


ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΤΜΗΜΑ ΠΟΛΙΤΙΚΩΝ ΜΗΧΑΝΙΚΩΝ
UNIVERSITY OF THESSALY
DEPARTMENT OF CIVIL ENGINEERING



ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ:

ΕΦΑΡΜΟΓΕΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΚΑΙ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΕΠΙΣΤΗΜΗ ΤΟΥ ΠΟΛΙΤΙΚΟΥ ΜΗΧΑΝΙΚΟΥ



ΠΑΠΑΝΙΚΟΛΑΟΥ ΝΙΚΟΛΑΟΣ
ΤΣΙΑΚΑΛΟΣ ΚΩΝΣΤΑΝΤΙΝΟΣ

ΕΠΙΒΛΕΠΩΝ: ΚΑΡΑΚΑΣΙΔΗΣ ΘΕΟΔΩΡΟΣ

ΒΟΛΟΣ
2020

© 2020 Παπανικολάου Νικόλαος και Τσιάκαλος Κωνσταντίνος

Η έγκριση της διπλωματικής εργασίας από το Τμήμα Πολιτικών Μηχανικών της Πολυτεχνικής Σχολής του Πανεπιστημίου Θεσσαλίας δεν υποδηλώνει αποδοχή των απόψεων του συγγραφέα (Ν. 5343/32 αρ. 202 παρ. 2).

Δήλωση

Βεβαιώνουμε ότι η παρούσα εργασία είναι δική μας, δεν έχει συγγραφεί από άλλο πρόσωπο με ή χωρίς αμοιβή, δεν έχει αντιγραφεί από δημοσιευμένη ή αδημοσίευτη εργασία άλλου και δεν έχει προηγουμένως υποβληθεί για βαθμολόγηση στο Πανεπιστήμιο Θεσσαλίας ή αλλού. Βεβαιώνουμε ότι είμαστε εν γνώσει των κανόνων περί λογοκλοπής του Τμήματος Πολιτικών Μηχανικών και ότι στο πλαίσιο αυτού έχουν τηρηθεί όλοι οι κανόνες κατά την ακαδημαϊκή δεοντολογία, σχετικά με αναφορές, βιβλιογραφίες, κ.λ.π., τόσο από έντυπες όσο και από ηλεκτρονικές πηγές. Σε περίπτωση λογοκλοπής αποδεχόμαστε όλες ανεξαιρέτως τις ποινές που προβλέπουν οι εκάστοτε κανονισμοί του Π.Θ. και του Τμήματος Πολιτικών Μηχανικών.

Ημερομηνία:

Παπανικολάου Νικόλαος και Τσιάκαλος Κωνσταντίνος

Ευχαριστίες

Η παρούσα διπλωματική εργασία με τίτλο «Εφαρμογές τεχνητής νοημοσύνης και μηχανικής μάθησης στην επιστήμη του πολιτικού μηχανικού», εκπονήθηκε από τους προπτυχιακούς φοιτητές Παπανικολάου Νικόλαο και Τσιάκαλο Κωνσταντίνο στο πλαίσιο των υποχρεώσεων τους για το Τμήμα Πολιτικών Μηχανικών του Πανεπιστημίου Θεσσαλίας κατά το ακαδημαϊκό έτος 2019-2020.

Κατ' αρχήν, θέλουμε να ευχαριστήσουμε τον επιβλέποντα της διπλωματικής εργασίας μας, τον καθηγητή κ. Θεόδωρο Καρακασίδη που με την καθοδήγηση και τις υποδείξεις του συνέβαλε καθοριστικά στην ολοκλήρωση της παρούσας διπλωματικής εργασίας. Επίσης, είμαστε ευγνώμονες στα υπόλοιπα μέλη της εξεταστικής επιτροπής της διπλωματικής εργασίας μας για την ανάγνωση και εξέταση της εργασίας μας.

Τέλος, ένα μεγάλο ευχαριστώ στις οικογένειες μας, για την συμπαράσταση που μας παρείχαν με κάθε τρόπο σε όλη την διάρκεια της φοιτητικής μας διαδρομής, και στους φίλους μας που μας στήριξαν σε κάθε μας προσπάθεια.

Περίληψη

Σε αυτή την διπλωματική εργασία αναπτύσσουμε την συνεισφορά της τεχνητής νοημοσύνης στον τομέα του πολιτικού μηχανικού. Πιο συγκεκριμένα, αναφέρουμε αναλυτικά τις μεθόδους τεχνητής νοημοσύνης που χρησιμοποιούνται ευρέως σε διάφορες εφαρμογές, όπως για παράδειγμα τα τεχνητά νευρωνικά δίκτυα, την ασαφή λογική και άλλους αλγόριθμους μηχανικής μάθησης. Ακόμη, γίνεται αναφορά σε ορισμένες τεχνικές με τις οποίες αναπτύσσονται και χρησιμοποιούνται οι αλγόριθμοι για την πρόβλεψη αποτελεσμάτων. Επιπλέον, αναλύουμε κάποιες βασικές κατηγορίες που αφορούν τους πολιτικούς μηχανικούς και οι οποίες τα τελευταία χρόνια γίνονται όλο και περισσότερο σημαντικές. Τέτοιες κατηγορίες είναι για παράδειγμα η παρακολούθηση της δομικής ακεραιότητας μιας κατασκευής, η ενεργειακή σχεδίαση μιας κατασκευής, η πρόβλεψη των ιδιοτήτων του σκυροδέματος και άλλες. Σε κάθε κατηγορία από αυτές αναφέρουμε ορισμένα από τα πλεονεκτήματα και τους λόγους χρήσης της τεχνητής νοημοσύνης και αναλύουμε διάφορες μελέτες πάνω σε αυτές. Τέλος, κάνουμε μια σύνοψη όλων των συμπερασμάτων από τις πειραματικές μελέτες και προτείνουμε διάφορες ενέργειες για την βελτιστοποίηση των μεθόδων αυτών, καθώς και άλλες εφαρμογές στις οποίες θα μπορούσε να γίνει χρήση της τεχνητής νοημοσύνης.

Λέξεις – Κλειδιά: τεχνητή νοημοσύνη, πολιτικός μηχανικός, μηχανική μάθηση, αλγόριθμος, τεχνητά νευρωνικά δίκτυα, πρόβλεψη, σχεδιασμός.

Abstract

In this bibliography the contribution of artificial intelligence, in the aspects of civil engineering, is being developed. More specifically, we point out the methods being used by AI (artificial intelligence), in several applications such as artificial neural networks, vague reason and other mechanical engineering algorithms. Still, we state particular techniques with several algorithms of outcome predictions are being developed and used. Furthermore, we analyze some basic categories which concern civil engineers and which in the last few years become more and more important. Such categories are, for example, the observation of structural integrity of a construction and its' energetic design, the prediction of some concrete properties and more. In each category, we mention some of the upsides and good reasons to apply AI in engineering and analyze several studies which support that cause. To sum up, we make a general conclusion of all experimental studies we analyzed and we suggest particular actions which could help optimize all above methods and also other aspects in which AI could make a difference.

Keywords: artificial intelligence, civil engineer, machine learning, algorithm, artificial neural networks, prediction, design.

Πίνακας περιεχομένων

Περίληψη	iv
Abstract.....	v
Αρκτικόλεξα	xiii
Κεφάλαιο 1 Εισαγωγή	1
1.1 Τεχνητή νοημοσύνη.....	1
1.2 Επιρροή στην επιστήμη του πολιτικού μηχανικού	3
Κεφάλαιο 2 Κατηγορίες τεχνητής νοημοσύνης.....	5
2.1 Αλγόριθμοι τεχνητής νοημοσύνης.....	5
2.1.1 Μηχανική μάθηση.....	5
2.1.2 Αναγνώριση προτύπων	7
2.1.3 Τεχνητά νευρωνικά δίκτυα	8
2.1.4 Γενετικός αλγόριθμος.....	12
2.1.5 Ασαφής λογική	14
2.1.6 Γενικοί αλγόριθμοι.....	15
2.2 Γενικά βήματα λειτουργίας των αλγορίθμων	16
2.2.1 Βάση δεδομένων αλγορίθμου	17
2.2.2 Εκπαίδευση.....	17
2.2.3 Συναρτήσεις σφάλματος.....	18
2.2.4 Διάγραμμα καμπύλων Receiver Operating Characteristic (ROC).....	20
Κεφάλαιο 3 Εφαρμογές τεχνητής νοημοσύνης.....	23
3.1 Παρακολούθηση δομικής ακεραιότητας κατασκευών και σχεδιασμός συστήματος παρακολούθησής τους.....	23
3.1.1 Μελέτη περίπτωσης 1: Ανίχνευση βλαβών σε σιδηροδρομική γέφυρα με επιρροή της θερμοκρασίας.....	26
3.1.2 Μελέτη περίπτωσης 2: Ανίχνευση βλαβών σε σιδηροδρομική γέφυρα.....	32
3.2 Πρόβλεψη αστοχιών και σχεδιασμός δομικών στοιχείων των κατασκευών.....	37
3.2.1 Μελέτη Περίπτωσης 1: Πρόβλεψη διάβρωσης χάλυβα.....	38

3.2.2 Μελέτη Περίπτωσης 2: Βελτίωση σχεδιασμού ψηλών κτηρίων με χρήση μηχανικής μάθησης.....	44
3.3 Πρόβλεψη σύνθεσης και ιδιοτήτων σκυροδέματος.....	47
3.3.1 Μελέτη περίπτωσης 1: Πρόβλεψη θλιπτικής αντοχής σε δοκίμια πολλών εθνών.....	49
3.3.2 Μελέτη περίπτωσης 2: Προβλέψεις σύνθεσης και ιδιοτήτων μέσω της κατάταξης στοιχείων.....	53
3.4 Ενεργειακή σχεδίαση κατασκευών.....	60
3.4.1 Μελέτη περίπτωσης 1: Πρόβλεψη ενεργειακής κατανάλωσης κτηρίου με την χρήση της μεθόδου βαθιάς μάθησης (Deep Learning).....	61
3.4.2 Μελέτη Περίπτωσης 2: Πρόβλεψη ενεργειακής κατανάλωσης σε κτήρια μέσω τεχνητού νευρωνικού δικτύου.....	67
3.5 Πυρασφάλεια (ανίχνευση – σχεδιασμός).....	72
3.5.1 Μελέτη περίπτωσης 1: Πρόβλεψη αντοχής κεντρικών υποστυλωμάτων σε συνθήκες πυρκαγιάς.....	73
3.5.2 Μελέτη Περίπτωσης 2: Εντοπισμός πυρκαγιάς και υπερθέρμανσης με την χρήση μηχανικής μάθησης.....	76
Κεφάλαιο 4 Σύνοψη και σχολιασμός.....	81
Κεφάλαιο 4.1 Σύνοψη.....	81
Κεφάλαιο 4.2 Σχολιασμός.....	82
Βιβλιογραφία.....	86

Κατάλογος Πινάκων

Πίνακας 1: Υλικά και γεωμετρικά χαρακτηριστικά της κατασκευής (Chalouhi et al., 2017)	27
Πίνακας 2: Θερμικά χαρακτηριστικά του υλικού της γέφυρας (Chalouhi et al., 2017)	27
Πίνακας 3: Πειραματικά αποτελέσματα από το πρώτο δοκίμιο (Sadowski, 2013).....	41
Πίνακας 4: Πειραματικά αποτελέσματα από το δεύτερο δοκίμιο (Sadowski, 2013) ..	41
Πίνακας 5: Χαρακτηριστικά των δειγμάτων (Ma et al., 2013).....	46
Πίνακας 6: Αποτελέσματα πρόβλεψης του γενετικού νευρωνικού δικτύου (Ma et al., 2013)	47
Πίνακας 7: Οι ιδιότητες του HPC ανά χώρα (Chou et al., 2014)	51
Πίνακας 8: Πρόβλεψη απόδοσης των μεμονωμένων μεθόδων (Chou et al., 2014)	52
Πίνακας 9: Σύγκριση των καλύτερων μεμονωμένων και συνδυασμένων μεθόδων (Chou et al., 2014)	53
Πίνακας 10: Το φάσμα των συστατικών των δοκιμίων του σκυροδέματος (Vakharia και Gujar, 2019)	54
Πίνακας 11: Το φάσμα των συστατικών των δοκιμίων για την κάθιση του σκυροδέματος (Vakharia και Gujar, 2019).....	54
Πίνακας 12: Το φάσμα των δεδομένων του τσιμέντου Portland (Vakharia και Gujar, 2019)	55
Πίνακας 13: Στοιχεία για την πρόβλεψη της θλιπτικής αντοχής σκυροδέματος (Vakharia και Gujar, 2019).....	55
Πίνακας 14: Στοιχεία για την πρόβλεψη της θλιπτικής αντοχής μέσω της κάθισης (slump test) (Vakharia και Gujar, 2019)	56
Πίνακας 15: Στοιχεία για την πρόβλεψη σύνθεσης του τσιμέντου Portland (Vakharia και Gujar, 2019).....	56
Πίνακας 16: Δεδομένα του κτηρίου (Amasyali και El-Gohary, 2017).....	62
Πίνακας 17: Χαρακτηριστικά που εμφανίζονται στο κτήριο κατά την λειτουργία (Amasyali και El-Gohary, 2017).....	63
Πίνακας 18: Χαρακτηριστικά του κλίματος για κάθε περιοχή (Amasyali και El-Gohary, 2017)	63
Πίνακας 19: Αποτελέσματα όλων των μεθόδων (Amasyali και El-Gohary, 2017)	65

Πίνακας 20: Πιθανοί συνδυασμοί χαρακτηριστικών κτηρίου για εκπαίδευση και δοκιμή
(Ekici και Aksoy, 2009).....69

Κατάλογος Σχημάτων

Σχήμα 1: Διάγραμμα χρονολογικής εξέλιξης ορισμένων επιστημών ανά έτος (Scopus και ίδια επεξεργασία).....	2
Σχήμα 2: Διάγραμμα χρονολογικής εξέλιξης εφαρμογών στον τομέα του πολιτικού μηχανικού (Scopus και ίδια επεξεργασία).....	4
Σχήμα 3: Απεικόνιση της τεχνητής νοημοσύνης και των υποσυνόλων της (Salehi και Burgueno, 2018)	5
Σχήμα 4: Κατηγορίες εκμάθησης του Machine Learning (Salehi και Burgueno, 2018)	7
Σχήμα 5: Σχεδιάγραμμα της μεθόδου αναγνώρισης προτύπων (Salehi και Burgueno, 2018 και των ιδίων).....	8
Σχήμα 6: Διαδικασία αναδρομικού δικτύου (Μήτσιος, 2017 και των ιδίων).....	9
Σχήμα 7: Τεχνητό νευρωνικό δίκτυο με N κρυμμένα στρώματα (Hyeon-Jong et al., 2019 και των ιδίων).....	10
Σχήμα 8: Μαθηματικό μοντέλο νευρώνα (Russell και Norvig, 2003)	11
Σχήμα 9: Η διαδικασία του γενετικού αλγορίθμου (Boukhatem et al., 2011 και των ιδίων).....	13
Σχήμα 10: Διαδικασία της Ασαφούς λογικής (Li και Adeli, 2018 και των ιδίων)	15
Σχήμα 11: Πέντε φορές διασταυρούμενη επικύρωση (Vakharia and Gujar, 2019 και των ιδίων).....	18
Σχήμα 12: Τρόπος κατασκευής καμπύλης ROC (Neves et al., 2017)	21
Σχήμα 13: Διάγραμμα καμπύλης ROC (Neves et al., 2017).....	22
Σχήμα 14: Διαδικασία της παρακολούθησης της δομικής ακεραιότητας των κατασκευών (SHM) (Amezquita-Sanchez et al., 2018)	23
Σχήμα 15: Διαδικασία που ακολουθείται για την επεξεργασία του σχήματος (Amezquita-Sanchez et al., 2018).....	24
Σχήμα 16: Σχηματική απεικόνιση του μοντέλου γέφυρας: ■ θέσεις των επιταχυνσιόμετρων, × θέσεις που προσομοιώθηκαν οι κατεστραμμένες συνθήκες (Chalouhi et al., 2017)	28
Σχήμα 17: Διαγράμματα σφάλματος πρόβλεψης σε σχέση με τις διελεύσεις της αμαξοστοιχίας: — γραμμή σφάλματος των φυσιολογικών συνθηκών, — γραμμή σφάλματος των κατεστραμμένων συνθηκών (Chalouhi et al., 2017).....	28

Σχήμα 18: Διαγράμματα σφάλματος πρόβλεψης και ταχύτητας ως ανεξάρτητη μεταβλητή: ○ φυσιολογικές συνθήκες, * κατεστραμμένες συνθήκες, + περάσματα αμαξοστοιχίας σε φυσιολογικές συνθήκες (Chalouhi et al., 2017)	29
Σχήμα 19: Διαγράμματα σφάλματος πρόβλεψης και θερμοκρασίας ως ανεξάρτητη μεταβλητή: ○ φυσιολογικές συνθήκες, * κατεστραμμένες συνθήκες, + περάσματα αμαξοστοιχίας σε φυσιολογικές συνθήκες (Chalouhi et al., 2017)	30
Σχήμα 20: Διάγραμμα ROC καμπυλών (Chalouhi et al., 2017)	31
Σχήμα 21: Περίπτωση βλάβης 1: 1-6 θέσεις των επιταχυνσιόμετρων, — θέση κατεστραμμένης συνθήκης, — βραχίονες, — σιδηροδρομική γραμμή (Neves et al., 2017)	33
Σχήμα 22: Περίπτωση βλάβης 2: 1-6 θέσεις των επιταχυνσιόμετρων, — θέση κατεστραμμένης συνθήκης, — βραχίονες, — σιδηροδρομική γραμμή (Neves et al., 2017)	33
Σχήμα 23: Αποτελέσματα RMSE για την περίπτωση βλάβης 1: ○ φυσιολογικές συνθήκες, + κατεστραμμένες συνθήκες (Neves et al., 2017)	34
Σχήμα 24: Αποτελέσματα Gauss για την περίπτωση βλάβης 1: ○ φυσιολογικές συνθήκες, * κατεστραμμένες συνθήκες, + τυχαία δεδομένα σε φυσιολογικές συνθήκες, — μέση απόκλιση, ■ τυπική απόκλιση (Neves et al., 2017)	35
Σχήμα 25: Διάγραμμα καμπυλών ROC για την πρώτη περίπτωση βλάβης με διαφορετικά μεγέθη βλάβης: — 20cm, — 40cm, — 70cm, — 100cm, — 160cm (Neves et al., 2017)	36
Σχήμα 26: Διάγραμμα καμπύλης ROC για την δεύτερη περίπτωση βλάβης (Neves et al., 2017)	36
Σχήμα 27: Σχηματική απεικόνιση μέτρησης της ηλεκτρικής αντίστασης (Sadowski, 2010)	39
Σχήμα 28: Τρόπος μέτρησης αντίστασης στο εργαστήριο (Sadowski, 2013).....	40
Σχήμα 29: Στάδια μεθοδολογίας για το MLP-NN (Sadowski, 2013).....	42
Σχήμα 30: Δομές MLP-NN: Αριστερά του πρώτου δοκιμίου και δεξιά του δεύτερου δοκιμίου (Sadowski, 2013)	43
Σχήμα 31: Διαγράμματα αποτελεσμάτων για την γενικευμένη επαλήθευση του MLP-NN (Sadowski, 2013).....	44
Σχήμα 32: Προβλεπόμενα αποτελέσματα για την θλιπτική αντοχή (Vakharina και Gujar, 2019)	57

Σχήμα 33: Προβλεπόμενα αποτελέσματα για την θλιπτική αντοχή μέσω κάθισης (slump test) (Vakharia και Gujar, 2019).....	58
Σχήμα 34: Προβλεπόμενα αποτελέσματα της σύνθεσης του τσιμέντου Portland (Vakharia και Gujar, 2019).....	59
Σχήμα 35: Προσομοίωμα κτηρίου (Amasyali και El-Gohary, 2017).....	62
Σχήμα 36: Δομή της μεθόδου DNN (Amasyali και El-Gohary, 2017).....	64
Σχήμα 37: Αποτελέσματα του DNN για κάθε περιοχή (Amasyali και El-Gohary, 2017).....	66
Σχήμα 38: Δομή του τεχνητού νευρωνικού δικτύου (Ekici και Aksoy, 2009).....	68
Σχήμα 39: Δομή κτηρίου και τοιχοποιίας (Ekici και Aksoy, 2009).....	68
Σχήμα 40: Καμπύλες σφαλμάτων των κτηρίων κατά την εκπαίδευση (Ekici και Aksoy, 2009).....	70
Σχήμα 41: Σύγκριση των υπολογισμένων από το πρόγραμμα (calculated) και προβλεπόμενων από το ANN (estimated) αποτελεσμάτων για κάθε δομή κτηρίου (Ekici και Aksoy, 2009).....	71
Σχήμα 42: Απεικόνιση των τύπων διατομής και οι συνθήκες στήριξης (Lazarevska et al., 2016).....	74
Σχήμα 43: Επίδραση του τύπου διατομής στην πυραντίσταση των δοκιμίων (Lazarevska et al., 2016).....	74
Σχήμα 44: Συγκριτικό διάγραμμα των δοκιμίων 30×30 (Lazarevska et al., 2016).....	76
Σχήμα 45: Απεικόνιση των αισθητήρων στους χώρους τοποθέτησης τους (Huang et al. 2012).....	78
Σχήμα 46: Διάγραμμα θερμοκρασίας-χρόνου για τα όρια των αισθητήρων μετά την εκπαίδευση (Huang et al. 2012).....	79
Σχήμα 47: a) Διάγραμμα θερμοκρασίας-χρόνου για τα αποτελέσματα της μεθόδου Gauss την ημέρα 22 Απριλίου του αισθητήρα 1. b) Διάγραμμα δείκτη απόκλισης KL-χρόνου για τα αποτελέσματα της μεθόδου KL την ημέρα 23 Απριλίου και για τους δυο αισθητήρες (Huang et al. 2012).....	80

Αρκτικόλεξα

AI: Artificial Intelligence

ML: Machine Learning

DL: Deep Learning

ANN: Artificial Neural Networks

GA: Genetic Algorithm

SHM: Structural Health Monitoring

MLP-NN: Multi-Layer Perception Neural Network

SVM: Support Vector Machine

DNN: Deep Neural Networks

ROC: Receiver Operation Characteristic

Κεφάλαιο 1 Εισαγωγή

Στο κεφάλαιο αυτό αναφέρονται ορισμένα ιστορικά στοιχεία, λόγοι και κατηγορίες που χρησιμοποιείται η τεχνητή νοημοσύνη στις μέρες μας. Επίσης, παρουσιάζεται με διαγράμματα η χρονολογική πορεία της τεχνητής νοημοσύνης σε διάφορες κατηγορίες και γίνεται αναφορά στην επιρροή που έχει στον τομέα του πολιτικού μηχανικού.

1.1 Τεχνητή νοημοσύνη

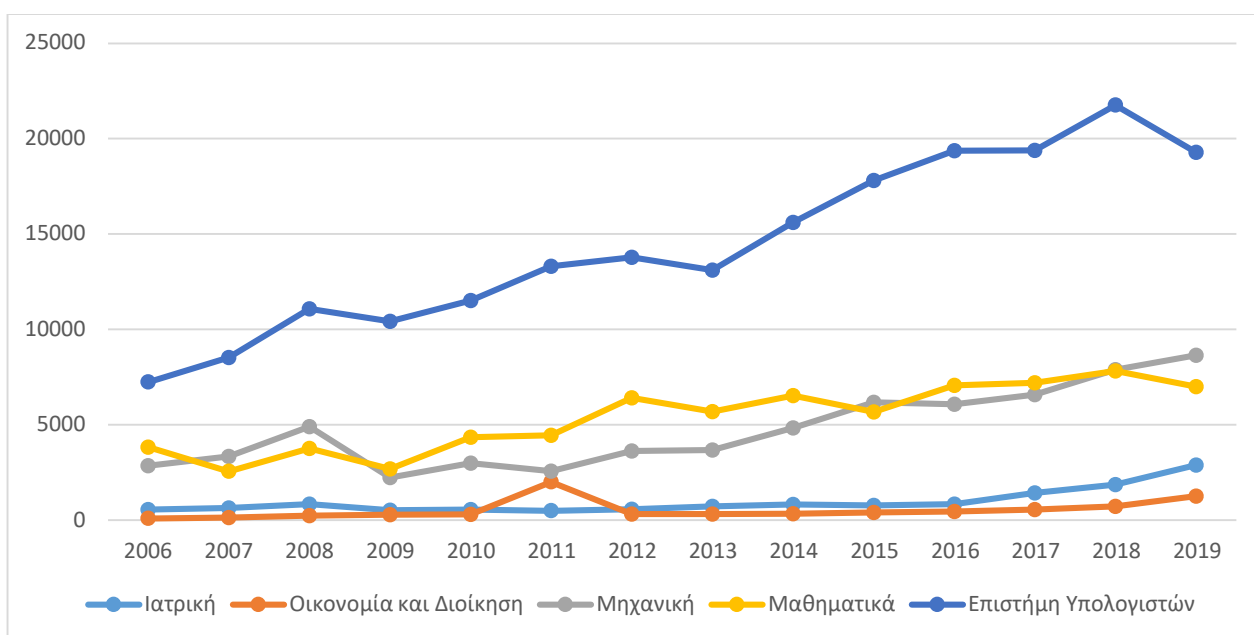
Για πολλά χρόνια ο άνθρωπος προσπαθεί να κατανοήσει το πώς σκέφτεται, δηλαδή πώς αντιλαμβάνεται, κατανοεί, προβλέπει και χειρίζεται ένα κόσμο μεγαλύτερο από τον εαυτό του. Το πεδίο της τεχνητής νοημοσύνης (Artificial Intelligence) προσπαθεί όχι μόνο να κατανοήσει, αλλά και να κατασκευάσει νοήμονες οντότητες. Υπάρχουν πολλοί ορισμοί της τεχνητής νοημοσύνης που βασίζονται σε συστήματα για το πώς σκέφτονται και πώς ενεργεί ο άνθρωπος και σε συστήματα που σκέφτονται και ενεργούν ορθολογικά. Συγκεκριμένα, οι ορισμοί των κατηγοριών που αναφέρθηκαν παραπάνω παρουσιάζονται ως εξής:

- **Συστήματα που σκέφτονται σαν τον άνθρωπο:** “Η αυτοματοποίηση των δραστηριοτήτων που συσχετίζονται με την ανθρώπινη σκέψη, όπως η λήψη αποφάσεων, η επίλυση προβλημάτων, η μάθηση...” (Bellman, 1978)
- **Συστήματα που ενεργούν σαν τον άνθρωπο:** “Η μελέτη του πώς μπορούμε να κάνουμε τους υπολογιστές να κάνουν πράγματα στα οποία, προς το παρόν, οι άνθρωποι είναι καλύτεροι.” (Rich and Knight, 1991)
- **Συστήματα που σκέφτονται ορθολογικά:** “Η μελέτη των υπολογιστικών εργασιών που μας δίνουν την δυνατότητα να αντιλαμβανόμαστε, να συλλογίζομαστε, και να ενεργούμε.” (Winston, 1992)
- **Συστήματα που ενεργούν ορθολογικά:** “Η τεχνητή νοημοσύνη ασχολείται με την ευφυή συμπεριφορά των τεχνουργημάτων.” (Nilsson, 1998)

Η τεχνητή νοημοσύνη είναι μια από τις νεότερες επιστήμες. Η σύλληψη και η εκτέλεση της ιδέας άρχισε να γίνεται μετά τον δεύτερο παγκόσμιο πόλεμο και πιο συγκεκριμένα ο όρος της τεχνητής νοημοσύνης εμφανίστηκε το 1956. Η δημιουργία της πρώτης γλώσσας προγραμματισμού, η οποία βοήθησε αρκετά στην ανάπτυξη της τεχνητής νοημοσύνης, είναι η γλώσσα LISP και καταγράφεται το 1958. Στη συνέχεια,

παρατηρήθηκε μια πτώση στην εξέλιξη της μέχρι την δεκαετία του '80, όπου η ανάπτυξη μιας νέας γλώσσας προγραμματισμού οδήγησε στην υλοποίηση περισσότερων εφαρμογών, όπως τα τεχνητά νευρωνικά δίκτυα. Μεγάλη αύξηση γνώρισε την δεκαετία του '90 και πιο συγκεκριμένα οι ευφυείς πράκτορες (agents), που είναι αυτόνομο λογισμικό της τεχνητής νοημοσύνης το οποίο αλληλοεπιδρά με το περιβάλλον. Επίσης, στο ίδιο διάστημα η τεχνητή νοημοσύνη επηρεάστηκε από την θεωρία πιθανοτήτων και στατιστικής. Η εξέλιξη της συνεχίζεται μέχρι σήμερα, αφού δεν έχει καλυφθεί πλήρως από τους προηγούμενους επιστήμονες.

Η τεχνητή νοημοσύνη συστηματοποιεί και αυτοματοποιεί διανοητικές εργασίες για αυτό και έχει ως αποτέλεσμα την εφαρμογή της σε οποιαδήποτε ανθρώπινη διανοητική δραστηριότητα. Συγκεκριμένα, συνδυάζει μια τεράστια ποικιλία επιμέρους πεδίων, τα οποία καλύπτουν ένα φάσμα που ξεκινά από γενικούς τομείς, όπως η μάθηση και η αντίληψη, και τελειώνει σε εργασίες όπως αποδείξεις μαθηματικών θεωρημάτων και σκάκι. Γενικά, η τεχνητή νοημοσύνη έχει ένα μεγάλο εύρος εφαρμογών και μερικά παραδείγματα είναι ο αυτόνομος σχεδιασμός και χρονοπρογραμματισμός, παιχνίδια, αυτόνομος έλεγχος, διάγνωση, ρομποτική και κατανόηση γλώσσας και επίλυση προβλημάτων. Έτσι αντιλαμβάνεται κανείς ότι η τεχνητή νοημοσύνη επιδρά σε πολλούς τομείς, όπως για παράδειγμα στην ιατρική, στην οικονομία, στην βιομηχανία, στην τεχνολογία και στον τομέα του μηχανικού.



Σχήμα 1: Διάγραμμα χρονολογικής εξέλιξης ορισμένων επιστημών ανά έτος (Scopus και ίδια επεξεργασία)


Στο Σχήμα 1 φαίνεται ένα συγκριτικό διάγραμμα της χρονολογικής εξέλιξης, ανά έτος, ορισμένων επιστημών που συμβάλλει η τεχνητή νοημοσύνη και διακρίναμε, με βάση άρθρα που έχουν δημοσιευθεί στην ηλεκτρονική βιβλιοθήκη του Scopus. Η αναζήτηση έγινε χρησιμοποιώντας τις κατάλληλες λέξεις κλειδιά με την αγγλική τους ορολογία για την κάθε κατηγορία που αναφέρουμε. Αυτές είναι η ιατρική, η οικονομία και διοίκηση, η μηχανική, η επιστήμη των μαθηματικών και η επιστήμη των υπολογιστών.

Όπως φαίνεται στο Σχήμα 1, την μεγαλύτερη εξέλιξη και ενασχόληση με την τεχνητή νοημοσύνη έχει η επιστήμη των υπολογιστών, όπως είναι αναμενόμενα λόγω της ανάπτυξης της τεχνολογίας των τελευταίων χρόνων. Ακόμη, μια σταθερή άνοδος παρατηρείται και στην επιστήμη του μηχανικού, σε αντίθεση με την επιστήμη των μαθηματικών όπου έχει πολλές αυξομειώσεις. Τέλος, όσον αφορά την οικονομία και την διοίκηση, φαίνεται να μην υπάρχει μεγάλη ενασχόληση με την τεχνητή νοημοσύνη.

1.2 Επιρροή στην επιστήμη του πολιτικού μηχανικού

Η τεχνητή νοημοσύνη επιδρά σε όλους τους βιομηχανικούς τομείς, όπως και του πολιτικού μηχανικού όμως με πιο αργά βήματα προόδου. Παρόλα αυτά ο κατασκευαστικός τομέας αναμένεται να επηρεαστεί και να αναπτυχθεί αρκετά μέσω της τεχνολογίας και κυρίως από την τεχνητή νοημοσύνη. Όταν γίνεται αναφορά της στον πολιτικό μηχανικό, αναφερόμαστε σε εξελιγμένες εφαρμογές στην βελτιστοποίηση του σχεδιασμό, στον έλεγχο των κινδύνων και τον ποιοτικό έλεγχο της κατασκευής. Οι κατασκευαστικές εργασίες με την χρήση της τεχνητής νοημοσύνης γίνονται πιο εύχρηστες και μπορεί να προσφέρει μεγαλύτερα κέρδη στις κατασκευάστριες εταιρίες.

Η συμβολή της τεχνητής νοημοσύνης τόσο στην επιστήμη του πολιτικού μηχανικού όσο και στην αρχιτεκτονική γίνεται με πολλούς και διάφορους τρόπους. Για παράδειγμα, μπορεί να συνεισφέρει αποτελεσματικά στον σχεδιασμό, στην εποπτεία μιας κατασκευής και να διορθώσει τυχόν λάθη σε περίπτωση που η περιοχή είναι επιρρεπής σε σεισμούς. Ακόμη, έχει την δυνατότητα να υπολογίζει όχι μόνο το χρονοδιάγραμμα εκτέλεσης, αλλά και το κόστος κατασκευής που χρειάζεται. Επίσης, εξίσου σημαντική είναι η συνεισφορά στην συντήρηση μιας κατασκευής ελέγχοντας τα δομικά στοιχεία και άλλα χαρακτηριστικά της που μπορούν να επεκτείνουν τον κύκλο ζωής της.



Σχήμα 2: Διάγραμμα χρονολογικής εξέλιξης εφαρμογών στον τομέα του πολιτικού μηχανικού (Scopus και ίδια επεξεργασία)

Στο Σχήμα 2 απεικονίζεται ένα διάγραμμα χρονολογικής εξέλιξης, ανά έτος, σε ορισμένες κατηγορίες που εφαρμόζεται η τεχνητή νοημοσύνη, με βάση δημοσιευμένα άρθρα, στον τομέα του πολιτικού μηχανικού και αναφέρονται και στα παρακάτω κεφάλαια. Οι κατηγορίες αυτές είναι η παρακολούθηση της δομικής ακεραιότητας μιας κατασκευής (SHM), η πυρασφάλεια, η ενεργειακή κατανάλωση και η πρόβλεψη αστοχιών σε δομές σκυροδέματος. Όπως παρατηρεί κανείς οι έρευνες για την ενεργειακή κατανάλωση τα τελευταία χρόνια έχουν σημειώσει μια απότομη αύξηση, λόγω των κλιματικών αλλαγών. Αντίθετα οι υπόλοιπες εφαρμογές στον τομέα αυτό εμφανίζουν μια μικρότερη και πιο σταδιακή αύξηση. Η δημιουργία του διαγράμματος έγινε με την ίδια διαδικασία όπως στο Σχήμα 1.

Η εφαρμογή της τεχνητής νοημοσύνης στην κατασκευαστική βιομηχανία, και συγκεκριμένα στον τομέα του πολιτικού μηχανικού, καθιστά την ανάπτυξη των έργων γρηγορότερη και οικονομικότερη. Έτσι η ενασχόληση του πολιτικού μηχανικού με αυτή δίνει ένα σημαντικό πλεονέκτημα σε σχέση με τον ανταγωνισμό.

Κεφάλαιο 2 Κατηγορίες τεχνητής νοημοσύνης


Στις παρακάτω παραγράφους γίνεται αναφορά διαφόρων μεθόδων στις οποίες διακρίνεται η τεχνητή νοημοσύνη, όπως η μηχανική μάθηση, τα τεχνητά νευρωνικά δίκτυα και άλλα, καθώς και τεχνικών που εφαρμόζονται σε τέτοια μοντέλα, όπως η εκπαίδευση και τρόπος ελέγχου ενός αλγορίθμου.

2.1 Αλγόριθμοι τεχνητής νοημοσύνης

Στην ενότητα αυτή θα αναλύσουμε την λειτουργία των πιο συχνών αλγορίθμων που εφαρμόζονται στην τεχνητή νοημοσύνη.

