

Εκτίμηση της Θλιπτικής Αντοχής του Αυτοσυμπυκνούμενου Σκυροδέματος με Χρήση Τεχνητών Νευρωνικών Δικτύων

Μ. Γ. Δουβίκα

Μεταπτυχιακή Φοιτήτρια, Εργαστήριο Υπολογιστικής Μηχανικής, Ανώτατη Σχολή Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης, mariadounika7@gmail.com

Α. Μητρόκα

Προπτυχιακή Φοιτήτρια, Εργαστήριο Υπολογιστικής Μηχανικής, Ανώτατη Σχολή Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης, aimilia.mitroka@gmail.com

Κ. Ροϊνός

Μεταπτυχιακός Φοιτητής, Εργαστήριο Υπολογιστικής Μηχανικής, Ανώτατη Σχολή Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης, kos_ro@hotmail.com

Κ. Γ. Κολοβός

Ειδικός Επιστήμονας, Εργαστήριο Ανόργανης Χημικής Τεχνολογίας, Στρατιωτική Σχολή Ευελπίδων, kolonosk@gmail.com

Π. Γ. Αστερής

Αν. Καθηγητής, Εργαστήριο Υπολογιστικής Μηχανικής, Ανώτατη Σχολή Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης, panagiotisasteris@gmail.com

Περίληψη

Η παρούσα εργασία προτείνει τη χρήση των Τεχνητών Νευρωνικών Δικτύων (Artificial Neural Networks) για την εκτίμηση της θλιπτικής αντοχής του αυτοσυμπυκνούμενου σκυροδέματος (Self-Compacting Concrete). Ειδικότερα, προτείνεται ένας ευρετικός αλγόριθμος (heuristic algorithm) για τον προσδιορισμό της βέλτιστης αρχιτεκτονικής του Τεχνητού Νευρωνικού Δικτύου σε όρους μέσου τετραγωνικού σφάλματος. Το δίκτυο εκπαιδεύεται με μία ερευνητική βάση δεδομένων 169 δοκιμίων, ενώ ορίστηκαν ως παράμετροι εισόδου οι 11 παράμετροι της σύνθεσης των δοκιμίων και ως παράμετρος εξόδου η μετρούμενη θλιπτική αντοχή του σκυροδέματος. Επιλέγη η μέθοδος οπισθοδιάδοσης του λάθους [backward propagation of errors (Backpropagation)]. Στα κυριότερα συμπεράσματα της εργασίας συγκαταλέγεται ότι ο προτεινόμενος ευρετικός αλγόριθμος συντελεί στην αποδοτική εύρεση της βέλτιστης αρχιτεκτονικής του Τεχνητού Νευρωνικού Δικτύου και μάλιστα έχοντας ως αποτέλεσμα την πιο αξιόπιστη εκτίμηση της θλιπτικής αντοχής σε σύγκριση με τις διαθέσιμες ημιεμπειρικές ή και αναλυτικές προτάσεις.

Λέξεις Κλειδιά: Αυτοσυμπυκνούμενο Σκυρόδεμα, Θλιπτική Αντοχή, Τεχνητά Νευρωνικά Δίκτυα, Τεχνητά Νευρωνικά Δίκτυα Οπισθοδιάδοσης

