



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Εφαρμογές μετα-ευρετικών αλγορίθμων σε θέματα
βελτιστοποίησης ευφύων δικτύων ηλεκτρικής ενέργειας**

Μεταπτυχιακή Διπλωματική Εργασία

Κεχαγιάς Χρήστος-Αλέξανδρος

Επιβλέπων: Παναπακίδης Ιωάννης

Φεβρουάριος 2022



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ


**Εφαρμογές μετα-ευρετικών αλγορίθμων σε θέματα
βελτιστοποίησης ευφύων δικτύων ηλεκτρικής ενέργειας**

Μεταπτυχιακή Διπλωματική Εργασία

Κεχαγιάς Χρήστος-Αλέξανδρος

Επιβλέπων: Παναπακίδης Ιωάννης

Φεβρουάριος 2022



UNIVERSITY OF THESSALY

SCHOOL OF ENGINEERING

DEPARTMENT OF ELECTRICAL AND COMPUTER ENGINEERING

**Applications of meta-heuristics algorithms in smart grids
optimization issues**

MSc Thesis

Kechagias Christos-Alexandros

Supervisor: Panapakidis Ioannis

February 2022

Εγκρίνεται από την Επιτροπή Εξέτασης:

Επιβλέπων

Παναπακίδης Ιωάννης

Επίκουρος Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

Μπαργιώτας Δημήτριος

Αναπληρωτής Καθηγητής, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

Μέλος

Δασκαλοπούλου Ασπασία

Επίκουρος Καθηγήτρια, Τμήμα Ηλεκτρολόγων Μηχανικών και
Μηχανικών Υπολογιστών, Πανεπιστήμιο Θεσσαλίας

**ΥΠΕΥΘΥΝΗ ΔΗΛΩΣΗ ΠΕΡΙ ΑΚΑΔΗΜΑΪΚΗΣ ΔΕΟΝΤΟΛΟΓΙΑΣ ΚΑΙ ΠΝΕΥΜΑΤΙΚΩΝ
ΔΙΚΑΙΩΜΑΤΩΝ**

Με πλήρη επίγνωση των συνεπειών του νόμου περί πνευματικών δικαιωμάτων, δηλώνω ρητά ότι η παρούσα μεταπτυχιακή διπλωματική εργασία, καθώς και τα ηλεκτρονικά αρχεία και πηγαίοι κώδικες που αναπτύχθηκαν ή τροποποιήθηκαν στα πλαίσια αυτής της εργασίας, αποτελούν αποκλειστικά προϊόν προσωπικής μου εργασίας, δεν προσβάλλουν οποιασδήποτε μορφής δικαιώματα διανοητικής ιδιοκτησίας, προσωπικότητας και προσωπικών δεδομένων τρίτων, δεν περιέχουν έργα/εισφορές τρίτων για τα οποία απαιτείται άδεια των δημιουργών/δικαιούχων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον και πληρούν τους κανόνες της επιστημονικής παράθεσης. Τα σημεία όπου έχω χρησιμοποιήσει ιδέες, κείμενο, αρχεία ή/και πηγές άλλων συγγραφέων αναφέρονται ευδιάκριτα στο κείμενο με την κατάλληλη παραπομπή και η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με πλήρη περιγραφή. Δηλώνω επίσης ότι τα αποτελέσματα της εργασίας δεν έχουν χρησιμοποιηθεί για την απόκτηση άλλου πτυχίου. Αναλαμβάνω πλήρως, ατομικά και προσωπικά, όλες τις νομικές και διοικητικές συνέπειες που δύναται να προκύψουν στην περίπτωση κατά την οποία αποδειχθεί, διαχρονικά, ότι η εργασία αυτή ή τμήμα της δεν μου ανήκει διότι είναι προϊόν λογοκλοπής.

Ο Δηλών

Κεχαγιάς Χρήστος-Αλέξανδρος

DISCLAIMER ON ACADEMIC ETHICS AND INTELLECTUAL PROPERTY RIGHTS

Being fully aware of the implications of copyright laws, I expressly state that this MSc thesis, as well as the electronic files and source codes developed or modified in the course of this thesis, are solely the product of my personal work and do not infringe any rights of intellectual property, personality and personal data of third parties, do not contain work / contributions of third parties for which the permission of the authors / beneficiaries is required and are not a product of partial or complete plagiarism, while the sources used are limited to the bibliographic references only and meet the rules of scientific citing. The points where I have used ideas, text, files and / or sources of other authors are clearly mentioned in the text with the appropriate citation and the relevant complete reference is included in the bibliographic references section. I also declare that the results of the work have not been used to obtain another degree. I fully, individually and personally undertake all legal and administrative consequences that may arise in the event that it is proven, in the course of time, that this thesis or part of it does not belong to me because it is a product of plagiarism.

The Declarant

Kechagias Christos-Alexandros

Ευχαριστίες

Σε αυτό το σημείο, θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου κύριο Παναπακίδη Ιωάννη για τη βοήθεια και την καθοδήγησή του, στοιχεία αναγκαία για την εκπόνηση της πτυχιακής μου εργασίας. Επίσης, θα ήθελα να ευχαριστήσω τον κ. Μπαργιώτα Δημήτριο και την κ. Δασκαλοπούλου Ασπασία για την συμμετοχή τους στην Επιτροπή Εξέτασης.

Ευχαριστώ τα αδέρφια μου και τους φίλους μου για τη στήριξή τους, την βοήθεια και τις τόσο πολύτιμες συμβουλές τους κατά τη διάρκεια συγγραφής της εν λόγω εργασίας.

Τέλος, όλα αυτά δεν θα ήταν δυνατά χωρίς την καταλυτική στήριξη και παρακίνηση των γονέων μου, Κωνσταντίνου και Ευδοκίας, σε δύσκολες προσωπικές στιγμές, στους οποίους και οφείλω τη συνέχιση των σπουδών μου και την αίσια έκβασή τους, στους οποίους και αφιερώνω την παρούσα εργασία.

Εφαρμογές μετα-ευρετικών αλγορίθμων σε θέματα βελτιστοποίησης ευφύων δικτύων ηλεκτρικής ενέργειας

Κεχαγιάς Χρήστος-Αλέξανδρος

Περίληψη

Οι μετα-ευρετικοί αλγόριθμοι έχουν εφαρμογές σε πολλούς τομείς της ανάλυσης δεδομένων και εύρεσης της βέλτιστης λύσης για διάφορα προβλήματα. Η παρούσα διπλωματική εργασία αποτελείται από 3 επιμέρους κεφάλαια. Αρχικά θα γίνει μία αναφορά στις εφαρμογές των μετα-ευρετικών αλγορίθμων σε διάφορους τομείς επιστημών. Στη συνέχεια θα αναλυθεί η συσταδοποίηση μέσω των αλγορίθμων k-means, k-medoids, FCM, SOM, WARD και μέσω υβριδικών αλγορίθμων οι οποίοι συνδυάζουν κάποιους από τους προαναφερθέντες και η σύγκριση των αποτελεσμάτων τους. Έπειτα μέσω των μετα-ευρετικών αλγορίθμων θα γίνει η εύρεση της κατάλληλης επιλογής αριθμού εισόδων σε έναν αλγόριθμο έτσι ώστε να βγάλει το βέλτιστο αποτέλεσμα.

Λέξεις-κλειδιά:

Μετα-ευρετικοί αλγόριθμοι, συσταδοποίηση, βελτιστοποίηση, καμπύλες φορτίου, πρόβλεψη φορτίου, τεχνητά νευρωνικά δίκτυα

MSc Thesis

Applications of meta-heuristics algorithms in smart grids optimization issues

Kechagias Christos-Alexandros

Abstract

Meta-heuristic algorithms have applications in many areas of data analysis and finding the best solution for various problems. This diploma thesis consists of 3 individual chapters. Firstly a reference will be made to the applications of meta-heuristic algorithms in various fields of science. Next, the clustering through the k-means, FCM, SOM, WARD algorithms and through hybrid algorithms that combine some of the above and the comparison of their results will be analyzed. Then through the meta-heuristic algorithms will be found the appropriate number of inputs selection in an algorithm so as to get the optimal result.

Keywords:

Meta-heuristic algorithms; clustering; optimization; load profiles; load forecasting;
Artificial Neural Networks

Πίνακας περιεχομένων

<i>Ευχαριστίες</i>	<i>xiii</i>
<i>Περίληψη</i>	<i>xv</i>
<i>Abstract</i>	<i>xvii</i>
<i>Πίνακας περιεχομένων</i>	<i>xix</i>
<i>Κατάλογος σχημάτων</i>	<i>xxi</i>
<i>Κατάλογος πινάκων</i>	<i>xxiv</i>
<i>Συνομογραφίες</i>	<i>xxvi</i>
Κεφάλαιο 1 Εισαγωγή	1
1.1 Αντικείμενο της διπλωματικής	1
1.1.1 Συνεισφορά.....	1
1.2 Οργάνωση του τόμου	2
Κεφάλαιο 2 Ανασκόπηση Εφαρμογών μετα-ευρετικών Αλγορίθμων	3
2.1 Εισαγωγή	3
2.2 Ανασκόπηση Εφαρμογών Μετα-ευρετικών Αλγορίθμων	4
2.2.1 Συσταδοποίηση.....	4
2.2.2 Εύρεση αριθμού εισόδων για την πρόβλεψη φορτίου	5
2.2.3 Εκτίμηση Παραμέτρων Επαγωγικών Κινητήρων	5
2.2.4 Συντονισμός μη συμβατικών ηλεκτρονόμων υπερέντασης	10
2.2.5 Οι εφαρμογές του αλγορίθμου Crow Search Algorithm σε προβλήματα συστήματος ισχύος....	14
2.2.6 Αναδιαμόρφωση δικτύου διανομής.....	18
2.2.7 Οικονομική Κατανομή Συνδυασμένης Θερμότητας και Ισχύος	21
2.2.8 Οικονομική Κατανομή Συστημάτων Πολλαπλών Ψυκτικών Σταθμών	25
2.2.9 Προσέγγιση Μακροπρόθεσμης Πρόβλεψης Φορτίου	27
2.2.10 Ροή Ισχύος σε Συστήματα Διανομής	32
Κεφάλαιο 3 Εφαρμογή μετα-ευρετικών αλγορίθμων στην συσταδοποίηση καμπυλών ηλεκτρικής ενέργειας	34
3.1 Εισαγωγή	34
3.1.1 Συσταδοποίηση με τη χρήση του αλγορίθμου K-means	36
3.1.2 Συσταδοποίηση με τη χρήση του αλγορίθμου K-medoids	38
3.1.3 Συσταδοποίηση με τη χρήση του αλγορίθμου Fuzzy c-means.....	39
3.1.4 Συσταδοποίηση με τη χρήση του αλγορίθμου Self-Organizing Map	41
3.1.5 Συσταδοποίηση με τη χρήση του προτεινόμενου αλγορίθμου CL-DE	44
3.2 Δείκτες αξιολόγησης συσταδοποίησης	49
3.3 Αποτελέσματα	50

Κεφάλαιο 4 Χρήση τεχνητών νευρωνικών δικτύων για την κατάλληλη επιλογή εισόδων	58
.....	
4.1 Εισαγωγή.....	58
4.2 Περιγραφή Αλγορίθμων Βέλτιστης Επιλογής Εισόδων	59
4.2.1 Χρήση του αλγορίθμου PSO για την επιλογή εισόδων.....	59
4.2.2 Χρήση του αλγορίθμου ACO για την επιλογή εισόδων	61
4.2.3 Χρήση του αλγορίθμου SA για την επιλογή εισόδων	63
4.2.4 Χρήση του Feed Forward Neural Network για την βέλτιστη επιλογή εισόδων.....	64
4.2.5 Χρήση του Elman Neural Network για την βέλτιστη επιλογή εισόδων	65
4.2.6 Χρήση του Extreme Machine Learning για την βέλτιστη επιλογή εισόδων	67
4.2.7 Χρήση του Generalized Regression Neural Network για τη βέλτιστη επιλογή εισόδων	68
4.3 Μεθοδολογία Βέλτιστης Επιλογής Εισόδου	70
4.4 Σχολιασμός αποτελεσμάτων	73
Κεφάλαιο 5 Συμπεράσματα.....	92
5.1 Σύνοψη και συμπεράσματα	92
5.2 Μελλοντικές επεκτάσεις	92
Βιβλιογραφία.....	93

Κατάλογος σχημάτων

Σχήμα 2.1: Το απλοποιημένο ισοδύναμο κυκλώμα του επαγωγικού κινητήρα	6
Σχήμα 2.2: Το πλήρες ισοδύναμο κύκλωμα του επαγωγικού κινητήρα	8
Σχήμα 2.3: Διάγραμμα Ροής του αλγορίθμου GSA.....	8
Σχήμα 2.4: Διάγραμμα ροής του βελτιωμένου αλγορίθμου CSA.....	17
Σχήμα 2.5: Διάγραμμα ροής του αλγορίθμου PSO για το πρόβλημα της οικονομικής κατανομής για συστήματα συνδυασμένης θερμότητας και ισχύος.....	24
Σχήμα 2.6: Διαδικασία πρόβλεψης φορτίου σε μακροπρόθεσμο ορίζοντα	28
Σχήμα 2.7: Σχηματική αναπαράσταση τεχνητού νευρωνικού δικτύου	28
Σχήμα 2.8: Διάγραμμα ροής του προτεινόμενου αλγορίθμου για την πρόβλεψη φορτίου	30
Σχήμα 2.9: Σύστημα διανομής δειγμάτων για την προσέγγιση της σάρωσης προς τα εμπρός και προς τα πίσω της ροής ισχύος.....	32
Σχήμα 3.1: Διάγραμμα ροής του αλγορίθμου k-means.....	37
Σχήμα 3.2: Διάγραμμα ροής του αλγορίθμου K-medoids	39
Σχήμα 3.3: Διάγραμμα ροής του αλγορίθμου FCM	40
Σχήμα 3.4: Διάγραμμα ροής του αλγορίθμου SOM.....	43
Σχήμα 3.5: Διάγραμμα Ροής της διαδικασίας διαμόρφωσης καμπυλών ηλεκτρικού φορτίου	45
Σχήμα 3.6: Διάγραμμα ροής του υβριδικού αλγορίθμου CL-DE	48
Σχήμα 3.7: Χρονοσειρές φορτίου του υπό μελέτη μετασχηματιστή διανομής	51
Σχήμα 3.8: Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη CDI σε σχέση με τον αριθμό των συστάδων	52
Σχήμα 3.9: Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη SI σε σχέση με τον αριθμό των συστάδων	52
Σχήμα 3.10: Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη SMI σε σχέση με τον αριθμό των συστάδων	53
Σχήμα 3.11: Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη DBI σε σχέση με τον αριθμό των συστάδων	53
Σχήμα 3.12: Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση CDI και PI	54
Σχήμα 3.13: Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση SI και PI	55
Σχήμα 3.14: Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση SMI και PI	55
Σχήμα 3.15: Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση DBI και PI	55
Σχήμα 3.16: Προφίλ φορτίου του υπό μελέτη μετασχηματιστή διανομής	56
Σχήμα 4.1: Διάγραμμα ροής του αλγορίθμου PSO	59
Σχήμα 4.2: Σχηματική αναπαράσταση του αλγορίθμου ACO.....	62
Σχήμα 4.3: Διάγραμμα ροής του αλγορίθμου ACO	62
Σχήμα 4.4: Διάγραμμα ροής του αλγορίθμου SA	63
Σχήμα 4.5: Σχηματική αναπαράσταση του FFNN.....	64
Σχήμα 4.6: Σχηματική αναπαράσταση του ENN	66
Σχήμα 4.7: Διάγραμμα ροής του Elman Neural Network	66

Σχήμα 4.8: Σχηματική αναπαράσταση ενός 3-στρωματικού νευρωνικού δικτύου ELM....	67
Σχήμα 4.9: Σχηματική αναπαράσταση του GRNN.....	69
Σχήμα 4.10: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 01/01/2011.....	82
Σχήμα 4.11: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/01/2011.....	83
Σχήμα 4.12: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/02/2011.....	83
Σχήμα 4.13: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/03/2011.....	84
Σχήμα 4.14: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 25/03/2011.....	84
Σχήμα 4.15: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/04/2011.....	85
Σχήμα 4.16: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/05/2011.....	85
Σχήμα 4.17: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/06/2011.....	86
Σχήμα 4.18: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/07/2011.....	86
Σχήμα 4.19: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/08/2011.....	87
Σχήμα 4.20: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 15/08/2011.....	87
Σχήμα 4.21: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/09/2011.....	88
Σχήμα 4.22: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/10/2011.....	88
Σχήμα 4.23: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 28/10/2011.....	89
Σχήμα 4.24: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/11/2011.....	89
Σχήμα 4.25: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/12/2011.....	90
Σχήμα 4.26: Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 25/12/2011.....	90
Σχήμα 4.27: Μεταβολή του σφάλματος MAPE του κάθε νευρωνικού δικτύου με την ημέρα	91

Κατάλογος πινάκων

Πίνακας 3.1: Κατανομή τύπου ημέρας ανά συστάδα.....	56
Πίνακας 4.1: Αποτελέσματα εφαρμογής αλγορίθμου PSO	73
Πίνακας 4.2: Επιλογή εισόδων αλγορίθμου PSO.....	75
Πίνακας 4.3: Αποτελέσματα εφαρμογής αλγορίθμου SA.....	76
Πίνακας 4.4: Επιλογή εισόδων αλγορίθμου SA	78
Πίνακας 4.5: Αποτελέσματα εφαρμογής αλγορίθμου ACO.....	79
Πίνακας 4.6: Επιλογή εισόδων αλγορίθμου ACO	81

Συντομογραφίες

ACO	Ant Colony Optimization
AP	Awareness Probability
BGSO	Binary Group Search Optimization
CL	Complete Linkage
CSA	Crow Search Algorithm
CTI	Coordination Time Interval
DAP	Dynamic Awareness Probability
DE	Differential Evolution
DOCR	Directional Overcurrent Relays
FCL	Fault Current Limiter
FCM	Fuzzy c-means
GA	Genetic Algorithm
GSA	Gravity Search Algorithm
IWO	Invasive Weed Optimization
PSO	Particle Swarm Optimization
SA	Simulating Annealing
SOM	Self Organizing Map
WGA	Wild Goat Algorithm
GSA	Gravity Search Algorithm

Κεφάλαιο 1 Εισαγωγή

Στην παρούσα διπλωματική εργασία αρχικά γίνεται μία ανασκόπηση διάφορων εφαρμογών των μετα-ευρετικών αλγορίθμων σε θέμα που σχετίζονται με τον τομέα της ηλεκτρικής ενέργειας. Στην συνέχεια παρουσιάζεται ένας καινοτόμος αλγόριθμος συσταδοποίησης και εφαρμόζεται σε ένα πρόβλημα προφίλ φορτίου. Τέλος, γίνεται μία συγκριτική ανάλυση τριών μετα-ευρετικών αλγορίθμων στο πρόβλημα της βέλτιστης επιλογής εισόδων για νευρωνικό δίκτυο που χρησιμοποιείται στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου.

1.1 Αντικείμενο της διπλωματικής

Η παρούσα διπλωματική επικεντρώνεται στην λύση δύο προβλημάτων βελτιστοποίησης με την χρήση μετα-ευρετικών αλγορίθμων. Το πρώτο πρόβλημα είναι η συσταδοποίηση καμπυλών ηλεκτρικού φορτίου. Για την επίλυση του συγκεκριμένου προβλήματος έγινε συσταδοποίηση με χρήση γνωστών αλγορίθμων και την χρήση ενός νέου αλγορίθμου. Στην συνέχεια, από την συγκριτική ανάλυση των αποτελεσμάτων με την βοήθεια δεικτών αξιολόγησης εξάχθηκαν τα αποτελέσματα για την απόδοση των αλγορίθμων στην επίλυση του προβλήματος συσταδοποίησης καμπυλών ηλεκτρικού φορτίου. Το δεύτερο πρόβλημα είναι η βέλτιστη επιλογή εισόδων για νευρωνικό δίκτυο που χρησιμοποιείται στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Για την επίλυση του συγκεκριμένου προβλήματος γίνεται χρήση αλγορίθμων για την εύρεση της βέλτιστης επιλογής εισόδων και η χρήση αυτών των εισόδων για την πρόβλεψη ηλεκτρικού φορτίου και η σύγκριση της πρόβλεψης με την πραγματική τιμή.

1.1.1 Συνεισφορά

Στην παρούσα διπλωματική εργασία τέθηκαν τα παρακάτω ερευνητικά ερωτήματα:

1. Ποια είναι η απόδοση ενός μετα-ευρετικού αλγορίθμου σε σχέση με άλλους αλγορίθμους συσταδοποίησης στο πρόβλημα της συσταδοποίησης καμπυλών ηλεκτρικού φορτίου.

2. Πως διαμορφώνεται το πρόβλημα της βέλτιστης επιλογής εισόδων στο πρόβλημα της πρόβλεψης φορτίου μέσω της χρήσης μετα-ευρετικών αλγορίθμων.

Η μεθοδολογία της διπλωματικής εργασία απαντά στα προαναφερθέντα ερευνητικά ερωτήματα ως εξής:

1. Πραγματοποιείται συγκριτική ανάλυση μεταξύ αλγορίθμων συσταδοποίησης διαφορετικών κατηγοριών και λαμβάνοντας υπόψη 4 δείκτες αξιολόγησης συσταδοποίησης
2. Παρέχεται η μαθηματική διατύπωση της βέλτιστης επιλογής εισόδων. Επίσης γίνεται συγκριτική ανάλυση μεταξύ τριών μετα-ευρετικών αλγορίθμων.

1.2 Οργάνωση του τόμου

Στο Κεφάλαιο 2 γίνεται μία ανασκόπηση διάφορων εφαρμογών των μετα-ευρετικών αλγορίθμων σε θέμα που σχετίζονται με τον τομέα της ηλεκτρικής ενέργειας.

Στο Κεφάλαιο 3 γίνεται εφαρμογή ενός πλήθους αλγορίθμων όπως ο k-means, ο K-medoids, ο FCM και άλλοι σε πρόβλημα συσταδοποίησης καμπυλών φορτίου. Επιπλέον παρουσιάζεται ένας καινοτόμος αλγόριθμος για την επίλυση του προαναφερθέντος προβλήματος και γίνεται η σύγκριση των αποτελεσμάτων τους.

Στο Κεφάλαιο 4 γίνεται μία συγκριτική ανάλυση τριών μετα-ευρετικών αλγορίθμων (PSO, SA, ACO) στο πρόβλημα της βέλτιστης επιλογής εισόδων για νευρωνικό δίκτυο που χρησιμοποιείται στη βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου. Επίσης, οι είσοδοι που βρέθηκαν από τους αλγορίθμους εισάγονται σε τέσσερα διαφορετικά νευρωνικά δίκτυα και γίνεται μία σύγκριση των αποτελεσμάτων τους την βραχυπρόθεσμη πρόβλεψη ηλεκτρικού φορτίου.

Τέλος, στο Κεφάλαιο 5 παρουσιάζονται οι λόγοι για τους οποίους οι μετα-ευρετικοί αλγόριθμοι είναι ιδιαίτερα κατάλληλοι για την επίλυση προβλημάτων βελτιστοποίησης και ιδιαίτερα των προβλημάτων συσταδοποίησης και βέλτιστης επιλογής εισόδων. Τέλος γίνεται μία πρόταση περαιτέρω χρήση των μετα-ευρετικών αλγορίθμων στο μέλλον.

Κεφάλαιο 2 Ανασκόπηση Εφαρμογών μετα-ευρετικών

Αλγορίθμων

2.1 Εισαγωγή

Οι μετα-ευρετικοί αλγόριθμοι, δηλαδή οι μέθοδοι βελτιστοποίησης που έχουν σχεδιαστεί σύμφωνα με τις στρατηγικές που ορίζονται σε ένα μετα-ευρετικό πλαίσιο, και έχουν πάντα ευρετικό χαρακτήρα. Αυτό το γεγονός τις διακρίνει από τις ακριβείς μεθόδους οι οποίες βρίσκουν τη βέλτιστη λύση σε πεπερασμένο χρονικό διάστημα. Επομένως, οι μετα-ευρετικοί αναπτύσσονται ειδικά για να βρουν μια λύση που είναι «αρκετά καλή» σε έναν υπολογιστικό χρόνο που είναι «αρκετά μικρός». Ειδικά για περίπλοκα προβλήματα ή μεγάλες περιπτώσεις προβλημάτων, οι μετα-ευρετικοί είναι συχνά σε θέση να προσφέρουν καλύτερη αντιστάθμιση μεταξύ της ποιότητας της λύσης και του χρόνου υπολογισμού. Επιπλέον, οι μετα-ευρετικοί είναι πιο ευέλικτοι από τις ακριβείς μεθόδους με δύο σημαντικούς τρόπους. Πρώτον, επειδή τα μετα-ευρετικά πλαίσια ορίζονται με γενικούς όρους, οι μετα-ευρετικοί αλγόριθμοι μπορούν να προσαρμοστούν, για να ταιριάζουν στις ανάγκες των περισσότερων προβλημάτων βελτιστοποίησης της πραγματικής ζωής όσον αφορά την αναμενόμενη ποιότητα λύσης και τον επιτρεπόμενο χρόνο υπολογισμού, ο οποίος μπορεί να ποικίλλει σημαντικά μεταξύ διαφορετικών προβλημάτων και διαφορετικών καταστάσεων. Δεύτερον, οι μετα-ευρετικοί αλγόριθμοι δε θέτουν απαιτήσεις στη διατύπωση του προβλήματος βελτιστοποίησης.[1]

Οι μετα-ευρετικοί αλγόριθμοι έχουν πολλές χρήσιμες εφαρμογές σε θέματα βελτιστοποίησης ευφών δικτύων ηλεκτρικής ενέργειας. Τα αναφερόμενα θέματα είναι η συσταδοποίηση, η εύρεση του κατάλληλου αριθμού εισόδων για την καλύτερη δυνατή πρόβλεψη φορτίου, η εξακρίβωση βέλτιστων παραμέτρων επαγωγικών κινητήρων, το πρόβλημα του συντονισμού σε ηλεκτρονόμους υπερέντασης στο οποίο η σύγκριση των αποτελεσμάτων του προβλήματος γίνεται με χρήση μετα-ευρετικών αλγορίθμων και η λήψη της βέλτιστης διαμόρφωσης των περιοριστών βλαβών ρεύματος σε ένα δίκτυο διανομής.

Αναλυτικότερα, τα ευφυή δίκτυα ηλεκτρικής ενέργειας για να λειτουργήσουν σύμφωνα με τις προδιαγραφές τους, απαιτούν την χρήση πολλών έξυπνων μετρητών πραγματικού.

Οι μετρητές αυτοί μπορούν να είναι μετρητές έντασης ρεύματος, τάσης και άλλοι. Για τη συλλογή, αποθήκευση και επεξεργασία των δεδομένων των μετρητών απαιτείται μεγάλη υπολογιστική ισχύς. Όμως πολλές φορές δεν υπάρχει διαθέσιμη τόση υπολογιστική ισχύς, οπότε η χρήση της συσταδοποίησης είναι ο πιο εφικτός τρόπος για την μείωση του όγκου των δεδομένων των μετρητών και την επακόλουθή τους αποθήκευση, επεξεργασία και ανάλυση. Για τη συσταδοποίηση έχουν προταθεί κάποιοι αλγόριθμοι, αλλά επειδή ο διαφορετικός τρόπος επεξεργασίας των δεδομένων των διαφορετικών αλγόριθμων οδηγεί σε διαφορετική συσταδοποίηση, η έρευνα με τη χρήση αλγορίθμων απλών ή υβριδικών είναι πιθανόν να οδηγήσει σε αποτελέσματα καλύτερα από τα ήδη υπάρχοντα.

2.2 Ανασκόπηση Εφαρμογών Μετα-ευρετικών Αλγορίθμων

2.2.1 Συσταδοποίηση

Ένας συνηθισμένος αλγόριθμος για τη συσταδοποίηση είναι ο αλγόριθμος Particle Swarm Optimization (PSO). Για την αναζήτηση ενός προβληματικού τομέα, οι αλγόριθμοι νοημοσύνης σμήνους όπως ο αλγόριθμος Particle Swarm Optimization επεξεργάζεται έναν πληθυσμό ατόμων. Κάθε άτομο αντιπροσωπεύει μία πιθανή λύση του προβλήματος βελτιστοποίησης. Η συνεργασία των σωματιδίων τείνει να οδηγεί τον πληθυσμό των ατόμων σε καλύτερες λύσεις. Η χρήση μίας αντικειμενικής συνάρτησης και η ελαχιστοποίηση ή η μεγιστοποίησή της δίνουν την καλύτερη λύση. Αυτό το χαρακτηριστικό είναι χρήσιμο για την εύρεση πολλαπλών λύσεων σε μη-γραμμικά, μη-ομογενή δεδομένα, επειδή οι τεχνικές αυτές μπορούν να χρησιμοποιηθούν σε κατανεμημένη ή παράλληλη αρχιτεκτονική υπολογισμού η οποία μπορεί να χειριστεί και να επεξεργαστεί μεγάλο όγκο δεδομένων. Εκτός από τον αλγόριθμο PSO, άλλοι μετα-ευρετικοί αλγόριθμοι οι οποίοι έχουν χρησιμοποιηθεί σε θέματα βελτιστοποίησης και ειδικότερα σε συσταδοποίηση είναι ο k-means, ο fuzzy c-means (FCM), ο Self-Organizing Map (SOM) και άλλοι. Συνδυασμός 2 διαφορετικών αλγορίθμων είναι δυνατόν να πετύχει καλύτερα αποτελέσματα, επειδή αντί για μία αντικειμενική συνάρτηση χρησιμοποιεί 2. Αυτό ακριβώς αναλύεται διεξοδικά στο κεφάλαιο 2 της παρούσας διπλωματικής. [2],[3]

2.2.2 Εύρεση αριθμού εισόδων για την πρόβλεψη φορτίου

Η εύρεση του κατάλληλου αριθμού εισόδων για την πρόβλεψη φορτίου είναι ένα πρόβλημα δυσεπίλυτο, επειδή η κατανάλωση αλλάζει συνεχώς. Επιπλέον με την αύξηση των έξυπνων μετρητών αυξάνεται πολύ ο όγκος των δεδομένων. Η χρήση τεχνητών νευρωνικών δικτύων κάνει τη διαδικασία της πρόβλεψης πιο εύκολη, όμως η χρήση μετα-ευρετικών αλγορίθμων βελτιστοποίησης όπως ο PSO, ο Simulating Annealing (SA), ο Ant Colony Optimization (ACO) και άλλοι είναι απαραίτητα για την εύρεση του αριθμού εισόδων του τεχνητού νευρωνικού δικτύου για τις οποίες η λύση είναι βέλτιστη σε κάποιο απαιτούμενο χρονικό διάστημα.[4],[5]

2.2.3 Εκτίμηση Παραμέτρων Επαγωγικών Κινητήρων

Οι επαγωγικοί κινητήρες ενώ έχουν αρκετά πλεονεκτήματα όπως χαμηλό κόστος αγοράς και επισκευής και εύκολο χειρισμό, λόγω της ευρείας χρήσης τους στην βιομηχανία, η συνολική τους κατανάλωση είναι αρκετά μεγάλη. Περίπου η μισή της συνολικής κατανάλωσης ηλεκτρικής ενέργειας γίνεται από τους συγκεκριμένους κινητήρες. Η απόδοση του κινητήρα εξαρτάται από τις εσωτερικές του παραμέτρους, η αναγνώριση και κατανόηση των οποίων είναι δύσκολη λόγω της μη-γραμμικότητας τους. Εάν οι εσωτερικές παράμετροι δεν είναι γνωστές, τότε η χρήση μετα-ευρετικών αλγορίθμων όπως ο PSO και ο Genetic Algorithm (GA) είναι ένας τρόπος να τις βρούμε. Όταν χρησιμοποιούνται μετα-ευρετικοί αλγόριθμοι, το πρόβλημα της εκτίμησης των εσωτερικών παραμέτρων των επαγωγικών κινητήρων λύνεται ως πρόβλημα βελτιστοποίησης με τις εσωτερικές παραμέτρους να είναι οι μεταβλητές απόφασης. Ένας επαγωγικός κινητήρας μπορεί να αναπαρασταθεί ως ισοδύναμο κύκλωμα σταθερής κατάστασης και αντιμετωπίζεται ως πρόβλημα βελτιστοποίησης τουλάχιστον τετραγώνου, το οποίο λόγω της φύσης του είναι εξαιρετικά μη γραμμικό καθίσταται δύσκολη η ελαχιστοποίησή του.

