών τιμών σε ασαφείς. Από την μία, η κανονικοποίηση, ένα προαιρετικό στάδιο, περιορίζει τα δεδομένα στο επιθυμητό διάστημα $[0,1]$. Έπειτα, το fuzzification γίνεται με την χρήση της προκαθορισμένης συνάρτησης κατωφλίου που χρησιμοποιείται στον αλγόριθμο εκμάθησης, με σκοπό τον -περαιτέρω- περιορισμό των δεδομένων και την μετατροπή τους στην απαραίτητη μορφή για την χρήση στους τύπους ενεργοποίησης (εξ. (3.1), κανόνες ενεργοποίησης των τιμών των κόμβων του Kosko και εξ. (3.2), κανόνες ενεργοποίησης των τιμών των κόμβων των Stylios και Groumpos).

Στη συνέχεια πρέπει να οριστεί η μέθοδος, με βάση την οποία το FCM θα εκτελέσει τον βασικό του στόχο, δηλαδή την παραγωγή πίνακα βαρών $W_{(n \times n)}$ και επομένως των αιτιωδών σχέσεων και των βαρών τους, ο οποίος να βασίζεται σε γνώσεις ειδικών, διαθέσιμα ιστορικά δεδομένα ή και στα δύο. Σύμφωνα με τον διαθέσιμο τύπο γνώσης, οι τεχνικές εκμάθησης μπορούν να χωριστούν σε τρεις κατηγορίες: τις Hebbian-based, τις population-based ή αλλιώς error driven και τέλος τις υβριδικές (hybrid) [31, 10]. Αναλυτικότερα:

- **Hebbian-based:** πρόκειται για μη επιβλεπόμενη τεχνική εκμάθησης, δηλαδή δεν απαιτεί συλλογή με κατηγοριοποιημένα δεδομένα. Αντίθετα, η αρχικοποίηση του πίνακα βαρών βασίζεται αποκλειστικά στην γνώση των ειδικών. Στη συγκεκριμένη τεχνική εκμάθησης η αιτιώτητα μεταξύ των εννοιών διατηρείται, καθώς παράγεται ένας ελαφρά διαφοροποιημένος πίνακας βαρών από τον αρχικά καθορισμένο από τους ειδικούς. Εντούτοις, κάτι τέτοιο καθίσταται εμπόδιο στην ικανότητα γενίκευσης του FCM, εφόσον υπόκειται και στην υποκειμενικότητα των επιστημόνων. Για αυτό το λόγο, προτιμώνται σε προβλήματα ελέγχου και προβλήματα πρόβλεψης χρονοσειρών στα οποία οι περιορισμοί είναι σαφώς γνωστοί και η γενίκευση δεν κρίνεται απαραίτητη.
- **Population-based:** σε αυτή την τεχνική οι επιστήμονες αντικαθίστανται από ιστορικά δεδομένα στα οποία βασίζεται η κατασκευή του αρχικού πίνακα βαρών. Ονομάζονται και τεχνικές που βασίζονται στα σφάλματα (error-driven) καθώς αρκετές φορές στόχος τους είναι η ελαχιστοποίηση μιας συνάρτησης σφάλματος μεταξύ των αναμενόμενων αποτελεσμάτων και των παραγόμενων από το FCM. Πρόκειται για τεχνική που αυξάνει την λειτουργικότητα και την ικανότητα γενίκευσης των FCM. Στα αρνητικά της συγκαταλέγεται το γεγονός ότι είναι χρονοβόρες και ότι απαιτούν πλήθος δεδομένων εισόδου-εξόδου κατά την εκπαίδευση για τον υπολογισμό του μοντέλου. Χρησιμοποιούνται κυρίως σε προβλήματα ταξινόμησης και πρόβλεψης που υπάρχει πλήθος δεδομένων για χρήση στην εκπαίδευση του FCM. Ωστόσο, με τις population-based τεχνικές διακυβεύεται η ικανότητα ερμηνείας του FCM καθώς δεν υπάρχει εγγύηση ότι ο παραγόμενος πίνακας βαρών περικλείει αυθεντικές αιτιώδεις σχέσεις.
- **Υβριδική (hybrid):** χαρακτηρίζεται η τεχνική που συνδυάζει τις δύο παραπάνω, δηλαδή την γνώση των επιστημών και τα ιστορικά δεδομένα, με επεξεργασία, ανανέωση του πίνακα βαρών σε δύο στάδια. Μια όχι και τόσο διαδεδομένη τεχνική για πραγματικά προβλήματα, για την οποία χρειάζεται περαιτέρω διερεύνηση.

Στο τελευταίο στάδιο, αφού έχει δημιουργηθεί και ο πίνακας βαρών μέσω της διαδικασίας

εκμάθησης η οποία βασίζεται σε έναν αρχικό, έχουμε την έξοδο του FCM. Με βάση τον παραγόμενο πίνακα, με άλλα λόγια των αιτιατών σχέσεων και των βαρών τους μεταξύ των εννοιών, γίνεται η πρόβλεψη της εξόδου. Προκειμένου να γίνει έλεγχος της επιτυχίας του FCM και επομένως της μοντελοποίησης, τα προβλεπόμενα αποτελέσματα πρέπει να περάσουν από το στάδιο του defuzzification, δηλαδή την μετατροπή των ασαφών σε πραγματικών τιμών και της αποκανονικοποίησης (denormalisation) σε περίπτωση που είχε προηγηθεί κανονικοποίηση κατά την είσοδο. Τέλος, κατά τον έλεγχο, στις Hebbian-based τεχνικές επιβεβαιώνονται οι αιτιώδεις σχέσεις μεταξύ των εννοιών σε σύγκριση και με την εμπειρία των ειδικών, ενώ στις population-based συγκρίνονται τα προβλεπόμενα αποτελέσματα με τα υπάρχοντα δεδομένα εξόδου.

3.2 Περιγραφή αλγορίθμου εκμάθησης *Active Hebbian Learning* (AHL)

Ο αλγόριθμος εκμάθησης *Active Hebbian Learning* (AHL) αποτελεί μια παραλλαγή του μη επιβλεπόμενου αλγορίθμου εκμάθησης *Hebbian Learning* (HL) [13] των νευρωνικών δικτύων και βελτιώνει την δομή του FCM, την ευελιξία και την δυναμική συμπεριφορά του. Προτάθηκε από τους Papageorgiou, Stylios και Groumpos (2004) [29] και δοκιμάστηκε με επιτυχία σε ένα πρόβλημα ελέγχου χημικής διαδικασίας, επιβεβαιώνοντας την αποτελεσματικότητά του. Ειδικότερα, επιλύει δύο από τις βασικές αδυναμίες των FCMs οι οποίες είναι η εξάρτησή τους από την γνώμη των ειδικών και η πιθανή σύγκλιση σε ανεπιθύμητες σταθερές καταστάσεις, χρησιμοποιώντας την λογική του *Hebbian* αλγορίθμου εκμάθησης.

Ο AHL αλγόριθμος εισάγει τον καθορισμό μιας συγκεκριμένης σειράς εννοιών-κόμβων ενεργοποίησης (sequence of activation concepts). Κάθε κύκλος επανάληψης απαρτίζεται από επιμέρους βήματα. Έτσι, σε κάθε βήμα της μπορεί να υπάρχουν ένας ή περισσότεροι κόμβοι ενεργοποίησης (activation concepts), οι οποίοι επηρεάζουν τους διασυνδεδεμένους κόμβους που στο επόμενο βήμα γίνονται ενεργοποιημένοι (Activated) κόμβοι. Η διαδικασία συνεχίζεται μέχρι να ενεργοποιηθούν όλοι οι κόμβοι της ακολουθίας ενεργοποίησης, πράγμα που σηματοδοτεί και το τέλος ενός κύκλου. Η ενεργοποίηση του κάθε Activated κόμβου έγκειται στην ανανέωση της τιμής του και των βαρών που ξεκινούν από τον Activation κόμβο και καταλήγουν στον Activated και εφαρμόζεται στο επόμενο βήμα. Επιπλέον της ακολουθίας ενεργοποίησης, στον AHL επιλέγεται και ένας περιορισμένος αριθμός κόμβων από τους επιστήμονες ως έξοδοι του συστήματος, οι λεγόμενες Έννοιες Απόφασης Ενεργοποίησης (Activation Decision Concepts (ADCs)). Τα ADCs είναι βασικοί παράγοντες του συστήματος, των οποίων τις τιμές θα υπολογίσει το FCM και αποτελούν την τελική κατάσταση του συστήματος.

Για την ενεργοποίηση των τιμών των κόμβων χρησιμοποιείται η εξίσωση (3.2) προσαρμοσμένη ώστε να περιλαμβάνει το είδος του κόμβου, είτε είναι Activation είτε δεν έχει κάποιο χαρακτηρισμό ακόμη. Έτσι, ο τύπος μετασχηματίζεται:

$$A_i^{(k+1)} = f(A_i^{(k)} + \sum_j A_j^{act}(k) \cdot w_{ji}), \quad (3.5)$$

όπου οι $A_j^{act}(k)$ είναι οι Activation κόμβοι που επηρεάζουν και ενεργοποιούν τον κόμβο C_i , το $A_i^{(k)}$ είναι η τιμή του Activated κόμβου C_i στο παρόν βήμα k και τα $w_{ji}(k)$ τα αντίστοιχα βάρη που περιγράφουν την επιρροή από κάποιον C_j στον C_i .

Στον AHL η εξίσωση ενεργοποίησης εφαρμόζεται στο επόμενο χρονικό βήμα, όπως και σε άλλους αλγορίθμους, με την διαφορά ότι στον συγκεκριμένο έχουμε δύο βασικές επαναλήψεις: τον γενικό κύκλο προσομοίωσης c (cycle) και τα επιμέρους βήματα k που ακολουθούνται σε κάθε κύκλο c . Έτσι, η εξ. (3.5) υπολογίζεται σε κάθε βήμα k και η ενεργοποιημένη τιμή εφαρμόζεται στο βήμα $k + 1$.

Στον Hebbian αλγόριθμο εκμάθησης που χρησιμοποιείται στα νευρωνικά δίκτυα [11], το πιο απλό δίκτυο αποτελείται από ένα σύνολο διανυσμάτων καταστάσεως x , εξόδους y και έναν πίνακα βαρών w στον οποίο κάθε w_{ij} συνδέει τον κόμβο x_i με τον y_j . Το πρόβλημα έγκειται στην εύρεση ενός πίνακα βαρών που θα ελαχιστοποιεί μια συνάρτηση λάθους (error function). Κατά την εκπαίδευση, το νευρωνικό δίκτυο δέχεται πολλές εισόδους ή μοτίβα τα οποία οργανώνει σε κατηγορίες. Ο κανόνας εκμάθησης του Hebb που εφαρμόζεται ορίζεται:

$$w_{ij}(k+1) = w_{ij}(k) + \rho \cdot y_j \cdot x_i, \quad (3.6)$$

όπου ρ μια παράμετρος μάθησης. Η εκμάθηση των βαρών απαιτεί τον ορισμό και την χρήση μιας συνάρτησης, που βασικός στόχος είναι να ελαχιστοποιηθεί. Όταν ικανοποιηθεί αυτό το κριτήριο, ο πίνακας βαρών έχει φτάσει σε μια σταθερή κατάσταση που καθορίζει την διαδικασία εκμάθησης και ορίζει το νευρωνικό μοντέλο.

Σε αντιστοιχία με τον κανόνα Hebb που χρησιμοποιείται στα νευρωνικά δίκτυα και με ορισμένες αλλαγές, η τιμή των $w_{ji}(k)$, δηλαδή η ενεργοποίηση των βαρών που συνδέουν τον activated κόμβο C_i με τους κόμβους-έννοιες από τους οποίους επηρεάζεται υπολογίζεται με την παρακάτω εξίσωση:

$$w_{ji}(k) = (1 - \gamma) \cdot w_{ji}(k-1) + \eta \cdot A_j^{act}(k-1) \cdot [A_i(k-1) - w_{ji}(k-1) \cdot (A_j^{act}(k-1))], \quad (3.7)$$

όπου $w_{ji}(k)$, $w_{ji}(k-1)$ το βάρος της ακμής που συνδέει τους κόμβους C_j και C_i στο παρόν k και στο προηγούμενο $k-1$ βήμα αντίστοιχα, $A_j^{act}(k-1)$, $A_i(k-1)$ η τιμή του Activation και του Activated κόμβου στο προηγούμενο βήμα και τα γ, η παράμετροι μάθησης. Οι δύο πρώτοι όροι $(1 - \gamma) \cdot w_{ji}(k-1) + \eta \cdot A_j^{act}(k-1) \cdot A_i(k-1)$ της εξίσωσης (3.7) αντιπροσωπεύουν την Hebbian μεταβολή των βαρών w_{ji} . Ο τελευταίος όρος $-w_{ji}(k-1) \cdot (A_j^{act}(k-1))^2$ αποτρέπει την απεριόριστη αύξηση της τιμής w_{ji} και είναι υπεύθυνος για την σταθεροποίηση. Η ενεργοποίηση των βαρών γίνεται μέχρις ότου τα τελικά υπολογισμένα βάρη να μην αλλάζουν πλέον ή να αλλάζουν σε αμελητέο βαθμό. Η ιδιαίτερη μορφή της εξίσωσης (3.7), σταματάει τα βάρη από το να μεγαλώσουν πολύ και βοηθάει στην σύγκλιση της διαδικασίας εκμάθησης.

3.2.1 Καθορισμός των παραμέτρων μάθησης

Στην εξίσωση ενεργοποίησης των βαρών χρησιμοποιούνται οι παράμετροι μάθησης η, γ . Ειδικότερα, η παράμετρος η είναι μια μικρή θετική κλιμακωτή παράμετρος που είναι ορισμένη να μειώνεται εκθετικά με κάθε κύκλο προσομοίωσης c :

$$\eta^{(c)} = b_1 \cdot \exp(-\lambda_1 \cdot c), \quad (3.8)$$

με τα b_1, λ_1 να είναι θετικές παράμετροι μάθησης που καθορίζονται με την δοκιμή (trial and error method). Ονομάζεται και παράμετρος ρυθμού μάθησης, καθώς καθορίζει το πόσο θα αυξηθεί η τιμή του ADC_i στον κάθε κύκλο c .

Από την άλλη, η παράμετρος ελάττωσης του βάρους, γ , καθορίζει το ποσοστό του προηγούμενου βάρους που θα 'μεταφερθεί' στον επόμενο κύκλο. Η γ μπορεί να είναι μηδέν, σταθερή ή να μειώνεται και αυτή εκθετικά με κάθε κύκλο c με τον τύπο:

$$\gamma^{(c)} = b_2 \cdot \exp(-\lambda_2 \cdot c), \quad (3.9)$$

όπου τα b_2, λ_2 είναι αντίστοιχα θετικές παράμετροι μάθησης που καθορίζονται με την δοκιμή (trial and error method).

Μεγάλες τιμές των δύο παραμέτρων μάθησης μπορεί να οδηγήσουν σε ταλάντωση αποτελεσμάτων αντί σε σύγκλιση. Η σύγκλιση των αποτελεσμάτων είναι αρκετά ευαίσθητη στις παραμέτρους η, γ και για αυτό τον λόγο τα προτεινόμενα όρια είναι μεταξύ $[0, 0.1]$.

3.2.2 Κριτήρια τερματισμού

Όπως περιγράφηκε, ο αλγόριθμος Active Hebbian Learning διαθέτει μια ασύγχρονη λειτουργία ενεργοποίησης. Έχει Activation κόμβους οι οποίοι ενεργοποιούν τους Activated σε κάθε κύκλο. Ακόμη, στον AHL ορίζονται και κόμβοι-έξοδοι, οι Activation Decision Concepts (ADCs) που αποτελούν την τελική κατάσταση των εννοιών μετά από τις προσομοιώσεις. Προκειμένου να γίνει ο έλεγχος τερματισμού, υπάρχουν δύο κριτήρια που υπολογίζονται στο τέλος κάθε κύκλου και καθορίζουν αν θα συνεχίσει ο αλγόριθμος στον επόμενο κύκλο. Το πρώτο κριτήριο, σε αντιστοιχία και με τον Hebbian learning αλγόριθμο, είναι μια συνάρτηση J (objective function) που στόχος είναι η ελαχιστοποίησή της. Αν θεωρήσουμε FCM με m Activation κόμβους, ο τύπος υπολογισμού της είναι:

$$J = \sqrt{\sum_{i=1}^m [(ADC_i - A_i^{min})^2 + (ADC_i - A_i^{max})^2]}. \quad (3.10)$$

Υπολογίζεται δηλαδή ως το άθροισμα της ευκλείδειας απόστασης των ADCs από την μέγιστη και ελάχιστη τιμή που έχει οριστεί στον εκάστοτε κόμβο εξόδου ADC_i . Η ελαχιστοποίηση της συνάρτησης (3.10) διασφαλίζει την σύγκλιση των τιμών των ADCs στις προκαθορισμένες τιμές.

Το δεύτερο κριτήριο τερματισμού καθορίζεται από τη μεταβολή δύο συνεχόμενων τιμών του ADC με βάση μια τιμή e και θα πρέπει να είναι ελάχιστη:

$$|ADC_i^{(c+1)} - ADC_i^{(c)}| < e, \quad (3.11)$$

όπου ADC_i είναι η τιμή της i -οστής έννοιας εξόδου. Ο όρος e είναι ένα όριο ανοχής που διατηρεί την διακύμανση των τιμών των ADCs όσο το δυνατόν χαμηλότερη και συνήθως προτείνεται ίσο με $e = 0.001$. Η εξίσωση (3.11) διασφαλίζει την ελαχιστοποίηση της διακύμανσης δύο συνεχόμενων τιμών ADCs.

Η ικανοποίηση και των δύο παραπάνω κριτηρίων ορίζει τον τερματισμό του αλγορίθμου εκμάθησης.

3.2.3 Υλοποίηση AHL σε FCM με n έννοιες-κόμβους

Ο αλγόριθμος αποτελείται από επτά βασικά βήματα. Το τρίτο βήμα αποτελείται από επιμέρους $n - p + 1$ υπο-βήματα, όπου $1 \leq p \leq n$, με n τον αριθμό των εννοιών και p το πλήθος των ταυτόχρονων activated εννοιών, δηλαδή που ενεργοποιούνται στο ίδιο βήμα. Επομένως, οι ειδικοί, πέρα από τον καθορισμό του activation sequence και των ADCs, πρέπει να καθορίσουν και ποιές από τις έννοιες θα ενεργοποιούνται ταυτόχρονα.

- Αν $p = n - 1$, τότε όλες οι n έννοιες ενεργοποιούνται ταυτόχρονα και από ασύγχρονος τρόπος εκμάθησης είναι σύγχρονος πλέον.
- Αν $p = 1$, τότε όλες οι έννοιες ενεργοποιούνται ασύγχρονα και το πλήθος των υπο-βημάτων είναι n , δηλαδή ίσο με το πλήθος των κόμβων του FCM.

Ο αριθμός των $n - p + 1$ υπο-βημάτων θεωρείται ως ένας κύκλος επανάληψης, που συμβολίζεται c .

Θεωρώντας ένα FCM με n κόμβους, η διαδικασία εκμάθησης του αλγορίθμου AHL αναλύεται παρακάτω και παρουσιάζεται συνοπτικά στον Αλγόριθμο 1 και στο διάγραμμα ροής (Σχήμα 3.1).

Βήμα 1: Ορισμός αρχικών τιμών στο διάνυσμα των εννοιών A^0 και στον πίνακα βαρών $w^{initial}$. Οι ειδικοί καθορίζουν την σειρά ενεργοποίησης των εννοιών-κόμβων καθώς και τους κόμβους εξόδου, ADCs.

Βήμα 2: Καθορίζονται οι παράμετροι $\eta^{(c)}, \gamma^{(c)}$ εντός των επιτρεπτών ορίων, ώστε να συγκλίνει το σύστημα και ξεκινάει ο πρώτος κύκλος επανάληψης ($c = 1$).

Βήμα 3: Εκτέλεση των $n - p + 1$ υπο-βημάτων με βάση το activation sequence.

Υπο-Βήμα 1: Η πρώτη έννοια του activation sequence C_j ενεργοποιεί την επόμενη έννοια C_i , η οποία είναι Activated σε αυτό το βήμα. Η τιμή ενεργοποίησης του Activated κόμβου για το βήμα k υπολογίζεται με την εξίσωση (3.5) χρησιμοποιώντας τις προηγούμενες προκαθορισμένες τιμές των Activation κόμβων και του ενημερωμένου πίνακα βαρών. Μόνο τα βάρη $w_{ji}(k)$ που ξεκινούν από τον Activation κόμβο C_j και επηρεάζουν τους Activated C_i κόμβους ενημερώνονται με χρήση της εξ. (3.7), ενώ τα υπόλοιπα μένουν ως έχουν.

Υπο-Βήμα 2: Ο Activation πλέον κόμβος C_i ενεργοποιεί τον επόμενο Activated κόμβο C_l , σύμφωνα με το activation sequence. Το υπο-βήμα k έχει αυξηθεί κατά 1 και με την

ίδια διαδικασία με το προηγούμενο βήμα ενημερώνεται η τιμή του C_l και τα βάρη μεταξύ του Activation και των Activated κόμβων C_l .

...

Υπο-Βήμα $n - p + 1$: Ο Activation κόμβος C_l ενεργοποιεί τον Activated κόμβο C_n στο βήμα $k = n - p + 1$. Η έννοια C_n έχει ορισθεί ως κόμβος εξόδου του FCM και αποτελεί Activation Decision Concept (ADC). Με το πέρας των $n - p + 1$ υπο-βημάτων υποδηλώνεται και το τέλος ενός κύκλου επανάληψης. Το διάνυσμα A_{final}^{act} που έχει διαμορφωθεί αποτελεί το νέο διάνυσμα κατάστασης και οι υπολογισμένες τιμές των ADC(s) χρησιμοποιούνται στα επόμενα βήματα.