Εισαγωγή

Ανάμεσα σε μια πληθώρα τάσεων και εξελίξεων στην οικοδομική βιομηχανία, η εισαγωγή του αυτοσυμπυκνούμενου σκυροδέματος (Self-Compacting Concrete) παρείχε σημαντικές επιπρόσθετες δυνατότητες και έστρεψε το ενδιαφέρον στην εκμετάλλευση εναλλακτικών πρώτων υλών, υποπροϊόντων, αποβλήτων και δευτερογενών υλικών, ως ανόργανα πρόσμικτα. Κοινώς χαρακτηρίζεται ως ένα ειδικό σκυρόδεμα, το οποίο διαθέτει βελτιωμένες ρεολογικές ιδιότητες, όπως αυξημένη ρευστότητα, ισχυρή αντίσταση στο διαχωρισμό των υλικών (απόμειξη) και δύναται να ρέει και να πληρώνει υπό την επίδραση μόνο του ίδιου βάρους του, ακόμη και κατά την ύπαρξη πυκνού οπλισμού και γεωμετρικά πολύπλοκων διατομών. Επομένως, το ΑΣΣ δύναται να συμπυκνώνεται χωρίς εσωτερική ή εξωτερική δόνηση κατά τη χύτευσή του, με αποτέλεσμα να αποφεύγεται η απόμειξη και η εξίδρωση και να διατηρείται ταυτόχρονα η συνεκτικότητά του (Dinakar et al. 2013, Alyamac and Ince 2009). Ιδιαίτερο ενδιαφέρονσα είναι η πιθανή χρήση του ΑΣΣ σε ελαφριές κατασκευές Güneyisi et al. 2016).

Λόγω της πολύπλοκης σύνθεσης που απαιτείται προκειμένου το αυτοσυμπυκνούμενο σκυρόδεμα (ΑΣΣ) να αποκτήσει τις απαιτούμενες ιδιότητες, είναι αναγκαίο ο σχεδιασμός του μείγματος να γίνεται με κατάλληλη μέθοδο, λαμβάνοντας υπόψη τα διαθέσιμα υλικά και τις αναλογίες ενός ή περισσότερων ανόργανων προσμίκτων (ή προσθέτων) και ενός ή περισσότερων χημικών προσμίκτων. Για την εξασφάλιση μεγαλύτερης συνεκτικότητας η ιδανική αναλογία χονδρόκοκκων και λεπτόκοκκων αδρανών και χημικών προσμίκτων είναι κρίσιμη για τη βελτιστοποίηση της κατανομής μεγέθους σωματιδίων των αδρανών. Σύμφωνα με τον Boukendakdji (Boukendakdji et al. 2012), οι παραλλαγές στο τσιμέντο ή στα ανόργανα πρόσθετα, λόγω τόσο αλλαγής της παραγωγικής διαδικασίας όσο και μεταβολών στον τύπο του αδρανούς, είναι σε θέση να προκαλέσουν σημαντικές διακυμάνσεις στις ιδιότητες του νωπού ΑΣΣ. Ως εκ τούτου, είναι ιδιαίτερα σημαντικό το μείγμα να είναι ανθεκτικό και να επηρεάζεται ελάχιστα από τις συνθήκες περιβάλλοντος. Προς αυτήν την κατεύθυνση, η χρήση της σκόνης βιομηχανικών παραπροϊόντων και αποβλήτων ως ανόργανα πρόσθετα κατά την παραγωγή ΑΣΣ, με σκοπό τα περιβαλλοντικά οφέλη, κερδίζει ολοένα και περισσότερο έδαφος ως ένας αποτελεσματικός τρόπος ανανεώσιμων πηγών ενέργειας (Güneyisi et al. 2016, Kayali 2008, Joseph and Ramamurthy 2009, Baykal and Döven 2000). Έχει προταθεί πλειάδα δευτερευόντων υλικών για ενσωμάτωση στο μείγμα (Boukendakdji et al. 2009 and 2012, Zhao et al. 2015, Rouis 2009, Alyamac and Ince 2009, Dinakar et al. 2013, Güneyisi et al. 2016, Kayali 2008, Joseph and Ramamurthy 2009, Baykal and Döven 2000), συμπεριλαμβανομένων σκόνης ασβεστόλιθου (LP), ιπτάμενης τέφρας (FA), υδρόψυκτης κοκκοποιημένης σκωρίας υψικαμίνου (GGBFS), πυριτικής παιπάλης (SF), τέφρας φλοιού ρυζιού (RHA), ενώ ως χημικά πρόσμικτα προτείνονται υπερρευστοποιητές νέας γενιάς (SP) και πρόσμικτα τροποποίησης ιξώδους (VMA).