Το ζητούμενο αποτέλεσμα είναι το σφάλμα των υπολογισθέντων και των κατασκευαστικών δεδομένων να ελαχιστοποιηθεί με την προσαρμογή των παραμέτρων. Στο Σχήμα 2.1 φαίνεται το απλοποιημένο ισοδύναμο κύκλωμα του επαγωγικού κινητήρα. Η μαθηματική διατύπωση της συνάρτησης που τα συνδυάζει όλα αυτά είναι η ακόλουθη:

$$F = (f_1)^2 + (f_2)^2 + (f_3)^2$$

Όπου οι f_1 , f_2 και f_3 εξηγούνται από τις ακόλουθες σχέσεις:

$$f_1 = \frac{\frac{K_1 R_2}{s[(R_1 + R_2/s)^2 + X_1^2]} - T_{fl}(mf)}{T_{fl}(mf)}$$

$$f_2 = \frac{\frac{K_1 R_2}{s[(R_1 + R_2/s)^2 + X_1^2]} - T_{lr}(mf)}{T_{lr}(mf)}$$

$$f_3 = \frac{\frac{K_t}{2[R_1 + \sqrt{R_1^2 + X_1^2}]} - T_{\max}(mf)}{T_{\max}(mf)}$$


Το K_t δίνεται από την σχέση :

$$K_t = \frac{3V_{ph}^2}{\omega_s}$$

Επιπλέον για το X_i υπάρχει ο περιορισμός $X_{i,\min} \leq X_i \leq X_{i,\max}$ στον οποίο τα $X_{i,\min}$ και $X_{i,\max}$ είναι το κατώτερο και το ανώτερο όριο της παραμέτρου X_i

Η μέγιστη ροπή υπολογίζεται από τον τύπο:

$$\frac{T_{\max}(C) - T_{\max}(mf)}{T_{\max}(mf)} \leq \pm 0.2$$



Σχήμα 2.1. Το απλοποιημένο ισοδύναμο κύκλωμα του επαγωγικού κινητήρα

Χρησιμοποιώντας το ακριβές μοντέλο του κυκλώματος και ρυθμίζοντας την αντίσταση του στάτορα, την αντίσταση του ρότορα, την αντίσταση διαρροής αυτεπαγωγής του στάτορα, την αντίσταση διαρροής ρότορα και την αντίσταση διαρροής μαγνήτισης του ρότορα είναι δυνατόν να προσδιοριστεί η μέγιστη ροπή, η ροπή πλήρους φορτίου, η ροπή εκκίνησης και του συντελεστή ισχύος πλήρους φορτίου. Στο Σχήμα 2.2 φαίνεται το πλήρες ισοδύναμο

κύκλωμα του επαγωγικού κινητήρα. Η μαθηματική περιγραφή της αντικειμενικής συνάρτησης είναι η ακόλουθη:

$$F = (f_1)^2 + (f_2)^2 + (f_3)^2 + (f_4)^2$$

Όπου οι f_1 , f_2 , f_3 και f_4 εξηγούνται από τις ακόλουθες σχέσεις:

$$f_1 = \frac{\frac{K_t R_2}{s[(R_{th} + R_2/s)^2 + X^2]} - T_{fl}(mf)}{T_{fl}(mf)}$$

$$f_2 = \frac{\frac{K_t R_2}{(R_{th} + R_2)^2 + X^2} - T_{lr}(mf)}{T_{lr}(mf)}$$

$$f_3 = \frac{\frac{K_t}{2[R_{th} + \sqrt{R_{th}^2 + X^2}]} - T_{\max}(mf)}{T_{\max}(mf)}$$

$$f_4 = \frac{\cos\left(\tan^{-1}\left(\frac{X}{R_{th} + R_2/s}\right)\right) - p f_{fl}(mf)}{p f_{fl}(mf)}$$

$$V_{th} = \frac{V_{ph} X_m}{X_1 + X_m}$$

$$R_{th} = \frac{R_1 X_m}{X_1 + X_m}$$

$$X_{th} = \frac{X_1 X_m}{X_1 + X_m}$$

$$K_t = \frac{3V_{th}^2}{\omega_s}$$

$$X = X_{th} + X_2$$


Επιπλέον υπάρχουν οι περιορισμοί :

$$X_{i,\min} \leq X_i \leq X_{i,\max}$$

$$\frac{T_{\max}(C) - T_{\max}(mf)}{T_{\max}(mf)} \leq \pm 0.2$$

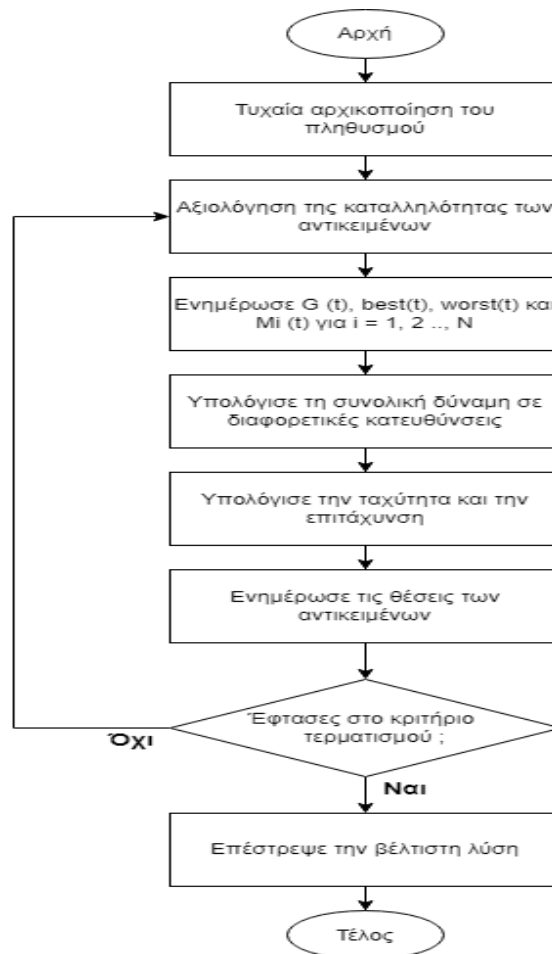
$$\frac{p_{fl} - (I_1^2 R_1 + I_2^2 R_2 + P_{rot})}{p_{fl}} = \eta_{fl}(mf)$$

Όπου : P_{rot} είναι οι απώλειες περιστροφικής ισχύος και p_{fl} είναι η ονομαστική ισχύς.



Σχήμα 2.2. Το πλήρες ισοδύναμο κύκλωμα του επαγωγικού κινητήρα

Για να βρεθούν οι ίδιες παράμετροι, έχει προταθεί η χρήση του αλγορίθμου Gravity Search Algorithm (GSA), ο οποίος βασίζεται στον νόμο της βαρύτητας (Gravity) και τις αλληλεπιδράσεις μεταξύ των μαζών, παίρνοντας έμπνευση από την Νευτώνεια βαρύτητα και τους νόμους της κίνησης. Το διάγραμμα ροής του αλγορίθμου GSA φαίνεται στο Σχήμα 2.3. Ο αλγόριθμος GSA χρησιμοποιεί την ιδιότητα των μαζών να έλκονται από την βαρύτερη μάζα λόγω της βαρύτητας και να κινούνται εξ 'αιτίας της. Οι μάζες για τον αλγόριθμο θεωρούνται παράγοντες.



Σχήμα 2.3. Διάγραμμα Ροής του αλγορίθμου GSA

Τώρα, εξετάζοντας ένα υπολογιστικό μοντέλο που έχει έναν i αριθμό παραγόντων που ορίζεται ως εξής:

$$x_i = (x_i^1, \dots, x_i^d, \dots, x_i^n), i = 1, 2, \dots, N$$

Όπου το x_i^d αντιπροσωπεύει τη θέση του i -στου παράγοντα στη d -στη διάσταση.

Σε χρόνο t η δύναμη που δρα από την μάζα i στην μάζα j ορίζεται ως εξής:

$$F_{ij}^d = G(t) \frac{Mp_i(t) \times Ma_j(t)}{R_{ij}(t) + \varepsilon} (x_j^d(t) - x_i^d(t))$$

Όπου Ma_j είναι η ενεργός βαρυντική μάζα που σχετίζεται με τον παράγοντα j , Mp_i είναι η παθητική βαρύτητα του παράγοντα i , $G(t)$ είναι η σταθερά βαρύτητας τη στιγμή t , ε είναι μία μικρή σταθερά και R_{ij} είναι η ευκλείδεια απόσταση μεταξύ του i -στου και του j -στου παράγοντα. Η δύναμη που δρα πάνω από έναν παράγοντα i σε ένα χώρο διαστάσεων d είναι :

$$F_i^d(t) = \sum_{j=1, j \neq i}^N rand_j F_{ij}^d(t)$$

Από τον 2^ο Νόμο του Νεύτωνα, η επιτάχυνση του παράγοντα i τη χρονική στιγμή t είναι:

$$a_i^d(t) = \frac{F_i^d(t)}{Mn_i(t)}$$

Όπου Mn_i είναι η αδρανειακή μάζα του παράγοντα i , η νέα ταχύτητα και θέση υπολογίζεται ως:

$$v_i^d(t+1) = rand_i \times v_i^d(t) + a_i^d(t)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1)$$

Η αρχική τιμή της βαρυντικής σταθεράς G , αλλάζει με την πάροδο του χρόνου ανάλογα με τη στρατηγική αναζήτησης. Το G είναι μία συνάρτηση της αρχικής τιμής της βαρυντικής σταθεράς G_0 και του χρόνου t :

$$G(t) = G(G_0, t)$$

Οι βαρυντικές και αδρανειακές μάζες αξιολογούνται με μία συνάρτηση κόστους, μία μεγαλύτερη μάζα σημαίνει καλύτερη λύση. Οι βαρυντικές και αδρανειακές μάζες ενημερώνονται με τις ακόλουθες εξισώσεις :

$$M_{ai} = M_{pi} = M_{ji} = M_i, i = 1, 2, \dots, N$$

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)}$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)}$$

Εν τέλει , γίνεται κατανοητό ότι η εκτίμηση των παραμέτρων των επαγωγικών κινητήρων η οποία είναι πολύ περίπλοκη για τις κλασικές μεθόδους βελτιστοποίησης, απλοποιείται σε μεγάλο βαθμό με τη χρήση του μοντέλου του σταθερού κυκλώματος και του αλγορίθμου GSA. [1]

2.2.4 Συντονισμός μη συμβατικών ηλεκτρονόμων υπερέντασης

Πολλές επιχειρήσεις κοινής ωφέλειας ακολουθούν το κριτήριο της αυξημένης χρήσης διαφορικής προστασίας σε γραμμές μεταφοράς το οποίο έχει απόλυτη επιλεκτικότητα χωρίς προσφερόμενη εφεδρική λειτουργία. Σε πολλές περιπτώσεις γίνεται χρήση ηλεκτρονόμων υπερέντασης ως εφεδρικά συστήματα προστασίας των γραμμών μεταφοράς ηλεκτρικού ρεύματος. Σε κάποιες άλλες περιπτώσεις γίνεται χρήση των κατευθυντικών ηλεκτρονόμων υπερέντασης (DOCR) για την εφεδρική προστασία των γραμμών διανομής ηλεκτρικού ρεύματος. Αυτό έχει ως αποτέλεσμα, ο συντονισμός DOCR σε πλέγμα διαμόρφωσης να είναι αρκετά συχνός. Σε ακραίες περιπτώσεις όπου το κύριο σύστημα προστασίας δεν λειτουργεί εξ 'αιτίας μίας βλάβης ή συντήρησης ο ηλεκτρονόμος υπερέντασης χρησιμοποιείται αντί για το κύριο σύστημα ασφαλείας των γραμμών μεταφοράς ή διανομής ρεύματος. Σε τέτοιες ακραίες περιπτώσεις η βέλτιστη ρύθμιση και λειτουργία των DOCR μπορεί να βοηθήσει σε μεγάλο βαθμό στην προστασία των γραμμών. Η προστατευτική αναμετάδοση περιλαμβάνει πολλές διαδικασίες και τεχνικές που επικεντρώνονται στη διατήρηση της λειτουργίας του συστήματος ισχύος με ασφάλεια κατά τη διάρκεια και μετά από ανεπιθύμητες ανωμαλίες στις συνθήκες δικτύου, που οφείλονται κυρίως σε απρόβλεπτα και ακραία γεγονότα.

Ο ηλεκτρονόμος υπερέντασης είναι ένας από τους παλαιότερους προστατευτικούς ηλεκτρονόμους. Η αρχή λειτουργίας τους είναι αρκετά απλή. Ο ηλεκτρονόμος υπερέντασης μπαίνει σε λειτουργία την στιγμή που μετρηθεί μεγαλύτερη ένταση ρεύματος μεγαλύτερη από μία προκαθορισμένη. Απαιτούνται λιγότερες μεταβλητές από

το σύστημα σε σύγκριση με άλλες προσασίες, με αποτέλεσμα ο ηλεκτρονόμος υπερέντασης να είναι η απλούστερη και επίσης η πιο δύσκολη προσασία στο συντονισμό. Η απλότητά του αντικατοπτρίζεται στο χαμηλό κόστος υλοποίησης, λειτουργίας και συντήρησης. Το αντίστοιχο συνίσταται στους αυξημένους χρόνους ενεργοποίησης που προσφέρονται από αυτό το είδος ηλεκτρονόμου κυρίως πριν από σφάλματα που βρίσκονται μακριά από τη θέση τους. Αυτό το πρόβλημα μπορεί να τονιστεί ιδιαίτερα, όταν χρησιμοποιούνται τυποποιημένες καμπύλες αντίστροφου χρόνου ή όταν θεωρούνται μόνο οι μέγιστες βλάβες που πραγματοποιούν συντονισμό του ηλεκτρονόμου. Αυτοί οι περιορισμοί έχουν προκαλέσει την αργή μείωση του αριθμού των ηλεκτρονόμων υπερέντασης και την αντικατάστασή τους από πιο εξελιγμένες συσκευές προσασίας, αλλά εξακολουθεί να εφαρμόζεται ευρέως σε συστήματα μεταφοράς, διανομής και βιομηχανικών συστημάτων.

Τεχνικές όπως η χρησιμοποίηση μη τυποποιημένων καμπυλών αντίστροφου χρόνου και αλγορίθμων βελτιστοποίησης οι οποίοι μπορούν να επεξεργαστούν δεδομένα στην περίπτωση που γίνει συντονισμός, εξελίσσουν την χρήση του ηλεκτρονόμου υπερέντασης χωρίς να γίνονται αλλαγές στις αρχές λειτουργίας του και στα πλεονεκτήματά του. Συνεπώς μπορούν να συνεχίσουν να χρησιμοποιούνται με ασφάλεια χωρίς να υπάρχει ανάγκη αντικατάστασή τους οδηγώντας έτσι σε εξοικονόμηση οικονομικών πόρων.

Για το συντονισμό των διακοπών υπερέντασης έχει γίνει η χρήση μετα-ευρετικών αλγορίθμων και πιο συγκεκριμένα του αλγορίθμου Invasive Weed Optimization (IWO). Τα άτομα ονομάζονται Weeds, ο δειγματικός χώρος των Weeds δημιουργείται τυχαία και στην συνέχεια αξιολογείται. Τα μέλη του πληθυσμού επιτρέπεται να αφήνουν η σπόρους (S) ανάλογα με τη δική τους και με την υψηλότερη και χαμηλότερη καταλληλότητα του πληθυσμού σύμφωνα με την εξίσωση :

$$S_i = S_{\min} \left[(F_i - F_{\min}) \frac{S_{\max} - S_{\min}}{F_{\max} - F_{\min}} \right]$$

Όπου S_i είναι οι συνολικοί σπόροι του weed i , S_{\max} και S_{\min} είναι το εύρος των επιτρεπόμενων σπόρων, F_i είναι η καταλληλότητα του weed i , F_{\max} και F_{\min} είναι η ελάχιστη και μέγιστη καταλληλότητα πληθυσμού.

Αφού καθοριστούν οι συνολικοί σπόροι κάθε weed, οι σπόροι υπόκεινται σε επεμβατικούς χειριστές weeds οι οποίοι είναι βασισμένοι σε σχήματα μετάλλαξης. Αυτοί

οι χειριστές είναι η εξάπλωση, η διασπορά και η κύλιση προς τα κάτω και καθορίζουν τη διάδοση του σπόρου του ζιζανίου το οποίο ισοδυναμεί με την εξερεύνηση και εκμετάλλευση του χώρου αναζήτησης.

Αναλυτικότερα, εξάπλωση είναι η διάδοση του σπόρου με τυχαία δημιουργία ενός νέου ατόμου, καθώς είναι δυνατόν να μη διαδοθούν όλοι οι σπόροι. Αυτό σημαίνει ότι ο σπόρος απλώνεται ενώ κάποιο μέρος του διατηρείται. Η διασπορά στοχεύει στη μεταφορά του σπόρου σε ένα μέρος κοντά στο αρχικό φυτό. Η κύλιση προς τα κάτω είναι η μεταφορά του σπόρου σε μια καλύτερη θέση. Με την μεταφορά, αξιολογείται η μεταφορά του σπόρου και σε περίπτωση που βρεθεί καλύτερο μέρος ο σπόρος σταματάει να κινείται.

Οι χρόνοι ενεργοποίησης και τα σφάλματα συντονισμού υπολογίζονται χρησιμοποιώντας τις παρακάτω εξισώσεις

$$t = \left[\frac{A}{\left(\frac{I_{sc}}{I_{pickup}} \right)^p - 1} + B \right] \times TDS$$

$$K_{sensitivity} = \frac{I_{sc}^{20}}{I_{pickup}^{Backup}}$$

Όπου t ο χρόνος ενεργοποίησης, I_{sc} ρεύμα βραχυκύκλωσης, TDS ρύθμιση ώρας και A, B, p χαρακτηριστικές σταθερές καμπύλης χρόνου. K συντελεστής ευαισθησίας, I_{sc}^{20} είναι το ρεύμα που αντιλαμβάνεται ο εφεδρικός ηλεκτρονόμος για το ελάχιστο σφάλμα που προσομοιώνεται στο μακρινό άκρο της μεγάλης παρακείμενης γραμμής και I_{pickup}^{Backup} το ρεύμα εκκίνησης του εφεδρικού ηλεκτρονόμου.

Οι εφεδρικοί ηλεκτρονόμοι ασφαλείας πρέπει να εισέρχονται σε λειτουργία ,μόνο όταν τα κύρια ηλεκτρικά στοιχεία ασφαλείας δεν λειτουργούν ή αρχίζουν να λειτουργούν με μεγάλη καθυστέρηση. Το χρονικό διάστημα το οποίο περιμένουν οι εφεδρικοί ηλεκτρονόμοι μέχρι να μπουν σε λειτουργία ονομάζεται χρονικό διάστημα συντονισμού (Coordination Time Interval→CTI). Συνεπώς ένας εφεδρικός ηλεκτρονόμος χρειάζεται να μπει σε λειτουργία μετά από χρόνο ίσο με το χρόνο εκκίνησης του κύριο στοιχείου ασφαλείας μαζί με το χρονικό διάστημα συντονισμού. Η αντικειμενική συνάρτηση είναι το άθροισμα του αριθμού των παραβιάσεων, το άθροισμα του πρωτεύοντος και του

εφεδρικού χρόνου, καθώς και το άθροισμα του αριθμού των συντονισμένων ζευγών σφάλματος CTI και φαίνεται παρακάτω :

$$fitness = \left(\frac{NV}{NCP}\right) + \left(\frac{\sum_{a=1}^{NCP} t_{primary_a}}{NCP}\right) * \alpha + \left(\frac{\sum_{b=1}^{NCP} t_{backup_b}}{NCP}\right) * \beta + \left(\sum_{L=1}^{NCP} E_{CTI_L}\right)$$

Όπου: α , β , δ είναι παράγοντες που αυξάνουν ή μειώνουν την επιρροή κάθε συνάρτησης επιμέρους στόχου και θα κάνουν για οποιοδήποτε άλλο σύστημα. Με:

- NV: αριθμός παραβιάσεων των περιορισμών συντονισμού,
- NCP: αριθμός ζευγών συντονισμού,
- $t_{primary_a}$: χρόνος λειτουργίας του κύριου ηλεκτρονόμου a ,
- t_{backup_b} : χρόνος λειτουργίας του ηλεκτρονόμου ασφαλείας b ,
- E_{CTI_L} : σφάλμα CTI του L -στού ζεύγους συντονισμού.

Το συγκεκριμένο πρόβλημα συντονισμού με τη χρήση του IWO μπορεί να εξάγει μία αρκετά γρήγορη λύση παίρνοντας ως δεδομένα τα άτομα που ονομάζονται weeds. Η μήτρα των weeds είναι τυχαία δημιουργημένη, οι χρόνοι ενεργοποίησης και τα σφάλματα συντονισμού υπολογίζονται χρησιμοποιώντας τις ίδιες εξισώσεις όπως παραπάνω και η θεωρούμενη για τον αλγόριθμο αντικειμενική συνάρτηση ελαχιστοποίησης είναι:

$$\underset{T_{mc}, f, g, h}{\text{minimize}} \frac{T_{mc}}{n} + \alpha \sum_{i=1}^m \frac{f_i(x_i)}{m} + \beta \sum_{j=1}^n \frac{g_j(y_j)}{n} + \gamma \sum_{j=1}^n \frac{h_j(x_j, y_j)}{n}$$

Όπου m και n είναι οι συνολικοί ηλεκτρονόμοι και τα συνολικά ζεύγη συντονισμού στο σύστημα και α , β , γ είναι οι συντελεστές βάρους του κάθε στόχου των διαφορετικών επιπέδων του βραχυκυκλώματος.

Τα διακριτά στάδια του IWO ξεκινούν μετά το βήμα αξιολόγησης. Τα weeds ταξινομούνται ανάλογα με την καταλληλότητά τους (F) και το καθένα επιτρέπεται να αφήνει σπόρους σύμφωνα με την κατάταξή τους. Ένας σπόρος είναι ένας κλώνος του πραγματικού weed που θα υποβληθεί σε τελεστές μετάλλαξης. Οι συνολικοί σπόροι (T_s) που θα δώσει το κάθε weed υπολογίζονται από την σχέση :

$$T_{S_i} = S_{rm} \left[(F_w - F_i) \times \frac{S_{rM} - S_{rm}}{F_w - F_b} \right]$$

Όπου Τα S_{rM} και S_{rM} είναι η ελάχιστη και η μέγιστη ποσότητα πιθανών weeds, τα F_b και F_w είναι οι τιμές καταλληλότητας του καλύτερου και χειρότερου στοιχείου και F_i είναι η τιμή της καταλληλότητας του συγκεκριμένου στοιχείου. Γίνεται χρήση τελεστών για την διασπορά, την μεταφορά και την κύλιση των weeds, έτσι ώστε να καταστεί δυνατόν για τα weeds να εξερευνήσουν, και να εκμεταλλευτούν τον χώρο τους με συνέπεια την εύρεση καλύτερου αποτελέσματος. Ο πρώτος τελεστής δημιουργεί ένα νέο weed βασισμένο στον αρχικό σπόρο. Ο δεύτερος τελεστής μετακινεί τον αρχικό σπόρο σε μία νέα περιοχή και ο τρίτος αντιγράφει και πολλαπλασιάζει τον αρχικό σπόρο σε αυτήν την νέα περιοχή. Η επαναλαμβανόμενη χρησιμοποίηση των τελεστών γίνεται μέχρι να βρεθεί μία βέλτιστη λύση ή μέχρι να μην υπάρχουν άλλα αντίγραφα των σπόρων. Το ποσοστό μετάλλαξης, το μέγεθος της διαταραχής και οι ρυθμίσεις για μετάλλαξη επιλέγονται τυχαία. Η καταλληλότητα των τρεχόντων weeds και των μεταλλαγμένων σπόρων ταξινομείται και επιλέγονται τα η πιο κατάλληλα στοιχεία για να συνθέσουν τον νέο πληθυσμό. Η μέθοδος αρχίζει από το βήμα εκχώρησης σπόρων και αυτή η διαδικασία επαναλαμβάνεται έως ότου ικανοποιηθεί το μόνο κριτήριο διακοπής που λαμβάνεται υπόψη για αυτήν την υλοποίηση, δηλαδή το εύρος των συνολικών επαναλήψεων T_i . [6]

2.2.5 Οι εφαρμογές του αλγορίθμου Crow Search Algorithm σε προβλήματα συστήματος ισχύος

Η αποτελεσματική χρήση της ενέργειας έχει προσελκύσει την προσοχή σε μια μεγάλη ποικιλία τομέων μηχανικής λόγω των περιβαλλοντικών της συνεπειών. Η υψηλή τους κατανάλωση έχει προκαλέσει την ανάγκη βελτίωσης της απόδοσής τους, η οποία εξαρτάται σε μεγάλο βαθμό από τη διαμόρφωση των εσωτερικών τους παραμέτρων. Προβλήματα όπως η αναγνώριση των εσωτερικών παραμέτρων των κινητήρων είναι αρκετά περίπλοκα. Γι αυτόν τον λόγο οι απλές ευρετικές μέθοδοι δυσκολεύονται να τα λύσουν. Η χρήση μετα-ευρετικών τεχνικών και αλγορίθμων είναι ο πιο συνετός τρόπος επίλυσης προβλημάτων τα οποία δεν είναι γραμμικά, εμφανίζουν ασυνέχειες και υψηλή πολυτροποικότητα. Αυτές οι μέθοδοι δε χρειάζονται συνέχεια, κυρτότητα, διαφοροποίηση ή ορισμένες αρχικές συνθήκες κάτι που αποτελεί πλεονέκτημα έναντι των παραδοσιακών τεχνικών. Η αναγνώριση εσωτερικών παραμέτρων των επαγωγικών κινητήρων επαγωγής αντιπροσωπεύει ένα σημαντικό πρόβλημα που μπορεί να μεταφραστεί ως εργασία βελτιστοποίησης. Κατά την χρήση του αλγορίθμου Crow Search

Algorithm (CSA) ο οποίος ανήκει στην κατηγορία των μετα-ευρετικών αλγορίθμων, δεδομένα του αλγορίθμου άτομα ακολουθούν την μιμητική συμπεριφορά των κορακιών(crows). Στη φύση, τα κοράκια καταδεικνύουν συμπεριφορές νοημοσύνης ως αυτογνωσία, χρησιμοποιώντας εργαλεία, αναγνωρίζουν πρόσωπα, προειδοποιούν το κοπάδι για πιθανώς εχθρικά, εξελιγμένους τρόπους επικοινωνίας και ανακαλώντας το κρυμμένο μέρος του φαγητού μετά από λίγο. Η εξελικτική διαδικασία CSA μιμείται τη συμπεριφορά που έχουν τα κοράκια να κρύβουν και να ανακτούν την επιπλέον τροφή που κρύβουν. Οι βασικότερες παράμετροι σύμφωνα με τις οποίες επεξεργάζεται τα δεδομένα ο αλγόριθμος είναι το μέγεθος της ομάδας των N crows τα οποία βρίσκονται σε χώρο n διαστάσεων. Η θέση $X_{i,k}$ του crow i σε μια ορισμένη επανάληψη k αντιπροσωπεύει μια πιθανή λύση για το πρόβλημα και περιγράφεται στην παρακάτω εξίσωση:

$$X_{i,k} = [x_{i,k}^1, x_{i,k}^2, \dots, x_{i,k}^n] \text{ με } i = 1, 2, \dots, N \text{ και } k = 1, 2, \dots, \maxIt$$

όπου \maxIt είναι ο μέγιστος αριθμός των επαναλήψεων της διαδικασίας.

Κάθε crow (άτομο) θεωρείται ότι έχει την ικανότητα να θυμάται την καλύτερη τοποθεσία $M_{i,k}$ για να κρύβει φαγητό μέχρι την τρέχουσα επανάληψη σύμφωνα με την εξίσωση:

$$M_{i,k} = [m_{i,k}^1, m_{i,k}^2, \dots, m_{i,k}^n]$$

Η θέση του καθενός τροποποιείται σύμφωνα με δύο συμπεριφορές: την καταδίωξη και την υπεκφυγή. Κατά τη φάση της καταδίωξης, ένα crow j ακολουθεί το crow i με σκοπό να ανακαλύψει το κρυφό του μέρος. Το crow i δεν παρατηρεί την παρουσία του crow j , ως συνέπεια ο σκοπός του crow j επιτυγχάνεται. Κατά τη φάση της υπεκφυγής, το crow i γνωρίζει για την παρουσία του crow j και για να προστατεύσει την τροφή του, το crow i παίρνει σκόπιμα μια τυχαία τροχιά. Αυτή η συμπεριφορά προσομοιώνεται στο CSA μέσω της υλοποίησης μιας τυχαίας κίνησης. Ο τύπος συμπεριφοράς που εξετάζεται από κάθε crow i καθορίζεται από μια πιθανότητα επίγνωσης (AP). Η θέση του κάθε crow μπορεί να βρεθεί από την ακόλουθη εξίσωση:

$$X_{i,k+1} = \begin{cases} X_{i,k} + r_i \cdot fl_{i,k} \cdot (M_{j,k} - X_{i,k}), & r_i \geq AP \\ \text{τυχαίο} & , \text{αλλιώς} \end{cases}$$

Η παράμετρος μήκους πτήσης $fl_{i,k}$ δείχνει το μέγεθος της κίνησης από το crow $X_{i,k}$ προς την καλύτερη θέση $M_{j,k}$ του crow j , το r_i είναι ένας τυχαίος αριθμός με ομοιόμορφη κατανομή στην περιοχή $[0, 1]$.