Βήμα 4: Αν $c < M$, όπου $M = 100$ κύκλοι, υπολογίζεται η συνάρτηση (3.10) για τον κύκλο c . Αλλιώς επιστροφή στο Βήμα 2 και επαναπροσδιορισμός των παραμέτρων μάθησης $\eta^{(c)}, \gamma^{(c)}$ εντός των επιτρεπτών ορίων, ώστε να συγκλίνει το σύστημα.

Βήμα 5: Αν ισχύει ότι $J(c - 2) > J(c - 1) > J(c)$, τότε συνέχεια στο Βήμα 6, αλλιώς επιστροφή στο Βήμα 3 και συνέχεια στον επόμενο κύκλο επανάληψης $c = c + 1$ και τιμή υπο-βήματος $k = k + 1$.

Βήμα 6: Έλεγχος του δεύτερου κριτηρίου τερματισμού με χρήση της (3.11) για τον υπολογισμό της διακύμανσης δύο συνεχόμενων τιμών του ADC_n , ώστε να μην ξεπερνάει το όριο ανοχής ϵ . Αν η Εξ. (3.11) δεν αληθεύει τότε συνέχεια στο Βήμα 3.

Βήμα 7: Ικανοποιούνται ταυτόχρονα και οι δύο συνθήκες τερματισμού και το σύστημα συγκλίνει σε μια κατάσταση ισορροπίας μεταξύ των καθορισμένων ορίων, οπότε η διαδικασία σταματάει.

Βήμα 8: Αν οι παράμετροι μάθησης έχουν ενημερωθεί τουλάχιστον 10 φορές, ζητείται από τους ειδικούς η επανακατασκευή του FCM και η διαδικασία ξεκινάει από την αρχή.

Αλγορίθμη 1 Active Hebbian Learning in n -node FCM

1: Αρχικοποίηση FCM

2: Καθορισμός παραμέτρων $\eta^{(c)}, \gamma^{(c)}$ Έναρξη πρώτου κύκλου

3: Εκτέλεση των $n - p + 1$ υπο-βημάτων

1ο υπο-βήμα: Ο Activation κόμβος C_j ενεργοποιεί τον Activated κόμβο C_i

2ο υπο-βήμα: Ο Activation κόμβος C_i ενεργοποιεί τον Activated κόμβο C_l

...

$n - p + 1$ υπο-βήμα: Ο C_l Activation κόμβος ενεργοποιεί τον n Activated κόμβο, ο οποίος αποτελεί και ADC

Τέλος Ολοκλήρωση ενός κύκλου c προσομοίωσης

4: Αν $c < M$ ($M = 100$), έλεγχος πρώτης συνθήκης τερματισμού (Εξ. (3.10))

αλλιώς Βήμα 2

5: Αληθής η πρώτη συνθήκη

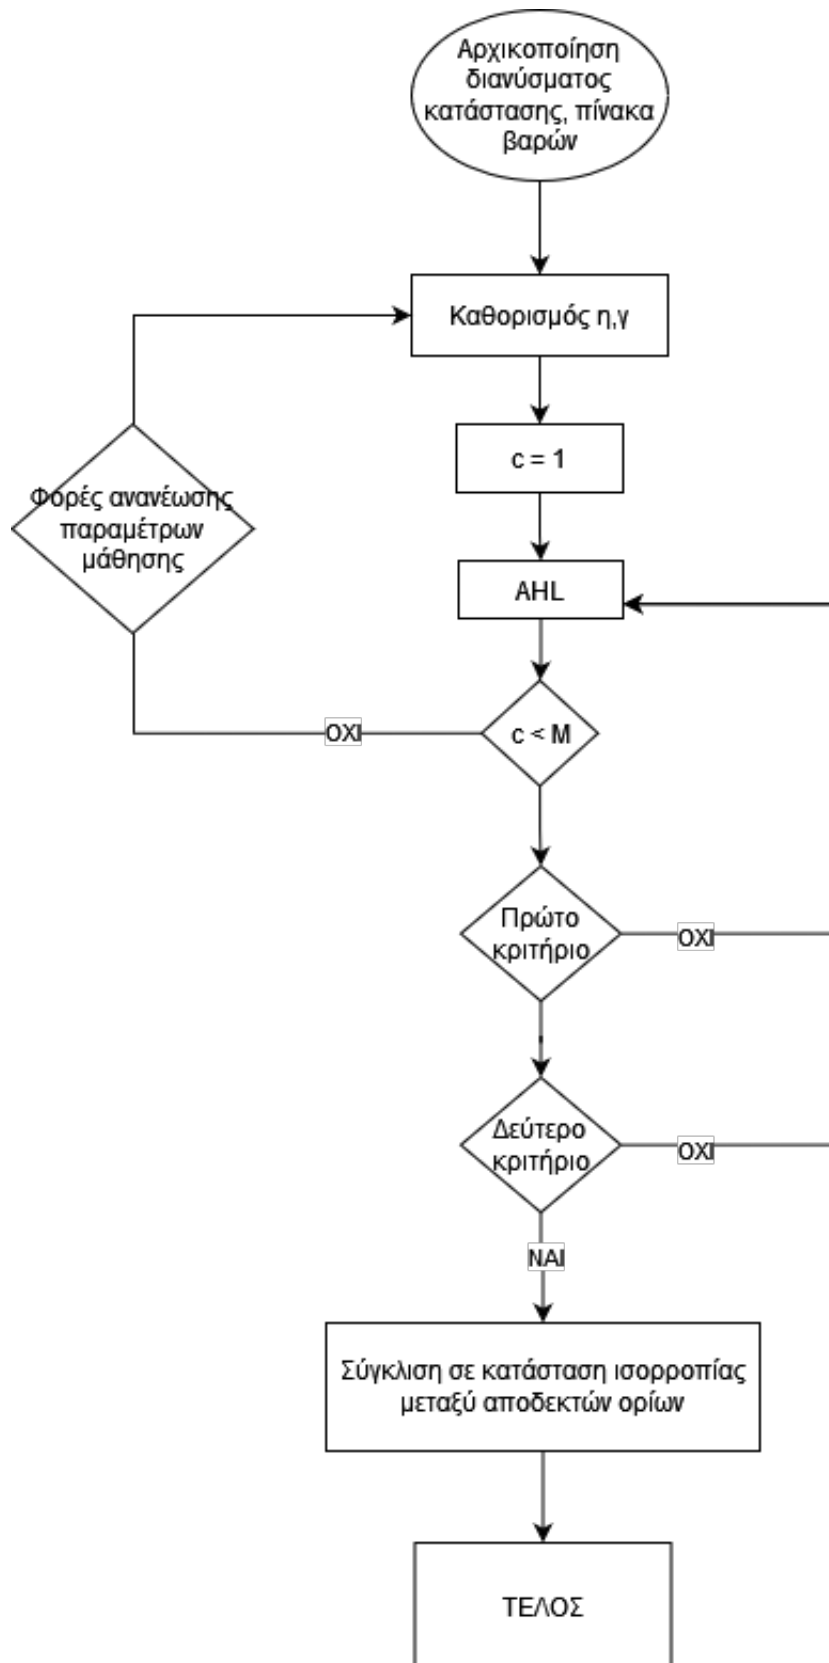
αλλιώς Βήμα 3

6: Έλεγχος δεύτερης συνθήκης τερματισμού (Εξ. (3.11))

7: Αν αληθής τότε ικανοποιούνται και οι δύο συνθήκες

αλλιώς Βήμα 3

8: Τέλος



Σχήμα 3.1: Διάγραμμα ροής αλγορίθμου εκμάθησης AHL

3.3 Περιγραφή αλγορίθμου εκμάθησης Nonlinear Hebbian Learning (NHL)

Ο αλγόριθμος εκμάθησης Nonlinear Hebbian Learning (NHL) βασίζει την ανανέωση των βαρών του στον μη γραμμικό (nonlinear) κανόνα Hebb που χρησιμοποιείται στην εκπαίδευση των τεχνητών νευρωνικών δικτύων (Artificial Neural Networks(ANNs)) [24]. Προτάθηκε από τους Parageorgiou και Groumpos (2005) [30] και χρησιμοποιήθηκε σε ένα πρόβλημα ελέγχου της χημικής βιομηχανίας. Ο NHL έχει ως βάση ότι όλες οι έννοιες-κόμβοι του FCM ενεργοποιούνται σε κάθε βήμα της επανάληψης και αλλάζουν την τιμή τους.

Σε σχέση με τον AHL, μοιάζει ως προς την ενεργοποίηση των τιμών και του πίνακα βαρών με βάση τον κανόνα Hebb και την ύπαρξη συναρτήσεων ως κριτήριο τερματισμού. Διαφέρει, όμως, στον τρόπο ενεργοποίησης των κόμβων, καθώς στον AHL υπήρχε καθορισμένη ακολουθία ενεργοποίησης, ενώ στον NHL οι κόμβοι ανανεώνονται ταυτόχρονα στο ίδιο βήμα. Ακόμη, όπως και στον AHL υπάρχουν τα ADCs, στον NHL οι ειδικοί καθορίζουν κάποιες έννοιες οι οποίες θα αποτελούν την έξοδο του συστήματος, δηλαδή τις Επιθυμητές Έννοιες Εξόδου (Desired Output Concepts (DOCs)).

Η ενεργοποίηση των τιμών των κόμβων του FCM υπλογίζεται στο βήμα $k + 1$ με την χρήση της εξίσωσης (3.2), χρησιμοποιώντας τιμές από το προηγούμενο βήμα k :

$$A_i^{(k+1)} = f(A_i^{(k)} + \sum_{\substack{j=1 \\ j \neq i}}^N A_j^{(k)} \cdot w_{ij}). \quad (3.12)$$

Η ενεργοποίηση των τιμών του πίνακα βαρών γίνεται με βάση τον κανόνα του Hebb, ο οποίος με ορισμένες μετατροπές δίνει τον μη γραμμικό κανόνα ανανέωσης:

$$w_{ji}^{(k)} = \gamma \cdot w_{ji}^{(k-1)} + \eta A_i^{(k-1)} (A_j^{(k-1)} - \text{sgn}(w_{ji}) w_{ji}^{(k-1)}) A_i^{(k-1)}, \quad (3.13)$$

όπου η είναι παράμετρος ρυθμού μάθησης και γ είναι η παράμετρος ελάττωσης του βάρους. Ο όρος $\text{sgn}(w_{ji})$ χρησιμοποιείται για την διατήρηση του προσήμου του αντίστοιχου βάρους, ώστε να μην χάνεται η φυσική σημασία των σχέσεων μεταξύ των κόμβων. Ακόμη, ο όρος $-\text{sgn}(w_{ji}) w_{ji}^{(k-1)} (A_i^{(k-1)})^2$ χρησιμοποιείται για την αποφυγή ανεπιθύμητης αύξησης της τιμής του βάρους σε σχέση με την αρχική τιμή που έχουν προτείνει και οι ειδικοί. Έτσι, όπως και στον AHL, μόνο οι μη μηδενικές τιμές του πίνακα βαρών ανανεώνονται σε κάθε βήμα.

3.3.1 Καθορισμός παραμέτρων μάθησης

Οι παράμετροι μάθησης η , γ παίρνουν μια σταθερή τιμή, η οποία καθορίζεται με την μέθοδο της δοκιμής και σφάλματος (trial and error). Έχει παρατηρηθεί πως για μεγάλες τιμές της παραμέτρου η , τα βάρη αλλάζουν σε τέτοιο βαθμό που αρκετές φορές αλλάζει το πρόσημό τους. Αντίστοιχα, για την παράμετρο γ έχει παρατηρηθεί πως για μικρές τιμές, ενώ αλλάζουν οι τιμές των βαρών, οι έννοιες του FCM δεν μπορούν να λάβουν τιμές σε προκαθορισμένα όρια.

Συνεπώς, τα όρια που έχουν καθοριστεί για την παράμετρο ρυθμού μάθησης η είναι $0 < \eta < 0.1$ και για την παράμετρο ελάττωσης των βαρών γ είναι $0.9 < \gamma < 1$ [27].

3.3.2 Κριτήρια τερματισμού

Στον NHL χρησιμοποιούνται δύο κριτήρια τερματισμού, που όταν ικανοποιούνται ορίζουν το τέλος του αλγορίθμου εκμάθησης.

Η πρώτη συνάρτηση τερματισμού εξετάζει τις αποδεκτές τιμές των κόμβων εξόδου, των DOCs και είναι αντίστοιχη της συνάρτησης J (εξ. (3.10)) του AHL. Ειδικότερα, ορίζεται ως εξής:

$$F1 = ||DOC_i - T_i||, \quad (3.14)$$

με το T_i να είναι η μέση επιθυμητή τιμή του ενδιαφερόμενου DOC_i . Η συνάρτηση $F1$ είναι ουσιαστικά η ευκλείδεια απόσταση της τιμής του DOC_i από την μέση επιθυμητή τιμή T_i . Δεδομένου ότι το DOC_i παίρνει τιμές εντός των ορίων $DOC_i = [T^{min}, T^{max}]$, η μέση επιθυμητή τιμή θα υπολογιστεί:

$$T_i = \frac{T^{min} + T^{max}}{2}. \quad (3.15)$$

Έτσι, σε ένα FCM με πλήθος DOCs ίσο με m , για τον υπολογισμό της συνάρτησης τερματισμού, γίνεται χρήση της εξίσωσης:

$$F1 = \sqrt{\sum_{j=1}^m (DOC_i - T_i)^2}. \quad (3.16)$$

Στόχος είναι η ελαχιστοποίηση της συνάρτησης $F1$ για το δεδομένο σύνολο βαρών. Όταν η $F1$ ελαχιστοποιηθεί το επιθυμητό σημείο ισορροπίας του FCM και των βαρών έχει επιτευχθεί.

Το δεύτερο κριτήριο τερματισμού στον NHL καθορίζεται από την ελαχιστοποίηση της διακύμανσης δύο συνεχόμενων τιμών των DOCs με βάση μια τιμή ορίου e . Αντίστοιχα και με τον AHL, το κριτήριο αυτό διασφαλίζει τον τερματισμό του αλγορίθμου μετά από καθορισμένο πλήθος επαναλήψεων που η επιθυμητή κατάσταση έχει επιτευχθεί. Ειδικότερα, η εξίσωση της συνθήκης ορίζεται:

$$F2 = |DOC_i^{(k+1)} - DOC_i^{(k)}| < e = 0.002. \quad (3.17)$$

Η τιμή της οριακής τιμής e πρέπει να είναι όσο μικρότερη γίνεται και στον NHL ορίζεται ως ίση με $e = 0.002$.

Η ελαχιστοποίηση της $F1$ και η ικανοποίηση της εξίσωσης $F2$ καθορίζουν το τέλος του αλγορίθμου εκμάθησης NHL.

3.3.3 Υλοποίηση NHL σε FCM

Ο αλγόριθμος εκμάθησης NHL αποτελείται από έξι βασικά βήματα. Η μέθοδος προσαρμογής βαρών που εντάσσει τον NHL για τον υπολογισμό του πίνακα βαρών, αποτελείται και

αυτή από έξι βήματα. Θεωρώντας πως η έννοια C_i έχει οριστεί ως κόμβος εξόδου, με τιμή DOC_i , η υλοποίηση του αλγορίθμου παρουσιάζεται στον Αλγόριθμο 2 και η υλοποίηση της διαδικασίας ανανέωσης των βαρών αναλύεται παρακάτω και στο διάγραμμα ροής (Σχήμα 3.2).

Βήμα 1: Αρχικοποίηση διανύσματος κατάστασης A και χρήση του αρχικού πίνακα βαρών.

Βήμα 2: Ορισμός των επιτρεπτών ορίων για την τιμή DOC_i του C_i .

Βήμα 3: Αν η αρχική τιμή A_i είναι εντός των ορίων, τότε τερματισμός και ο αρχικός πίνακας βαρών είναι ο κατάλληλος για το παρόν σενάριο. Αλλιώς, αν η τιμή A_i δεν είναι αποδεκτή, συνέχεια στον αλγόριθμο.

Βήμα 4: Αλγόριθμος NHL (Αλγόριθμος 2):

Βήμα I: Χρήση των αρχικών τιμών των εννοιών και των βαρών

Βήμα II: Καθορισμός των παραμέτρων η, γ

Βήμα III: Υπολογισμός των νέων τιμών των εννοιών με την εξ. (3.12) και

Βήμα IV: των βαρών w_{ij} με χρήση της εξ. (3.13) για ένα πλήθος επαναλήψεων.

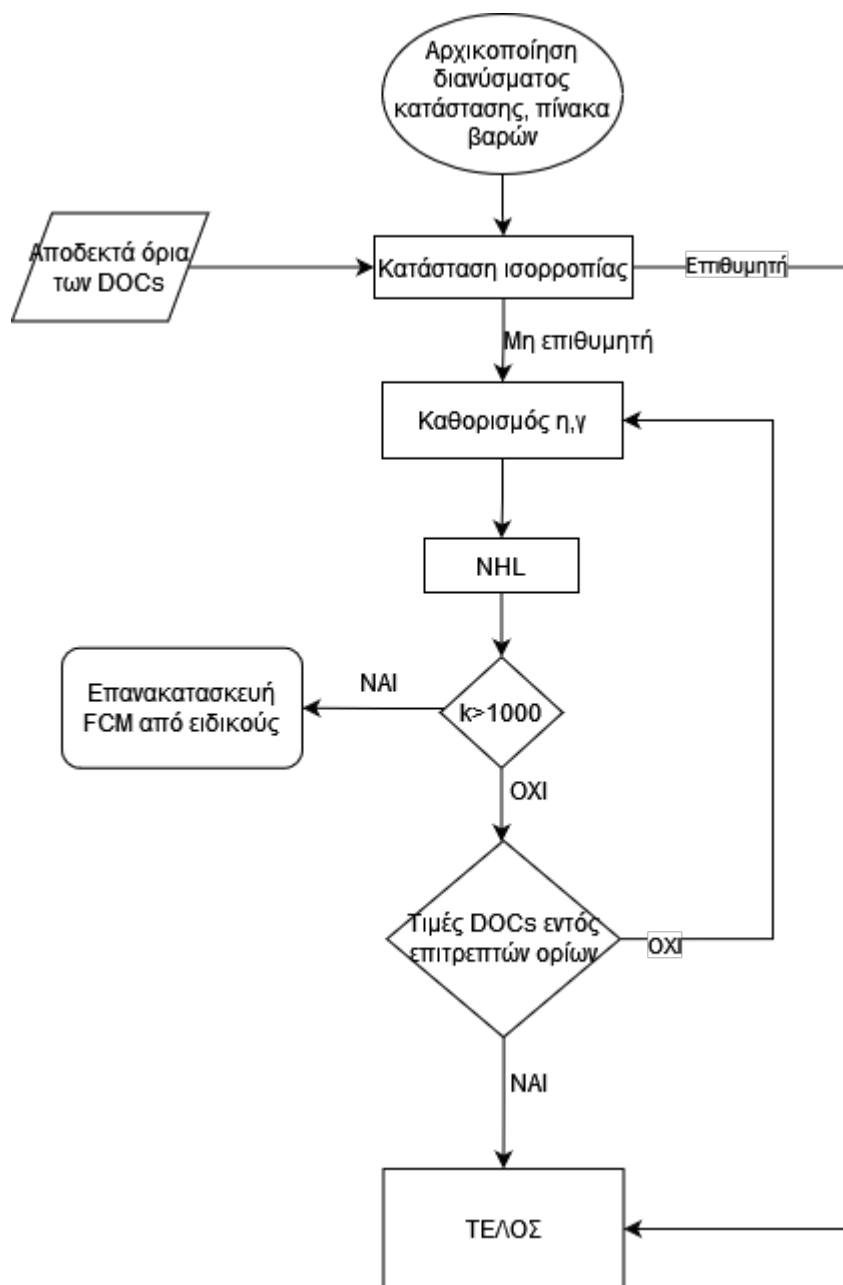
Βήμα V: Η διαδικασία επαναλαμβάνεται μέχρις ότου ικανοποιούνται και οι δύο συνθήκες τερματισμού. Έτσι, ένας ανανεωμένος πίνακας βαρών w_{NHL} παράγεται και οι κόμβοι εξόδου συγχλίνουν σε ένα σημείο ισορροπίας.

Βήμα 5: Αν δεν ικανοποιούνται τα δύο κριτήρια τερματισμού και έχει ξεπεραστεί το πλήθος των 1000 επαναλήψεων, τότε οι ειδικοί καλούνται να επανακατασκευάσουν το FCM. Ο νέος πίνακας βαρών χρησιμοποιείται για τον υπολογισμό των τιμών εξόδου.

Βήμα 6: Αν το DOC_i δεν φτάσει σε κάποια αποδεκτή τιμή μεταξύ των επιτρεπόμενων ορίων τότε συνέχεια στο *Βήμα 4*, επαναπροσδιορισμός των παραμέτρων μάθησης η, γ και εκ νέου υλοποίηση του NHL. Αλλιώς, ο αλγόριθμος τερματίζει και ο ανανεωμένος πίνακας βαρών είναι ο επιθυμητός για το παρόν σενάριο.