2.1.1 Μηχανική μάθηση

Ένα από τα κυριότερα υποσύνολα της τεχνητής νοημοσύνης είναι η μηχανική μάθηση (Machine Learning - ML), όπως φαίνεται και στο Σχήμα 3. Ως μηχανική μάθηση ορίζεται η ικανότητα δημιουργίας αλγορίθμων, οι οποίοι μέσω ενός μαθηματικού μοντέλου μαθαίνουν και εκτελούν κάποιες διεργασίες χωρίς να έχουν προγραμματιστεί ρητά για αυτές. Συγκεκριμένα, σύμφωνα με τους Salehi και Burgueno (2018), η λειτουργία των αλγορίθμων βασίζεται στην κατασκευή μοντέλων μέσω πειραματικών δεδομένων, ώστε να πραγματοποιούν προβλέψεις και να εξάγουν αποτελέσματα με βάση αυτά. Επιπλέον, η μηχανική μάθηση έχει ένα πιο γενικό εύρος σε σχέση με τις άλλες μεθόδους τεχνητής νοημοσύνης και μπορεί να χρησιμοποιηθεί σε διάφορους κλάδους, όπως του μηχανικού, της επιστήμης των υπολογιστών, της οικονομίας και άλλων.

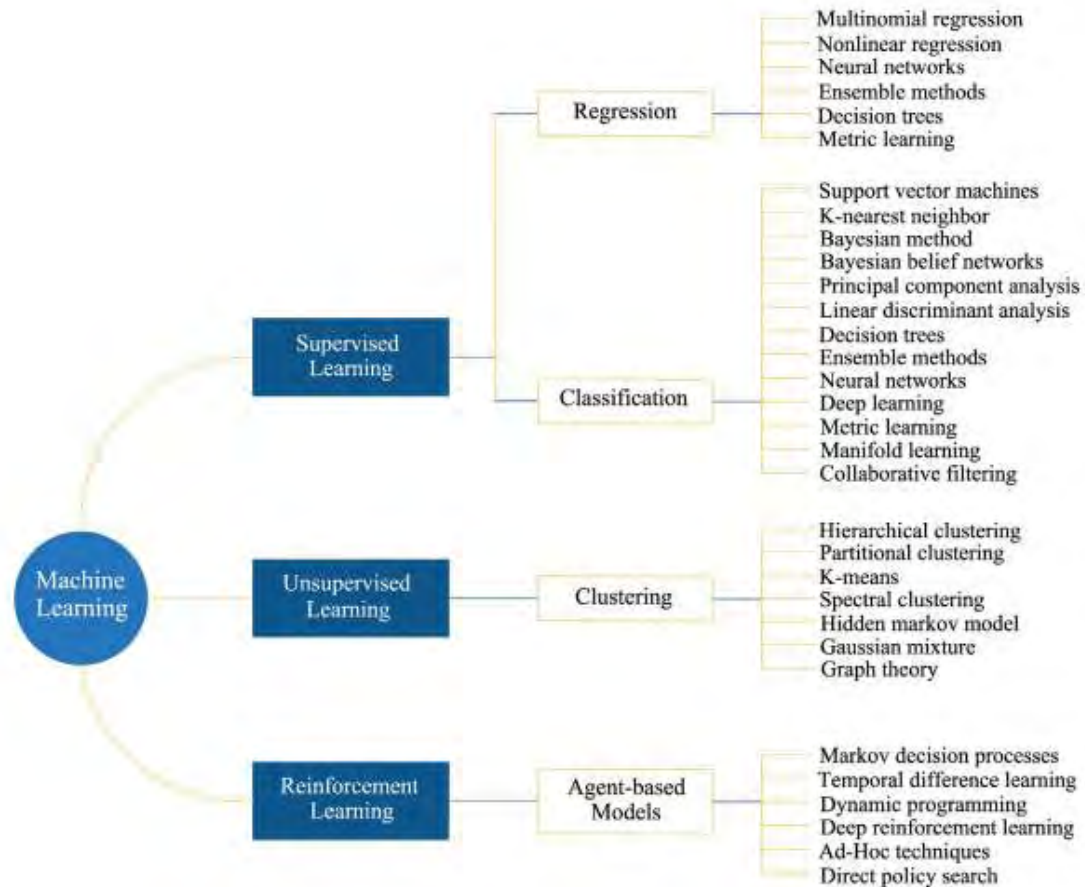


Σχήμα 3: Απεικόνιση της τεχνητής νοημοσύνης και των υποσυνόλων της (Salehi και Burgueno, 2018)

Η εκμάθηση της μεθόδου αυτής διακρίνεται σε τρεις κατηγορίες, όπως παρουσιάζεται στο Σχήμα 4, την μάθηση με επίβλεψη (supervised learning), την μάθηση χωρίς επίβλεψη (unsupervised learning) και την ενισχυτική μάθηση (reinforcement learning). Η διαδικασία που παρουσιάζει η μάθηση με επίβλεψη συνδυάζει έναν εξωτερικό εκπαιδευτή και τη συνολική ή γενικευμένη πληροφορία. Στόχος της είναι η όσο το δυνατόν πιο ακριβή πρόβλεψη αποτελεσμάτων σε εφαρμογές με άγνωστα στοιχεία. Παραδείγματα στα οποία χρησιμοποιείται η μάθηση με επίβλεψη είναι για αποφάσεις για το πότε θα πρέπει να σταματήσει η διαδικασία εκπαίδευσης και η παρουσίαση προόδου του δικτύου. Ωστόσο, η διαδικασία χωρίζεται σε δυο κατηγορίες ανάλογα με το αποτέλεσμα του προβλήματος που θέλει να προβλέψει. Αν η πρόβλεψη αφορά συνεχείς μεταβλητές τότε ορίζεται ως παλινδρόμηση (regression), ενώ αν αφορά διακριτές μεταβλητές ορίζεται ως ταξινόμηση (classification). Ένα παράδειγμα αυτής της μεθόδου είναι στην ανάλυση ενός χειρόγραφου όταν ένας εξωτερικός εκπαιδευτής πρέπει να καθορίσει το εκπαιδευτικό σύνολο, το οποίο μπορεί να είναι ένας χειρόγραφος χαρακτήρας, μια ολόκληρη λέξη ή μια ολόκληρη σειρά.

Αντιθέτως, στην μάθηση χωρίς επίβλεψη, που αποτελείται από αυτοργανωμένους αλγόριθμους, δεν απαιτείται η παρουσία κάποιου επιβλέποντα με αποτέλεσμα να μην μπορεί να γίνει τροποποίηση των δεδομένων ή των παραμέτρων. Στόχος της μάθησης αυτής είναι να διαχωρίζει τα δεδομένα σε ομάδες, ώστε να παρουσιάζει υψηλό επίπεδο εγγύτητας. Έτσι, το σύστημα δημιουργεί από μόνο του μια συστάδα (cluster) από τα δεδομένα εισόδου. Για παράδειγμα, η μέθοδος αυτή μπορεί να χρησιμοποιηθεί για την αναγνώριση ενός αντικειμένου, όπως είναι το ποδήλατο, σε ένα μεγάλο πλήθος από βίντεο.

Όσον αφορά την ενισχυτική μάθηση, δίνει την δυνατότητα σε ένα πρόγραμμα να αλληλεπιδρά με ένα δυναμικό περιβάλλον, με σκοπό την επίτευξη ενός στόχου χωρίς κάποιος εξωτερικός παράγοντας να τροποποιεί την διαδικασία του. Η βελτιστοποίηση του γίνεται με την χρήση κάποιου πράκτορα (agent), ο οποίος με βάση δοκιμές και σφάλματα, που έχει συλλέξει, καθορίζει την ιδανική συμπεριφορά. Ένα παράδειγμα αυτής της μάθησης είναι η δυνατότητα αντιμετώπισης κάποιου αντιπάλου σε ένα παιχνίδι, όπως το σκάκι.



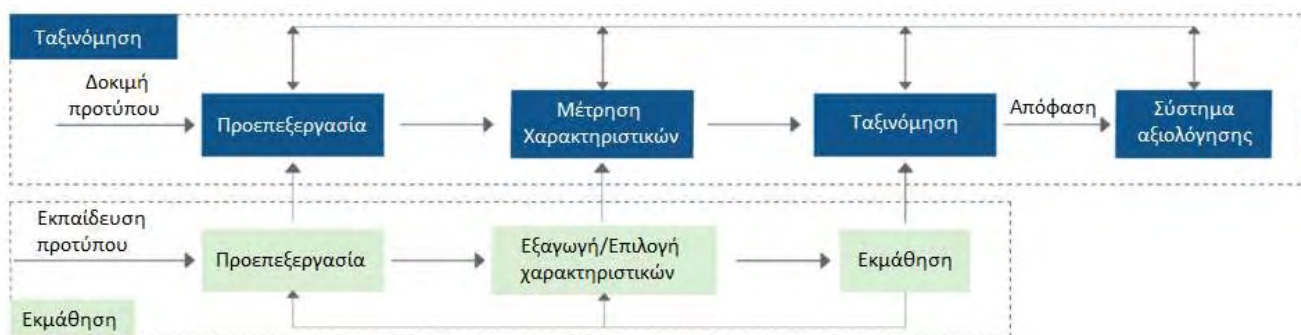
Σχήμα 4: Κατηγορίες εκμάθησης του Machine Learning (Salehi και Burgueno, 2018)

Ως ένας τομέας της μηχανικής μάθησης θεωρείται η βαθιά μάθηση (Deep Learning), η οποία όπως φαίνεται στο Σχήμα 3 είναι υποσύνολο της μηχανικής μάθησης (Machine Learning) και αποτελεί μέρος της τεχνητής νοημοσύνης (Artificial Intelligence). Το σύστημα μαθαίνει διάφορα χαρακτηριστικά από τα δεδομένα. Συγκεκριμένα, λειτουργεί ως ένα εργαλείο αναπαράστασης των δεδομένων, με σκοπό να συμβάλει στην κατανόηση τους, ώστε να λυθεί το πρόβλημα από την μηχανική μάθηση. Η μέθοδος της βαθιάς μάθησης είναι βασισμένη κυρίως στην διαδικασία που ακολουθούν τα νευρωνικά δίκτυα.

2.1.2 Αναγνώριση προτύπων

Η αναγνώριση προτύπων (Pattern Recognition) έχει προσελκύσει το ενδιαφέρον των ερευνητών για την δημιουργία αλγορίθμων με αυτοματοποιημένη διαδικασία, με σκοπό την αναγνώριση διάφορων δεδομένων που εισάγονται. Επιπλέον, είναι στενά συνδεδεμένη με την επιστήμη της τεχνητής νοημοσύνης και της μηχανικής μάθησης, όπως φαίνεται για παράδειγμα στην εξόρυξη δεδομένων (Data Mining).

Σύμφωνα με την διαδικασία αυτή, κάνει εξόρυξη κάποιων πληροφοριών από μεγάλες βάσεις δεδομένων, με σκοπό οι πληροφορίες που θα εξαχθούν να την κάνουν πιο κατανοητή προς τον μελετητή και να πάρει τις κατάλληλες αποφάσεις. Ως αναγνώριση προτύπων ορίζεται μια τεχνική κατά την οποία ταξινομεί τα αντικείμενα σε διάφορες τάξεις ή κατηγορίες. Τέτοια αντικείμενα μπορεί να είναι εικόνες, σήματα, ομιλία ή μετρήσεις. Η διαδικασία που ακολουθεί ένας αλγόριθμος αναγνώρισης προτύπων, σύμφωνα με τους Salehi και Burgueno (2018), αποτελείται από δύο λειτουργίες, οι οποίες είναι η εκμάθηση και η ταξινόμηση. Κατά την λειτουργία της εκμάθησης, από το σύνολο των χαρακτηριστικών γίνεται εξαγωγή των επιλεγμένων χαρακτηριστικών και ο ταξινομητής εκπαιδεύεται να τα χωρίζει στο χώρο. Στη λειτουργία ταξινόμησης, τα μοτίβα που εισέρχονται κάνουν χρήση του εκπαιδευμένου ταξινομητή, ενώ η αποτελεσματικότητά του ελέγχεται με κάποιο σύστημα αξιολόγησης. Η παραπάνω διαδικασία φαίνεται και στο Σχήμα 5.



Σχήμα 5: Σχεδιάγραμμα της μεθόδου αναγνώρισης προτύπων (Salehi και Burgueno, 2018 και των ιδίων)

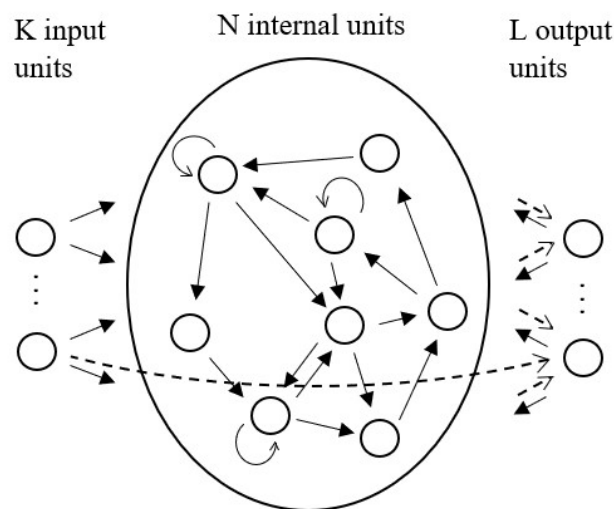
Η αναγνώριση προτύπων μπορεί να είναι επιβλεπόμενη ή μη-επιβλεπόμενη μέθοδος. Οι έννοιες αυτές έχουν αναφερθεί στην παράγραφο της μηχανικής μάθησης. Επίσης, η μέθοδος αυτή διαφοροποιείται σε γενετικά και διακριτικά μοντέλα. Τα γενετικά μοντέλα είναι στατιστικά μοντέλα με συνδυασμένη πιθανότητα κατανομής, ενώ τα διακριτικά μοντέλα είναι μοντέλα της υπό όρους πιθανότητας ενός στόχου.

2.1.3 Τεχνητά νευρωνικά δίκτυα

Τα τελευταία χρόνια έχει υπάρξει μεγάλο ενδιαφέρον για την εφαρμογή των τεχνητών νευρωνικών δικτύων (Artificial Neural Networks - ANN) σε πεδία της επιστήμης και της τεχνολογίας. Για παράδειγμα, κάποιες από αυτές είναι η ιατρική, τα χρηματοοικονομικά, η επιστήμη του μηχανικού και άλλες. Συγκεκριμένα,

χρησιμοποιούνται με μεγάλη απήχηση στους παραπάνω κλάδους σε θέματα πρόβλεψης, ταξινόμησης ή ελέγχου. Ως αποτέλεσμα πολλών πειραμάτων και αναλύσεων που έχουν γίνει, το τεχνητό νευρωνικό δίκτυο έχει μεγάλο ποσοστό επιτυχιών.

Αρχικά, το τεχνητό νευρωνικό δίκτυο ορίζεται ως ένα δίκτυο το οποίο αποτελείται από υπολογιστικούς κόμβους (νευρώνες), που είναι συνδεδεμένοι μεταξύ τους. Υπάρχουν δύο κατηγορίες νευρωνικών δικτύων, τα δίκτυα με την εμπρός τροφοδότηση (feed-forward neural networks) και τα αναδρομικά (recurrent neural networks). Η διαδικασία που ακολουθεί ένα αναδρομικό δίκτυο είναι να τροφοδοτεί έναν κόμβο από οποιονδήποτε άλλον χωρίς κάποια συγκεκριμένη ροή. Για παράδειγμα, ο κόμβος εξόδου μπορεί να τροφοδοτηθεί κατευθείαν από τον κόμβο εισόδου ή και το αντίστροφο (Σχήμα 6)

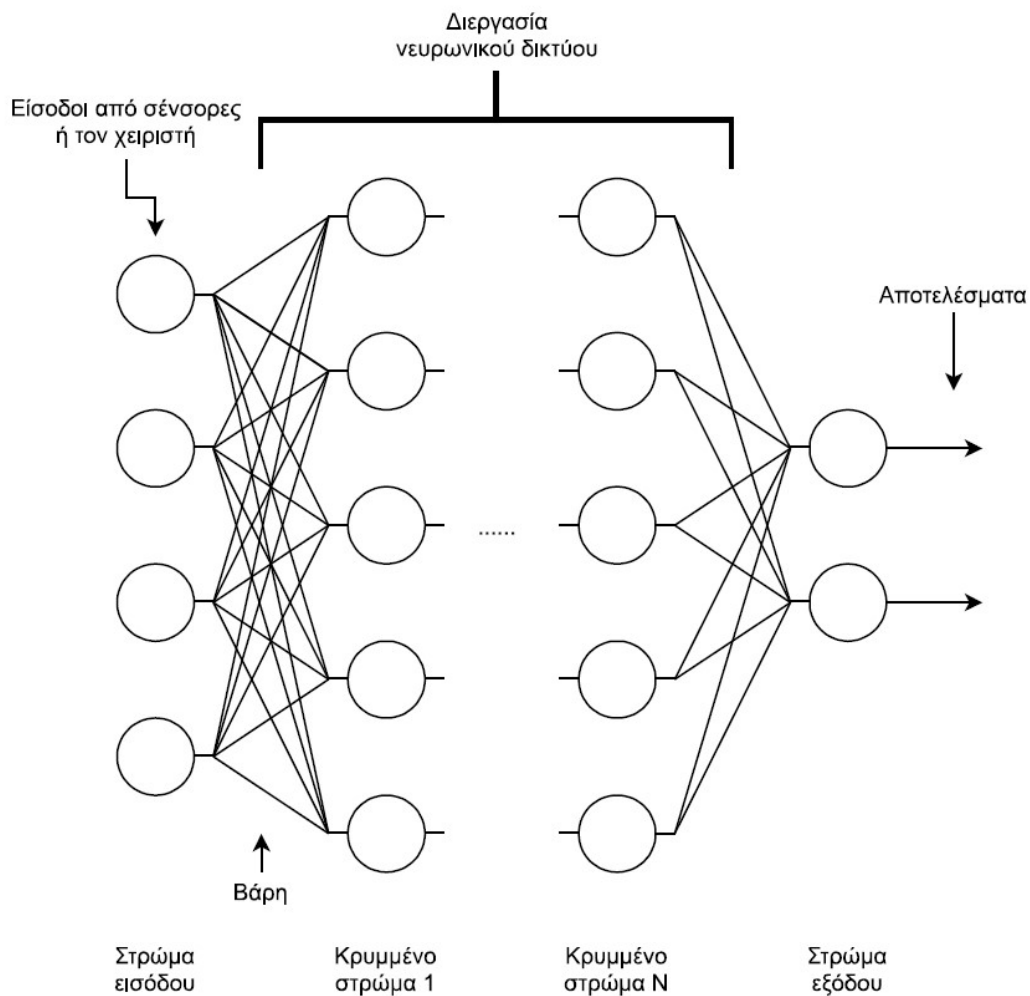


Σχήμα 6: Διαδικασία αναδρομικού δικτύου (Μήτσιος, 2017 και των ιδίων)

Αντίθετα, στα δίκτυα με την προς τα εμπρός τροφοδότηση δεν υπάρχει καμία σύνδεση μεταξύ των κόμβων που βρίσκονται στο ίδιο επίπεδο ή καμία αναδρομική διαδικασία (Σχήμα 7). Το τεχνητό νευρωνικό δίκτυο (ANN) στο οποίο θα αναφερθούμε βασίζεται στη δομή της προς τα εμπρός τροφοδότησης και συμβάλλει στην επίλυση προβλημάτων που δεν μπορούν να λυθούν με τις παραδοσιακές μεθόδους. Σύμφωνα με τους Kudus et al. (2013) το ANN αποτελείται από τρία στρώματα (layers) (Σχήμα 7):

- ένα στρώμα εισόδου (input)

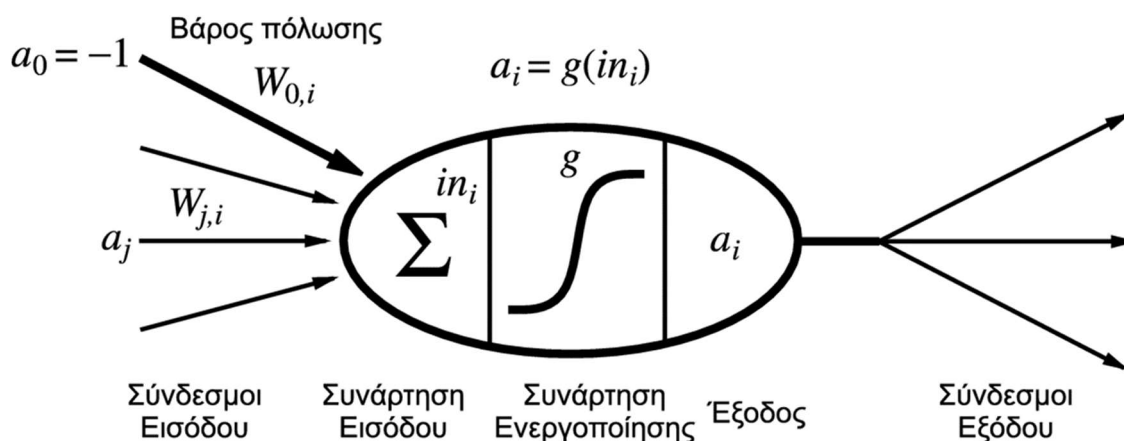
- ένα στρώμα εξόδου (output)
- ένα ή περισσότερα κρυμμένα στρώματα (hidden)



Σχήμα 7: Τεχνητό νευρωνικό δίκτυο με N κρυμμένα στρώματα (Hyeon-Jong et al., 2019 και των ιδίων)

Τα στρώματα αυτά αποτελούνται από κόμβους, οι οποίοι συνδέονται μεταξύ τους με ένα σχετικό βάρος και μια συνάρτηση ενεργοποίησης (σιγμοειδής). Συγκεκριμένα στο στρώμα εισόδου εισάγονται τιμές, είτε από το περιβάλλον είτε από άλλους νευρώνες, χωρίς να υλοποιείται κάποια υπολογιστική πράξη. Στη συνέχεια, τα κρυμμένα στρώματα επιτελούν τους απαραίτητους υπολογισμούς με βάση τα δεδομένα εισόδου που δοθήκαν. Τα δεδομένα αυτά πολλαπλασιάζονται με τα αντίστοιχα σχετικά βάρη τους. Τέλος, αφού έχει προηγηθεί το άθροισμα των γινομένων αυτών και η συνάρτηση ενεργοποίησης τους, προσδιορίζεται η έξοδος του δικτύου που εμφανίζεται

στο στρώμα εξόδου. Η τιμή αυτή μπορεί να χρησιμοποιηθεί ως είσοδος σε ένα άλλο νευρωνικό δίκτυο ή ως αποτέλεσμα στο περιβάλλον. Η διαδικασία των υπολογισμών που πραγματοποιείται στα κρυμμένα στρώματα και στο στρώμα εξόδου, φαίνεται στο Σχήμα 8.



Σχήμα 8: Μαθηματικό μοντέλο νευρώνα (Russell και Norvig, 2003)

Οι τύποι που χρησιμοποιούνται είναι οι εξής:

Συνάρτηση εισόδου:

$$in_i = \sum_{j=0}^n W_{j,i} a_j \quad (1)$$

όπου $W_{j,i}$ το αριθμητικό βάρος και a_j στοιχείο εξόδου του προηγούμενου κόμβου.

Συνάρτηση ενεργοποίησης:

$$a_i = g(in_i) = g\left(\sum_{j=0}^n W_{j,i} a_j\right) \quad (2)$$

Όπου g συνάρτηση ενεργοποίησης.

Ένα νευρωνικό δίκτυο έχει την ικανότητα αυτό-οργάνωσης ή μάθησης, η οποία συμβάλλει στην βελτίωση του προγράμματος, ώστε να επιλύει κάποιο πρόβλημα. Αυτό πραγματοποιείται μέσω μιας επαναληπτικής διαδικασίας, η οποία συλλεγεί, αποθηκεύει, αναλύει, επεξεργάζεται μεγάλο αριθμό δεδομένων και προσαρμόζει τις παραμέτρους και τα βάρη καταλληλά για την αποτελεσματικότερη επίλυση του προβλήματος. Ανάλογα τις παραμέτρους του κάθε προβλήματος προσδιορίζονται και ο αριθμός των κρυμμένων στρωμάτων του ANN. Η μέθοδος της εκμάθησης χωρίζεται σε δυο κατηγορίες, την μάθηση με επίβλεψη και την μάθηση χωρίς επίβλεψη, η διαδικασία των οποίων έχει αναφερθεί στην μηχανική μάθηση.

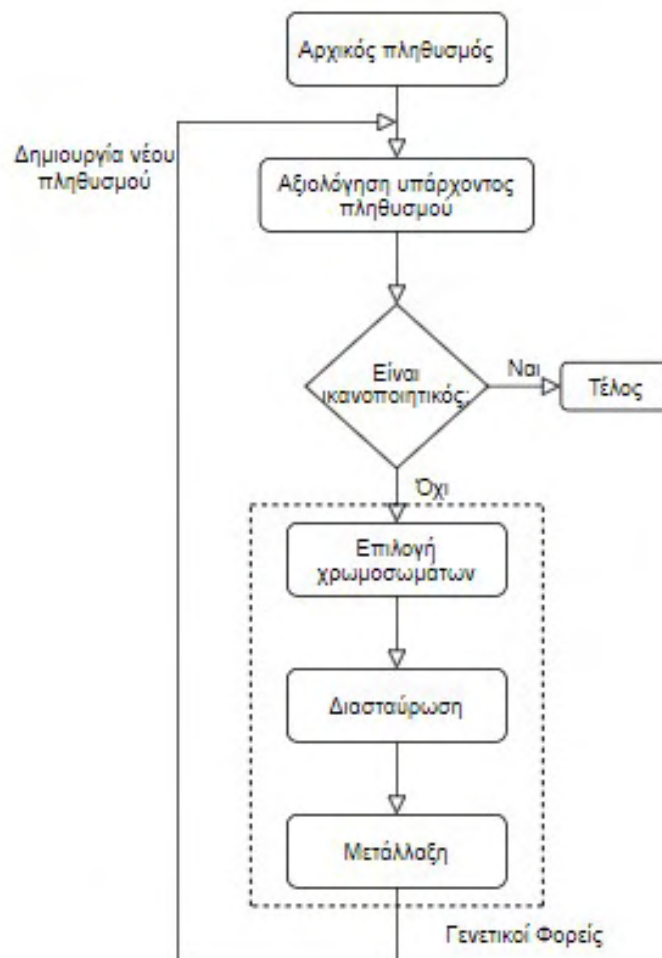
Επίσης, η οπισθοδιάδοση (back-propagation) είναι μια διαδικασία που εφαρμόζεται στα νευρωνικά δίκτυα με σκοπό την μείωση του σφάλματος. Η διαδικασία αυτή πραγματοποιείται λόγω της έλλειψης γνώσης των σφαλμάτων στα κρυφά επίπεδα. Κατά την λειτουργία της ακολουθούνται τα εξής βήματα:

- Υπολογίζονται οι τιμές ενός τροποποιημένου σφάλματος για τις μονάδες εξόδου χρησιμοποιώντας το παρατηρηθέν σφάλμα.
- Ξεκινώντας από το επίπεδο εξόδου, επαναλαμβάνοντας τα παρακάτω για κάθε επίπεδο του δικτύου μέχρι να φτάσουμε στο πρώτο κρυφό επίπεδο:
 - Γίνεται διάδοση των τιμών του τροποποιημένου σφάλματος πίσω στο προηγούμενο επίπεδο.
 - Γίνεται ενημέρωση των βαρών μεταξύ των επιπέδων.

Στον τομέα του πολιτικού μηχανικού το τεχνητό νευρωνικό δίκτυο παρουσιάζει αρκετές εφαρμογές. Ορισμένες γενικές εφαρμογές είναι η παρακολούθηση της δομικής ακεραιότητας της κατασκευής (SHM) όπως των Neves et al. (2018) και Chalouhi et al. (2018), ο βέλτιστος σχεδιασμός κάποιας δομής όπως του Ma et al. (2013) και η καλύτερη ενεργειακή σχεδίαση σε κατασκευή όπως των Amasyali and El-Gohary (2017) και Khairulzaman and Usman (2018).

2.1.4 Γενετικός αλγόριθμος

Μια μέθοδος αναζήτησης βέλτιστων λύσεων είναι ο γενετικός αλγόριθμος (Genetic Algorithm - GA), ο οποίος εφαρμόζει τον μηχανισμό της φυσικής γενετικής και της φυσικής επιλογής. Η χρησιμότητά του εμφανίζεται σε εφαρμογές που έχουν πολλές μεταβλητές και δεν υπάρχει μια αναλυτική μέθοδος που μπορεί να αναζητήσει τον βέλτιστο συνδυασμό λύσεων. Η διαδικασία που ακολουθεί ένας γενετικός αλγόριθμος για την λειτουργία του προέρχεται από την επιστήμη της βιολογίας και συγκεκριμένα από την θεωρία εξέλιξης του Δαρβίνου και την γενετική θεωρία του Mendel.



Σχήμα 9: Η διαδικασία του γενετικού αλγορίθμου (Boukhatem et al., 2011 και των ιδίων)

Σύμφωνα με το Σχήμα 9 αλγόριθμος δημιουργεί τον αρχικό πληθυσμό ο οποίος αποτελείται από ένα σύνολο χρωμοσωμάτων, τα οποία προσομοιώνουν ένα σύνολο πιθανών λύσεων και στη συνέχεια, ο αλγόριθμος αξιολογεί την ικανότητα του πληθυσμού και αν αυτή είναι ικανοποιητική σταματάει. Σε αντίθετη περίπτωση, επιλέγει τα καλύτερα χρωμοσώματα από αυτόν τον πληθυσμό, τα διασταυρώνει και με την μέθοδο της μετάλλαξης δημιουργείται ένας νέος πληθυσμός. Έπειτα, αξιολογεί τον νέο πληθυσμό και αν δεν είναι ικανοποιητικός ακολουθεί την ίδια διαδικασία μέχρις ότου να είναι ικανοποιητικός. Όσο περισσότερες επαναλήψεις της διαδικασίας πραγματοποιούνται τόσο καλύτερες λύσεις επιλέγονται. Σύμφωνα με τους Li και Adeli (2018), ο γενετικός αλγόριθμος προτιμάται γιατί η διαδικασία που ακολουθεί

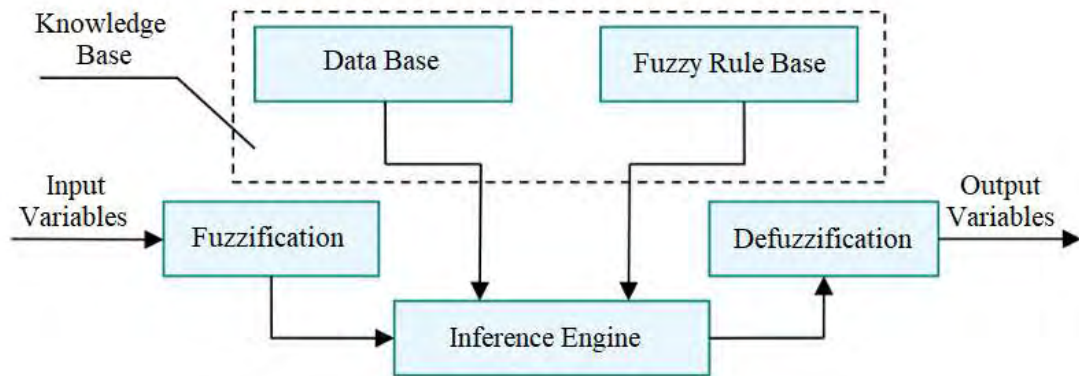
πραγματοποιεί αναζήτηση σε πολλαπλά πεδία με αποτέλεσμα να μένει σε ένα τοπικό μέγιστο.

2.1.5 Ασαφής λογική

Η ασαφής λογική (Fuzzy Logic) είναι μια μαθηματική μέθοδος σύμφωνα με την οποία το μοντέλο δεν αντιμετωπίζει το πρόβλημα με τις τιμές 0 και 1, οι οποίες αντιστοιχούν στις έννοιες ψευδής και αληθής, αλλά χρησιμοποιεί έναν αριθμό ανάμεσα σε αυτές τις δυο τιμές για τον καθορισμό του αποτελέσματος. Για παράδειγμα, αν θεωρηθεί η πρόταση “Ο Νίκος είναι 1,80” και γίνει η ερώτηση “Ο Νίκος είναι ψηλός;”, η απάντηση δεν μπορεί να είναι αληθής ή ψευδής. Επειδή υπάρχουν διαβαθμίσεις στο ύψος και η λέξη ψηλός δεν έχει αυστηρή οριοθέτηση, δημιουργείται ένα ασαφές σύνολο, δηλαδή ένα σύνολο χωρίς σαφή όρια, το οποίο περιγράφεται από λογικές μεταβλητές, όπως “αρκετά”, μέσω της ασαφής λογικής (Russell και Norvig, 2003). Συγκεκριμένα, οι λογικές μεταβλητές έχουν σκοπό να διευκολύνουν την έκφραση κανόνων και γεγονότων. Σύμφωνα με τους Li και Adeli (2018) η διαδικασία που ακολουθεί μια ασαφής λογική για την λειτουργία της είναι η εξής (Σχήμα 10):

- Ασαφοποίηση (Fuzzification)
- Εφαρμογή της βάσης (Knowledge Base)
- Μηχανισμός συμπερασμάτων (Inference Engine)
- Αποσαφήνιση (Defuzzification)

Αρχικά, κατά την **ασαφοποίηση** γίνεται μετασχηματισμός των τιμών εισόδου (input variables) σε λογικές μεταβλητές, μέσω μίας συνάρτησης, ώστε να μπορούν να χρησιμοποιηθούν. Στη συνέχεια, από την **εφαρμογή της βάσης**, η οποία αποτελείται από την βάση δεδομένων (Data Base) και τους κανόνες της ασαφούς λογικής (Fuzzy Rule Base) γίνεται υλοποίηση του ελέγχου (όπως IF...THEN...). Έπειτα, ο **μηχανισμός συμπερασμάτων** λαμβάνει υπόψιν την βάση για την εύρεση του αποτελέσματος από τον έλεγχο. Τέλος, γίνεται χρήση της **αποσαφήνισης** που είναι ο αντίστροφος μετασχηματισμός του πρώτο βήματος, με σκοπό την μετατροπή των ασαφών αποτελεσμάτων σε πραγματικά (output variables).



Σχήμα 10: Διαδικασία της Ασαφούς λογικής (Li και Adeli, 2018 και των ιδίων)

Με την πάροδο του χρόνου πολλοί ερευνητές δημιούργησαν μοντέλα συνδυάζοντας την ασαφή λογική (FL) και το τεχνητό νευρωνικό δίκτυο (ANN). Η ασαφής λογική, όπως αναφέρουν οι Boukhatem et al. (2011), έχει μεγάλη εφαρμογή στον τομέα του πολιτικού μηχανικού με χρήση του σε πολλά παραδείγματα, μερικά από τα οποία είναι εύρεση της θλιπτικής αντοχής του σκυροδέματος και του συντελεστή ελαστικότητας του, έλεγχος κόπωσης σε δομικά μέλη χάλυβα και άλλα.

2.1.6 Γενικοί αλγόριθμοι

Στο υποκεφάλαιο αυτό θα αναφερθούν ορισμένοι γενικοί αλγόριθμοι που χρησιμοποιούνται για την εκτέλεση διάφορων πειραμάτων με χρήση τεχνητής νοημοσύνης.