Μόλις τροποποιηθούν τα crows, η θέση τους αξιολογείται και το διάνυσμα μνήμης ενημερώνεται σύμφωνα με την εξίσωση:

$$M_{i,k+1} = \begin{cases} F(X_{i,k+1}), & \text{αν } F(X_{i,k+1}) < F(M_{i,k}) \\ M_{i,k} & , \text{ αλλιώς} \end{cases}$$

Όπου F είναι η αντικειμενική συνάρτηση που πρέπει να ελαχιστοποιηθεί. Η πιθανότητα δυναμικής επίγνωσης (DAP) η οποία είναι μία προσαρμοσμένη τιμή της AP, υπολογίζεται από την εξίσωση:

$$DAP_{i,k} = 0.9 \cdot \frac{F(X_{i,k})}{wV} + 0.1$$

όπου το wV αντιπροσωπεύει τη χειρότερη τιμή φυσικής κατάστασης που έχει παρατηρηθεί μέχρι τώρα. Με αυτήν τη μέθοδο, οι υποσχόμενες λύσεις θα έχουν μεγάλη πιθανότητα να αξιοποιηθούν, όμως λύσεις κακής ποιότητας θα έχουν μεγάλη πιθανότητα να αρχειοποιηθούν εκ νέου με μια τυχαία θέση. Ο αρχικός αλγόριθμος CSA μιμείται δύο διαφορετικές συμπεριφορές των crows: την καταδίωξη και την υπεκφυγή. Η συμπεριφορά της υπεκφυγής προσομοιώνεται με την υλοποίηση μιας τυχαίας κίνησης η οποία υπολογίζεται μέσω μιας τυχαίας τιμής ομοιόμορφα κατανεμημένης. Στις πτήσεις Lévy, οι οποίες είναι ένα είδος τυχαίας διαδρομής, το μέγεθος του βήματος ελέγχεται από μια κατανομή πιθανοτήτων με μεγάλο βάρος στο τέλος, συνήθως γνωστή ως κατανομή Lévy. Η εξερεύνηση του χώρου αναζήτησης είναι καλύτερη με την χρήση της κατανομής Lévy σε σχέση με την ομοιόμορφη τυχαία κατανομή. Η χρήση των πτήσεων Lévy γίνεται από τον βελτιωμένο αλγόριθμο CSA για την προσομοίωση της συμπεριφοράς υπεκφυγής. το διάγραμμα ροής του αλγορίθμου φαίνεται στο Σχήμα 2.4. Επομένως, δημιουργείται μια νέα τυχαία θέση $X_{i,k}$ προσθέτοντας στην τρέχουσα θέση $X_{i,k}$ την υπολογισμένη πτήση Lévy L . Προκειμένου να ληφθεί μια συμμετρική σταθερή κατανομή Lévy για το L , το πρώτο βήμα είναι να υπολογιστεί το μέγεθος του βήματος Z_i ως εξής:

$$Z_i = \frac{a}{|b|^{1/\beta}}$$

όπου a και b είναι n -διάστατοι τελεστές και $\beta=3/2$. Τα στοιχεία κάθε διανύσματος a και b λαμβάνονται από την κανονική κατανομή που χαρακτηρίζεται από τις ακόλουθες παραμέτρους:

$$a \sim N(0, \sigma_a^2)$$

$$\sigma_a = \left\{ \frac{\Gamma(1 + \beta) \sin(\pi \beta / 2)}{\Gamma[(1 + \beta) / 2] \beta \cdot 2^{(\beta - 1) / 2}} \right\}^{1 / \beta}$$

$$b \sim N(0, \sigma_b^2), \sigma_b = 1$$

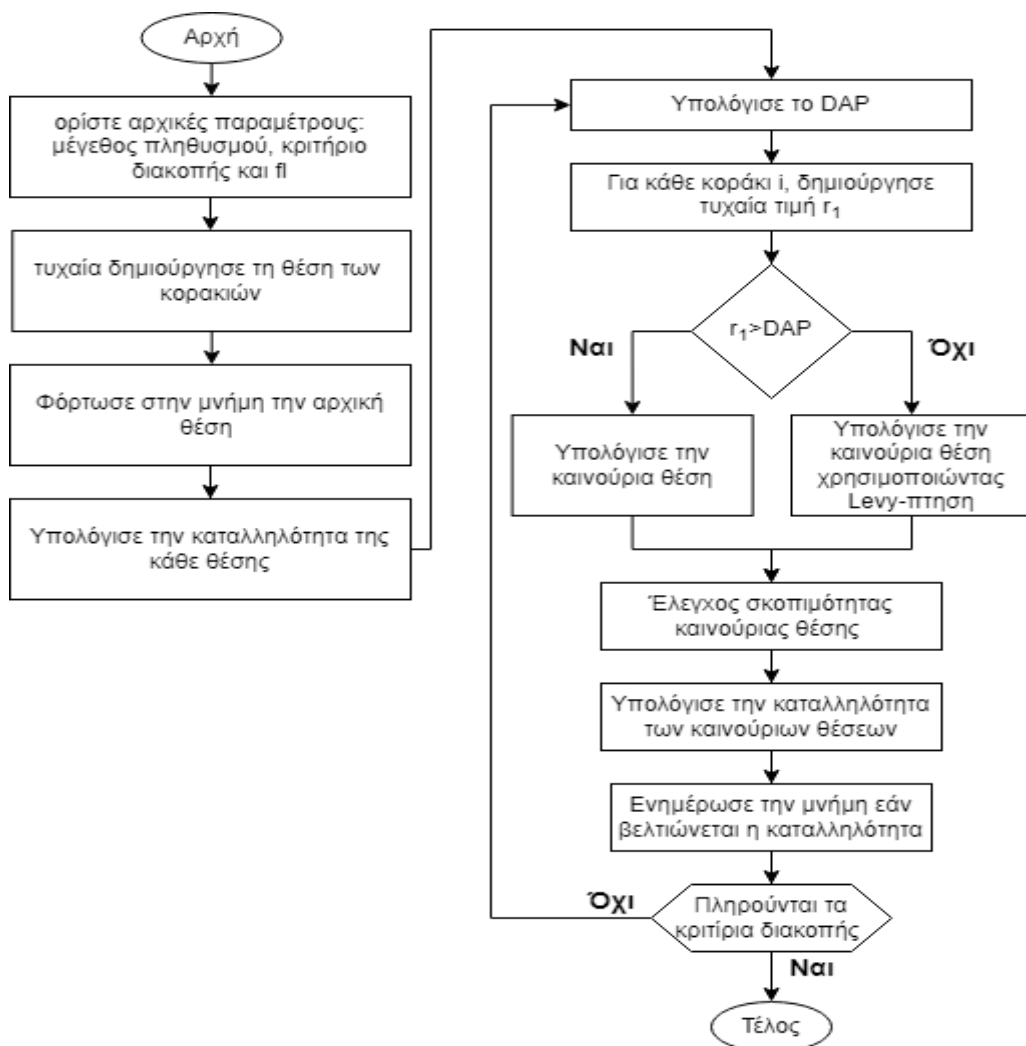
Όπου $\Gamma()$ υποδηλώνει την κατανομή Γάμα. Αφού ληφθεί η τιμή του Z_i , ο παράγοντας L υπολογίζεται από το ακόλουθο μοντέλο:

$$L = 0.01 \cdot Z_i \odot (X_{i,k} - X^{best})$$

όπου το γινόμενο \odot υποδηλώνει τους πολλαπλασιασμούς βάσει στοιχείων, το X^{best} αντιπροσωπεύει την καλύτερη λύση που έχει γίνει μέχρι σήμερα όσον αφορά την ποιότητα καταλληλότητας. [1]

Η καινούργια θέση δίνεται από τον τύπο:

$$X_{i,k+1} = X_{i,k} + L$$



Σχήμα 2.4. Διάγραμμα ροής του βελτιωμένου αλγορίθμου CSA

2.2.6 Αναδιαμόρφωση δικτύου διανομής

Η αναδιαμόρφωση δικτύου διανομής (DNR) είναι ο τρόπος προσαρμογής της τοπολογίας του συστήματος μέσω της μεταβαλλόμενης κατάστασης ενεργοποίησης/απενεργοποίησης των διακοπών και διατηρώντας τη δομή ακτινικής λειτουργίας του δικτύου. Η DNR ανάμεσα σε άλλα χρησιμοποιείται επίσης για την μείωση των απωλειών στις γραμμές και τη βελτίωση της ποιότητας τάσης. Τα δίκτυα διανομής λειτουργούν συνήθως σε ακτινική διάταξη. Ο αλγόριθμος Binary Group Search Optimization (BGSO) προτείνεται για την αντιμετώπιση του προβλήματος βέλτιστης αναδιαμόρφωσης δικτύου στα συστήματα διανομής. Εδώ, η ελαχιστοποίηση συνολικών απωλειών θεωρείται ως ο στόχος που επιλύεται με την επιφύλαξη της ακτινικής λειτουργίας του συστήματος και των περιορισμών ροής ισχύος.

Ο κύριος σχεδιασμός του GSO ενθαρρύνεται από τις αρχές διαβίωσης των ομάδων ζώων. Ένα αποτέλεσμα της συλλογικής ζωής είναι ότι η ομαδική αναζήτηση επιτρέπει σε κάθε ένα από τα μέλη να αυξήσει τις ταχύτητες κέρδους σημείων καθώς και να μειώσει τη διαφορά στην επιτυχία του κυνηγιού. Ο διαχωρισμός των μελών μίας ομάδας γίνεται στις ακόλουθες αυτές κατηγορίες:

- Producers: Περιλαμβάνει τα μέλη της ομάδας με την καταλληλότερη θέση.
- Scroungers: περιλαμβάνει τα μέλη της ομάδας που ακολουθούν την προηγούμενη με απώτερο σκοπό την ένταξη σε αυτήν.
- Rangers: Οι φύλακες εκτελούν τυχαίο περπάτημα στον χώρο αναζήτησης.

Ο πληθυσμός του αλγορίθμου GSO ονομάζεται ομάδα και κάθε άτομο του πληθυσμού ονομάζεται μέλος. Στον n -διάστατο χώρο αναζήτησης, το i -οστό μέλος στην k -οστή επανάληψη αναζήτησης έχει μια τρέχουσα θέση $X_i^k \in R^n$ και γωνία κεφαλής:

$$\varphi_i^k = (\varphi_{i1}^k, \dots, \varphi_{i(n-1)}^k) \in R^{n-1}$$

Όπου, R είναι το σύνολο των πραγματικών αριθμών και φ_{ik} είναι η πολική γωνία του i -οστού μέλους σε σχέση με την k -οστή διάσταση.

Η κατεύθυνση αναζήτησης του i -οστού μέλους του, $D_i^k(\varphi_i^k)$ θα μπορούσε να υπολογιστεί από το φ_i^k μέσω ενός μετασχηματισμού πολικής σε καρτεσιανές συντεταγμένες :

$$d_{i1}^k = \prod_{q=1}^{n-1} \cos(\varphi_{iq}^k)$$

$$d_{ij}^k = \sin(\varphi_{i(j-1)}^k) \prod_{q=j}^{n-1} \cos(\varphi_{iq}^k), j=2, \dots, n-1$$

$$d_{in}^k = \sin(\varphi_{i(n-1)}^k)$$

$$D_i^k(\varphi_i^k) = (d_{i1}^k, d_{i2}^k, \dots, d_{in}^k)$$

Οι scroungers ορίζουν τη διαδρομή αναζήτησής τους σε σχέση με την τοποθεσία του μέλους producer.

Στην k-οστή επανάληψη ο producer X_p θα πραγματοποιήσει σάρωση σε μηδενικό βαθμό και, στη συνέχεια, θα πραγματοποιήσει πλάγια σάρωση δειγματοληπτικά τυχαία τρία σημεία στο πεδίο σάρωσης σύμφωνα με τις σχέσεις :

$$X_z = X_p^k + r_1 l_{\max} D_p^k(\varphi^k)$$

$$X_r = X_p^k + r_1 l_{\max} D_p^k(\varphi^k + r_2 \theta_{\max}/2)$$

$$X_l = X_p^k + r_1 l_{\max} D_p^k(\varphi^k - r_2 \theta_{\max}/2)$$

Όπου $r_1 \in R^1$ είναι ένας κανονικά κατανομημένος τυχαίος αριθμός με μηδέν μέσο όρο και μία τυπική απόκλιση και $r_2 \in R^{n-1}$ είναι μια ομοιόμορφα κατανομημένη ακολουθία τυχαίων αριθμών στην περιοχή (0, 1).

Αξιολογούνται τα υπάρχοντα σημεία και γίνεται αναζήτηση νέου σημείου. Εάν το τελευταίο έχει καλύτερη τιμή τότε ο producer μετακινείται σε αυτό. Αν όχι, θα παραμείνει στην τρέχουσα θέση του και θα γυρίσει το κεφάλι του χρησιμοποιώντας την εξίσωση :

$$\varphi^{k+1} = \varphi^k + r_2 a_{\max}$$

όπου $a_{\max} \in R^1$ είναι η μέγιστη γωνία στροφής.

Εάν ο producer δεν μπορεί να βρει καλύτερη περιοχή μετά από μία επανάληψη, θα γυρίσει το κεφάλι του πίσω στο μηδέν σύμφωνα με την εξίσωση :

$$\varphi^{k+\alpha} = \varphi^k$$

με α μία σταθερά.

Στην k-οστή επανάληψη, η συμπεριφορά αντιγραφής περιοχής του i-οστού scrounger μπορεί να μοντελοποιηθεί ως τυχαίος περίπατος προς τον producer σύμφωνα με την ακόλουθη σχέση :

$$X_i^{k+1} = X_i^k + r_3 \circ (X_p^k - X_i^k)$$

όπου $r_3 \in R^n$ είναι μια ομοιόμορφη τυχαία ακολουθία στην περιοχή $(0, 1)$. Ο τελεστής "ο" είναι το γινόμενο Hadamard ή το γινόμενο Schur, το οποίο υπολογίζει το λογικό γινόμενο δύο διανυσμάτων. Κατά τη διάρκεια της επαιτείας(scrounge) , ο i-οστός scrounger θα συνεχίσει να αναζητά άλλες ευκαιρίες, για να συμμετάσχει στον scrounger. Τα υπόλοιπα μέλη της ομάδας θα διαλυθούν από τις τρέχουσες θέσεις τους.

Στην k-οστή επανάληψη, ένας ranger δημιουργεί μια τυχαία γωνία κεφαλής φ χρησιμοποιώντας τη σχέση :

$$\varphi^{k+1} = \varphi^k + r_2 a_{\max}$$

έπειτα επιλέγει μια τυχαία απόσταση χρησιμοποιώντας τη σχέση :

$$l_i = ar_1 l_{\max}$$

και μετακινείται στο νέο σημείο χρησιμοποιώντας τη σχέση :

$$X_i^{k+1} = X_i^k + l_i D_i^k(\varphi^{k+1})$$

Σύμφωνα με τον αλγόριθμο BGSO, στον δυαδικό χώρο αναζήτησης, όλα τα μέλη της ομάδας GSO είναι είτε 0 είτε 1. Τα σημεία μηδέν, δεξιά και αριστερά ορίζονται χρησιμοποιώντας τον όρο $r_1 l_{\max}$ ως τυχαίο μήκος.

Η κίνηση του scrounger στο δυαδικό χώρο μπορεί να διατυπωθεί ως εξής:

$$\Delta X_i^k = XOR(X_p^k, X_i^k)$$

όπου, το X_p^k είναι η θέση μέλους παραγωγού στην k-οστή επανάληψη και το X_i^k είναι η θέση του i-οστού μέλους scrounger στην k-οστή επανάληψη. Η διαδικασία του ranger εκτελείται χρησιμοποιώντας τυχαίο μήκος και γωνία κεφαλής. Παρόμοια με τον producers και τους scroungers, το τυχαίο μήκος επιτυγχάνεται χρησιμοποιώντας δύο τυχαίους δείκτες για δυαδικά μέλη ranger. Πρώτον, θα πρέπει να δημιουργηθεί ένα τυχαίο μήκος που χρησιμοποιεί τους δείκτες r_8 και r_9 στο οποίο, ο r_8 είναι ένας τυχαίος αριθμός στην περιοχή $(1, n)$ και ο r_9 είναι ένας τυχαίος αριθμός στο εύρος των $(1, n)$.

Έπειτα, δημιουργείται η τυχαία κατεύθυνση από την εξίσωση:

$$\Delta X_i = randint(1, l)$$

όπου, ΔX_i είναι ο επιλεγμένος υπο-πίνακας χρησιμοποιώντας το r_8 και το r_9 $randint(1, x)$ είναι ένας τελεστής που παρέχει έναν τυχαίο δυαδικό πίνακα με μήκος x και το l είναι το

παραγόμενο τυχαίο μήκος. Η αναδιαμόρφωση του δικτύου διανομής είναι η διαδικασία αλλαγής της τοπολογίας των συστημάτων διανομής, αλλάζοντας την κατάσταση ανοιχτού/κλειστού των διακοπών σύνδεσης και διατομής. Ο στόχος είναι να ελαχιστοποιηθεί η συνολική απώλεια ενεργού ισχύος του συστήματος, ενώ ικανοποιεί παράλληλα τη ροή φορτίου και άλλους λειτουργικούς περιορισμούς του δικτύου διανομής.

Το πρόβλημα θα μπορούσε να διατυπωθεί ως εξής:

$$\text{Min: } Z = \sum_{i=1}^L r_i \frac{P_i^2 + Q_i^2}{V_i^2}$$

όπου Z είναι η αντικειμενική συνάρτηση, r_i είναι η αντίσταση του i -οστού κλάδου και L είναι ο συνολικός αριθμός των διακλαδώσεων. Το P_i και το Q_i είναι ενεργή και άεργη ισχύς στον τελικό δίαυλο του κλάδου του, αντίστοιχα.[6]

2.2.7 Οικονομική Κατανομή Συνδυασμένης Θερμότητας και Ισχύος

Λόγω του αυξημένου ενεργειακού κόστους και των περιορισμών των πηγών ενέργειας από ορυκτά καύσιμα, συστήματα με υψηλότερη απόδοση, όπως τα συστήματα συνδυασμένης θερμότητας και ισχύος (CHP) έχουν γίνει πιο δημοφιλή. Η απόδοση των μονάδων CHP είναι περίπου 90% στην καλύτερη περίπτωση, ενώ το ποσό αυτό είναι μικρότερο από 60% για άλλες μονάδες συνδυασμένου κύκλου. Η οικονομική κατανομή εφαρμόζεται για τον προσδιορισμό της ισχύος και της θερμικής απόδοσης των μονάδων με ταυτόχρονη ελαχιστοποίηση του κόστους λειτουργίας. Στο πρόβλημα οικονομικής κατανομής για συστήματα συνδυασμένης θερμότητας και ισχύος (CHPED), ικανοποιούνται δύο τύποι απαιτήσεων που περιλαμβάνουν τις απαιτήσεις σε ισχύ και θερμότητα. Ο αλγόριθμος PSO είναι μία καλή τεχνική για την επίλυση του προβλήματος CHPED. Η αντικειμενική συνάρτηση είναι :

$$OF = \sum_{i=1}^{N_p} C_i(P_i^p) + \sum_{j=1}^{N_c} C_j(P_j^c, H_j^c) + \sum_{k=1}^{N_h} C_k(H_k^h)$$

Όπου $C_i(P_i^p)$ είναι το κόστος λειτουργίας της i -οστής μονάδας που λειτουργεί μόνο με ισχύ για την παραγωγή P_i^p MW ενέργειας. Το κόστος λειτουργίας για την j -οστή μονάδα συμπαραγωγής για παραγωγή P_j^c MW ηλεκτρικής ενέργειας και H_j^c MW θερμικής ισχύος

δίνεται από $C_j(P_j^c, H_j^c)$, $C_k(H_k^h)$ είναι το κόστος λειτουργίας της μονάδας μόνο θερμότητας κατά την παραγωγή H_k^h MW θερμικής ισχύος. Τα N_p , N_c και N_h είναι οι συνολικοί αριθμοί μονάδων μόνο ισχύος, CHP και μόνο θερμότητας, αντίστοιχα. i , j και k είναι δείκτες για τις παραπάνω μονάδες. Οι συναρτήσεις κόστους των μονάδων διατυπώνονται ως :

$$C_i(P_i^p) = \alpha_i(P_i^p)^2 + \beta P_i^p + \gamma_i$$

$$C_j(P_j^c, H_j^c) = a_j(P_j^c)^2 + b_j P_j^c + c_j + d_j(H_j^c)^2 + e_j H_j^c + f_j P_j^c H_j^c$$

$$C_k(H_k^h) = a_k(H_k^h)^2 + b_k H_k^h + c_k$$

Για την πρώτη εξίσωση, τα α_i , β_i και γ_i είναι σταθεροί συντελεστές κόστους για την i -οστή μονάδα ισχύος μόνο. Για την δεύτερη εξίσωση, a_j , b_j , c_j , d_j , e_j και f_j είναι συντελεστές συνάρτησης κόστους που σχετίζονται με την j -στη μονάδα CHP. Για την τρίτη εξίσωση, a_k , b_k και c_k είναι συντελεστές για τον υπολογισμό του κόστους λειτουργίας της k -οστής μονάδας μόνο θερμότητας.

Το άθροισμα της παραγόμενης ισχύος και θερμότητας θα πρέπει να ανταποκρίνεται στις απαιτήσεις ισχύος και θερμότητας :

$$\sum_{i=1}^{N_p} P_i^p + \sum_{j=1}^{N_c} P_j^c = P_d + P_{loss}$$

$$\sum_{j=1}^{N_c} H_j^c + \sum_{k=1}^{N_h} H_k^h = H_d$$

όπου P_d και H_d είναι απαιτήσεις ισχύος και θερμότητας, η P_{loss} είναι απώλεια μετάδοσης του συστήματος ισχύος.

Η παραγόμενη ηλεκτρική και θερμική ισχύς θα πρέπει να είναι στο αποδεκτό εύρος για κάθε μονάδα:

$$P_i^{pmin} \leq P_i^p \leq P_i^{pmax}, i = 1, 2, \dots, N_p$$

$$P_j^{cmin}(H_j^c) \leq P_j^c \leq P_j^{cmax}(H_j^c), j = 1, 2, \dots, N_c$$

$$H_j^{cmin}(P_j^c) \leq H_j^c \leq H_j^{cmax}(P_j^c), j = 1, 2, \dots, N_c$$

$$H_k^{hmin} \leq H_k^h \leq H_k^{hmax}, k = 1, 2, \dots, N_h$$

Όπου P_i^{pmin} και P_i^{pmax} είναι κατώτερα και ανώτερα όρια παραγωγής για μονάδες μόνο με ισχύ, P_j^{cmin} , H_j^{cmin} , P_j^{cmax} και H_j^{cmax} είναι οι ελάχιστες και μέγιστες εξόδους ηλεκτρικής και θερμικής ισχύος για μονάδες CHP, τέλος, τα όρια για μονάδες μόνο θερμότητας είναι H_k^{hmin} και H_k^{hmax} .

Για την εύρεση της βέλτιστης λύσης για το συγκεκριμένο πρόβλημα έχει προταθεί ο αλγόριθμος PSO, ο οποίος είναι ένας αλγόριθμος βελτιστοποίησης που βασίζεται στη νοημοσύνη του σμήνους, ο οποίος εμπνέεται από συμπεριφορές σμήνους ζώων όπως τα πουλιά. Το διάγραμμα ροής του αλγορίθμου PSO για την επίλυση του συγκεκριμένου προβλήματος φαίνεται στο Σχήμα 2.5. Κάθε σωματίδιο i έχει ένα διάνυσμα θέσης X και ένα διάνυσμα ταχύτητας V σε κάθε αριθμό επανάληψης που μπορεί να διατυπωθεί ως:

$$X_i^{iter} = [x_{i,1}^{iter}, x_{i,2}^{iter}, \dots, x_{i,N}^{iter}]$$

$$V_i^{iter} = [v_{i,1}^{iter}, v_{i,2}^{iter}, \dots, v_{i,N}^{iter}]$$

όπου N είναι ο συνολικός αριθμός των μεταβλητών απόφασης στο πρόβλημα. Η μαθηματική διατύπωση αυτής της διαδικασίας είναι:

$$v_{i,n}^{iter} = \omega \times v_{i,n}^{iter-1} + C_1 \times r_1^n \times (p_{best,i,n}^{iter-1} - x_{i,n}^{iter-1}) + C_2 \times r_2^n \times (g_{best,n}^{iter-1} - x_{i,n}^{iter-1})$$

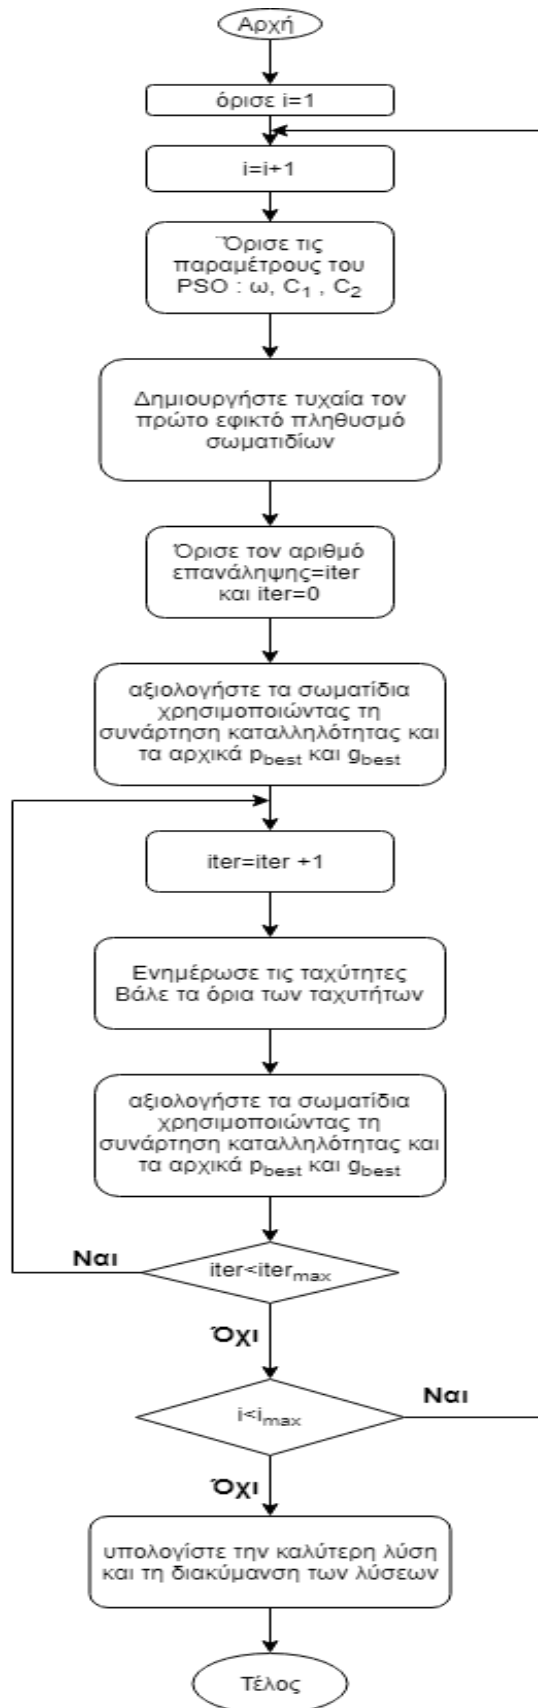
$$x_{i,n}^{iter} = x_{i,n}^{iter-1} + v_{i,n}^{iter}$$

όπου ω είναι το βάρος αδράνειας, r_1^n και r_2^n είναι τυχαίοι αριθμοί στο διάστημα $[0, 1]$. $p_{best,i,n}^{iter-1}$ και $g_{best,n}^{iter-1}$ είναι οι καλύτερες θέσεις του i -οστού σωματιδίου σε προηγούμενη επανάληψη και η καλύτερη θέση ολόκληρου του σμήνους, αντίστοιχα. Οι C_1 και C_2 είναι παράγοντες μάθησης που είναι συνήθως ίσοι. Οι ενημερωμένες ταχύτητες πρέπει να βρίσκονται σε κάποια προκαθορισμένα όρια:

$$-v_n^{max} \leq v_{i,n} \leq v_n^{max}$$

$$v_n^{max} = (x_n^{max} - x_n^{min})/r$$

όπου x_n^{max} , x_n^{min} είναι τα μέγιστα και ελάχιστα όρια των μεταβλητών όπως αναφέρεται στο r είναι μια παράμετρος για τον έλεγχο του ποσού της αλλαγής της ταχύτητας. [6]



Σχήμα 2.5. Διάγραμμα ροής του αλγορίθμου PSO για το πρόβλημα της οικονομικής κατανομής για συστήματα συνδυασμένης θερμότητας και ισχύος

2.2.8 Οικονομική Κατανομή Συστημάτων Πολλαπλών Ψυκτικών Σταθμών

Σε χώρες όπως η Ελλάδα που έχουν ζεστό κλίμα, τα συστήματα πολλαπλών ψυκτών καταναλώνουν μεγάλη ποσότητα ηλεκτρικής ενέργειας για να παράγουν ψύξη. Η χρήση συστημάτων πολλαπλών ψυκτών σε εφαρμογές κλιματισμού είναι ένας σημαντικός παράγοντας στην αύξηση της κατανάλωσης ηλεκτρικής ενέργειας. Για να επιτευχθεί σημαντική εξοικονόμηση ενέργειας στην ψύξη χώρων κτιρίων, είναι απαραίτητη η βέλτιστη λειτουργία των ψυκτικών συγκροτημάτων με ενεργειακά αποδοτικό τρόπο. Η ανάπτυξη ενός μεικτού προγράμματος μη-γραμμικής, ακέραιου αριθμού βελτιστοποίησης για εγκαταστάσεις πολλαπλών ψυκτών είναι απαραίτητη. Με αυτόν τον τρόπο η βέλτιστη κατάσταση ενεργοποίησης ή απενεργοποίησης και οι έξοδοι ψύξης των ψυκτικών συγκροτημάτων θα βρεθούν με τρόπο ώστε η κατανάλωση ενέργειας να ελαχιστοποιείται. Για την επίλυση του προβλήματος βέλτιστης φόρτισης ψυκτικού συγκροτήματος (OCL), η παραγωγή ψύξης των ψυκτών είναι ίση με τη ζήτηση ψύξης, η ψυκτική ικανότητα κάθε ψυκτικού συγκροτήματος είναι μικρότερη ή ίση με την χωρητικότητα ψύξης του. Στο πρόβλημα OCL, το άθροισμα της κατανάλωσης ηλεκτρικής ενέργειας των ψυκτών N ελαχιστοποιείται ως αντικειμενική συνάρτηση :

$$\text{Αντικειμενική συνάρτηση} = \sum_{i=1}^N P_i^t$$

όπου P_i^t είναι η ηλεκτρική ισχύς που καταναλώνει η μονάδα i τη χρονική στιγμή t και λαμβάνεται από :

$$u_i^t = \begin{cases} 0 & \text{εάν ο ψύκτης } i \text{ είναι απενεργοποιημένος} \\ 1 & \text{εάν ο ψύκτης } i \text{ είναι ενεργοποιημένος} \end{cases}$$

$$PLR_i^t = \begin{cases} 0 & \text{εάν ο ψύκτης είναι απενεργοποιημένος} \\ \frac{\text{ψυκτικό φορτίο της μονάδας } i \text{ τη χρονική στιγμή } t}{\text{Ψυκτική ικανότητα της μονάδας } i} = \text{τυχαίος αριθμός,} & \text{εάν ο ψύκτης } i \text{ είναι ενεργοποιημένος} \end{cases}$$

$$P_i^t = \begin{cases} 0 & , \text{εάν } u_i^t = 0 \\ a_i + b_i PLR_i^t + c_i (PLR_i^t)^2 + d_i (PLR_i^t)^3, & \text{εάν } u_i^t = 1 \end{cases}$$

Το u_i^t είναι μια δυαδική μεταβλητή που είναι 1 εάν η μονάδα i είναι ενεργοποιημένη, διαφορετικά είναι 0, ο περιορισμός της ικανότητας ψύξης μοντελοποιείται ως PLR_i^t , μια τυχαία μεταβλητή η οποία ανήκει στο διάστημα $[0,1]$ και δημιουργείται ως PLR του ψυκτικού συγκροτήματος i . Το ψυκτικό φορτίο αυτής της μονάδας υπολογίζεται με βάση

τον τυχαίο αριθμό και την ικανότητα ψύξης. Η κατανάλωσή του εξαρτάται από τους συντελεστές a_i , b_i , c_i και d_i και τη ζήτηση ψύξης που ικανοποιείται από αυτό το ψυκτικό συγκρότημα, διαφορετικά θα είναι 0.

Ο περιορισμός ισορροπίας φορτίου-παραγωγής είναι :

$$CL_t = \sum_{i=1}^N PLR_i^t \times RT_i$$

οι παράμετροι CL_t και RT_i είναι το ψυκτικό φορτίο τη στιγμή t και η ψυκτική ικανότητα του ψυκτικού συγκροτήματος i .

Ο αλγόριθμος Wild Goat Algorithm (WGA) εφαρμόζεται για την επίλυση του προβλήματος βέλτιστης φόρτισης ψυκτικού συγκροτήματος. Στο πρώτο βήμα, η κίνηση του leader είναι προς την κατεύθυνση των προσωπικών του εμπειριών, αλλά στα επόμενα βήματα, εκτός από τις προσωπικές εμπειρίες, θα παρακολουθεί την κίνηση άλλων επιτυχημένων leaders. Το πρώτο βήμα της επαναληπτικής διαδικασίας ενός αλγορίθμου που βασίζεται στον πληθυσμό είναι η προετοιμασία όλων των μελών του πληθυσμού και εάν η διάσταση του προβλήματος βελτιστοποίησης είναι N_{var} , τότε ο πίνακας που αντιπροσωπεύει κάθε μέλος του πληθυσμού είναι δίνεται από την εξίσωση:

$$wgi = [x_{i,1}, \dots, x_{i,Nvar}], i = 1, \dots, N_{wg}$$

όπου N_{wg} είναι ο αριθμός των Wild Goats.