Αλγοριθμ 2 Nonlinear Hebbian Learning

- 1: Αρχικοποίηση FCM με διάνυσμα κατάστασης A_i , πίνακα βαρών w^0
 - 2: Επανάληψη για κάθε βήμα k
 - 3: Υπολογισμός του $A_i^{(k)}$ με βάση την Εξ.(3.12)
 - 4: Ανανέωση των βαρών με βάση την Εξ.(3.13)
 - 5: Υπολογισμός των δύο συνθηκών τερματισμού (Εξ. (3.16), Εξ. (3.17))
 - 6: Μέχρι την ικανοποίηση των συνθηκών τερματισμού
 - 7: Έξοδος τα τελικά βάρη w_{NHL}
-



Σχήμα 3.2: Διάγραμμα ροής προσαρμογής βαρών στον NHL

Κεφάλαιο 4

Πειραματική Υλοποίηση και Αποτελέσματα Προσομοίωσης

4.1 Πειραματική Υλοποίηση

Στην παρούσα εργασία γίνεται χρήση Fuzzy Cognitive Map για μια βασική μοντελοποίηση του συστήματος offloading μεταξύ κινητών συσκευών και του κοντινού (edge) εξυπηρετητή. Το θέμα προσεγγίζεται από την πλευρά του εξυπηρετητή και με δεδομένο ότι είναι ο μοναδικός σε αυτό το επίπεδο.

4.1.1 Παραγωγή Δεδομένων

Τα δεδομένα που χρησιμοποιήθηκαν στις προσομοιώσεις έχουν παραχθεί με αλγόριθμο με καθορισμένα κριτήρια. Ειδικότερα, στα δεδομένα των Requests χρησιμοποιείται κατανομή Poisson με exponential interarrival time δηλαδή με εκθετικό χρόνο άφιξης μεταξύ των αιτημάτων. Το dataset που παράχθηκε περιλαμβάνει τέσσερις στήλες δεδομένων, μία για κάθε κόμβο του FCM.

4.1.2 Περιγραφή γράφου Fuzzy Cognitive Map

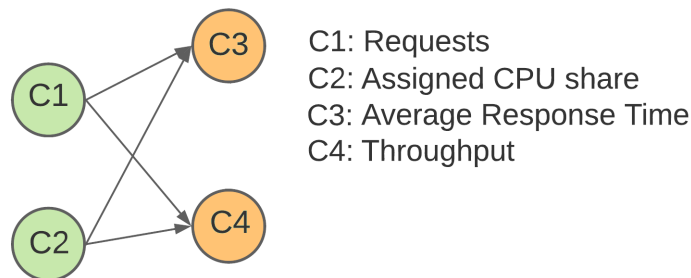
Προκειμένου να κατασκευαστεί ο γράφος που θα εκφράζει το FCM που θα αναπαριστά το σύστημα, πρέπει να οριστούν αρχικά οι έννοιες-κόμβοι που θα τον αποτελούν. Δεδομένου ότι γίνεται μια πρώτη δοκιμή και προσέγγιση του θέματος, οι έννοιες που συμπεριλαμβάνονται είναι οι βασικές και αντιστοιχούν στους κόμβους ως εξής:

- C_1 : Αιτήματα (Requests) των κινητών συσκευών για την μεταφόρτωση διεργασιών στον συγκεκριμένο εξυπηρετητή
- C_2 : Μερίδιο υπολογιστικής ισχύος που παραχωρείται (assigned CPU share), αφορά τους επεξεργαστές που μπορεί να παραχωρήσει ο edge εξυπηρετητής την εκάστοτε στιγμή για την εκτέλεση/επεξεργασία των μεταφορτομένων διεργασιών
- C_3 : Μέσος χρόνος απόκρισης (average response time) από την μεριά του εξυπηρετητή

- C_4 : Πλήθος δεδομένων που αποστέλλονται και λαμβάνονται ανά μονάδα χρόνου (throughput)

Η σύνδεση των εννοιών έχει γίνει με βάση την επιρροή μεταξύ τους. Συγκεκριμένα, τόσο τα αιτήματα, όσο και το πόσους επεξεργαστές θα παραχωρήσει ο εξυπηρετητής επηρεάζουν τον μέσο χρόνο απόκρισης και το throughput του εξυπηρετητή. Ως κόμβοι εισόδου έχουν οριστεί οι κόμβοι C_1, C_2 , ενώ ως κόμβοι εξόδου οι C_3, C_4 , δεδομένου ότι αυτοί είναι που αποτελούν χαρακτηριστικά της συμπεριφοράς του συστήματος που μοντελοποιείται. Οι τιμές των κόμβων του FCM ανήκουν στο διάστημα $[0,1]$ και οι τιμές των βαρών στο $[-1,1]$ αντίστοιχα. Στο Σχήμα 4.1 αναπαρίσταται ο γράφος με τους κόμβους και τις αντίστοιχες συνδέσεις τους.

Οι σχέσεις μεταξύ των εννοιών θα πρέπει να έχουν αρνητική αιτιότητα στην ακμή $C_1 - C_4$, καθώς όσο περισσότερα αιτήματα δέχεται ο εξυπηρετητής (C_1), τόσο λιγότερα θα επεξεργάζεται συγκριτικά στην μονάδα χρόνου (C_4) και στην $C_2 - C_3$, δεδομένου ότι όσο περισσότεροι επεξεργαστές παραχωρούνται για τις διεργασίες (C_2) τόσο πιο μικρός χρόνος απόκρισης θα υπάρχει (C_3). Από την άλλη, οι σχέσεις $C_1 - C_3$ και $C_2 - C_4$ θα πρέπει να έχουν θετική αιτιότητα εφόσον η αύξηση των αιτημάτων προκαλεί και αύξηση του χρόνου απόκρισης και η αύξηση του assigned CPU share αυξάνει το throughput.




Σχήμα 4.1: Διάταξη γράφου FCM υλοποίησης

Στις προσομοιώσεις που παρουσιάζονται χρησιμοποιήθηκε αρχικός γράφος με τυχαία αρχικοποίηση του πίνακα βαρών που εμφανίζεται στο σχήμα 4.2.

Παρατηρείται πως εν μέρει οι αρχικές σχέσεις είναι αντίστοιχες με τις αναμενόμενες, εκτός από την σχέση $C_2 - C_4$ η οποία θα πρέπει να παρουσιάζει θετική αιτιότητα. Κατά την εκπαίδευση του FCM με τους δύο αλγορίθμους AHL, NHL, εξετάζεται και η ικανότητά τους να βελτιώσουν αυτή την αναντιστοιχία.

4.1.3 Επεξεργασία δεδομένων του FCM

Τα παραγόμενα δεδομένα χρησιμοποιήθηκαν ως βάση για την κατασκευή και εκπαίδευση του FCM και χωρίστηκαν σε δύο ξεχωριστά dataset: train, test, για την εκπαίδευση του FCM και για τον έλεγχο των αποτελεσμάτων των αλγορίθμων αντίστοιχα. Το ποσοστό που διαχωρίζεται το dataset είναι 80% σε train δεδομένα και 20% σε test.



Σχήμα 4.2: Αρχικός τυχαίος γράφος

Όσον αφορά στην προεπεξεργασία των δεδομένων, αρχικά έγινε χρήση του κινούμενου μέσου όρου (sliding window), δεδομένου ότι υπήρχαν κάποιες ακραίες τιμές στο dataset που επηρέαζαν αρνητικά τα αποτελέσματα. Έτσι, με την χρήση του sliding window εξομαλύνθηκαν αυτές οι αποκλίσεις, καθώς ως τιμή αποθηκεύεται ο μέσος όρος των n προηγούμενων τιμών, όπου n το μέγεθος του window. Συγκεκριμένα, ύστερα από δοκιμές συμπεράστηκε πως το βέλτιστο μέγεθος παραθύρου για την προκειμένη εργασία είναι sliding window = 4 και στους δύο αλγορίθμους εκμάθησης.

Κατά την επεξεργασία των τιμών για την χρήση τους στους αλγορίθμους, τα δεδομένα υπέστησαν κανονικοποίηση και fuzzyfication. Η κανονικοποίηση περιορίζει τα δεδομένα στο διάστημα $[0,1]$ και πραγματοποιήθηκε με τον γενικό τύπο:

$$C_i = \frac{c_i - c_i^{\min}}{c_i^{\max} - c_i^{\min}}, \quad (4.1)$$

όπου το c_i είναι η αρχική τιμή του κόμβου i υπολογισμένη με sliding window, τα c_i^{\max} , c_i^{\min} είναι η μέγιστη και ελάχιστη τιμή από τις αρχικές του κόμβου αντίστοιχα και C_i η κανονικοποιημένη τιμή.

Ύστερα από την κανονικοποίηση, είναι απαραίτητο και το fuzzyfication, καθώς τα δεδομένα του FCM για να μπορούν να χρησιμοποιηθούν στους αλγορίθμους θα πρέπει να έχουν fuzzy μορφή. Για το fuzzyfication χρησιμοποιείται η σιγμοειδής συνάρτηση, όπως ορίζεται στην Εξ. (3.3) με $\lambda = 1$, η οποία εξ ορισμού και αυτλη περιορίζει τα δεδομένα στο διάστημα $[0,1]$.

Στο τέλος κάθε αλγορίθμου, προκειμένου οι τιμές να επανέλθουν στην πραγματική τους τιμή, υφίστανται αποκανονικοποίηση και defuzzyfication με τις αντίστροφες συναρτήσεις των εξ. (4.1), εξ. (3.3).

4.1.4 Κατηγορίες γραφημάτων

Κατά την εκτέλεση του αλγορίθμου και προκειμένου να συγκριθούν τα παραγόμενα αποτελέσματα, παράγονται πέντε κατηγορίες γραφημάτων.

- *Διακύμανση τιμής κόμβων στον AHL* : παρουσιάζει την μεταβολή της τιμής των κόμβων εξόδου κατά την διάρκεια της εκπαίδευσης. Οι τιμές κυμαίνονται στο διάστημα $[0,1]$ καθώς έχουν περάσει από στάδια κανονικοποίησης και fuzzyfication.
- *Διακύμανση τιμής βαρών κόμβου εξόδου στον AHL* : παρουσιάζει την μεταβολή των βαρών που επηρεάζουν τον κόμβο εξόδου κατά την διάρκεια εκτέλεσης του αλγορίθμου. Παράγεται ένα διάγραμμα για κάθε κόμβο εξόδου.
- *Γράφος FCM* : Οπτικοποίηση του γράφου, στην οποία είναι ορατές και οι τιμές των βαρών με ακρίβεια τεσσάρων δεκαδικών ψηφίων.
- *Σύγκριση προβλεπόμενης-πραγματικής τιμής κόμβου* : συγκρίνονται οι τιμές ενός κόμβου εξόδου που παράγονται κατά τον έλεγχο αποτελεσμάτων με τις αντίστοιχες από το dataset. Παράγεται ένα διάγραμμα για κάθε κόμβο εξόδου.

4.1.5 Εργαλεία που χρησιμοποιήθηκαν

Για την υλοποίηση του γράφου FCM και των δύο αλγορίθμων εκμάθησης (AHL, NHL) χρησιμοποιήθηκε η Python σε έκδοση 3.7.0, καθώς οι βιβλιοθήκες που διαθέτει είναι αρκετά χρήσιμες στην παρούσα εργασία. Συγκεκριμένα, χρησιμοποιήθηκαν οι βιβλιοθήκες: networkx¹ για την κατασκευή, διαχείριση και οπτικοποίηση του γράφου FCM, matplotlib² για την παραγωγή και αποθήκευση των γραφημάτων στα οποία παρουσιάζονται τα αποτελέσματα, καθώς και οι numpy³, scipy⁴ για τους διάφορους μαθηματικούς υπολογισμούς.

Οι προσομοιώσεις της υλοποίησης διεξήχθησαν σε προσωπικό υπολογιστή με επεξεργαστή Intel(R) Core(TM) i5-2540M CPU @ 2.60GHZ 2.60 GHZ με μνήμη 8.00 GB και x64-based processor.

4.2 Αλγόριθμος AHL

4.2.1 Περιγραφή Υλοποίησης

Ο πρώτος αλγόριθμος που δοκιμάστηκε στα δεδομένα ήταν ο Active Hebbian Learning (AHL). Για την εκπαίδευση του FCM ορίστηκαν οι παρακάτω παράμετροι που απαιτεί ο αλγόριθμος στην χρήση του.

- Έννοιες Απόφασης Ενεργοποίησης (ADCs): με άλλα λόγια οι κόμβοι εξόδου του AHL, οι οποίοι όπως έχουν οριστεί και στον FCM είναι οι κόμβοι C_3, C_4 .

¹<https://networkx.org/>

²<https://matplotlib.org/>

³<https://numpy.org/>

⁴<https://www.scipy.org/>

- Ακολουθία εννοιών ενεργοποίησης (Activation concepts sequence): $\{[C_1, C_2], [C_3], [C_4]\}$. Επομένως, οι κόμβοι εισόδου είναι ταυτόχρονα κόμβοι ενεργοποίησης, δηλαδή στο ίδιο βήμα k και ενεργοποιούν ξεχωριστά τους κόμβους εξόδου, με πρώτο τον C_3 (average response time) και στη συνέχεια τον δεύτερο ADC, τον C_4 (throughput).
- Κριτήρια Τερματισμού (εξ. (3.10), εξ. (3.11)): Στην παρούσα υλοποίηση, η εκπαίδευση του FCM γίνεται με βάση κάποια δεδομένα για όλους τους κόμβους και ο έλεγχος των αποτελεσμάτων στους κόμβους εξόδου γίνεται πάλι σύμφωνα με κάποια δεδομένα. Συνεπώς, η ύπαρξη των συνθηκών, που έχουν στόχο να συγκλίνει το σύστημα σε μία κατάσταση ισορροπίας και να διατηρεί τις τιμές των κόμβων εξόδου εντός συγκεκριμένων ορίων, δεν είναι απαραίτητη. Η διατήρηση των τιμών των ADCs εντός κάποιων ορίων επιτυγχάνεται κατά την εκπαίδευση με τις τιμές που έχουν ανατεθεί στους κόμβους εξόδου από το dataset που έχει παραχθεί.
- Μέγιστο πλήθος επαναληπτικών κύκλων, M : πρόκειται για τον μέγιστο αριθμό των κύκλων c που θα εκτελεστούν και θα γίνεται έλεγχος της πρώτης συνθήκης τερματισμού (εξ. (3.10)). Δεδομένου ότι οι συνθήκες τερματισμού δεν είναι απαραίτητες, μέγιστο πλήθος κύκλων αποτελεί το μέγεθος του dataset που χρησιμοποιείται για training. Έτσι, θεωρώντας αρχικό dataset μεγέθους $n = 1500$, το μέγεθος του training set θα είναι: $n_{train} = 80\% \cdot 1500$, οπότε και $M = n_{train} = 1200$. Επομένως, ως μοναδική συνθήκη τερματισμού ορίζεται η : $c < M$

Για την υλοποίηση της διαδικασίας της εκπαίδευσης χρησιμοποιήθηκε το 80% των τιμών του dataset, στο οποίο περιλαμβάνονται τιμές για όλους τους κόμβους. Όπως περιγράφηκε, ο αλγόριθμος AHL αρχικοποιεί μία φορά το διάνυσμα κατάστασης και τον πίνακα βαρών στην αρχή και κατά την εκπαίδευση ενημερώνει τις τιμές τους με βάση τις εξισώσεις ενεργοποίησης (εξ. (3.5), εξ. (3.7)) μέχρι την ικανοποίηση των συνθηκών τερματισμού. Στην παρούσα υλοποίηση, δεδομένου ότι γίνεται χρήση dataset για την εκπαίδευση, είναι απαραίτητη μια τροποποίηση. Έτσι, οι τιμές του dataset αρχικοποιούνται σε κάθε κύκλο c του αλγορίθμου στους αντίστοιχους κόμβους, ενώ στα επιμέρους βήματα k γίνεται κανονικά η χρήση των εξισώσεων ενεργοποίησης τιμών για τον Activated κόμβο και τα αντίστοιχα βάρη. Η αρχικοποίηση του πίνακα βαρών έγινε με τυχαίο τρόπο με χρήση κανονικής κατανομής.

Για την υλοποίηση της διαδικασίας ελέγχου των αποτελεσμάτων, χρησιμοποιήθηκε το 20% των τιμών του dataset. Έγινε αρχικοποίηση του διανύσματος κατάστασης με δεδομένα και του πίνακα βαρών με τις τιμές που προέκυψαν από τον αλγόριθμο AHL. Στη συνέχεια, χρησιμοποιήθηκε η εξίσωση ενεργοποίησης (εξ. (3.2)) για την πρόβλεψη τιμών των ADCs, C_3, C_4 . Τέλος, για τον έλεγχο των αποτελεσμάτων έγινε χρήση της συνάρτησης ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Square Error (RMSE)) για την εκτίμηση του σφάλματος μεταξύ της πραγματικής τιμής, δηλαδή της τιμής του dataset και της προβλεπόμενης τιμής, δηλαδή της παραγόμενης από τον αλγόριθμο. Το RMSE ορίζεται ως εξής [10]:

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{t=1}^N \left[\frac{E^{(t)}}{y^{(t)}} \right]^2}, \quad (4.2)$$

όπου N το πλήθος των δεδομένων, $y^{(t)}$ η πραγματική τιμή του εξεταζόμενου κόμβου την χρονική στιγμή t και $E^{(t)}$ η διαφορά μεταξύ προβλεπόμενης ($\hat{y}^{(t)}$) και πραγματικής τιμής ($y^{(t)}$), δηλαδή $E^{(t)} = \hat{y}^{(t)} - y^{(t)}$.

4.2.2 Αποτελέσματα AHL και Αξιολόγηση

Στον AHL υπάρχουν δύο βασικές παράμετροι που επηρεάζουν τα αποτελέσματα και αυτές είναι οι παράμετροι μάθησης η, γ , καθώς χρησιμοποιούνται στην εξίσωση ενεργοποίησης των τιμών των βαρών (εξ. (3.13)). Οι τιμές των παραμέτρων που χρησιμοποιήθηκαν στη βιβλιογραφία [29] εμφανίζονται στον πίνακα 4.1:

η	γ
$0.02 \cdot \exp(-0.2 \cdot c)$	0
	0.02
	$0.08 \cdot \exp(-c)$

Πίνακας 4.1: Παράμετροι μάθησης AHL η, γ βιβλιογραφίας

Στην υλοποίηση του αλγορίθμου έγινε διερεύνηση των παραμέτρων εκμάθησης και ειδικότερα ως προς τις παραμέτρους $b_1, \lambda_1, b_2, \lambda_2$. Τα σενάρια συνδυασμών που υλοποιήθηκαν παρουσιάζονται στους παρακάτω πίνακες με χρήση του αρχικού πίνακα βαρών και γράφου, όπως φαίνεται στο Σχήμα 4.2.

Αξιολόγηση παραμέτρου η

Αρχικά, έγινε διερεύνηση της η για τα τρία είδη της: την σταθερή μορφή όταν $\lambda_1 = 0$ (Πίνακας 4.2) και τις δύο εκθετικές, στις οποίες εξετάστηκαν ξεχωριστά οι παράμετροι b_1 (Πίνακας 4.3) και λ_1 (Πίνακας 4.4). Όλες οι περιπτώσεις δοκιμάστηκαν για κάποια ενδεικτικά γ που παρουσιάζονται στους πίνακες και συγκεκριμένα, χρησιμοποιήθηκε μια μηδενική, μια σταθερή και μια εκθετική τιμή. Η επιλογή των αποτελεσμάτων που παρουσιάζονται έγινε με κριτήριο την βέλτιστη αναπαράσταση της σύγκρισης.

Στην πρώτη περίπτωση, στην οποία $\lambda_1 = 0$ και εξετάζεται η τιμή του b_1 για κάποιες ενδεικτικές τιμές γ , προκύπτει πως όσο μικρότερη είναι η τιμή του, τόσο καλύτερα αποτελέσματα δίνει ο αλγόριθμος. Ενδεικτικά, παρουσιάζονται τα γραφήματα για τις περιπτώσεις που $b_1 = 0.02$ και $b_1 = 0.2$ για $\gamma = 0.05$.