Το **νευρωνικό δίκτυο πολλών επιπέδων** (Multilayer Perception neural network – MLP) είναι μια πιο εξειδικευμένη μέθοδος ANN, με περισσότερους κόμβους εξόδου, που χρησιμοποιείται για την επίλυση πιο πολύπλοκων προβλημάτων. Συγκεκριμένα, είναι ένα δίκτυο με πολλά κρυφά στρώματα με βασικό πλεονέκτημα της μεθόδου ότι όσο περισσότερα είναι τα στρώματα, τόσο πιο πολύ μεγαλώνει ο χώρος υποθέσεων που αναπαριστά ένα δίκτυο. Για παράδειγμα, με την χρήση ενός μεγάλου (πολλοί κόμβοι) κρυφού στρώματος έχει την δυνατότητα αναπαράστασης μιας συνεχής συνάρτησης, ενώ με την χρήση δύο στρωμάτων μπορεί να γίνει και αναπαράσταση ασυνεχών συναρτήσεων. Όμως, οποιαδήποτε δομή δικτύου δεν μπορεί να προσδιοριστεί με ακρίβεια για το ποιες συναρτήσεις αναπαριστά. Όπως σε κάθε μοντέλο νοημοσύνης πραγματοποιείται η εκμάθησή του, έτσι και στο MLP χρησιμοποιείται ο αλγόριθμος οπίσθιας διάδοσης (back-propagation) για την

εκπαίδευσή του, αφού είναι ο πιο χρησιμοποιημένος και αποτελεσματικότερος στην συγκεκριμένη μέθοδο.

Οι **μηχανές διανυσμάτων υποστήριξης** (Support Vector Machine - SVM) είναι μια επιβλεπόμενη μέθοδος εκμάθησης με κύρια χρήση την ταξινόμηση, την παλινδρόμηση και την πρόβλεψη των δεδομένων. Το SVM είναι μια μέθοδος που αναπαριστά αποδοτικά πολύπλοκες μη γραμμικές συναρτήσεις. Επίσης, όταν λειτουργεί για ταξινόμηση έχει τις τιμές 0 και 1 για τα δεδομένα, ενώ για παλινδρόμηση χρησιμοποιεί οποιαδήποτε πραγματική τιμή. Όσον αφορά την πρόβλεψη, παράγει αποτελέσματα ανάλογα με τα δεδομένα εισόδου που του έχουν δοθεί.

Η **Γραμμική Παλινδρόμηση** (Linear Regression) είναι μια γραμμική προσέγγιση μεταξύ μιας εξαρτημένης μεταβλητής και μιας ή περισσότερων ανεξάρτητων μεταβλητών. Η γραμμική παλινδρόμηση αποτελεί μια επέκταση της παλινδρόμησης (Regression Analysis) και χρησιμοποιείται για στατιστικές αναλύσεις. Επιπλέον, είναι μια μέθοδος στατιστικής εκμάθησης κατά την οποία γίνεται τοποθέτηση μιας ελεύθερης γραμμής σε μια ακολουθία πειραματικών παρατηρήσεων με τον περιορισμό ότι πρέπει να βρίσκεται αρκετά κοντά στις παρατηρήσεις.

Το **Random Forest** είναι ένας αλγόριθμος ο οποίος βασίζεται στην διαδικασία των δέντρων αποφάσεων (Decision Trees). Συγκεκριμένα, τα δέντρα αυτά είναι μέθοδοι αποφάσεων, τα οποία κάνουν χρήση ενός δέντρου που περιλαμβάνει τις αποφάσεις, μέσω των ελέγχων, και τις πιθανές συνέπειες τους. Δηλαδή, η μέθοδος αυτή προσθέτει μια τυχαιότητα στα χαρακτηριστικά και μέσω της ανάπτυξης αυτών των δέντρων γίνεται η αναζήτηση του καλύτερου χαρακτηριστικού. Από τη μέθοδο αυτή έχουν αναπτυχθεί παρόμοιοι αλγόριθμοι, όπως το CART για την πρόβλεψη κατασκευαστικών μοντέλων, και το CHAID (chi-squared automatic interaction detector). Τέτοιου είδους δέντρα μπορούν να βελτιστοποιηθούν, μέσω ενός συνόλου δεδομένων μάθησης, περιορίζοντας το από τα περιττά δεδομένα κάνοντας το πιο απλό.

2.2 Γενικά βήματα λειτουργίας των αλγορίθμων

Στις παρακάτω παραγράφους, παρουσιάζεται η διαδικασία με την οποία ελέγχεται και γίνεται καλύτερος ένας αλγόριθμος μέσω της βάσης δεδομένων που έχει δημιουργηθεί, καθώς επίσης και τις συναρτήσεις σφάλματος που χρησιμοποιούνται για την σύγκρισή του με τα πραγματικά δεδομένα.

2.2.1 Βάση δεδομένων αλγορίθμου

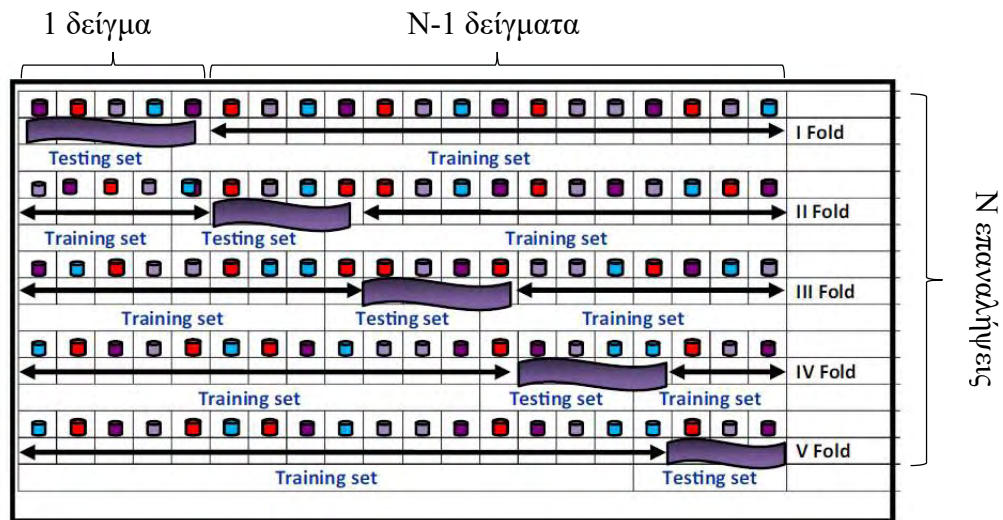
Για την δημιουργία αλγορίθμου χρειάζεται αρχικά να δημιουργηθεί από τον χρήστη μια βάση δεδομένων (Database). Η βάση δεδομένων ορίζεται ως ένα σύστημα το οποίο έχει την δυνατότητα να αποθηκεύει και να κατανέμει κατάλληλα μεγάλο όγκο πληροφοριών ή δεδομένων. Τέτοιου είδους πληροφορίες είναι στοιχεία του δοκιμίου και αποτελέσματα που έχουν προκύψει από πειράματα που έχουν πραγματοποιηθεί. Επίσης, βρίσκεται μόνιμα στη διάθεση του αλγορίθμου για χρήση και μπορεί να ανανεωθεί με βάση τα αποτελέσματα που δημιουργεί αυτός. Το πλήθος των πληροφοριών που εισάγονται στην βάση χρειάζεται να είναι περιορισμένα, ώστε να μην δημιουργούνται αστοχίες. Συγκεκριμένα, στους αλγορίθμους με υπερβολικά μεγάλη βάση δεδομένων έχει παρατηρηθεί ότι υπάρχει πιθανότητα να προκύψουν σφάλματα.

2.2.2 Εκπαίδευση

Η εκπαίδευση του αλγορίθμου (Training) αποτελεί ένα αρκετά σημαντικό κομμάτι στην δημιουργία και την εξέλιξη του, ώστε να εξάγει καλύτερα αποτελέσματα. Η διαδικασία αυτή πραγματοποιείται με την βοήθεια του χρήστη και σύμφωνα με τις πληροφορίες που έχουν τοποθετηθεί στη βάση δεδομένων. Κατά την διάρκεια της εκπαίδευσης ο χρήστης αρχικά διαλέγει ένα ποσοστό πληροφοριών από την βάση δεδομένων με το οποίο πραγματοποιεί την εκπαίδευση του, ώστε να μπορεί στη συνέχεια να κάνει πρόβλεψη. Έπειτα, ακολουθεί η φάση δοκιμής του αλγορίθμου όπου ο χρήστης εισάγει τα δεδομένα των δοκιμίων από το υπόλοιπο ποσοστό της βάσης δεδομένων, ώστε να γίνει η πρόβλεψη των αποτελεσμάτων και να εξακριβωθεί η λειτουργικότητα και η αποτελεσματικότητά του σε σύγκριση με τα πραγματικά αποτελέσματα που έχουν προκύψει. Αυτή η διαδικασία διαφέρει από χρήστη σε χρήστη.

Η διασταυρούμενη επικύρωση (Cross-validation) αποτελεί μια άλλη μέθοδο εκπαίδευσης του αλγορίθμου, κατά την οποία η βάση δεδομένων χωρίζεται σε N δείγματα. Από αυτά τα δείγματα ο αλγόριθμος χρησιμοποιεί τα $N-1$ για την εκπαίδευση του και με αυτό που μένει πραγματοποιεί την δοκιμή. Αυτή η διαδικασία πραγματοποιείται N φορές λαμβάνοντας κάθε φορά για δείγμα δοκιμής το επόμενο. Το πλεονέκτημα της μεθόδου είναι στο γεγονός ότι όλες οι παρατηρήσεις

χρησιμοποιούνται για εκπαίδευση και δοκιμή ταυτόχρονα. Αυτή η διαδικασία φαίνεται στο παρακάτω σχήμα:



Σχήμα 11: Πέντε φορές διασταυρούμενη επικύρωση (Vakharia and Gujar, 2019 και των ιδίων)

Στη συνέχεια πραγματοποιείται δοκιμή του με ανεξάρτητα δεδομένα από αυτά της βάσης με σκοπό να ελεγχθεί η αποτελεσματικότητά του. Ο έλεγχος που εφαρμόζεται ανάμεσα στα δεδομένα του αλγορίθμου και στα πραγματικά γίνεται με την χρήση των δεικτών σφάλματος.

2.2.3 Συναρτήσεις σφάλματος

Για την σύγκριση των αποτελεσμάτων που εξάγει ένας αλγόριθμος με τα πραγματικά δεδομένα ενός πειράματος χρησιμοποιούνται διάφορα σφάλματα ελέγχου, με τα οποία αξιολογείται η απόδοση του. Μερικά από τα πιο συνηθισμένα σφάλματα παρουσιάζονται παρακάτω (Chou et al., 2014).

Μέσο απόλυτο σφάλμα (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (3)$$

όπου y'_i είναι η προβλεπόμενη τιμή, y_i η πραγματική τιμή και n ο αριθμός των δειγμάτων.

Μέσο απόλυτο ποσοστό σφάλματος (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \quad (4)$$

όπου y'_i είναι η προβλεπόμενη τιμή, y_i η πραγματική τιμή και n ο αριθμός των δειγμάτων.

Μέσο τετραγωνικό σφάλμα (MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \quad (5)$$

όπου y'_i είναι η προβλεπόμενη τιμή, y_i η πραγματική τιμή και n ο αριθμός των δειγμάτων.

Μέσο σφάλμα τετραγωνικής ρίζας (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (6)$$

όπου y'_i είναι η προβλεπόμενη τιμή, y_i η πραγματική τιμή και n ο αριθμός των δειγμάτων.

Συντελεστής συσχέτισης:

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{n \sum x^2 - \sum x^2 [n \sum y^2 - (\sum y)^2]}} \quad (7)$$

όπου n το πλήθος των παρατηρήσεων, $\sum x$ η μέση τιμή των πρώτων μεταβλητών και $\sum y$ η μέση τιμή των δεύτερων μεταβλητών του σετ δεδομένων.

$$R^2 = \frac{\sum_{i=1}^n (y'_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

όπου y'_i είναι η προβλεπόμενη τιμή, y_i η πραγματική τιμή, \bar{y} η μέση τιμή των δειγμάτων και n ο αριθμός των δειγμάτων.

Δείκτης σύνθεσης (SI):

$$SI = \frac{1}{n} \sum_{i=1}^n \left(\frac{P_i - P_{min,i}}{P_{max,i} - P_{min,i}} \right) \quad (9)$$

όπου P_i μέτρο απόδοσης και n ο αριθμός των δειγμάτων.

Συντελεστής Kendall's Tau:

$$t_b = \frac{P - Q}{\sqrt{(P + Q + X_0)(P + Q + Y_0)}} \quad (10)$$

όπου P τα συγκριτικά ζεύγη, Q τα ασύμβατα ζεύγη, X_o εξαρτημένα ζεύγη από την μεταβλητή X και Y_o εξαρτημένα ζεύγη από την μεταβλητή Y.

Συντελεστής Διακύμανσης:

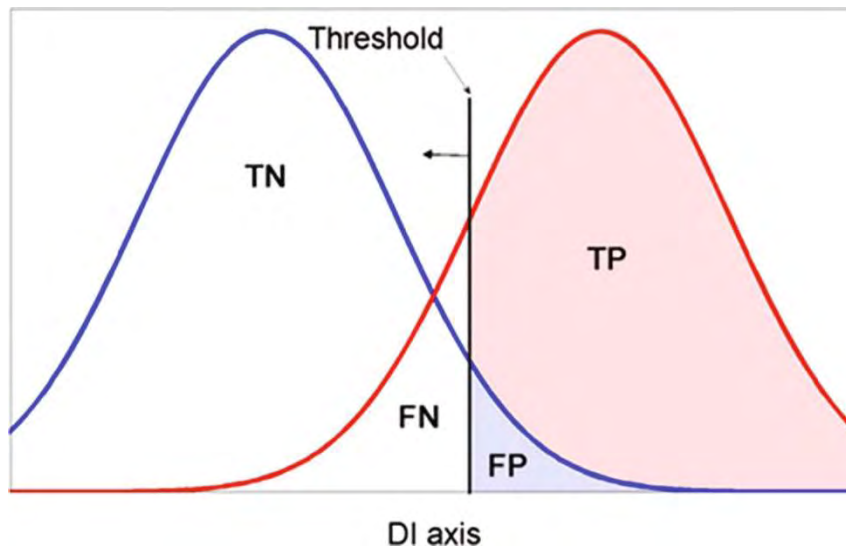
$$CV = \frac{\sqrt{\frac{\sum_{i=1}^n (y_{predict,i} - y_{data,i})^2}{n-1}}}{\bar{y}_{data}} \quad (11)$$

όπου $y_{predict,i}$ η προβλεπόμενη κατανάλωση ενέργειας στην ώρα i, $y_{data,i}$ η πραγματική (προσομοιωμένη) κατανάλωση ενέργειας στην ώρα i, n ο αριθμός των ωρών στο σύνολο των δεδομένων και \bar{y}_{data} η μέση κατανάλωση της ενέργειας.

2.2.4 Διάγραμμα καμπύλων Receiver Operating Characteristic (ROC)

Η καμπύλη Receiver Operating Characteristic (ROC) αποτελεί μια στατιστική αξιολόγηση των σφαλμάτων που απεικονίζεται σε ένα διάγραμμα δυο αξόνων. Ο κάθετος άξονας ορίζεται ως True Positive (TP) και δείχνει την πιθανότητα σωστής ανίχνευσης του αλγορίθμου, ενώ ο οριζόντιος άξονας ορίζεται ως False Positive (FP) και δείχνει την πιθανότητα εμφάνισης λανθασμένης πρόβλεψης. Η δημιουργία του διαγράμματος βασίζεται στην επιλογή ενός κατώφλιού, όπως για παράδειγμα ο δείκτης βλαβών (Damage Index – DI). Συγκεκριμένα, ο δείκτης αυτός ορίζεται ως ένα όριο βλάβης το οποίο αν ξεπεραστεί προειδοποιεί το σύστημα για βλάβη, ενώ σε αντίθετη περίπτωση δεν εκπέμπει κάποια ένδειξη.


Στο Σχήμα 12 απεικονίζεται το ποσοστό των TP, δηλαδή των σωστών προβλέψεων, με κόκκινο, ενώ με μπλε απεικονίζεται το ποσοστό των FP, δηλαδή των ψευδών συναγερωμών. Ακόμη, ως True Negative (TN) ορίζεται το ποσοστό των προβλέψεων ότι δεν ισχύει μια συνθήκη και δεν ισχύει στην πραγματικότητα. Επιπλέον, εμφανίζεται ως False Negative (FN) το ποσοστό των λανθασμένων προβλέψεων που δείχνει ότι μια συνθήκη δεν ισχύει, όμως στην πραγματικότητα ισχύει. Ακόμη, φαίνεται το κατώφλι (Threshold), το οποίο είναι ένα ποσοστό και ορίζει το κατώτατο όριο, όπου διαχωρίζει τα σωστά αποτελέσματα από τα λανθασμένα και επιλέγεται από τον μελετητή. Για παράδειγμα, στο Σχήμα 12 έχει οριστεί ένα σταθερό κατώφλι και απεικονίζονται τα TP με ποσοστό 70% και FP με ποσοστό 15%, δηλαδή το κατώφλι έχει οριστεί ως 15% άρα οποιοδήποτε αποτέλεσμα έχει πιθανότητα μεγαλύτερη του 15% θα είναι σωστό.



Σχήμα 12: Τρόπος κατασκευής καμπύλης ROC (Neves et al., 2017)

Για παράδειγμα, έστω ένα πρόγραμμα του υπολογιστή αναγνωρίζει από μια φωτογραφία, που περιέχει 12 σκύλους και μερικές γάτες, 8 σκύλους από τους οποίους οι 5 είναι σκύλοι και 3 όχι. Τότε ως True Positive θεωρούνται οι 5 σκύλοι, ενώ τα 3 λανθασμένα αποτελέσματα θεωρούνται ως False Positive. Τέλος, ως False Negative θεωρούνται τα σκυλιά τα οποία δεν έχει βρει, δηλαδή τα υπόλοιπα 7, και ως True Negative θεωρούνται οι γάτες που δεν θεώρησε ως σκύλους.

Στο Σχήμα 13 εμφανίζεται η καμπύλη του διαγράμματος ROC, στο οποίο με μπλε γραμμή φαίνεται η ιδανική περίπτωση εμφάνισης μόνο σωστών αποτελεσμάτων. Με κόκκινη γραμμή φαίνεται τα λιγότερο ακριβή αποτελέσματα ανίχνευσης βλαβών. Η πράσινη δείχνει μια τυπική καμπύλη κατά την οποία για την αύξηση των TP μετακινείται το κατώφλι σε υψηλότερο σημείο λαμβάνοντας επιεική κριτήρια (Lenient threshold), ενώ για την αύξηση των FP λαμβάνονται αυστηρότερα κριτήρια (Strict threshold). Τέλος, η βέλτιστη επιλογή (Optimal threshold) βρίσκεται ανάμεσα στα κριτήρια που προαναφέρθηκαν.



Σχήμα 13: Διάγραμμα καμπύλης ROC (Neves et al., 2017)

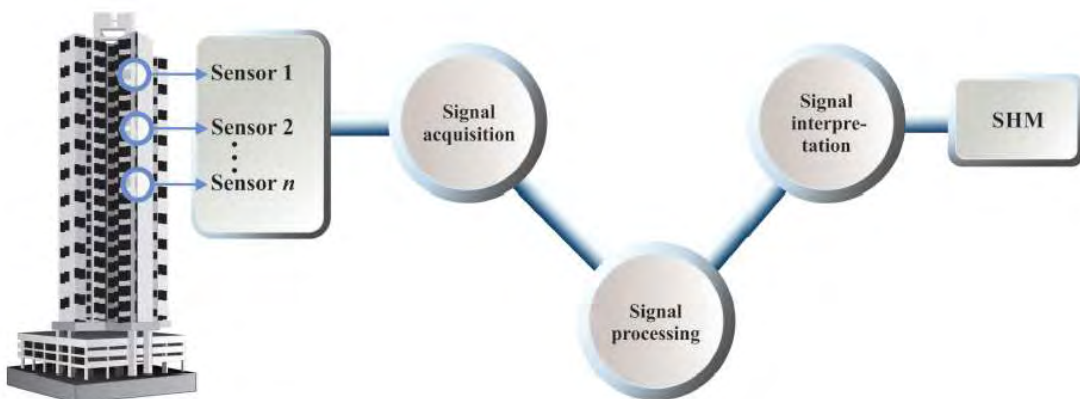
Κεφάλαιο 3 Εφαρμογές τεχνητής νοημοσύνης

Στο κεφάλαιο αυτό αναλύονται οι διάφοροι τομείς εφαρμογής των μεθόδων τεχνητής νοημοσύνης, με σκοπό την καλύτερη κατανόηση τους. Επίσης, σε καθένα από τα παρακάτω υποκεφάλαια αναπτύσσονται παραδείγματα που παρουσιάζουν το περισσότερο ενδιαφέρον.

3.1 Παρακολούθηση δομικής ακεραιότητας κατασκευών και σχεδιασμός συστήματος παρακολούθησής τους

Καθώς οι κατασκευές του πολιτικού μηχανικού αυξάνονται σε αριθμό και σε μέγεθος, εμφανίζονται προβλήματα ως προς την παρακολούθηση και την συντήρησή τους. Για αυτό το λόγο είναι αναγκαία η ανάπτυξη συστημάτων παρακολούθησης της υγείας και ανίχνευσης βλαβών των κατασκευών. Η παρακολούθηση της δομικής ακεραιότητας μιας κατασκευής ή αλλιώς Structural Health Monitoring (SHM) γίνεται με σκοπό την επίτευξη των παραπάνω αναγκών. Η ικανότητα της παρακολούθησης και του έγκαιρου εντοπισμού των βλαβών, παρέχει ακριβείς προβλέψεις για την μελλοντική κατάσταση της δομής, με αποτέλεσμα να καθιστούν άμεσα την συντήρησή της. Η διαδικασία που ακολουθεί το SHM (Σχήμα 14) αποτελείται από τρία βασικά βήματα τα οποία είναι:

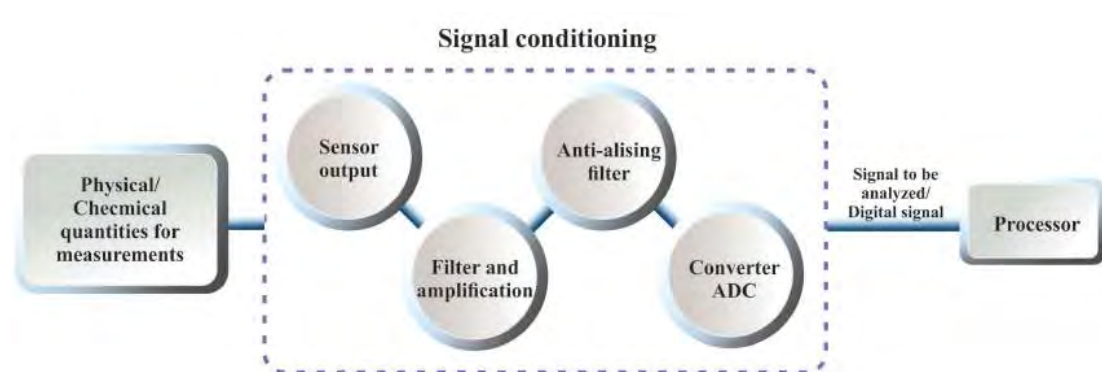
- η λήψη του σήματος (Signal acquisition)
- η επεξεργασία του σήματος (Signal processing)
- η ερμηνεία του σήματος (Signal interpretation)



Σχήμα 14: Διαδικασία της παρακολούθησης της δομικής ακεραιότητας των κατασκευών (SHM) (Amezquita-Sanchez et al., 2018)

Οι Amezquita-Sanchez et al. (2018) παρουσιάζουν την διαδικασία λειτουργίας και τα εργαλεία που χρειάζεται ένα τέτοιο σύστημα παρακολούθησης της δομικής ακεραιότητας των κατασκευών (SHM). Για την λήψη είναι απαραίτητη η χρήση αισθητήρων, ενσύρματοι ή ασύρματοι, όπως για παράδειγμα την μέτρηση μετακινήσεων, ροπών και επιταχύνσεων. Τέτοιοι αισθητήρες είναι τα επιταχυνσιόμετρα (Accelerometers), που μετράνε τις ταλαντώσεις σε δυναμικές φορτίσεις έχοντας την δυνατότητα καταγραφής μεγάλου φάσματος συχνοτήτων (κυρίως χαμηλές). Άλλου τύπου αισθητήρες είναι τα μηκησιόμετρα (Strain Gauges), τα οποία είναι χρήσιμα για την μέτρηση παραμορφώσεων. Παρόμοιοι είναι οι πιεζοκεραμικοί (Piezoceramic-based sensors), οι οποίοι παρόλο το χαμηλό κόστος και το μικρό μέγεθος τους δεν έχουν χρησιμοποιηθεί σε πραγματικές καταστάσεις. Τέλος, είναι οι περιβαλλοντικοί (Ambiental sensors), που μετράνε την θερμοκρασία και την ταχύτητα του ανέμου.

Η επεξεργασία του σήματος στους ενσύρματους αισθητήρες ακολουθεί μια σειρά βημάτων. Αρχικά, το σήμα (Sensor output) μετατρέπεται σε τάση μέσω ενός συστήματος, φιλτράρεται και ενισχύεται (Filter and amplification) ώστε να αποφευχθεί η απώλεια πληροφορίας. Στη συνέχεια, επεξεργάζεται μέσω ενός φίλτρου χαμηλών συχνοτήτων (Anti-aliasing filter), γίνεται μετατροπή του σε ψηφιακό (Converter ADC) και η μεταφορά σε χώρο αποθήκευσης με στόχο να γίνει η ανάλυση τους από τα ψηφιακά συστήματα (Σχήμα 15). Η παραπάνω διαδικασία για τους ασύρματους αισθητήρες γίνεται με την χρήση ενός ενσωματωμένου επεξεργαστή που περιέχεται στον καθένα από αυτούς ξεχωριστά. Για την ερμηνεία του συστήματος χρησιμοποιείται συνήθως το τεχνητό νευρωνικό δίκτυο.



Σχήμα 15: Διαδικασία που ακολουθείται για την επεξεργασία του σήματος (Amezquita-Sanchez et al., 2018)

Σημαντικό χαρακτηριστικό αποτέλεσμα του SHM είναι ο εντοπισμός βλαβών. Σύμφωνα με τους Neves et al. (2017) ακολουθείται μια σειρά ελέγχων και ταυτοποίησης της βλάβης, η οποία είναι η εξής:

1. Παρουσιάζεται κάποια βλάβη στο κτήριο;
2. Που βρίσκεται η βλάβη;
3. Τι είδους βλάβη είναι;
4. Ποσό σημαντική είναι η βλάβη;
5. Ποια είναι η πρόβλεψη για την υπολειπομένη διάρκεια ζωής της κατασκευής;

Η ιδέα πίσω από αυτή την σειρά που ακολουθείται είναι ότι όσο πιο πολλές ερωτήσεις απαντώνται τόσο περισσότερες πληροφορίες θα έχει κανείς σχετικά με τη δομική κατάσταση, αλλά δημιουργεί επίσης τη δυσκολία για την απόκτηση αυτών των πληροφοριών. Παρόλα αυτά, ανάλογα το επίπεδο στο οποίο βρίσκεται υπάρχουν διαφορετικές απαιτήσεις με αποτέλεσμα να χρειάζονται διαφορετικού τύπου αισθητήρες και αλγόριθμοι για την παρακολούθηση των βλαβών και τον αριθμό των παραμέτρων του μοντέλου.

Για την παρακολούθηση της δομικής ακεραιότητας των κατασκευών έχουν πραγματοποιηθεί αρκετά πειράματα, με κύριο σκοπό την επέκταση της διάρκειας ζωής των δομών του πολιτικού μηχανικού. Οι Chalouhi et al. (2017) στη μελέτη τους, εφάρμοσαν την μέθοδο των ANN σε ένα προσομοιωτικό μοντέλο μιας σιδηροδρομικής γέφυρας, με σκοπό τον έλεγχο επιρροής της θερμοκρασίας στην ανίχνευση των βλαβών των δομικών στοιχείων της. Ως αποτέλεσμα, προέκυψε ότι η θερμοκρασία αποτελούσε βασικό παράγοντα στην κατασκευή και στον αλγόριθμο για την εύρεση βλαβών. Οι Neves et al. (2017) στην έρευνά τους προσπάθησαν να αξιολογήσουν την αποδοτικότητα ενός αλγορίθμου ANN σε ένα προσομοιωτικό μοντέλο μιας σιδηροδρομικής γέφυρας για τον εντοπισμό των βλαβών, με χρήση σφαλμάτων για την αξιολόγηση. Τα αποτελέσματα που προέκυψαν ήταν αρκετά ικανοποιητικά και ο αλγόριθμος συνιστάται για τέτοιες εφαρμογές.

Παρακάτω παρουσιάζονται αναλυτικότερα τα παραδείγματα των Chalouhi et al. (2017) και Neves et al. (2017) ως προς την μεθοδολογία που ακολουθήθηκε και τα συμπεράσματα που προέκυψαν.

3.1.1 Μελέτη περίπτωσης 1: Ανίχνευση βλαβών σε σιδηροδρομική γέφυρα με επιρροή της θερμοκρασίας

Στη μελέτη τους οι Chalouhi et al. (2017) προσπάθησαν να προβλέψουν τις αστοχίες μια σιδηροδρομικής γέφυρας και συγκεκριμένα την επίδραση περιβαλλοντικών συνθηκών, όπως η θερμοκρασία, στην κατασκευή και στην μέθοδο μηχανικής μάθησης που χρησιμοποίησαν.

Οι μελετητές αρχικά, μέσω του προγράμματος Bridge Weight In Motion (BWIM) έγινε η προσομοίωση της γέφυρας, των επιταχυνσιομέτρων, των αισθητήρων θερμοκρασίας, των διελεύσεων της αμαξοστοιχίας και έκαναν συλλογή δεδομένων, όπως τα φορτία και η θέση της αμαξοστοιχίας κάθε στιγμή. Αυτά τα δεδομένα σε συνδυασμό με την θερμοκρασία, την ταχύτητα και την επιτάχυνση προηγούμενων διελεύσεων χρησιμοποιήθηκαν ως δεδομένα εισόδου στο ANN. Ως έξοδο ο αλγόριθμος έβγαζε την επιτάχυνση της αμαξοστοιχίας και με την χρήση του παρακάτω τύπου υπολογίζεται το προβλεπόμενο σφάλμα τύπου MSE:

$$pe^s = \frac{1}{n} \sum_{i=1}^n [ANN(x_i^s) - t_i^s]^2 \quad (12)$$

όπου n το πλήθος των δεδομένων εισόδου x_i^s , t_i^s τα δεδομένα μέσω του προγράμματος (στόχοι) και $ANN(x_i^s)$ τα προβλεπόμενα δεδομένα από το ANN.

Στην συνέχεια, γίνεται υπολογισμός των σφαλμάτων και μέσω της μεθόδου Gauss υπολογίζεται μια κανονική κατανομή αυτών. Τέλος, με την χρήση του τύπου 13 γίνεται η ανίχνευση των βλαβών στην γέφυρα.

$$DI = \frac{1}{n_s} \sum_{i=1}^{n_s} \frac{pe^s - \mu_s(v)}{\sigma_s(v)} \quad (13)$$

όπου n_s το πλήθος των επιταχυνσιομέτρων, pe^s το προβλεπόμενο σφάλμα, $\mu_s(v)$ η μέση τιμή και $\sigma_s(v)$ η τυπική απόκλιση των προβλεπόμενων σφαλμάτων ως συνάρτηση της θερμοκρασίας και της ταχύτητας.

Τα δεδομένα που λήφθηκαν ήταν από προσομοίωση 650 περασμάτων της αμαξοστοιχίας υπό κανονικές συνθήκες, από τις οποίες τα 300 χρησιμοποιήθηκαν για την εκπαίδευση του ANN, τα 150 για τον Gauss και τα 200 για δοκιμή. Επίσης, για δοκιμή χρησιμοποιήθηκαν ακόμη 200 περάσματα υπό μη φυσιολογικές συνθήκες.

Όσον αφορά την κατασκευή της γέφυρας, οι διαστάσεις που χρησιμοποιήσαν αποτελούν πραγματικά δεδομένα και πιο συγκεκριμένα της γέφυρας Banafjäl Bridge (Πίνακας 1). Τα δομικά μέλη της κατασκευής αποτελούνται από χάλυβα, όμως το μέτρο ελαστικότητας Young μεταβαλλόταν ανάλογα με την θερμοκρασία σύμφωνα με τον τύπο 14.

$$E(T) = E_{15^{\circ}\text{C}} [1 - \alpha_E * (T - 15^{\circ}\text{C})] \quad (14)$$


Πίνακας 1: Υλικά και γεωμετρικά χαρακτηριστικά της κατασκευής (Chalouhi et al., 2017)

Bridge span length (L)	42 m
Cross sectional area (A)	7.11253 m ²
Mass per unit meter (ρ)	18066 kg/m
Moment of inertia of the cross section (I)	0.62 m ⁴
Number of elements of the mesh (n_{el})	150
Length of each element (L_{el})	0.28 m

Η θερμοκρασία που χρησιμοποιήθηκε κατά την προσομοίωση θεωρήθηκε 15°C και οι ιδιότητες του χάλυβα φαίνονται στον Πίνακας 2. Η αμαξοστοιχία θεωρήθηκε ότι αποτελείται από μια μηχανή τραίνου και τρία βαγόνια και οι αποστάσεις που είχαν μεταξύ τους είναι 2, 3 και 2m. Η μοντελοποίησή της θεωρείται ως τέσσερα εξωτερικά κινητά φορτία, τα οποία εφαρμόζονται στην κατασκευή. Η ταχύτητά τους θεωρείται σταθερή με εύρος 20 - 23 m/s (72 - 83 km/h) και το φορτίο του κάθε βαγονιού θεωρείται 100 - 120 kN. Τα επιταχυνσιόμετρα που χρησιμοποιήθηκαν είχαν την δυνατότητα δειγματοληψίας συχνοτήτων 300 Hz και τοποθετήθηκαν στους κόμβους 30, 50, 75 και 115. Οι θέσεις που έγινε η προσομοίωση των κατεστραμμένων συνθηκών, μειώνοντας το μέτρο ελαστικότητας Young κατά 30%, είναι οι κόμβοι από 88 έως 92. Η αναπαράσταση όλων των παραπάνω δεδομένων φαίνονται στο Σχήμα 16.


Πίνακας 2: Θερμικά χαρακτηριστικά του υλικού της γέφυρας (Chalouhi et al., 2017)

Young modulus at 15 °C ($E_{15^{\circ}\text{C}}$)	210 GPa
Temperature coefficient for Young modulus (α_E)	2.4e-41/°C
Coefficient of thermal expansion (α_L)	10.7e-61/°C




Σχήμα 16: Σχηματική απεικόνιση του μοντέλου γέφυρας: ■ θέσεις των επιταχυνσιόμετρων, × θέσεις που προσομοιώθηκαν οι κατεστραμμένες συνθήκες (Chalouhi et al., 2017)

Στο Σχήμα 17 απεικονίζονται τα αποτελέσματα για το σφάλμα πρόβλεψης (pe) για τα δεδομένα δοκιμής του αλγορίθμου. Τα δεδομένα σε κανονικές συνθήκες παρουσιάζονται με μπλε κύκλους, ενώ τα κατεστραμμένα με κόκκινους αστερίσκους. Όπως παρατηρείται για κάθε επιταχυνσιόμετρο, εκτός από το πρώτο, οι καμπύλες ανάμεσα στα κατεστραμμένα και μη δεδομένα διαχωρίζονται καλύτερα και επιβεβαιώνεται το επιθυμητό αποτέλεσμα, δηλαδή οι τιμές του pe σε κατεστραμμένες συνθήκες είναι υψηλότερες.