Τα Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) (Artificial Neural Networks) έχουν αναδειχθεί ως μία καινοτόμα τεχνική προσομοίωσης, με ευρεία εφαρμογή σε ποικίλους τεχνολογικούς κλάδους και ιδιαίτερα σε προβλήματα πρόβλεψης. Τις τελευταίες δύο δεκαετίες παρατηρείται εκτεταμένη χρήση των ΤΝΔ στην πρόβλεψη των μηχανικών ιδιοτήτων των υλικών μεταξύ των οποίων δεσπόζουσα θέση κατέχει το σκυρόδεμα (Waszczyszyn and Ziemiański 2001). η σχετική βιβλιογραφία περιλαμβάνει κυρίως δημοσιεύματα σχετικά με την εφαρμογή των ΤΝΔ για την πρόβλεψη της θλιπτικής αντοχής και του μέτρου ελαστικότητας (Dias and Pooliyadda 2001, Lee 2003, Torcu and Saridemir 2008, Trtnik et al. 2009). Για τον προσδιορισμό της θλιπτικής αντοχής των υλικών σκυροδέματος έχουν χρησιμοποιηθεί και άλλες μέθοδοι τεχνητής νοημοσύνης (Artificial Intelligence), όπως η ασαφής

λογική (Fuzzy Logic) και οι γενετικοί αλγόριθμοι (Genetic Algorithms) (Baykasoğlu et al. 2004, Akkurt et al. 2004, Özcan et al. 2009).

Στην παρούσα εργασία, παρουσιάζεται η εφαρμογή των μοντέλων ΤΝΔ για την εκτίμηση της θλιπτικής αντοχής της 28ης ημέρας του αυτοσυμπυκνούμενου σκυροδέματος. Ειδικότερα, τα ΤΝΔ εκπαιδεύονται με μία ερευνητική βάση δεδομένων 169 δοκιμών σκυροδέματος (Malagavelli και Manalel 2014). Οι παράμετροι της σύνθεσης των δοκιμών είναι έντεκα [τσιμέντο (Cement), ασβεστολιθική παιπάλη (Limestone powder), ιπτάμενη τέφρα (Fly Ash), σκωρία υψικαμίνων (Ground-granulated blast-furnace slag), πυριτική παιπάλη (Silica Fume), τέφρα φλοιών ρυζιού (Rice Husk Ash), χονδρόκοκκα αδρανή (Coarse Aggregate), λεπτόκοκκα αδρανή (Fine Aggregate), νερό (Water), υπερρευστοποιητής (Superplasticizer), και ρυθμιστικά ιξώδους (Viscosity Modifying Admixtures)], ενώ μετρούμενο μέγεθος ορίζεται η θλιπτική αντοχή των δοκιμών (compressive strength). Για την εκπαίδευση των δικτύων χρησιμοποιήθηκαν ως παράμετροι εισόδου οι προαναφερθείσες 11 παράμετροι της σύνθεσης των δοκιμών, ενώ ως παράμετρος εξόδου η μετρούμενη θλιπτική αντοχή. Καταδεικνύεται ότι τα προκύπτοντα νευρωνικά δίκτυα είναι εξαιρετικά επιτυχή, καθώς παρέχουν σημαντικά αξιόπιστες προβλέψεις για την εκτίμηση της θλιπτικής αντοχής του αυτοσυμπυκνούμενου σκυροδέματος.