Σε αυτόν τον αλγόριθμο, μετά την αρχικοποίηση, οι τιμές καταλληλότητας κάθε Wild Goat «wgi», που είναι μια βέλτιστη υποψήφια λύση, πρέπει να αξιολογηθούν σε σχέση με την αντικειμενική συνάρτηση:

$$f(wgi) = f([x_{i,1}, \dots, x_{i,Nvar}]), i = 1, \dots, N_{wg}$$

Για να υπάρχει καλύτερη σύγκριση μεταξύ των Wild Goats (wgs), ορίζεται ένα βάρος για κάθε Wild Goat (wg), το οποίο δίνεται από την ακόλουθη εξίσωση:

$$W_i = \exp \left(-N_{var} \frac{f(wg_i) - \min_j \{f(wg_j)\}}{\sum_{j=1}^{N_{wg}} (f(wg_j) - \min_j \{f(wg_j)\})} \right), i = 1, \dots, N_{wg}$$

Το βάρος(W) του wg που έχει τη βέλτιστη αντικειμενική τιμή συνάρτησης θα ισούται με ένα. Έτσι, το W άλλων Wild Goats (wgs) θα δώσει μια τιμή μεταξύ μηδέν και ένα. Τα Wild Goats ταξινομούνται ως προς το βάρος κάθε Wild Goat. Οι λύσεις με το μεγαλύτερο βάρος επιλέγονται ως leaders ομάδων. Ο αριθμός των ομάδων και των leaders στην αρχή του αλγορίθμου ορίζεται από το N_g . Οι leaders με υψηλό βάρος απορροφούν περισσότερους οπαδούς. Τα Wild Goats δεν μπορούν να φτάσουν στην κορυφή υπό τις δύο συνθήκες. Πρώτον όταν μετακινούνται σε πολλές ομάδες με μικρότερο αριθμό μελών και δεύτερον όταν μετακινούνται μόνο σε μία ομάδα. Η ιδανική κατάσταση είναι η μέση τους. Μετά τον καθορισμό του αριθμού των ομάδων, τα υπόλοιπα Wild Goats (εκτός από τους leaders) που ονομάζουμε followers κατανέμονται μεταξύ των ομάδων με βάση το βάρος των ηγετών των ομάδων. Όσο περισσότερο βάρος έχει ένας leader, τόσο περισσότερους followers προσελκύει. Τα αρχικά διανύσματα κίνησης όλου του πληθυσμού είναι μηδέν την πρώτη φορά. Ο καλύτερος leader έχει το μεγαλύτερο βάρος και προχωρά μόνο προς την κατεύθυνση του διανύσματος κίνησής του. Εδώ, οι followers, εκτός από το ότι κινούνται προς το διάνυσμα κίνησης και την καλύτερη προσπάθειά τους, κυνηγούν τον leader της ομάδας και όλες τις άλλες wild goats στις ομάδες τους που έχουν μεγαλύτερο βάρος από αυτούς. Μετά από αυτά, το βάρος κάθε wild goat αξιολογείται σε σύγκριση με τα βάρη των άλλων μελών της ομάδας. Αν μειωθεί το βάρος του, τότε ακολουθεί άλλους followers με μεγάλο βάρος, αντίστροφα αν το βάρος του αυξάνεται, το ακολουθούν και άλλα μέλη. Η θέση κάθε wild goat, καθορίζεται από την προηγούμενη θέση της και το διάνυσμα κίνησης της τρέχουσας επανάληψης, από την εξίσωση:


$$wg_i(t + 1) = wg_i(t) + u_i(t + 1), i = 1, \dots, N_{wg}$$

Οι ομάδες των Wild Goats φτάνουν μαζί στις πλαγιές του βουνού καθώς πηγαίνουν στην κορυφή ή κατεβαίνουν στους πρόποδες και ανταλλάσσουν τις εμπειρίες τους μαζί και οι αρχηγοί διαφορετικών ομάδων θα συζητήσουν μαζί για την κατεύθυνση και την ποιότητα της διαδρομής, που δημιουργεί την έννοια της συνεργασίας. Στο τέλος του αλγορίθμου, μόνο μία ομάδα αντέχει, και ο αρχηγός αυτής της ομάδας, θα φτάσει στο καλύτερο σημείο και στην πραγματικότητα, είναι η βέλτιστη λύση.[6]


2.2.9 Προσέγγιση Μακροπρόθεσμης Πρόβλεψης Φορτίου

Μία άλλη χρήση των μετα-ευρετικών αλγορίθμων είναι η μακροπρόθεσμη πρόβλεψη φορτίου η οποία έγινε με την χρήση τεχνητού νευρωνικού δικτύου. Η διαδικασία της

μακροπρόθεσμης πρόβλεψης φορτίου φαίνεται στο Σχήμα 2.6 και η σχηματική αναπαράσταση ενός τεχνητού νευρωνικού δικτύου στο Σχήμα 2.7. Αναλυτικότερα, Μελέτες δείχνουν ότι το αυξανόμενο ποσοστό πληθυσμού παντού κόσμο οδηγεί σε αύξηση της κατανάλωσης ηλεκτρικής ενέργειας. Ως εκ τούτου, η πρόβλεψη της ηλεκτρικής ζήτησης γίνεται όλο και πιο κρίσιμη για την παροχή βοήθειας στους διαχειριστές συστημάτων ηλεκτρικής ενέργειας στη διαχείριση του δικτύου ηλεκτρικής ενέργειας, είτε για βραχυπρόθεσμες αναλύσεις είτε για μακροπρόθεσμες εφαρμογές όπως η οικονομική κατανομή εκπομπών, η δέσμευση μονάδας, ο βέλτιστος προγραμματισμός. Είναι εφικτή η χρήση τεχνητών νευρωνικών δικτύων δυναμική ανατροφοδότησης οπίσθιας διάδοσης για τη μακροπρόθεσμη πρόβλεψη της ηλεκτρικής ζήτησης.



Σχήμα 2.6. Διαδικασία πρόβλεψης φορτίου σε μακροπρόθεσμο ορίζοντα



Σχήμα 2.7. Σχηματική αναπαράσταση τεχνητού νευρωνικού δικτύου

Το συμβατικό νευρωνικό δίκτυο αποτελείται από ένα στρώμα εισόδου, ένα κρυφό στρώμα και ένα στρώμα εξόδου. Επιπλέον, η σχέση μεταξύ των παραμέτρων, των επιπέδων αλλά

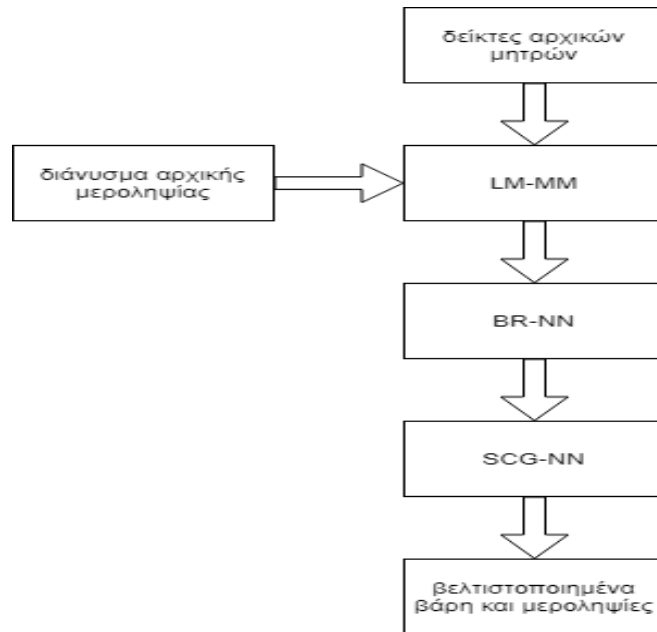
και των βημάτων εκπαίδευσης, οδηγεί στο σκοπό πρόβλεψης. Επιπλέον, ο όγκος υπολογισμού είναι ένα πολύ κρίσιμο σημείο που πρέπει να ληφθεί υπόψη, εάν ο αριθμός των δειγμάτων δεδομένων είναι αξιοσημείωτος για την εφαρμογή σύγκλισης. Ο πίνακας βάρους και τα διανύσματα μεροληψίας είναι οι παράμετροι διέγερσης του ANN που απαιτούνται για τη γενίκευση της ποικιλομορφίας των διανυσμάτων εισόδου και απλώς διασυνδέουν τις διακοπτόμενες εισόδους που είναι ηλεκτρική ζήτηση σε αυτή την περίπτωση, στα διορθωτικά βήματα της πρόβλεψης. Η συνάρτηση ενεργοποίησης είναι ο χειριστής του δικτύου που προσαρμόζεται τόσο σε διαδικασίες διόρθωσης όσο και σε διαδικασίες εκπαίδευσης. Οι σύνδεσμοι, οι οποίοι είναι νευρώνες, μεταφέρουν τις βελτιστοποιημένες τιμές βάρους και πόλωσης στο επίπεδο εξόδου με συγκεκριμένη σειρά. Το δυναμικό νευρωνικό δίκτυο ορίζεται ως ο συνδυασμός τριών μεθόδων μάθησης που βασίζονται στην παλινδρόμηση που είναι οι Levenberg Marquardt (LM), Bayesian Regulation (BR) και Scaled Conjugated Gradient (SCG). Πρώτα απ' όλα, ο χειριστής του συστήματος εκμάθησης θα ξεκινήσει με το LM να εκπαιδεύσει το τμήμα του συνόλου δεδομένων εισόδου (70%) και θα εκχωρήσει πρωτεύοντα διανύσματα βάρους και μεροληψίας. Μετά τη γενίκευση, η εκπαιδευμένη έξοδος χρησιμοποιείται στο δεύτερο δίκτυο διάδοσης (BR) για να ομαλοποιηθούν και να φιλτραριστούν οι λευκοί θόρυβοι του συνόλου σε σχέση με την απόδοση σφάλματος (MSE) του πρώιμου νευρωνικού δικτύου με 70% ως αναλογία εκπαίδευσης. Η κλιμακούμενη συζευγμένη θα βρει τα συγκεκριμένα διανύσματα για την ελαχιστοποίηση του σφάλματος (MSE). Στο Σχήμα 2.8 φαίνεται το διάγραμμα ροής του αναφερόμενου αλγορίθμου για την μακροπρόθεσμη πρόβλεψη φορτίου.

Η Τεχνική Back Propagation (BP) είναι μια μέθοδος εκμάθησης και προσαρμογής που μεταφέρει αρκετές επιμέρους παραγώγους από τη βασική παράμετρο του νευρωνικού δικτύου. Σε αυτή τη μέθοδο, προσπαθούμε να ελαχιστοποιήσουμε την αντικειμενική συνάρτηση και να λάβουμε το μέσο τετραγωνικό σφάλμα (MSE) μεταξύ της εξόδου του καθαρού και της επιθυμητής παραγωγής ηλεκτρικής ζήτησης, χρησιμοποιώντας δυναμικό αλγόριθμο.

Ο κανόνας προσαρμογής βάρους στην επανάληψη εξαρτάται από το μέγεθος του βάρους στην προηγούμενη επανάληψη ως :

$$MSE = \frac{1}{2} \sum_{t=1}^T (\hat{y}_t - y_t)^2$$

όπου \hat{y}_t και y_t είναι τα προβλεπόμενα αποτελέσματα και η αναμενόμενη έξοδος του νευρωνικού δικτύου, αντίστοιχα. Αυτό έχει ως αποτέλεσμα να μπορεί να αποφευχθεί η παγίδευση στο τοπικό ελάχιστο και η τοποθέτηση σε επίπεδες επιφάνειες,



Σχήμα 2.8. Διάγραμμα ροής του προτεινόμενου αλγορίθμου για την πρόβλεψη φορτίου

Ο Αλγόριθμος Levenberg Marquardt (LM) είναι μια υπολογιστική προσέγγιση για προβλήματα εξόρυξης δεδομένων του NN που περιλαμβάνουν αβέβαιη δομή παραμέτρων. Για τις συγκεκριμένες περιπτώσεις πιο γνωστή είναι η μέθοδος Gaussi-Newton για συναρτήσεις μη μοναδικότητας (tansig) όπως η εξίσωση:

$$x^{k+1} = x^k + \Delta x, \quad k = 1, 2, \dots, N$$

όπου x^{k+1} , x^k και Δx αντιπροσωπεύουν την τρέχουσα κατάσταση, την ιστορική πρόσφατη κατάσταση και την απόκλιση με το χρονικό βήμα των χρονοσειρών. Η απόκλιση μπορεί να μοντελοποιηθεί στην έννοια του LM στην οποία οι Jacobians των σφαλμάτων εκπαιδεύουν κάθε κόμβο νευρωνικού δικτύου ως : $\Delta x = [J^T J + \eta I]^{-1} J^T MSE$, όπου τα J, η και MSE αντιπροσωπεύουν την πρώτη παράγωγο των σφαλμάτων σε σχέση με τη διαδικασία back propagation, το ποσοστό εκμάθησης (70%) και το μέσο τετράγωνο σφάλμα.

Αφού εξεταστούν τα βήματα τυποποίησης του LM στη διαδικασία διάδοσης, εφαρμόζεται η Bayesian Regularization (BR) για το πρόβλημα υπερβολικής προσαρμογής της κατανομής βάρους στο NN. Το BR φιλτράρει τα αμερόληπτα βάρη που επιλέγονται τυχαία. Επιπλέον, με τον προσδιορισμό τέτοιου βάρους που είναι οι λευκοί θόρυβοι του NN, οι βέλτιστες τιμές μπορούν να είναι πιο επιτεύξιμες από την προηγούμενη κατάστασή του. Όταν μειώνεται η πιθανότητα αμερόληπτων βαρών, η σύγκλιση της πρόβλεψης αυξάνεται μέχρι να στραφεί σε μια ανθεκτική υπολογιστική μονάδα έναντι των τοπικών βέλτιστων.

Στο βήμα της συζευγμένης κλιμακούμενης διαβάθμισης, το συζευγμένο εύρος χρησιμοποιείται για να μεγιστοποιήσει το χαρακτηριστικό βελτιστοποίησης της δυναμικής τεχνικής. Η έννοια του SCG βασίζεται στη διάταξη των συνολικών ελαχίστων του τετραγωνικού προβλήματος που στοχεύει στη μείωση της κλίσης των σφαλμάτων. Ένας τελεστή κλίσης χρησιμοποιείται, τόσο για τα σφάλματα, όσο και για τη διαβάθμιση των σφαλμάτων. Μετά τη διεξαγωγή των τεχνικών Bayesian Regularization και Levenberg Marquardt, το SCG αρχικοποιεί με το x_0 ως το κύριο σημείο του αλγορίθμου γραμμικής αναζήτησης για βάρη σύμφωνα με την εξίσωση: $x_0 \in R, f(x) \leq f(x_0)$.

Η συνδυαστική κλίση βρίσκεται με τις εξισώσεις:

$$\|\nabla f(x) - \nabla f(y)\| \leq L\|x - y\|$$

$$y = g_{k+1} - g_k$$

$$g_k = \nabla f(x_k)$$

όπου $\nabla f(x), \nabla f(y)$ είναι η διαβάθμιση του σφάλματος, η διαβάθμιση του σφάλματος των πινάκων βάρους καθώς και τα x και y είναι η απεικόνιση των βαρών εισόδου και L η διαβάθμιση σφάλματος. Η διαδικασία διάδοσης του SCG μπορεί να εκφραστεί από την ακόλουθη σειρά εξισώσεων:

$$x_{k+1} = x_k + \alpha_k d_k \rightarrow (\omega_{k+1} = \omega_k + \alpha_k d_k)$$

$$d_{k+1} = -\theta_{k+1} g_{k+1} + \beta_k s_k$$

$$\theta_{k+1} = \frac{s_k^T s_k}{y_k s_k}$$


$$s_k = x_{k+1} - x_k$$

Όπου d_k και α_k είναι ο μετρητής κατεύθυνσης και βημάτων της τεχνικής αναζήτησης. Όπως φαίνεται, η διαδικασία διάδοσης του SCG εξαρτάται πλήρως από τη βέλτιστη επιλογή του

α_k και του α_k . Αυτή η προϋπόθεση μας επιβάλλει ότι ο μετρητής βημάτων (α_k) πρέπει να καθοριστεί αρχικά για την επιτάχυνση της υπολογιστικής αναζήτησης.[6]

2.2.10 Ροή Ισχύος σε Συστήματα Διανομής

Μία άλλη εφαρμογή των μετα-ευρετικών αλγορίθμων είναι η για την εύρεση της βέλτιστης ροής ισχύος. Πιο συγκεκριμένα, ο αλγόριθμος ροής ισχύος backward-forward sweep (BFS) σε συστήματα διανομής είναι ένα καλό εργαλείο για την εύρεση της βέλτιστης ροής ισχύος. Στο Σχήμα 2.9 φαίνεται το σύστημα διανομής δειγμάτων για την προσέγγιση της σάρωσης προς τα εμπρός και προς τα πίσω της ροής ισχύος. Αναλυτικότερα, η ανάλυση ροής φορτίου των κατανεμημένων συστημάτων ισχύος χρησιμοποιείται για την εύρεση της τιμής ρεύματος του τροφοδότη, του μεγέθους και της γωνίας τάσης του διαύλου, των απωλειών ενεργού και αέργου ισχύος, της αξιολόγησης σταθερότητας τάσης και άλλων. Οι συμβατικές μέθοδοι ροής ισχύος Newton-Raphson και γρήγορης αποσύνδεσης αποτυγχάνουν στην εύρεση του σημείου λειτουργίας των συστημάτων διανομής λόγω Υψηλού λόγου R/X τροφοδότη, αδύναμων πλεγμένων συστημάτων διανομής, μη ισορροπημένου συστήματος. ο υπολογιστικός φόρτος και ο χρόνος υπολογισμού του αλγορίθμου BFS είναι χαμηλότερος από εκείνους των συμβατικών μεθόδων ροής ισχύος Newton-Raphson και γρήγορης αποσύνδεσης. Η μέθοδος ροής φορτίου BFS χρησιμοποιεί έναν πίνακα σύνθετης αντίστασης φορτίου για γρήγορο και υπολογιστικά αποδοτικό υπολογισμό του μεγέθους της τάσης του διαύλου σε ακτινικά και ασθενώς δικτυωτά πλέγματα διανομής.



Σχήμα 2.9 Σύστημα διανομής δειγμάτων για την προσέγγιση της σάρωσης προς τα εμπρός και προς τα πίσω της ροής ισχύος

Το ρεύμα που εισέρχεται στον i -στο κόμβο μπορεί να υπολογιστεί από την εξίσωση:

$$j_i^{k+1} = \left(\frac{\dot{S}_i}{\dot{V}_i} \right)^* - \dot{Y}_i \dot{V}_i^{(k)}$$

Όπου j_i^{k+1} είναι η έγχυση ρεύματος στον κόμβο i στην $(k + 1)$ -στη επανάληψη, $\dot{V}_i^{(k)}$ είναι η τάση του κόμβου i στην k -στη επανάληψη, \dot{S}_i είναι η έγχυση ισχύος του κόμβου i και \dot{Y}_i είναι η παράλληλη αγωγιμότητα του κόμβου i .

Στο βήμα της σάρωσης προς τα πίσω, το άθροισμα όλων των ρευμάτων που εγχέονται στον κλάδο i λαμβάνεται από την εξίσωση:

$$j_i^{k+1} = -j_i^{k+1} + \sum_{j \in C_i} j_j^{k+1}$$

όπου j_i^{k+1} είναι το Ρεύμα του κλάδου i στην $(k + 1)$ -στη επανάληψη και j_j^{k+1} είναι το Ρεύμα του κλάδου j στην $(k + 1)$ -στη επανάληψη.

Στο βήμα της σάρωσης προς τα εμπρός, σύμφωνα με το ληφθέν ρεύμα σε διαδικασία προς τα πίσω, η νέα τιμή της τάσης του διαύλου διαμορφώνεται από την εξίσωση:

$$\dot{V}_j^{k+1} = \dot{V}_i^{k+1} - j_j^{k+1} \times Z_j$$

Όπου Z_j είναι η εμπέδηση του κλάδου j , \dot{V}_i^{k+1} είναι η τάση του διαύλου i στην $(k + 1)$ -στη επανάληψη, \dot{V}_j^{k+1} είναι η τάση του διαύλου j στην $(k + 1)$ -στη επανάληψη. Για να οριστικοποιηθούν οι υπολογισμοί της ροής ισχύος, θα πρέπει να ικανοποιείται ο περιορισμός της συνολικής απώλειας ενεργού ισχύος. Οι συνολικές απώλειες ενεργού ισχύος δίνονται από την εξίσωση:

$$F_{loss} = \sum_{\substack{i,j=1 \\ i \neq j}}^{n_l} g_{i,j} [V_i^2 + V_j^2 - 2V_i V_j \cos(\theta_i - \theta_j)]$$

Όπου F_{loss} είναι η συνολική πραγματική απώλεια ισχύος ως αντικειμενική συνάρτηση, $g_{i,j}$ είναι η αγωγιμότητα του κλάδου από i σε j , V_i και V_j είναι το μέγεθος της τάσης των δεσμών i και j , θ_i και θ_j είναι η γωνία της τάσης των δεσμών i και j και n_l είναι ο συνολικός αριθμός κλάδων. [6]

Κεφάλαιο 3 Εφαρμογή μετα-ευρετικών αλγορίθμων στην συσταδοποίηση καμπυλών ηλεκτρικής ενέργειας

3.1 Εισαγωγή

Μία από τις σημαντικότερες εφαρμογές των μετα-ευρετικών αλγορίθμων είναι η συσταδοποίηση καμπυλών ηλεκτρικής ενέργειας. Οι ανάγκες των καταναλωτών για ηλεκτρική ενέργεια είναι διαφορετικές και επιπλέον αλλάζουν σε σχέση με το χρόνο, δηλαδή την μέρα και την ώρα. Οι καμπύλες ηλεκτρικής ενέργειας είναι οι γραφικές παραστάσεις της κατανάλωσης ηλεκτρικής ενέργειας από τους επιμέρους καταναλωτές συναρτήσει του χρόνου. Οι συγκεκριμένες καμπύλες είναι ιδιαίτερα χρήσιμες στην πρόβλεψη φορτίου επειδή μετά την ανάλυσή τους μπορούν να εκμαιευθούν δεδομένα όπως η μέγιστη και η ελάχιστη κατανάλωση ηλεκτρικής ενέργειας. Το σοβαρότερο πρόβλημα όμως είναι το πλήθος τους, το οποίο είναι ίσο με το πλήθος των καταναλωτών της περιοχής που αναλύεται. Αρκετές τεχνικές έχουν ερευνηθεί για την συσταδοποίηση των συγκεκριμένων καμπυλών έτσι ώστε να είναι πιο εύκολη η ανάλυση και με μικρότερες ανάγκες σε υπολογιστική ικανότητα. Ο στόχος της συσταδοποίησης είναι να συγκεντρώσει σε ομάδες πρότυπα με μεγάλο βαθμό ομοιότητας. Όσο μεγαλύτερος είναι αυτός ο βαθμός, τόσο πιο αποδοτική είναι η συσταδοποίηση.

Συνήθως το ζητούμενο είναι αν το σύνολο των συστάδων είναι ένθετο ή όχι, δηλαδή η συσταδοποίηση είναι ιεραρχική ή χωριζόμενη. Η ιεραρχική συσταδοποίηση μπορεί να θεωρηθεί ως μια ακολουθία χωριζόμενων ομαδοποιήσεων και μια χωριζόμενη ομαδοποίηση μπορεί να παρθεί λαμβάνοντας οποιοδήποτε μέλος αυτής της ακολουθίας, δηλαδή, κόβοντας το ιεραρχικό δέντρο σε ένα συγκεκριμένο επίπεδο.

Στην ασαφή συσταδοποίηση, κάθε αντικείμενο ανήκει σε κάθε συστάδα με βάρος μέλους που είναι μεταξύ (δεν ανήκει απολύτως) και 1 (ανήκει απολύτως). Με άλλα λόγια, οι συστάδες αντιμετωπίζονται ως ασαφή σύνολα. Επειδή τα βάρη ή οι πιθανότητες συμμετοχής για οποιοδήποτε αντικείμενο αθροίζονται στο 1, μια ασαφής ή πιθανολογική συσταδοποίηση δεν αντιμετωπίζει πραγματικές καταστάσεις πολλαπλών τάξεων. Αντ' αυτού, αυτές οι προσεγγίσεις είναι οι πλέον κατάλληλες για την αποφυγή της αυθαιρεσίας

της καταχώρησης ενός αντικειμένου σε ένα μόνο σύμπλεγμα, όταν μπορεί να είναι κοντά σε πολλά. [7]

Μία πλήρης συσταδοποίηση καταχωρεί κάθε αντικείμενο σε μία συστάδα, ενώ μια μερική ομαδοποίηση όχι. Μερικές φορές αντικείμενα ενός συνόλου δεδομένων δεν ανήκουν σε καλά ορισμένες ομάδες. Πολλές φορές τα αντικείμενα στα δεδομένα μπορεί να αντιπροσωπεύουν θόρυβο, ακραία δεδομένα ή αδιάφορο υπόβαθρο.

Κατά τη φάση της συσταδοποίησης ανεξάρτητα από τη μέθοδο και από τον αλγόριθμο που θα χρησιμοποιηθεί για να γίνει, οι συστάδες μπορούν να καταταγούν σε διαφορετικούς τύπους θα αναφερθούν στην συνέχεια.

Η καλά διαχωρίσιμη συστάδα περιλαμβάνει πρότυπα τα οποία είναι περισσότερο όμοια μεταξύ τους σε σχέση με τα άλλα πρότυπα που δεν ανήκουν στην συστάδα. Η απόσταση μεταξύ δύο σημείων σε διαφορετικές ομάδες είναι μεγαλύτερη από την απόσταση μεταξύ δύο σημείων μέσα σε μια ομάδα. Τα καλά διαχωρισμένα σμήνη δε χρειάζεται να είναι σφαιρικά, αλλά μπορούν να έχουν οποιοδήποτε σχήμα.

Μία συστάδα βασισμένη σε κάποια πρωτότυπη είναι μία συστάδα στην οποία ένα σύνολο αντικειμένων από τα οποία κάθε αντικείμενο είναι πιο κοντά (πιο παρόμοιο) με το πρωτότυπο που ορίζει η συστάδα παρά με το πρωτότυπο οποιασδήποτε άλλης συστάδας. Για δεδομένα με συνεχή χαρακτηριστικά, το πρωτότυπο ενός συμπλέγματος είναι συχνά ένα centroid, ο μέσος όρος όλων των σημείων του συμπλέγματος. Όταν ένα centroid δεν έχει νόημα, το πρωτότυπο είναι ένα medoid, το πιο αντιπροσωπευτικό σημείο μιας συστάδας.

Εάν τα δεδομένα αντιπροσωπεύονται ως γράφημα, όπου οι κόμβοι είναι αντικείμενα και οι σύνδεσμοι αντιπροσωπεύουν συνδέσεις μεταξύ αντικειμένων, τότε μία συστάδα μπορεί να οριστεί ως ένα συνδεδεμένο στοιχείο, δηλαδή, μια ομάδα αντικειμένων που συνδέονται μεταξύ τους, αλλά δεν έχουν καμία σχέση με αντικείμενα εκτός της ομάδας. Ένα παράδειγμα συστάδας το οποίο βασίζεται σε γράφημα είναι οι συστάδες που βασίζονται στη γειτονία, όπου δύο αντικείμενα συνδέονται μόνο εάν βρίσκονται σε συγκεκριμένη απόσταση μεταξύ τους.

Μία συστάδα είναι μια πυκνή περιοχή αντικειμένων που περιβάλλεται από μια περιοχή χαμηλής πυκνότητας. Ο ορισμός μίας συστάδας πυκνότητας χρησιμοποιείται συχνά όταν

οι ομάδες είναι ακανόνιστες ή αλληλένδετες και όταν υπάρχει θόρυβος και υπερβολικές τιμές.

Κάποιοι από τους αλγόριθμους που μελετήθηκαν είναι ο k-means, ο fuzzy c-means και ο SOM.

3.1.1 Συσταδοποίηση με τη χρήση του αλγορίθμου K-means

Ο k-means είναι μια τεχνική συσταδοποίησης η οποία προσπαθεί να βρει έναν αριθμό συστάδων οι οποίες καθορίζονται από το χρήστη (K). Το διάγραμμα ροής του αλγορίθμου K-means φαίνεται στο Σχήμα 3.1. Αυτές οι συστάδες αντιπροσωπεύονται από τα centroids τους. Για την εύρεση των centroids γίνεται χρήση της ευκλείδειας απόστασης μεταξύ του συνόλου. Το centroid της συστάδας είναι το κεντρικό της σημείο. Το centroid μπορεί ορίζεται με διάφορους τρόπους, όπως με τη μέση τιμή των αντικειμένων (ή σημείων) τα οποία έχουν ανατεθεί στη συστάδα.

Αναλυτικότερα για τον τρόπο λειτουργίας του συγκεκριμένου αλγορίθμου, αρχικά τα σημεία κατατάσσονται στα αρχικά centroids, τα οποία είναι ήδη μέσα στη μεγαλύτερη ομάδα σημείων. Αφού τα σημεία καταχωρηθούν σε ένα centroid, το centroid ενημερώνεται. Στη συνέχεια, τα σημεία καταχωρούνται στα ενημερωμένα centroid και τα centroids ενημερώνονται ξανά. Ο αλγόριθμος k-means τερματίζεται όταν δεν συμβαίνουν άλλες αλλαγές, επομένως τα centroid έχουν προσδιορίσει τις φυσικές ομαδοποιήσεις σημείων. Για να κατανεμηθεί ένα πρότυπο σε μία συστάδα θα πρέπει να χρησιμοποιηθεί μία μαθηματική συνάρτηση που εκφράζει το βαθμό ομοιότητας μεταξύ του προτύπου και του centroid της συστάδας.

Η διαφορά μεταξύ ενός αντικειμένου p το οποίο ανήκει στο υποσύνολο C_i και ενός αντικειμένου c_i , του αντιπροσωπευτικού της συστάδας, μετριέται από την $dist(p, c_i)$, όπου $dist(x, y)$ είναι η Ευκλείδεια απόσταση μεταξύ δύο σημείων x και y .