Όσον αφορά στα βάρη, παρατηρείται αύξηση σχεδόν όλων των βαρών και στις δύο περιπτώσεις (Σχήματα 4.3, 4.4). Εξαίρεση αποτελεί η περίπτωση που $\eta = 0.02$, στην οποία το βάρος μεταξύ των $C_1 - C_4$ μειώνεται, κατί επιθυμητό δεδομένου ότι είχε αρχικοποιηθεί θετικό, ενώ στην πραγματικότητα πρέπει να είναι αρνητικό (Σχήμα 4.4α'). Ως προς την διακύμανση των προβλεπόμενων τιμών των κόμβων εξόδου, οι δύο τιμές η μοιάζουν σε συμπεριφορά.

b_1	γ
0.02	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.05	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.1	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.15	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.2	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.5	0
	$0.05 \cdot \exp(-0.05 \cdot c)$

Πίνακας 4.2: Τιμές b_1 όταν
 $\eta = b_1, (\lambda_1 = 0)$

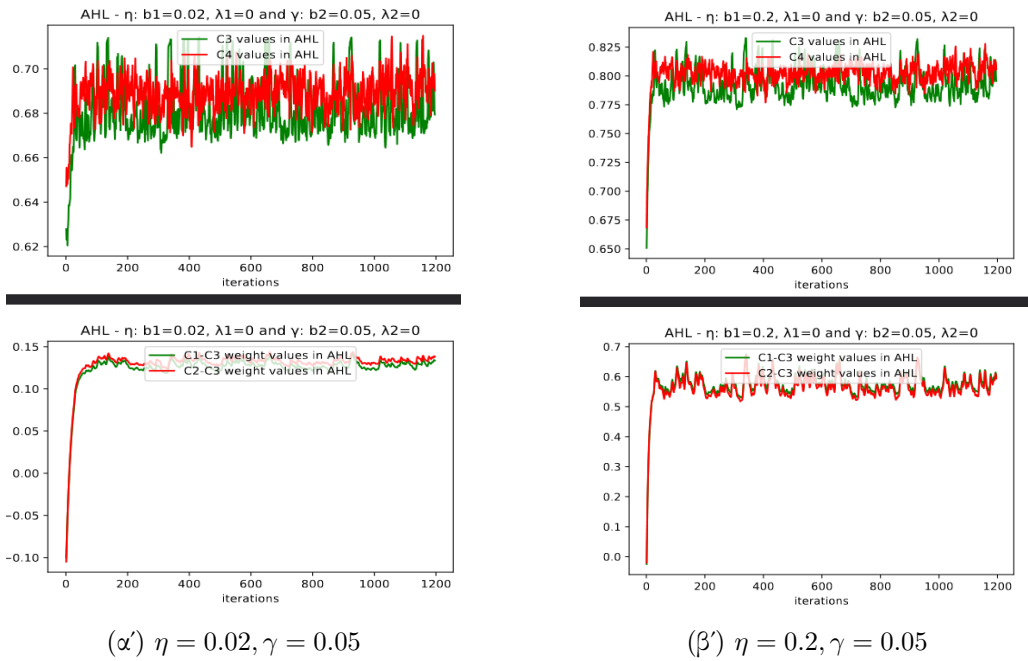
b_1	γ
0.02	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.05	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.2	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.5	0
	$0.05 \cdot \exp(-0.05 \cdot c)$

Πίνακας 4.3: Τιμές b_1 όταν
 $\eta = b_1 \cdot \exp(-0.2 \cdot c), (\lambda_1 = 0.2)$

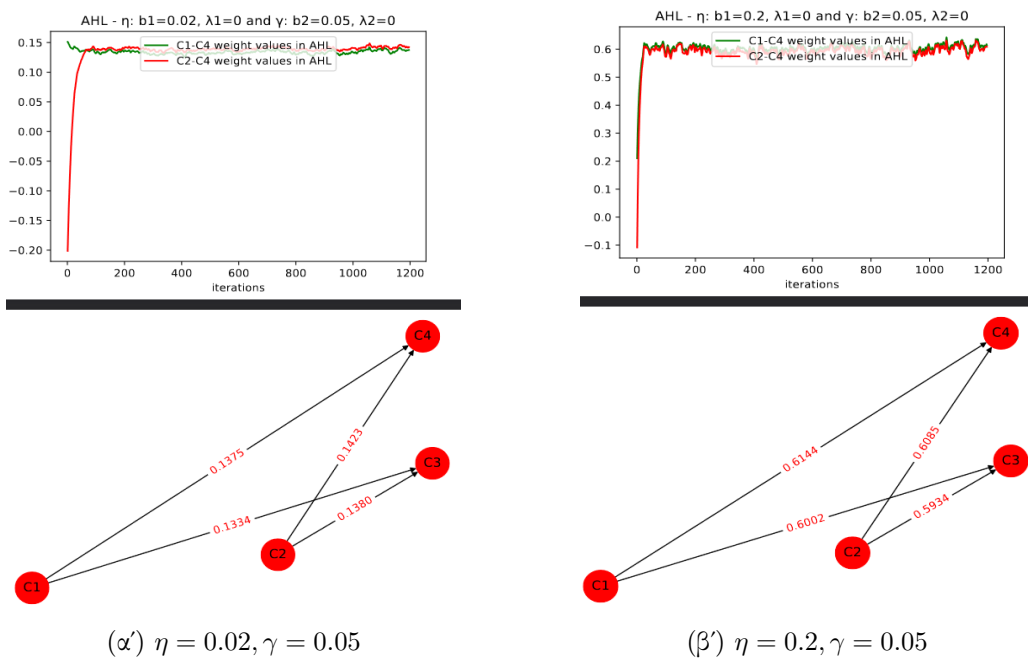
λ_1	γ
0.02	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.05	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.2	0
	$0.05 \cdot \exp(-0.05 \cdot c)$
0.5	0
	$0.05 \cdot \exp(-0.05 \cdot c)$

Πίνακας 4.4: Τιμές λ_1 όταν
 $\eta = 0.02 \cdot \exp(-\lambda_1 \cdot c), (b_1 = 0.02)$

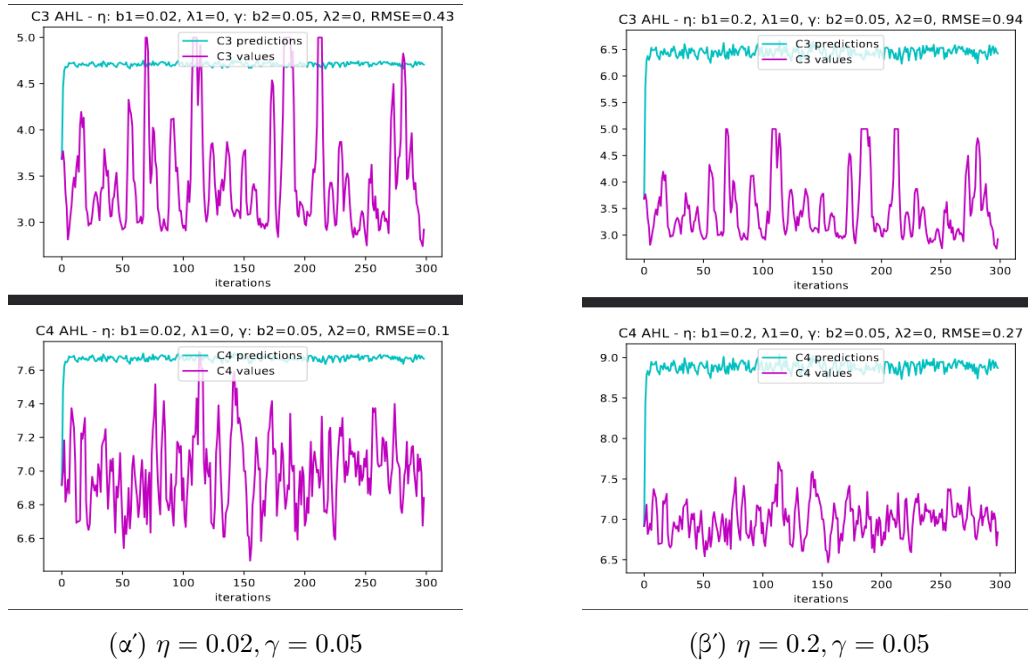
Όμως, η μικρότερη τιμή (Σχήμα 4.5α'), βελτιώνει κατά πολύ την απόδοση του αλγορίθμου συγκριτικά με την $\eta = 0.2$ (Σχήμα 4.5β').



Σχήμα 4.3: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση $\eta, \lambda_1 = 0$)




Σχήμα 4.4: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση $\eta, \lambda_1 = 0$)



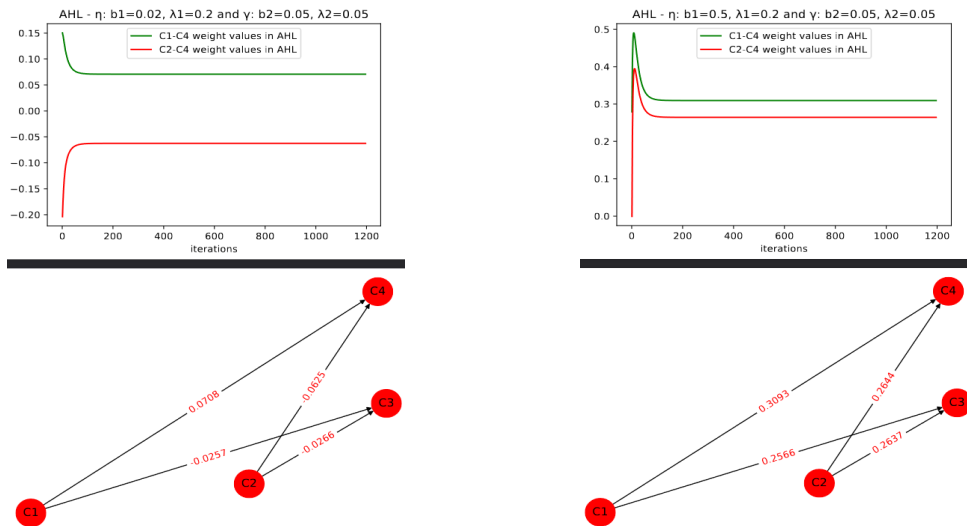
Σχήμα 4.5: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $\lambda_1 = 0$)

Στη συνέχεια, διερευνήθηκε η επιρροή της παραμέτρου b_1 για κάποιες ενδεικτικές τιμές γ , με την διαφορά ότι πλέον η η είχε εκθετική μορφή ($\lambda_1 = 0.2$), δηλαδή $\eta = b_1 \cdot \exp(-0.2 \cdot c)$. Όπως και στις προηγούμενες προσομοιώσεις και σε αυτήν την περίπτωση προκύπτουν καλύτερα αποτελέσματα όταν b_1 παίρνει μικρότερες τιμές. Παρακάτω παρατίθεται ενδεικτική σύγκριση για τιμές $b_1 = 0.02$ και $b_1 = 0.5$, με $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$.



(α') $\eta = 0.02 \cdot \exp(-0.2 \cdot c), \gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.5 \cdot \exp(-0.2 \cdot c), \gamma = 0.05 \cdot \exp(-0.05 \cdot c)$


Σχήμα 4.6: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση η , $\lambda_1 = 0.2$)



(α') $\eta = 0.02 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.5 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$

Σχήμα 4.7: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση η , $\lambda_1 = 0.2$)

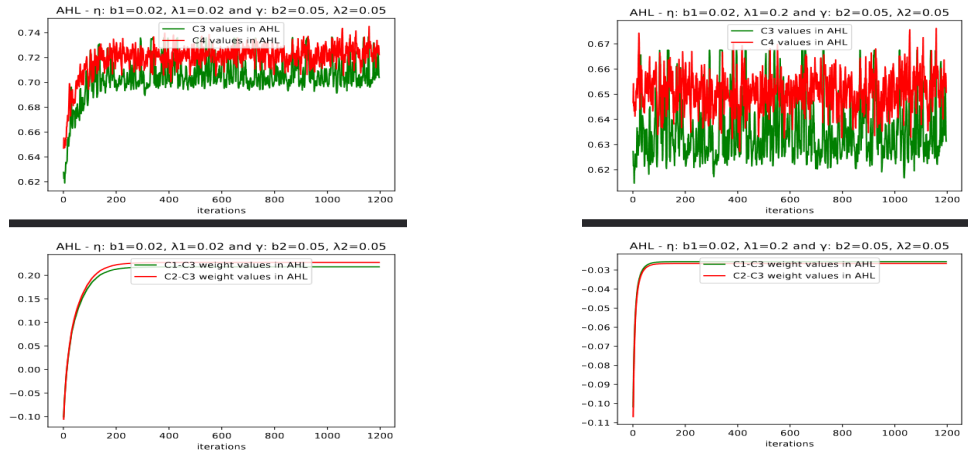
Από την πλευρά σύγκρισης της εκπαίδευσης των βαρών (Σχήματα 4.6, 4.7), φαίνεται πως στην μικρότερη τιμή b_1 (Σχήμα 4.7α') προκύπτουν πιο σωστά αποτελέσματα ως προς τα βάρη του κόμβου C_4 . Συγκεκριμένα, το βάρος $C_2 - C_4$ αυξάνεται, με τάση να φτάσει στα θετικά, ενώ το βάρος $C_1 - C_4$ μειώνεται με τάση να γίνει αρνητικό, όπως θα έπρεπε. Παράλληλα, παρόλο που για μεγαλύτερη τιμή b_1 υπάρχει καλύτερη διακύμανση στις τιμές των προβλέψεων (Σχήμα 4.8β'), απέχουν περισσότερο από τις πραγματικές τιμές σε σύγκριση και με την μικρότερη τιμή (Σχήμα 4.8α'), η οποία εν τέλει είναι η επιθυμητή.



(α') $\eta = 0.02 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.5 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$

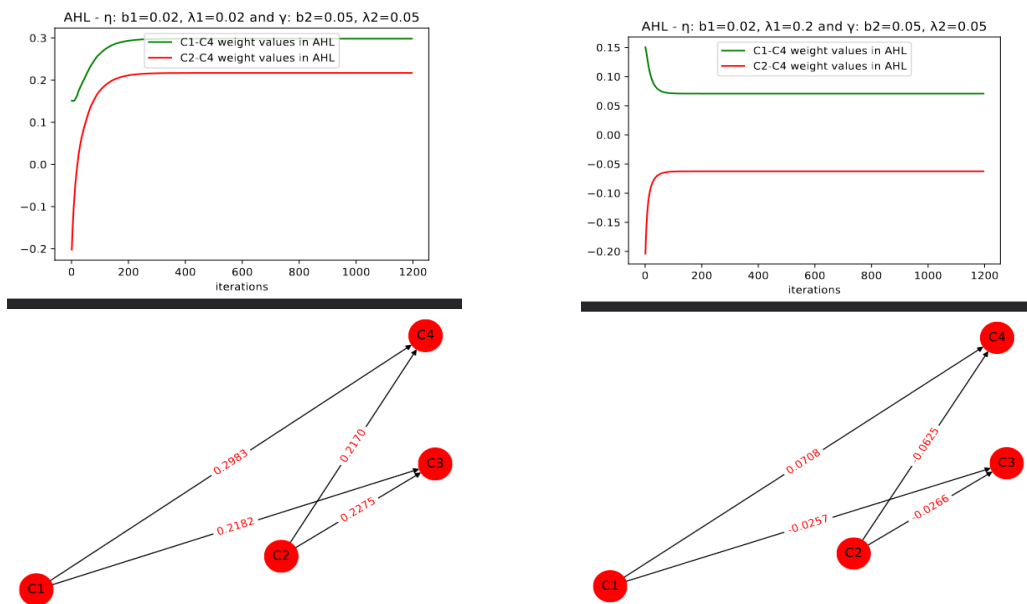
Σχήμα 4.8: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $\lambda_1 = 0.2$)

Τέλος, διερευνήθηκε με ποιον τρόπο οι παράμετροι λ_1 επηρεάζουν τα αποτελέσματα, με χρήση $b_1 = 0.02$. Παρατηρήθηκε πως μεγάλες τιμές του λ_1 βελτιώνουν την απόδοση του αλγορίθμου. Παρακάτω παρουσιάζονται τα γραφήματα σύγκρισης για $\lambda_1 = 0.02$ και $\lambda_1 = 0.2$, με $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$.



(α') $\eta = 0.02 \cdot \exp(-0.02 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.02 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$

Σχήμα 4.9: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση η , $b_1 = 0.02$)




(α') $\eta = 0.02 \cdot \exp(-0.02 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.02 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$

Σχήμα 4.10: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση η , $b_1 = 0.02$)

Η πορεία των βαρών του κόμβου C_4 σε αυτήν την περίπτωση (Σχήμα 4.10 β') είναι καλύτερη από όταν $\lambda_1 = 0.02$ (Σχήμα 4.10 α'), όπως αναλύθηκε και στην διερεύνηση του b_1 . Ταυτόχρο-

να, στα γραφήματα 4.11α' και 4.11β' φαίνεται πως για μεγαλύτερη τιμή του λ_1 , εμφανίζεται μικρότερο σφάλμα RMSE.



(α') $\eta = 0.02 \cdot \exp(-0.02 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$ (β') $\eta = 0.02 \cdot \exp(-0.2 \cdot c)$, $\gamma = 0.05 \cdot \exp(-0.05 \cdot c)$

Σχήμα 4.11: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση η , $b_1 = 0.02$)

Αξιολόγηση παραμέτρου γ

Όπως και στην αξιολόγηση της επιρροής της παραμέτρου η , έτσι και στην παράμετρο μάθησης γ διερευνάται μεμονωμένα η επιρροή της στην απόδοση του αλγορίθμου AHL. Παρομοίως με την η , εξετάζονται τρεις γενικές περιπτώσεις με χρήση κάποιων ενδεικτικών τιμών η . Οι συνδυασμοί των προσομοιώσεων παρουσιάζονται αναλυτικά στους Πίνακες 4.5, 4.6, 4.7. Η επιλογή των αποτελεσμάτων που παρουσιάζονται έγινε με κριτήριο την βέλτιστη αναπαράσταση της σύγκρισης.

b_2	η
0.02	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.05	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.1	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.15	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.2	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.5	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$

Πίνακας 4.5: Τιμές b_2 όταν
 $\gamma = b_2$, ($\lambda_2 = 0$)

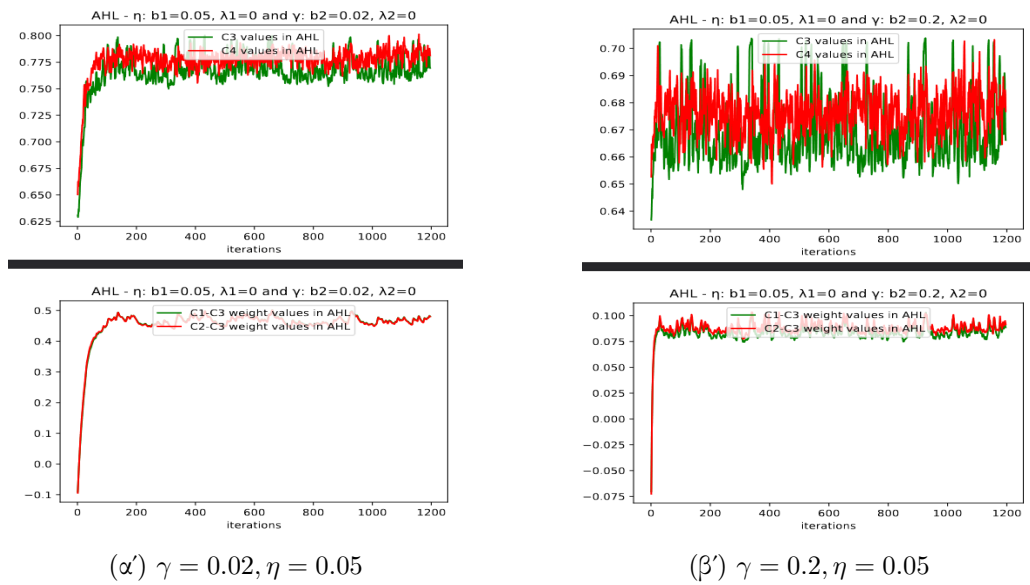
b_2	η
0.02	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.05	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.2	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.5	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$

Πίνακας 4.6: Τιμές b_2 όταν
 $\gamma = b_2 \cdot \exp(-0.2 \cdot c)$, ($\lambda_2 = 0.05s$)

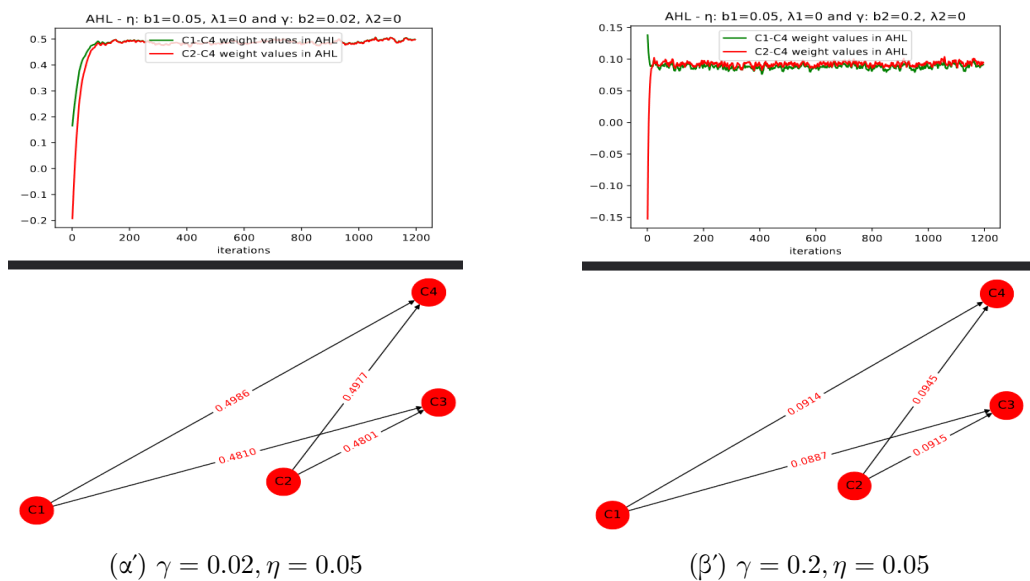
λ_2	η
0.02	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.05	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.2	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.2 \cdot c)$
0.5	0.05
	$0.05 \cdot \exp(-0.05 \cdot c)$ $0.05 \cdot \exp(-0.5 \cdot c)$

Πίνακας 4.7: Τιμές λ_2 όταν
 $\gamma = 0.05 \cdot \exp(-\lambda_2 \cdot c)$, ($b_2 = 0.02$)

Στην πρώτη περίπτωση εξετάζεται η επιρροή της παραμέτρου μάθησης όταν $\lambda_2 = 0$ και δοκιμάστηκε για ορισμένες τιμές της η . Από τις προσομοιώσεις προέκυψε το συμπέρασμα πως όσο μεγαλύτερη τιμή παίρνει το b_2 τόσο καλύτερα είναι και τα αποτελέσματα. Παρακάτω παρουσιάζονται τα γραφήματα για τις τιμές $b_2 = 0.02$, $b_2 = 0.2$ με χρήση $\eta = 0.05$.