Αρχιτεκτονική Τεχνητών Νευρωνικών Δικτύων

Στην παρούσα ενότητα παρουσιάζεται συνοπτικά το θεωρητικό υπόβαθρο των τεχνητών νευρωνικών δικτύων (ΤΝΔ). Ιδιαίτερη έμφαση δίνεται στον προτεινόμενο ευρετικό αλγόριθμο που συντελεί στην εύρεση της βέλτιστης αρχιτεκτονικής του Τεχνητού Νευρωνικού Δικτύου για την εκτίμηση της θλιπτικής αντοχής της 28ης ημέρας του αυτοσυμπυκνούμενου σκυροδέματος με πρόσμικτα. Τα ΤΝΔ είναι μοντέλα επεξεργασίας πληροφοριών διαμορφωμένα για μία συγκεκριμένη εφαρμογή μέσω μίας διαδικασίας εκπαίδευσης. Ένα ΤΝΔ αντιστοιχίζει ραγδαία μία δεδομένη τιμή εισόδου με τις επιθυμητές ποσότητες εξόδου (παρόμοια με τις διαδικασίες προσαρμογής καμπύλης) και ως εκ τούτου χρησιμοποιείται ως μεταμοντέλο προκειμένου να βελτιώσει την αποδοτικότητα της διαδικασίας αριθμητικής ανάλυσης. Το κύριο πλεονέκτημα ενός ΤΝΔ έναντι των συμβατικών διαδικασιών αριθμητικής ανάλυσης (όπως η ανάλυση παλινδρόμησης, υπό την προϋπόθεση ότι τα δεδομένα εκπαίδευσης και επαλήθευσης καλύπτουν όλο το φάσμα των παραμέτρων των τιμών εισόδου), είναι ότι τα αποτελέσματα μπορούν να παραχθούν με πολύ μικρότερο υπολογιστικό φόρτο (Plevris and Asteris 2014 and 2015, Giovanis and Papadopoulos 2015, Asteris and Plevris 2013 and 2016, Asteris et al. 2016, Cavaleri et al. 2016)

Νευρωνικά Δίκτυα Πίσω Διάδοσης

Στην παρούσα εργασία, χρησιμοποιούμε ένα Νευρωνικό Δίκτυο Πίσω Διάδοσης (Back-Propagation Neural Network (BPNN)). Σε αυτόν τον τύπο νευρωνικού δικτύου, τα αποτελέσματα της ανάλυσης συγκρίνονται με τις ακριβείς τιμές για μία προκαθορισμένη συνάρτηση σφάλματος. Μέσω ποικίλων διαδικασιών, το σφάλμα ανατροφοδοτείται μέσω του δικτύου. Με βάση τη συγκεκριμένη πληροφορία, ο αλγόριθμος ρυθμίζει τα βάρη κάθε σύνδεσης, προκειμένου να μειώσει την τιμή της συνάρτησης σφάλματος κατά ένα μικρό ποσοστό. Έχοντας επαναλάβει τη διαδικασία αυτή για ικανοποιητικά μεγάλο αριθμό κύκλων εκπαίδευσης, το δίκτυο συγκλίνει συνήθως με αρκετά χαμηλό υπολογιστικό σφάλμα. Σύμφωνα λοιπόν με την τεχνική ορολογία, ο αλγόριθμος πίσω διάδοσης χρησιμοποιείται για να υπολογίσει την κλίση του σφάλματος του δικτύου σε συνάρτηση με τα

τροποποιήσιμα βάρη του. Για να ρυθμιστούν κατάλληλα τα βάρη, εφαρμόζεται γενικευμένη μεθοδολογία για μη γραμμική βελτιστοποίηση, η λεγόμενη gradient descent. Προκειμένου να ελαχιστοποιηθεί το σφάλμα, υπολογίζεται η παράγωγος της συνάρτησης σφάλματος συναρτήσει των βαρών του δικτύου, ενώ τα βάρη αλλάζουν έτσι ώστε να μειωθεί το σφάλμα (καθοδική πορεία στην επιφάνεια της συνάρτησης σφάλματος). Για αυτόν τον λόγο, ο αλγόριθμος πίσω διάδοσης περιορίζεται μόνο σε δίκτυα με παραγωγίσιμες συναρτήσεις. Η μέθοδος της πίσω-διάδοσης του λάθους συνήθως επιτρέπει ταχεία σύγκλιση σε τοπικά ελάχιστα σφάλματος για τα δίκτυα για τα οποία κρίνεται κατάλληλη.