Σχήμα 17: Διαγράμματα σφάλματος πρόβλεψης σε σχέση με τις διελεύσεις της αμαξοστοιχίας: — γραμμή σφάλματος των φυσιολογικών συνθηκών, — γραμμή σφάλματος των κατεστραμμένων συνθηκών (Chalouhi et al., 2017)

Τα αποτελέσματα που προέκυψαν για το σφάλμα πρόβλεψης (pe), που έγινε με την μέθοδο του Gauss και την χρήση της ταχύτητας (Σχήμα 18) και της θερμοκρασίας (Σχήμα 19) ως ανεξάρτητες μεταβλητές σε αυτή, φαίνονται στο και αντίστοιχα. Όσον αφορά τα σχήματα οι κόκκινοι αστερίσκοι και οι μπλε κύκλοι παριστάνουν τα ίδια δεδομένα με το Σχήμα 17, ενώ οι μαύροι σταυροί προέρχονται από τα περάσματα της αμαξοστοιχίας σε κανονικές συνθήκες που χρησιμοποιούνται για την εκπαίδευση του Gauss. Η μαύρη γραμμή είναι η μέση τιμή της ανεξάρτητης μεταβλητής για κάθε σχήμα και η γκρι περιοχή δημιουργείται από την μέση τιμή και την τυπική απόκλιση ($\mu_s(v) \pm 2\sigma_s(v)$ ή $\mu_s(T) \pm 2\sigma_s(T)$). Όπως παρατηρείται από τα διαγράμματα, οι τιμές pe σε κανονικές συνθήκες ανήκουν στην γκρι περιοχή δείχνοντας την σωστή λειτουργία της μεθόδου Gauss. Συγκριτικά μεταξύ των δυο διαγραμμάτων, ο διαχωρισμός μεταξύ των κατεστραμμένων και μη δεδομένων είναι πιο ορατός στο Σχήμα 18, ενώ το pe είναι πιο διαδεδομένο και με λιγότερο σαφή τάση στο Σχήμα 19. Έτσι για να είναι αξιόπιστος ο δείκτης βλάβης (DI) χρησιμοποιήθηκε μόνο η ταχύτητα ως ανεξάρτητη μεταβλητή.



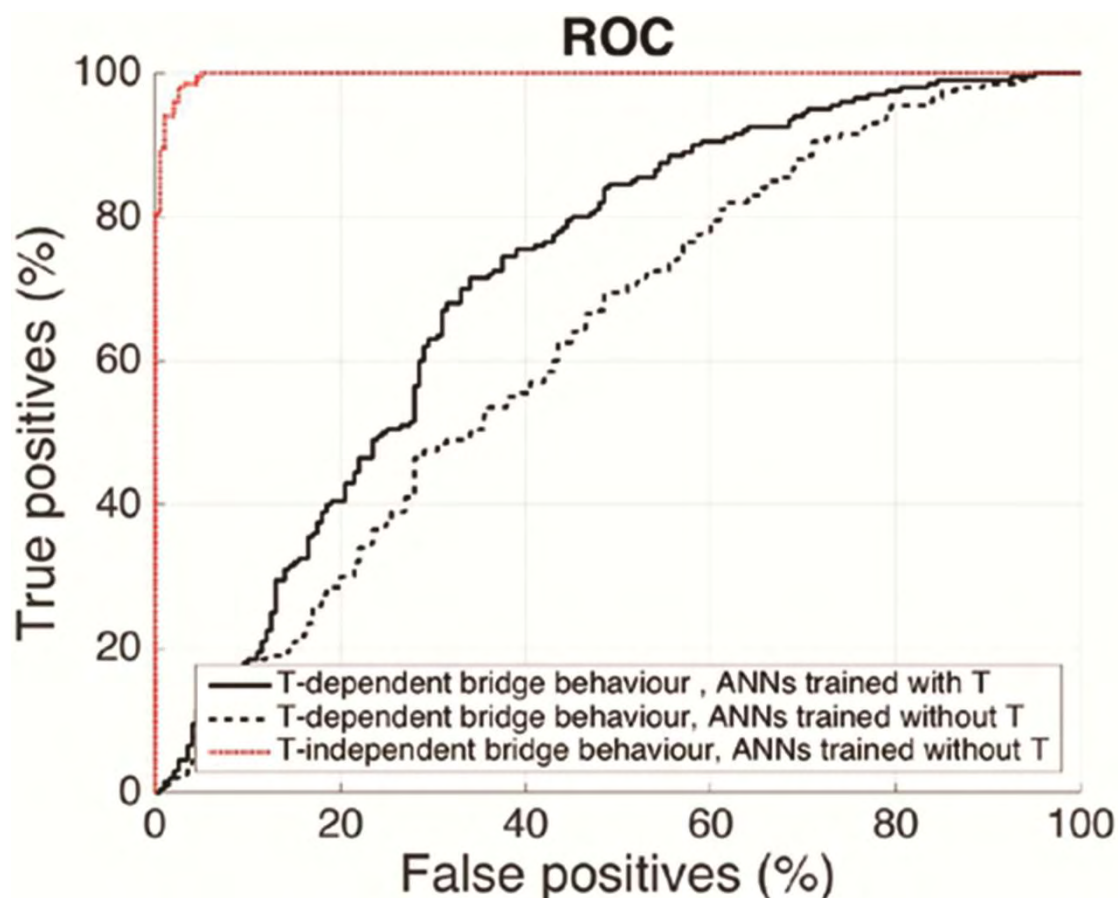
Σχήμα 18: Διαγράμματα σφάλματος πρόβλεψης και ταχύτητας ως ανεξάρτητη μεταβλητή: \circ φυσιολογικές συνθήκες, $*$ κατεστραμμένες συνθήκες, $+$ περάσματα αμαξοστοιχίας σε φυσιολογικές συνθήκες (Chalouhi et al., 2017)



Σχήμα 19: Διαγράμματα σφάλματος πρόβλεψης και θερμοκρασίας ως ανεξάρτητη μεταβλητή: ○ φυσιολογικές συνθήκες, * κατεστραμμένες συνθήκες, + περάσματα αμαξοστοιχίας σε φυσιολογικές συνθήκες (Chalouhi et al., 2017)

Τα αποτελέσματα του διαγράμματος (Σχήμα 20) Receiver Operating Characteristics (ROC), η διαδικασία του οποίου αναφέρεται εκτενέστερα στο κεφάλαιο 2.2.4, έδειξαν την καλύτερη λειτουργία του αλγορίθμου με την χρήση της θερμοκρασίας ως δεδομένο εισόδου. Πιο συγκεκριμένα στο διάγραμμα παρουσιάζονται τα αποτελέσματα για τρεις διαφορετικές καταστάσεις. Με μαύρη γραμμή, όταν η θερμοκρασία είναι εξαρτημένη μεταβλητή στην συμπεριφορά της γέφυρας και ως δεδομένο εισόδου στο ANN, με μαύρη διακεκομμένη, όταν είναι εξαρτημένη μόνο στην συμπεριφορά της γέφυρας, και με κόκκινη, όταν δεν αποτελεί δεδομένο η θερμοκρασία. Όπως φαίνεται στο διάγραμμα, τα αποτελέσματα που προέκυψαν με την χρήση της θερμοκρασίας ως δεδομένο εισόδου στο ANN ήταν καλύτερα σε σχέση με την μη χρήση της, όμως δεν είναι αρκετά αξιόπιστα αφού για 70% επιτυχών αποτελεσμάτων (True Positive – TP) υπάρχει ποσοστό ίσο με 33% για λανθασμένη πρόβλεψη (False Positive – FP). Ακόμη, φαίνεται ότι όταν δεν λαμβάνεται

καθόλου ως δεδομένο τα αποτελέσματα είναι ιδανικά, όμως είναι μη ρεαλιστικά αφού δεν γίνεται να αγνοηθεί η θερμοκρασία από τις πραγματικές συνθήκες.



Σχήμα 20: Διάγραμμα ROC καμπυλών (Chalouhi et al., 2017)


Συνοψίζοντας, τα αποτελέσματα που προέκυψαν για το ANN με την χρήση της θερμοκρασίας ως δεδομένο δεν ήταν πλήρως ικανοποιητικά λόγω της μεγάλης πιθανότητας το αποτέλεσμα να είναι λανθασμένο. Ως κύρια συμπεράσματα, τα οποία μπορούν να βοηθήσουν σε μελλοντικές μελέτες, είναι ότι οι βλάβες μιας τέτοιας κατασκευής είναι πιο εύκολο να εντοπιστούν όταν η αμαξοστοιχία κινείται με μεγαλύτερη ταχύτητα και ότι τα επιταχυνσιόμετρα έχουν καλύτερη ένδειξη όταν τοποθετούνται μακριά από πακτώσεις. Η χρήση αυτής της μεθόδου στο μέλλον, με τις απαραίτητες βελτιώσεις, θα μπορεί να προβλέψει τις αστοχίες μια γέφυρας αποτελεσματικά και να είναι ταυτόχρονα εξαρτώμενη από τις περιβαλλοντικές συνθήκες, όπως η υγρασία, ο άνεμος, το υψόμετρο και άλλες, προσομοιώνοντας έτσι τις πραγματικές συνθήκες που επικρατούν στο περιβάλλον.

3.1.2 Μελέτη περίπτωσης 2: Ανίχνευση βλαβών σε σιδηροδρομική γέφυρα

Οι Neves et al. (2017) στην μελέτη τους προσπάθησαν να αξιολογήσουν την αποδοτικότητα των τεχνητών νευρωνικών δικτύων (Artificial Neural Networks – ANN), ως προς την ανίχνευση των βλαβών της γέφυρας. Το πείραμα που πραγματοποίησαν αφορούσε ένα προσομοιωτικό μοντέλο γέφυρας και όλες οι δοκιμές έγιναν μέσω ηλεκτρονικού υπολογιστή.


Ο λόγος της επιλογής του αλγορίθμου ANN από τους μελετητές, είναι ότι έχει καλύτερη αποτελεσματικότητα σε προβλήματα επεξεργασίας δεδομένων που απαιτούν βελτιστοποίηση λόγω της μεγάλης πολυπλοκότητας των αλληλεπιδράσεων των μεταβλητών. Αναλυτικότερα, η θεωρία και ο τρόπος λειτουργίας του, παρουσιάζονται στο Κεφάλαιο 2.1.3. Για την προσομοίωση της γέφυρας έγινε χρήση του προγράμματος ABAQUS, με το οποίο δημιουργήθηκε ένα τρισδιάστατο μοντέλο της γέφυρας. Όσον αφορά την κατασκευή, αποτελούνταν από ένα κατάστρωμα κατασκευασμένο από σκυρόδεμα, δύο χαλύβδινους δοκούς που συγκρατούσαν το κατάστρωμα και χαλύβδινους βραχίονες που συνδέονταν με τις δοκούς. Τα στοιχεία που απαρτίζουν την γέφυρα θεωρούνται ότι συνδέονται άκαμπτα μεταξύ τους.

Για την προσομοίωση των βλαβών, οι μελετητές δημιούργησαν δύο τεχνητά σενάρια βλαβών στην κατασκευή. Στην πρώτη περίπτωση, έγινε αφαίρεση ενός τμήματος από το πέλμα της δοκού στήριξης, το οποίο απεικονίζεται με κόκκινο χρώμα, ώστε να γίνει προσομοίωση μιας ρωγμής λόγω κόπωσης (Σχήμα 21). Το τμήμα το οποίο αφαιρείται έχει μήκος l και παρουσιάζει την κατάσταση κατά την οποία η ρωγμή διάδοσης έχει φτάσει στο κρίσιμο βάθος προκαλώντας την απότομη ρήξη σε όλο το πλάτος του πέλματος. Στο σχήμα, οι αριθμοί 1 έως 6 δείχνουν την θέση των προσομοιωμένων επιταχυνσιόμετρων, από τα οποία τα τρία είναι παράλληλα στην κίνηση αμαξοστοιχίας και τοποθετημένα στο κατάστρωμα, ενώ τα υπόλοιπα είναι τοποθετημένα παράλληλα και πάνω στην δοκό. Επιπλέον, με γαλάζιο απεικονίζεται η σιδηροδρομική γραμμή και με μωβ οι βραχίονες.



Σχήμα 21: Περίπτωση βλάβης 1: 1-6 θέσεις των επιταχυνσιόμετρων, — θέση κατεστραμμένης συνθήκης, — βραχίονες, — σιδηροδρομική γραμμή (Neves et al., 2017)

Στην δεύτερη περίπτωση, για την προσομοίωση μείωσης του ελαστικού συντελεστή της κατασκευής, αφαιρείται ένας βραχίονας από τους οποίους συνδέονται οι ράβδοι (Σχήμα 22). Αυτό μπορεί να παρουσιάσει μια συνθήκη χαλάρωσης στην σύνδεση μεταξύ τους, όπως για παράδειγμα χαλάρωση του μπουλονιού. Αντίστοιχα, όπως και στην πρώτη περίπτωση, τα επιταχυνσιόμετρα είναι τοποθετημένα στα ίδια σημεία.

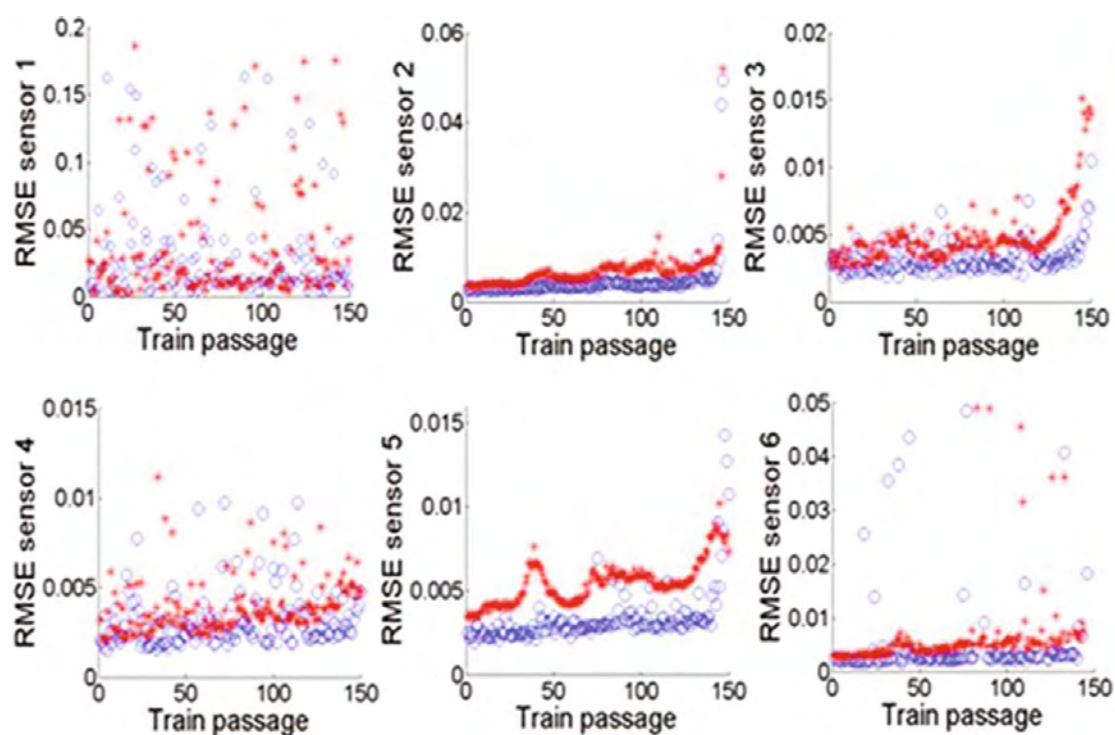


Σχήμα 22: Περίπτωση βλάβης 2: 1-6 θέσεις των επιταχυνσιόμετρων, — θέση κατεστραμμένης συνθήκης, — βραχίονες, — σιδηροδρομική γραμμή (Neves et al., 2017)

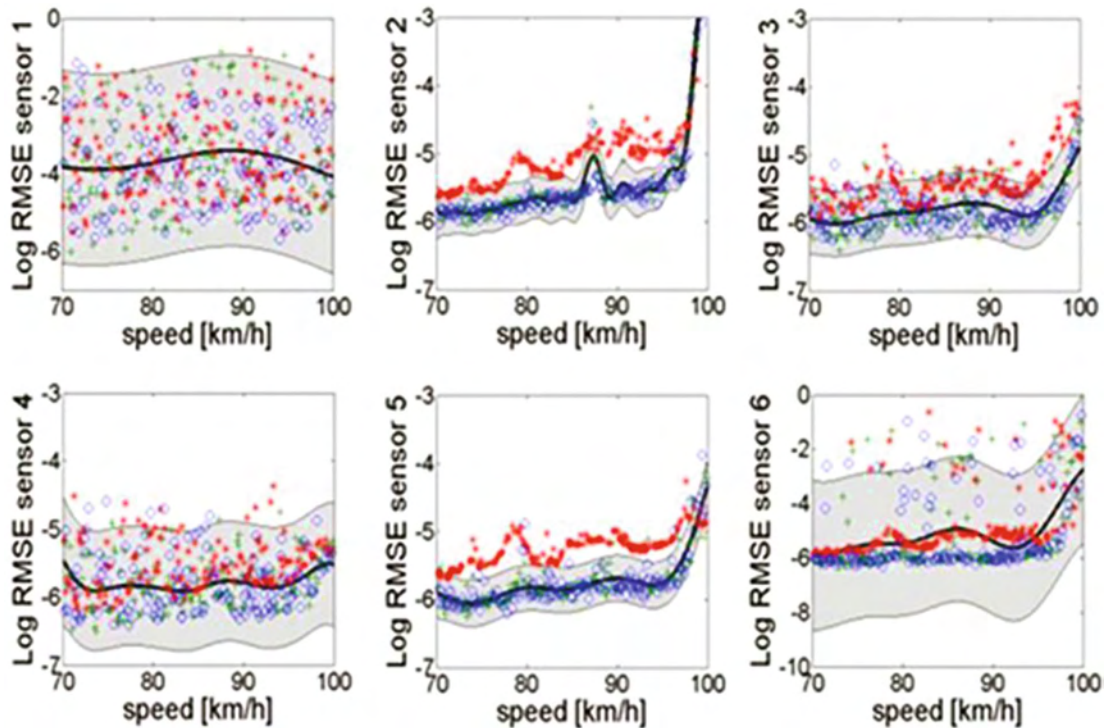
Για την εκπαίδευση του αλγορίθμου έγινε προσομοίωση 300 περασμάτων της αμαξοστοιχίας από την γέφυρα, με ταχύτητα από 70 – 100 km/h με βήμα 0.1 km/h. Για την αξιολόγηση της κατάστασης της κατασκευής έκαναν χρήση των μετρούμενων

δονήσεων, που προέρχονταν από τις διελεύσεις της αμαξοστοιχίας. Τα φορτία των βαγονιών προσομοιώθηκαν ως σειρά σταθερών κινούμενων δυνάμεων.

Για την αξιολόγηση του αλγορίθμου έγινε χρήση του σφάλματος Root Mean Squared Error (RMSE), όπου συγκρίνει την προβλεπόμενη επιτάχυνση από τον αλγόριθμο με την υπολογισμένη από το πρόγραμμα, και της διαδικασίας του Gauss. Στο Σχήμα 23 και στο Σχήμα 24 φαίνονται τα αποτελέσματα τους για την πρώτη περίπτωση σφάλματος, κατά το οποίο αφαίρεσαν κομμάτι εμβαδού $0.9 \times 0.4 \text{ m}^2$ από το κάτω πέλμα. Για τον Gauss έγινε χρήση 150 τυχαίων δεδομένων σε φυσιολογικές συνθήκες με στόχο την δημιουργία των ορίων. Αυτά απεικονίζονται στο Σχήμα 24 με πράσινο σταυρό, ενώ με μαύρη γραμμή φαίνεται η μέση απόκλιση και η γκρι περιοχή δείχνει την τυπική απόκλιση. Στη συνέχεια, δημιουργήθηκαν νέα δεδομένα, τα οποία ήταν 150 σε φυσιολογικές συνθήκες και 150 σε κατάσταση βλάβης και φαίνονται στα σχήματα με μπλε και κόκκινο χρώμα αντίστοιχα.



Σχήμα 23: Αποτελέσματα RMSE για την περίπτωση βλάβης 1: \circ φυσιολογικές συνθήκες, $+$ κατεστραμμένες συνθήκες (Neves et al., 2017)



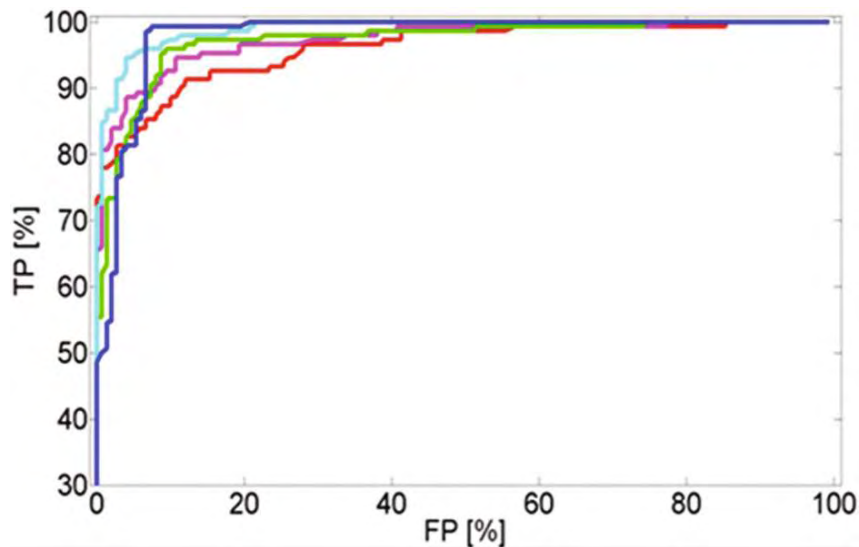
Σχήμα 24: Αποτελέσματα Gauss για την περίπτωση βλάβης 1: ○ φυσιολογικές συνθήκες, * κατεστραμμένες συνθήκες, + τυχαία δεδομένα σε φυσιολογικές συνθήκες, — μέση απόκλιση, ■ τυπική απόκλιση (Neves et al., 2017)

Σύμφωνα με τα διαγράμματα, τα αποτελέσματα που προκύπτουν είναι ότι η πρόβλεψη της δομικής κατάστασης της κατασκευής σε χαμηλές ταχύτητες εμφανίζουν αξιόπιστα αποτελέσματα και έτσι γίνεται πιο εύκολα κατανοητή η εμφάνιση της αστοχίας. Αυτό παρατηρείται από την μέση απόκλιση όπου στις υψηλές ταχύτητες εμφανίζει μια απότομη άνοδο. Επίσης, ενδιαφέροντα είναι τα αποτελέσματα σχετικά με την θέση των αισθητήρων και συγκεκριμένα αυτών που είναι αρκετά κοντά στις πακτώσεις (1, 3, 4, 6), οι οποίοι δεν λειτουργούν αποτελεσματικά, ενώ οι αισθητήρες (2, 5) που βρίσκονται στο μέσον της κατασκευής εξάγουν καλύτερα αποτελέσματα. Αυτό φαίνεται από τα διαγράμματα όπου για τους ακραίους αισθητήρες (1, 3, 4, 6) η γκρι περιοχή, που απεικονίζει την τυπική απόκλιση, έχει αρκετά μεγάλος εύρος με αποτέλεσμα να θεωρεί σχεδόν όλους τους συναγερμούς (κόκκινοι) ως φυσιολογική κατάσταση, αφού περιλαμβάνονται μέσα στην γκρι περιοχή. Το αντίθετο συμβαίνει στους μεσαίους αισθητήρες (2, 5).


Στη συνέχεια, οι μελετητές για να λάβουν υπόψη μόνο τα περάσματα με υψηλό σφάλμα πρόβλεψης έκαναν χρήση του τύπου 15, με τον οποίο υπολογίζεται ο δείκτης βλαβών (Damage Index – DI) βασισμένος στην ταχύτητα της αμαξοστοιχίας.

Συγκεκριμένα, σε φυσιολογικές συνθήκες οι δείκτης είναι περίπου ίσος με το μηδέν ($DI \approx 0$), ενώ σε κατεστραμμένες συνθήκες ο δείκτης είναι διάφορος του μηδενός ($DI \neq 0$). Στο Σχήμα 25 φαίνεται το διάγραμμα καμπύλων ROC, το οποίο αναφέρεται αναλυτικά στο κεφάλαιο 2.2.4, για διαφορετικές βλάβες στην πρώτη περίπτωση, ενώ στο Σχήμα 26 φαίνονται τα αποτελέσματα για την δεύτερη περίπτωση βλάβης.

$$DI(v) = \sum_{n=1}^6 \frac{RMSE_n(v) - \mu_n(v)}{\sigma_n(v)} \quad (15)$$



Σχήμα 25: Διάγραμμα καμπυλών ROC για την πρώτη περίπτωση βλάβης με διαφορετικά μεγέθη βλάβης: — 20cm, — 40cm, — 70cm, — 100cm, — 160cm (Neves et al., 2017)



Σχήμα 26: Διάγραμμα καμπύλης ROC για την δεύτερη περίπτωση βλάβης (Neves et al., 2017)

Τα συμπεράσματα που προκύπτουν από τα παραπάνω διαγράμματα είναι ότι οι καμπύλες συγκλίνουν αρκετά κοντά στον άξονα των TP (True Positive) δείχνοντας ότι ο αλγόριθμος ήταν αποτελεσματικός στην πρόβλεψη των βλαβών. Πιο συγκεκριμένα, στο Σχήμα 25 για σταθερό σφάλμα που φαίνεται στον άξονα FP (False Positive) ίσο με 8%, οι καμπύλες των επιτυχών αποτελεσμάτων που εμφανίζονται στον άξονα TP έχουν ως αποτέλεσμα 86, 90.7, 92, 96 και 99.3% που αντιστοιχούν στις βλάβες της πρώτης περίπτωσης με μεγέθη 20, 40, 70, 100 και 160cm.

Συνοψίζοντας, από την παραπάνω μελέτη προκύπτει ότι για την καλύτερη εξαγωγή συμπερασμάτων οι ταχύτητες της αμαξοστοιχίας θα πρέπει να είναι χαμηλές και η τοποθέτηση των αισθητήρων θα πρέπει να γίνεται σε απόσταση από τις πακτώσεις, λόγω της καλύτερης δυναμικής απόκρισης της κατασκευής στο μέσον της. Έτσι, θα συμβάλλει στον σχεδιασμό της κατασκευής αλλά και στην καλύτερη ανάπτυξη συστήματος παρακολούθησης μέσω αισθητήρων. Η μελλοντική χρήση αυτού του αλγόριθμου θα είναι να προβλέπει και να εντοπίζει τις αστοχίες μιας γέφυρας χωρίς την επίβλεψη του, αλλά και χωρίς τον έλεγχο ολόκληρης της γέφυρας από κάποιο ειδικό συνεργείο.

3.2 Πρόβλεψη αστοχιών και σχεδιασμός δομικών στοιχείων των κατασκευών

Μια άλλη εφαρμογή της τεχνητής νοημοσύνης στον τομέα του πολιτικού μηχανικού είναι η πρόβλεψη αστοχιών και ο σχεδιασμός των δομικών στοιχείων μιας κατασκευής. Ο κύριος στόχος της ανάπτυξης και έρευνας σε τέτοιου είδους εφαρμογές είναι για την καλύτερη σχεδίαση μιας κατασκευής, η οποία θα έχει την δυνατότητα αύξησης του κύκλου ζωής του κτηρίου και πιο συγκεκριμένα των δομικών στοιχείων. Η βέλτιστη σχεδίαση μπορεί να συμβάλλει αρκετά στον σχεδιασμό ψηλών κτηρίων, όπου οι επιλογές των δομικών συστημάτων έχουν γίνει διαφορετικές και έχει ως αποτέλεσμα να γίνεται πολύ πιο εύκολα η επιλογή μιας ακατάλληλης δομής. Επιπλέον, μπορεί να προβλεφθεί μια κτηριακή δομή, η οποία θα είναι πιο οικονομική και εξίσου αποδοτική. Ένας άλλος στόχος τέτοιων εφαρμογών είναι η έγκαιρη πρόβλεψη αστοχιών δομικών στοιχείων. Σκοπός της πρόβλεψης είναι η άμεση επέμβαση του ανθρώπινου παράγοντα για τον έλεγχο και την επισκευή της βλάβης, για την αποφυγή επέκτασης της βλάβης στο κτήριο και την ασφάλεια των ανθρώπων.

Ορισμένες τέτοιες μελέτες αναφέρονται συνοπτικά παρακάτω. Ο Sadowski (2013) πραγματοποίησε μια μελέτη για την πρόβλεψη της διάβρωσης του χάλυβα, με χρήση δοκιμίων, κάνοντας σύγκριση ανάμεσα σε ένα Multilayer Perception Neural Network (MLP-NN) και στον συνδυασμό των μεθόδων ηλεκτρικής αντίστασης, της γαλβανιστικής αντίστασης και της μεθόδου Linear Polarisation Resistance (LPR). Τα αποτελέσματα που προέκυψαν ήταν αρκετά ικανοποιητικά αφού ο αλγόριθμος εμφάνισε μηδενικό σφάλμα. Οι Hwang et al. (2019) στην μελέτη τους με την βοήθεια του Artificial Neural Network (ANN) προσπάθησαν να προβλέψουν το βέλτιστο μήκος μάτισης και έκαναν σύγκριση τα αποτελέσματά του με αυτά των κανονισμών, όπως του Eurocode 2, ACI 318-14 και ACI 408R-03. Τα αποτελέσματα που προέκυψαν ήταν αρκετά καλά και αποδεικνύει ότι το ANN ενισχύει την αξιοπιστία στον σχεδιασμό και την αποδοτικότητά του σε εφαρμογές σχεδιασμού. Οι Ma et al. (2013) στην έρευνα τους δημιούργησαν έναν συνδυασμό γενετικού αλγορίθμου με νευρωνικά δίκτυα, με σκοπό την βέλτιστη επιλογή δομών για ψηλά κτίρια.

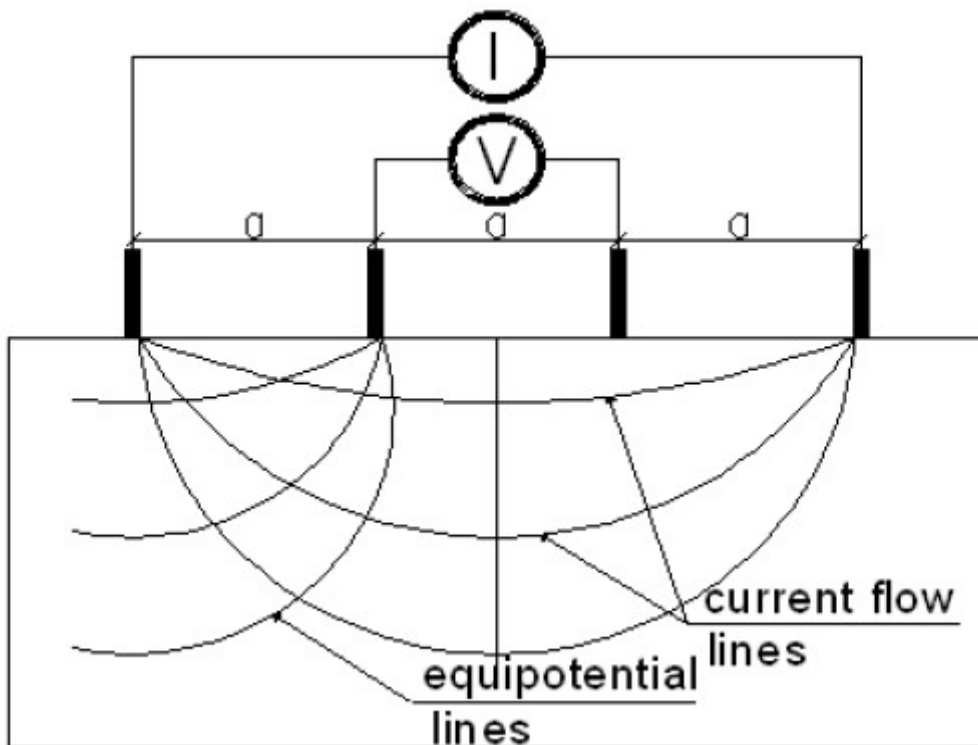
Παρακάτω παρουσιάζονται αναλυτικότερα τα παραδείγματα των Sadowski (2013) και Ma et al. (2013) ως προς την μεθοδολογία που ακολουθήθηκε και τα συμπεράσματα που προέκυψαν.

3.2.1 Μελέτη Περίπτωσης 1: Πρόβλεψη διάβρωσης χάλυβα

Ο Sadowski (2013) πραγματοποίησε μια πειραματική μελέτη, με σκοπό την πρόβλεψη διάβρωσης του χάλυβα σε δομικά στοιχεία με χρήση μη καταστροφικών μεθόδων του σκυροδέματος. Την πρόβλεψη της διάβρωσης την υπολόγισε με την βοήθεια του ANN. Η διάβρωση του χάλυβα αποτελεί μια κύρια αιτία φθοράς σε κατασκευές από οπλισμένο σκυρόδεμα και τίθεται αναγκαία η πρόβλεψή της λόγω της μη εύκολης πρόσβασης σε αυτή. Στο συγκεκριμένο πείραμα ο μελετητής έκανε χρήση συνδυαστικά των μεθόδων της ηλεκτρικής αντίστασης (resistivity method), της γαλβανοστατικής (galvanostatic method) και της μεθόδου αντίστασης γραμμικής πόλωσης (Linear Polarisation Resistance – LPR), παρόλο την συχνή χρήση της μεθόδου LPR σε πολλές άλλες πειραματικές μελέτες. Αυτό συμβαίνει διότι μεμονωμένα το LPR παρουσίαζε μειονεκτήματα όπως ότι απαιτείται η διάσπαση της επικάλυψης σκυροδέματος για την μέτρηση της πυκνότητας της διάβρωσης και την έλλειψη ακρίβειας λόγω της μόλυνσης του χάλυβα από χλώριο. Με την μέθοδο LPR υπολογίζεται η πυκνότητα διάβρωσης του σκυροδέματος, με την χρήση ενός συνεχές ηλεκτρικού σήματος DC.

Στο Σχήμα 27 φαίνεται η μέθοδος της ηλεκτρικής αντίστασης κάνει χρήση ενός εναλλασσόμενου ρεύματος χαμηλής έντασης I σε ένα διάστημα “ a ” το οποίο διέρχεται από το σκυρόδεμα με την χρήση δυο επιφανειακών ηλεκτροδίων. Στη συνέχεια, η μέτρηση του δυναμικού V ανάμεσα στα δυο μεσαία ηλεκτρόδια, δίνει μια τιμή της ηλεκτρικής αντίστασης στην περιοχή της επιφάνειας του σκυροδέματος με την χρήση του τύπου 16.


$$\rho = 2\pi a \frac{V}{I} \quad (16)$$



Σχήμα 27: Σχηματική απεικόνιση μέτρησης της ηλεκτρικής αντίστασης (Sadowski, 2010)

Στο πείραμα αυτό, λόγω της συχνής χρήσης μεθόδων όπως το τεχνητό νευρωνικό δίκτυο (Artificial Neural Network – ANN) για την πρόβλεψη της διάβρωσης από διάφορους ερευνητές, εφαρμόζεται το Multilayer Perception Neural Network (MLP-NN) ως ένα από τα δημοφιλέστερα μοντέλα ANN. Συγκεκριμένα, γίνεται χρήση τεσσάρων παραμέτρων, όπου θα αναφερθούν παρακάτω, σε αντίθεση με τις άλλες μελέτες.

Τα δοκίμια που χρησιμοποιήθηκαν στο εργαστήριο για την εξαγωγή των πειραματικών αποτελεσμάτων ήταν δυο ειδών και διέφεραν στον ρυθμό διάβρωσης τους (Δοκίμιο 1/Slab A και Δοκίμιο 2/Slab B). Πιο συγκεκριμένα, τα δοκίμια είχαν διαστάσεις 400 mm × 300 mm × 100 mm και αποτελούνταν από σκυρόδεμα C 20/25 και τσιμέντο Portland CEM I 42.5R πάχους 5 mm. Μέσα στο σκυρόδεμα ήταν τοποθετημένη χαλύβδινη ράβδος 30 mm κατηγορίας A-III 34GS. Τα δοκίμια ήταν τοποθετημένα στο εργαστήριο με σχετική υγρασία σκυροδέματος $65\% \pm 1\%$. Στο Σχήμα 28 φαίνεται ο τρόπος με τον οποίο γίνεται η μέτρηση και το δοκίμιο που χρησιμοποιείται στο εργαστήριο.