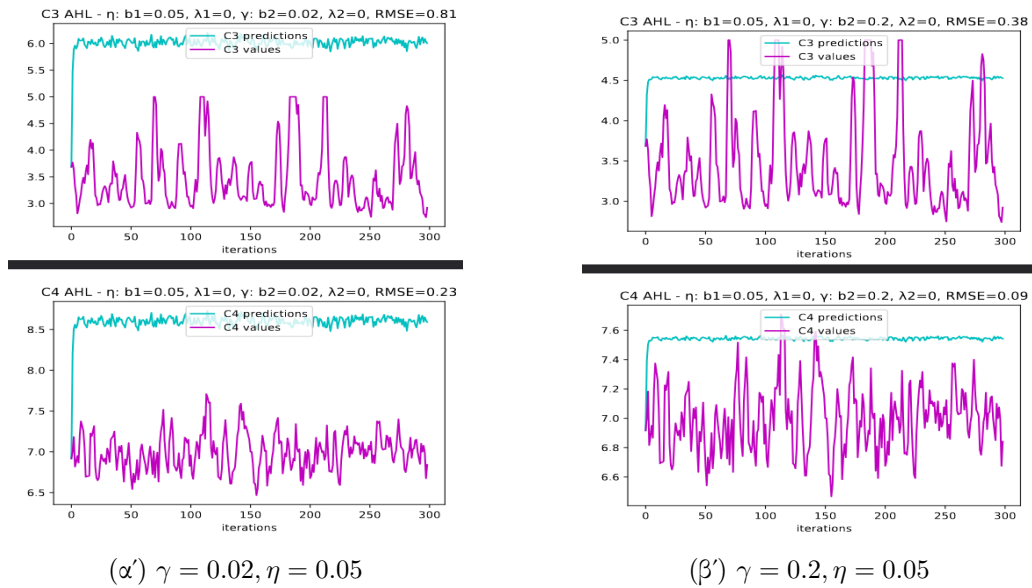
Σχήμα 4.12: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση $\gamma, \lambda_2 = 0$)



Σχήμα 4.13: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση $\gamma, \lambda_2 = 0$)


Στα αποτελέσματα των προσομοιώσεων παρατηρείται αύξηση των τιμών του κόμβου C_3 και στις δύο περιπτώσεις, στον κόμβο C_4 όμως διαφοροποιούνται. Όπως φαίνεται και στο Σχήμα 4.13β', η πορεία των αντίστοιχων τιμών των βαρών είναι η επιθυμητή για μεγαλύτερο b_2 , σε σύγκριση και με την περίπτωση με μικρότερη τιμή b_2 (Σχήμα 4.13α'). Ακόμη, στην συγκεκριμένη περίπτωση, επιβεβαιώνεται ότι μεγαλύτερη τιμή του b_2 (Σχήμα 4.14β') βελτιώνει τα αποτελέσματα αρκετά και κρατά φανερά την διακύμανση των προβλεπόμενων τιμών, αν και

σε μικρότερο βαθμό (Σχήμα 4.14).



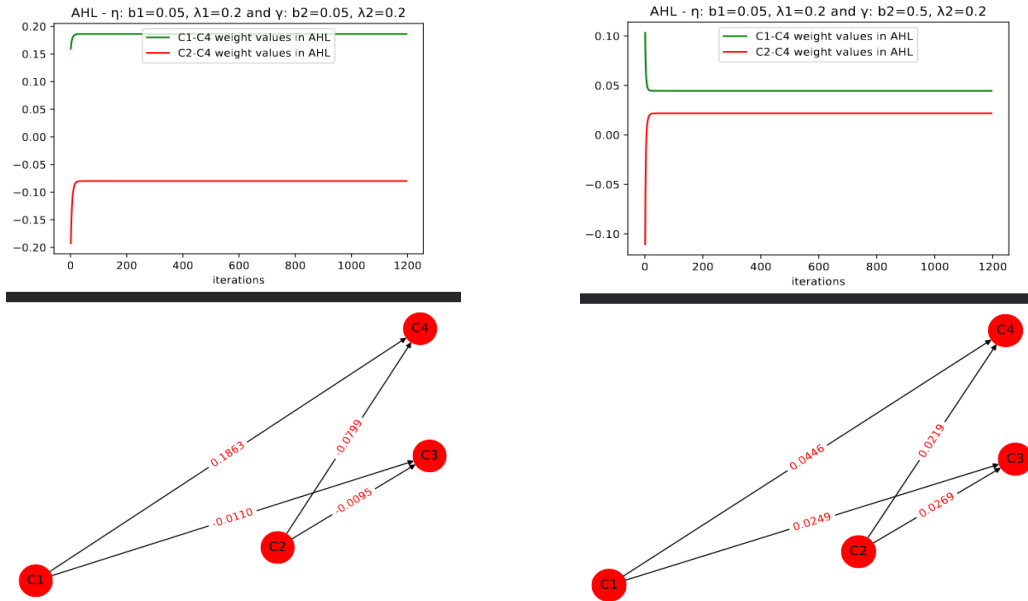
Σχήμα 4.14: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση $\gamma, \lambda_2 = 0$)

Όσον αφορά στην επιρροή της παραμέτρου b_2 όταν $\lambda_2 = 0.2$, θα πρέπει να χρησιμοποιείται σχετικά μικρή τιμή για την βέλτιστη απόδοση. Ενδεικτικά, παρουσιάζονται τα αποτελέσματα για $b_2 = 0.05, b_2 = 0.5$ με $\eta = 0.05 \cdot \exp(-0.2 \cdot c)$.




(α') $\gamma = 0.05 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$

Σχήμα 4.15: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση $\gamma, \lambda_2 = 0.2$)



(α') $\gamma = 0.05 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$

Σχήμα 4.16: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση $\gamma, \lambda_2 = 0.2$)



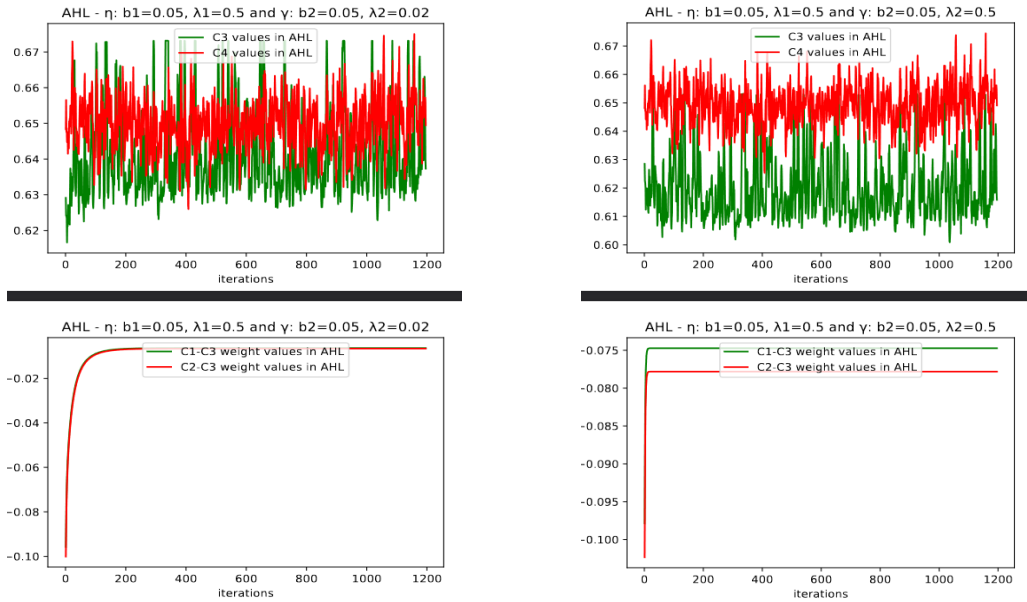
(α') $\gamma = 0.05 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.2 \cdot c), \eta = 0.05 \cdot \exp(-0.2 \cdot c)$

Σχήμα 4.17: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση $\gamma, \lambda_2 = 0$)

Στα γραφήματα του σχήματος 4.16 φαίνεται πως για μικρές διαφορές είναι καλύτερη η μικρότερη τιμή b_2 , η οποία εμφανίζει και πιο διακριτές διακυμάνσεις τιμών στις προβλέψεις.



Τέλος, δοκιμάζεται η επιρροή της γ όταν το $b_2 = 0.05$ και για ορισμένες τιμές του η . Από

τις προσομοιώσεις προέκυψε ότι βέλτιστη απόδοση του συστήματος υπάρχει όταν η τιμή του λ_2 είναι σχετικά μεγάλη. Παρακάτω παρουσιάζονται τα γραφήματα για τις περιπτώσεις που $\lambda_2 = 0.02$ και $\lambda_2 = 0.5$, με $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$.



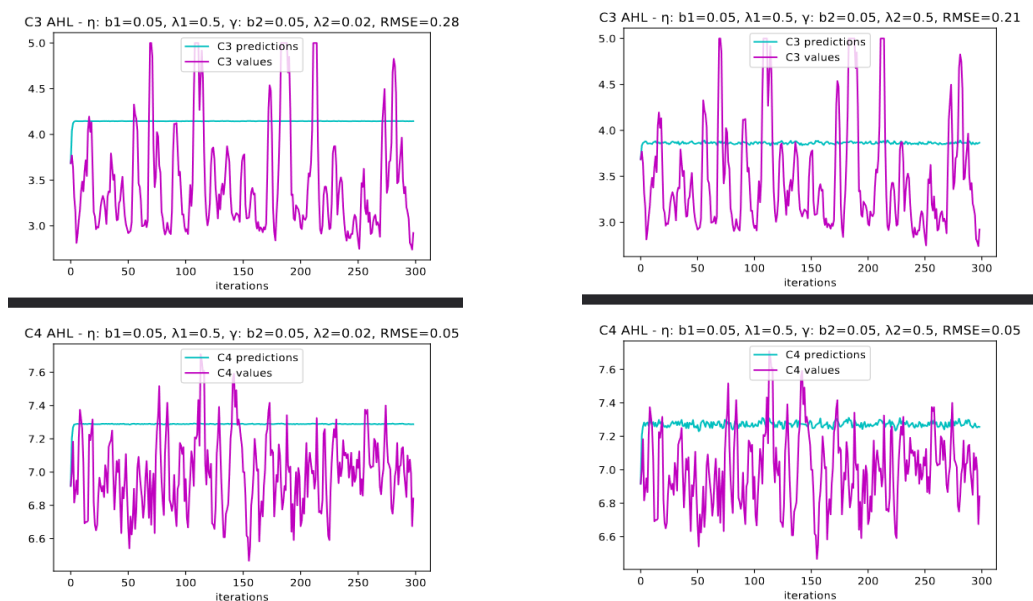
(α') $\gamma = 0.05 \cdot \exp(-0.02 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$ (β') $\gamma = 0.05 \cdot \exp(-0.5 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$

Σχήμα 4.18: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (διερεύνηση γ , $b_2 = 0.05$)



(α') $\gamma = 0.05 \cdot \exp(-0.02 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$ (β') $\gamma = 0.05 \cdot \exp(-0.5 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$

Σχήμα 4.19: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (διερεύνηση γ , $b_2 = 0.05$)



(α') $\gamma = 0.05 \cdot \exp(-0.02 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$ (β') $\gamma = 0.05 \cdot \exp(-0.5 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.5 \cdot c)$

Σχήμα 4.20: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, διερεύνηση γ , $b_2 = 0.05$)

Όπως διακρίνεται και στη σύγκριση των γραφημάτων του σχήματος 4.20, κυρίως στον κόμβο C_3 , η τιμή του λ_2 που αποδίδει καλύτερα είναι η μεγαλύτερη (Σχήμα 4.20β').

Συνδυαστική αξιολόγηση παραμέτρων μάθησης

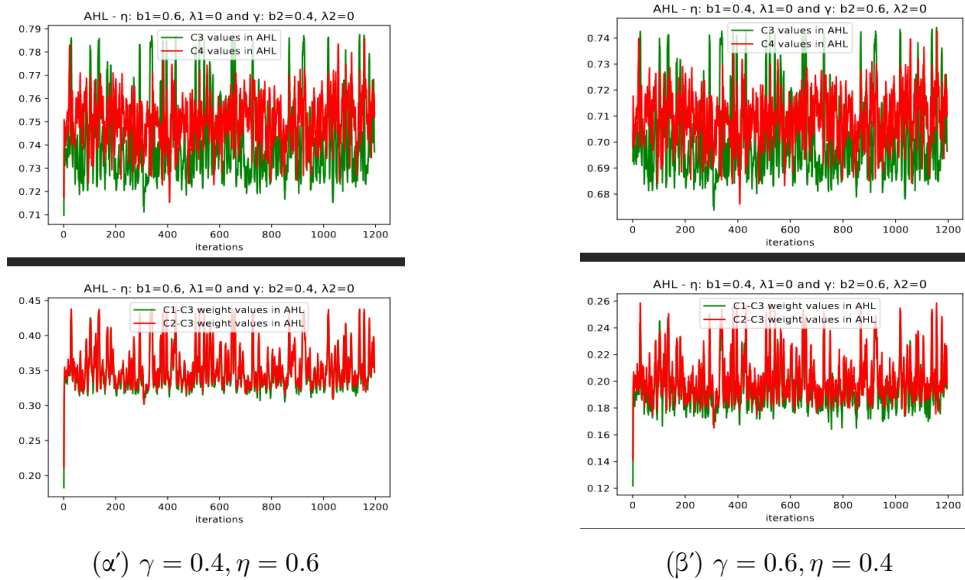
Σύμφωνα με τα παραπάνω αποτελέσματα, επιλέχθηκαν κάποιες τιμές συνδυαστικά για την τελική σύγκριση και αξιολόγηση του τρόπου που επηρεάζουν οι παράμετροι η , γ τον αλγόριθμο AHL. Αναλυτικά οι περιπτώσεις παρουσιάζονται στον Πίνακα 4.8.

	η	γ
Ίσες και σταθερές τιμές	0.05	0.05
	0.3	0.3
	0.6	0.6
Σταθερές τιμές και $\eta + \gamma = 1$	0.6	0.4
	0.4	0.6
Εκθετικές	$0.05 \cdot \exp(-0.5 \cdot c)$	$0.05 \cdot \exp(-0.5 \cdot c)$
	$0.05 \cdot \exp(-0.8 \cdot c)$	$0.05 \cdot \exp(-0.8 \cdot c)$
	$0.05 \cdot \exp(-0.8 \cdot c)$	$0.5 \cdot \exp(-0.8 \cdot c)$
Σταθερό γ	$0.05 \cdot \exp(-0.8 \cdot c)$	0.5
	$0.05 \cdot \exp(-0.8 \cdot c)$	0

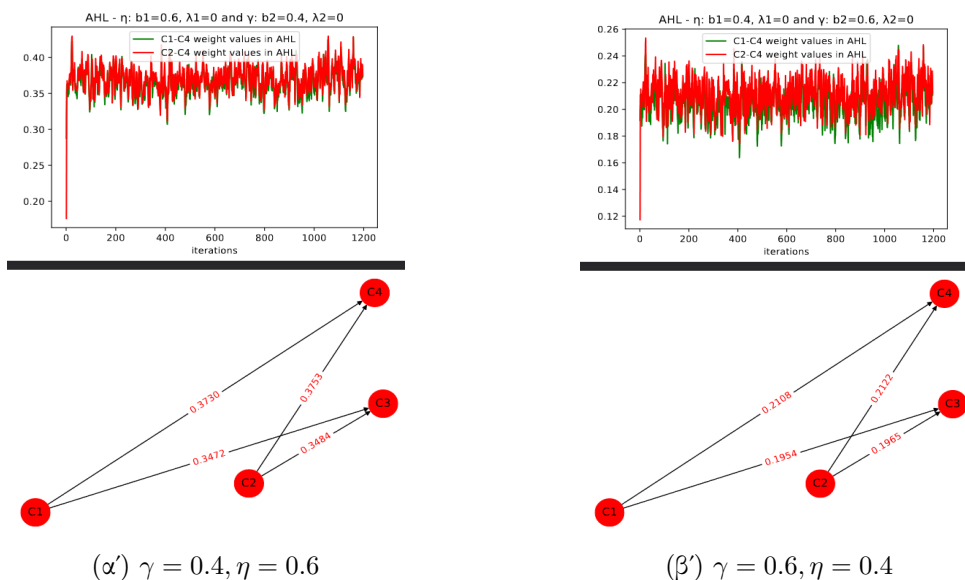
Πίνακας 4.8: Τιμές η , γ για συνδυαστική αξιολόγηση AHL

Στην πρώτη περίπτωση που οι παράμετροι μάθησης είναι σταθερές και ίσες μεταξύ τους, παρατηρήθηκε πως, με ελάχιστη διαφορά, καλύτερα ήταν τα αποτελέσματα όταν η τιμή ήταν σχετικά μεγάλη.

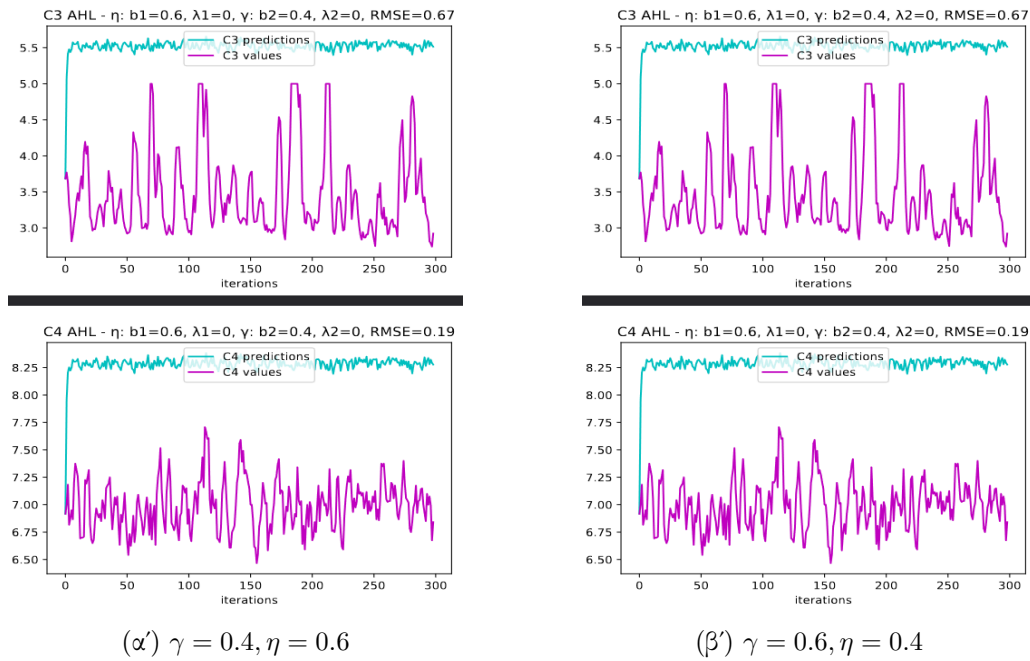
Όσον αφορά στην δεύτερη περίπτωση που οι παράμετροι μάθησης ανθροίζουν στην μονάδα, παρατηρήθηκε ότι δίνουν κοντινά αποτελέσματα με την προηγούμενη περίπτωση, ως προς την συνάρτηση σφάλματος (RMSE). Αξιοσημείωτο είναι το γεγονός ότι όταν η παράμετρος γ παίρνει την πιο μεγάλη τιμή σε σχέση με την η , έχουμε καλύτερη απόδοση (Σχήματα 4.22, 4.23), πράγμα που επιβεβαιώνει και τις παρατηρήσεις που έγιναν κατά την ξεχωριστή διερεύνηση των τιμών (Σχήματα 4.4, 4.13).



Σχήμα 4.21: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL ($\eta + \gamma = 1$ και σταθερά)



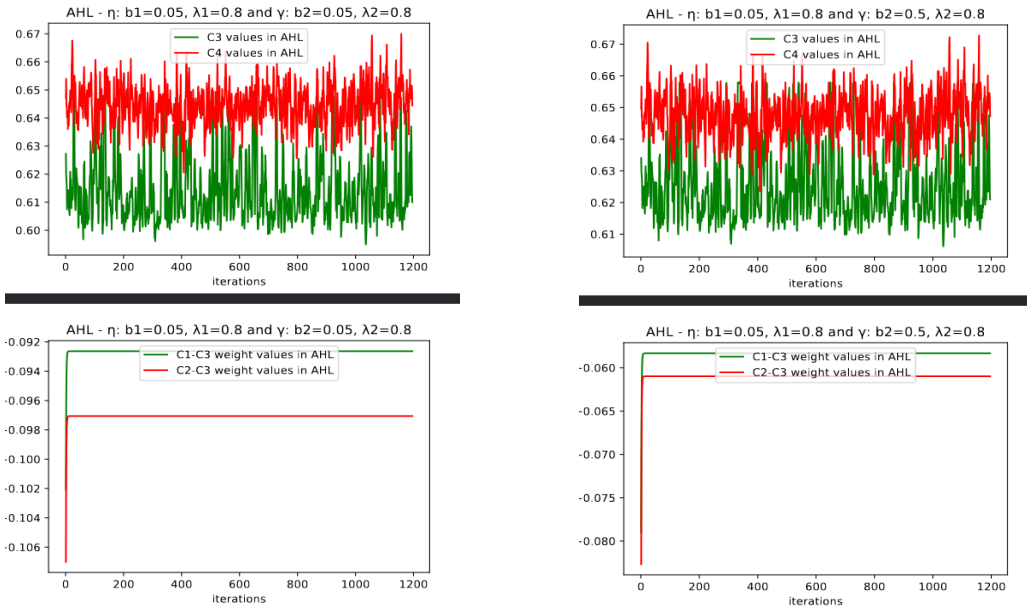
Σχήμα 4.22: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL ($\eta + \gamma = 1$ και σταθερά)



Σχήμα 4.23: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, $\eta + \gamma = 1$ και σταθερά)



Ακολούθως δοκιμάστηκαν τρεις περιπτώσεις στις οποίες και οι δύο παράμετροι εκμάθησης έχουν εκθετική μορφή, συνδυάζοντας τις παραπάνω παρατηρήσεις για την επιλογή τους. Στην πρώτη περίπτωση οι παράμετροι b_1, b_2 έχουν επιλεχθεί μικρές και οι παράμετροι λ_1, λ_2 μεγάλες. Στην δεύτερη περίπτωση, έγινε αύξηση των παραμέτρων μέσα στον εκθετικό όρο, δεδομένου ότι είχε παρατηρηθεί στις αντίστοιχες προσομοιώσεις διερεύνησης. Στην τρίτη περίπτωση δοκιμάστηκε η αύξηση της παραμέτρου b_2 , εφόσον στις προηγούμενες προσομοιώσεις φαίνεται να βελτιώνει την απόδοση του αλγορίθμου.