Ένα Τεχνητό Νευρωνικό Δίκτυο Πίσω Διάδοσης (BPNN) είναι ένα πολυεπίπεδο δίκτυο με τροφοδότηση προς τα εμπρός (feed-forward) και συγκεκριμένη δομή, δηλαδή οι νευρώνες δε συνδέονται εντός του επιπέδου, αλλά συμμετέχουν στο νευρώνα του επιπέδου με όλους τους νευρώνες των προηγούμενων και επόμενων επιπέδων αντίστοιχα. Ένα τέτοιο νευρωνικό δίκτυο έχει την ακόλουθη τυπική δομή:


$$N - H_1 - H_2 - \dots - H_{NHL} - M \quad (1)$$

όπου N ο αριθμός των νευρώνων εισόδου (παράμετροι εισόδου), H_v ο αριθμός των νευρώνων στο νιοστό κρυφό επίπεδο για $v = 1, \dots, NHL$, NHL ο αριθμός των κρυφών επιπέδων και M ο αριθμός των νευρώνων εξόδου (παράμετροι εξόδου). Το Σχήμα 1 απεικονίζει ένα παράδειγμα ενός BPNN με επίπεδο εισόδου 5 νευρώνων, δύο κρυφά επίπεδα 4 και 3 νευρώνων αντίστοιχα και επίπεδο εξόδου 2 νευρώνων, δηλαδή ένα BPNN 5-4-3-2.

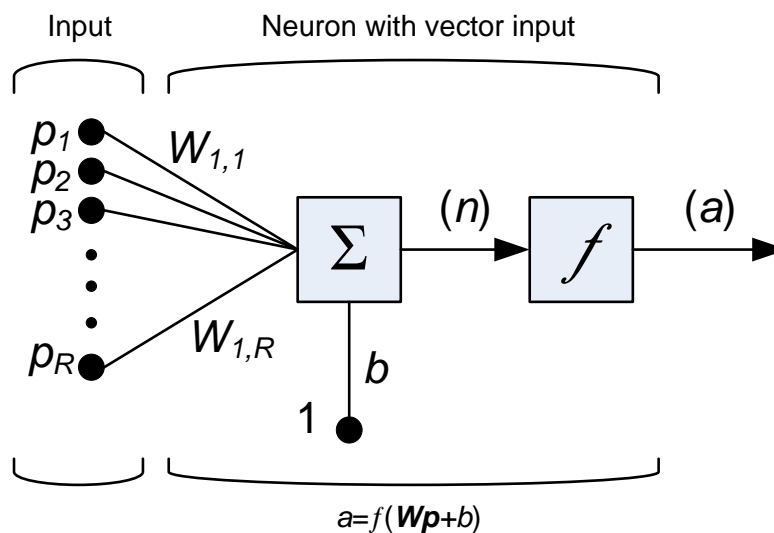
Το Σχήμα 2 αναπαριστά την αρχιτεκτονική της βασικής μονάδας των νευρωνικών δικτύων, η οποία και συνίσταται από έναν απλό νευρώνα με πολλαπλές εισόδους (διάνυσμα p). Για κάθε κόμβο, κάθε τιμή του διανύσματος εισόδου p_1, \dots, p_R πολλαπλασιάζεται με το αντίστοιχο βάρος $w_{1,1}, \dots, w_{1,R}$ και οι σταθμισμένες πλέον τιμές τροφοδοτούν τον κόμβο άθροισης. Κατόπιν, παράγεται το εσωτερικό γινόμενο $W \cdot p$ του διανύσματος-γραμμής $W = [w_{1,1}, \dots, w_{1,R}]$ και του διανύσματος-στήλης $p = [p_1, \dots, p_R]^T$. Το γινόμενο $W \cdot p$ αθροίζεται με το γινόμενο μίας άλλης εισόδου, η οποία ισούται πάντα με τη μονάδα επί το αντίστοιχο βάρος της b . Η τελευταία αυτή είσοδος στον αθροιστή ονομάζεται πόλωση (bias). Η πόλωση έχει την ιδιότητα να αυξάνει ή να μειώνει την είσοδο στη συνάρτηση μεταφοράς (transfer function) όταν είναι θετική ή αρνητική αντίστοιχα. Το άθροισμα που προκύπτει από τον αθροιστή ονομάζεται τοπικό πεδίο του νευρώνα και περιγράφεται από την εξίσωση:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b = Wp + b \quad (2)$$