Σχήμα 28: Τρόπος μέτρησης αντίστασης στο εργαστήριο (Sadowski, 2013)

Στη συνέχεια, κάνοντας χρήση της συνδυαστικής μεθόδου που αναφέρθηκε πιο πάνω, έγινε ο υπολογισμός των πειραματικών αποτελεσμάτων. Πιο συγκεκριμένα, για κάθε δοκίμιο έγιναν 68 μετρήσεις, χωρίς την αλλαγή κάποιας μεταβλητής και πραγματοποιώντας συνεχώς μια καινούργια μέτρηση, από τις οποίες γινόταν υπολογισμός:

- της θερμοκρασίας (T σε °C)
- της αντίστασης AC της ράβδου ($\rho_{AC,bar}$ σε kΩ cm)
- της αντίστασης AC του σκυροδέματος ($\rho_{AC,conc}$ σε kΩ cm)
- της αντίστασης DC της ράβδου (ρ_{DC} σε kΩ cm)

Με βάση τις παραπάνω μετρήσεις γινόταν υπολογισμός της πυκνότητας διάβρωσης (i_{corr} σε $\mu\text{A}/\text{cm}^2$). Οι μετρήσεις αυτές φαίνονται στους Πίνακες 3 και Πίνακας 4, από τους οποίους έχουν παραληφθεί κάποια στοιχεία, για το δοκίμιο 1 και 2 αντίστοιχα.

Πίνακας 3: Πειραματικά αποτελέσματα από το πρώτο δοκίμιο (Sadowski, 2013)

No.	T (°C)	$\rho_{ac,bar}$ (k Ω cm)	$\rho_{AC,conc}$ (k Ω cm)	ρ_{DC} (k Ω cm)	i_{corr} ($\mu\text{A}/\text{cm}^2$)
1	21.00	3.15	24.93	3.75	8.412
2	20.80	3.16	24.99	3.81	8.425
3	20.50	3.18	25.12	3.86	8.436
4	20.10	3.19	25.28	3.88	8.441
.
.
.
68	19.10	3.16	23.92	2.76	8.411

Πίνακας 4: Πειραματικά αποτελέσματα από το δεύτερο δοκίμιο (Sadowski, 2013)

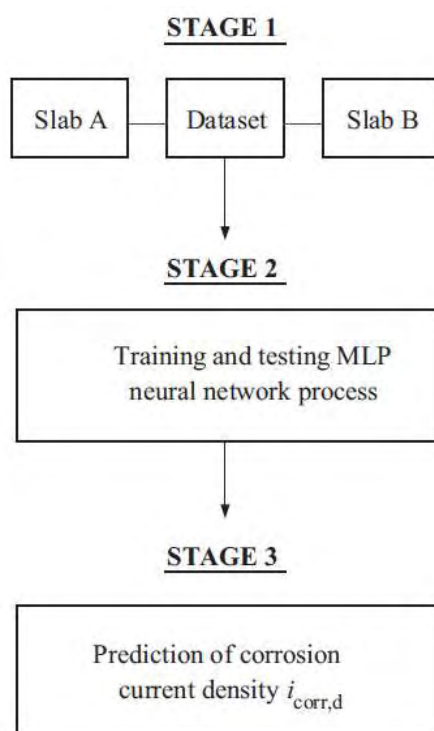
No.	T (°C)	$\rho_{ac,bar}$ (k Ω cm)	$\rho_{AC,conc}$ (k Ω cm)	ρ_{DC} (k Ω cm)	i_{corr} ($\mu\text{A}/\text{cm}^2$)
1	21.00	19.31	22.27	21.81	0.422
2	20.80	19.33	22.28	21.83	0.423
3	20.50	19.34	22.30	21.85	0.421
4	20.10	19.35	22.31	21.91	0.439
.
.
.
68	19.10	19.30	22.22	21.77	0.421

Έπειτα, ο μελετητής ακολουθεί τρία στάδια για την μεθοδολογία του MLP-NN (Σχήμα 29). Αρχικά, στο πρώτο στάδιο γίνεται συλλογή των πειραματικών αποτελεσμάτων που υπολογίστηκαν για εκπαίδευση και δοκιμή του MLP-NN. Στον αλγόριθμο ως είσοδοι χρησιμοποιούνται οι τέσσερις παράμετροι T, $\rho_{AC,bar}$, $\rho_{AC,conc}$ και ρ_{DC} , ενώ ως έξοδος υπολογίζεται η μεταβλητή $i_{corr,d}$. Στο δεύτερο βήμα, γίνεται κανονικοποίηση των δεδομένων εισόδου και εξόδου, πριν εισαχθούν στον αλγόριθμο, μέσω του τύπου 17.

$$\alpha \frac{y_i - y_{min}}{y_{max} - y_{min}} + b \quad (17)$$

Όπου y_{min} και y_{max} είναι η ελάχιστη και η μέγιστη τιμή από τα δεδομένα, y_i η τιμή για τον δείκτη i και οι σταθερές a και b λαμβάνονται ως 0.6 και 0.2 αντίστοιχα.

Στη συνέχεια γίνεται η εκπαίδευση και η δοκιμή του, που αναφέρονται εκτενέστερα παρακάτω, με τα παραπάνω επεξεργασμένα δεδομένα. Επίσης, για τον έλεγχο των αποτελεσμάτων χρησιμοποιούνται τα σφάλματα R^2 και MAPE, που αναφέρονται στο κεφάλαιο 2.2.3, και πριν την ολοκλήρωση του σταδίου 2 γίνεται αποκανονικοποίηση. Τέλος, κατά το τρίο στάδιο γίνεται πρόβλεψη της μεταβλητής $i_{corr,d}$.

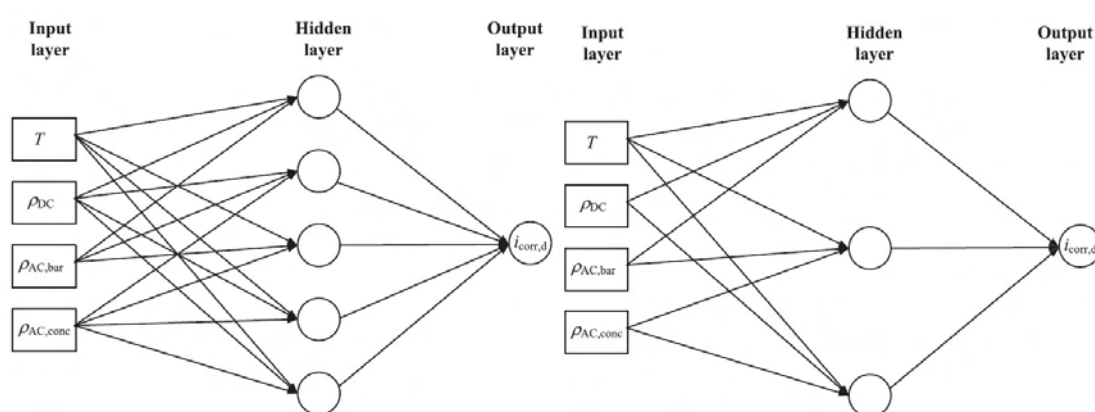


Σχήμα 29: Στάδια μεθοδολογίας για το MLP-NN (Sadowski, 2013)

Όσον αφορά, τα δεδομένα που συλλέχθηκαν από τα πειράματα, ο ερευνητής τα χώρισε και τα χρησιμοποίησε για την εκπαίδευση, την δοκιμή και την επαλήθευση του αλγορίθμου. Συγκεκριμένα, το 70% των δεδομένων εφαρμόστηκε για την εκπαίδευση του αλγορίθμου και το 15% για την δοκιμή του. Τα αποτελέσματα που προέκυψαν ήταν αρκετά ικανοποιητικά και αυτό φαίνεται από το μέγεθος των σφαλμάτων που υπολογίστηκαν.

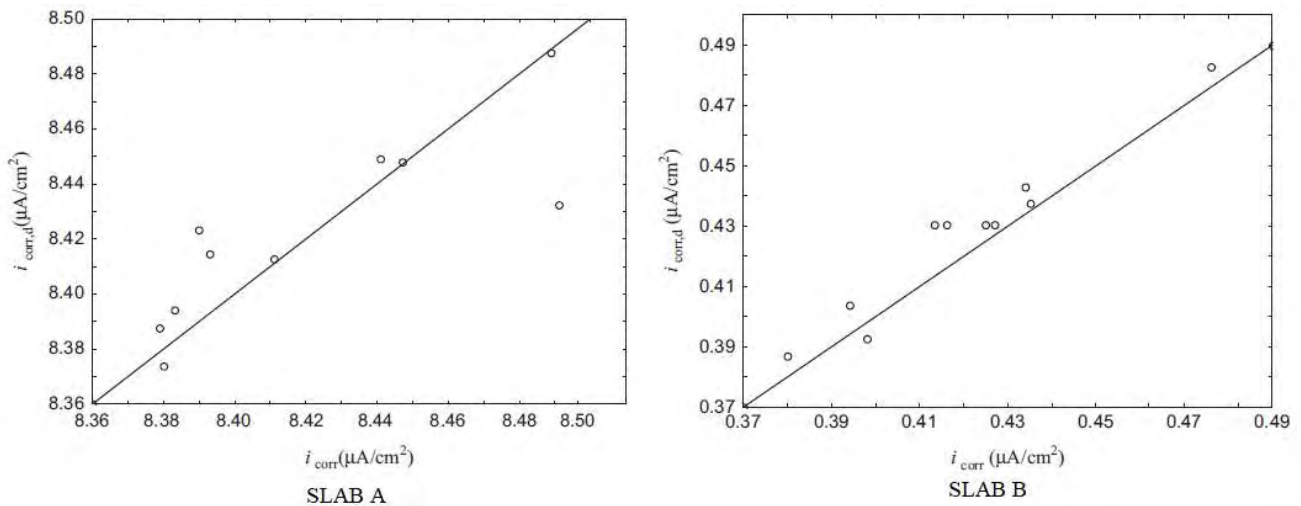
Για τον αλγόριθμο έγιναν δοκιμές για την εύρεση της βέλτιστης δομής, ως προς το πλήθος των κόμβων στο κρυφό στρώμα. Συγκεκριμένα, έκαναν δοκιμές με χρήση από 3 έως 9 κόμβους και γίνεται υπολογισμός των σφαλμάτων R^2 και MAPE για την

διαδικασία της εκπαίδευσης και της δοκιμής, με σκοπό την σύγκριση τους και την εύρεση του πιο αποδοτικού. Η διαδικασία αυτή ακολουθήθηκε για τους αλγόριθμους και των δυο δοκιμίων. Για το πρώτο δοκίμιο καλύτερη δομή βρέθηκε αυτή με την χρήση 5 κόμβων (Σχήμα 30), με τα αποτελέσματα των σφαλμάτων να είναι για την εκπαίδευση 0.943629 και 0.000090 για τα R^2 και MAPE αντίστοιχα, ενώ για την δοκιμή 0.984322 και 0.000035. Το δεύτερο δοκίμιο λειτούργησε αποδοτικότερα με την χρήση 3 κόμβων (Σχήμα 30) και τα αποτελέσματα που προέκυψαν για την εκπαίδευση είναι 0.910938 και 0.000077 για τα R^2 και MAPE αντίστοιχα, ενώ για την δοκιμή 0.980172 και 0.000021.



Σχήμα 30: Δομές MLP-NN: Αριστερά του πρώτου δοκιμίου και δεξιά του δεύτερου δοκιμίου (Sadowski, 2013)

Έπειτα, έγινε χρήση του υπόλοιπου 15% από το σύνολο των δεδομένων για τον έλεγχο της γενικευμένης ικανότητας του MLP-NN σε κάθε δοκίμιο. Τα αποτελέσματα που προέκυψαν για το πρώτο δοκίμιο ήταν 0.846335 και 0.000266 για τα R^2 και MAPE αντίστοιχα, ενώ για το δεύτερο δοκίμιο 0.982395 και 0.000027. Όπως φαίνεται λόγω του υψηλού αριθμού του συντελεστή συσχέτισης (R^2) και του χαμηλού μέσου απόλυτου ποσοστού σφάλματος (MAPE), οι αλγόριθμοι λειτούργησαν με υψηλό βαθμό ακρίβειας. Όπως φαίνεται στο παρακάτω Σχήμα 31, το οποίο στους άξονες είναι η πυκνότητα διάβρωσης για τα προβλεπόμενα ($i_{corr,d}$) και πειραματικά δεδομένα (i_{corr}), τα αποτελέσματα του αλγορίθμου εμφανίζονται αρκετά κοντά στα ιδανικά αποτελέσματα, που απεικονίζονται με την ευθεία γραμμή.



Σχήμα 31: Διαγράμματα αποτελεσμάτων για την γενικευμένη επαλήθευση του MLP-NN (Sadowski, 2013)

Συνοψίζοντας, το MLP-NN όπως φαίνεται λειτουργήσε αρκετά αποδοτικά για την εύρεση της διάβρωσης του χάλυβα. Τα αποτελέσματα που εξάγει είναι θεωρητικά χρησιμοποιώντας την πυκνότητα του ρεύματος χωρίς την ανάγκη σύνδεσης με τον χάλυβα. Όμως, μπορεί να βελτιωθεί με την εφαρμογή περισσότερων δοκιμίων, με σκοπό την αύξηση του φάσματος έχοντας περισσότερα δεδομένα για την αντίσταση και υγρασία του σκυροδέματος. Η εφαρμογή αυτής της μεθόδου μηχανικής μάθησης μπορεί να εφαρμοστεί στο μέλλον σε διάφορες περιπτώσεις χωρίς να χρειάζεται να επηρεαστεί η επικάλυψη του σκυροδέματος, όπως αυτό συμβαίνει τώρα με την μέθοδο του LPR.

3.2.2 Μελέτη Περίπτωσης 2: Βελτίωση σχεδιασμού ψηλών κτηρίων με χρήση μηχανικής μάθησης

Στην μελέτη τους οι Ma et al. (2013), προσπάθησαν να προσδιορίσουν την βέλτιστη δομή ενός πολυώροφου κτηρίου με την βοήθεια της μηχανικής μάθησης. Οι λόγοι έρευνας και ανάπτυξης αλγόριθμου οφείλονται στην περίπλοκη διαδικασία σχεδιασμού ψηλών κτηρίων, αφού με την ανάπτυξη της οικονομίας και την αύξηση του αστικού πληθυσμού καθίσταται αναγκαίο η αύξηση του ύψους και η ασφάλεια των κτηρίων. Επειδή σε τέτοιες κατασκευές είναι πολύ εύκολη η επιλογή ενός ακατάλληλου δομικού συστήματος, είναι αρκετά σημαντική η δημιουργία μιας μεθόδου μηχανικής μάθησης για την καταλληλότερη επιλογή.

Οι ερευνητές για την δημιουργία μίας τέτοιας μεθόδου έκαναν χρήση του νευρωνικού δικτύου μέσω του προγράμματος MATLAB και των γενετικών αλγορίθμων, με σκοπό να δημιουργήσουν ένα συνδυαστικό αλγόριθμο. Η διαδικασία των αλγορίθμων φαίνεται εκτενέστερα στο κεφάλαιο 2. Συγκεκριμένα, ο συνδυαστικός αλγόριθμος αποτελείται από ένα νευρωνικό δίκτυο οπισθοδιάδοσης και τον γενετικό αλγόριθμο. Η διαδικασία που ακολουθεί ο αλγόριθμος γενετικού νευρωνικού δικτύου είναι η εξής:

- Κώδικας: εκφράζει τα βάρη ως πραγματικό αριθμό και καθορίζει τις παραμέτρους, όπως η κλίμακα του πληθυσμού, την πιθανότητα διασταύρωσης, την πιθανότητα μετάλλαξης, το στρώμα δικτύου (χωρίς την ύπαρξη επιπέδου εισόδου) και τους αριθμούς νευρώνων σε κάθε στρώμα.
- Αρχικοποίηση του πληθυσμού: δημιουργεί n τυχαίους πίνακες με βάρη για να σχηματιστεί ο αρχικός πληθυσμός, όπου κάθε πίνακας αντιπροσωπεύει ένα νευρωνικό δίκτυο που θα εκπαιδευτεί.
- Αξιολόγηση: χειρίζεται το νευρωνικό δίκτυο, υπολογίζει τις τιμές και κρατάει τις καλύτερες.
- Γενετική λειτουργία: χειρίζεται τα νευρωνικά δίκτυα επιλέγοντας, ανταλλάζοντας, μεταλλάζοντας και εκπαιδεύοντάς τα, διατηρώντας τις καλύτερες τιμές και αν το σφάλμα πληροί κάποια καθορισμένη ακρίβεια τελειώνει η διαδικασία, αλλιώς επαναλαμβάνεται το βήμα.

Οι μελετητές σύμφωνα με την βιβλιογραφία που μελέτησαν, ξεχώρισαν ορισμένους βασικούς παράγοντες που επηρεάζουν την δομή μιας κατασκευής πολλών επιπέδων. Αυτοί οι παράγοντες είναι οι εξής:

- Συνολικό ύψος κτηρίου (X_1): αφορά το συνολικό ύψος του κτηρίου, σύμφωνα με τις προδιαγραφές για τα μέγιστα ύψη που ισχύουν στην περιοχή.
- Τύπος υλικού (X_2): αφορά το υλικό που θα χρησιμοποιηθεί για την κατασκευή του κτηρίου. Ο αλγόριθμος επιλέγει 1 για δομή σκυροδέματος και 2 για μεταλλική δομή.
- Βαθμός αντισεισμικής ικανότητας (X_3): αναφέρεται στην αντισεισμική ενίσχυση του κτηρίου βασισμένη σε δεδομένα σεισμών της περιοχής.
- Κατηγορίες τοποθεσιών (X_4): σχετίζεται με τις γεωλογικές πληροφορίες και την δραστηριότητα του σεισμού και επηρεάζει τον βαθμό της αντισεισμικής

ικανότητας. Οι κατηγορίες επιλογής του αλγορίθμου είναι 1 για την τάξη I, 2 για την τάξη α και 3 για την τάξη β.

- Ένταση ανέμου (X_5): αναφέρεται στην πλευρική παραμόρφωση του κτηρίου ανάλογα το φορτίο ανέμου που δέχεται.
- Χαρακτηριστικά σχεδίου κτηρίου (X_6, X_7): αφορά τους λόγους βάθους – πλάτους (X_6) και μήκους – πλάτους (X_7) μιας κατασκευής δείχνοντας την συμμετρία και την κανονικότητα της.
- Λειτουργία κτηρίου (X_8): σχετίζεται με τις διάφορες λειτουργίες που μπορεί να έχει ένα κτήριο. Ο αλγόριθμος επιλέγει 1 για διαμέρισμα, 2 για ξενοδοχείο, 3 για γραφείο, 4 για δημόσια υπηρεσία, 5 για χώρους εκδηλώσεων, 6 για εστιατόριο.

Όσο αναφορά το γενετικό νευρωνικό δίκτυο, αποτελείται από 8 εισόδους, οι οποίοι είναι οι παράμετροι που προαναφέρθηκαν, 21 νευρώνες στο κρυφό στρώμα και 4 νευρώνες στο στρώμα εξόδου. Οι νευρώνες εξόδου παρουσιάζουν τα δομικά στοιχεία που επιλέγονται από τον αλγόριθμο και οι επιλογές που έχει είναι y_1 για αντισεισμικό τοίχωμα (shear wall), y_2 για αντισεισμικό πλαίσιο (frame shear), y_3 για frame-tube και y_4 για tube in tube. Οι μεταβλητές y_1, y_2, y_3 και y_4 υποδηλώνουν την πιθανότητα το κτήριο να αποτελείται από αυτόν τον τύπο δομών. Η εκπαίδευσή του πραγματοποιήθηκε με χρήση 180 δειγμάτων, όπως φαίνονται στον Πίνακα 5. Η διαδικασία εκπαίδευσης ολοκληρώθηκε μετά από 5030 βήματα όπου το μέγεθος του σφάλματος ήταν αρκετά μικρό.

Πίνακας 5: Χαρακτηριστικά των δειγμάτων (Ma et al., 2013)

Serial number	Name	X_1	X_2	X_3	X_4	X_5	X_6	X_7	Structure	X_8
1	Xiyuan Hotel	93	1	8	2	344	1.31	1.45	shear wall	1
2	Kunlun Hotel	99.5	1	8	2	343.2	2.97	1.42	shear wall	1
	
41	Hongqiao Hotel	103.7	1	7	3	490	1	2.19	frame shear	1
42	International Mansion	101	1	8	2	343	1.8	2.85	frame shear	5
	
180	Hilton Hotel Shanghai	143.6	1	7	3	490	1.5	2.37	tube in tube	2

Για την δοκιμή του αλγορίθμου έγινε επιλογή 10 τυχαίων δεδομένων από τον παραπάνω πίνακα με σκοπό να ελεγχθεί η αποδοτικότητα του. Τα αποτελέσματα του φαίνονται στον παρακάτω Πίνακας 6.

Πίνακας 6: Αποτελέσματα πρόβλεψης του γενετικού νευρωνικού δικτύου (Ma et al., 2013)

Serial number (K)	y_1	y_2	y_3	y_4	Forecast structure type	Actual structure
1	0.9092	0.0005	0.0030	0.0077	shear wall	shear wall
2	0.9887	0.0000	0.0544	0.0000	shear wall	shear wall
.....					...	
<u>7</u>	<u>0.0003</u>	<u>0.3851</u>	<u>0.0067</u>	<u>0.7843</u>	<u>tube in tube</u>	<u>frame-tube</u>
8	0.0203	0.0350	0.9445	0.0000	frame-tube	frame-tube
9	0.0001	0.0063	0.0291	0.9599	tube in tube	tube in tube
10	0.0001	0.0001	0.0440	0.9935	tube in tube	tube in tube

Όπως φαίνεται ο αλγόριθμος λειτούργησε αρκετά καλά έχοντας προβλέψει σωστά όλες τις περιπτώσεις εκτός από μία. Στην πρώτη για παράδειγμα, ο αλγόριθμος προέβλεψε σωστά την δομή shear wall αφού $y_1=0.9092$. Συγκεκριμένα στην έβδομη ο αλγόριθμος προέβλεψε κτήριο με δομή tube in tube (Forecast structure type) αφού έβγαλε $y_4=0.7843$, ενώ το κτήριο έχει δομή frame tube (Actual structure). Τέλος, ο αλγόριθμος είναι αρκετά αποδοτικός, όμως σύμφωνα με τους ερευνητές το μοντέλο μπορεί να βελτιωθεί με αύξηση των δειγμάτων για εκπαίδευση, έτσι ώστε να έχει καλύτερη απόδοση, υψηλότερη ακρίβεια και ευρύτερο πεδίο εφαρμογής. Ο αλγόριθμος αυτός στο μέλλον, μετά από βελτίωση, θα μπορεί να χρησιμοποιηθεί για την πρόβλεψη της δομής ενός ψηλού κτηρίου και να αποφευχθούν λανθασμένες επιλογές που μπορούν να οδηγήσουν σε σοβαρά προβλήματα της κατασκευής.

3.3 Πρόβλεψη σύνθεσης και ιδιοτήτων σκυροδέματος

Τα τελευταία χρόνια έχει παρουσιαστεί μια αύξηση στην εφαρμογή αλγορίθμων στο σκυρόδεμα για την εύρεση διαφόρων χαρακτηριστικών και ιδιοτήτων του. Αυτό οφείλεται στη τάση να ψηφιοποιηθούν τα δοκίμια σε εικονικό περιβάλλον με στόχο την πραγματοποίηση πειραμάτων σε μικρό χρονικό διάστημα και άμεση αλλαγή των στοιχείων σε περίπτωση σφάλματος. Όλα αυτά γίνονται χωρίς το κόστος, την αναμονή δημιουργίας του δοκιμίου και την εκτέλεση του πειράματος. Ορισμένοι από τους αλγόριθμους έχουν να κάνουν με την βέλτιστη σύνθεση του σκυροδέματος όπως και με την θλιπτική αντοχή του. Με την ανάπτυξη της τεχνολογίας έχουν δημιουργηθεί αρκετά μοντέλα προσομοίωσης με σκοπό την ταχεία και ακριβέστερη

πρόβλεψη ιδιοτήτων του σκυροδέματος. Επιπλέον, η ανάπτυξη των αλγορίθμων μπορούν να βοηθήσουν στην δημιουργία ενός διαφορετικού τύπου σκυροδέματος με άλλα αδρανή (όπως καουτσούκ, σκωριά, τέφρα) ή αλλάζοντας τα ποσοστά χρήσης του κάθε υλικού (όπως νερό, αδρανή, τσιμέντο), με σκοπό την επίτευξη του επιθυμητού αποτελέσματος στις ιδιότητες του. Επίσης, ένας ακόμη λόγος χρήσης τους είναι η συνεισφορά τους στην λήψη αποφάσεων των κατασκευαστών, σε περιπτώσεις όπως η εύρεση της αντοχής του σκυροδέματος σε πρώιμα στάδια.

Τα πειράματα που πραγματοποιούνται στο σκυρόδεμα ποικίλουν ανάλογα με το αποτέλεσμα που θέλουν να παρουσιάσουν. Οι Boukhatem et al. (2011) χρησιμοποιούν προσομοιωτικό μοντέλο τεχνητού νευρωνικού δικτύου και πιο συγκεκριμένα το πρόγραμμα BetonlabPro, το οποίο περιέχει εφαρμογές τεχνητής νοημοσύνης, με σκοπό την απεικόνιση της σύνθεσης του σκυροδέματος και την πρόβλεψη της αντοχής του. Οι Chou et al. (2014), έχοντας ως δεδομένα δοκιμίων που διαφέρουν ανάλογα με τον τρόπο παρασκευής τους από πέντε διαφορετικές χώρες, χρησιμοποιούν όχι μεμονωμένες μεθόδους μηχανικής μάθησης, όπως για παράδειγμα Multilayer Perception (MLP) neural network, Support Vector Machine (SVM), Classification and Regression Tree (CART) και Linear Regression (LR), αλλά και συνδυαστικά με σκοπό την εύρεση του καλύτερου τρόπου για την πρόβλεψη της θλιπτικής αντοχής του σκυροδέματος. Ως συμπέρασμα προκύπτει ότι καλύτερη πρόβλεψη παρουσιάζουν οι συνδυαστικές τεχνικές μάθησης, ωστόσο ο συνδυασμός των μεμονωμένων μεθόδων πρέπει να γίνει με προσοχή για καλύτερη αποτελεσματικότητα. Οι Prayogo et al. (2017) δημιούργησαν έναν συνδυαστικό αλγόριθμο, τον Symbiotic Organisms Search-Based Support Vector Regression (SOS-SVR), για την πρόβλεψη της θλιπτικής αντοχής, τον οποίο τον σύγκριναν με πέντε διαφορετικές μεθόδους μηχανικής μάθησης, μερικές από τις οποίες είναι το classification and regression tree (C&R tree), το Support Vector Machine (SVM) και το Neural Network (neural net), με στόχο να βρουν την αντοχή του σκυροδέματος σε πρώιμα στάδια. Τα συμπεράσματα που προέκυψαν είναι ότι ο συνδυαστικός αλγόριθμος έχει καλύτερα αποτελέσματα σε σχέση με τους υπόλοιπους. Οι Vakharia και Gujar (2019) προσπάθησαν με την χρήση της διασταυρούμενης επικύρωσης και της κατάταξης των χαρακτηριστικών να βελτιώσουν τα αποτελέσματα που εξάγουν οι τέσσερις μέθοδοι πρόβλεψης που χρησιμοποιούνται, οι οποίες είναι το Isotonic regression, το Multilayer Perception (MLP), το Support Vector Machine (SVM) και το

Random Forest, ως προς την σύνθεση και την αντοχή του σκυροδέματος και ως προς την σύνθεση του τσιμέντου Portland.

Παρακάτω παρουσιάζονται αναλυτικότερα τα παραδείγματα των Chou et al. (2014) και Vakharia και Gujar (2019) ως προς την μεθοδολογία που ακολουθήθηκε και τα συμπεράσματα που προέκυψαν.

3.3.1 Μελέτη περίπτωσης 1: Πρόβλεψη θλιπτικής αντοχής σε δοκίμια πολλών εθνών

Οι Chou et al. (2014) όπως αναφέραμε παραπάνω πραγματοποίησαν ένα πείραμα πρόβλεψης της θλιπτικής αντοχής σε δοκίμια σκυροδέματος υψηλής αντοχής (HPC) από διαφορετικές χώρες, με στόχο να αξιολογηθεί η χρησιμότητα και να προσδιοριστεί η καλύτερη μέθοδος μηχανικής μάθησης. Η πρόβλεψη ενός τέτοιου είδους σκυροδέματος είναι πιο δύσκολη σε σχέση με το συμβατικό σκυρόδεμα, λόγω της μη γραμμικής συσχέτισης μεταξύ των συστατικών και των ιδιοτήτων του σκυροδέματος. Οι μέθοδοι μηχανικής μάθησης που επέλεξαν οι ερευνητές είναι οι πιο δημοφιλείς και πιο εφαρμοσμένοι σε τέτοιου είδους προβλήματα, επειδή έχουν καλύτερη αποτελεσματικότητα σε σχέση με τις μεθόδους που χρησιμοποιούνται σε πειράματα συμβατικού σκυροδέματος. Αυτές οι μέθοδοι είναι οι εξής:

- Multilayer Perception (MLP) neural network
- Support Vector Machine (SVM)
- Classification and Regression Tree (CART)
- Linear Regression (LR)

Οι παραπάνω αλγόριθμοι παρουσιάζονται στο κεφάλαιο 2.

Στη συνέχεια, για τον συνδυασμό των αλγορίθμων έγινε χρήση τριών διαφορετικών μεθόδων συνδυασμού, οι οποίες είναι:

- **Votting:** κάνει χρήση των αποτελεσμάτων που προκύπτουν από τους μεμονωμένους αλγορίθμους και με διαφορετικό συνδυασμό εκτιμήσεων πιθανότητας γίνεται ο συνδυασμός τους.
- **Bagging:** χρησιμοποιεί τη μέθοδο bootstrap, η οποία βασίζεται στην τυχαία δειγματοληψία, για την μεμονωμένη εκπαίδευση των αλγορίθμων με διαφορετικά δεδομένα και έπειτα δημιουργεί ένα σύνολο για τον κάθε έναν

αλγόριθμο μέσω μιας κατάλληλης μεθόδου συνδυασμού, όπως τον μέσο όρο πιθανοτήτων.

- **Stacking:** δημιουργεί μια κατασκευή πολλαπλών επιπέδων, στην οποία το πρώτο επίπεδο αποτελείται από μεμονωμένους αλγόριθμους και τα αποτελέσματα, που παράγει, τα χρησιμοποιεί ο συνδυασμένος αλγόριθμος για την εκπαίδευση του, που βρίσκεται στο δεύτερο επίπεδο. Έτσι, η τελική απόφαση προκύπτει από τον συνδυασμένο αλγόριθμο.

Επιπλέον, για τους μεμονωμένους και συνδυασμένους αλγορίθμους έγινε χρήση της διασταυρούμενης μεθόδου για την εκπαίδευση των αλγορίθμων. Για την εύρεση των σφαλμάτων χρησιμοποιήθηκαν ορισμένοι από τους τύπους που έχουν προαναφερθεί στο κεφάλαιο 2.2.3, και πιο συγκεκριμένα το MAE, RMSE, MAPE και SI.

Τα δεδομένα με τα οποία εργάστηκαν οι μελετητές προέρχονται από πέντε διαφορετικές χώρες και διαφέρουν ως προς τα συστατικά του σκυροδέματος. Πιο συγκεκριμένα οι χώρες αυτές είναι η Ταϊβάν, η Χιλή, το Χόνγκ Κόνγκ, η Νότια Κορέα και το Ιράν. Τα δεδομένα που συλλέχθηκαν από την κάθε χώρα αναγράφονται παρακάτω:

- Ταϊβάν: δεδομένα από μια ομάδα 1133 κυλινδρικών δοκιμίων τσιμέντου Portland, το οποίο περιείχε διάφορα πρόσθετα, με διάμετρο 15 εκατοστών.
- Χιλή: κυλινδρικά δοκίμια διαμέτρου 15 και 30 εκατοστών από ταχείας σκλήρυνσης τσιμέντου σκωρίας Portland
- Χόνγκ Κόνγκ: δεδομένα από 144 δοκίμια τσιμέντου Portland και με διαφορετικό ποσοστό νερού και ιπτάμενης τέφρας, η οποία αντικαθιστά το σκυρόδεμα σε ποσοστό από 0 – 55 %
- Νότια Κορέα: δοκίμια κατασκευασμένα από τσιμέντο, με θλιπτική αντοχή 40 – 80 MPa, και τέφρα με ποσότητα από 0 – 20 %
- Ιράν: δεδομένα από 100 δείγματα σκυροδέματος που περιέχουν Metakaolin, το οποίο είναι ποζολάνιο και προσφέρει υψηλή αρχική αντοχή στο σκυρόδεμα, και αντικαθιστά το τσιμέντο σε ποσοστό από 0 – 20 %

Αναλυτικότερα τα δεδομένα φαίνονται στον Πίνακα 7.

Πίνακας 7: Οι ιδιότητες του HPC ανά χώρα (Chou et al., 2014)

Parameter	Unit	Min.	Ave.	Max.	Direction	
<i>Dataset 1 – Taiwan</i>						
Cement	kg/m ³	102.0	276.50	540.0	Input	
Blast-furnace slag	kg/m ³	0.0	74.27	359.4		
Fly ash	kg/m ³	0.0	62.81	260.0		
Water	kg/m ³	121.8	182.98	247.0		
Super-plasticizer	kg/m ³	0.0	6.42	32.2		
Coarse aggregate	kg/m ³	708.0	964.83	1145.0		
Fine aggregate	kg/m ³	594.0	770.49	992.6		
Age of testing	Days	1.0	44.06	365.0		
Concrete compressive strength	MPa	2.3	35.84	82.6		
<i>Dataset 2 – Chile</i>						
Coarse aggregate	kg/m ³	1105.0	1135.73	1173.0	Input	
Fine aggregate	kg/m ³	488.0	602.71	700.0		
Cement	kg/m ³	408.0	518.31	659.0		
Silica fume	kg/m ³	0.0	24.57	59.0		
Water	kg/m ³	160.0	164.74	168.0		
Plasticizer	kg/m ³	2.2	2.73	3.3		
High-range water-reducing	kg/m ³	6.7	9.30	14.5		
Entrapped air content	%	1.3	1.82	2.5		
Age of testing	Days	1.0	18.81	56.0		
Concrete compressive strength	MPa	21.2	67.11	113.7		
<i>Dataset 3 – Hong Kong</i>						
Fly ash replacement ratio	%	0.0	25.00	55.0	Input	
Silica fume replacement ratio	%	0.0	1.88	5.0		
Total cementitious material	kg/m ³	400.0	436.67	500.0		
Fine aggregate	kg/m ³	536.0	639.38	724.0		
Coarse aggregate	kg/m ³	1086.0	1125.00	1157.0		
Water content	lit/m ³	150.0	171.98	205.0		
High rate water reducing agent	lit/m ³	0.0	4.87	13.0		
Age of samples	Days	3.0	60.67	180.0		
Concrete compressive strength	MPa	7.8	56.63	107.8		
<i>Dataset 4 – South Korea</i>						
Water to binder ratio	%	30.0	37.60	45.0	Input	
Water content	kg/m ³	160.0	170.00	180.0		
Fine aggregate	%	37.0	46.00	53.0		
Fly ash	%	0.0	10.10	20.0		
Air entraining ratio	kg/m ³	0.04	0.05	0.08		
Supper-plasticizer	kg/m ³	1.89	4.48	8.5		
Concrete compressive strength	MPa	38.0	52.68	74.0		
<i>Dataset 5 – Iran</i>						
Cement	kg/m ³	320.0	357.4	400.0		Input
Coarse aggregate	kg/m ³	765.0	881.3	954.0		
Fine aggregate	kg/m ³	796.0	884.7	1017.5		
Water	kg/m ³	140.0	173.0	200.0		
Metakaolin	kg/m ³	0.0	42.0	80.0		
Age of testing	Days	7.0	76.3	180.0		
Concrete compressive strength	MPa	19.0	49.3	82.5		

Για κάθε σύνολο δεδομένων από τις χώρες που επιλέχθηκαν, οι μελετητές αρχικά χρησιμοποίησαν μεμονωμένα τον κάθε αλγόριθμο και στη συνέχεια με βάση τις παραπάνω μεθόδους συνδυασμού έλεγξαν τους συνδυασμένους αλγορίθμους που προέκυψαν. Τα αποτελέσματα που προέκυψαν από την δοκιμή των μεμονωμένων αλγορίθμων είναι ότι το μικρότερο ποσοστό σφάλματος στα σύνολα δεδομένων Ταϊβάν, Νότια Κορέα και Χιλή, Χόνγκ Κόνγκ είχαν το SVM και MLP αντίστοιχα, ενώ στο σύνολο δεδομένων του Ιράν καλύτερα λειτούργησε το CART, όπως φαίνεται και στον Πίνακα 8.