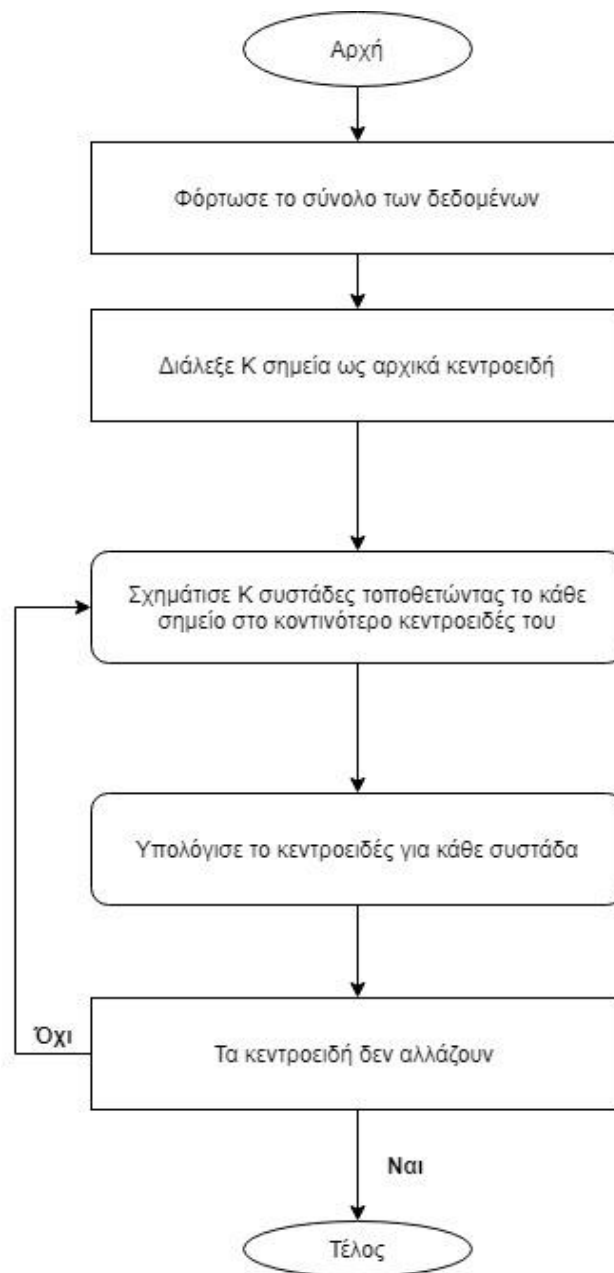
Η ποιότητα της συστάδας C_i μπορεί να μετρηθεί μέσω της ενδοσυσταδικής μεταβολής, η οποία είναι το άθροισμα του τετραγωνικού σφάλματος μεταξύ όλων των αντικειμένων στο C_i και το centroid c_i , ορίζεται ως :

$$E = \sum_{i=1}^k \sum_{p \in C_i} dist(\vec{p}, \vec{c}_i)$$

όπου E είναι το άθροισμα του τετραγωνικού σφάλματος για όλα τα αντικείμενα στο σύνολο δεδομένων. p είναι το σημείο στο χώρο που αντιπροσωπεύει ένα δεδομένο αντικείμενο. και c_i είναι το centroid της συστάδας C_i (τόσο το p όσο και το c_i είναι πολυδιάστατο).

Το centroid (μέσο) της i στοιβάδας ορίζεται από την εξίσωση :

$$\vec{c}_i = \frac{1}{m_i} \sum_{x \in C_i} x$$



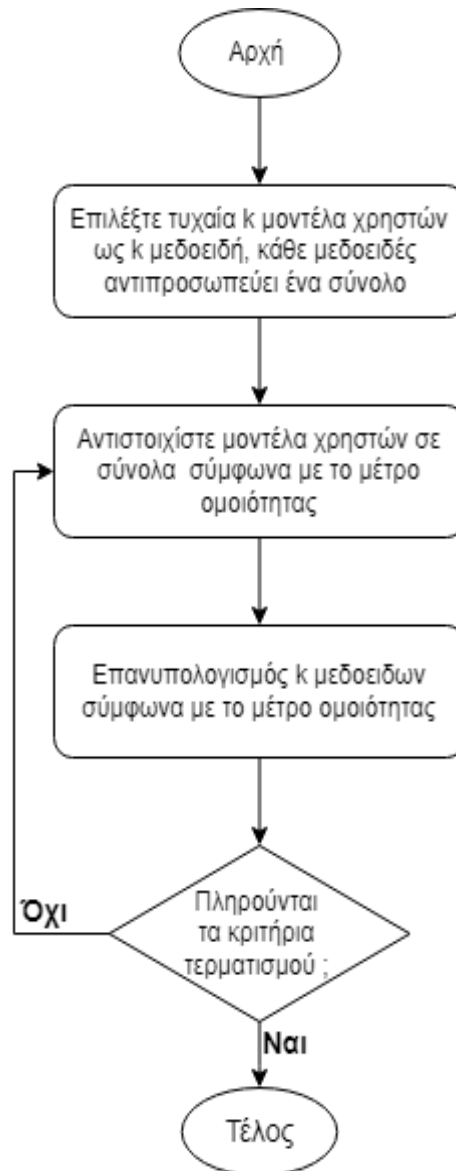
Σχήμα 3.1 Διάγραμμα ροής για τον αλγόριθμο k-means

Δηλαδή, για κάθε αντικείμενο σε κάθε συστάδα, η απόσταση από το αντικείμενο στο κέντρο της συστάδας τετραγωνίζεται και οι αποστάσεις αθροίζονται. Αυτή η αντικειμενική συνάρτηση προσπαθεί να κάνει τα συμπλέγματα k που προκύπτουν όσο πιο συμπαγή και όσο το δυνατόν πιο ξεχωριστά.

Είναι επίσης αρκετά αποτελεσματικός, παρόλο που συχνά χρειάζονται πολλαπλά τρεξίματα, για να βγάλει το επιθυμητό αποτέλεσμα. Η ανίχνευση και αφαίρεση αυτών των τιμών μπορεί να βοηθήσει σημαντικά σε τέτοιες καταστάσεις. Επιπλέον ο k -means περιορίζεται σε δεδομένα για τα οποία υπάρχει η έννοια του κέντρου ή centroid. Μια παρόμοια τεχνική, η k -medoid συσταδοποίηση, δεν έχει αυτόν τον περιορισμό και θα μελετηθεί αργότερα.[8]

3.1.2 Συσταδοποίηση με τη χρήση του αλγορίθμου K-medoids

Ο αλγόριθμος K-medoids είναι ένας αλγόριθμος ομαδοποίησης που σχετίζεται με τον αλγόριθμο K-means. Και οι δύο αλγόριθμοι είναι τμηματικοί και προσπαθούν να ελαχιστοποιήσουν το τετραγωνικό σφάλμα, την απόσταση μεταξύ των σημείων που βρίσκονται σε ένα σύνολο και ενός σημείου που ορίζεται ως το κέντρο αυτού του συνόλου. Ο K-Medoids αντί να λαμβάνει ως σημείο αναφοράς τη μέση τιμή των αντικειμένων ενός συνόλου, μπορεί να χρησιμοποιεί ένα medoid, το οποίο είναι το πιο κεντρικό αντικείμενο σε ένα σύνολο. Έτσι, η μέθοδος διαχωρισμού μπορεί ακόμα να εκτελεστεί με βάση την αρχή της ελαχιστοποίησης του αθροίσματος των διαφορών μεταξύ κάθε αντικειμένου και του αντίστοιχου σημείου αναφοράς του. Αυτό αποτελεί τη βάση της μεθόδου K-Medoids. Η βασική στρατηγική των αλγορίθμων ομαδοποίησης K-Medoids είναι να βρουν k συμπλέγματα σε n αντικείμενα βρίσκοντας πρώτα αυθαίρετα ένα αντιπροσωπευτικό αντικείμενο (τα Medoids) για κάθε σύνολο. Κάθε αντικείμενο που απομένει συγκεντρώνεται με το medoid με το οποίο μοιάζει περισσότερο. Η μέθοδος K-Medoids χρησιμοποιεί αντιπροσωπευτικά αντικείμενα ως σημεία αναφοράς αντί να παίρνει τη μέση τιμή των αντικειμένων σε κάθε σύμπλεγμα. Ο αλγόριθμος λαμβάνει την παράμετρο εισόδου k , τον αριθμό των συστάδων που θα κατανεμηθούν σε ένα σύνολο n αντικειμένων. Το διάγραμμα ροής του αλγορίθμου K-Medoids φαίνεται στο Σχήμα 3.2.



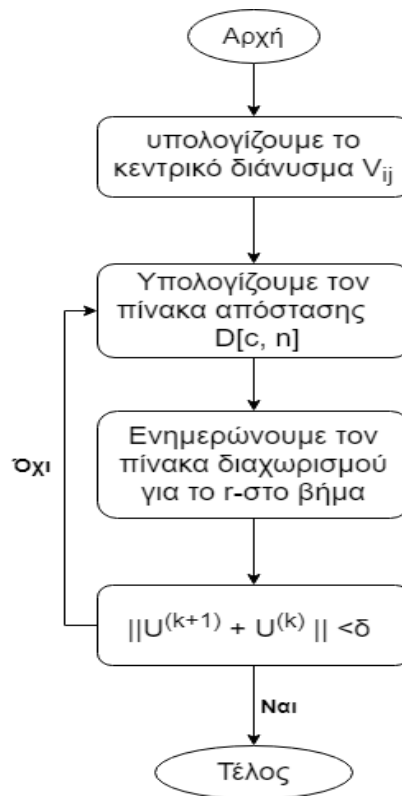
Σχήμα 3.2 Διάγραμμα ροής του αλγορίθμου K-medoids

3.1.3 Συσταδοποίηση με τη χρήση του αλγορίθμου Fuzzy c-means

Ο αλγόριθμος Fuzzy c-means (FCM) είναι ένα αλγόριθμος ομαδοποίησης χωρίς επίβλεψη που εφαρμόζεται σε μεγάλο εύρος προβλημάτων που σχετίζονται με την ανάλυση χαρακτηριστικών, την ομαδοποίηση και την ταξινόμηση. Ο FCM εφαρμόζεται ευρέως στη γεωργία, μηχανική, αστρονομία, χημεία, γεωλογία, ανάλυση εικόνας, ιατρική διάγνωση, ανάλυση σχήματος και αναγνώριση στόχου. Το διάγραμμα ροής του αλγορίθμου FCM φαίνεται στο Σχήμα 3.3.

Αυτός ο αλγόριθμος χρησιμοποιείται για ανάλυση με βάση την απόσταση μεταξύ διαφόρων σημείων εισόδων δεδομένων. Οι συστάδες σχηματίζονται ανάλογα με την

απόσταση μεταξύ των σημείων δεδομένων και κέντρα συστάδων δημιουργούνται για κάθε συστάδα. Επί της ουσίας είναι μία τεχνική συσταδοποίησης όπου ένα σετ δεδομένων ομαδοποιείται σε N ομάδες(συστάδες), με κάθε σημείο δεδομένων στο σύνολο δεδομένων να σχετίζεται με κάθε συστάδα και να συνδέεται καλύτερα με τα σημεία της συγκεκριμένης συστάδας και χειρότερα με τα σημεία μίας οποιασδήποτε άλλης συστάδας.



Σχήμα 3.3 Διάγραμμα ροής του αλγόριθμου FCM

Τα οποία υπολογίζονται από τους ακόλουθους τύπους :

$$v_{ij} = \frac{\sum_{k=1}^n (\mu_{ik})^m x_{kj}}{\sum_{k=1}^n (\mu_{ij})^m}$$

$$D_{ij} = \left(\sum_{j=1}^m (x_{kj} - v_{ij})^2 \right)^{1/2}$$

$$\mu_{ij}^{r-1} = \left(1 / \sum_{j=1}^c (d_{ik}^r / d_{jk}^r)^{2/m-1} \right)$$

Στα οποία :

c = αριθμός στοιβάδων με $2 \leq c = n$

U πίνακας διαχωρισμού

r = βήμα αλγόριθμου

m = παράμετρος τερματισμού ορισμένη από τον χρήστη

Η FCM μετακινεί επανειλημμένα τα κέντρα της συστάδας προς την βέλτιστη τοποθεσία μέσα σε ένα σύνολο δεδομένων. Επί της ουσίας, οι τεχνικές ομαδοποίησης FCM βασίζονται σε ασαφή συμπεριφορά. Ο FCM παίρνει ένα σύνολο δεδομένων και έναν επιθυμητό αριθμό συστάδων και επιστρέφει τα βέλτιστα κέντρα των συστάδων και βαθμούς συμμετοχής για κάθε σημείο δεδομένων. Ξεκινά με μια αρχική εικασία για τα κέντρα των συστάδων, τα οποία προορίζονται να σηματοδοτήσουν τη μέση θέση της καθεμίας συστάδας. Η αρχική υπόθεση για αυτά τα κέντρα συστάδων πολύ πιθανόν να είναι ανακριβής. Στη συνέχεια, ο FCM καταχωρεί σε κάθε σημείο δεδομένων ένα βαθμό συμμετοχής για κάθε συστάδα.

Με την επαναλαμβανόμενη ενημέρωση των κέντρων των συστάδων και των βαθμών συμμετοχής για κάθε σημείο δεδομένων, ο FCM μετακινεί επαναληπτικά το κέντρο της συστάδας στη βέλτιστη θέση μέσα στο σύνολο των δεδομένων. Αυτή η επανάληψη βασίζεται στην ελαχιστοποίηση της αντικειμενικής συνάρτησης που αντιπροσωπεύει την απόσταση από οποιοδήποτε δεδομένο σημείο δεδομένων σε μία κεντρικά σταθμισμένη συστάδα με το βαθμό συμμετοχής του σημείου δεδομένων.

Επομένως, η FCM συσταδοποίηση είναι μία επαναληπτική διαδικασία, η οποία σταματάει όταν φτάσει στον μέγιστο αριθμό επαναλήψεων ή όταν η βελτίωση της αντικειμενικής συνάρτησης μεταξύ δύο συνεχόμενων επαναλήψεων είναι μικρότερη από την προκαθορισμένη ελάχιστη τιμή βελτίωσης.[9]

3.1.4 Συσταδοποίηση με τη χρήση του αλγορίθμου Self-Organizing Map

Το Self-Organizing Map (SOM) είναι ένας ειδικός τύπος νευρωνικού δικτύου που μπορεί να μάθει από πολύπλοκα, πολυδιάστατα δεδομένα και να τα μετατρέψει σε οπτικά αποκρυπτογραφήσιμα σμήνη. Στο Σχήμα 3.4 φαίνεται το διάγραμμα ροής του αλγορίθμου SOM. Η θεωρία του δικτύου SOM βασίζεται στην παρατήρηση της λειτουργίας του

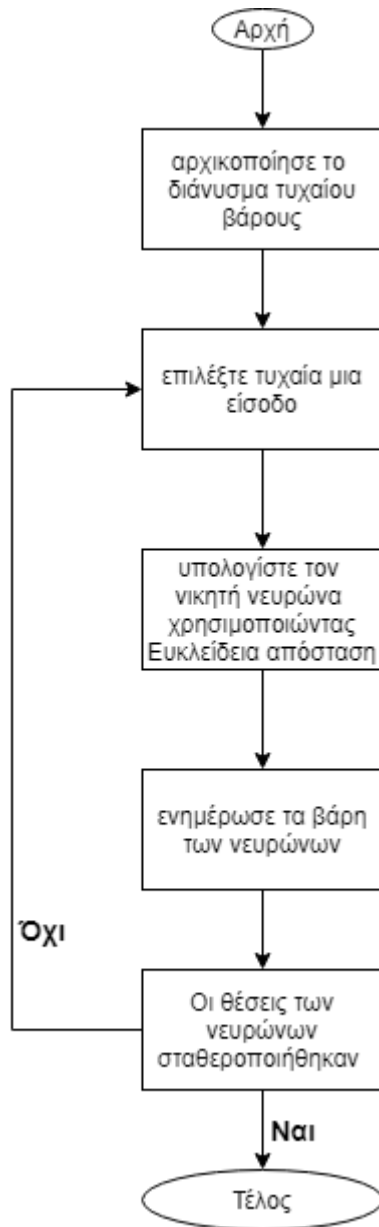
εγκεφάλου. Διάφορες ανθρώπινες αισθητηριακές εντυπώσεις είναι νευρολογικά χαρτογραφούνται στον εγκέφαλο έτσι ώστε χωρικές ή άλλες σχέσεις μεταξύ ερεθισμάτων αντιστοιχούν σε χωρικές σχέσεις μεταξύ των νευρώνων οργανωμένων σε ένα δισδιάστατο χάρτη. Η κύρια λειτουργία των δικτύων SOM είναι η χαρτογράφηση τα δεδομένα εισόδου από έναν χώρο n-διαστάσεων σε ένα διάγραμμα χαμηλότερης διάστασης διατηρώντας παράλληλα τις αρχικές τοπολογικές σχέσεις.

Η φυσική θέση των σημείων στο χάρτη δείχνει τη σχετική ομοιότητα μεταξύ των σημείων στον πολυδιάστατο χώρο. Σε αντίθεση με άλλες προσεγγίσεις νευρωνικών δικτύων, το δίκτυο SOM λειτουργεί χωρίς εποπτευόμενη εκπαίδευση, δηλαδή κατά τη διαδικασία εκμάθησης οι μονάδες επεξεργασίας στο δίκτυο προσαρμόζουν τα βάρη τους κυρίως με βάση τις πλευρικές συνδέσεις ανάδρασης. Η πιο κοινή προσέγγιση των νευρωνικών δικτύων απαιτούσε εποπτευόμενη εκπαίδευση του δικτύου. Αποκλίσεις από το σωστό αποτέλεσμα εξόδου οδηγούν στην προσαρμογή των βαρών των μονάδων επεξεργασίας. Από την άλλη, η μάθηση χωρίς επίβλεψη δεν απαιτεί τη γνώση των αξιών-στόχων. Οι κόμβοι στο δίκτυο συγκλίνουν για να σχηματίσουν συμπλέγματα τα οποία αντιπροσωπεύουν ομάδες οντοτήτων με παρόμοιες ιδιότητες. Ο αριθμός και η σύνθεση των συστάδων μπορεί να προσδιοριστεί οπτικά με βάση την κατανομή εξόδου που δημιουργείται από τη διαδικασία εκπαίδευσης.

Αναλυτικότερα, προβάλλει ένα σύνολο δεδομένων από M διανύσματα $x^{(m)}$ ενσωματωμένο σε H -διάστατο χώρο σε ένα σετ από C πρωτότυπα διανύσματα $u^{(c)}$. Το αρχικό διάνυσμα έχει τις ίδιες διαστάσεις με το αρχικό διάνυσμα δεδομένων, αλλά τοποθετείται σε χώρο χαμηλότερων διαστάσεων (συνήθως ένα δισδιάστατο πλέγμα). Το αρχικό διάνυσμα $u^{(c)}$ είναι μια μονάδα νευρωνικά ανταγωνιστικών στρωμάτων και μόνο μία μονάδα ανταποκρίνεται στην παρουσία κάθε εισόδου $x^{(m)}$. Η συνάρτηση ενεργοποίησης είναι μία αντίστροφη συνάρτηση του $d(x^{(m)}, u^{(c)})$. Η νικήτρια μονάδα στη συνέχεια ενημερώνεται ανάλογα με τη σχέση :

$$u_{new}^{(c)} = u_{old}^{(c)} + \eta(x^{(m)} - u_{old}^{(c)})$$

Όπου η είναι ο ρυθμός μάθησης.



Σχήμα 3.4 Διάγραμμα ροής του αλγόριθμου SOM

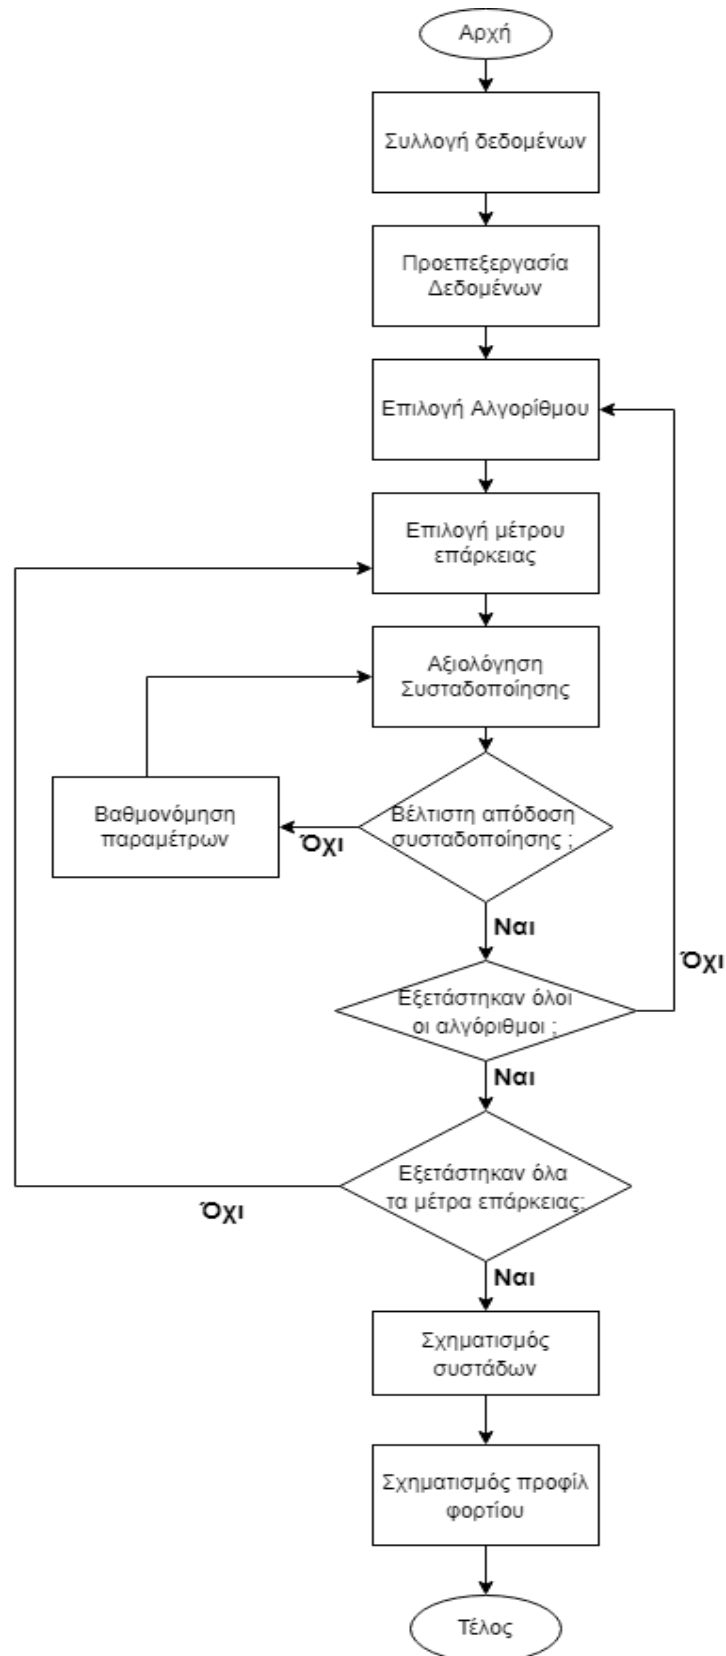
Η ικανότητα προβολής οφείλεται στο γεγονός ότι ο αλγόριθμος εκμάθησης εξετάζει επίσης τη θέση κάθε μονάδας $u(c)$ στον χώρο S -διάστασης και ενημερώνει όχι μόνο το βάρος της μονάδας που κερδίζει, αλλά και τα βάρη των κοντινών μονάδων της σε αντίστροφη αναλογία της απόστασης από αυτούς. Το μέγεθος της γειτονιάς κάθε μονάδας μειώνεται σταδιακά στη μαθησιακή διαδικασία, ξεκινώντας σχεδόν από ολόκληρο τον χάρτη και καταλήγοντας σε μια μεμονωμένη μονάδα. Έτσι, ο χάρτης οργανώνεται αυτόματα με τέτοιο τρόπο ώστε τα αντικείμενα που βρίσκονται κοντά να ταιριάζουν με τα παρόμοια μοτίβα στον αρχικό χώρο. Το γεγονός της διατήρησης της εγγύτητας των δεδομένων στον χώρο εισόδου και εξόδου έχει ως αποτέλεσμα την διατήρηση της

τοπολογίας του χώρου των δεδομένων. Όταν διενεργείται η μαθησιακή διαδικασία, τα δεδομένα κατατάσσονται σε σημεία υποδοχής(ενεργές μονάδες) τα οποία είναι περιτριγυρισμένα από δεδομένα τα οποία δεν νικούν στο διαγωνισμό του συνόλου δεδομένων εκπαίδευσης(νεκρές μονάδες. Ο SOM παράγει μια οπτικά κατανοητή προβολή των αρχικών δεδομένων στον χώρο μειωμένης διάστασης, αλλά όπως και άλλοι αλγόριθμοι προβολής, δεν είναι μια άμεση μέθοδος συσταδοποίησης. Ένας άλλος τρόπος της λήψης των συστάδων οι οποίες παράγονται από τον SOM είναι με οπτική επιθεώρηση του παραγόμενου χάρτη. [9],[10]

3.1.5 Συσταδοποίηση με τη χρήση του προτεινόμενου αλγορίθμου CL-DE

Η παρούσα εργασία παρουσιάζει έναν υβριδικό αλγόριθμο που αποτελείται από τον ιεραρχικό αλγόριθμο Complete Linkage (CL) και τον αλγόριθμο Differential Evolution (DE). Δηλαδή, συνδυάζει ιεραρχική ομαδοποίηση και μετα-ευρετική. Οι μετα-ευρετικοί αλγόριθμοι έχουν την ιδιότητα της τυχαίας αρχικοποίησης. Η συγκεκριμένη ιδιότητα έχει ως αποτέλεσμα όταν εκτελείται ο αλγόριθμος πολλές φορές τα αποτελέσματά του να είναι διαφορετικά. Αρχικά γίνεται χρήση του αλγορίθμου CL με σκοπό την αρχικοποίηση του χώρου αναζήτησης του αλγορίθμου DE. Το πρόβλημα της συσταδοποίησης δεδομένων φορτίου λύνεται ως πρόβλημα βελτιστοποίησης από τον προτεινόμενο αλγόριθμο. Με την χρήση μίας επαναληπτικής διαδικασίας, η συνάρτηση καταλληλότητας ελαχιστοποιείται. Η ποιότητα των δημιουργούμενων συστάδων εκφράζεται από την συνάρτηση καταλληλότητας. Η περίπτωση δοκιμής αναφέρεται στο συγκεντρωτικό φορτίο που συνδέεται με έναν μετασχηματιστή συστήματος διανομής που βρίσκεται στο ελληνικό σύστημα ηλεκτρικής ενέργειας. Διαμορφώνοντας συστάδες ημερήσιων καμπυλών φορτίου για μετασχηματιστές διανομής, οι έξοδοι της συσταδοποίησης μπορούν να παρέχουν εκμεταλλεύσιμες πληροφορίες σχετικά με την περιοδική μεταβολή των προτύπων ζήτησης (δηλαδή, ανά ημέρα, εβδομάδα, εποχή και έτος) και γενικά, να εμφανίζουν μακροσκοπική συμπεριφορά του συνολικού φορτίου που εξυπηρετεί ο υποσταθμός διανομής.[11]

Μια διαδικασία διαμόρφωσης προφίλ φορτίου περιλαμβάνει διάφορα βήματα, όπως φαίνονται στο Σχήμα 3.5.



Σχήμα 3.5 Διάγραμμα Ροής της διαδικασίας διαμόρφωσης καμπυλών ηλεκτρικού φορτίου

Αρχικά, οι ψηφιακοί μετρητές συλλέγουν τα δεδομένα φορτίου. Η ποιότητα και η ποσότητα των δεδομένων επηρεάζουν σε μεγάλο βαθμό τα αποτελέσματα. Γι' αυτόν τον λόγο σε λανθασμένες ή ακραίες τιμές δεδομένων ή σε ελλιπή δεδομένα είναι απαραίτητο να γίνεται προ-επεξεργασία ή ακόμα και αφαίρεσή τους από το σύνολο δεδομένων πριν γίνει η συσταδοποίηση τους. Επιπλέον για να δημιουργηθεί ένα ακριβές προφίλ φορτίου χρειάζεται ένας επαρκής όγκος δεδομένων. Σε γενικές γραμμές δεδομένα για την διάρκεια ενός έτους θεωρούνται ως η ελάχιστη αποδεκτή ποσότητα.

Το επόμενο βήμα είναι η αναπαράσταση δεδομένων. Σε αυτό το βήμα, τα αρχικά δεδομένα αλλάζουν μορφή με την χρήση κατάλληλων μαθηματικών μετασχηματισμών, έτσι ώστε να μπορούν να εφαρμοστούν σε αυτά αλγόριθμοι συσταδοποίησης. Έχουν χρησιμοποιηθεί δύο τεχνικές αναπαράστασης προκειμένου να διερευνηθεί πλήρως ο προτεινόμενος αλγόριθμος ομαδοποίησης. Η πρώτη τεχνική περιλαμβάνει την έκφραση των δεδομένων ως διανύσματα που περιέχουν την ισχύ. Κάθε καμπύλη ημερήσιου φορτίου εκφράζεται από ένα διάνυσμα D διαστάσεων:

$$p_m = [p_{m1}, \dots, p_{mD}]^T$$

Όπου $i = 1, 2, \dots, D$ είναι η διάσταση, $m = 1, 2, \dots, M$ είναι ο αριθμός των ημερήσιων καμπυλών φορτίου και T είναι ο τελεστής μεταφοράς. Το σύνολο των ημερήσιων καμπυλών συμβολίζεται ως $P\{p_m, m = 1, 2, \dots, M\}$.

Για την εφαρμογή της συσταδοποίησης, τα δεδομένα φορτίου που ορίζονται κανονικοποιούνται στην περιοχή $[0, 1]$, με διαίρεση κάθε p_m με μέγιστη τιμή του P , p_{\max} :

$$x_m = \frac{p_m}{p_{\max}}$$

Το σύνολο των κανονικοποιημένων δεδομένων συμβολίζεται ως:

$$X = \{x_m, m = 1, \dots, M\}$$

Η δεύτερη αναφέρεται δείκτες ισχύος (Power Indexes), ο m -στος τελεστής εκφράζεται ως:

$$x_{PI}^{(m)} = [p_1^{(m)}, p_2^{(m)}, p_3^{(m)}, p_4^{(m)}, p_5^{(m)}, p_6^{(m)}, p_7^{(m)}]^T$$

Ο αριθμός των Power Indexes (PI) είναι επτά και είναι οι ακόλουθοι:

$$p_1^{(m)} = p_{\max}^{(m)}$$

$$p_2^{(m)} = p_{\min}^{(m)}$$

$$p_3^{(m)} = p_D^{(m)}$$

$$p_4^{(m)} = \sqrt{\frac{1}{D} \sum_{j=1}^D (p_j^{(m)} - \bar{p}_D^{(m)})^2}$$

$$p_5^{(m)} = \sqrt{\frac{1}{V} \sum_{j=1}^V (p_j^{(m)} - \bar{p}_V^{(m)})^2}$$

$$p_6^{(m)} = \sqrt{\frac{1}{L} \sum_{j=9}^N (p_j^{(m)} - \bar{p}_L^{(m)})^2}$$

$$p_7^{(m)} = \sqrt{\frac{1}{P} \sum_{j=19}^{22} (p_j^{(m)} - \bar{p}_P^{(m)})^2}$$

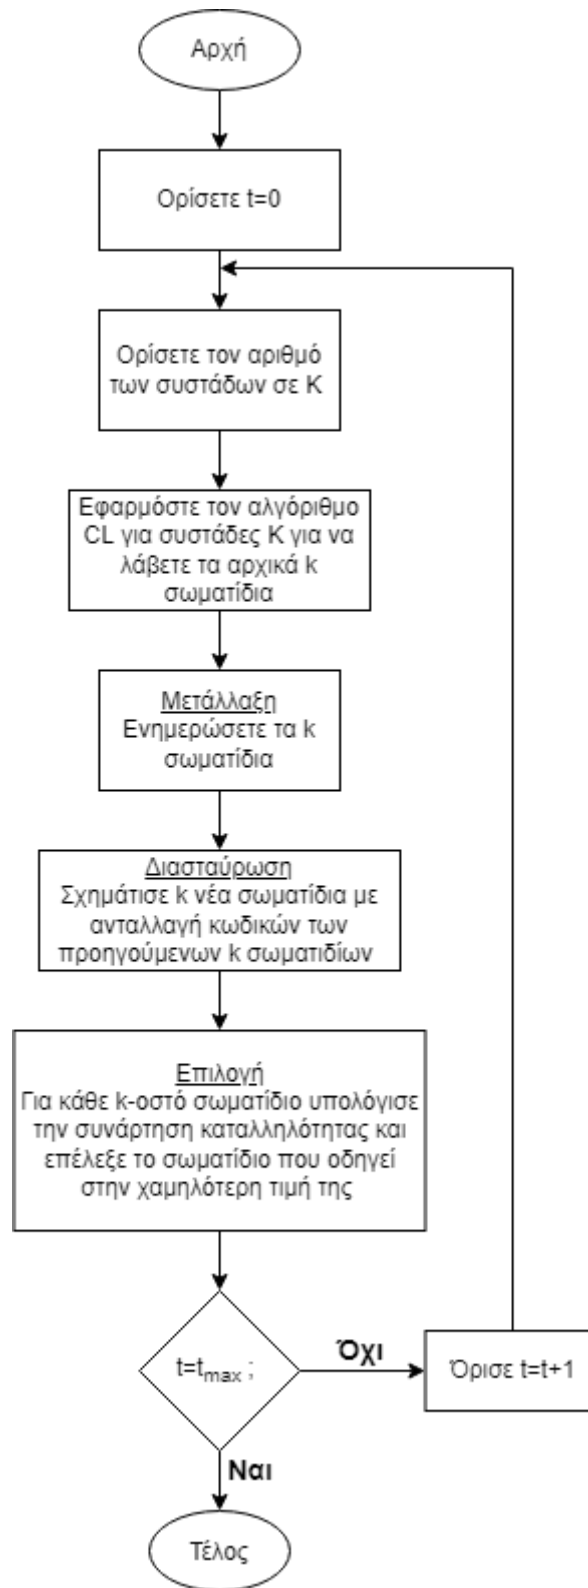
Επομένως υπάρχει μείωση διάστασης σε σύγκριση με την αναπαράσταση του τομέα χρόνου. Στην αναπαράσταση PI οι ημερήσιες τιμές ισχύος και οι τυπικές αποκλίσεις λαμβάνονται υπόψιν για τρεις συγκεκριμένες χρονικές περιόδους. Αυτές οι χρονικές περίοδοι είναι οι ώρες αιχμής, οι ώρες εκτός αιχμής και οι υπόλοιπες ώρες.