Το άθροισμα (n) αποτελεί την είσοδο στη συνάρτηση ενεργοποίησης (activation function) f , η οποία καθορίζει την τιμή εξόδου του δικτύου. Η επιλογή της συνάρτησης ενεργοποίησης (activation function) επηρεάζει καθοριστικά την πολυπλοκότητα και την απόδοση των νευρωνικών δικτύων. Στην παρούσα μελέτη, χρησιμοποιούνται ως συναρτήσεις μεταφοράς η λογιστική σιγμοειδής συνάρτηση (Logistic Sigmoid) και η συνάρτηση υπερβολικής εφαπτομένης (Hyperbolic Tangent).



Σχ. 1 BPNN 5-4-3-2



Σχ. 2 Απλός νευρώνας με ένα απλό διάνυσμα εισόδου R στοιχείων

Βέλτιστη Αρχιτεκτονική Τεχνητών Νευρωνικών Δικτύων

Για την εύρεση της βέλτιστης αρχιτεκτονικής ενός ΤΝΔ αρκεί να υπολογιστεί ο αριθμός των κρυφών επιπέδων (hidden layers) των αντίστοιχων νευρώνων (neurons), δεδομένου ότι ο αριθμός των παραμέτρων εισόδου και εξόδου είναι γνωστός. Στο σημείο αυτό αξίζει να σημειωθεί ότι κατά τη

διαδικασία αναζήτησης της βέλτιστης λύσης πρέπει να αποφευχθεί το σύνθημα η βέλτιστη λύση να οδηγήσει σε υπερπροσαρμογή (over-fitting problem). Το φαινόμενο της υπερπροσαρμογής προκύπτει όταν ένα μοντέλο είναι υπερβολικά περίπλοκο, όπως όταν διαθέτει πάρα πολλές παραμέτρους σε σχέση με το πλήθος των παρατηρήσεων, καθώς και όταν τα δεδομένα εκπαίδευσης δεν καλύπτουν όλο το φάσμα των τιμών των παραμέτρων εισόδου του προβλήματος, ενδεικτικά (ακραίο παράδειγμα) όταν ο αριθμός των παραμέτρων είναι ίσος ή υπερβαίνει τις το πλήθος των παρατηρήσεων. Ένα απλό μοντέλο μπορεί να προβλέψει τα δεδομένα εκπαίδευσης απομνημονεύοντάς τα, αλλά αποτυγχάνει στο να προβλέψει καινούργια διότι δεν μαθαίνει να γενικεύει. Με σκοπό να αποφευχθεί το πρόβλημα της υπερπροσαρμογής, έχουν προταθεί διάφορες τεχνικές/ αλγόριθμοι και κριτήρια (Blum 1992, Boger and Guterman 1997, Berry and Linoff 1997, Papadopoulos et al. 2012, Lamanna et al. 2012, Chen 2013, Giovanis and Papadopoulos 2015, Asteris et al. 2016, Cavaleri et al. 2016).

Στην παρούσα εργασία, προτείνεται ένας απλός ευρετικός αλγόριθμος (heuristic algorithm) ο οποίος οδηγεί αξιόπιστα σε βέλτιστη αρχιτεκτονική ΤΝΔ. Τα βήματά του για την περίπτωση εκτίμησης της θλιπτικής αντοχής του αυτοσυμπυκνούμενου σκυροδέματος με πρόσμικτα είναι τα ακόλουθα:

- Βήμα 1.** Κανονικοποίηση των δεδομένων: Η κανονικοποίηση είναι ένα στάδιο προ-επεξεργασίας των δεδομένων (normalization of data), το οποίο έχει αποδειχθεί ως το πιο κρίσιμο για κάθε τύπου πρόβλημα στον τομέα των υπολογιστικών τεχνικών όπως στις τεχνικές τεχνητών νευρωνικών δικτύων.
- Βήμα 2.** Ανάπτυξη και εκπαίδευση πολλών νευρωνικών δικτύων: Η ανάπτυξη και η εκπαίδευση των ΝΔ πραγματοποιείται για μία σειρά από κρυφά επίπεδα που κυμαίνονται από 1 έως 2 και με ένα πλήθος νευρώνων που κυμαίνεται από 4 έως 20. Επίσης, κάθε νευρωνικό δίκτυο εκπαιδεύεται για έναν αριθμό συναρτήσεων ενεργοποίησης, με και χωρίς τη χρήση τεχνικών προ-επεξεργασίας των δεδομένων (Βήμα 1).
- Βήμα 3.** Προσδιορισμός του μέσου τετραγωνικού σφάλματος (mean square error (MSE)): Για καθένα από τα παραπάνω ΝΔ υπολογίζεται το μέσο τετραγωνικό σφάλμα για το σύνολο των δεδομένων επαλήθευσης (validation data), τα οποία δεν έχουν χρησιμοποιηθεί κατά τη διάρκεια της διαδικασίας εκπαίδευσης (training data) των ΤΝΔ.
- Βήμα 4.** Καθορισμός άνω και κάτω ορίων: Εισάγονται άνω και κάτω όρια για την παράμετρο εξόδου (θλιπτική αντοχή), βάσει πειραματικών ή αριθμητικών δεδομένων, καθώς και λογικών εκτιμήσεων από τους χρήστες.
- Βήμα 5.** Επιλογή βέλτιστης αρχιτεκτονικής: Η βέλτιστη αρχιτεκτονική είναι αυτή που δίνει το ελάχιστο μέσο τετραγωνικό σφάλμα.

Αποτελέσματα

Παρουσιάζεται βήμα προς βήμα η αξιοπιστία και η αποτελεσματικότητα του παραπάνω προτεινόμενου αλγόριθμου για την εύρεση της βέλτιστης αρχιτεκτονικής ενός ΤΝΔ οπισθοδιάδοσης. Ειδικότερα, ο προτεινόμενος αλγόριθμος έχει εφαρμοστεί για την πρόβλεψη της θλιπτικής αντοχής στις 28 ημέρες του αυτοσυμπυκνούμενου σκυροδέματος με πρόσμικτα με βάση τα διαθέσιμα στη βιβλιογραφία πειραματικά δεδομένα.

Πειραματικά Δεδομένα

Η βάση δεδομένων, η οποία χρησιμοποιήθηκε για το σχεδιασμό και την ανάπτυξη των νευρωνικών δικτύων, αποτελείται από τα δεδομένα και τα αποτελέσματα 169 δοκιμών αυτοσυμπυκνούμενου σκυροδέματος της βιβλιογραφίας (Sukumar et al. 2008, Grdic et al. 2008, Brouwers and Radix 2005, Fathi et al. 2013, Baskar et al. 2012, Sahmaran et al. 2009, Sfikas and Trezos 2013, Memon et al. 2011, Gesoglu and Ozbay 2007, Gesoglu et al. 2009, Rahman et al. 2014, Siddique 2011, Valcuende et al. 2012, Felekoglu et al. 2007, Sonebi 2004, Phani et al. 2013, Rao et al. 2009, Gettu et al. 2002, Gandage et al. 2013), τα οποία έχουν παρόμοιες φυσικές και χημικές ιδιότητες. Οι πειραματικές παράμετροι εισόδου είναι: τσιμέντο (cement-C), χονδρόκοκκα αδρανή (coarse aggregate-CA), λεπτόκοκκα αδρανή (fine aggregate-FA), νερό (water-W), σκόνη ασβεστόλιθου (limestone powder-LP), ιπτάμενη τέφρα (fly ash-FA), σκωρία υψικαμίνου (ground-granulated blast-furnace slag-GGBFS), πυριτική παιπάλη (silica fume-SF), τέφρα από φλοιό ρυζιού (rice husk ash-RHA) και ως χημικά πρόσμικτα, υπερρευστοποιητές νέας γενιάς (superplasticizers-SP) και πρόσμικτα τροποποίησης του ιξώδους (viscosity modifying admixtures-VMA), ενώ ως έξοδος ορίζεται η θλιπτική αντοχή (compressive strength) των δοκιμών του αυτοσυμπυκνούμενου σκυροδέματος.