Αρχικά, επιβεβαιώθηκε η υπόθεση πως όσο μεγαλύτερες τιμές παίρνουν τα λ_1, λ_2 προκύπτουν και καλύτερα αποτελέσματα (Σχήματα 4.24α', 4.25α', 4.26α'. Σε αντίθεση με το αναμενόμενο, η αύξηση της b_2 , όταν έχουμε εκθετικές μορφές και στις δύο παραμέτρους δεν αποτελεί την καλύτερη λύση (Σχήματα 4.24β', 4.25β', 4.26β').




(α') $\gamma = 0.05 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$

Σχήμα 4.24: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (η, γ εκθετικά και διερεύνηση b_2)



(α') $\gamma = 0.05 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$

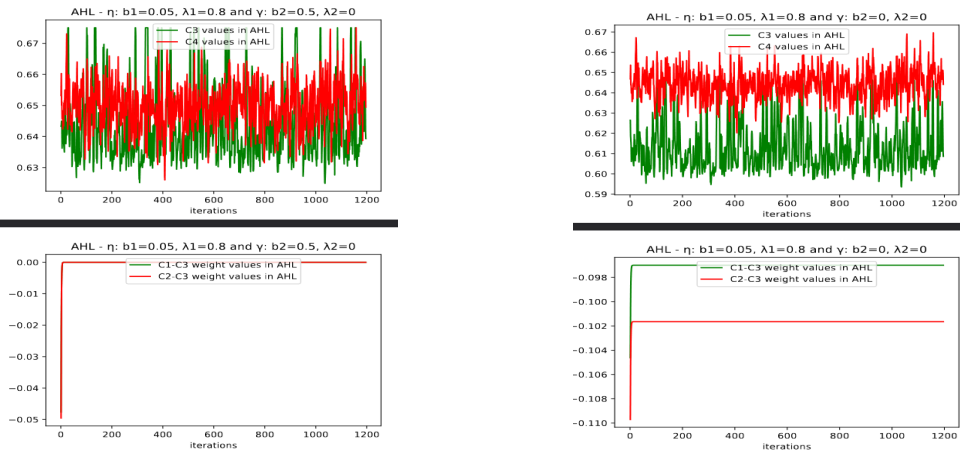
Σχήμα 4.25: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (η, γ εκθετικά και διερεύνηση b_2)



(α') $\gamma = 0.05 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$ (β') $\gamma = 0.5 \cdot \exp(-0.8 \cdot c)$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$

Σχήμα 4.26: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, η , γ εκθετικά και διερεύνηση b_2)

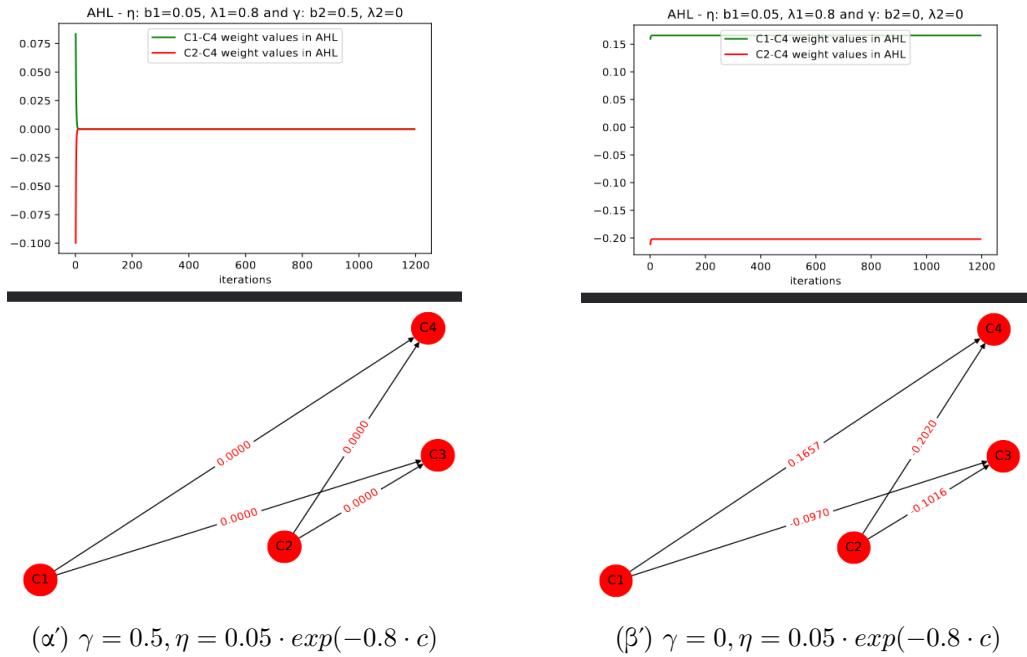
Με βάση τις παραπάνω παρατηρήσεις, δοκιμάστηκαν εκθετικές τιμές της παραμέτρου η σε συνδυασμό με σταθερή τιμή του γ και συγκεκριμένα μια σχετικά μεγάλη τιμή και μια μηδενική. Τα αποτελέσματα των προσομοιώσεων έδειξαν πως στην πρώτη περίπτωση παρόλο που το τελικό σφάλμα (RMSE) φαίνεται να είναι σχετικά μικρό, τα υπόλοιπα γραφήματα δείχνουν πως δεν αποδίδει η διαδικασία της εκπαίδευσης, καθώς και τα βάρη τείνουν να μηδενιστούν (Σχήματα 4.29 α' , 4.27 α' , 4.28 α'). Αντίθετα, στην περίπτωση που το γ είναι μηδέν, τόσο το σφάλμα όσο και τα υπόλοιπα αποτελέσματα είναι αρκετά ικανοποιητικά (Σχήματα 4.27 β' , 4.28 β' , 4.29 β').




(α') $\gamma = 0.5$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$

(β') $\gamma = 0$, $\eta = 0.05 \cdot \exp(-0.8 \cdot c)$

Σχήμα 4.27: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον AHL (η εκθετικό και διερεύνηση γ σταθερής τιμής)



Σχήμα 4.28: Διακύμανση τιμών βαρών του C_4 στον AHL και γράφος ύστερα από AHL (η εκθετικό και διερεύνηση γ σταθερής τιμής)



Σχήμα 4.29: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (AHL, η εκθετικό και διερεύνηση γ σταθερής τιμής)

Συνεπώς προκύπτει πως τα βέλτιστα αποτελέσματα από τις τελευταίες συνδυαστικές προσομοιώσεις προέκυψαν στην περίπτωση που οι δύο παράμετροι είχαν εκθετική μορφή και με b_1, b_2 μικρά, λ_1, λ_2 μεγάλα (Σχήματα 4.24α', 4.25α', 4.26α'), καθώς και στην περίπτωση που

το η έχει την εκθετική μορφή και το γ έχει μηδενική τιμή (Σχήματα 4.27β', 4.28β', 4.29β').

4.3 Αλγόριθμος NHL

4.3.1 Περιγραφή Υλοποίησης

Ο δεύτερος αλγόριθμος που δοκιμάστηκε για την μοντελοποίηση του συστήματος offloading ήταν ο Nonlinear Hebbian Algorithm (NHL). Ειδικότερα, για την υλοποίησή του χρησιμοποιήθηκε το ίδιο dataset και ο ίδιος τυχαία αρχικοποιημένος γράφος (Σχήμα 4.2), ώστε να μπορεί να γίνει και η τελική σύγκριση. Οι παράμετροι του αλγορίθμου που χρησιμοποιήθηκαν ορίζονται παρακάτω.

- Επιθυμητές Έννοιες Εξόδου (DOCs): όπως και στον αλγόριθμο AHL, ως κόμβοι εξόδου του FCM ορίστηκαν οι κόμβοι C_3, C_4 .
- Συνθήκες τερματισμού (εξ. (3.16), εξ. (3.17)): εφόσον η εκπαίδευση του FCM γίνεται με βάση κάποια καθορισμένα δεδομένα, ο αριθμός των επαναλήψεων θα είναι καθορισμένος και αυτός. Έτσι, η ύπαρξη των συνθηκών για τερματισμό του αλγορίθμου και σύγκλιση των τιμών εξόδου στις επιθυμητές δεν κρίνεται απαραίτητος.
- Μέγιστο πλήθος επαναλήψεων k : στην παρούσα υλοποίηση ισούται με το μέγεθος του dataset το οποίο χρησιμοποιείται για training. Αντίστοιχα και με τον AHL, αν το αρχικό dataset είναι μεγέθους $n = 1500$, τότε το πλήθος των επαναλήψεων θα είναι 1200 και μοναδική συνθήκη τερματισμού του αλγορίθμου $k < 1200$.

Για την διαδικασία της εκπαίδευσης και σε αυτόν τον αλγόριθμο χρησιμοποιήθηκε το 80% του δεδομένου dataset. Ο αλγόριθμος NHL κατά την διαδικασία εκμάθησης αρχικοποιεί το διάνυσμα κατάστασης και τον πίνακα βαρών και στην συνέχεια ενεργοποιεί τις τιμές των κόμβων και των βαρών με τις εξισώσεις (3.12) και (3.13). Στην συγκεκριμένη περίπτωση, το διάνυσμα καταστάσεων αρχικοποιείται με τιμές από το dataset, το οποίο χρησιμοποιείται και στην συνέχεια, στους τύπους ενεργοποίησης. Η αρχικοποίηση του πίνακα βαρών έγινε με τυχαίο τρόπο με χρήση κανονικής κατανομής. Για την σύγκριση μεταξύ των αλγορίθμων AHL, NHL, τα αποτελέσματα που παρουσιάζονται και αναλύονται παρακάτω έχουν προκύψει από την αρχικοποίηση του πίνακα βαρών με τον τυχαίο που είχε χρησιμοποιηθεί στον AHL. Ο αρχικός γράφος παρουσιάζεται στο Σχήμα 4.2.

Για την διαδικασία ελέγχου των αποτελεσμάτων, χρησιμοποιήθηκε το 20% των τιμών του dataset. Έγινε αρχικοποίηση του διανύσματος κατάστασης με δεδομένα και αντίστοιχα του πίνακα βαρών με τιμές που προέκυψαν από τον αλγόριθμο NHL. Στη συνέχεια, χρησιμοποιήθηκε η εξίσωση ενεργοποίησης (3.2) για την πρόβλεψη τιμών των DOCs, C_3, C_4 . Τέλος, για τον έλεγχο των αποτελεσμάτων έγινε χρήση της συνάρτησης ρίζα μέσου τετραγωνικού σφάλματος (εξ. (4.2), (RMSE)) για την εκτίμηση του σφάλματος μεταξύ της πραγματικής τιμής, δηλαδή της τιμής του dataset και της προβλεπόμενης τιμής, δηλαδή της παραγόμενης από τον αλγόριθμο.

4.3.2 Αποτελέσματα NHL και Αξιολόγηση

Στον NHL υπάρχουν δύο παράμετροι μάθησης και αυτές είναι τα η και γ , οι οποίες χρησιμοποιούνται στην εξίσωση ενεργοποίησης βαρών (3.13). Στην βιβλιογραφία [30] προτείνεται η χρήση των παραμέτρων αυτών σε καθορισμένα διαστήματα και συγκεκριμένα:

$$0 < \eta < 0.1, \quad 0.9 < \gamma < 1. \quad (4.3)$$

Έτσι, για την διερεύνηση της επιρροής των παραμέτρων έγιναν προσομοιώσεις με την χρήση των παραπάνω ορίων και βήμα αύξησης της τιμής 0.01. Ακόμη, έγινε και μεμονωμένη διερεύνηση με χρήση διάφορων τιμών, οι οποίες παρουσιάζονται στους Πίνακες 4.9, 4.10, ενώ στο τέλος δοκιμάστηκαν συνδυαστικά κάποια σενάρια. Τα γραφήματα που παρουσιάζονται σε κάθε περίπτωση επιλέχθηκαν για να αντιπροσωπεύουν το κάθε συμπέρασμα που αναλύεται.

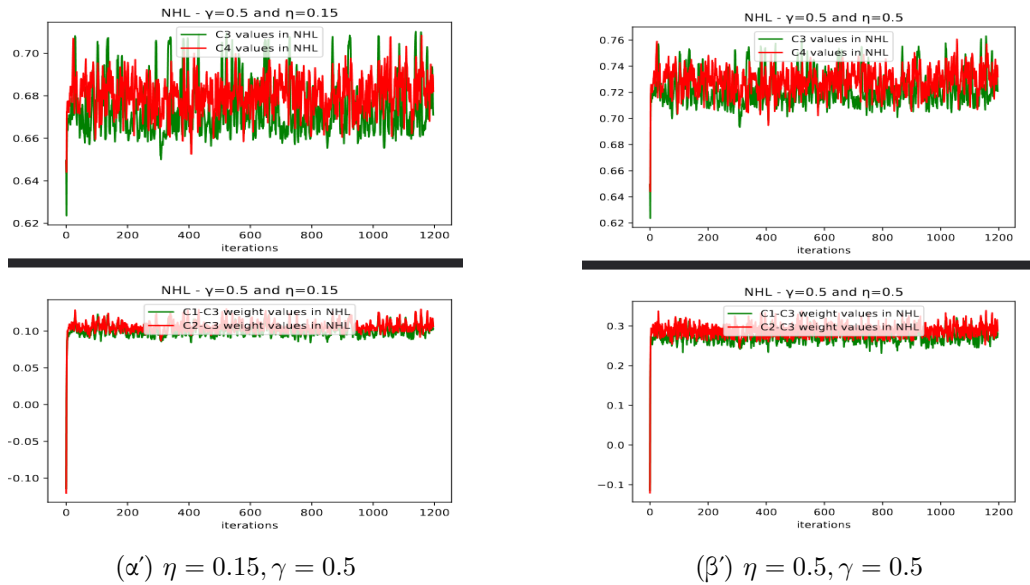
Αξιολόγηση παραμέτρου η

Αρχικά, έγινε μια διερεύνηση ως προς την επιρροή της η στον αλγόριθμο μάθησης. Χρησιμοποιήθηκαν ενδεικτικές τιμές και εκτός των προτεινόμενων ορίων, οι οποίες συνδυάστηκαν με κάποιες ενδεικτικές τιμές της παραμέτρου γ , όπως φαίνεται στον πίνακα 4.9.

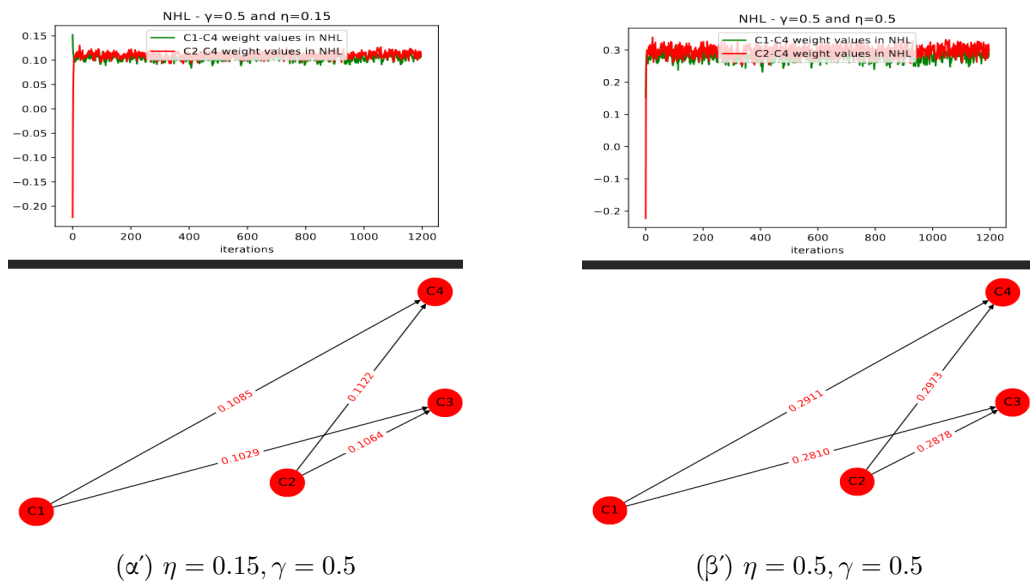
η	γ
0.02	0.05
	0.2
	0.5
	0.9
0.05	0.05
	0.2
	0.5
	0.9
0.1	0.05
	0.2
	0.5
	0.9
0.15	0.05
	0.2
	0.5
	0.9
0.2	0.05
	0.2
	0.5
	0.9
0.5	0.05
	0.2
	0.5
	0.9

Πίνακας 4.9: Τιμές διερεύνησης η

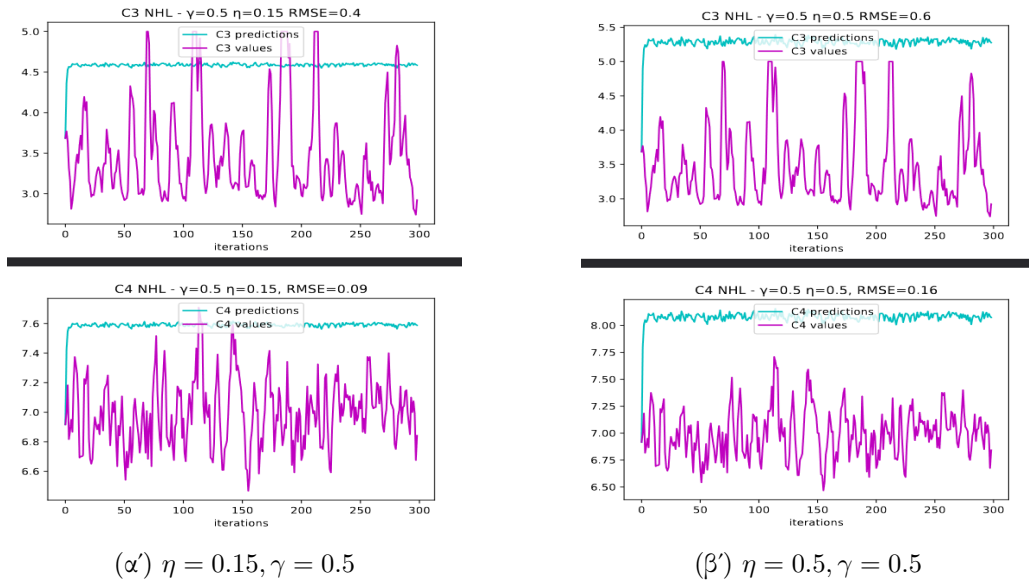
Μετά από τις προσομοιώσεις παρατηρήθηκε πως όσο μικρότερη τιμή έχει η η τόσο καλύτερα είναι και τα αποτελέσματα (Σχήμα 4.32). Εντούτοις, φαίνεται πως ο πίνακας βαρών μειώνει αρκετά την τιμή των βαρών (Σχήμα 4.31), ώστε δεν υπάρχει τόσο καλή διακύμανση προβλεπόμενων τιμών. Ενδεικτικά παρουσιάζονται τα αποτελέσματα για $\gamma = 0.5$ και $\eta = 0.15$ και $\eta = 0.5$.



Σχήμα 4.30: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερεύνηση η)



Σχήμα 4.31: Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση η)



Σχήμα 4.32: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διερεύνηση η)

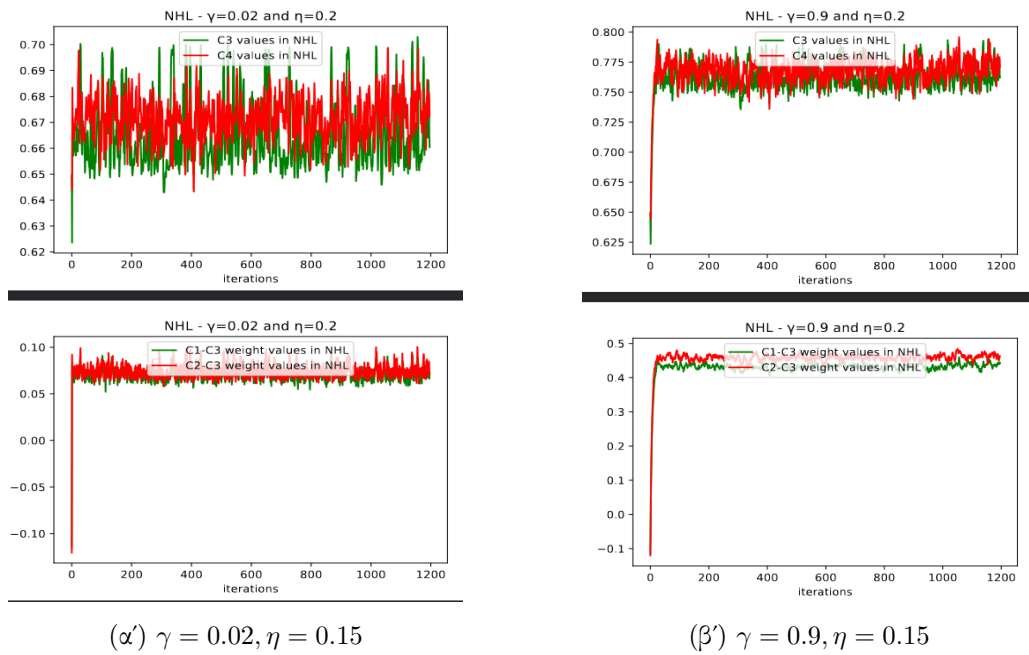
Αξιολόγηση της γ

Ακολούθως, εξετάστηκε μεμονωμένα η επίδραση της παραμέτρου γ στον αλγόριθμο χρήσει κάποιων ενδεικτικών τιμών της η , όπως παρουσιάζεται και στον πίνακα 4.10.