Το διάγραμμα ροής του προτεινόμενου αλγορίθμου CL-DE φαίνεται στο Σχήμα 3.6. Η δυνατότητα του DE να αρχικοποιείται με τυχαίο τρόπο, είναι δυνατόν να οδηγήσει σε λύση που δεν είναι βέλτιστη αφού ο αλγόριθμος μπορεί να συγκλίνει σε τοπικά βέλτιστη λύση. Οπότε γίνεται χρήση του αλγορίθμου CL για την αρχική συσταδοποίηση των δεδομένων. Ο CL χρησιμοποιείται για την εξαγωγή των αρχικών centroids. Τα αρχικά centroid είναι αυτά που θα αρχικοποιήσουν τον αλγόριθμο DE, ο οποίος θα παράγει την τελική συσταδοποίηση.

Το centroid εκφράζεται από ένα D-διάστατο διάνυσμα:

$$c^{(k)} = \{c_j^{(k)}, \dots, c_D^{(k)}\} = \frac{1}{M_K} \sum_{\substack{m=1 \\ x^{(m)} \in C_k}}^M x^{(m)}$$

Όπου M_k είναι ο αριθμός των διανυσμάτων που ανήκουν στην συστάδα C_k . Το σύνολο των συστάδων συμβολίζεται ως $C_k = \{c^{(k)}, k = 1, \dots, K\}$.



Σχήμα 3.6. Διάγραμμα ροής του υβριδικού αλγορίθμου CL-DE

Έστω d_{Eucl} η ευκλείδεια απόσταση. Ο αλγόριθμος αρχικά συσταδοποιεί τα δεδομένα με την ελαχιστοποίηση της ευκλείδειας απόστασης μεταξύ των καμπυλών ημερήσιου φορτίου και των centroids των συστάδων. Έστω J_k η αντικειμενική συνάρτηση. Εκφράζεται ως:

$$J_k = \sqrt{\sum_{i=1}^{M_k} x^{(k)} \in C_k d_{Eucl}(c^{(k)}, x^{(k)})}$$

Η θέση κάθε σωματιδίου του DE στο χώρο λύσης αντιστοιχεί σε μια τιμή του $c^{(k)}$. Το DE είναι ένας αλγόριθμος που βασίζεται στην επανάληψη. Ο στόχος είναι η ελαχιστοποίηση της συνάρτησης καταλληλότητας, μέσω μίας επαναληπτικής διαδικασίας.

3.2 Δείκτες αξιολόγησης συσταδοποίησης

Ο δείκτης αξιολόγησης συσταδοποίησης αναφέρεται σε μία μαθηματική συνάρτηση, η οποία κάνει αποτίμηση το πόσο καλά διαχωρισμένες είναι οι συστάδες ή το πόσο καλά συνεκτικές είναι οι συστάδες, δηλαδή το πόσο μεγαλύτερος είναι ο βαθμός ομοιότητας των προτύπων που ανήκουν στην ίδια συστάδα. Ορίζονται τα εξής:

- i. Η Ευκλείδεια απόσταση μεταξύ δύο διανυσμάτων $x^{(s)}$ και $x^{(t)}$, με $(x^{(s)}, x^{(t)}) \in X$ είναι:

$$d_{Eucl}(x^{(s)}, x^{(t)}) = \sqrt{\frac{1}{D} \sum_{h=1}^D (x_h^{(s)} - x_h^{(t)})^2}$$

- ii. Το υποσύνολο του X που ανήκει στη συστάδα C_k συμβολίζεται ως S_k . Η ευκλείδεια απόσταση μεταξύ του centroid $c^{(k)}$ και του k -οστού συμπλέγματος και του υποσυνόλου S_k είναι ο γεωμετρικός μέσος όρος των ευκλείδειων αποστάσεων $d(c^{(k)}, S_k)$ ανάμεσα στο $c^{(k)}$ και το κάθε μέλος $x^{(k)}$ του S_k :

$$d(c^{(k)}, S_k) = \sqrt{\frac{\sum_{i=1}^{M_k} x^{(k)} \in S_k d_{Eucl}^2(c^{(k)}, x^{(k)})}{M_k}}$$

- iii. Ο γεωμετρικός μέσος όρος των εσωτερικών αποστάσεων μεταξύ των χαρακτηριστικών μελών του υποσυνόλου S_k είναι:

$$d_{Eucl}(S_k) = \sqrt{\frac{1}{2M_k} \sum_{x^{(k)} \in S_k} d_{Eucl}^2(x^{(k)}, x^{(m)})}$$

Ο Δείκτης Διασποράς Συστάδων (CDI), είναι ο λόγος της μέσης απόστασης μεταξύ των διανυσμάτων εισόδου στην ίδια συστάδα και της απόστασης μεταξύ των centroids των συστάδων:

$$CDI = \frac{\sqrt{\frac{1}{K} \sum_{k=1}^K d_{Eucl}^2(S_k)}}{\sqrt{\frac{1}{2K} \sum_{k=1}^K d_{Eucl}^2(c^{(k)}, C_k)}}$$

Ο Δείκτης Σκέδασης (SI), σχετίζεται με τις αποστάσεις μεταξύ των μελών των συστάδων και των centroids και τον αριθμητικό μέσο όρο:

$$SI = \frac{\sum_{m=1}^M d_{Eucl}^2(x_m, p)}{\sum_{k=1}^K d_{Eucl}^2(c_k, p)}$$

όπου p είναι ο αριθμητικός μέσος όρος του συνόλου X .

Ο Δείκτης Πίνακα Ομοιότητας (SMI), ορίζεται ως:


$$SMI = \max_{s>t} \left\{ \left(1 - \frac{1}{\ln[d_{Eucl}(c_s, c_t)]} \right)^{-1} \right\}; s, t = 1, \dots, M$$

Ο δείκτης Davies-Bouldin (DBI), συσχετίζει τη μέση απόσταση κάθε συστάδας με την απόσταση από την πλησιέστερη συστάδα:

$$DBI = \frac{1}{K} \sum_{s,t=1}^K \max_{s \neq t} \left\{ \frac{\hat{d}_{Eucl}(C_s) + \hat{d}_{Eucl}(C_t)}{d_{Eucl}(c_s, c_t)} \right\}$$

3.3 Αποτελέσματα


Η περίπτωση δοκιμής περιλαμβάνει το συγκεντρωτικό φορτίο ενός μετασχηματιστή διανομής υψηλής έως μέσης τάσης που βρίσκεται στο ελληνικό ενεργειακό σύστημα. Η περίοδος των δεδομένων αναφέρεται σε ένα έτος. Το Σχήμα 3.7 δείχνει τη χρονοσειρά φορτίου του μετασχηματιστή. Προκειμένου να επαληθευτεί η ευρωστία του προτεινόμενου αλγορίθμου, πραγματοποιείται σύγκριση λαμβάνοντας υπόψη τους αλγορίθμους K-means, K-medoids, FCM, Ward και SOM.




Σχήμα 3.7 Χρονοσειρές φορτίου του υπό μελέτη μετασχηματιστή διανομής

Για το συγκεκριμένο σύνολο δεδομένων δεν είναι γνωστές εκ των προτέρων πληροφορίες σχετικά με τον αριθμό των συστάδων. Κάθε αλγόριθμος εκτελείται ξεχωριστά για 3 έως και 30 συστάδες.


Τα Σχήματα 3.8-3.11 παρουσιάζουν τις τιμές των CDI, SI, SMI και DBI, αντίστοιχα, λαμβάνοντας υπόψη την αναπαράσταση του πεδίου χρόνου. Ένας αλγόριθμος θεωρείται ότι κερδίζει στη σύγκριση όταν οδηγεί σε χαμηλότερες τιμές ενός δείκτη στις περισσότερες , εάν όχι στο σύνολο των συστάδων. Αν οι παραγόμενες συστάδες είναι συμπαγείς και καλά διαχωρισμένες η διαδικασία της συσταδοποίησης θεωρείται καλή. Το συμπαγές μέγεθος αντιστοιχεί στον βαθμό που υποδηλώνει πόσο κοντά είναι οι καμπύλες φορτίου μέσα στην ίδια συστάδα και οι καμπύλες φορτίου στα centroids. Μία συμπαγής συστάδα εμφανίζει μικρές εσωτερικές αποστάσεις, δηλαδή, τα μέλη της συστάδας είναι κοντά το ένα στο άλλο. Αυτό σημαίνει ότι παρουσιάζουν μεγάλη ομοιότητα.



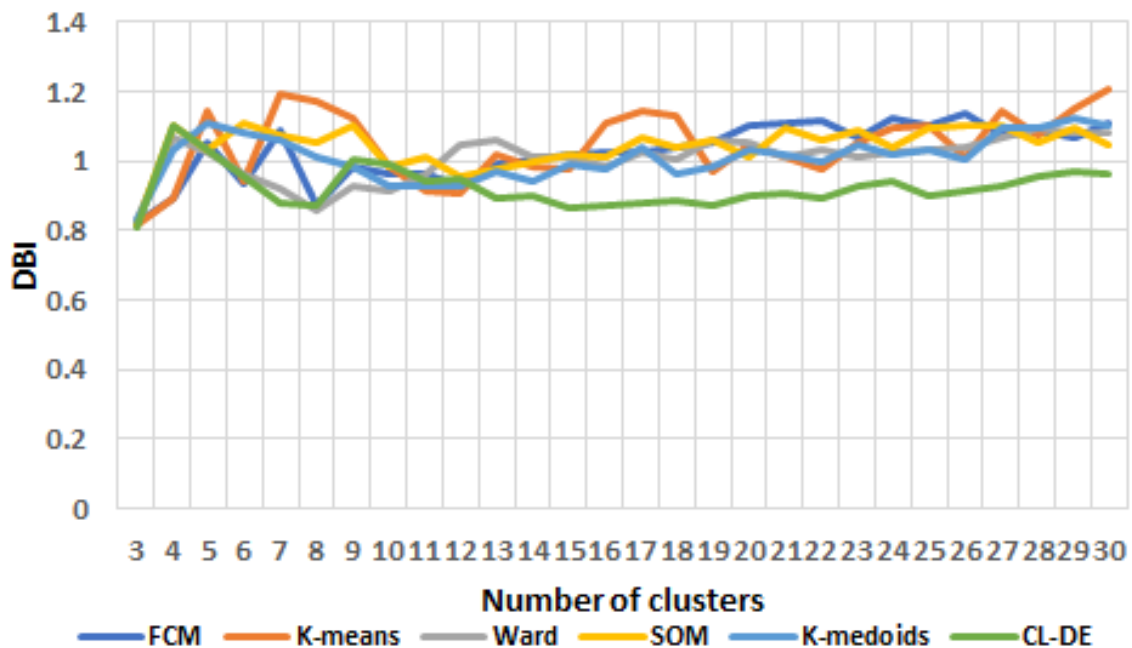
Σχήμα 3.8 Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη CDI σε σχέση με τον αριθμό των συστάδων



Σχήμα 3.9. Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη SI σε σχέση με τον αριθμό των συστάδων



Σχήμα 3.10 Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη SMI σε σχέση με τον αριθμό των συστάδων




Σχήμα 3.11. Σύγκριση των αλγορίθμων που εξετάστηκαν μέσω του δείκτη DBI σε σχέση με τον αριθμό των συστάδων.

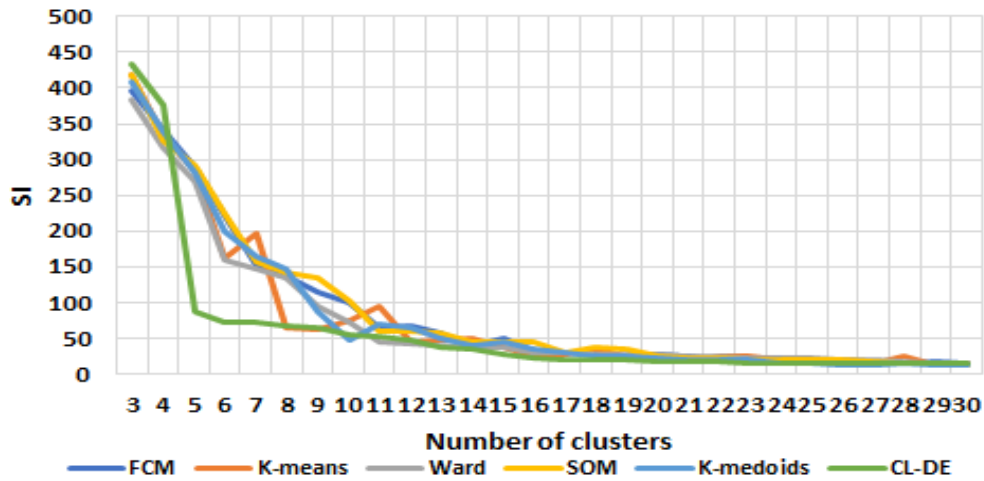
Το CDI είναι ένας δείκτης ο οποίος δείχνει το πόσο συμπαγείς και διαχωρισμένες είναι οι παραγόμενες συστάδες. Οι τιμές του CDI μειώνονται όταν αυξάνεται το πλήθος των συστάδων. Στο Σχήμα 3.11 φαίνεται ότι η απόδοση του CL-DE είναι καλύτερη συγκριτικά

με την απόδοση των υπολοίπων αλγορίθμων. Αρκετά καλή απόδοση φαίνεται ότι έχει και ο αλγόριθμος Ward. Η καλή του απόδοση εμφανίζεται σε χαμηλές τιμές του SI, κάτι το οποίο συμβαίνει και στην εξέταση του δείκτη CDI. Όμως ο αλγόριθμος CL-DE οδηγεί ξανά σε καλύτερη συσταδοποίηση από τους υπόλοιπους αλγορίθμους. Η συμπεριφορά των δεικτών SMI και το DBI είναι ιδιαίτερα ασταθής. Ένας ισχυρός αλγόριθμος συσταδοποίησης είναι απαραίτητο να εμφανίζει όσο το δυνατόν μικρότερες διακυμάνσεις αυτών των δεικτών για το διαφορετικό αριθμό συστάδων. Από τον δείκτη SMI φαίνεται ότι ο αλγόριθμος CL-DE οδηγεί σε μικρότερες τιμές για τις περισσότερες συστάδες. Από τον δείκτη DBI φαίνεται ότι ο αλγόριθμος CL-DE οδηγεί σε καλύτερη απόδοση.


Στα Σχήματα 3.12-3.15 παρουσιάζονται οι τιμές των δεικτών CDI, SI, SMI και DBI, αντίστοιχα, λαμβάνοντας υπόψη την αναπαράσταση των δεικτών ισχύος (Power Indexes→PI). Τα PI αντιστοιχούν σε υψηλότερες τιμές των δεικτών σε σχέση με την αναπαράσταση η οποία λαμβάνει υπόψη την ισχύ. Όμως, εάν ληφθεί υπόψη η διάσταση, η χρήση τους είναι ιδανική, αφού τα δεδομένα εκφράζονται με 7 τιμές σε σχέση με τις 24 τιμές που περιλαμβάνονται στην αναπαράσταση του πεδίου του χρόνου. Ο μικρότερος αριθμός απαιτούμενων τιμών έχει ως αποτέλεσμα μικρότερο χρόνο εκτέλεσης του αλγορίθμου. Γενικά, ο αλγόριθμος CL-DE οδηγεί σε καλύτερα αποτελέσματα σε σχέση με τους υπόλοιπους και στην αναπαράσταση των PI. Στην περίπτωση του δείκτη DBI, για κάποιον αριθμό συστάδων οι αλγόριθμοι Ward και K-medoids έχουν ως αποτέλεσμα χαμηλότερη τιμή για τον συγκεκριμένο δείκτη. Είναι επίσης ιδιαίτερα εμφανές ότι ο δείκτης DBI υψηλότερες μεταβολές για το σύνολο των αλγορίθμων ειδικά εάν συγκριθεί και με την αναπαράσταση που περιλαμβάνει την ισχύ.




Σχήμα 3.12 Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση CDI και PI



Σχήμα 3.13 Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση SI και PI




Σχήμα 3.14 Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση SMI και PI



Σχήμα 3.15 Σύγκριση των αλγορίθμων λαμβάνοντας υπόψη την αναπαράσταση DBI και PI

Με την εφαρμογή της knee-point detection method στο δείκτη CDI που παράγεται από τον αλγόριθμο CL-DE, εξάγεται ο ιδανικός αριθμός συστάδων.

Ο βέλτιστος αριθμός είναι 7. Το Σχήμα 3.16 απεικονίζει τα προφίλ φορτίου των 7 συστάδων. Στον Πίνακα 3.1 φαίνεται η κατανομή του τύπου ημέρας ανά συστάδα. Το προφίλ#3 είναι μία συστάδα η οποία περιλαμβάνει 1 μέλος. Η συστάδα#1 και η συστάδα#7 περιλαμβάνουν 2 μέλη. Η συστάδα#5 περιλαμβάνει τα περισσότερα μέλη. Οι συστάδες #2 και #5 περιλαμβάνουν ημέρες κάθε τύπου.



Σχήμα 3.16 Προφίλ φορτίου του υπό μελέτη μετασχηματιστή διανομής

Πίνακας 3.1 Κατανομή τύπου ημέρας ανά συστάδα

Συστάδα	Αριθμός μερών ανά Συστάδα						
	Δευτέρα	Τρίτη	Τετάρτη	Πέμπτη	Παρασκευή	Σάββατο	Κυριακή
1	0	0	1	0	0	1	0
2	17	2	21	24	22	22	22
3	0	0	0	0	1	0	0
4	1	11	1	0	1	1	0
5	33	31	27	28	28	29	29

6	1	1	0	0	0	0	0
7	0	8	2	0	0	0	1

Κεφάλαιο 4 Χρήση τεχνητών νευρωνικών δικτύων για την κατάλληλη επιλογή εισόδων

4.1 Εισαγωγή

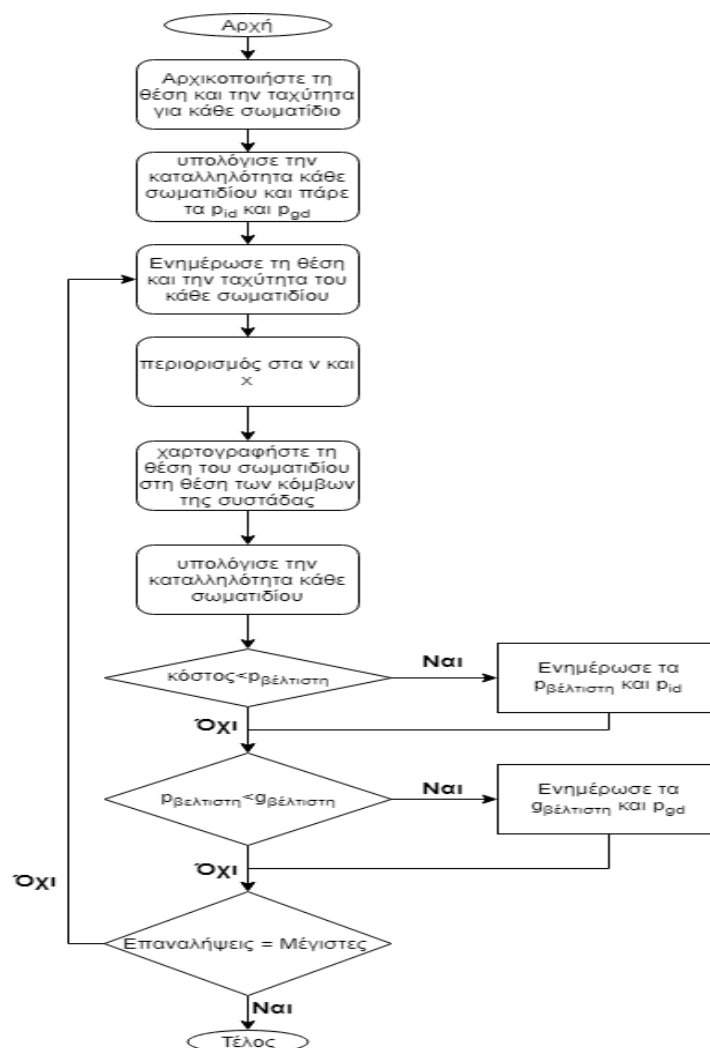
Γενικά, τα μοντέλα χρονοσειρών, τα οποία χρησιμοποιούν προηγούμενη γνώση και μηχανική μάθηση, αναφέρονται ως τεχνητά νευρωνικά δίκτυα και ασαφή συστήματα. Τα μοντέλα χρονοσειρών απαιτούν έναν εκ των προτέρων ορισμό του σειρά/τύπος μοντέλου. Ο ορισμός απαιτεί τη χρησιμοποίηση συνόλου μαθηματικών κριτηρίων που εξετάζουν διάφορα χαρακτηριστικά των χρονικών σειρών όπως η τάση, η στασιμότητα, κυκλικό μοτίβο, εποχικότητα και άλλα. Επιπλέον, η μηχανική μάθηση ορίζει αυτόματα τη σειρά/τύπο του μοντέλου μέσω της κατάρτισης, δηλαδή χρησιμοποιώντας τα πρότυπα κατάρτισης. Πολλά μοντέλα μηχανικής μάθησης αναφέρονται ως Τεχνητά Νευρωνικά δίκτυα (ANN → Artificial Neural Network) διαφόρων τύπων, που οδηγούν στο συμπέρασμα ότι το ANN είναι μια κοινώς χρησιμοποιούμενη προσέγγιση πολλές μελέτες πρόβλεψης φορτίου. Μόλις το νευρωνικό δίκτυο είναι επαρκώς εκπαιδευμένο μπορεί να χρησιμοποιηθεί περαιτέρω σε εκτός δείγματος προβλέψεις. Ένα ANN παρέχει την ευελιξία να είναι σε συνδυασμό με άλλα μοντέλα. Επιπλέον, σε ορισμένες μελέτες πρόβλεψης, ένα μοντέλο μπορεί να περιλαμβάνει προεπεξεργασία δεδομένων ή στάδια μετασχηματισμού χρησιμοποιώντας εμπειρικό τρόπο αποσύνθεσης, διακριτό μετασχηματισμό κυματιδίων και άλλα. Ένα ANN αποτελείται από καταναμημένα στοιχεία επεξεργασίας που είναι συντονισμένα με τέτοιο τρόπο που μπορούν και παρέχουν προσεγγίσεις συναρτήσεων. Το ANN αναφέρεται στη μοντελοποίηση μαύρου κουτιού, δηλαδή στην αρχική δομή του δικτύου που είναι εκ των προτέρων άγνωστη. Μέσα από τη διαδικασία μάθησης, το ANN ενημερώνει τα βάρη του μεταξύ των νευρώνων με σκοπό την ελαχιστοποίηση μιας συνάρτησης κόστους. Το τελευταίο συνήθως αναφέρεται στην απόλυτη διαφορά μεταξύ της επιθυμητής εξόδου και αυτής που παρέχεται από το ίδιο το δίκτυο. Εκτός από θέματα σχεδιασμού όπως ο αριθμός κρυφών στρωμάτων, ο αριθμός νευρώνων στο κρυφό στρώμα, η λειτουργία σύνδεσης (δηλαδή πλήρως ή μερικές συνδέσεις), η λειτουργία ενεργοποίησης νευρώνων, η εκπαίδευση αλγορίθμου και άλλοι, κρίσιμο ρόλο κατέχουν επίσης οι τύποι και αριθμός εισόδων. Οι εισοδοί είναι συγκεκριμένες για το πρόβλημα. Γενικά, η επιλογή του αριθμού και των τύπων εισόδων βασίζεται στην εξειδίκευση, στην

έρευνα βιβλιογραφίας ή στον συνδυασμό και των δυο.

4.2 Περιγραφή Αλγορίθμων Βέλτιστης Επιλογής Εισόδων

4.2.1 Χρήση του αλγορίθμου PSO για την επιλογή εισόδων

Ο αλγόριθμος βελτιστοποίησης σμήνους σωματιδίων (PSO) είναι ένας αλγόριθμος που βασίζεται στον πληθυσμό, δηλαδή στη γνωστική και κοινωνική συμπεριφορά του σμήνους. Ο PSO εκμεταλλεύεται τον πληθυσμό των ατόμων για να διερευνήσει τις πολλά υποσχόμενες περιοχές του χώρου αναζήτησης. Σε αναλογία με τις εξελικτικές μεθόδους υπολογισμού, ένα σμήνος είναι παρόμοιο με τον πληθυσμό και ένα σωματίδιο είναι παρόμοιο με ένα άτομο. Ο PSO ακολουθεί μία στοχαστική μέθοδο βελτιστοποίησης βασισμένη στην Ευφυΐα του Σμήνους. Το διάγραμμα ροής του αλγορίθμου PSO φαίνεται στο Σχήμα 4.1.



Σχήμα 4.1 Διάγραμμα ροής του αλγορίθμου PSO

Η βασική ιδέα είναι ότι κάθε σωματίδιο αντιπροσωπεύει μία πιθανή λύση την οποία ενημερώνει ανάλογα με τις εμπειρίες του και των γειτόνων του. Ο PSO αναζητά ταυτόχρονα για πολλές λύσεις χρησιμοποιώντας μία ομάδα σωματιδίων. Τα άτομα ή τα σωματίδια ενός σμήνους, προσεγγίζουν το βέλτιστο μέσω της τρέχουσας ταχύτητας τους, της προηγούμενης εμπειρίας τους και της εμπειρίας των γειτόνων τους. Ο PSO ψάχνει τον τομέα του προβλήματος προσαρμόζοντας τις τροχιές των κινούμενων σωματιδίων στον πολυδιάστατο χώρο. Η κίνηση των μεμονωμένων σωματιδίων για την εύρεση της βέλτιστης λύσης ρυθμίζεται μέσω των αλληλεπιδράσεων της θέσης και της ταχύτητας του κάθε σωματιδίου, την δικιά του καλύτερη προηγούμενη απόδοση και αυτής των γειτόνων του. Για ένα σμήνος n σωματιδίων το i -στο σωματίδιο αντιπροσωπεύεται από μια θέση που συμβολίζεται ως $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$ όπου n είναι ο αριθμός των σωματιδίων. Εκτός από τη θέση, κάθε σωματίδιο του σμήνους αναπαρίσταται σε τρισδιάστατο χώρο με ταχύτητα $v_i = (v_{i1}, v_{i2}, \dots, v_{in})$. Τα σωματίδια εξερευνούν το χώρο αναζήτησης με ταχύτητα η οποία δυναμικά προσαρμόζεται ανάλογα με τη δικιά του επίδοση και αυτής του γείτονά του. Η τυπική μέθοδος PSO ενημερώνει την ταχύτητα και τη θέση κάθε σωματιδίου σύμφωνα με τις εξισώσεις που δίνονται παρακάτω.

$$v_{id}(t + 1) = \omega \cdot v_{id}(t) + c_1 \cdot rand() \cdot (p_{id} - x_{id}) + c_2 \cdot rand() \cdot (p_{gd} - x_{id})$$

$$x_{id}(t + 1) = v_{id}(t + 1) + x_{id}(t)$$

Όπου c_1 και c_2 είναι 2 θετικές σταθερές επιτάχυνσης, $rand()$ είναι ένας ομοειδής τυχαίος αριθμός που ανήκει στο διάστημα $(0, 1)$, p_{id} και p_{gd} είναι οι καλύτερες θέσεις που έχουν βρεθεί μέχρι στιγμής από το i -οστό σωματίδιο και γενικά από όλα τα σωματίδια, t είναι ο αριθμός της επανάληψης ω : είναι ένας βάρους αδράνειας το οποίο μειώνεται γραμμικά κατά τη διάρκεια των επαναλήψεων.

Το βάρους αδράνειας ω παίζει το ρόλο εξισορρόπησης της τοπικής και ολικής αναζήτησης.

Για την εξίσωση της ταχύτητας, το πρώτο μέρος δείχνει την τρέχουσα ταχύτητα του σωματιδίου δηλαδή την παρούσα κατάσταση, το δεύτερο μέρος δείχνει τη σκέψη του ίδιου του σωματιδίου και το τρίτο μέρος είναι ένας κοινωνικός όρος που δείχνει το ικανότητα ανταλλαγής πληροφοριών μεταξύ των σμηνών.