Πίνακας 8: Πρόβλεψη απόδοσης των μεμονωμένων μεθόδων (Chou et al., 2014)

Dataset	ML technique	MAE (MPa)	RMSE (MPa)	MAPE (%)	SI
<i>Dataset 1 – Taiwan</i>					
	MLP	6.19	7.95	20.84	0.54
	CART	5.86	7.84	20.66	0.50
	SVM	3.75	5.59	12.03	0.00
	LR	7.87	10.11	29.89	1.00
<i>Dataset 2 – Chile</i>					
	MLP	4.00	5.40	6.81	0.00
	CART	4.29	5.72	7.35	0.04
	SVM	8.02	10.32	16.95	0.61
	LR	11.38	13.49	21.87	1.00
<i>Dataset 3 – Hong Kong</i>					
	MLP	4.28	5.81	10.51	0.00
	CART	7.29	9.28	16.31	0.56
	SVM	5.34	6.62	13.26	0.19
	LR	9.56	11.04	23.91	1.00
<i>Dataset 4 – South Korea</i>					
	MLP	1.43	1.90	11.34	0.47
	CART	1.86	2.58	3.22	0.68
	SVM	1.31	1.73	2.95	0.00
	LR	1.72	2.20	3.41	0.45
<i>Dataset 5 – Iran</i>					
	MLP	6.08	7.87	14.16	0.27
	CART	5.42	7.11	12.55	0.00
	SVM	7.73	10.10	18.83	1.00
	LR	6.47	7.86	15.68	0.40

Όσον αναφορά τα αποτελέσματα των συνδυαστικών μεθόδων, για τα δεδομένα των χωρών Ταϊβάν και Νότια Κορέα η μέθοδος stacking λειτούργησε πιο καλά με το συνδυασμό CART+SVM+LR. Επίσης, η μέθοδος stacking λειτούργησε εξίσου καλά και στα δεδομένα του Χόνγκ Κόνγκ με τον συνδυασμό MLP+SVM+LR. Για τα σύνολα δεδομένων της Χιλής και του Ιράν πιο αποτελεσματικές είναι οι μέθοδοι bagging και votting αντίστοιχα. Τα αποτελέσματα αυτά συνοψίζονται στον Πίνακα 9.

Πίνακας 9: Σύγκριση των καλύτερων μεμονωμένων και συνδυασμένων μεθόδων (Chou et al., 2014)

Dataset	Predictive technique	MAE (MPa)	RMSE (MPa)	MAPE (%)
Dataset 1 (Taiwan)	SVM	3.75	5.59	12.03
	CART+SVM+LR (stacking)	3.52	5.08	11.97
Dataset 2 (Chile)	MLP	4.00	5.40	6.81
	CART (bagging)	3.82	5.13	6.50
Dataset 3 (Hong Kong)	MLP	4.28	5.81	10.51
	MLP+SVM+LR (stacking)	4.70	6.02	11.75
Dataset 4 (South Korea)	SVM	1.31	1.73	2.95
	CART+SVM+LR (stacking)	1.09	1.51	2.11
Dataset 5 (Iran)	CART	5.42	7.11	12.55
	MLP+CART+LR (voting)	4.06	5.61	9.87

Ως γενικά συμπεράσματα που παρατηρήθηκαν από τους μελετητές είναι ότι οι συνδυαστικοί μέθοδοι ξεπέρασαν την πρόβλεψη της θλιπτικής αντοχής σε σχέση με τους αλγόριθμους ξεχωριστά. Παρόλα αυτά η επιλογή των μεμονωμένων αλγορίθμων χρειάζεται να γίνει προσεκτικά για την δημιουργία του καλύτερου δυνατού μοντέλου. Οι αλγόριθμοι αυτοί θα μπορούν να συμβάλλουν στην εξαγωγή αποτελεσμάτων για την θλιπτική αντοχή διαφόρων δοκιμίων, τα οποία είναι κατασκευασμένα με διαφορετική σύνθεση το καθένα. Έτσι η εξαγωγή της θλιπτικής αντοχής τους, δεν θα καθιστά απαραίτητη την δημιουργία και την πειραματική μελέτη τους στο εργαστήριο. Τέλος, η εφαρμογή τέτοιων αλγορίθμων θα συμβάλλουν στην ταχύτερη ανάπτυξη σκυροδέματος με επιθυμητές ιδιότητες.

3.3.2 Μελέτη περίπτωσης 2: Προβλέψεις σύνθεσης και ιδιοτήτων μέσω της κατάταξης στοιχείων

Όσον αφορά τους Vakharia και Gujar (2019), πραγματοποίησαν πειράματα τα οποία αφορούν την πρόβλεψη της θλιπτικής αντοχής σκυροδέματος υψηλής αντοχής (HPC), της θλιπτικής αντοχής σκυροδέματος μέσω της κάθισης (slump test) και της σύνθεσης του τσιμέντου Portland. Στο πείραμα αυτό προσπάθησαν με την βοήθεια της μεθόδου κατάταξης χαρακτηριστικών να βελτιώσουν τις δυνατότητες πρόβλεψης των αλγορίθμων. Ο λόγος εφαρμογής αυτής της μεθόδου, σύμφωνα με τους μελετητές, γίνεται για να αφαιρεθούν οι περιττές πληροφορίες που παρέχονται, οι οποίες μειώνουν τις δυνατότητες των μοντέλων για ακριβή πρόβλεψη. Οι μελετητές στο παρόν πείραμα έκαναν χρήση τεσσάρων μεθόδων μηχανικής μάθησης:

- Isotonic Regression
- Random Forest
- Support Vector Machine (SVM)

- Multilayer Perception (MLP) neural network

Οι παραπάνω αλγόριθμοι παρουσιάζονται στο κεφάλαιο 2.

Επίσης, η επιλογή του Support Vector Machine (SVM) και του Random Forest έγινε με σκοπό την εύρεση καλύτερων αποτελεσμάτων με την χρήση των μεθόδων κατάταξης χαρακτηριστικών. Η εκπαίδευση όλων των μεθόδων που χρησιμοποιήσαν οι μελετητές έγινε με δέκα φορές διασταυρούμενη επικύρωση. Επιπλέον, για την εύρεση των σφαλμάτων έγινε χρήση ορισμένων τύπων από αυτούς που έχουν αναφερθεί στο κεφάλαιο 2.2.3.

Οι μελετητές χρησιμοποίησαν δεδομένα από τα οποία αυτά για την θλιπτική αντοχή του σκυροδέματος (Πίνακας 10) και την θλιπτική αντοχή μέσω της κάθισης (slump test) του (Πίνακας 11) λήφθηκαν από το πανεπιστήμιο της Καλιφόρνιας (UCI), ενώ για την σύνθεση του τσιμέντου Portland τα δεδομένα λήφθηκαν από το εργαστήριο τους (Πίνακας 12). Τα χαρακτηριστικά τους φαίνονται στους παρακάτω πίνακες.

Πίνακας 10: Το φάσμα των συστατικών των δοκιμών του σκυροδέματος (Vakharia και Gujar, 2019)

Concrete Components	Maximum	Minimum	Mean	Std Deviation
Cement	540.0	102.0	281.2	104.50
Blast Furnace Slag	359.4	0.0	73.9	86.27
Fly Ash	200.1	0.0	54.2	63.99
Water	247.0	121.8	181.6	21.35
Superplasticizer	32.2	0.0	6.2	5.97
Coarse Aggregate	1145.0	801.0	972.9	77.75
Fine Aggregate	992.6	594.0	773.6	80.17
Age (day)	365.0	1.0	45.7	63.16
Concrete compressive strength (MPa)	82.6	2.3	35.8	16.70

Πίνακας 11: Το φάσμα των συστατικών των δοκιμών για την κάθιση του σκυροδέματος (Vakharia και Gujar, 2019)

Slump Components	Maximum	Minimum	Mean	Std Deviation
Cement	374	137	229.89	78.87
Slag	193	0	77.97	60.46
Fly ash	260	0	149.01	85.41
Water	240	160	197.16	20.20
SP	19	4.4	8.53	2.80
Coarse Aggr.	1049.9	708	883.97	88.39
Fine Aggr.	902	640.6	739.60	63.34
Compressive Strength (Mpa)	58.53	17.19	36.03	7.83

Πίνακας 12: Το φάσμα των δεδομένων του τσιμέντου Portland (Vakharia και Gujar, 2019)

Portland cement component	Maximum	Minimum	Mean	Std Deviation
Mixing Time	595	74	249.36	124.71
Cohesion	28	4	17.75	5.85
Cohesion	35	11	24.74	5.91
Set Time	952	118	399.0	199.55
Wet Track Abrasion loss	799	311	507.23	123.27
Ordinary Portland Cement	4	0	2.15	1.24

Στη συνέχεια, οι μελετητές εφαρμόζοντας την λειτουργία της κατάταξης στοιχείων (feature ranking) δίνουν την δυνατότητα στους αλγορίθμους να αφαιρέσουν τα περιττά στοιχεία. Επίσης, για να δείξουν την αποτελεσματικότητα αυτής της μεθόδου έκαναν σύγκριση με τα δεδομένα που εμφάνιζαν οι αλγόριθμοι χωρίς την λειτουργία αυτή και με την βοήθεια ορισμένων σφαλμάτων, τα οποία είναι ο συντελεστής συσχέτισης, το Kendall's Tau, το απόλυτο μέσο σφάλμα (MAE) και το μέσο τετραγωνικό σφάλμα (MSE), που αναφέρονται αναλυτικά στο κεφάλαιο 2.2.3.

Για την πρόβλεψη της θλιπτικής αντοχής του HPC οι αλγόριθμοι ως δεδομένα εισόδου χρησιμοποίησαν τα στοιχεία του πάνω μέρος του Πίνακα 13, ενώ στο κάτω μέρος φαίνεται ο αριθμός των στοιχείων που χρησιμοποίησαν μετά την εφαρμογή της κατάταξης στοιχείων.

Πίνακας 13: Στοιχεία για την πρόβλεψη της θλιπτικής αντοχής σκυροδέματος (Vakharia και Gujar, 2019)

S.No.	Ranked feature	Ranking method
1	Age (day)	ReliefF
2	Water	
3	Cement	
4	Superplasticizer	
5	Fly Ash	
6	Blast Furnace Slag	
7	Fine Aggregate	
8	Coarse Aggregate	

Isotonic Regression	ANN	SVM	Random Forest
One	Seven	Six	Seven

Αντίστοιχα, ακολουθήθηκε η ίδια διαδικασία και στους υπόλοιπους πίνακες. Για την κάθιση χρησιμοποιήθηκαν τα δεδομένα που φαίνονται στον Πίνακα 14, ενώ για την σύνθεση του τσιμέντου Portland έγινε χρήση των δεδομένων που αναφέρονται στον Πίνακα 15.

Πίνακας 14: Στοιχεία για την πρόβλεψη της θλιπτικής αντοχής μέσω της κάθισης (slump test) (Vakharia και Gujar, 2019)

S.No.	Ranked feature	Ranking method
1	Fly ash	RelieFF
2	Cement	
3	Slag	
4	Water	
5	Coarse Aggregate	
6	Fine Aggregate	

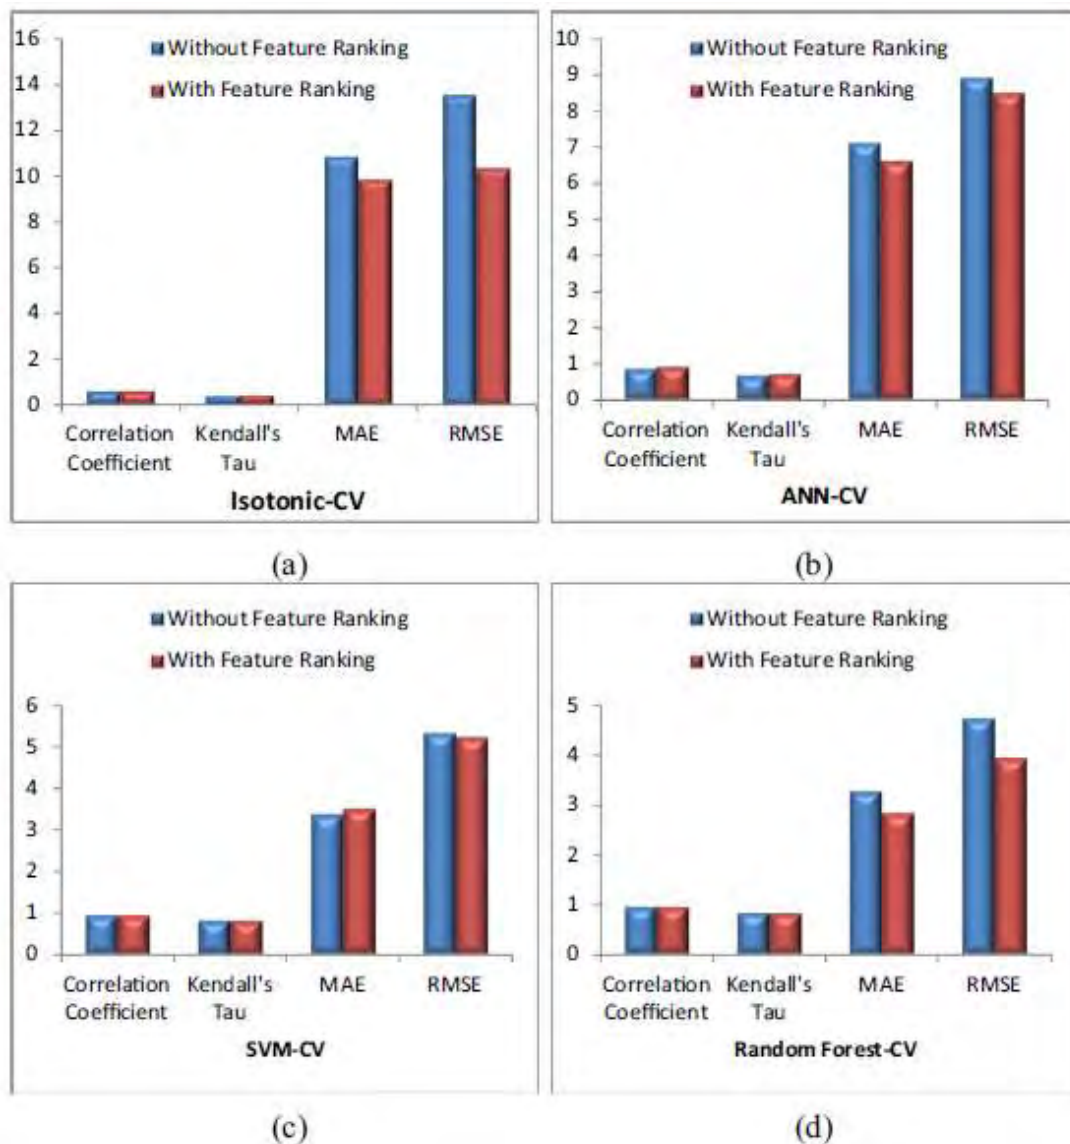
Isotonic Regression	ANN	SVM	Random Forest
Two	Five	Five	Four

Πίνακας 15: Στοιχεία για την πρόβλεψη σύνθεσης του τσιμέντου Portland (Vakharia και Gujar, 2019)

S.No.	Ranked feature	Ranking method
1	Wet Track Abrasion loss	RelieFF
2	Mixing Time	
3	Set Time	
4	Cohesion	
5	Cohesion	

Isotonic Regression	ANN	SVM	Random Forest
Two	Four	Three	Four

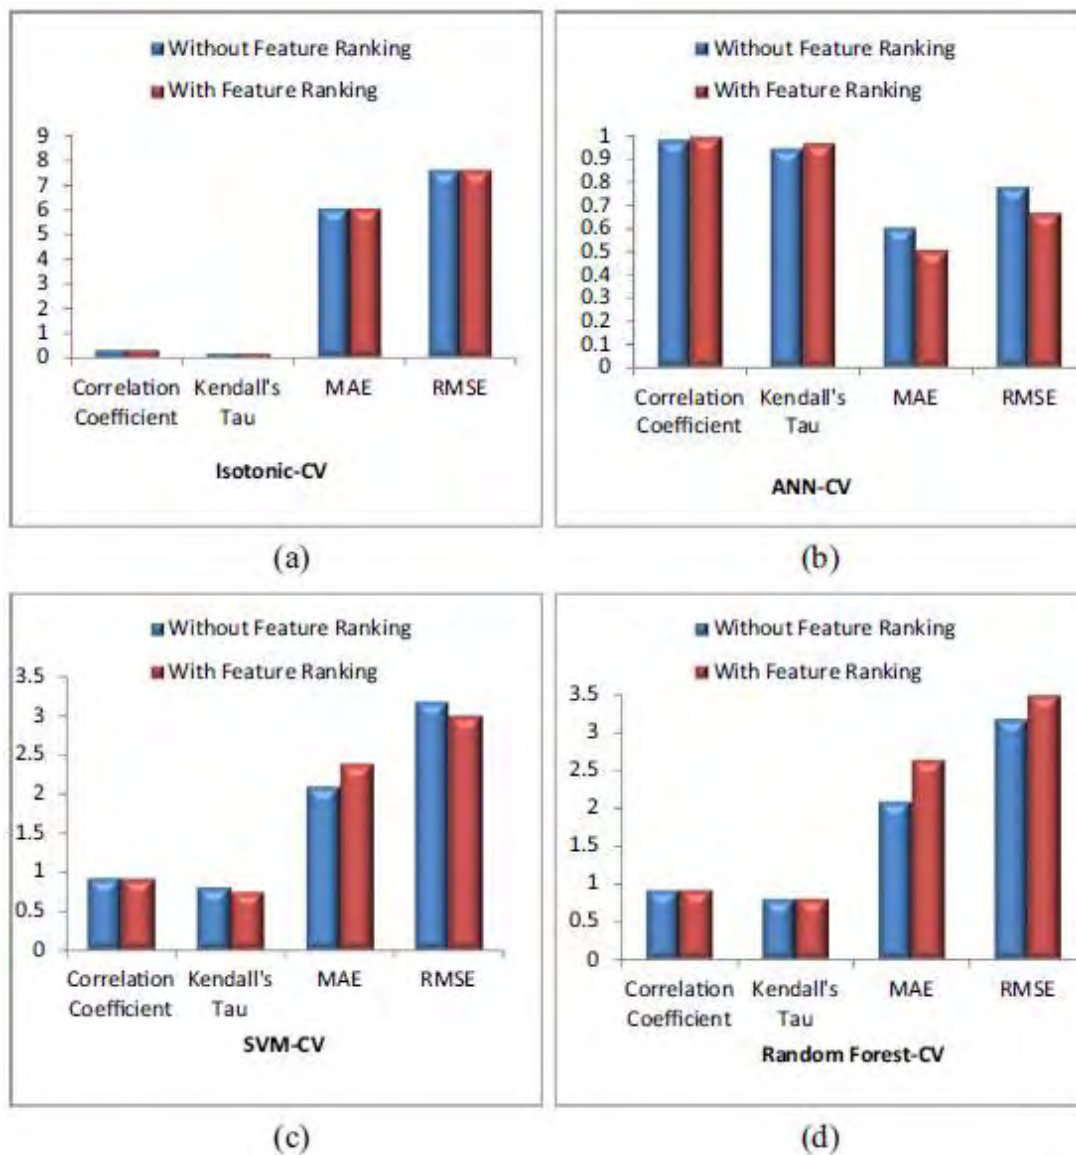
Τα αποτελέσματα που προέκυψαν για την πρόβλεψη της θλιπτικής αντοχής παρουσιάζονται στο Σχήμα 32.



Σχήμα 32: Προβλεπόμενα αποτελέσματα για την θλιπτική αντοχή (Vakharia και Gujar, 2019)

Από τα διαγράμματα παρατηρείται ότι οι τιμές των σφαλμάτων MAE και RMSE εμφανίζουν χαμηλότερη τιμή, άρα και καλύτερη ακρίβεια, με την χρήση της μεθόδου κατάταξης στοιχείων. Επίσης, το Random Forest εξάγει ακριβέστερα αποτελέσματα σε σχέση με τα υπόλοιπα εξεταζόμενα μοντέλα.

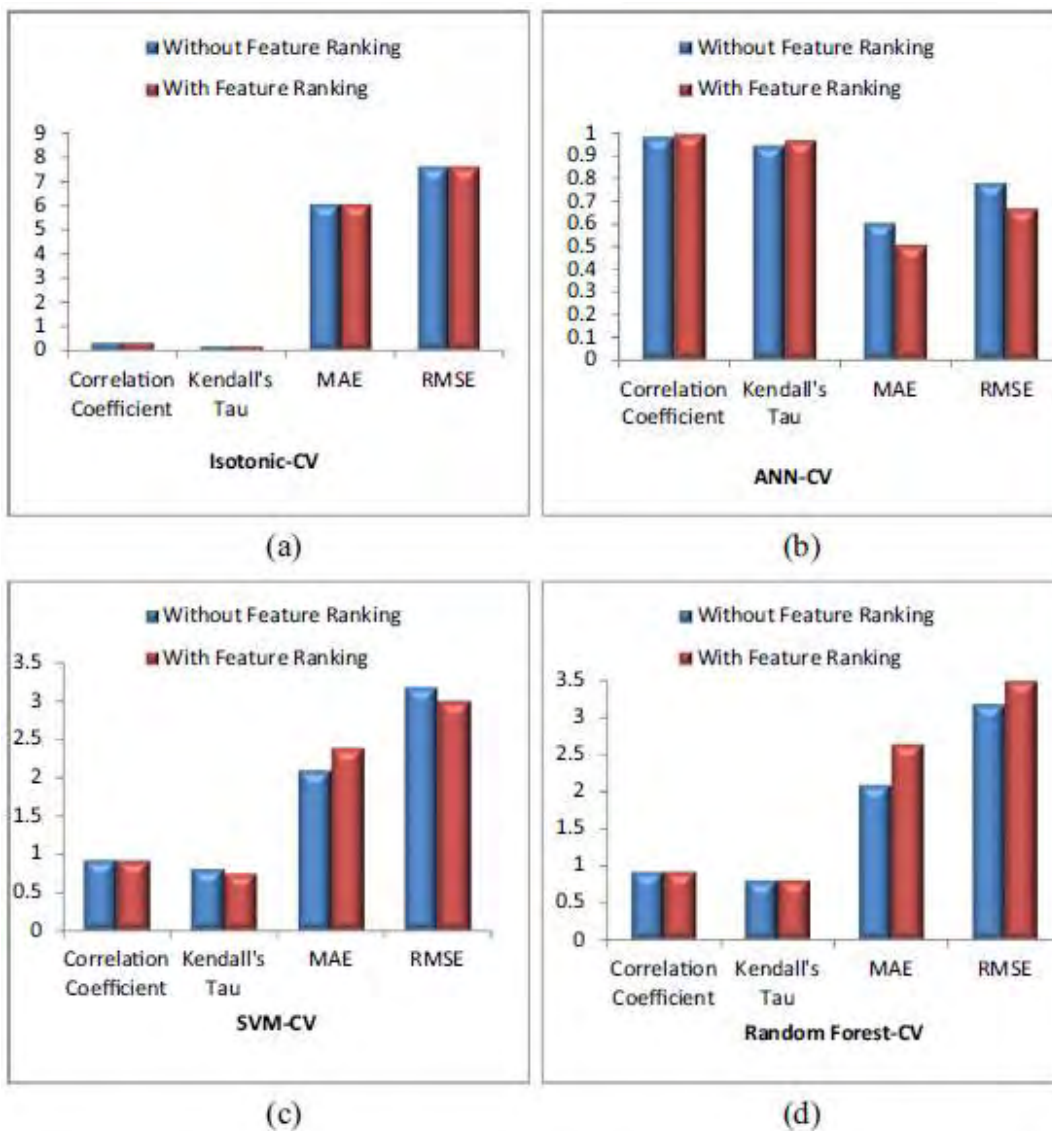
Για την πρόβλεψη της θλιπτικής αντοχής μέσω της κάθισης (slump test) του σκυροδέματος τα αποτελέσματα παρουσιάζονται στο Σχήμα 33.



Σχήμα 33: Προβλεπόμενα αποτελέσματα για την θλιπτική αντοχή μέσω κάθισης (*slump test*) (Vakharia και Gujar, 2019)

Σύμφωνα με τα διαγράμματα, το ANN εμφανίζει καλύτερα αποτελέσματα με την χρήση της κατάταξης στοιχείων, όπως φαίνεται και στις τιμές των MAE και RMSE που είναι χαμηλότερη. Επιπλέον, το ANN είναι καταλληλότερη μέθοδος σε σχέση με τις υπόλοιπες όταν έχουμε ως δεδομένα την κάθιση (*slump test*).

Όσον αφορά την σύνθεση του τσιμέντου Portland τα αποτελέσματα του φαίνονται στο Σχήμα 34.



Σχήμα 34: Προβλεπόμενα αποτελέσματα της σύνθεσης του τσιμέντου Portland (Vakharia και Gujar, 2019)

Το ANN είναι καλύτερο σε σχέση με τα άλλα μοντέλα όταν εφαρμόζεται η κατάταξη στοιχείων, όπως δείχνουν τα διαγράμματα. Αυτό αποδεικνύεται από τον συντελεστή συσχέτισης και το Kendall's Tau που έχουν μεγαλύτερη τιμή και ταυτόχρονα από τις τιμές των MAE και RMSE που είναι χαμηλότερες.

Συνοψίζοντας, και στα τρία πειράματα που πραγματοποιήθηκαν η εφαρμογή της λειτουργίας της κατάταξης στοιχείων βοηθάει τους αλγορίθμους να λειτουργήσουν με περισσότερη ακρίβεια και αποτελεσματικότητα ως προς την πρόβλεψη του σκυροδέματος. Η εξαγωγή των αποτελεσμάτων στα παραπάνω πειράματα θα μπορεί να γίνει με την χρήση μεθόδων μηχανικής μάθησης, χωρίς την διάθεση χρημάτων για

την δημιουργία δοκιμίων και την αναμονή που χρειάζονται ώστε να πραγματοποιηθούν τα πειράματα.

3.4 Ενεργειακή σχεδίαση κατασκευών

Μια άλλη κατηγορία εφαρμογής της τεχνητής νοημοσύνης στον κλάδο του πολιτικού μηχανικού είναι η καλύτερη ενεργειακή σχεδίαση των κτηρίων, η οποία έστρεψε το ενδιαφέρον των μελετητών στην έρευνα και στην πρόβλεψη της κατανάλωσης ενέργειας. Σύμφωνα με διάφορες έρευνες που έχουν πραγματοποιηθεί, ο οικοδομικός τομέας παρουσιάζεται ως ένας από τους κύριους παράγοντες κατανάλωσης ενέργειας. Αυτό καθιστά αναγκαία την καλύτερη ενεργειακή απόδοση των κτηρίων με την μείωση της ενεργειακής κατανάλωσης τους, η οποία μπορεί να επιτευχθεί μέσω διαφόρων ερευνητικών προσπαθειών που ταξινομούνται σε μερικές κατηγορίες. Τέτοιες είναι:

- η βελτίωση της αποδοτικότητας των συσκευών
- η αύξηση της χρήσης ανανεώσιμων πηγών ενέργειας
- η αυτοματοποίηση του ελέγχου των κτηρίων για την βελτίωση της λειτουργίας τους

Επιπλέον, λόγω της κλιματικής αλλαγής οι μηχανικοί και οι αρχιτέκτονες προσπαθούν να πετύχουν ένα μεγαλύτερο φάσμα παραμέτρων κατά την δημιουργία των κτηρίων, όπως είναι η αύξηση του κύκλου ζωής τους, η βιωσιμότητα τους και η ενεργειακή απόδοσή τους.

Για την βελτίωση της ενεργειακής αποδοτικότητας πραγματοποιούνται πολλά πειράματα, στα οποία γίνεται χρήση διαφόρων αλγορίθμων και υλικών. Οι Amasyali και El-Gohary (2017) θέλοντας να εξετάσουν τον τομέα του Deep Learning, και πιο συγκεκριμένα κάνοντας χρήση του αλγορίθμου Deep Neural Network (DNN), έκαναν σύγκριση με άλλους αλγόριθμους και του προγράμματος EnergyPlus για τον έλεγχο της αποδοτικότητας σε ένα προσομοίωμα ενός κτηρίου, και στη συνέχεια έγινε εφαρμογή του για την πρόβλεψη της ενεργειακής κατανάλωσης στο ίδιο προσομοίωμα σε συνθήκες από πέντε διαφορετικές τοποθεσίες. Οι Khairulzaman και Usman (2018) στην έρευνα τους έφτιαξαν μια αυτοματοποιημένη διαδικασία, με σκοπό την βέλτιστη ενεργειακή λειτουργία ενός κτηρίου. Με την βοήθεια των μοντέλων δομικών πληροφοριών (Building Information Modelling – BIM), της τεχνητής νοημοσύνης και του προγράμματος MyCrest δημιούργησαν μια ακολουθία κατά την οποία το μοντέλο

BIM ελέγχεται από το MyCrest, ως προς την ενεργειακή του κατανάλωση, και αν τα αποτελέσματα δεν είναι αποδεκτά το μοντέλο BIM μέσω της τεχνητής νοημοσύνης και της βάσης δεδομένων επιδέχεται τις απαραίτητες τροποποιήσεις. Οι Ekici και Aksoy (2009) κάνοντας χρήση του τεχνητού νευρωνικού δικτύου πραγματοποίησαν ένα πείραμα για τον υπολογισμό των ενεργειακών αναγκών 3 διαφορετικών κτηρίων, ως προς την δομή, και την εύρεση της καλύτερης δομής με βάση την αποδοτικότητα του αλγόριθμου.

Παρακάτω παρουσιάζονται αναλυτικότερα τα παραδείγματα των Amasyali και El-Gohary (2017) και Ekici και Aksoy (2009) ως προς την μεθοδολογία που ακολουθήθηκε και τα συμπεράσματα που προέκυψαν.

3.4.1 Μελέτη περίπτωσης 1: Πρόβλεψη ενεργειακής κατανάλωσης κτηρίου με την χρήση της μεθόδου βαθιάς μάθησης (Deep Learning)


Στο πείραμα αυτό, οι Amasyali και El-Gohary (2017), έκαναν χρήση της μεθόδου βαθιάς μάθησης (Deep Learning) για την πρόβλεψη της ενεργειακής κατανάλωσης ενός κτηρίου. Ο λόγος εφαρμογής αυτής της μεθόδου ήταν για να εξετάσουν την αποτελεσματικότητα της, λόγω της έλλειψης των πειραματικών προβλέψεων στην μέθοδο αυτή και παράλληλα των πολλών μελετών που βασίζονται σε άλλες μεθόδους, όπως το SVM, το ANN και άλλους αλγόριθμους στατικής παλινδρόμησης. Οι ερευνητές στο πείραμά τους επέλεξαν να χρησιμοποιήσουν μεθόδους, που έχουν αναλυθεί αρκετά στο πεδίο αυτό και να τους συγκρίνουν με έναν αλγόριθμο βασισμένο στη μέθοδο του DL. Αυτές οι μέθοδοι είναι οι εξής:

- Deep Neural Networks (DNN)
- Random Forest
- Linear Regression
- Support Vector Machine (SVM)

Οι παραπάνω αλγόριθμοι παρουσιάζονται στο κεφάλαιο 2.

Για την εύρεση την ορθότητας των προβλέψεων από τις μεθόδους γίνεται σύγκριση με τα αποτελέσματα ενός προγράμματος προσομοίωσης ενέργειας του κτηρίου, το οποίο είναι το EnergyPlus (National Renewable Energy Laboratory - NREL). Συγκεκριμένα, το πρόγραμμα αυτό χρησιμοποιείται από μηχανικούς για να ελέγξουν την κατανάλωση ενέργειας και νερού σε ένα κτήριο.

Οι προβλέψεις των παραπάνω μεθόδων έγιναν σε ένα προσομοίωμα ενός τριώροφου γραφείου με 15 θερμικές ζώνες (Σχήμα 35). Οι διαστάσεις που δόθηκαν στο κτήριο είναι 61 m * 31.5 m * 10.98 m και ύψος κάθε ορόφου 3.66 m. Επιπλέον, ο κάθε όροφος χωρίστηκε σε δωμάτια μήκους 6.1 m και το κάθε δωμάτιο είχε διαφορετικό σύστημα θέρμανσης. Τέλος, τα εξωτερικά παράθυρα του κάθε ορόφου καταλαμβάνουν το 40% του ποσοστού των τοίχων και τα αναλυτικά δεδομένα της στέγης, των εξωτερικών και εσωτερικών τοίχων φαίνονται στον Πίνακα 16. Η σχεδίαση του κτηρίου έγινε με το πρόγραμμα SketchUp (Trimble).



Σχήμα 35: Προσομοίωμα κτηρίου (Amasyali και El-Gohary, 2017)

Πίνακας 16: Δεδομένα του κτηρίου (Amasyali και El-Gohary, 2017)

Building property	Value
Exterior wall	12.7 mm gypsum + 110 mm wall insulation + 203 mm high weight concrete + 25 mm stucco
Interior wall	G01a 19 mm gypsum board + F04 wall air space resistance + G01a 199 gypsum board
Roof	Metal decking + 210 mm roof insulation + roof membrane
Window	Clear 3 mm

Για την προσομοίωση του κτηρίου έγινε χρήση των δεδομένων του Πίνακα 17 για όλες τις μεθόδους, με ώρες λειτουργίας του χώρου από τις 8 π.μ. έως τις 6 μ.μ. για τις καθημερινές μέρες. Επίσης, για τον έλεγχο της αποτελεσματικότητας της μεθόδου DNN έγινε προσομοίωση του κτηρίου με δεδομένα πέντε διαφορετικών τοποθεσιών από τον Μάιο μέχρι τον Οκτώβριο. Το κλίμα της κάθε περιοχής φαίνεται στον Πίνακα 18.

Πίνακας 17: Χαρακτηριστικά που εμφανίζονται στο κτήριο κατά την λειτουργία (Amasyali και El-Gohary, 2017)

Operational characteristic	Value
Cooling setpoint (occupied)	24°C
Cooling setback (not occupied)	26.7°C
Occupancy	0.056511 people/m ²
Lights	10.656271 W/m ²
Equipment	7.642376 W/m ²

Πίνακας 18: Χαρακτηριστικά του κλίματος για κάθε περιοχή (Amasyali και El-Gohary, 2017)

Location	Climate type	Cooling degree days (CDD) (18.3°C Baseline)
San Francisco, CA	Warm - marine	79
Golden, CO	Cool - dry	312
Tampa, FL	Hot - humid	1954
Chicago, IL	Cool - humid	468
Sterling, VA	Mixed - humid	622

Στο σύνολο δεδομένων χρησιμοποιήθηκαν μόνο οι ώρες που λειτουργούσε το κτήριο και τα δεδομένα αποτελούνταν από 22 παραμέτρους, που σχετίζονταν με τις καιρικές συνθήκες. Έπειτα από την χρήση παλινδρόμησης για την επιλογή των χαρακτηριστικών προέκυψαν 14 παράμετροι, όπως:


- η ατμοσφαιρική πίεση (atmospheric pressure)
- η σχετική υγρασία (relative humidity)
- η ταχύτητα ανέμου (wind speed)
- κατεύθυνση ανέμου (wind direction)
- η θερμοκρασία ξηρού βολβού (dry-bulb temperature)
- η θερμοκρασία σημείου δρόσου (dew point temperature)
- η ακτινοβολία στο όριο της ατμόσφαιρας (extraterrestrial direct normal radiation)
- η άμεση κανονική ακτινοβολία (direct normal radiation)
- η διάχυτη οριζόντια ακτινοβολία (diffuse horizontal radiation)
- η άμεση κανονική φωτεινότητα (direct normal illuminance)
- η φωτεινότητα ζενίθ (zenith luminance)

- το αδιαφανές κάλυμμα ουρανού (opaque sky cover)
- το ύψος οροφής (ceiling height)
- το κατακρημνισμένο νερό (precipitable water)

Τα δεδομένα κατανάλωσης που δημιουργήθηκαν από το EnergyPlus και οι 14 παράμετροι ενσωματώθηκαν σε ένα σύνολο δεδομένων, το οποίο αποτελείται από 6435 δείγματα.