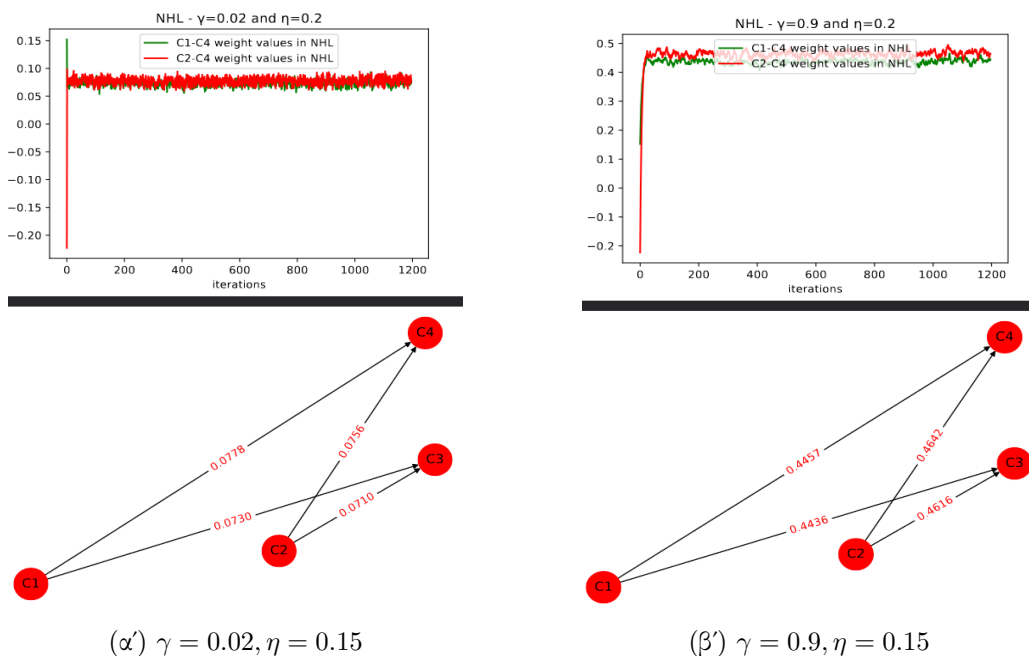
η	γ
0.02	0.02
	0.05
	0.2
	0.5
0.05	0.02
	0.05
	0.2
	0.5
0.2	0.02
	0.05
	0.2
	0.5
0.5	0.02
	0.05
	0.2
	0.5
0.9	0.02
	0.05
	0.2
	0.5

Πίνακας 4.10: Τιμές διερεύνησης γ

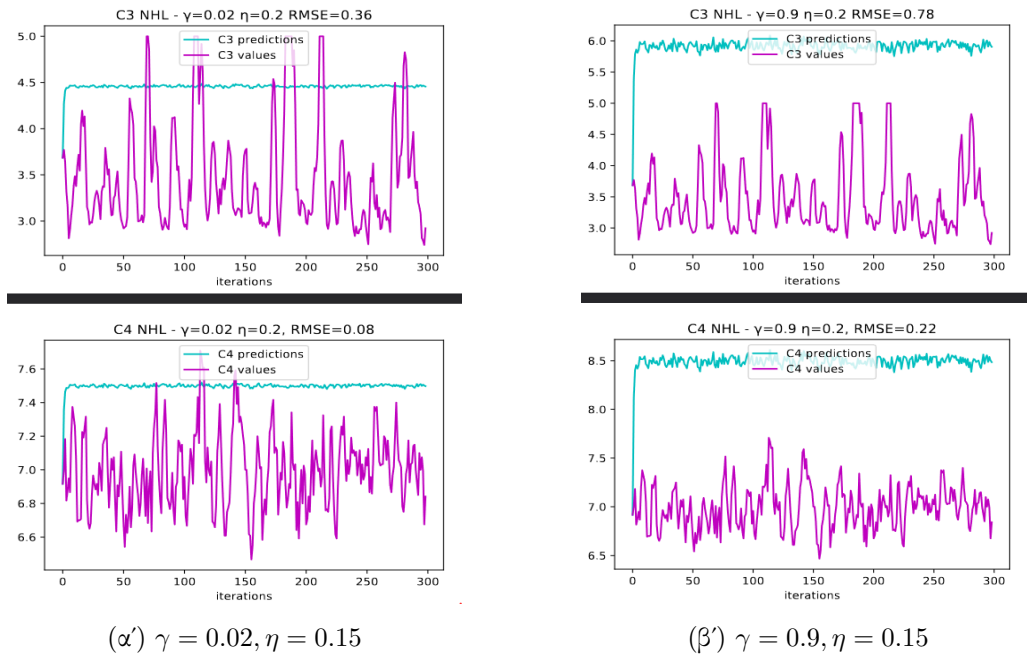
Όπως και με την άλλη παράμετρο μάθησης, φαίνεται πως όσο μικρότερη τιμή έχει και η γ δίνει καλύτερα αποτελέσματα, παρόλο που μειώνει σε σημαντικό βαθμό τα βάρη του γράφου. Αναλυτικά παρουσιάζονται οι περιπτώσεις στις οποίες $\eta = 0.2$ και $\gamma = 0.02$ και $\gamma = 0.9$.



Σχήμα 4.33: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερεύνηση γ)



Σχήμα 4.34: Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση γ)



Σχήμα 4.35: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διερεύνηση γ)

Συνδυαστική αξιολόγηση παραμέτρων μάθησης

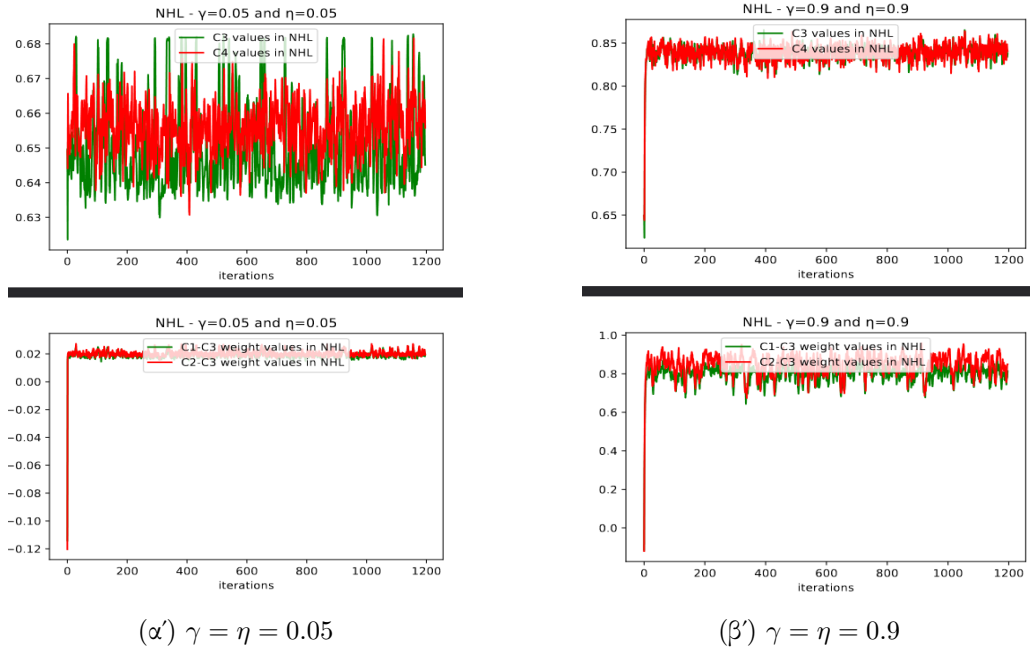
Τέλος, δοκιμάστηκαν συνδυαστικά οι παράμετροι η, γ σε διάφορες περιπτώσεις. Αρχικά, έγινε δοκιμή των παραμέτρων στο αντίστοιχο προτεινόμενο διάστημα 4.3, με αλλαγή της κάθε παραμέτρου με βήμα 0.01. Σε αυτά τα σενάρια, παρατηρήθηκε πως σε όλες τις περιπτώσεις των τιμών γ , το καλύτερο σενάριο προέκυπτε να είναι με την παράμετρο $\eta = 0.01$. Ακόμη, μεταξύ των τιμών των γ η καλύτερη ήταν όταν $\gamma = 0.9$, δηλαδή η μικρότερη δυνατή της προσομοίωσης. Επομένως, επιβεβαιώνονται και οι παραπάνω παρατηρήσεις που προέκυψαν κατά την μεμονωμένη διερεύνηση των παραμέτρων.

Στη συνέχεια, δοκιμάστηκαν ορισμένα σενάρια, όπως παρουσιάζονται και στον πίνακα 4.11.

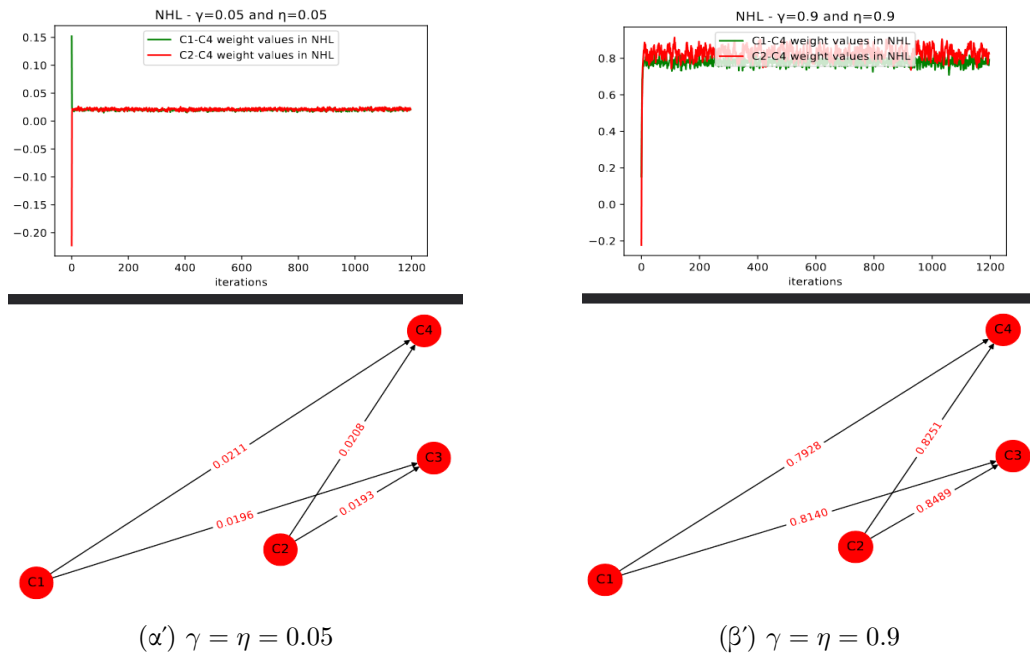
	η	γ
Ίσες τιμές	0.01	0.01
	0.05	0.05
	0.2	0.2
	0.5	0.5
	0.9	0.9
$\eta + \gamma = 1$	0.6	0.4
	0.4	0.6
	0.9	0.1
	0.1	0.9
Μικρή τιμή η , μεγαλύτερη γ	0.01	0.4
	0.01	0.6

Πίνακας 4.11: Τιμές η, γ για συνδυαστική αξιολόγηση NHL

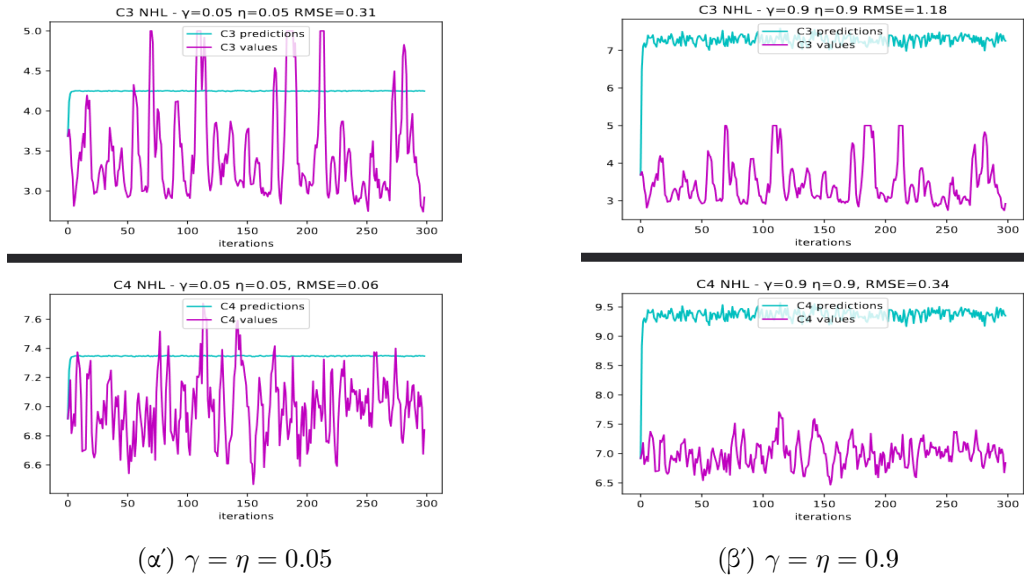
Στην πρώτη περίπτωση που δοκιμάζονται ίσες τιμές στις δύο παραμέτρους, παρατηρήθηκε πάλι πως όσο μικρότερες είναι δίνουν και καλύτερα αποτελέσματα. Βέβαια, παρατηρείται ξανά η τάση μηδένισης των βαρών και άρα μείωση της διακύμανσης των προβλεπόμενων τιμών. Ενδεικτικά, παρουσιάζονται οι περιπτώσεις όπου $\eta = \gamma = 0.05$ και $\eta = \gamma = 0.9$.



Σχήμα 4.36: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL ($\eta = \gamma$)

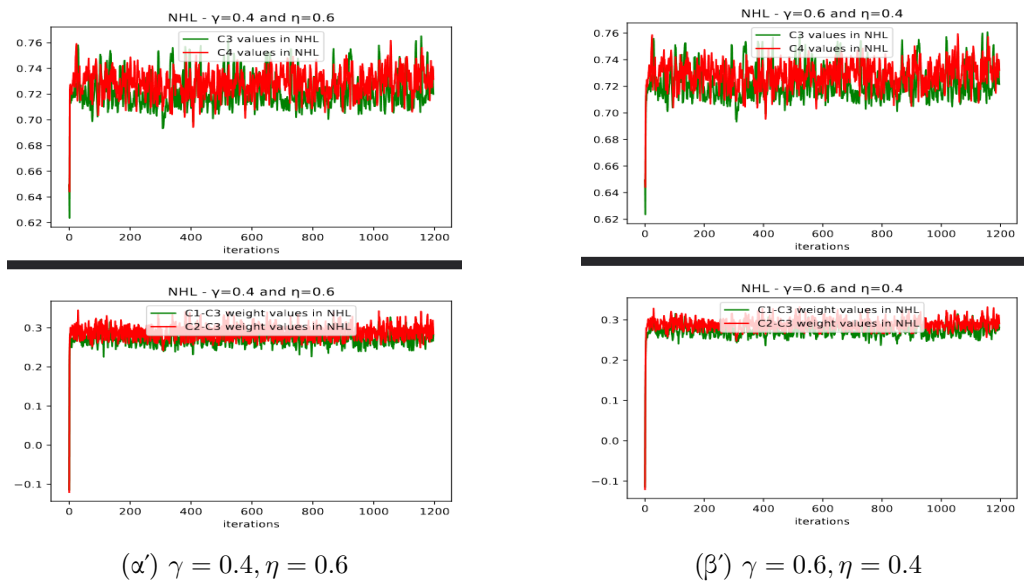


Σχήμα 4.37: Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL ($\eta = \gamma$)

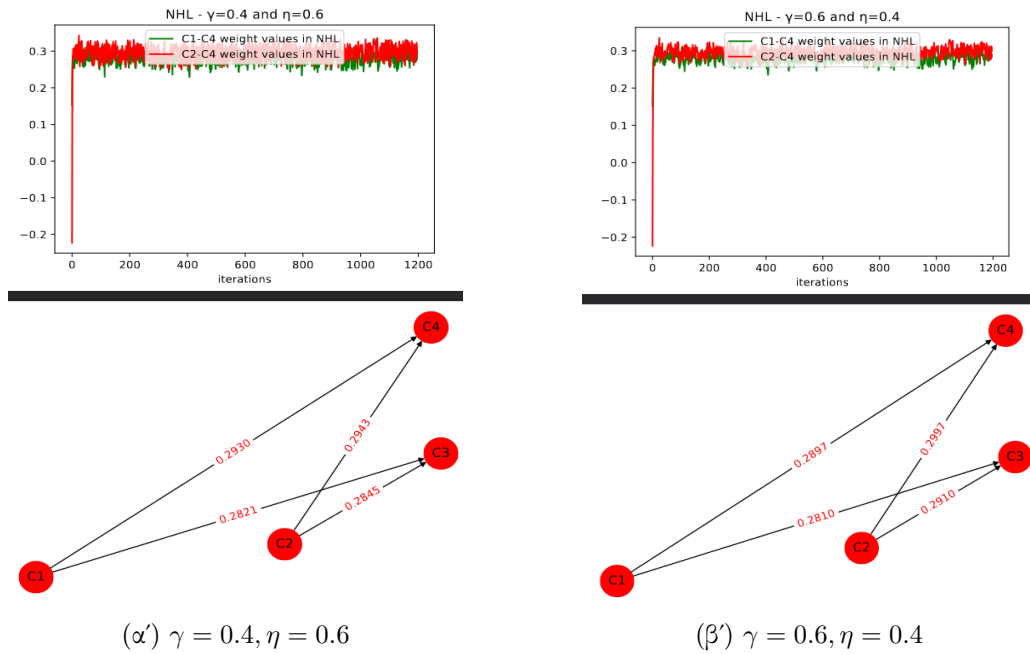


Σχήμα 4.38: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, ($\eta = \gamma$))

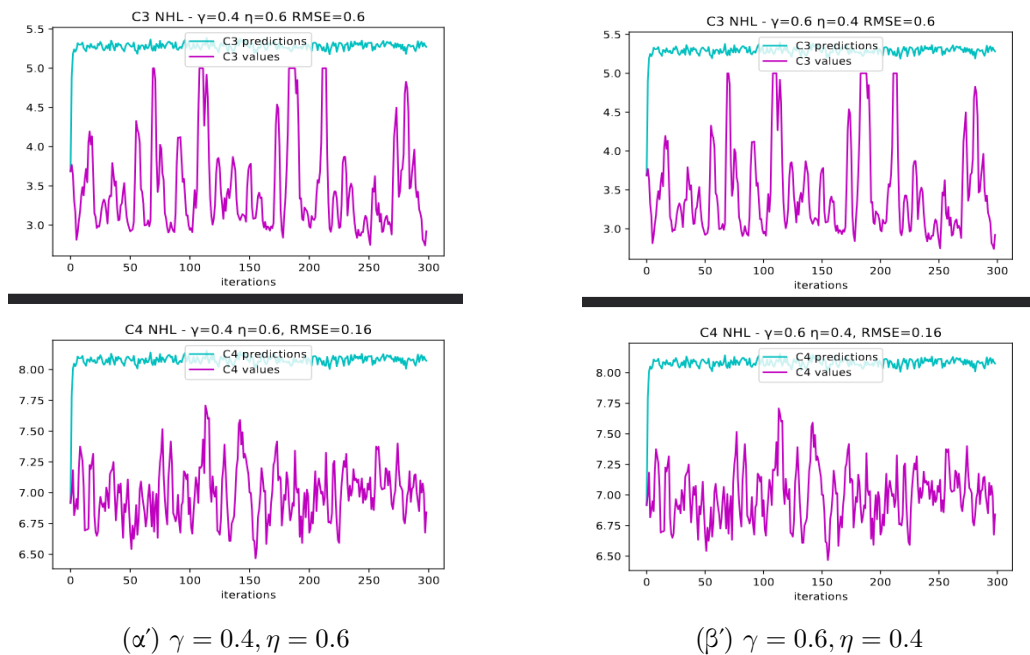
Μια ακόμη περίπτωση που διερευνήθηκε ήταν όταν οι παράμετροι αθροίζουν στην μονάδα. Σε κάθε σενάριο που υλοποιήθηκε τα αποτελέσματα ήταν πολύ κοντινά, τόσο εκείνα που αφορούν την ανταλλαγή των τιμών των παραμέτρων (π.χ. $\eta = 0.6, \gamma = 0.4$ και $\eta = 0.4, \gamma = 0.6$), όσο και όλα τα σενάρια μεταξύ τους. Όσον αφορά στην απόδοση γενικότερα, τα αποτελέσματα δεν είναι τόσο ικανοποιητικά. Ενδεικτικά, παρακάτω παρουσιάζεται η περίπτωση του παραδείγματος.