Τα πλεονεκτήματα του PSO αλγορίθμου είναι ότι είναι πολύ γρήγορος στην εκτέλεση, απλός και εύκολος στην κατανόηση και στην υλοποίηση. Επιπλέον πολύ λίγες παράμετροι

χρειάζονται ρύθμιση και απαιτεί ελάχιστη μνήμη για τον υπολογισμό. Όμως έχει και τα μειονεκτήματα του, ο PSO δίνει καλά αποτελέσματα και ακρίβεια για βελτιστοποίηση ενός στόχου, αλλά για πρόβλημα πολλαπλών στόχων κολλάει στα τοπικά βέλτιστα. Η φύση του για γρήγορη και πρόωρη σύγκλιση στα τοπικά βέλτιστα σημεία.[9],[12]

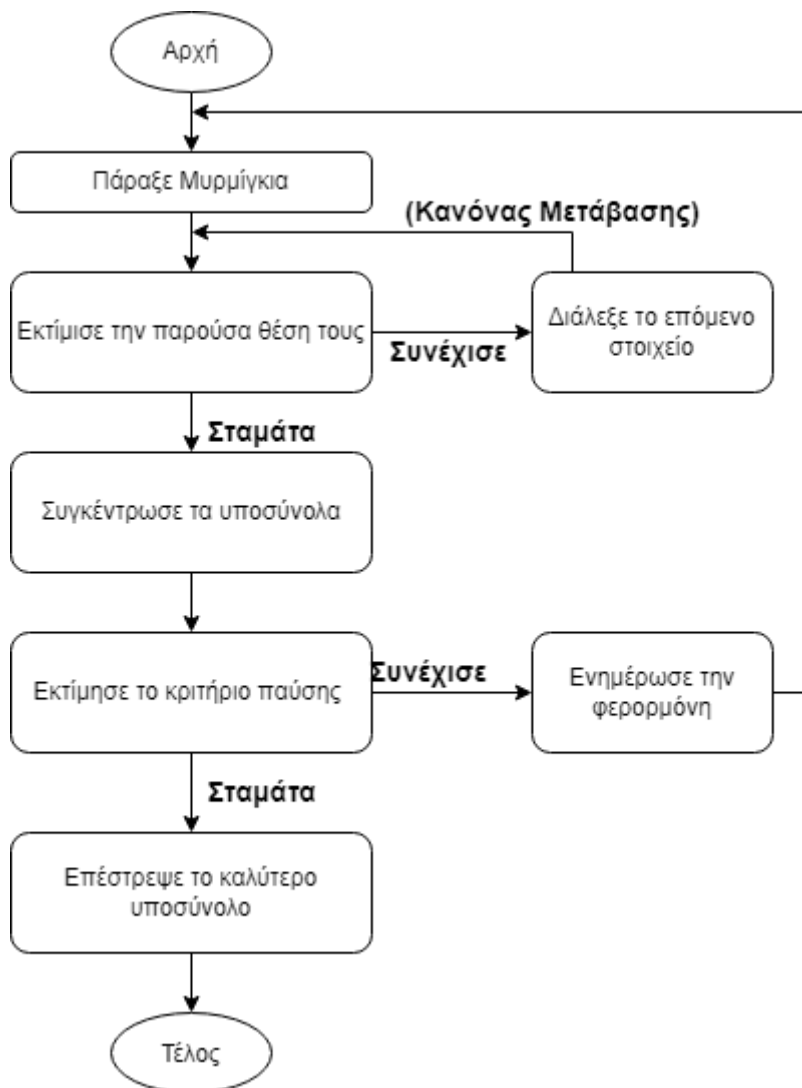
4.2.2 Χρήση του αλγορίθμου ACO για την επιλογή εισόδων

Ο αλγόριθμος Ant Colony Optimization (ACO) είναι ένας εμπνευσμένος από τη φύση μετα-ερευνητικός αλγόριθμος για την επίλυση προβλημάτων δύσκολης συνδυαστικής βελτιστοποίησης (CO) και χρησιμοποιούνται για την απόκτηση αρκετά καλών λύσεων σε εύλογο χρονικό διάστημα υπολογισμού. Η ικανότητα των πραγματικών μυρμηγκιών να βρίσκουν τις συντομότερες διαδρομές οφείλεται κυρίως στην εναπόθεσή τους φερομόνης καθώς ταξιδεύουν, κάθε μυρμηγκί προτιμά πιθανώς να ακολουθεί μια κατεύθυνση πλούσια σε αυτή τη χημική ουσία. Η φερομόνη διασπάται με την πάροδο του χρόνου, με αποτέλεσμα πολύ λιγότερη φερομόνη σε λιγότερο δημοφιλή μονοπάτια. Δεδομένου ότι με την πάροδο του χρόνου η συντομότερη διαδρομή θα έχει τον υψηλότερο ρυθμό διέλευσης μυρμηγκιών, αυτό το μονοπάτι θα ενισχυθεί και τα άλλα θα μειωθούν έως ότου όλα τα μυρμηγκία ακολουθήσουν την ίδια, συντομότερη διαδρομή δηλαδή την καλύτερη λύση του προβλήματος της διαδρομής.

Ο ACO απαιτεί ένα πρόβλημα να αναπαρασταθεί ως γράφημα. Εδώ οι κόμβοι αντιπροσωπεύουν χαρακτηριστικά, ενώ οι ακμές μεταξύ τους υποδηλώνουν την επιλογή του επόμενου χαρακτηριστικού. Η αναζήτηση για το βέλτιστο υποσύνολο χαρακτηριστικών είναι στη συνέχεια μια διέλευση μυρμηγκιού μέσω του γραφήματος όπου επισκέπτεται έναν ελάχιστο αριθμό κόμβων και ικανοποιείται το κριτήριο διακοπής της διέλευσης. Το Σχήμα 4.2 απεικονίζει αυτή την αναπαράσταση και στο Σχήμα 4.3 φαίνεται το διάγραμμα ροής του αλγορίθμου. Το μυρμηγκί βρίσκεται αυτήν τη στιγμή στον κόμβο a και έχει τη δυνατότητα να επιλέξει ποιο χαρακτηριστικό θα προσθέσει δίπλα στο μονοπάτι του (διακεκομμένες γραμμές). Επιλέγει το χαρακτηριστικό b στη συνέχεια με βάση τον κανόνα μετάβασης, μετά c και μετά d. Κατά την άφιξη στο d, το τρέχον υποσύνολο {a, b, c, d} προσδιορίζεται ότι ικανοποιεί το κριτήριο διακοπής της διέλευσης (π.χ. έχει επιτευχθεί μια κατάλληλα υψηλή ακρίβεια ταξινόμησης με αυτό το υποσύνολο). Το μυρμηγκί τερματίζει τη διέλευση του και εξάγει αυτό το υποσύνολο χαρακτηριστικών ως υποψήφιος για μείωση δεδομένων.[13],[14]



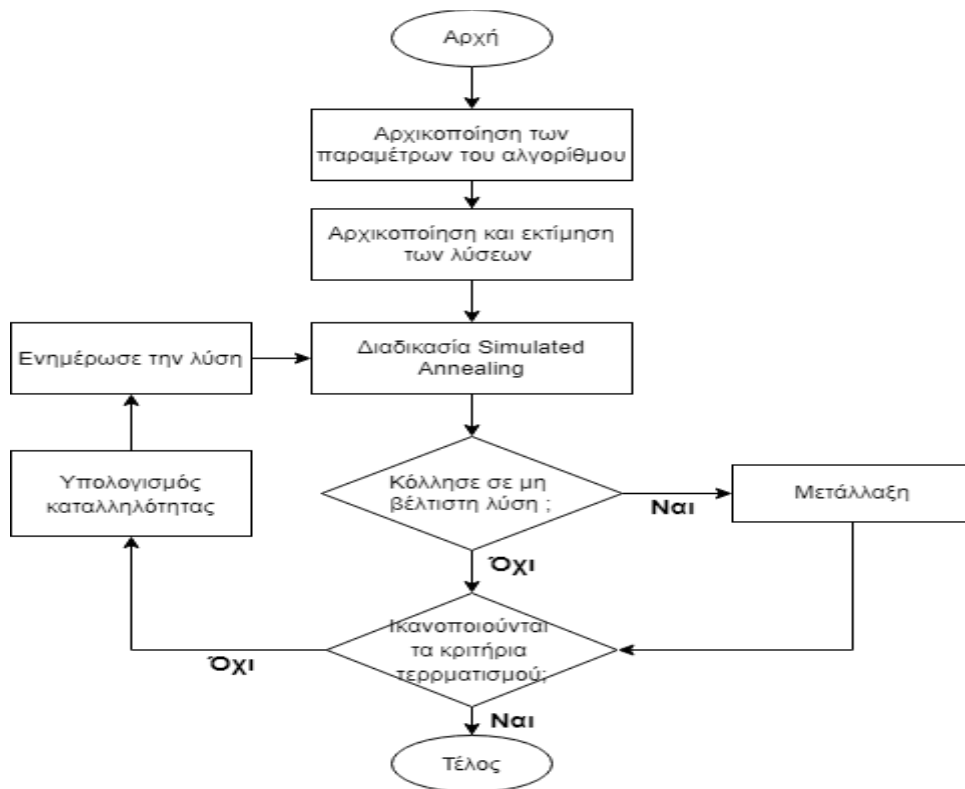
Σχήμα 4.2. Σχηματική αναπαράσταση του αλγορίθμου ACO



Σχήμα 4.3. Διάγραμμα ροής του αλγορίθμου ACO

4.2.3 Χρήση του αλγορίθμου SA για την επιλογή εισόδων

Ο αλγόριθμος SA είναι μια πιθανολογική μέθοδος τοπικής αναζήτησης που χρησιμοποιεί μια αρχική λύση ως βάση εκκίνησης και στη συνέχεια δημιουργεί μια λύση γειτονιάς. Η παραγόμενη λύση γειτονιάς θα αντικατασταθεί με την αρχική, εάν είναι καλύτερη ως προς την ποιότητα ή ικανοποιεί την πιθανότητα αποδοχής. Το διάγραμμα ροής του αλγορίθμου SA φαίνεται στο Σχήμα 4.4. Η αρχική λύση δημιουργείται με τυχαία τροποποίηση αυτής της λύσης. Στη συνέχεια, ο αλγόριθμος καλεί τη διαδικασία SA, για να δημιουργήσει καλύτερη λύση, τροποποιώντας επαναληπτικά την αρχική λύση που δημιουργείται. Εάν η λύση δεν μπορεί να βελτιωθεί για έναν ορισμένο αριθμό επαναλήψεων, εφαρμόζεται ένας τελεστής μετάλλαξης. Διαφορετικά, ο αλγόριθμος ελέγχει τη συνθήκη τερματισμού. Εάν αυτό ικανοποιηθεί, η διαδικασία σταματά και επιστρέφει την καλύτερη λύση. Διαφορετικά, υπολογίζεται η καταλληλότητα της λύσης που προκύπτει. Στη συνέχεια, εφαρμόζεται η στρατηγική ενημέρωσης λύσης, για να προσδιοριστεί εάν ενημερώνει την τρέχουσα λύση ή όχι. Αυτή η διαδικασία θα επαναληφθεί για έναν προκαθορισμένο αριθμό επαναλήψεων.[15],[16]




Σχήμα 4.4 Διάγραμμα ροής του αλγορίθμου SA

4.2.4 Χρήση του Feed Forward Neural Network για την βέλτιστη επιλογή εισόδων

Τα Feed Forward Neural Networks (FFNNs) έχουν χρησιμοποιηθεί εκτενώς σε πολλά πεδία λόγω της ικανότητάς τους να προσεγγίζουν πολύπλοκες μη γραμμικές αντιστοιχίσεις απευθείας από τα δείγματα εισόδου και να παρέχουν μοντέλα για μια μεγάλη κατηγορία φυσικών και τεχνητών φαινομένων που είναι δύσκολο να χειριστούν χρησιμοποιώντας κλασικές παραμετρικές τεχνικές. Η σχηματική αναπαράσταση του FFNN φαίνεται στο Σχήμα 4.5. Από την άλλη πλευρά, λείπουν ταχύτεροι αλγόριθμοι εκμάθησης για νευρωνικά δίκτυα. Οι παραδοσιακοί αλγόριθμοι εκμάθησης είναι συνήθως πολύ πιο αργοί από ό,τι απαιτείται. Δεν αποτελεί έκπληξη το γεγονός ότι μπορεί να χρειαστούν αρκετές ώρες, αρκετές ημέρες και ακόμη περισσότερος χρόνος για την εκπαίδευση των νευρωνικών δικτύων χρησιμοποιώντας παραδοσιακές μεθόδους. [17],[18]

Ένα feed-forward NN αποτελείται από ένα στρώμα εισόδων νευρώνων, έναν αυθαίρετο αριθμό κρυφών επιπέδων και ένα στρώμα εξόδου.



Σχήμα 4.5 Σχηματική αναπαράσταση του Feedforward Neural Network

Υποθέτοντας ότι η κρυφή συνάρτηση μεταφοράς είναι συνάρτηση σιγμοειδούς και η συνάρτηση μεταφοράς εξόδου είναι μια γραμμική συνάρτηση ενεργοποίησης.

η έξοδος του j ου κρυφού κόμβου είναι:

$$f(s_j) = 1 / \left(1 + \exp \left(- \left(\sum_{i=1}^n w_{ij} \cdot x_i - \theta_j \right) \right) \right) \quad j = 1, 2, \dots, H$$

όπου n είναι ο αριθμός του κόμβου εισόδου, w_{ij} είναι το βάρος σύνδεσης από τον i -στο

κόμβο του στρώματος εισόδου στον j -στο κόμβο του κρυφού στρώματος, θ_j είναι το κατώφλι της μονάδας του j -στου κρυφού επιπέδου, x_i είναι η i -στη είσοδος, s_j είναι το κρυφό άθροισμα βάρους που κρύβεται, και $s_j = \exp(-(\sum_{i=1}^n w_{ij} \cdot x_i - \theta_j))$.

Η έξοδος του k -στου στρώματος εξόδου είναι:


$$y_k = \sum_{j=1}^H w_{kj} \cdot f(s_j) - \theta_k \quad k = 1, 2, \dots, O$$

Όπου w_{kj} είναι το βάρος σύνδεσης από τον j -στο κρυφό κόμβο στον k -στο κόμβο εξόδου, θ_k είναι το κατώφλι της k -στης μονάδας εξόδου.

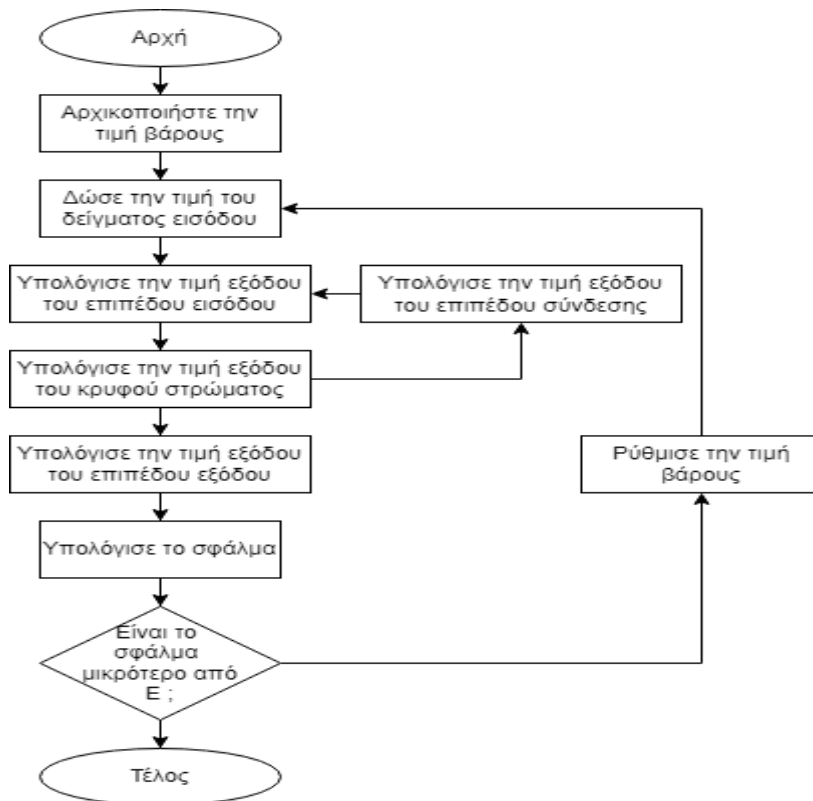
4.2.5 Χρήση του Elman Neural Network για την βέλτιστη επιλογή εισόδων

Το Elman Neural Network (ENN) είναι ένα τυπικό δυναμικό δίκτυο το οποίο βασίζεται στο νευρωνικό δίκτυο BP και αποθηκεύει την εσωτερική κατάσταση είναι να κάνει τη δυναμική λειτουργία της χαρτογράφησης μέσω της εισαγωγής σήματος ανάδρασης. Στο Σχήμα 4.6 και στο Σχήμα 4.7 φαίνονται η σχηματική αναπαράσταση και το διάγραμμα ροής του ENN αντίστοιχα. Σε σύγκριση με το παραδοσιακό νευρωνικό δίκτυο οπίσθιας διάδοσης, το ENN έχει ένα ειδικό επίπεδο που ονομάζεται στρώμα περιβάλλοντος, το οποίο κάνει αυτό το δίκτυο να έχει την ικανότητα να μαθαίνει μοτίβα που μεταβάλλονται χρονικά. Για το λόγο αυτό, το ENN είναι πολύ κατάλληλο για προβλήματα διακριτών χρονικών σειρών. Το πιο σημαντικό χαρακτηριστικό είναι ότι το νευρωνικό δίκτυο Elman προσθέτει ένα επίπεδο λήψης στο κρυφό στρώμα του δικτύου για να σχηματίσει τοπική ανάδραση. Η συνάρτηση μεταφοράς του στρώματος λήψης είναι μια γραμμική συνάρτηση. Με την εκπαίδευση του δικτύου, τα ιστορικά δεδομένα αποθηκεύονται στη δομή του δικτύου.

Το βασικό νευρωνικό δίκτυο Elman, αποτελείται από ένα επίπεδο εισόδου, ένα κρυφό στρώμα, ένα επίπεδο σύνδεσης και ένα στρώμα εξόδου. Η είσοδος κάθε στρώματος σταθμίζεται και η συνάρτηση μεταφοράς του κρυφού στρώματος είναι ένα είδος μη γραμμικής συνάρτησης, γενική συνάρτηση σιγμοειδούς. Η συνάρτηση του στρώματος εξόδου και του στρώματος σύνδεσης είναι γραμμική.



Σχήμα 4.6 Σχηματική αναπαράσταση του ENN



Σχήμα 4.7 Διάγραμμα ροής του Elman Neural Network


Το δίκτυο Elman είναι επίσης ένας Back Propagation αλγόριθμος για την εκτέλεση των βαρών, η συνάρτηση ευρετηρίου εκμάθησης χρησιμοποιεί τη συνάρτηση του αθροίσματος σφαλμάτων των τετραγώνων η οποία είναι η:

$$E(w) = \sum_{k=1}^n [y_k(w) - \overline{y_k(w)}]$$

Όπου $\overline{y_k}$ είναι το διάνυσμα του προσδοκώμενου στόχου εξόδου. [19],[20],[21]

4.2.6 Χρήση του Extreme Machine Learning για την βέλτιστη επιλογή εισόδων

Ο αλγόριθμος Extreme Machine Learning (ELM) είναι ένας αλγόριθμος μηχανικής μάθησης για ένα μονοστρωματικό νευρωνικό δίκτυο τροφοδοσίας, στο οποίο απαιτείται μόνο το βάρος εξόδου, για να υπολογιστεί σύμφωνα με τις παραμέτρους του κρυφού στρώματος και το κρυφό στρώμα ορίζεται τυχαία. Μία σχηματική αναπαράσταση του ELM φαίνεται στο Σχήμα 4.8. Τα βάρη εξόδου μπορούν να υπολογιστούν με απλή εφαρμογή γενικευμένης αντίστροφης πράξης στον κρυφό πίνακα εξόδου. Αυτός ο αλγόριθμος όχι μόνο έχει υψηλότερη απόδοση γενίκευσης και μεγαλύτερη ταχύτητα εκμάθησης από τις παραδοσιακές τεχνικές μάθησης, αλλά έχει επίσης ισχυρή ικανότητα προσαρμογής και χαμηλότερη υπολογιστική πολυπλοκότητα. Αυτός ο αλγόριθμος όχι μόνο έχει υψηλότερη γενικευμένη απόδοση και μεγαλύτερη ταχύτητα εκμάθησης από τις παραδοσιακές εκδόσεις εκμάθησης που βασίζονται σε κλίση, αλλά έχει επίσης ισχυρή ικανότητα προσαρμογής και χαμηλότερη υπολογιστική πολυπλοκότητα. [22],[23]



Σχήμα 4.8 Σχηματική αναπαράσταση ενός 3-στρωματικού νευρωνικού δικτύου ELM

Το ELM νευρωνικό δίκτυο έχει κάποια βασικά βήματα. Αρχικά υποθέτουμε ότι υπάρχουν N δείγματα εκπαίδευσης $\{(x_i, t_i)\}_{i=1}^N$, όπου $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$, το νευρωνικό δίκτυο με μια συνάρτηση ενεργοποίησης $g(x)$ και k

κρυφούς κόμβους παρουσιάζονται μαθηματικά ως:


$$H\beta = T$$

Όπου $H = \{h_{ij}\}_{i=1,\dots,N,j=1,\dots,k}$ αντιπροσωπεύει τον πίνακα εξόδου του κρυφού στρώματος. $h_{ij} = g(a_j^T x_i + b_j)$ είναι η έξοδος του j -στου κρυφού κόμβου σε σχέση με το x_i . $a_j = [\alpha_{j1}, \alpha_{j2}, \dots, \alpha_{jm}]^T$, είναι το διάνυσμα βάρους που συνδέει τους κόμβους εισόδου με τον j -στο κρυφό νευρώνα. Το b_j είναι η προτίμηση του j -στου κρυφού νευρώνα. Ο πίνακας βαρών εξόδου αναπαρίσταται ως $\beta = [\beta_1, \beta_2, \dots, \beta_k]^T$, με $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T, j = 1, \dots, k$ είναι το διάνυσμα βάρους που συνδέει τους κόμβους εξόδου με τον j -στο κρυφό νευρώνα. Ο πίνακας $T = [t_1, t_2, \dots, t_N]^T$ αντιπροσωπεύει τον πίνακα των στόχων. [22],[23]

Η ιδέα του ELM είναι να δημιουργεί τυχαία τα αρχικά βάρη εισόδου και τις κρυφές προκαταλήψεις. Στη συνέχεια, ο πίνακας H προσδιορίζεται σύμφωνα με τη συνάρτηση ενεργοποίησης $g(x)$. Με αυτόν τον τρόπο, η εκπαίδευση του Feed Forward νευρωνικού δικτύου μπορεί να μετατραπεί σε πρόβλημα επίλυσης της λύσης ελαχίστων τετραγώνων (LS) σε γραμμικό σύστημα. [22],[23]

4.2.7 Χρήση του Generalized Regression Neural Network για τη βέλτιστη επιλογή εισόδων

Το Generalized Regression νευρωνικό δίκτυο (GRNN) είναι μια παραλλαγή νευρωνικών δικτύων ακτινικής βάσης που έχει σχεδιαστεί για προσέγγιση συναρτήσεων και παλινδρόμηση. Καθιερώνεται με βάση έναν αλγόριθμο εκμάθησης *onepass* και δεν απαιτεί εκμάθηση μέσω της διαδικασίας αναδρομικής διάδοσης σφαλμάτων των δεδομένων εκπαίδευσης. Μπορεί να εφαρμοστεί σε οποιοδήποτε πρόβλημα παλινδρόμησης στο οποίο δε δικαιολογείται η υπόθεση της γραμμικότητας. Μια σχηματική αναπαράσταση του GRNN φαίνεται στο Σχήμα 4.9. Έχει παρατηρηθεί ότι το GRNN αποδίδει καλύτερα αποτελέσματα από το δίκτυο *back-propagation* όσον αφορά την απόδοση πρόβλεψης. Είναι ικανό να σχηματίζει πολύ λογικές επιφάνειες παλινδρόμησης με βάση μόνο λίγα δείγματα. Η γρήγορη εκμάθηση και η σύγκλιση στη βέλτιστη επιφάνεια παλινδρόμησης είναι τα κύρια πλεονεκτήματα του GRNN. Καθώς ο αριθμός των δειγμάτων εκπαίδευσης γίνεται μεγάλος, το σφάλμα εκτίμησης πλησιάζει το μηδέν με μόνο ήπιους περιορισμούς στη συνάρτηση. [24],[25]



Σχήμα 4.9 Σχηματική αναπαράσταση του Generalized Regression Neural Network

Ένα GRNN αποτελείται από τέσσερα επίπεδα: το επίπεδο εισόδου, το επίπεδο προτύπων, το επίπεδο άθροισης και το επίπεδο εξόδου τα οποία αναλύονται στην συνέχεια.

Ο αριθμός των νευρώνων του επιπέδου εισόδου είναι ίσος με τη διάσταση του διανύσματος εισόδου των δειγμάτων εκμάθησης και η μεταβλητή εισόδου μεταβιβάζεται απευθείας στο επίπεδο μοντέλου. Οι νευρώνες του στρώματος προτύπου είναι ίσοι με τον αριθμό των δειγμάτων εκμάθησης. Κάθε νευρώνας αντιστοιχεί στο δείγμα αντίστοιχα, η συνάρτηση μεταφοράς είναι:

$$P_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right], i = 1, 2, \dots, n$$

Όπου X είναι η μεταβλητή εισόδου, X_i είναι ο i -στος νευρώνας που αντιστοιχεί στα δείγματα μάθησης. Υπάρχουν δύο τύποι αθροιστικών νευρώνων. Ένα είδος είναι το αριθμητικό άθροισμα των νευρώνων του επιπέδου εξόδου του μοντέλου, ο τύπος υπολογισμού και η συνάρτηση μεταφοράς είναι:

$$S_D = \sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right]$$

Το ένα άλλο είναι το σταθμισμένο άθροισμα των νευρώνων του στρώματος σχήματος. Τα βάρη σύνδεσης μεταξύ των νευρώνων είναι τα j στοιχεία του i -στού δείγματος εξόδου Y_i . Ο τύπος υπολογισμού και η συνάρτηση μεταφοράς είναι:

$$\sum_{i=1}^n Y_i \exp\left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2}\right]$$

$$S_{Nj} = \sum_{j=1}^n y_{ij} P_i, j = 1, 2, \dots, k$$

Ο αριθμός των νευρώνων στο επίπεδο εξόδου είναι ίσος με τις διαστάσεις του διανύσματος εξόδου των δειγμάτων εκμάθησης. Κάθε έξοδος νευρώνων διαιρείται με το στρώμα άθροισης. Η έξοδος του j-στου νευρώνα αντιστοιχεί στο j-στο στοιχείο των αποτελεσμάτων εκτίμησης $\hat{Y}(X)$:

$$y_j = \frac{S_{Nj}}{S_D}, j = 1, 2, \dots, k$$

4.3 Μεθοδολογία Βέλτιστης Επιλογής Εισόδου

Οι εισοδοί μπορούν να διακριθούν σε τρεις τύπους: οι ιστορικές τιμές φορτίου, οι τιμές και οι δείκτες θερμοκρασίας και η κωδικοποίηση τύπου ημέρας. Η διερεύνηση της βραχυπρόθεσμης περιοδικότητας του φορτίου είναι η σημαντικότερη διαδικασία. Ο σκοπός είναι να γίνει επιλογή των πιο συσχετισμένων τιμών υστέρησης φορτίου. Συμβολίζουμε με $L(h, d)$ το φορτίο της τρέχουσας ώρας h της ημέρας d . Έτσι, οι τιμές ωριαίου φορτίου των προαναφερθέντων ημερών θεωρούνται ως εισοδοί στο ANN. Έστω $d, d-1$ και $d-7$ οι δείκτες που αναφέρονται στην ημέρα-στόχο την προηγούμενη ημέρα και την προηγούμενη εβδομάδα, αντίστοιχα. Οι εισοδοί του τεχνητού νευρωνικού δικτύου αναφέρονται παρακάτω.

- 1-24: ωριαίο φορτίο της $d-1$.
- 25-48: ωριαίο φορτίο της $d-7$.
- 49-50: μέγιστη και ελάχιστη θερμοκρασία της μέρας d , $T_{\max}(d)$ και $T_{\min}(d)$
- 51-52: μέγιστη και ελάχιστη θερμοκρασία της $d-1$, $T_{\max}(d-1)$ και $T_{\min}(d-1)$
- 53: τετραγωνική τιμή της απόκλισης της ημερήσιας ελάχιστης και μέγιστης θερμοκρασίας από την περιοχή των θερμοκρασιών κατωφλίου ψύξης και θέρμανσης και δίνεται από την εξίσωση:

$$CT(d) = \begin{cases} (T_{max}(d) - T_{c,min})^2, & \text{αν } T_{max}(d) < T_{c,min} \\ 0, & \text{αν } T_{c,min} \leq T_{max}(d) \leq T_{c,max} \\ (T_{max}(d) - T_{c,max})^2, & \text{αν } T_{max}(d) > T_{c,max} \end{cases}$$

Όπου $T_{c,min}=17^\circ\text{C}$ και $T_{c,max}=25^\circ\text{C}$, είναι οι θερμοκρασίες κατωφλίου ψύξης και θέρμανσης.

- 54: διαφορά μεταξύ των μέγιστων ημερήσιων θερμοκρασιών των ημερών d-1 και d-2, $T_{max}(d-1) - T_{max}(d-2)$, CT(d-1).
- 55: διαφορά μεταξύ των μέγιστων ημερήσιων θερμοκρασιών των ημερών d και d-1, $T_{max}(d) - T_{max}(d-1)$, CT(d).
- 56-57: περιοδικότητα εντός του έτους της ημέρας d, εκφράζεται ως ζεύγος τιμών $\{\sin(2\pi d/365), \cos(2\pi d/365)\}$.
- 58-64: κωδικός του κάθε τύπου ημέρας, 1 για Δευτέρα και 7 για Κυριακή.
- 65: κωδικός διάκρισης ημερών (1 για διακοπές και 0 για εργάσιμες μέρες ή σαββατοκύριακα), HI(d).

Το δεδομένο τεχνητό νευρωνικό δίκτυο έχει 65 νευρώνες στο στρώμα εισόδου. Το σετ εκπαίδευσης χρησιμοποιείται για τον προσδιορισμό της δομής του μοντέλου, δηλαδή τον αριθμό των κρυφών στρωμάτων, τον αριθμό των νευρώνων στα κρυφά στρώματα και τον τύπο της λειτουργίας ενεργοποίησης των νευρώνων.

Οι μετα-ευρετικοί αλγόριθμοι όπως οι PSO, SA, ACO, που χρησιμοποιήθηκαν έχουν τη δυνατότητα να εξερευνήσουν μια ευρεία περιοχή του χώρου αναζήτησης που περιέχει όλες τις πιθανές λύσεις σε ένα πρόβλημα βελτιστοποίησης.

Θεωρήθηκε ότι $L_a^{train}(d_{train}, h)$ και $L_f^{train}(d_{train}, h)$ είναι οι πραγματικές τιμές φορτίου και οι τιμές φορτίου πρόβλεψης της ημέρας εκμάθησης d του συνόλου εκπαίδευσης και $L_a^{test}(d_{test}, h)$, $L_f^{test}(d_{test}, h)$ τις πραγματικές τιμές φορτίου και οι τιμές φορτίου πρόβλεψης της ημέρας δοκιμής d του συνόλου δοκιμής, αντίστοιχα. Τα κανονικοποιημένα μέσα τετραγωνικά σφάλματα (NMSE) των συνόλων εκπαίδευσης και δοκιμής είναι, αντίστοιχα:

$$NRMSE_{train} = \frac{1}{D_{train}} \frac{1}{H} \sum_{d_{train}=1}^{D_{train}} \sum_{h=1}^H \frac{(L_a^{train}(d_{train}, h) - L_f^{train}(d_{train}, h))^2}{\bar{L}_a^{train} \bar{L}_f^{train}}$$

$$NRMSE_{test} = \frac{1}{D_{test}} \frac{1}{H} \sum_{d_{test}=1}^{D_{test}} \sum_{h=1}^H \frac{(L_a^{test}(d_{test}, h) - L_f^{test}(d_{test}, h))^2}{\bar{L}_a^{test} \bar{L}_f^{test}}$$

Όπου D_{train} και D_{test} είναι ο συνολικός αριθμός ημερών στο σετ εκπαίδευσης και δοκιμής, αντίστοιχα, $h = 1, 2, \dots, H$ είναι ένας δείκτης που υποδηλώνει την ώρα και $\bar{L}_a^{train}, \bar{L}_f^{train}, \bar{L}_a^{test}$ και \bar{L}_f^{test} είναι οι μέσοι όροι των $L_a^{train}(d_{train}, h), L_f^{train}(d_{train}, h), L_a^{test}(d_{test}, h)$ και $L_f^{test}(d_{test}, h)$. Το NMSE δίνει μία εκτίμηση των συνολικών αποκλίσεων μεταξύ των προβλεπόμενων και των μετρούμενων τιμών. [5]

Οι μεταβλητές απόφασης της διαδικασίας βελτιστοποίησης είναι οι είσοδοι του ANN που ελαχιστοποιούν την ακόλουθη συνάρτηση καταλληλότητας:

$$J(w) = w_{km}^{train} \times NRMSE_{train} + w_{km}^{test} \times NRMSE_{test}$$

Οι πίνακες βαρών των φάσεων εκπαίδευσης και δοκιμής είναι:

$$W_{train} = \{w_{kn}^{train}, k = 2, 4, \dots, 30, n = 1, 2, \dots, 65\}$$

$$W_{test} = \{w_{kn}^{test}, k = 2, 4, \dots, 30, n = 1, 2, \dots, 65\}$$

όπου k δηλώνει τον k -στο νευρώνα στο κρυφό στρώμα και n υποδηλώνει τον n -στο νευρώνα στο στρώμα εξόδου. Η επιλογή του αριθμού των νευρώνων στο κρυφό στρώμα είναι θέμα της ανάλυσης ευαισθησίας. Στην παρούσα εργασία, ο αριθμός των νευρώνων στο κρυφό στρώμα ποικίλει μεταξύ 2 και 30, με ένα αυξανόμενο βήμα ίσο με 2.