Το Deep Neural Network (DNN) είναι μια μέθοδος βασισμένη στην εμπρόσθια τροφοδότηση ενός ANN, με περισσότερα από ένα κρυφά στρώματα. Το DNN χρησιμοποιείται με μεγαλύτερη αποδοτικότητα σε εφαρμογές, όπως την ταξινόμηση εικόνων (Simonyan και Zisserman, 2014) και την αναγνώριση ομιλίας (Hinton et al., 2012).

Το DNN μοντέλο που αναπτύχθηκε από τους ερευνητές, αποτελείται από τρία κρυμμένα στρώματα που κάνουν χρήση του Bayesian νευρωνικού δικτύου και του αλγόριθμου Levenberg-Marquart (LM), ο οποίος χρησιμοποιείται για την επίλυση μη γραμμικών προβλημάτων ελάχιστων τετραγώνων. Ένα δίκτυο Bayes είναι ένα κατευθυνόμενο γράφημα, στο οποίο κάθε κόμβος επισημαίνεται με ποσοτικές πιθανοτικές πληροφορίες (Russell και Norvig, 2003). Μετά από έλεγχο των στρωμάτων με διαφορετικό αριθμό νευρώνων για τον προσδιορισμό της βέλτιστης απόδοσης, προέκυψαν 12 νευρώνες σε κάθε κρυμμένο στρώμα. Το Σχήμα 36 δείχνει την δομή του DNN. Όλοι οι μέθοδοι εκπαιδεύτηκαν με το πρόγραμμα MATLAB και της δεκαπλής διασταυρούμενης επικύρωσης, έτσι ώστε να αξιολογήσουν την αποδοτικότητά τους. Ακόμα, χρησιμοποιήθηκαν για τον προσδιορισμό των σφαλμάτων τα R^2 και CV, όπου το CV παραχωρήθηκε από την ASHRAE (American Society of Heating, Refrigerating and Air-Conditioning Engineers), και οι τύποι τους φαίνονται στο κεφάλαιο 2.2.3. Όσο πιο μικρό είναι το ποσοστό του συντελεστή συσχέτισης (CV) και όσο πιο μεγάλο του R^2 τόσο πιο παρόμοια είναι η διασπορά μεταξύ προβλεπόμενης και πραγματικής κατανάλωσης.



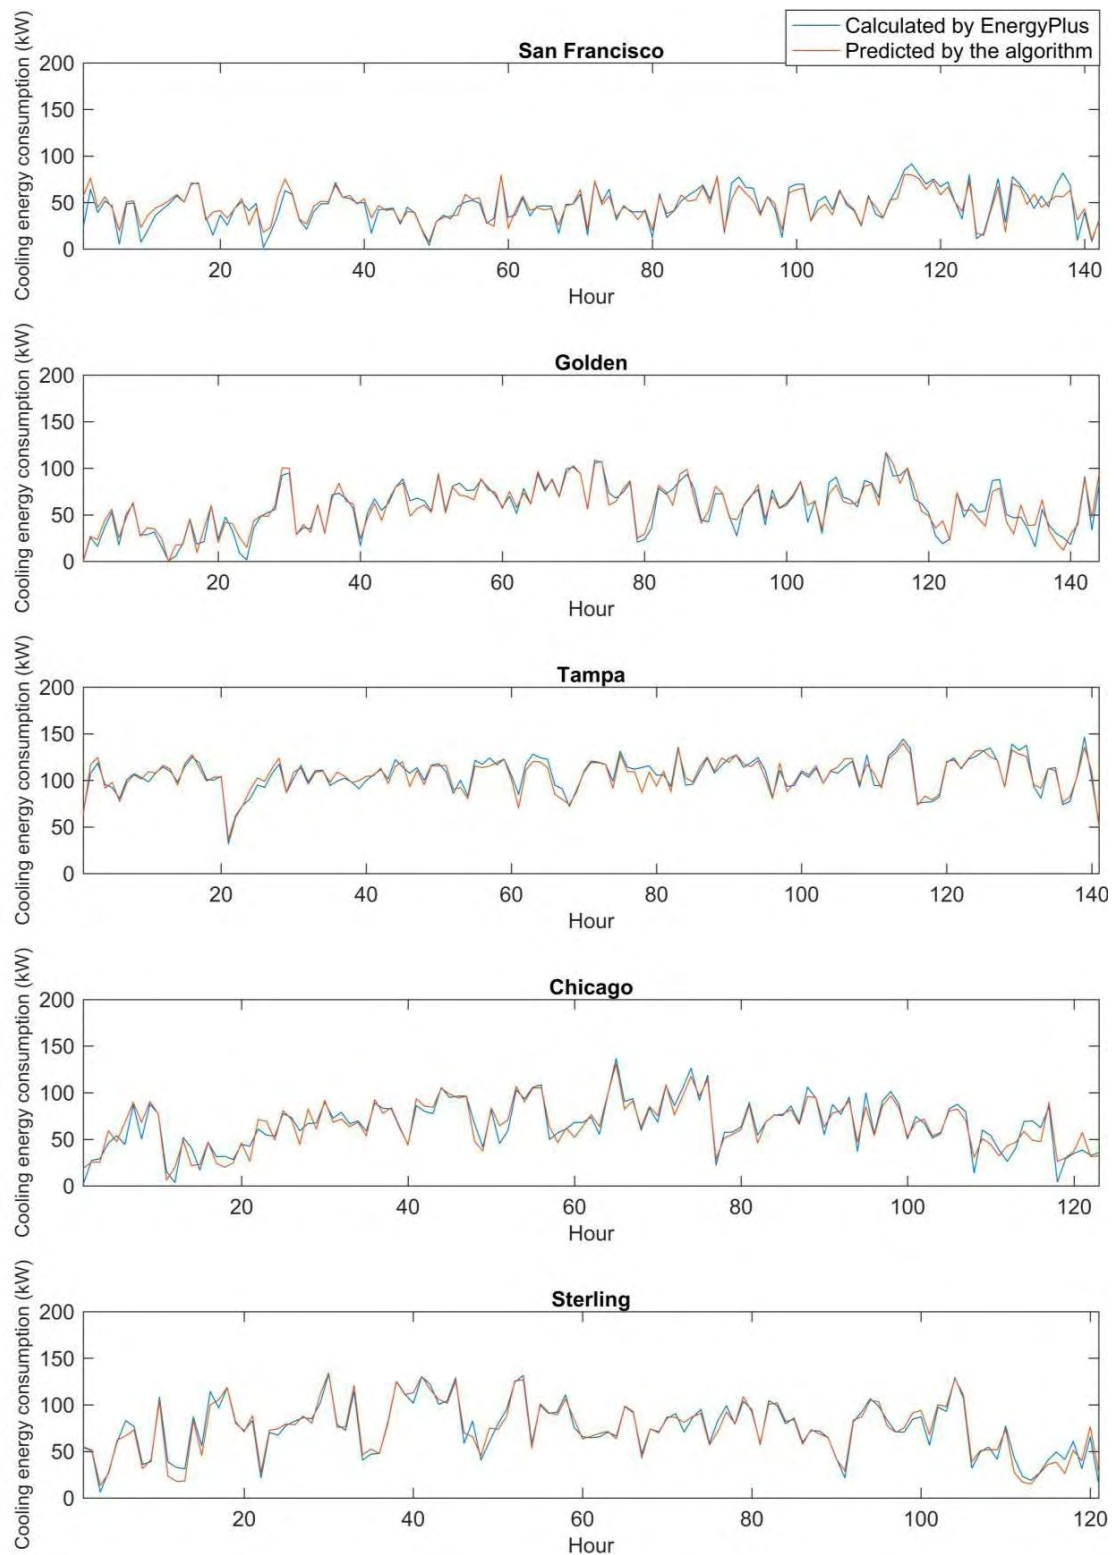
Σχήμα 36: Δομή της μεθόδου DNN (Amasyali και El-Gohary, 2017)

Όσον αφορά τα αποτελέσματα που προέκυψαν από το πείραμα φαίνονται στον Πίνακα 19 και αποτελούν συνδυαστικά αποτελέσματα και των 5 περιοχών. Το DNN έδειξε ικανοποιητικά αποτελέσματα σε σχέση με τις άλλες μεθόδους. Το SVM παρόλο που έδειξε καλύτερα αποτελέσματα από το DNN, ο χρόνος εκπαίδευσης του αλγορίθμου ήταν αρκετά μεγαλύτερος. Επίσης, το Linear Regression παρότι χρειάστηκε τον λιγότερο χρόνο εμφάνισε την χειρότερη απόδοση από όλες τις μεθόδους, αφού το σφάλμα που εμφάνισε όπως φαίνεται και στον παρακάτω πίνακα είναι αρκετά μεγάλο και πιθανότατα οφείλεται στην γραμμική συσχέτιση που λαμβάνει. Τέλος, το Random Forest παρουσίασε χειρότερα αποτελέσματα στα προβλεπόμενα δεδομένα, ενώ αντίθετα στα δεδομένα της εκπαίδευσης ήταν καλύτερα σε σχέση με το DNN με παρόμοιους χρόνους. Άρα οι μέθοδοι DNN και Random Forest είχαν μεγαλύτερη ακρίβεια και υπολογιστική αποδοτικότητα.

Πίνακας 19: Αποτελέσματα όλων των μεθόδων (Amasyali και El-Gohary, 2017)

Model	Training time	Testing dataset		Training dataset	
		CV	R ²	CV	R ²
Deep Neural Networks	13.926 s	8.88%	96.11%	8.02%	96.84%
Support Vector Machines	146.464 s	8.59%	96.36%	7.95%	96.90%
Random Forest	8.605 s	9.35%	95.69%	5.84%	98.33%
Linear Regression	1.034 s	19.99%	79.11%	18.74%	82.08%

Για τις προβλέψεις που έγιναν με τα δεδομένα των 5 τοποθεσιών, όπως φαίνεται και στο Σχήμα 37, τα αποτελέσματα του DNN είχαν αρκετά καλή εφαρμογή στα δεδομένα από το πρόγραμμα EnergyPlus. Αυτό φαίνεται από την ταύτιση σε αρκετά σημεία των προβλεπόμενων αποτελεσμάτων του αλγορίθμου με τα υπολογισμένα από το πρόγραμμα.



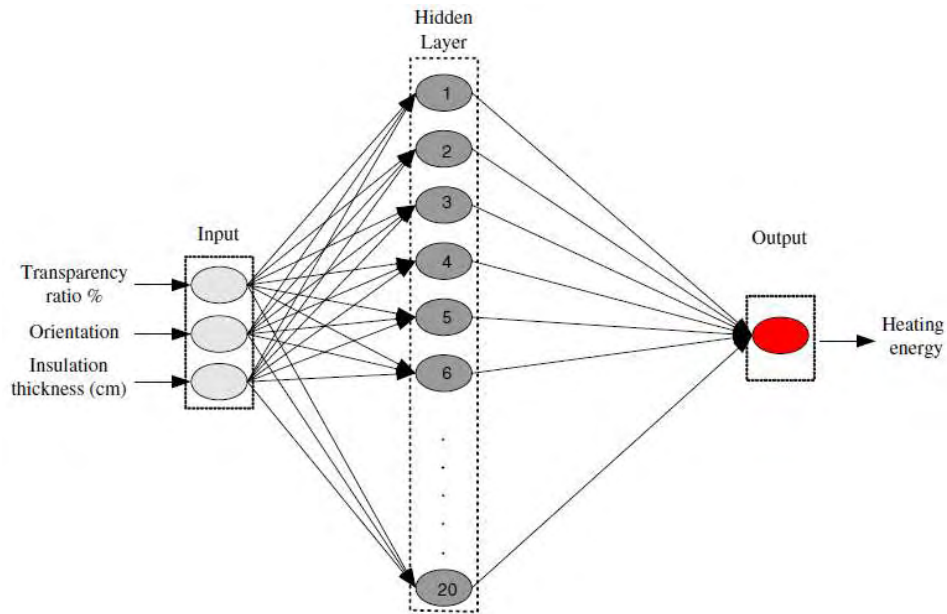
Σχήμα 37: Αποτελέσματα του DNN για κάθε περιοχή (Amasyali και El-Gohary, 2017)

Το κύριο πλεονέκτημα της μεθόδου της μηχανικής μάθησης έναντι του προγράμματος EnergyPlus, είναι η πιο αυτοματοποιημένη διαδικασία που ακολουθεί, για την πρόβλεψη της ενεργειακής αποδοτικότητας ενός κτηρίου, χωρίς την επίβλεψη και τον έλεγχο του προγράμματος από κάποιον παρατηρητή.

3.4.2 Μελέτη Περίπτωσης 2: Πρόβλεψη ενεργειακής κατανάλωσης σε κτήρια μέσω τεχνητού νευρωνικού δικτύου


Στη μελέτη αυτή, οι Ekici και Aksoy (2009), είχαν ως κύριο στόχο την πρόβλεψη των ενεργειακών αναγκών των κτηρίων με την χρήση του τεχνητού νευρωνικού δικτύου (artificial neural network) και διαφόρων παραμέτρων. Συγκεκριμένα, υπάρχουν πολλοί παράμετροι που επηρεάζουν την ενεργειακή κατανάλωση του κτηρίου και χωρίζονται σε δύο κατηγορίες. Η μια κατηγορία είναι οι εξωτερικοί παράγοντες, που αποτελούνται από τις φυσικές συνθήκες του περιβάλλοντος, όπως η θερμοκρασία, η ταχύτητα του αέρα, η ποσότητα ενεργειακής ακτινοβολίας και άλλων. Η άλλη κατηγορία είναι οι τεχνητοί παράγοντες, οι οποίοι απαρτίζονται από τα τεχνικά χαρακτηριστικά του κτηρίου, όπως είναι η αναλογία διαφάνειας (αναλογία παραθύρων-τοίχου), ο προσανατολισμός και άλλα.

Για την εκτέλεση του πειράματος έγινε χρήση ενός τεχνητού νευρωνικού δικτύου με προς τα εμπρός τροφοδότηση (feed-forward) και με εφαρμογή της οπισθοδιάδοσης. Η ανάλυση και ο τρόπος λειτουργίας του αλγορίθμου αναφέρεται εκτενέστερα στο Κεφάλαιο 2.1.3. Κατά την διάρκεια της μελέτης εξετάστηκαν διαφορετικά σύνολα κρυμμένων στρωμάτων και νευρώνων, με αποτέλεσμα να επιλεγεί το ένα στρώμα με 20 νευρώνες λόγω της καλύτερης αποτελεσματικότητάς του. Για την εύρεση των σφαλμάτων χρησιμοποιήθηκαν ορισμένα από τα σφάλματα που έχουν αναφερθεί στο κεφάλαιο 2.2.3, και πιο συγκεκριμένα ήταν το MSE. Για τον αλγόριθμο ως είσοδοι εκλαμβάνονται ορισμένοι από τις παραπάνω παραμέτρους, οι οποίοι είναι η αναλογία διαφάνειας (Transparency ratio %), ο προσανατολισμός (Orientation) και το πάχος της μόνωσης (Insulation thickness). Η δομή του πολυστρωματικού δικτύου που χρησιμοποιούν οι μελετητές απεικονίζεται στο Σχήμα 38.



Σχήμα 38: Δομή του τεχνητού νευρωνικού δικτύου (Ekici και Aksoy, 2009)

Η μελέτη πραγματοποιείται σε 3 τύπους κτηρίων, τα οποία έχουν το ίδιο εμβαδόν με διαφορετικό συντελεστή αναλογίας μήκους-πλάτους (FF 1/1, FF 1/2, FF 2/1). Τα υλικά που χρησιμοποιήθηκαν για την κατασκευή του κτηρίου, όπως σοβάς, τούβλα και άλλα, έχουν τις ίδιες ιδιότητες. Η μόνωση τοποθετήθηκε στο εξωτερικό μέρος του τοίχου (Σχήμα 39) με μεταβλητό πάχος από 0 – 15 cm και η γωνία προσανατολισμού (αζιμούθιου γωνία) του κτηρίου κυμαίνεται από 0 – 80°, όπως φαίνεται στον Πίνακα 20.

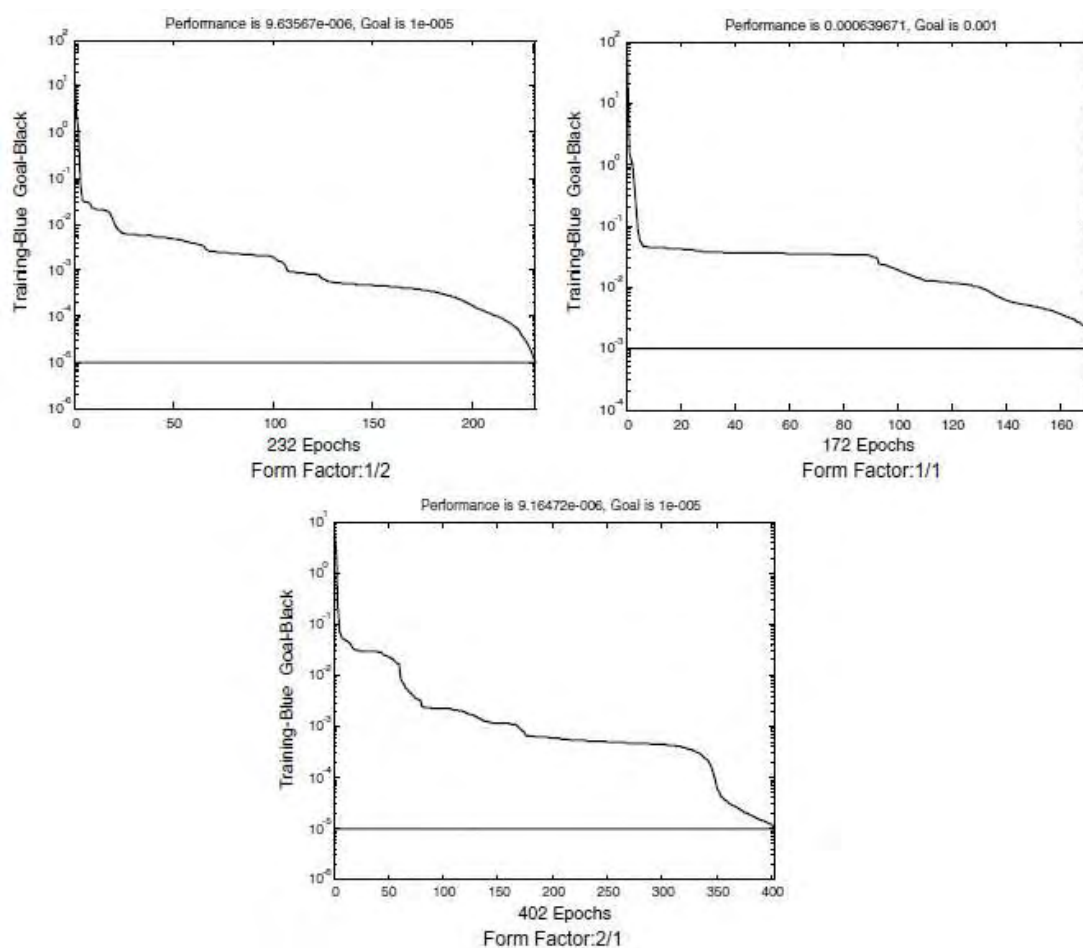


Σχήμα 39: Δομή κτηρίου και τοιχοποιίας (Ekici και Aksoy, 2009)

Πίνακας 20: Πιθανοί συνδυασμοί χαρακτηριστικών κτηρίου για εκπαίδευση και δοκιμή (Ekici και Aksoy, 2009)


Transparency ratios (%)	Insulation thickness	Building form factors		
		FF 1/2	FF 1/1	FF2/1
15	0 cm insulation	0	0	0
		10	10	10
		20	20	20
20		30	30	30
		40	40	40
		50	50	50
25		60	60	60
		70	70	70
		80	80	80
15	2.5 cm insulation	0	0	0
		10	10	10
		20	20	20
20		30	30	30
		40	40	40
		50	50	50
25		60	60	60
		70	70	70
		80	80	80
15	5 cm insulation	0	0	0
		10	10	10
		20	20	20
20		30	30	30
		40	40	40
		50	50	50
25		60	60	60
		70	70	70
		80	80	80
15	10 cm insulation	0	0	0
		10	10	10
		20	20	20
20		30	30	30
		40	40	40
		50	50	50
25		60	60	60
		70	70	70
		80	80	80
15	15 cm insulation	0	0	0
		10	10	10
		20	20	20
20		30	30	30
		40	40	40
		50	50	50
25		60	60	60
		70	70	70
		80	80	80

Όσον αφορά την εκπαίδευση του αλγορίθμου με βάση τα δεδομένα που αναφέρθηκαν, έγινε χρήση της ορολογίας epoch. Συγκεκριμένα, ένα epoch είναι ένα σύνολο πληροφοριών που μεταβιβάζεται προς τα εμπρός και προς τα πίσω μέσω του νευρωνικού δικτύου. Λόγω του μεγάλου πλήθους δεδομένων και το γεγονός ότι δεν μπορούν να μεταφερθούν όλα ταυτόχρονα στον υπολογιστή, γίνεται εφαρμογή του με σκοπό τον διαχωρισμό τους σε μικρότερα μεγέθη, την τοποθέτηση τους ένα προς ένα στο νευρωνικό δίκτυο και την ενημέρωση των βαρών. Οι μελετητές χρησιμοποίησαν διαφορετικό πλήθος epoch σε κάθε δομή κτηρίου, δηλαδή 232 για το FF 1/2, 172 για το FF 1/1 και 402 για το FF 2/1, με σκοπό να μειώσουν την καμπύλη του σφάλματος στην τιμή 10^{-3} (Σχήμα 40).



Σχήμα 40: Καμπύλες σφαλμάτων των κτηρίων κατά την εκπαίδευση (Ekici και Aksoy, 2009)

Σύμφωνα με τα αποτελέσματα που προέκυψαν οι μέσες αποκλίσεις από τις ενεργειακές ανάγκες θέρμανσης είναι 1.48%, 3.64% και 5.16% για τα κτήρια FF 1/2, FF 1/1 και FF 2/1 αντίστοιχα. Στην πραγματικότητα τα αποτελέσματα για τα ενεργειακά φορτία θα επηρεάζοντουσαν από τις κλιματολογικές συνθήκες, αλλά αυτές εξαλείφονται αφού οι μελετητές υποθέτουν ότι τα κτήρια βρίσκονται στην ίδια περιοχή. Η σύγκριση ανάμεσα στα υπολογισμένα από το πρόγραμμα (calculated) και προβλεπόμενων από το ANN (estimated) αποτελέσματα φαίνονται στο Σχήμα 41.



Σχήμα 41: Σύγκριση των υπολογισμένων από το πρόγραμμα (calculated) και προβλεπόμενων από το ANN (estimated) αποτελεσμάτων για κάθε δομή κτηρίου (Ekici και Aksoy, 2009)

Η ακρίβεια του ANN κυμαίνεται από 90 – 99% για κάθε δομή κτηρίου, με επικρατέστερο το FF 1/2 και έχοντας ποσοστό μέσης ακρίβειας 98.51%. Το ANN, σύμφωνα και με το πείραμα, έδειξε ότι αγνοώντας τους εξωτερικούς παράγοντες, εμφάνισε αξιόπιστα και γρήγορα αποτελέσματα για την ενεργειακή κατανάλωση ενός κτηρίου. Αυτό γίνεται εύκολα αντιληπτό, αφού τα αποτελέσματα του ANN ταυτίζονται σε αρκετά σημεία με τα υπολογισμένα. Τέλος, η χρήση αυτού του αλγορίθμου θα

βοηθάει στην σωστή τοποθέτηση του κτηρίου για την εύρεση της βέλτιστης ενεργειακής κατανάλωσης και θα μπορεί να πραγματοποιεί ταυτόχρονα και την βέλτιστη σχεδίαση του κτηρίου ως προς της ενεργειακές του ανάγκες.

3.5 Πυρασφάλεια (ανίχνευση – σχεδιασμός)

Ένας ακόμη κύριος κλάδος εφαρμογής της τεχνητής νοημοσύνης είναι η πυρασφάλεια του κτηρίου, ο οποίος αφορά τόσο την ανίχνευση μιας πυρκαγιάς όσο και τον σχεδιασμό των δομών για μεγαλύτερη αντοχή σε μια τέτοια κατάσταση. Η φωτιά είναι μια καταστροφική δύναμη της φύσης, της οποίας τα αποτελέσματα σε δομές ενός κτηρίου δεν έχουν αποσαφηνιστεί πλήρως. Ακόμη ένα πρόβλημα που εμφανίζεται σε καταστάσεις πυρκαγιάς, είναι ο μεγάλος αριθμός μεταβλητών και η έλλειψη καθοδήγησης ως προς την επιλογή των παραμέτρων εισόδου. Τα τελευταία χρόνια, η ανάγκη εύρεσης λύσεων στα προβλήματα του τομέα αυτού, έχει οδηγήσει στην εφαρμογή σύγχρονων, ταχύτερων και ακριβότερων μεθόδων για τον προσδιορισμό της αντίστασης στην φωτιά, καθώς επίσης και στον σχεδιασμό έξυπνων κτηρίων με χρήση διαφόρων τεχνολογιών.

Ορισμένα παραδείγματα εφαρμογής της τεχνητής νοημοσύνης για θέματα πυρασφάλειας αναφέρονται στη συνέχεια. Συγκεκριμένα, οι Lazarevska et al. (2016) πραγματοποίησαν μια προσομοίωση μελέτης αντοχής τεσσάρων διαφορετικών ειδών υποστλωμάτων σε συνθήκες πυρκαγιάς, εφαρμόζοντας ένα τεχνητό νευρωνικό δίκτυο και συγκρίνοντας τα αποτελέσματα του με αυτά του προγράμματος FIRE. Επίσης, ο Naser (2019) μέσω της μελέτης του προσπάθησε να προβλέψει την απόδοση των ιδιοτήτων της ξυλείας, ως διάφορα δομικά στοιχεία, σε κατάσταση πυρκαγιάς. Αυτό πραγματοποιήθηκε με την χρήση ενός τεχνητού νευρωνικού δικτύου σε συνδυασμό με έναν αλγόριθμο συμβολικής παλινδρόμησης και έναν γενετικό αλγόριθμο, και συγκρίθηκε με τα αποτελέσματα κανονισμών (EC5, ASCE) και άλλων μελετών. Ακόμα, οι Huang et al. (2012) πραγματοποίησαν ένα πείραμα για την προειδοποίηση πυρκαγιάς εφαρμόζοντας ένα ασύρματο δίκτυο αισθητήρων, με σκοπό την ανίχνευση της θερμοκρασίας. Τα δεδομένα των αισθητήρων αναλύονταν από έναν αλγόριθμο μηχανικής μάθησης, ο οποίος εξέπεμπε σήματα για την έγκαιρη προειδοποίηση.

Παρακάτω παρουσιάζονται αναλυτικότερα τα παραδείγματα Lazarevska et al. (2016) και Huang et al. (2012) ως προς την μεθοδολογία που ακολουθήθηκε και τα συμπεράσματα που προέκυψαν.


3.5.1 Μελέτη περίπτωσης 1: Πρόβλεψη αντοχής κεντρικών υποστυλωμάτων σε συνθήκες πυρκαγιάς

Στη μελέτη που πραγματοποίησαν οι Lazarevska et al. (2016), προσπάθησαν με την βοήθεια ενός νευρωνικού δικτύου να προσομοιάσουν την αντοχή τεσσάρων διαφορετικών υποστυλωμάτων σε κατάσταση πυρκαγιάς. Επειδή οι περισσότερες πειραματικές μέθοδοι, σχετικά με τον υπολογισμό της αντοχής σε πυρκαγιά διάφορων δομικών στοιχείων, είναι αρκετά δαπανηρές και οι αναλυτικές μέθοδοι είναι περίπλοκες και χρειάζονται χρόνο, έκαναν χρήση του νευρωνικού δικτύου λόγω της καταλληλότητάς του σε μελέτες με παλαιότερες αναλύσεις. Οι μελετητές θέλοντας να δείξουν την αποδοτικότητά του έκαναν σύγκριση των αποτελεσμάτων του με αυτά που υπολογίστηκαν από το πρόγραμμα FIRE (FIre REsponse).


Συγκεκριμένα, το πρόγραμμα FIRE είναι ένα πρόγραμμα που έχει την δυνατότητα πρόβλεψης στοιχείων οπλισμένου σκυροδέματος που υπόκειται σε φόρτιση πυρκαγιάς. Η τεχνική επίλυσης που χρησιμοποιεί το πρόγραμμα είναι μια μέθοδος πεπερασμένων στοιχείων, με την οποία αναλύει την συμπεριφορά των κεντρικών υποστυλωμάτων που εκτίθενται σε φωτιά ISO 834 (Eurocode 1, part 2.2) και οι τέσσερις πλευρές και παρουσιάζει την επιρροή των χαρακτηριστικών του υποστυλώματος, όπως η γεωμετρία, το πάχος επικάλυψης και άλλα. Στο πείραμα μέσω του προγράμματος εξετάστηκε η επίδραση της γεωμετρίας, της αξονικής φόρτισης και των διαφορετικών τύπων διατομών. Οι διαστάσεις που επιλέχθηκαν για τα δοκίμια είναι 30×30, 30×50 και 40×40 και το αξονικό φορτίο λάμβανε διαφορετικές τιμές και μέσω αυτού υπολογιζόταν ο συντελεστής φόρτισης a (Loading coefficient), που κυμαίνεται από 0.1 μέχρι 0.5 ($a = \frac{N}{N_{ult}}$ όπου N το αξονικό φορτίο που ασκείται και N_{ult} το μέγιστο αξονικό φορτίο).

Όσον αφορά τους τύπους διατομών που εξετάστηκαν, είναι το πλήρως εγκλεισμένο υποστύλωμα από χάλυβα (Concrete Filled hollow Steel section - CFS), το μερικώς εγκλεισμένο υποστύλωμα από χάλυβα (Partially Encased Steel section - PES), το υποστύλωμα με ενσωματωμένο χάλυβα (Totally Encased Steel section - TES) και το απλό υποστύλωμα οπλισμένου σκυροδέματος (Reinforced Concrete - RC), το οποίο χρησιμοποιήθηκε για σύγκριση (Σχήμα 42). Ο λόγος χρήσης του χάλυβα γίνεται για να αποτραπεί η υπερβολική σκλήρυνση του σκυροδέματος υπό συνθήκες φορτίου και πυρκαγιάς. Επιπλέον, στο Σχήμα 42 απεικονίζονται οι συνθήκες στήριξης (πάκτωση

στο κάτω μέρος και κύλιση στο επάνω) και το σημείο εφαρμογής του φορτίου (N), καθώς και το σημείο εφαρμογής της φωτιάς.



Σχήμα 42: Απεικόνιση των τύπων διατομής και οι συνθήκες στήριξης (Lazarevska et al., 2016)

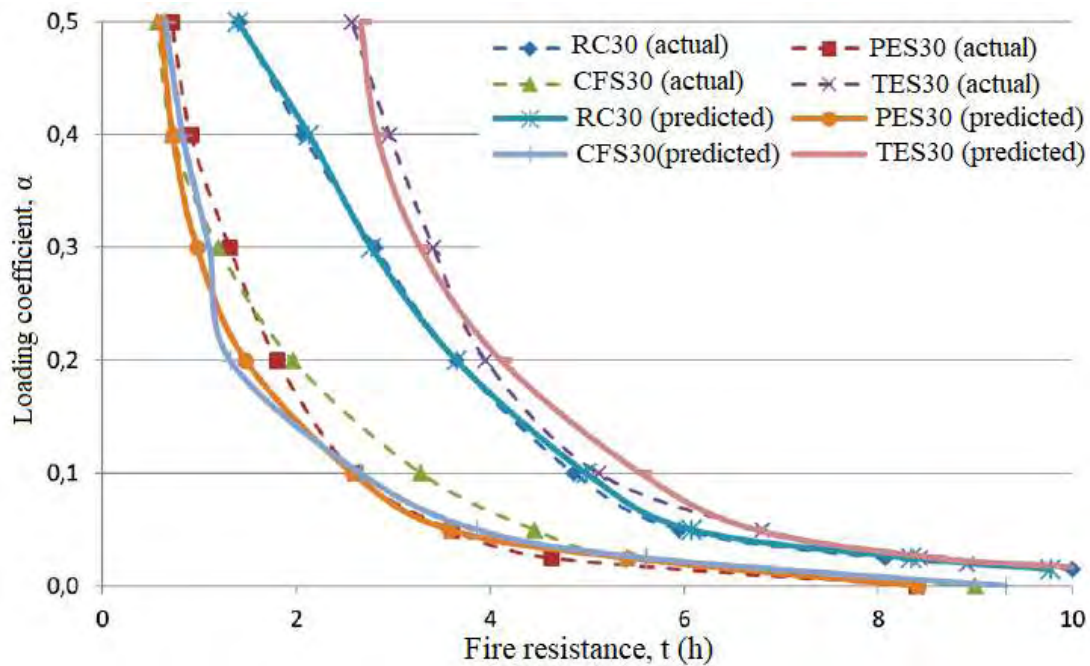


Σχήμα 43: Επίδραση του τύπου διατομής στην πυραντίσταση των δοκιμίων (Lazarevska et al., 2016)

Σύμφωνα με το πρόγραμμα FIRE το καλύτερο δοκίμιο, ως προς την αντίστασή του στην πυρκαγιά (Fire resistance), ήταν το TES30. Ο λόγος της αστοχίας των υπόλοιπων δοκιμίων είναι ότι παρόλο που ο χάλυβας αυξάνει σημαντικά την αρχική φέρουσα ικανότητα, η τοποθέτησή του περιφερειακά δίνει την δυνατότητα να θερμαίνεται σε σύντομο χρονικό διάστημα και να μειώνει τις μηχανικές ιδιότητες του (Σχήμα 43). Αυτό έχει ως αποτέλεσμα την χαμηλότερη αντίσταση σε φωτιά.

Σχετικά με το νευρωνικό δίκτυο, το οποίο δημιούργησαν οι μελετητές για την πρόβλεψη της πυραντίστασης, χρησιμοποίησαν τα αποτελέσματα που προέκυψαν από τις αριθμητικές αναλύσεις του FIRE. Τα αποτελέσματα αυτά εισήχθησαν ως δεδομένα εισόδου για την εκπαίδευση του νευρωνικού δικτύου, ώστε να παρέχει ακριβείς εξόδους για οποιαδήποτε άλλη σύνθετη κολώνα. Συγκεκριμένα, η εκπαίδευση έγινε με την χρήση 87 περιπτώσεων από τις οποίες οι 70 εφαρμόστηκαν για εκπαίδευση και οι υπόλοιπες για την δοκιμή του. Η παραπάνω διαδικασία έγινε με την βοήθεια του λογισμικού Neural Tools ver. 6 (Palisade). Η δομή του δικτύου αποτελείται από 3 επίπεδα, τα οποία είναι ένα στρώμα εισόδου, ένα κρυφό και ένα εξόδου. Το στρώμα εισόδου αποτελείται από 4 νευρώνες, έναν για κάθε ανεξάρτητη μεταβλητή, δηλαδή για τις διαστάσεις της διατομής (a, b), τον συντελεστή φόρτισης α και τον τύπο του υποστρώματος, ενώ το στρώμα εξόδου έχει μόνο έναν νευρώνα, ο οποίος είναι η πυραντίσταση της κολώνας εκφρασμένη σε λεπτά (t). Όσον αφορά το κρυφό στρώμα, οι μελετητές έκαναν δοκιμές για την εύρεση του βέλτιστου αριθμού νευρώνων με πλήθος νευρώνων από 2 έως 10. Η αξιολόγησή τους έγινε με βάση τριών παραμέτρων που είναι το ποσοστό κακών προβλέψεων (με μέγιστο όριο 30%) και τα σφάλματα RMSE και MAE, των οποίων οι τύποι φαίνονται στο κεφάλαιο 2.2.3 Το χαμηλό ποσοστό κακών προβλέψεων και η ένδειξη των χαμηλότερων σφαλμάτων σε σχέση με τα υπόλοιπα (RMSE=0.35, MAE=0.27), οδήγησε στην επιλογή του κρυφού στρώματος με 7 νευρώνες.