Σχήμα 4.39: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL ($\eta + \gamma = 1$)



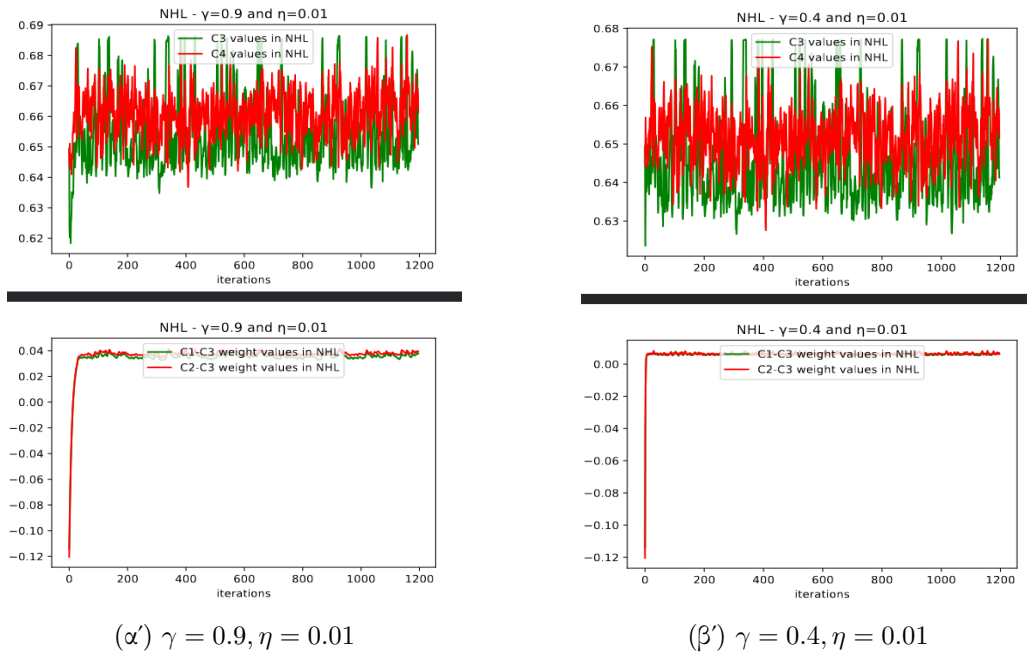
Σχήμα 4.40: Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL ($\eta + \gamma = 1$)



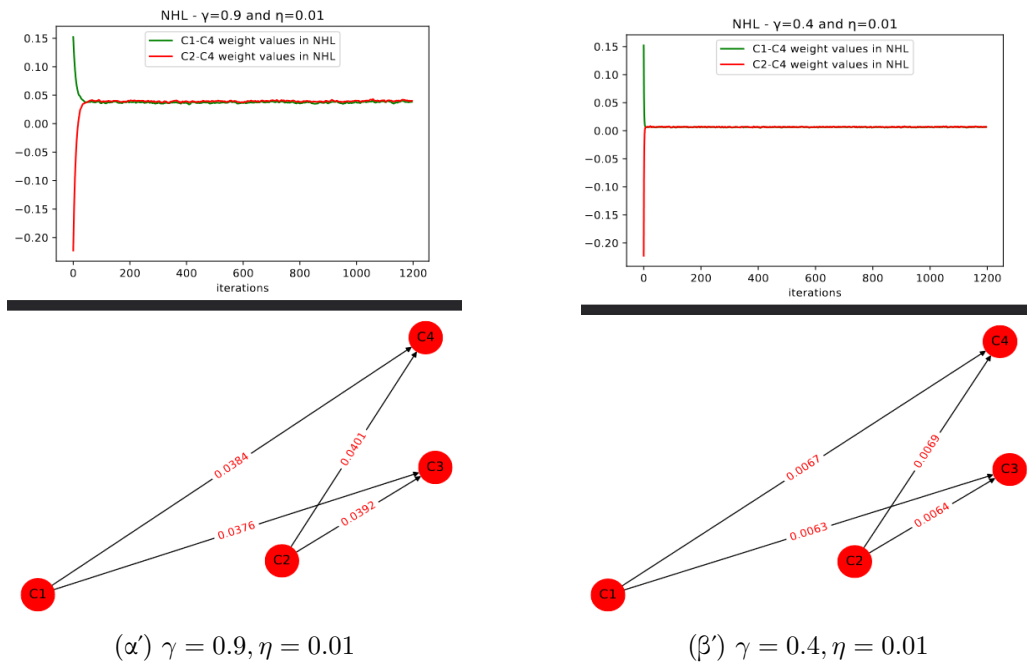
Σχήμα 4.41: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, ($\eta + \gamma = 1$))

Τέλος, δεδομένων και των αποτελεσμάτων της προσομοίωσης με τις τιμές της βιβλιογραφίας, δοκιμάστηκαν δύο περιπτώσεις με διαφορετική τιμή γ και με $\eta = 0.01$. Σε αυτές παρατηρήθηκε πως η μικρότερη τιμή δείχνει μικρότερη τιμή σφάλματος, αλλά με επιβάρυνση

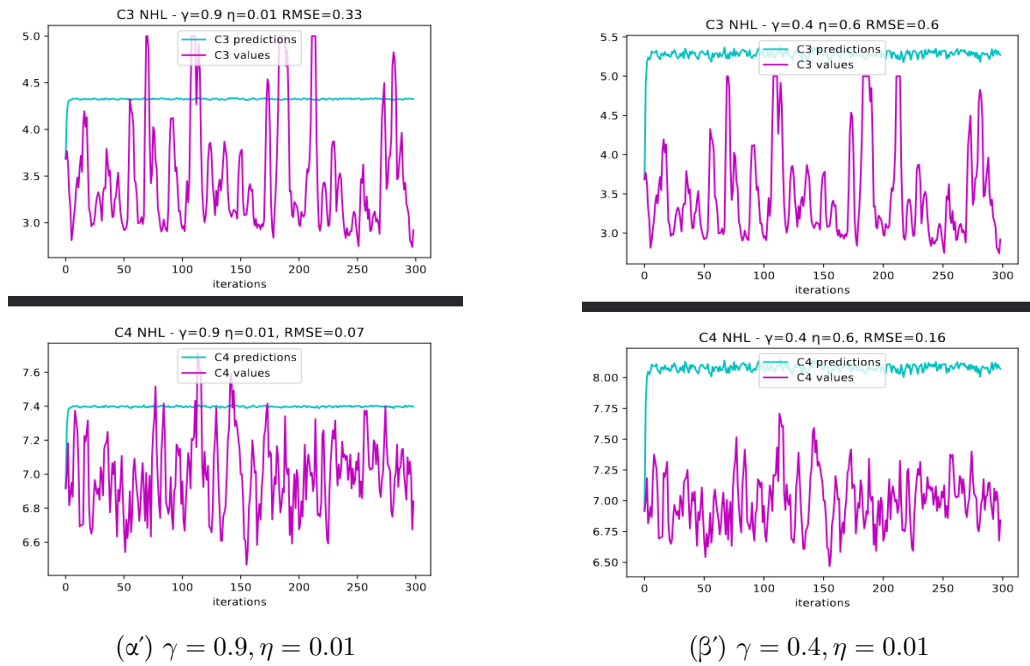
στην διακύμανση. Παρακάτω παρουσιάζεται η βέλτιστη περίπτωση της προσομοίωσης των τιμών της βιβλιογραφίας (Σχήματα 4.42α', 4.43α', 4.44α'), με την βέλτιστη εκ των δύο σεναρίων, όπου $\gamma = 0.4$ (Σχήματα 4.42β', 4.43β', 4.44β').



Σχήμα 4.42: Διακύμανση τιμών κόμβων εξόδου και τιμών βαρών του C_3 στον NHL (διερεύνηση $\gamma, \eta = 0.01$)



Σχήμα 4.43: Διακύμανση τιμών βαρών του C_4 στον NHL και γράφος ύστερα από NHL (διερεύνηση $\gamma, \eta = 0.01$)



Σχήμα 4.44: Σύγκριση παραγόμενων - πραγματικών τιμών των κόμβων εξόδου (NHL, διερεύνηση $\gamma, \eta = 0.01$)

Κεφάλαιο 5

Επίλογος

5.1 Συμπεράσματα

Στο πλαίσιο αυτής της διπλωματικής έγινε βασική μοντελοποίηση συστήματος μεταφόρτωσης διεργασιών από κινητή συσκευή σε κοντινό εξυπηρετητή με την χρήση Fuzzy Cognitive Map (FCM) από την μεριά του εξυπηρετητή. Συγκεκριμένα, δοκιμάστηκαν δύο αλγόριθμοι εκμάθησης για την πρόβλεψη των τιμών, ο Active Hebbian Learning (AHL) και ο Nonlinear Hebbian Learning (NHL) και έγινε διερεύνηση της επιρροής των δύο παραμέτρων μάθησης η, γ στα αποτελέσματα της μοντελοποίησης για κάθε αλγόριθμο.

Οι δύο αλγόριθμοι μοιάζουν αρκετά στην υλοποίησή τους, εφόσον και οι δύο βασίζονται στον κανόνα του Hebb για την ενεργοποίηση των βαρών και έχουν παρόμοια κριτήρια τερματισμού. Βασική διαφορά τους αποτελεί η ασύγχρονη ενεργοποίηση τιμών των εννοιών και των βαρών στον AHL, στον οποίο ορίζεται και συγκεκριμένη ακολουθία εννοιών ενεργοποίησης. Από την μια, πρόκειται για ένα επιπλέον βήμα για το οποίο πρέπει να μεριμνήσουν οι ειδικοί, δεδομένου ότι το ορίζουν μαζί με τις έννοιες, τις σχέσεις των εννοιών και τους κόμβους εξόδου του γράφου. Εντούτοις, συγκρίνοντας τα αποτελέσματα και με τον NHL, φαίνεται πως με κατάλληλη επιλογή παραμέτρων μάθησης μπορεί να αποδώσει σε ικανοποιητικό βαθμό την συμπεριφορά του εξυπηρετητή και ταυτόχρονα να βελτιώσει προς το επιθυμητό τον πίνακα βαρών. Αντίθετα, ο NHL αλγόριθμος, ενώ και αυτός με τις κατάλληλες παραμέτρους μάθησης πλησιάζει τις επιθυμητές τιμές κόμβων, δεν εκπαιδεύει το ίδιο καλά το FCM, δεδομένου ότι τα βάρη τείνουν να μηδενιστούν.

Συνεπώς, φαίνεται πως τα FCM μπορούν να μοντελοποιήσουν ένα βασικό σύστημα off-loading σε ικανοποιητικό βαθμό, με προτιμώμενη χρήση για την εκπαίδευση του γράφου του αλγορίθμου εκμάθησης AHL με τις κατάλληλες παραμέτρους μάθησης.

5.2 Μελλοντική Εργασία

Το έργο της παρούσας διπλωματικής εργασίας μπορεί να επεκταθεί και στις εξής ακόλουθες ενδεικτικές, αλλά συγκεκριμένες, κατευθύνσεις:

- Την περαιτέρω διερεύνηση των βέλτιστων τιμών των παραμέτρων μάθησης, η, γ , στους

αλγορίθμους AHL, NHL ανάλογα και με το σύστημα το οποίο μοντελοποιείται.

- Την υλοποίηση ενός γράφου FCM που να περιλαμβάνει στις έννοιες-κόμβους του περισσότερες από τις βασικές παραμέτρους του offloading, οι οποίες περιγράφονται και στο Κεφάλαιο 2, όπως είναι το interference μεταξύ των συσκευών που στέλνουν τα αιτήματα και του edge εξυπηρετητή.
- Την επέκταση της μοντελοποίησης σε σύστημα που περιλαμβάνει πάνω από έναν edge εξυπηρετητή που διαχειρίζεται το offloading. Με αυτόν τον τρόπο, θα μπορέσει να γίνει μια πιο ρεαλιστική αναπαράσταση του συστήματος μεταφόρτωσης διεργασιών, πέρα από την βασική μοντελοποίηση που παρουσιάστηκε.
- Την δοκιμή επιπλέον αλγορίθμων εκμάθησης με βάση τις απαιτήσεις του συστήματος που μοντελοποιείται. Δεδομένου ότι τα FCM είναι μια τεχνική μοντελοποίησης που διαδίδεται ολοένα και περισσότερο σε διάφορους τομείς, έχουν αναπτυχθεί και υλοποιηθεί αρκετοί αλγόριθμοι εκμάθησης πάνω σε αυτά. Η επιλογή τους έγκειται τόσο στο σύστημα που μοντελοποιείται, όσο και στο είδος των παραμέτρων που θα δεχθούν για εκπαίδευση και για αυτό το λόγο είναι ενδιαφέρουσα η διερεύνηση του βέλτιστου αλγορίθμου για το εκάστοτε σύστημα.

Γλωσσάριο

Ελληνικός όρος

Χάρτης Ασαφούς Λογικής
καθυστέρηση
μεταφόρτωση διεργασιών
παρεμβολή
τιμή ενεργοποίησης
συνάρτηση κατωφλίου
σιγμοειδής συνάρτηση
κανονικοποίηση
αποκανονικοποίηση
Έννοιες Απόφασης Ενεργοποίησης
ενεργοποιημένη έννοια
έννοια ενεργοποίησης
σειρά εννοιών ενεργοποίησης
Επιθυμητές Έννοιες Εξόδου

Αγγλικός όρος

Fuzzy Cognitive Map (FCM)
latency
computational offloading
interference
activation value
threshold function
sigmoid function
normalisation
denormalisation
Activation Decision Concepts (ADCs)
Activated concept
Activation concept
sequence of activation concepts
Desired Output Concepts (DOCs)

Βιβλιογραφία

- [1] A. S. Andreou, N. H. Mateou, and G. A. Zombanakis. The cyprus puzzle and the greek-turkish arms race: Forecasting developments using genetically evolved fuzzy cognitive maps. *Defence and Peace Economics*, 14(4):293–310, 2003.
- [2] M. Avgeris. *Dynamic Resource Allocation and Computational Offloading at the Network Edge for Internet of Things Applications*. PhD thesis, 2021.
- [3] M. Avgeris, D. Spatharakis, D. Dechouniotis, N. Kalatzis, I. Roussaki, and S. Papavassiliou. Where there is fire there is smoke: a scalable edge computing framework for early fire detection. *Sensors*, 19(3):639, 2019.
- [4] R. Axelrod. The structure of decision: Cognitive maps of political elites-princeton. univ. 1976.
- [5] S. Bueno and J. L. Salmeron. Fuzzy modeling enterprise resource planning tool selection. *Computer Standards & Interfaces*, 30(3):137–147, 2008.
- [6] Y. Cai, C. Miao, A.-H. Tan, Z. Shen, and B. Li. Creating an immersive game world with evolutionary fuzzy cognitive maps. *IEEE computer graphics and applications*, 30(2):58–70, 2009.
- [7] J. P. Carvalho. On the semantics and the use of fuzzy cognitive maps in social sciences. In *International Conference on Fuzzy Systems*, pages 1–6. IEEE, 2010.
- [8] Z. Chunying, L. Lu, O. Dong, and L. Ruitao. Research of rough cognitive map model. In *International Conference on Electronic Commerce, Web Application, and Communication*, pages 224–229. Springer, 2011.
- [9] U. Drolia, K. Guo, and P. Narasimhan. Precog: Prefetching for image recognition applications at the edge. In *Proceedings of the Second ACM/IEEE Symposium on Edge Computing*. Association for Computing Machinery, 2017.
- [10] G. Felix, G. Nápoles, R. Falcon, W. Froelich, K. Vanhoof, and R. Bello. A review on methods and software for fuzzy cognitive maps. *Artificial intelligence review*, 52(3):1707–1737, 2019.
- [11] M. H. Hassoun et al. *Fundamentals of artificial neural networks*. MIT press, 1995.

- [12] X. He, J. Liu, R. Jin, and H. Dai. Privacy-aware offloading in mobile-edge computing. In *GLOBECOM 2017 - 2017 IEEE Global Communications Conference*, pages 1–6, 2017.
- [13] D. O. Hebb. The first stage of perception: growth of the assembly. *The Organization of Behavior*, 4:60–78, 1949.
- [14] D. H. Ho and T. Aaron Gulliver. Prioritized cell association and power control in uplink heterogeneous networks. *IEEE Access*, 8:1209–1223, 2020.
- [15] A. Jonathan, A. Chandra, and J. Weissman. Locality-aware load sharing in mobile cloud computing. In *Proceedings of The 10th International Conference on Utility and Cloud Computing*, page 141–150. Association for Computing Machinery, 2017.
- [16] B. Kosko. Fuzzy cognitive maps. *International Journal of Man-Machine Studies*, 24(1):65–75, 1986.
- [17] T. L. Kottas, A. D. Karlis, and Y. S. Boutalis. Fuzzy cognitive networks for maximum power point tracking in photovoltaic arrays. In *Fuzzy Cognitive Maps*, pages 231–257. Springer, 2010.
- [18] G. Lee, W. Saad, and M. Bennis. An online secretary framework for fog network formation with minimal latency. In *2017 IEEE International Conference on Communications (ICC)*, pages 1–6, 2017.
- [19] X. Li, H. Ji, R. Zheng, Y. Li, and F. R. Yu. A novel team-centric peer selection scheme for distributed wireless p2p networks. In *2009 IEEE Wireless Communications and Networking Conference*, pages 1–5. IEEE, 2009.
- [20] Y. Li, Y. Chen, T. Lan, and G. Venkataramani. Mobiqor: Pushing the envelope of mobile edge computing via quality-of-result optimization. In *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*, pages 1261–1270, 2017.
- [21] C. lo Storto. Assessing ambiguity tolerance in staffing software development teams by analyzing cognitive maps of engineers and technical managers. In *2010 Second International Conference on Engineering System Management and Applications*, pages 1–6. IEEE, 2010.
- [22] W. Lu, J. Yang, and X. Liu. The hybrids algorithm based on fuzzy cognitive map for fuzzy time series prediction. *Journal of Information & Computational Science*, 11(2):357–366, 2014.
- [23] X. Luo, X. Wei, and J. Zhang. Game-based learning model using fuzzy cognitive map. In *Proceedings of the First ACM International Workshop on Multimedia Technologies for Distance Learning*, page 67–76. Association for Computing Machinery, 2009.

- [24] E. Oja. Learning in non-linear constrained hebbian networks. *Proceedings of the ICANN'91, 1991*, pages 385–390, 1991.
- [25] E. Papageorgiou, A. Markinos, and T. Gemtos. Soft computing technique of fuzzy cognitive maps to connect yield defining parameters with yield in cotton crop production in central greece as a basis for a decision support system for precision agriculture application. In *Fuzzy cognitive maps*, pages 325–362. Springer, 2010.
- [26] E. Papageorgiou and J. Salmeron. A review of fuzzy cognitive map research at the last decade. *IEEE Transactions on Fuzzy Systems*, 01 2013.
- [27] E. Papageorgiou, C. Stylios, and P. Groumpos. Fuzzy cognitive map learning based on nonlinear hebbian rule. In *Australasian joint conference on artificial intelligence*, pages 256–268. Springer, 2003.
- [28] E. Papageorgiou, C. Stylios, and P. Groumpos. The soft computing technique of fuzzy cognitive maps for decision making in radiotherapy. In *Intelligent and adaptive systems in medicine*, pages 191–230. CRC Press, 2008.
- [29] E. Papageorgiou, C. D. Stylios, and P. P. Groumpos. Active hebbian learning algorithm to train fuzzy cognitive maps. *International journal of approximate reasoning*, 37(3):219–249, 2004.
- [30] E. I. Papageorgiou and P. P. Groumpos. A weight adaptation method for fuzzy cognitive map learning. *Soft Computing*, 9(11):846–857, 2005.
- [31] E. I. Papageorgiou and J. L. Salmeron. Methods and algorithms for fuzzy cognitive map-based modeling. In *Fuzzy cognitive maps for applied sciences and engineering*, pages 1–28. Springer, 2014.
- [32] E. I. Papageorgiou, C. Stylios, and P. P. Groumpos. Unsupervised learning techniques for fine-tuning fuzzy cognitive map causal links. *International Journal of Human-Computer Studies*, 64(8):727–743, 2006.
- [33] T. Rajaram and A. Das. Modeling of interactions among sustainability components of an agro-ecosystem using local knowledge through cognitive mapping and fuzzy inference system. *Expert Systems with Applications*, 37(2):1734–1744, 2010.
- [34] V. Rodin, G. Querrec, P. Ballet, F.-R. Bataille, G. Desmeulles, J.-F. Abgrall, and J. Tisseau. Multi-agents system to model cell signalling by using fuzzy cognitive maps. application to computer simulation of multiple myeloma. In *2009 Ninth IEEE International Conference on Bioinformatics and BioEngineering*, pages 236–241. IEEE, 2009.
- [35] L. Rodriguez-Repiso, R. Setchi, and J. L. Salmeron. Modelling it projects success with fuzzy cognitive maps. *Expert Systems with Applications*, 32(2):543–559, 2007.

- [36] F. Saeik, M. Avgeris, D. Spatharakis, N. Santi, D. Dechouniotis, J. Violos, A. Leivadreas, N. Athanasopoulos, N. Mitton, and S. Papavassiliou. Task offloading in edge and cloud computing: A survey on mathematical, artificial intelligence and control theory solutions. *Computer Networks*, 195:108177, 2021.
- [37] D. Spatharakis, M. Avgeris, N. Athanasopoulos, D. Dechouniotis, and S. Papavassiliou. A switching offloading mechanism for path planning and localization in robotic applications. In *2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData) and IEEE Congress on Cybermatics (Cybermatics)*, pages 77–84. IEEE, 2020.
- [38] C. D. Stylios and P. P. Groumpos. Modeling complex systems using fuzzy cognitive maps. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 34(1):155–162, 2004.
- [39] L. Tang and S. He. Multi-user computation offloading in mobile edge computing: A behavioral perspective. *IEEE Network*, 32(1):48–53, 2018.
- [40] G. Xirogiannis, M. Glykas, and C. Staikouras. Fuzzy cognitive maps in banking business process performance measurement. In *Fuzzy cognitive maps*, pages 161–200. Springer, 2010.
- [41] D. Yaman and S. Polat. A fuzzy cognitive map approach for effect-based operations: An illustrative case. *Information Sciences*, 179(4):382–403, 2009.
- [42] C. Yoon, D. Kim, W. Jung, C. Kang, and H. Cha. Appscope: Application energy metering framework for android smartphone using kernel activity monitoring. In *2012 USENIX Annual Technical Conference (USENIX ATC 12)*, pages 387–400. USENIX Association, 2012.
- [43] A. Yousefpour, C. Fung, T. Nguyen, K. Kadiyala, F. Jalali, A. Niakanlahiji, J. Kong, and J. P. Jue. All one needs to know about fog computing and related edge computing paradigms: A complete survey. *Journal of Systems Architecture*, 98:289–330, 2019.