Οι αλγόριθμοι PSO, SA, ACO, που χρησιμοποιήθηκαν ελαχιστοποιούν την $J(w)$ μέσω μιας επαναληπτικής διαδικασίας. Ο αριθμός των επιθυμητών εξόδων καθορίζεται εκ των προτέρων. Η έξοδος του εκάστοτε αλγορίθμου είναι μια ακολουθία ακεραίων αριθμών που αντιστοιχούν στις επιλεγμένες εισόδους.

Η αξιολόγηση της απόδοσης του τεχνητού νευρωνικού δικτύου πραγματοποιείται με το Μέσο Απόλυτο Σφάλμα (MAPE). Το MAPE είναι η απόλυτη διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών, κανονικοποιημένη στη μέγιστη ισχύ:

$$MAPE = \frac{1}{D} \sum_{d=1}^D \frac{|L_a(d) - L_f(d)|}{L_a(d)} \times 100$$

Όπου D είναι ο συνολικός αριθμός ημερών και $L_a(d), L_f(d)$ είναι τα πραγματικά και τα προβλεπόμενα φορτία της ημέρας D . Το τεχνητό νευρωνικό δίκτυο εκπαιδεύεται με

μεταβλητό αριθμό νευρώνων στο κρυφό στρώμα και για κάθε αριθμό ελέγχεται το MAPE.

4.4 Σχολιασμός αποτελεσμάτων

Με το μοντέλο των 65 εισόδων το οποίο υποδεικνύεται από την βιβλιογραφία το ελάχιστο MAPE βρέθηκε ότι είναι 6,376463% για τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν.

Τα αποτελέσματα των προβλέψεων τα οποία πήραν ως δεδομένα τις εισόδους που βρέθηκαν μέσω του αλγορίθμου PSO φαίνονται στον Πίνακα 4.1

Πίνακας 4.1: Αποτελέσματα εφαρμογής PSO

Αλγόριθμος	Αριθμός εισόδων	Μέγιστος αριθμός επαναλήψεων	MAPE(%)
ENN	39	2	7,208499
ENN	42	2	7,204519
ENN	48	2	7,592782
ENN	50	2	7,693979
ENN	52	2	7,114246
ENN	55	2	7,489464
ENN	39	3	6,777542
ENN	42	3	6,87621
ENN	48	3	7,121132
ENN	50	3	7,427351
ENN	52	3	7,142492
ENN	55	3	7,525831
FFNN	39	2	6,56277
FFNN	42	2	6,546289
FFNN	48	2	6,829719
FFNN	50	2	6,507917
FFNN	52	2	6,781533
FFNN	55	2	6,086436
FFNN	39	3	6,399319
FFNN	42	3	6,756123
FFNN	48	3	6,541843
FFNN	50	3	6,790608

FFNN	52	3	6,833781
FFNN	55	3	6,465032
ELM	39	2	42,8597
ELM	39	3	29,0972
ELM	42	2	26,1740
ELM	42	3	26,7371
ELM	48	2	29,6060
ELM	48	3	33,2232
ELM	50	2	25,9582
ELM	50	3	33,2652
ELM	52	2	29,8463
ELM	52	3	17,2194
ELM	55	2	25,8513
ELM	55	3	28,0426
GRNN	39	2	11,1369
GRNN	39	3	10,7213
GRNN	42	2	11,0155
GRNN	42	3	10,7459
GRNN	48	2	10,7252
GRNN	48	3	10,9004
GRNN	50	2	10,8289
GRNN	50	3	10,8289
GRNN	52	2	11,1061
GRNN	52	3	11,1061
GRNN	55	2	10,9613
GRNN	55	3	11,0261

Από τον Πίνακα 4.1 φαίνεται ότι οι παραγόμενες εισοδοί του αλγορίθμου PSO έχουν ιδιαίτερα μικρό σφάλμα MAPE όταν οι εισοδοί χρησιμοποιούνται από τους αλγορίθμους ENN, FFNN περίπου 6-7%, ενώ η χρήση των εξόδων από το νευρωνικό δίκτυο GRNN έχει ως αποτέλεσμα σφάλμα περίπου 10-11% και 18-33% όταν οι εξοδοί του PSO χρησιμοποιούνται από το νευρωνικό δίκτυο ELM. Από τα προαναφερθέντα αποτελέσματα είναι εμφανές ότι παρόλο που ο αλγόριθμος PSO έχει πολύ καλή ακρίβεια προβλέψεων οι

έξοδοί του δεν έχει την ίδια απόδοση για όλα τα διαφορετικά νευρωνικά δίκτυα. Επομένως οι έξοδοι του συγκεκριμένου αλγορίθμου είναι θεμιτό να χρησιμοποιούνται κυρίως από τα νευρωνικά δίκτυα ENN, FFNN. Το ελάχιστο MAPE (6,086436%) ήταν αποτέλεσμα της διαδικασίας τρεξίματος του αλγορίθμου PSO για 2 επαναλήψεις και την παραγωγή 55 εισόδων για τα νευρωνικά δίκτυα. Επιπλέον φαίνεται ότι ο αλγόριθμος PSO παρόλο που την καλύτερη λύση την βρήκε για 2 επαναλήψεις, όταν κάνει 3 επαναλήψεις έχει ως αποτέλεσμα αρκετά μικρά σφάλματα ανεξάρτητα από την επιλογή εισόδων την οποία θα πρέπει να παράγει. Επίσης, από τον Πίνακα 4.1 είναι εμφανές ότι με την παραγωγή του μικρότερου αριθμού εισόδων (39) που δοκιμάστηκαν ο αλγόριθμος PSO είχε αρκετά μικρά σφάλματα τα οποία αυξανόταν ανάλογα με τον τύπο του νευρωνικού δικτύου που χρησιμοποιεί αυτές τις εισόδους, το οποίο συμβαίνει και για τον μέγιστο αριθμό εισόδων (55). Αντιθέτως στις ενδιάμεσες περιπτώσεις το σφάλμα MAPE αυξάνεται. Το συγκεκριμένο γεγονός είναι ιδιαίτερα σημαντικό, επειδή ένας μικρός αριθμός εισόδων οδηγεί γρήγορα αποτελέσματα με μικρή υπολογιστική ισχύς. Όμως είναι εμφανές ότι για να επιτευχθεί το βέλτιστο αποτέλεσμα, πρέπει ο αριθμός των εισόδων να αυξηθεί.

Στον Πίνακα 4.2 φαίνονται οι εισοδοί του νευρωνικού δικτύου οι οποίες είναι έξοδοι του PSO για την επίτευξη του ελαχίστου MAPE 6,086436% και το οποίο επιτεύχθηκε για 55 εξόδους.

Πίνακας 4.2: Επιλογή εισόδων PSO

Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή
2	$L(2, d - 1)$	22	$L(22, d - 1)$	45	$L(21, d - 7)$
4	$L(4, d - 1)$	23	$L(23, d - 1)$	46	$L(22, d - 7)$
5	$L(5, d - 1)$	24	$L(24, d - 1)$	47	$L(23, d - 7)$
6	$L(6, d - 1)$	25	$L(1, d - 7)$	49	$T_{\max}(d)$
7	$L(7, d - 1)$	26	$L(2, d - 7)$	50	$T_{\min}(d)$
8	$L(8, d - 1)$	27	$L(3, d - 7)$	51	$T_{\max}(d-1)$
9	$L(9, d - 1)$	28	$L(4, d - 7)$	52	$T_{\min}(d-1)$

10	$L(10,d-1)$	29	$L(5, d-7)$	53	$CT(d)$
11	$L(11,d-1)$	30	$L(6, d-7)$	55	$T_{max}(d)-T_{max}(d-1)$
12	$L(12,d-1)$	32	$L(8, d-7)$	56	$\sin(2\pi d/365)$
13	$L(13,d-1)$	35	$L(11, d-7)$	57	$\cos(2\pi d/365)$
14	$L(14,d-1)$	36	$L(12, d-7)$	58	Κωδικός τύπου ημέρας
15	$L(15,d-1)$	37	$L(13, d-7)$	60	Κωδικός τύπου ημέρας
16	$L(16,d-1)$	38	$L(14, d-7)$	61	Κωδικός τύπου ημέρας
17	$L(17,d-1)$	39	$L(15, d-7)$	62	Κωδικός τύπου ημέρας
18	$L(18,d-1)$	41	$L(17, d-7)$	63	Κωδικός τύπου ημέρας
19	$L(19,d-1)$	43	$L(19, d-7)$	64	Κωδικός τύπου ημέρας
20	$L(20,d-1)$	44	$L(20, d-7)$	65	$HI(d)$
21	$L(21,d-1)$				

Τα αποτελέσματα των προβλέψεων τα οποία πήραν ως δεδομένα τις εισόδους που βρέθηκαν μέσω του αλγορίθμου SA φαίνονται στον Πίνακα 4.3.

Πίνακας 4.3: Αποτελέσματα εφαρμογής SA

Αλγόριθμος	Αριθμός εισόδων	Μέγιστος αριθμός επαναλήψεων	MAPE(%)
ENN	39	2	7,926435
ENN	42	2	6,813174
ENN	48	2	7,357228
ENN	52	2	7,181599
ENN	55	2	6,709245
ENN	39	3	6,926689
ENN	42	3	6,237834
ENN	48	3	7,536487
ENN	52	3	6,862579
ENN	55	3	6,357133

FFNN	39	2	7,003745
FFNN	42	2	6,651268
FFNN	48	2	6,541848
FFNN	50	2	6,511877
FFNN	52	2	6,346052
FFNN	55	2	6,621859
FFNN	39	3	6,444875
FFNN	42	3	6,270914
FFNN	48	3	6,888132
FFNN	50	3	6,928035
FFNN	52	3	6,243889
FFNN	55	3	6,161595
ELM	39	2	27,9382
ELM	39	3	27,6197
ELM	42	2	28,3942
ELM	42	3	18,0501
ELM	48	2	33,0756
ELM	48	3	24,3803
ELM	50	2	26,6027
ELM	50	3	22,3290
ELM	52	2	24,1738
ELM	52	3	31,5708
ELM	55	2	32,6392
ELM	55	3	29,6789
GRNN	39	2	11,1994
GRNN	39	3	10,7188
GRNN	42	2	10,4374
GRNN	42	3	10,7642
GRNN	48	2	10,5615
GRNN	48	3	11,3754
GRNN	50	2	10,7783
GRNN	50	3	10,9839
GRNN	52	2	10,8416

GRNN	52	3	10,8663
GRNN	55	2	10,4514
GRNN	55	3	10,7513

Από τον Πίνακα 4.3 φαίνεται ότι ο αλγόριθμος SA οδηγεί σε καλύτερα αποτελέσματα όταν οι έξοδοί του χρησιμοποιούνται από τα νευρωνικά δίκτυα ENN, FFNN περίπου 6-7%, ενώ η χρήση των εξόδων από το νευρωνικό δίκτυο GRNN έχει ως αποτέλεσμα σφάλμα περίπου 10% και 18-35% όταν οι έξοδοι του SA χρησιμοποιούνται από το νευρωνικό δίκτυο ELM. Από τα προαναφερθέντα αποτελέσματα είναι εμφανές ότι παρόλο που ο αλγόριθμος SA έχει πολύ καλή ακρίβεια προβλέψεων οι έξοδοί του δεν έχει την ίδια απόδοση για όλα τα διαφορετικά νευρωνικά δίκτυα. Επομένως οι έξοδοι του συγκεκριμένου αλγορίθμου είναι θεμιτό να χρησιμοποιούνται κυρίως από τα νευρωνικά δίκτυα ENN, FFNN. Ο αλγόριθμος SA έχει μικρότερο σφάλμα MAPE(6,161595%) με την παραγωγή 55 εισόδων και 3 επαναλήψεων. Γενικά με την χρήση των 3 επαναλήψεων το σφάλμα MAPE είναι μικρότερο από όταν γίνεται χρήση 2 επαναλήψεων. Συνεπώς η χρήση πολλών εισόδων και επαναλήψεων οδηγεί στα βέλτιστα αποτελέσματα όμως το πλήθος των εισόδων είναι δυνατόν να οδηγήσει σε καθυστέρηση της πρόβλεψης.

Στον Πίνακα 4.4 φαίνονται οι εισόδοι του νευρωνικού δικτύου οι οποίες είναι έξοδοι του SA για την επίτευξη του ελαχίστου MAPE 6,161595% και το οποίο επιτεύχθηκε για 55 εξόδους.

Πίνακας 4.4: Επιλογή εισόδων SA

Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή
1	$L(1,d-1)$	21	$L(21,d-1)$	44	$L(20,d-7)$
2	$L(2,d-1)$	22	$L(22,d-1)$	45	$L(21,d-7)$
3	$L(3,d-1)$	23	$L(23,d-1)$	46	$L(22,d-7)$
4	$L(4,d-1)$	24	$L(24,d-1)$	47	$L(23,d-7)$
5	$L(5,d-1)$	25	$L(1,d-7)$	48	$L(24,d-7)$
6	$L(6,d-1)$	26	$L(2,d-7)$	49	$T_{\max}(d)$
7	$L(7,d-1)$	28	$L(4,d-7)$	50	$T_{\min}(d)$
8	$L(8,d-1)$	32	$L(8,d-7)$	51	$T_{\max}(d-1)$
9	$L(9,d-1)$	33	$L(9,d-7)$	53	$CT(d)$

10	$L(10,d-1)$	34	$L(10,d-7)$	54	CT(d-1)
11	$L(11,d-1)$	35	$L(11,d-7)$	55	$T_{\max}(d) - T_{\max}(d-1)$
12	$L(12,d-1)$	37	$L(13,d-7)$	56	$\sin(2\pi d/365)$
13	$L(13,d-1)$	38	$L(14,d-7)$	60	Κωδικός τύπου ημέρας
14	$L(14,d-1)$	39	$L(15,d-7)$	61	Κωδικός τύπου ημέρας
15	$L(15,d-1)$	40	$L(16,d-7)$	62	Κωδικός τύπου ημέρας
17	$L(17,d-1)$	41	$L(17,d-7)$	63	Κωδικός τύπου ημέρας
18	$L(18,d-1)$	42	$L(18,d-7)$	64	Κωδικός τύπου ημέρας
19	$L(19,d-1)$	43	$L(19,d-7)$	65	HI(d)
20	$L(20,d-1)$				

Τα αποτελέσματα των προβλέψεων τα οποία ως δεδομένα τις εισόδους που βρέθηκαν μέσω του αλγορίθμου ACO φαίνονται στον Πίνακα 4.5.

Πίνακας 4.5: Αποτελέσματα εφαρμογής ACO

Αλγόριθμος	Αριθμός εισόδων	Μέγιστος αριθμός επαναλήψεων	MAPE (%)
ENN	39	2	6,818116
ENN	42	2	6,387954
ENN	45	2	6,397018
ENN	48	2	6,365564
ENN	52	2	7,314225
ENN	55	2	7,310237
ENN	39	3	6,533304
ENN	42	3	6,822177
ENN	45	3	7,0264
ENN	48	3	7,031657
ENN	52	3	6,853453
ENN	55	3	6,774614
FFNN	39	2	6,308621
FFNN	42	2	6,488976
FFNN	45	2	6,581294
FFNN	48	2	6,489785

FFNN	52	2	7,046912
FFNN	55	2	6,304364
FFNN	39	3	6,771289
FFNN	42	3	6,389877
FFNN	45	3	6,63688
FFNN	48	3	6,96027
FFNN	52	3	6,78075
FFNN	55	3	6,571998
ELM	39	2	27,4189
ELM	39	3	28,1979
ELM	42	2	27,7598
ELM	42	3	17,2791
ELM	45	2	21,8473
ELM	45	3	25,3469
ELM	48	2	22,8436
ELM	48	3	23,5369
ELM	52	2	32,4569
ELM	52	3	21,5163
ELM	55	2	20,4470
ELM	55	3	27,0998
GRNN	39	2	10,7973
GRNN	39	3	10,7973
GRNN	42	2	10,7973
GRNN	42	3	10,7973
GRNN	45	2	10,7973
GRNN	45	3	10,7973
GRNN	48	2	10,7973
GRNN	48	3	10,7973
GRNN	52	2	10,7973
GRNN	52	3	10,7973
GRNN	55	2	10,7973
GRNN	55	3	10,7973

Από τον Πίνακα 4.5 φαίνεται ότι ο αλγόριθμος ACO οδηγεί σε καλύτερα αποτελέσματα όταν οι έξοδοι του χρησιμοποιούνται από τα FFNN, ENN νευρωνικά δίκτυα. περίπου 6-7%, ενώ η χρήση των εξόδων από το νευρωνικό δίκτυο GRNN έχει ως αποτέλεσμα σφάλμα περίπου 11% και 17-32% όταν οι έξοδοι του ACO χρησιμοποιούνται από το νευρωνικό δίκτυο ELM. Από τα προαναφερθέντα αποτελέσματα είναι εμφανές ότι παρόλο που ο αλγόριθμος SA έχει πολύ καλή ακρίβεια προβλέψεων οι έξοδοί του δεν έχει την ίδια απόδοση για όλα τα διαφορετικά νευρωνικά δίκτυα. Επομένως οι έξοδοι του συγκεκριμένου αλγορίθμου είναι θεμιτό να χρησιμοποιούνται κυρίως από τα νευρωνικά δίκτυα ENN, FFNN. Ο συγκεκριμένος αλγόριθμος πετυχαίνει το ελάχιστο σφάλμα MAPE(6,304364%) του με την παραγωγή 55 εισόδων του νευρωνικού και 2 επαναλήψεων. Σε αντίθεση με τους αλγορίθμους PSO, SA ο αλγόριθμος ACO με την χρήση 2 επαναλήψεων οδηγεί σταθερά σε μικρότερα σφάλματα από όταν κάνει χρήση 3 επαναλήψεων. Η ανάγκη για 2 επαναλήψεις αντί για 3 για την εξαγωγή βέλτιστων αποτελεσμάτων είναι ιδιαίτερα σημαντική επειδή μειώνει τον χρόνο και την υπολογιστική ισχύς που απαιτείται για την πρόβλεψη του φορτίου.


Στον Πίνακα 4.6 φαίνονται οι εισόδους του νευρωνικού δικτύου οι οποίες είναι έξοδοι του ACO για την επίτευξη του ελαχίστου MAPE 6,304364% και το οποίο επιτεύχθηκε για 55 εξόδους.

Πίνακας 4.6: Επιλογή εισόδων ACO


Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή	Είσοδος	Μεταβλητή
1	$L(1,d-1)$	23	$L(23,d-1)$	45	$L(21,d-7)$
2	$L(2,d-1)$	24	$L(24,d-1)$	46	$L(22,d-7)$
3	$L(3,d-1)$	25	$L(1,d-7)$	47	$L(23,d-7)$
4	$L(4,d-1)$	26	$L(2,d-7)$	48	$L(24,d-7)$
5	$L(5,d-1)$	27	$L(3,d-7)$	49	$T_{\max}(d)$
6	$L(6,d-1)$	28	$L(4,d-7)$	50	$T_{\min}(d)$
7	$L(7,d-1)$	29	$L(5,d-7)$	51	$T_{\max}(d-1)$
8	$L(8,d-1)$	30	$L(6,d-7)$	52	$T_{\min}(d-1)$
9	$L(9,d-1)$	31	$L(7,d-7)$	53	CT(d)
10	$L(10,d-1)$	32	$L(8,d-7)$	54	CT(d-1)
11	$L(11,d-1)$	33	$L(9,d-7)$	55	$T_{\max}(d)-T_{\max}(d-1)$

12	$L(12,d-1)$	34	$L(10,d-7)$	56	$\sin(2\pi d/365)$
13	$L(13,d-1)$	35	$L(11,d-7)$	57	$\cos(2\pi d/365)$
14	$L(14,d-1)$	36	$L(12,d-7)$	58	Κωδικός τύπου ημέρας
15	$L(15,d-1)$	37	$L(13,d-7)$	59	Κωδικός τύπου ημέρας
16	$L(16,d-1)$	38	$L(14,d-7)$	60	Κωδικός τύπου ημέρας
17	$L(17,d-1)$	39	$L(15,d-7)$	61	Κωδικός τύπου ημέρας
18	$L(18,d-1)$	40	$L(16,d-7)$	62	Κωδικός τύπου ημέρας
19	$L(19,d-1)$	41	$L(17,d-7)$	63	Κωδικός τύπου ημέρας
20	$L(20,d-1)$	42	$L(18,d-7)$	64	Κωδικός τύπου ημέρας
21	$L(21,d-1)$	43	$L(19,d-7)$	65	$HI(d)$
22	$L(22,d-1)$	44	$L(20,d-7)$		


Στην συνέχεια χρησιμοποιήσαμε τους αλγόριθμους ELM,GRNN,FFNN,ENN για την πρόβλεψη φορτίου για συγκεκριμένες μέρες του χρόνου. Στα Σχήματα 4.10-4.26 φαίνεται η σύγκριση των ωριαίων προβλέψεων των τεχνητών νευρωνικών δικτύων με τα πραγματικά δεδομένα του σταθμού παραγωγής της Νέας Ελβετίας για συγκεκριμένες μέρες της χρονιάς 2011.




Σχήμα 4.10 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 01/01/2011




Σχήμα 4.11 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/01/2011




Σχήμα 4.12 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/02/2011




Σχήμα 4.13 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/03/2011




Σχήμα 4.14 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 25/03/2011




Σχήμα 4.15 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/04/2011




Σχήμα 4.16 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/05/2011




Σχήμα 4.17 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/06/2011




Σχήμα 4.18 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/07/2011




Σχήμα 4.19 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/08/2011




Σχήμα 4.20 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 15/08/2011




Σχήμα 4.21 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/09/2011




Σχήμα 4.22 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/10/2011




Σχήμα 4.23 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 28/10/2011




Σχήμα 4.24 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/11/2011



Σχήμα 4.25 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 10/12/2011



Σχήμα 4.26 Το πραγματικό φορτίο και οι προβλέψεις για την ημέρα 25/12/2011



Σχήμα 4.27 Μεταβολή του σφάλματος MAPE του κάθε νευρωνικού δικτύου με την ημέρα

Στο Σχήμα 4.27 φαίνεται η απόκλιση της κάθε πρόβλεψης από τα νευρωνικά δίκτυα μέσω του δείκτη σφάλματος MAPE. Είναι εμφανές ότι η απόκλιση των νευρωνικών δικτύων GRNN, FFNN και ENN από την 1^η Ιανουαρίου έως την 10^η Μαΐου είναι σχετικά μικρή και χωρίς μεγάλες μεταβολές 9-31%. Στις 10 Ιουλίου η πρόβλεψη όλων των νευρωνικών δικτύων έχει την μέγιστη απόκλιση 40-70%. Από τη 10^η Αυγούστου και έπειτα έως την 25^η Δεκεμβρίου η απόκλιση για όλους του τύπους νευρωνικών δικτύων συνεχώς αλλάζει και αυξάνεται και μειώνεται χωρίς σταθερή να έχει σταθερή μεταβολή. Η πρόβλεψη των FFNN και ENN φαίνεται να έχει γενικά μικρότερη απόκλιση από την πραγματική παρόλο που για κάποιες μέρες τα ELM και GRNN καταλήγουν σε καλύτερα αποτελέσματα.

Το FFNN πετυχαίνει το μικρότερο δυνατό σφάλμα πρόβλεψης την 15^η Αυγούστου (4,63%), την 28^η Οκτωβρίου (9,34%) και την 10^η Δεκεμβρίου (5,6%) όπως και το ENN το οποίο έχει σφάλμα 4,13%, 6,75% και 5,2% για την 15^η Αυγούστου, την 28^η Οκτωβρίου και την 10^η Δεκεμβρίου αντίστοιχα.

Το ELM πετυχαίνει το μικρότερο δυνατό σφάλμα την 10^η Φεβρουαρίου και την 10^η Μαρτίου 5,04% και 7,44% αντίστοιχα.

Το GRNN πετυχαίνει το μικρότερο δυνατό σφάλμα την 10^η Δεκεμβρίου και την 10^η Απριλίου 6,30% και 12,97% αντίστοιχα.

Κεφάλαιο 5 Συμπεράσματα

5.1 Σύνοψη και συμπεράσματα

Οι μετα-ευρετικοί αλγόριθμοι έχουν εφαρμογές στην επίλυση δύσκολων προβλημάτων τα οποία μπορούν να προέρχονται από διάφορους κλάδους των επιστημών. Πιο συγκεκριμένα για την συσταδοποίηση καμπυλών φορτίου έχουν πολύ καλά αποτελέσματα σε αρκετά μικρό χρονικό διάστημα. Αυτό το γεγονός τους κάνει κατάλληλους για ευρεία χρήση.

Ενώ οι απλοί μετα-ευρετικοί αλγόριθμοι δεν έχουν δυνατότητες βελτίωσης, ο συνδυασμός δύο αλγορίθμων οδήγησε σε καλύτερα αποτελέσματα από τους αρχικούς. Η συγκεκριμένη εργασία επικεντρώθηκε στην χρήση των μετα-ευρετικών αλγορίθμων για την συσταδοποίηση και την βέλτιστη επιλογή εισόδων για την πρόβλεψη φορτίου στο διασυνδεδεμένο σύστημα διανομής της Ελλάδας.

Επίσης η χρήση μετα-ευρετικών αλγορίθμων και διαφορετικών τύπων τεχνητών νευρωνικών δικτύων είχε ως αποτέλεσμα πρόβλεψη φορτίου με αρκετά μικρή απόκλιση από το πραγματικό.

5.2 Μελλοντικές επεκτάσεις

Οι μετα-ευρετικοί αλγόριθμοι είναι ένα ιδιαίτερα σημαντικό εργαλείο στην επίλυση πολύπλοκων προβλημάτων βελτιστοποίησης, όπως η συσταδοποίηση και η πρόβλεψη φορτίου, σε σχετικά μικρό χρονικό διάστημα. Με την χρήση διαφορετικών συνδυασμών αλγορίθμων και νευρωνικών δικτύων είναι πιθανόν να προκύψουν ακόμα καλύτερα αποτελέσματα.

Βιβλιογραφία

- [1] Cuevas E., Espejo E.B. and Enríquez A.C., “Metaheuristics Algorithms in Power Systems”, *Studies in Computational Intelligence*, vol. 822, no. 1, 2019.
- [2] Chicco G., “Load Pattern-Based Classification of Electricity Customers”, *IEEE Trans. on Power Systems*, vol. 19, no. 2, pp. 1232-1239, May 2004.
- [3] Chicco G., Napoli R., and Piglione F., “Comparisons Among Clustering Techniques for Electricity Customer Classification”, *IEEE Trans. on Power Systems*, vol. 21, no.2, pp 933-940, May 2006.
- [4] Panapakidis I., Bouhouras A., and Christoforidis G., “A Comparison of Feature Selection Techniques for Neural Network Based Load Forecasting”, in *Proc 2019 International Universities Power Engineering Conference*, Bucharest, Romania, 2019, pp 1-6.
- [5] Panapakidis I., Bouhouras A., and Christoforidis G., “Metaheuristics-based input selection for neural networks: Application in short-term load forecasting”, in *Proc 2019 International Conference on Energy Transition in the Mediterranean Area*, Cagliari, Italy, 2019, pp. 1-6.
- [6] Hajiabbas P.M. and Mohammadi-Ivatloo B., “Optimization of Power Systems Problems”, *Studies in Systems, Decision and Control*, Springer, vol.262, 2020.
- [7] Tsekouras G.J., Hatziargyriou N. D., and Dialynas E .N., “Two-stage pattern recognition of load curves for classification of electricity customers” *IEEE Trans. Power Syst.*, vol. 22, pp. 1120-1128, August 2007.
- [8] López J. J., Aguado J.A., Martín F., Munoz F., Rodríguez A., and J. E. Ruiz J. E., “Hopfield–K-Means clustering algorithm: A proposal for the segmentation of electricity customers”, *Elect. Power. Syst. Res.*, vol. 81, pp. 716-722, February 2011.
- [9] Chicco G., “Overview and performance assessment of the clustering methods for electrical load pattern grouping”, *Energy*, vol. 42, no.1, pp. 68-80, June 2012.
- [10] Shieh S. L. and Liao I. E., “A new approach for data clustering and visualization using self-organizing maps”, *Expert Systems with Applications*, vol. 39, pp. 11924-11933, 2012.
- [11] Panapakidis I. P., Kechagias C. A., Bargiotas D., “A Hybrid Metaheuristics-Based Algorithm for Electricity Load Curves Profiling”, *56th International Universities Power Engineering Conference (UPEC)*, Middlesbrough, United Kingdom, September, 2021.

- [12] Huang C. L. and Dun J. F., "A distributed PSO–SVM hybrid system with feature selection and parameter optimization", *Applied Soft Computing*, vol. 8, no. 4, pp. 1381-1391, September 2008.
- [13] Kanan H. R., and Faez K., "An improved feature selection method based on ant colony optimization (ACO) evaluated on face recognition system", *Applied Mathematics and Computation*, vol. 205, pp. 716-725, 2008.
- [14] Socha K. and Blum C., "An ant colony optimization algorithm for continuous optimization: application to feed-forward neural network training", *Neural Computing and Applications*, vol. 16, pp. 235-247, 2007.
- [15] Turkey A., Sabar N. R. and Song A., "An Evolutionary Simulating Annealing Algorithm for Google Machine Reassignment Problem", *Intelligent and Evolutionary Systems, Proceedings in Adaptation, Learning and Optimization*, vol. 8, pp. 431-442, 2016.
- [16] Bertsimas D. and Tsitsiklis J., "Simulated Annealing", *Statistical Science*, vol. 8, no. 1, pp. 10-16, 1993.
- [17] Huang G. B., Zhu Q. Y. and Siew C. K., "Extreme learning machine: Theory and applications", *Neurocomputing*, vol. 70, pp.489-501, 2006.
- [18] Zhang J. R., Zhang J., Lok T. M. and Lyu M. R., "A hybrid particle swarm optimization–back propagation algorithm for feedforward neural network training", *Applied Mathematics and Computation*, vol. 185, pp. 1026-1037, 2007.
- [19] Yu Y., Wang X. and Bróndlinger R., "Improved Elman Neural Network Short-Term Residents Load Forecasting Considering Human Comfort Index", *Journal of Electrical Engineering & Technology*, vol. 14, pp. 2315-2322, September 2018.
- [20] Zhang X., Wang R., Liao T., Zhang T. and Zha Y., "Short-term forecasting of wind power generation Based on the Similar Day and Elman Neural Network", *2015 IEEE Symposium Series on Computational Intelligence*, Cape Town, South Africa, pp.647-650, December 2015.
- [21] Xie K., Yi H., Hu G., Li L. and Fan Z., "Short-term power load forecasting based on Elman neural network with particle swarm optimization", *Neurocomputing*, vol. 416, pp. 136-142, November 2020.
- [22] Cai W., Yang J., Yu Y., Song Y., Zhou T. and Qin Z., "PSO-ELM: A Hybrid Learning Model for Short-term Traffic Flow Forecasting", *IEEE Access*, vol. 8, pp. 6505-6514, January 2020.

- [23] Zhang C., Zhou J., Li C., Fu W. and Peng T., "A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting", *Energy Conversion and Management*, vol. 143, pp. 360-376, 2017.
- [24] Wang K., Huang S. And Ding Y., "Application of GRNN Neural Network in Short Term Load Forecasting", *Advanced Materials Research*, vols. 971-973, pp.2242-2247, 2014.
- [25] Alilou V. K. and Yaghmaee F., "Application of GRNN Neural Network in Non-Texture Image Inpainting and Restoration", *Pattern Recognition Letters*, vol. 62, pp. 24-31, September 2015.