Στη συνέχεια, οι μελετητές έκαναν πρόβλεψη για τους 4 διαφορετικούς τύπους δοκιμίων 30×30, που έχουν αναφερθεί πιο πάνω, με την χρήση του νευρωνικού δικτύου. Με βάση τα αποτελέσματα αυτά (predicted) και του προγράμματος FIRE (actual) προέκυψε το παρακάτω συγκριτικό διάγραμμα για τις καμπύλες πυραντίστασης (Σχήμα 44).



Σχήμα 44: Συγκριτικό διάγραμμα των δοκιμών 30×30 (Lazarevska et al., 2016)

Όπως φαίνεται και από το Σχήμα 44, τα αποτελέσματα του νευρωνικού δικτύου είναι παρόμοια και σχετικά κοντά με του προγράμματος FIRE και αποδεικνύει ότι τα νευρωνικά δίκτυα είναι ένα αρκετά καλό εργαλείο για την πρόβλεψη πυραντίστασης σε κολώνες, ακόμη και σε περιπτώσεις που δεν υπάρχουν αρκετά πειραματικά ή αριθμητικά αποτελέσματα. Κύριο πλεονέκτημα της χρήσης του νευρωνικού δικτύου έναντι του προγράμματος είναι η ταχύτερη πρόβλεψη αποτελεσμάτων, λόγω του τρόπου υπολογισμού που ακολουθεί. Οι χρήσεις του αλγορίθμου μελλοντικά και έπειτα από πιθανή βελτιστοποίηση του, θα μπορέσουν να βοηθήσουν στην ανάπτυξη υποστυλωμάτων, τα οποία θα έχουν μεγαλύτερη αντοχή σε καταστάσεις πυρκαγιάς, αλλά και χωρίς την ανάπτυξη πειραματικών δοκιμών για την εξαγωγή αποτελεσμάτων.

3.5.2 Μελέτη Περίπτωσης 2: Εντοπισμός πυρκαγιάς και υπερθέρμανσης με την χρήση μηχανικής μάθησης

Οι Huang et al. (2012) στην μελέτη τους πραγματοποίησαν μια έρευνα, σε ένα υπάρχον κτήριο, στην οποία διερευνήθηκε η χρήση ασύρματων αισθητήρων και τεχνικών μηχανικής μάθησης με σκοπό τον εντοπισμό των κινδύνων πυρκαγιάς ή υπερθέρμανσης μέσα στα κτήρια. Ένας από τους κυριότερους λόγους χρήσης της μηχανικής μάθησης είναι το μεγάλο πλήθος δεδομένων που λαμβάνονται από τους αισθητήρες, το οποίο είναι πρακτικά αδύνατο να αναλυθεί από τον άνθρωπο και να

οδηγήσει στην εξαγωγή κάποιου αποτελέσματος. Για την συλλογή δεδομένων έγινε χρήση ασύρματων αισθητήρων και σε συνδυασμό με τον αλγόριθμο μηχανικής μάθησης δημιουργήθηκε ένα ασύρματο δίκτυο αισθητήρων (Wireless Sensor Network). Η διαδικασία και ο τρόπος λειτουργίας ενός τέτοιου δικτύου και των αισθητήρων αναλύονται περισσότερο στο Κεφάλαιο 3.1.

Οι μελετητές κάνοντας χρήση της γλώσσας Python ανέπτυξαν έναν αλγόριθμο μηχανικής μάθησης, με σκοπό τον εντοπισμό κινδύνων. Οι κίνδυνοι αυτοί μπορούν να θεωρηθούν ως ένας τύπος ανωμαλιών που δεν συμβαδίζουν με την φυσιολογική συμπεριφορά ενός κτηρίου και για την ανίχνευση αυτών γίνεται χρήση 3 κανόνων:


- Εκμάθηση της φυσιολογικής συμπεριφοράς από ένα πλήθος παρατηρήσεων
- Καθορισμός ενός μέτρου απόκλισης για την διάκριση μιας ανωμαλίας από την κανονική συμπεριφορά
- Δημιουργία μιας προειδοποίησης, όταν μια παρατήρηση εμφανίζει μεγάλη τιμή στο μέτρο απόκλισης.

Για τον καθορισμό των ανωμαλιών στο συγκεκριμένο πείραμα γίνεται χρήση δύο μεθόδων. Η πρώτη μέθοδος κάνει χρήση της κατανομής Gauss, η οποία θεωρείται ως υποκείμενη πιθανότητα σε εφαρμογές που περιλαμβάνουν στατιστική ανάλυση δεδομένων. Το διάστημα εμπιστοσύνης επιλέγεται συνήθως ίσο με 3σ ($3 \times$ τυπική απόκλιση), όμως στο πείραμα επιλέχθηκε ίσο με 2σ για την εύρεση πιο συντηρητικών λύσεων και με στόχο όσο το δυνατόν περισσότερων κινδύνων με ανεκτικότητα σε κάποιο πλήθος ψευδών συναγερωμών.

Η δεύτερη μέθοδος εφαρμόζει την απόκλιση Kullback-Leibler (KL), το οποίο είναι το φυσικό στατιστικό μέτρο της διαφοράς μεταξύ δυο κατανομών πιθανότητας. Στόχος της μεθόδου είναι να εξεταστεί η συσχέτιση του ενός αισθητήρα με τον άλλον, και όχι μόνο η μεμονωμένη συμπεριφορά τους. Δηλαδή, αν οι αισθητήρες εμφανίζουν την ίδια θερμοκρασία τότε χαρακτηρίζεται ως φυσιολογική συμπεριφορά, ενώ αν ένας αισθητήρας εμφανίσει μεγαλύτερη θερμοκρασία από τον άλλον τότε χαρακτηρίζεται ως ανωμαλία και εμφανίζει σήμα προειδοποίησης.

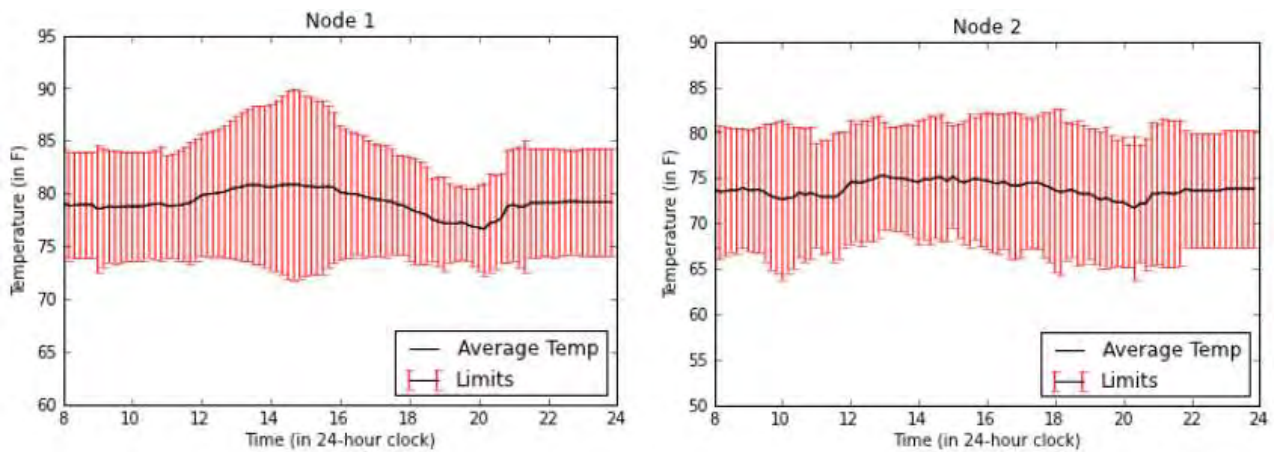
Στο πείραμα έγινε χρήση δυο αισθητήρων που λειτουργούν με την ενέργεια του φωτός και τοποθετήθηκαν σε δυο διαφορετικούς χώρους του ίδιου κτηρίου. Ο ένας (Node 1) εγκαταστάθηκε κοντά σε ένα παράθυρο, ώστε να τροφοδοτείται κυρίως από

το φως του εξωτερικού χώρου, ενώ ο άλλος (Node 2) τοποθετήθηκε σε μια αίθουσα χωρίς παράθυρο, με σκοπό την τροφοδότηση του μόνο από το φως της λάμπας (Σχήμα 45). Προτιμήθηκαν αισθητήρες τροφοδοτούμενοι από τον περιβάλλοντα φωτισμό για την μακροχρόνια λειτουργία τους, λόγω της γρήγορης εξάντλησης των μπαταριών σε λίγους μήνες.



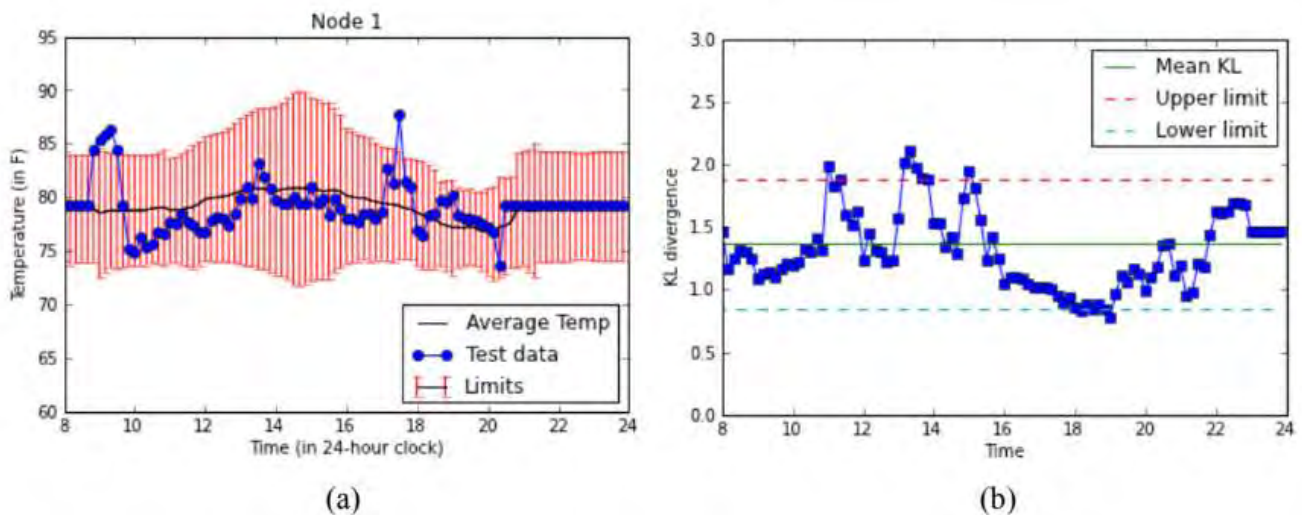
Σχήμα 45: Απεικόνιση των αισθητήρων στους χώρους τοποθέτησης τους (Huang et al. 2012)

Η διάρκεια εκτέλεσής του και συλλογής των δεδομένων ήταν 18 ημερών (από 7 Απριλίου έως 24 Απριλίου), με αποτέλεσμα ο συνολικός αριθμός δεδομένων να είναι 87106 και να δημιουργηθούν 30 τεχνητές συνθήκες υπερθέρμανσης μέσω ενός αερόθερμου. Στις πρώτες 12 ημέρες πραγματοποιήθηκε η εκπαίδευση του αλγορίθμου, ενώ στις υπόλοιπες 6 έγινε η δοκιμή του. Πριν την χρήση των δεδομένων προηγήθηκε η προεπεξεργασία τους λόγω των πιθανών θορύβων που εμφανίζονται είτε από την δυσλειτουργία του αισθητήρα είτε για διάφορους άλλους λόγους. Για την εξομάλυνση αυτών των θορύβων έγινε χρήση του κυλιόμενου μέσου όρου (moving average method) σε διάστημα 10 λεπτών. Για την εκπαίδευση του αλγορίθμου τα δεδομένα που συλλέχθηκαν από το κτήριο είναι σε κανονικές συνθήκες, με σκοπό την δημιουργία ορίων της θερμοκρασία ανάλογα με την ώρα λειτουργίας του. Τα αποτελέσματα της εκπαίδευσης φαίνονται στο παρακάτω Σχήμα 46, όπου τα όρια θερμοκρασίας που προέκυψαν απεικονίζονται με την κόκκινη διαγράμμιση και η μέση θερμοκρασία με την μαύρη συνεχόμενη γραμμή.



Σχήμα 46: Διάγραμμα θερμοκρασίας-χρόνου για τα όρια των αισθητήρων μετά την εκπαίδευση (Huang et al. 2012)

Στο διάστημα δοκιμής των 6 ημερών ο αλγόριθμος δοκιμάστηκε για την αποδοτικότητά του στην έγκαιρη προειδοποίηση για κίνδυνο πυρκαγιάς. Στο Σχήμα 47 φαίνεται η δοκιμή δυο διαφορετικών ημερών, που απεικονίζεται με την μπλε γραμμή, μια για την κάθε μέθοδο, κατά τις οποίες δημιουργήθηκαν 2 τεχνητά σήματα για την μέθοδο Gauss και 4 για την μέθοδο KL. Για την μέτρηση της αποδοτικότητας του αλγορίθμου χρησιμοποιήθηκαν 3 τυπικές μεταβλητές, οι οποίες είναι η ακρίβεια (Precision – P), ο αριθμός ευστοχιών (Recall – R) και η τιμή F που υπολογίζεται από τον τύπο $F = \frac{2P}{P+R}$. Η μεταβλητή της ακρίβειας ορίζεται ως ο λόγος των σωστών προβλέψεων ως προς τις συνολικές προβλέψεις του αλγορίθμου, ενώ η μεταβλητή του αριθμού ευστοχιών ορίζεται ως ο λόγος των σωστών προβλέψεων ως προς το σύνολο των προσομοιώσεων πυρκαγιάς που πραγματοποιήθηκαν.



Σχήμα 47: a) Διάγραμμα θερμοκρασίας-χρόνου για τα αποτελέσματα της μεθόδου Gauss την ημέρα 22 Απριλίου του αισθητήρα 1. b) Διάγραμμα δείκτη απόκλισης KL-χρόνου για τα αποτελέσματα της μεθόδου KL την ημέρα 23 Απριλίου και για τους δυο αισθητήρες (Huang et al. 2012)

Ο αλγόριθμος αποδείχθηκε αρκετά αποδοτικός στον εντοπισμό των κινδύνων κατά την διάρκεια δοκιμής του εντοπίζοντας όλες τις τεχνητές συνθήκες πυρκαγιάς. Υπήρξαν μόνο δύο λάθος προειδοποιήσεις κατά την διάρκεια της εκπαίδευσης. Ο αλγόριθμος με χρήση της μεθόδου Gauss εμφάνιζε επίπεδο εμπιστοσύνης 95%, με αποτέλεσμα να έχει πολύ μικρό ποσοστό εμφάνισης λανθασμένης προειδοποίησης σε κανονικές συνθήκες. Τα αποτελέσματα των μεταβλητών μέτρησης έδειξαν υψηλή ακρίβεια του αλγορίθμου σε περιπτώσεις ανίχνευσης κινδύνου (P=93.8%, R=100% και F=96.8%). Τέλος, με την χρήση του αλγορίθμου θα μπορεί να εμφανιστεί μια έγκαιρη ειδοποίηση, όπως το χτύπημα ενός συναγερμού, ή η πραγματοποίηση κάποιας άλλης ενέργειας από το σύστημα, σε περιπτώσεις αύξησης της θερμοκρασίας. Αυτή η λειτουργία θα έχει την δυνατότητα πρόβλεψης μιας πυρκαγιάς, έναντι των υπάρχοντων συστημάτων, τα οποία χρειάζονται ανίχνευση καπνού για να λειτουργήσουν.

Κεφάλαιο 4 Σύνοψη και σχολιασμός

Στο κεφάλαιο αυτό παρουσιάζονται συνοπτικά τα πλεονεκτήματα και τα συμπεράσματα που παρατηρούνται από τα πειράματα που αναλύθηκαν στο προηγούμενο κεφάλαιο. Επιπλέον, αναφέρουμε και τα δικά μας συμπεράσματα που διακρίναμε και κάποιες προτάσεις μας σχετικά με την ενασχόληση κάποιου με την τεχνητή νοημοσύνη.

Κεφάλαιο 4.1 Σύνοψη

Μέσα από τις παραπάνω πειραματικές μελέτες με τις οποίες ασχοληθήκαμε, εξαγάγαμε κάποια γενικά συμπεράσματα είτε μεμονωμένα είτε συγκριτικά για τις μελέτες του κάθε κεφαλαίου. Αυτά φαίνονται παρακάτω:

Όσον αφορά την παρακολούθηση της δομικής ακεραιότητας της κατασκευής, παρατηρήθηκε ότι η ανάγκη εφαρμογής των περιβαλλοντικών συνθηκών στον αλγόριθμο μηχανικής μάθησης είναι σημαντική. Παρά το γεγονός ότι στην μελέτη περίπτωσης 1, όπου έγινε εφαρμογή των περιβαλλοντικών συνθηκών, ο αλγόριθμος δεν ήταν αρκετά αποτελεσματικός, όπως αυτός στην μελέτη περίπτωσης 2 όπου δεν περιλάμβανε περιβαλλοντικούς παράγοντες, έδειξε ότι με την κατάλληλη βελτίωση θα μπορεί να προβλέπει τις βλάβες μιας τέτοιας κατασκευής. Έτσι, οι μελλοντικοί μελετητές μπορούν να στραφούν στην ανάπτυξη αλγορίθμων πρόβλεψης βλαβών με χρήση των περιβαλλοντικών συνθηκών, ώστε να είναι περισσότερο αποτελεσματικοί σε πραγματικές συνθήκες εφαρμογής. Επίσης, ορισμένα συμπεράσματα που προέκυψαν και μπορούν να λαμβάνουν υπόψιν οι μελλοντικοί μελετητές, είναι ότι οι εφαρμογές των αισθητήρων θα πρέπει να γίνεται μακριά από τις πακτώσεις της κατασκευής, αφού η κατασκευή εμφανίζει καλύτερη δυναμική απόκριση στο μέσον της. Ακόμη, η ταχύτητα της αμαξοστοιχίας δίνει καλύτερα αποτελέσματα στον αλγόριθμο όταν δεν είναι πολύ υψηλή, δηλαδή περίπου από 70 έως 90 km/h.

Η πρόβλεψη αστοχιών σε δομικά στοιχεία και η βέλτιστη δομική σχεδίαση μιας κατασκευής, παρατηρήθηκε ότι με την συμβολή της μηχανικής μάθησης επιφέρει αρκετά πλεονεκτήματα στον μηχανικό. Συγκεκριμένα, μπορεί να τον βοηθήσει στην βελτιστοποίηση ενός δομικού στοιχείου για την αποφυγή βλαβών, όπως η διάβρωση του χάλυβα. Ακόμη, έχει την δυνατότητα να αποτρέψει τον μηχανικό από λάθος επιλογές ως προς την δομή της κατασκευής. Γενικά, η εφαρμογή της μηχανικής μάθησης σε αυτή την κατηγορία μπορεί να επιφέρει αρκετά αποτελέσματα.

Για την πρόβλεψη των ιδιοτήτων του σκυροδέματος, μπορεί να σημειωθεί ότι η αποδοτικότητα της μηχανικής μάθησης είναι αρκετά μεγάλη σε αρκετές περιπτώσεις όπου μπορεί να εφαρμοστεί. Τα κύρια συμπεράσματα που μπορούν να λάβουν υπόψη μελλοντικοί μελετητές, είναι ότι η λειτουργία των συνδυαστικών αλγορίθμων έδειξε καλύτερα αποτελέσματα καθώς και η χρήση της κατάταξης στοιχείων (feature ranking) συνέβαλε αρκετά στην βελτίωση του αλγορίθμου.

Όσον αφορά την λειτουργία των αλγορίθμων στην βέλτιστη πρόβλεψη της ενεργειακής κατανάλωσης ενός κτηρίου, γίνεται αντιληπτό ότι η αποδοτικότητά της μηχανικής μάθησης είναι εξίσου καλή και σε αυτήν την κατηγορία. Συγκεκριμένα, παρατηρήθηκε ότι τα νευρωνικά δίκτυα χρησιμοποιούνται πιο συχνά, όπως φαίνεται και στις μελέτες που εξετάστηκαν, και η αυτοματοποιημένη διαδικασία τους έδειξε το ίδιο καλά αποτελέσματα με κάποιο ενεργειακό πρόγραμμα.

Η εφαρμογή της τεχνητής νοημοσύνης σε εφαρμογές πυρασφάλειας ενός κτηρίου ή κάποιου δομικού στοιχείου, παρατηρήθηκε ότι συμβάλλει σημαντικά στην πρόβλεψη κάποιας πυρκαγιάς, είτε με την χρήση νευρωνικού δικτύου είτε κάποιου άλλου αλγορίθμου μηχανικής μάθησης. Όσον αφορά την αποδοτικότητά τους στις μελέτες που παρουσιάστηκαν, έδειξαν να ανταποκρίνεται αρκετά καλά στις προβλέψεις τους με αρκετά μικρό ποσοστό αστοχίας τους.

Κεφάλαιο 4.2 Σχολιασμός

Η αποδοτικότητα των αλγορίθμων μπορεί να είναι εξίσου καλή με τα προγράμματα που έχουν δημιουργηθεί για την εκάστοτε μελέτη ή το εκάστοτε πείραμα, όμως οι αλγόριθμοι εμφανίζουν αρκετά πλεονεκτήματα σε σχέση με αυτά και γενικά με τους παραδοσιακούς τρόπους που χρησιμοποιούνται. Αρχικά, ένα σημαντικό πλεονέκτημα που εμφανίζεται κυρίως σε πειράματα είναι η εξοικονόμηση χρημάτων από τα δοκίμια που θα έπρεπε να δημιουργηθούν και από την διεξαγωγή των πειραμάτων που θα εφαρμοστούν αυτά. Συγκεκριμένα, δεν χρειάζεται η δημιουργία πολλών δοκιμίων, τα οποία αποτελούν απαραίτητη προϋπόθεση για να είναι ένα πείραμα έγκυρο και αποτελεσματικό, αφού όλη η διαδικασία δημιουργίας των δοκιμίων μπορεί να γίνει με την χρήση της μηχανικής μάθησης, όπου μπορούν να προσομοιωθούν και να χρησιμοποιείται διαφορετική σύνθεση σε κάθε δοκιμή. Ακόμη ένα πλεονέκτημα, είναι η μείωση του χρόνου για την εξαγωγή αποτελεσμάτων, τα οποία μπορεί να αφορούν κάποιο πείραμα ή κάποια μελέτη. Αυτό φαίνεται σε ορισμένα

από τα παραπάνω πειράματα, όπου ο αλγόριθμος χρειάζεται από κάποια δευτερόλεπτα έως λίγα λεπτά για την εξαγωγή του αποτελέσματος. Επίσης, αντί στον χρόνο που θα χρειαζόταν κάποιος μελετητής για την πραγματοποίηση ενός πειράματος με ένα συγκριμένο αριθμό δοκιμίων, μπορεί με την χρήση της μηχανικής μάθησης στον ίδιο χρόνο να εξετάσει μεγαλύτερο αριθμό δοκιμίων και να εξάγει καλύτερα αποτελέσματα.

Όσον αφορά την επιτήρηση στα πειράματα, είναι απαραίτητη για τυχόν λάθη και κινδύνους που μπορούν να προκύψουν όταν γίνεται η χρήση των παραδοσιακών τρόπων, ενώ για τις μεθόδους μηχανικής μάθησης δεν είναι τόσο αναγκαία από τρίτους. Επιπλέον, με την εφαρμογή των αλγορίθμων ο εξοπλισμός που χρειάζεται για την πραγματοποίηση του πειράματος είναι λιγότερος και μικρότερος σε σχέση με τον εξοπλισμό που χρησιμοποιείται όταν γίνεται χρήση παραδοσιακών μεθόδων, όπου η απαίτηση για εξοπλισμό είναι μεγαλύτερη και χρειάζεται περισσότερους οικονομικούς πόρους. Όμως, ένα σημαντικό μειονέκτημα της μηχανικής μάθησης είναι η απαίτηση πολλών δεδομένων, η οποία προκύπτει από πραγματικά πειράματα, ώστε να δημιουργηθεί μια μεγάλη και ικανοποιητική βάση δεδομένων για την εκπαίδευση και την καλύτερη απόδοσή τους.

Οι προοπτικές που παρουσιάζονται για την κατηγορία της παρακολούθησης της δομικής ακεραιότητας ενός κτηρίου και άλλων κατηγοριών που κάνουν χρήση των αισθητήρων είναι αρκετά μεγάλες. Αυτό συμβαίνει λόγω της ραγδαίας αύξησης της τεχνολογίας, όπου έχει συμβάλει στην ανάπτυξη της τεχνολογίας που αφορά τους αισθητήρες. Έτσι με αυτή την εξέλιξη και σε συνδυασμό με την μείωση του κόστους των αισθητήρων και με την πιο εύκολη λειτουργία τους, γίνονται πιο προσιτοί στην χρήση από διάφορους μηχανικούς για την εξαγωγή δεδομένων. Επίσης, η εξέλιξη των δικτύων, όπως είναι η ανάπτυξη του δικτύου 5G που προσφέρει σύνδεση πολλών συσκευών σε έναν πομπό, έχει βοηθήσει στην καλύτερη και ταχύτερη συνδεσιμότητα μεταξύ των αισθητήρων και με κάποια εξωτερική βάση δεδομένων, όπου αποστέλλονται τα δεδομένα που συλλέγει ο αισθητήρας. Όμως ένα σημαντικό μειονέκτημα που παρουσιάζεται είναι η διαχείριση των δεδομένων λόγω του μεγάλου όγκου του. Έτσι εκτός από την ανάπτυξη αλγορίθμων χρειάζεται να εστιάσουμε και στον τρόπο με τον οποίο θα γίνεται η διαχείριση των δεδομένων.

Η κατηγορία που εφαρμόζεται η τεχνητή νοημοσύνη στον τομέα του πολιτικού μηχανικού και έχει αναπτυχθεί περισσότερο είναι η ενεργειακή κατανάλωση των

κτηρίων. Όμως εξίσου σημαντικές κατηγορίες, όπως η δομική ακεραιότητα των κτηρίων, είναι αρκετά σημαντικό να αναπτυχθούν ώστε να εξελιχθούν τα συστήματα για την πρόληψη και την προστασία των κατασκευών. Για την εξέλιξη των κατηγοριών όμως είναι αναγκαία η ύπαρξη βάσης δεδομένων από προηγούμενες μελέτες που έχουν γίνει ώστε να βελτιωθεί η εκπαίδευση του αλγορίθμου. Έτσι, είναι απαραίτητο οι μελετητές μετά από την εκτέλεση ενός πειράματος να διαθέτουν τα δεδομένα που εξάγουν σε μια ανοιχτή πλατφόρμα, ώστε να είναι εύκολα προσβάσιμα σε επόμενους μελετητές.

Οι μελλοντικοί μελετητές έχουν ένα μεγάλο εύρος εφαρμογής της μηχανικής μάθησης με το οποίο θα μπορούν να ασχοληθούν. Ορισμένες από αυτές τις μελέτες, τις οποίες προτείνουμε και μπορούν στραφούν, είναι η ανάπτυξη ενός αλγορίθμου για τον καλύτερο έλεγχο των βλαβών στα δομικά στοιχεία, ώστε να γίνεται η καλύτερη πρόληψή τους και η επιδιόρθωσή τους να είναι ταχύτερη. Ακόμη, μπορούν να ασχοληθούν με την έρευνα και των σχεδιασμό 3D τυπωμένων κτηρίων. Τέλος, μια καινοτομία που μπορεί να αναπτυχθεί από τους μελετητές είναι η μελέτη κίνησης και συμπεριφοράς των εργατών σε ένα εργοτάξιο. Αυτό θα συμβάλλει στο να προβλέπει τους κινδύνους που μπορούν να προκύψουν σε περίπτωση μη τήρησης των σωστών και απαραίτητων βημάτων για την εκτέλεση μιας εργασίας.

Με την εφαρμογή της τεχνητής νοημοσύνης σε διάφορες δραστηριότητες του πολιτικού μηχανικού θα οδηγήσει στην ανάπτυξη καινούργιας ενασχόλησης στον τομέα αυτό, και συγκεκριμένα θα γίνεται πρόσληψη ατόμων που εξειδικεύονται σε τέτοιου είδους αλγορίθμους. Για παράδειγμα, μια ειδίκευση που παρατηρούμε είναι αυτή του σωστού σχεδιασμού ενός συστήματος παρακολούθησης μιας κατασκευής και της παρακολούθησης των δεδομένων που εξάγονται από αυτούς, ώστε να ελέγχεται η σωστή λειτουργία του συστήματος. Ακόμη, μπορεί να δημιουργηθεί μια νέα ειδίκευση βασισμένη στην ανάπτυξη και την εξέλιξη των αλγορίθμων στις διάφορες κατηγορίες εφαρμογής τους. Όπως γίνεται αντιληπτό, αυτές οι νέες ειδικεύσεις θα οδηγήσουν στην ανάπτυξη νέων θέσεων εργασίας στην αγορά, με αποτέλεσμα να υπάρχει και μεγαλύτερη απορρόφηση των πολιτικών μηχανικών.

Για την συναναστροφή των νέων μηχανικών με την τεχνητή νοημοσύνη καλό είναι να υπάρχουν θεωρητικά αλλά και εργαστηριακά μαθήματα στα ανώτατα εκπαιδευτικά ιδρύματα ή κάποιου είδους σεμιναρίων για τους υπάρχοντες μηχανικούς.

Αυτό θα έχει ως αποτέλεσμα, την ανάπτυξη μιας γενικής γνώσης στο θέμα αυτό. Η πρόταση μας στο θέμα αυτό είναι η ανάπτυξη ενός καινούργιου τομέα, όπως οι υπάρχον τομείς του δομοστατικού, υδραυλικού και συγκοινωνιακού, ο οποίος βασίζεται στην τεχνητή νοημοσύνη και με σκοπό την ειδίκευση πάνω σε αυτή αλλά και την βοήθεια στους υπόλοιπους τομείς. Επίσης, μια γενική πρόταση στο θέμα αυτό είναι η δημιουργία ενός μαθήματος (project) στην δευτεροβάθμια εκπαίδευση, μέσω του οποίου ο μαθητής θα έρθει σε μια πρώτη επαφή με το αντικείμενο μαθαίνοντας έτσι τις αρχικές έννοιες της τεχνητής νοημοσύνης και τον τρόπο εφαρμογής της.

Βιβλιογραφία

- Amasyali, K., & El-Gohary, N. (2017, January). Deep Learning for Building Energy Consumption Prediction. In 6th CSCE-CRC International Construction Specialty Conference 2017-Held as Part of the Canadian Society for Civil Engineering Annual Conference and General Meeting 2017 (pp. 466-474). Canadian Society for Civil Engineering.
- Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., & Adeli, H. (2018). Wireless smart sensors for monitoring the health condition of civil infrastructure. *Scientia Iranica*, 25(6), 2913-2925.
- Boukhatem, B., Kenai, S., Tagnit-Hamou, A., & Ghrici, M. (2011). Application of new information technology on concrete: an overview. *Journal of Civil Engineering and Management*, 17(2), 248-258.
- Chalouhi, E. K., Gonzalez, I., Gentile, C., & Karoumi, R. (2017, July). Vibration-Based SHM of Railway Bridges Using Machine Learning: The Influence of Temperature on the Health Prediction. In *International Conference on Experimental Vibration Analysis for Civil Engineering Structures* (pp. 200-211). Springer, Cham.
- Chou, J. S., Tsai, C. F., Pham, A. D., & Lu, Y. H. (2014). Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction and Building Materials*, 73, 771-780.
- Ekici, B. B., & Aksoy, U. T. (2009). Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software*, 40(5), 356-362.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal processing magazine*, 29(6), 82-97.
- Huang, Q., Cox, R. F., Shaurette, M., & Wang, J. (2012). Intelligent building hazard detection using wireless sensor network and machine learning techniques. In *Computing in Civil Engineering* (2012) (pp. 485-492).

- Hwang, H. J., Baek, J. W., Kim, J. Y., & Kim, C. S. (2019). Prediction of bond performance of tension lap splices using artificial neural networks. *Engineering Structures*, 198, 109535.
- Khairulzaman, H. A., & Usman, F. (2018). Automation in civil engineering design in assessing building energy efficiency. *International Journal of Engineering and Technology (UAE)*, 7(4), 722-727.
- Kudus, S. A., Bunnori, N. M., Basri, S. R., Shahiron, S., Jamil, M. N. M., & Noorsuhada, M. N. (2013). An overview current application of artificial neural network in concrete. In *Advanced Materials Research (Vol. 626, pp. 372-375)*. Trans Tech Publications.
- Lazarevska, M., Cvetkovska, M., Trombeva Gavriloska, A., Milos, K., & Milivoje, M. (2016). Neural-network-based approach for prediction of the fire resistance of centrally loaded composite columns. *Technical gazette*.
- Li, Z., & Adeli, H. (2018). Control methodologies for vibration control of smart civil and mechanical structures. *Expert Systems*, 35(6), e12354.
- Ma, L. Y., Gu, B. X., & Liu, G. L. (2013). A Study on High-Rise Building Structure Selections Using Artificial Intelligence Methods. In *Applied Mechanics and Materials (Vol. 351, pp. 1198-1201)*. Trans Tech Publications.
- Naser, M. Z. (2019). Fire resistance evaluation through artificial intelligence-A case for timber structures. *Fire safety journal*, 105, 1-18.
- Neves, A. C., González, I., Leander, J., & Karoumi, R. (2017, July). A New Approach to Damage Detection in Bridges Using Machine Learning. In *International Conference on Experimental Vibration Analysis for Civil Engineering Structures (pp. 73-84)*. Springer, Cham.
- Prayogo, D., Cheng, M. Y., Widjaja, J., Ongkowijoyo, H., & Prayogo, H. (2017). Prediction of concrete compressive strength from early age test result using an advanced metaheuristic-based machine learning technique. In *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction (Vol. 34)*. IAARC Publications.

- Russell, S., Norvig, P. & Canny, J. (2003). Artificial intelligence : a modern approach (2nd ed.). Upper Saddle River, N.J: Prentice Hall/Pearson Education
- Sadowski, Ł. (2010). New non-destructive method for linear polarisation resistance corrosion rate measurement. Archives of Civil & Mechanical Engineering (Oficyna Wydawnicza Politechniki Wrocławskiej), 10(2).
- Sadowski, L. (2013). Non-destructive investigation of corrosion current density in steel reinforced concrete by artificial neural networks. Archives of Civil and Mechanical Engineering, 13(1), 104-111.
- Salehi, H., & Burgueno, R. (2018). Emerging artificial intelligence methods in structural engineering. Engineering structures, 171, 170-189.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Vakharia, V., & Gujar, R. (2019). Prediction of compressive strength and portland cement composition using cross-validation and feature ranking techniques. Construction and Building Materials, 225, 292-301.
- Μήτσιοϋ, Γ. (2017). Αναδρομικά νευρωνικά δίκτυα και αυτόματη παραγωγή Hashtag από Tweet του Twitter. Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης.

<https://energyplus.net/>

<https://www.palisade.com/neuraltools/default.asp>

<https://www.sketchup.com/>