Κανονικοποίηση των Δεδομένων

Η κανονικοποίηση των δεδομένων επιδρά καθοριστικά στη διαδικασία σχεδιασμού και ανάπτυξης των ΤΝΔ. Θεωρητικά δεν είναι απαραίτητη, ωστόσο στην πράξη αποδεικνύεται ότι όταν οι αριθμητικές τιμές των δεδομένων κανονικοποιούνται, η εκπαίδευση των νευρωνικών δικτύων προκύπτει πιο αποτελεσματική, γεγονός που οδηγεί σε καλύτερη πρόβλεψη. Στην παρούσα εργασία, κατά τη διάρκεια της προεπεξεργασίας, χρησιμοποιήθηκαν οι τεχνικές κανονικοποίησης Min-Max (Delen et al. 2006) και Zscore. Η τεχνική Min-Max έχει εφαρμόσει τιμές άνω και κάτω ορίου μεταξύ [0,1] και [-1,1].

Αλγόριθμοι Εκπαίδευσης

Για την εκπαίδευση των νευρωνικών δικτύων οπισθοδιάδοσης αξιοποιούνται αρκετοί αλγόριθμοι εκπαίδευσης, όπως: quasi-Newton, Resilient, One-step secant, Gradient descent with momentum and adaptive learning rate and Levenberg-Marquardt backpropagation algorithms. Ο αλγόριθμος με την καλύτερη πρόβλεψη για μη γραμμική συμπεριφορά θλιπτικής αντοχής αυτοσυμπυκνούμενου σκυροδέματος, κατά ένα σημαντικό ποσοστό, είναι ο Levenberg-Marquardt (Lourakis 2005), ο οποίος αποδεικνύεται ταχύτερος για εκπαίδευση μετρίου μεγέθους νευρωνικών δικτύων με τροφοδότηση προς τα εμπρός (έως και αρκετές εκατοντάδες βάρη) καθώς και για μη γραμμικά προβλήματα.

Σχεδιασμός Τεχνητών Νευρωνικών Δικτύων

Με βάση τον παραπάνω αλγόριθμο, σχεδιάστηκαν και εκπαιδεύτηκαν 21.760 μοντέλα νευρωνικών δικτύων οπισθοδιάδοσης. Συγκεκριμένα, αναλύθηκαν 5.440 περιπτώσεις νευρωνικών δικτύων με 4 διαφορετικούς υπολογιστές. Αποφασίστηκε να χρησιμοποιηθούν διαφορετικοί υπολογιστές, καθώς τα μοντέλα των νευρωνικών δικτύων εξάγουν διαφοροποιημένα αποτελέσματα σε άμεση εξάρτηση με το αντίστοιχο υπολογιστικό περιβάλλον, λόγω της ίδιας της φύσης της αριθμητικής κινητής

υποδιαστολής. Κάθε μοντέλο εκπαιδεύτηκε (training) μέσω 113 δεδομένων (από το σύνολο των 169, δηλαδή ποσοστό 66,86%) και η αξιοπιστία των αποτελεσμάτων επιβεβαιώθηκε (validation) μέσω 28 δεδομένων (ποσοστό 16,57%) και ελέγχθηκε (test) έναντι των υπολοίπων 28 δεδομένων (16,57% του συνολικού), υπολογίζοντας το συντελεστή συσχέτισης R του Pearson. Οι παράμετροι που χρησιμοποιήθηκαν για την εκπαίδευση των νευρωνικών δικτύων παρουσιάζονται στον Πίνακα 2.

Το σύνολο των 21760 μοντέλων ΤΝΔ έχουν ταξινομηθεί με βάση το συντελεστή συσχέτισης R του Pearson και οι 20 βέλτιστες αρχιτεκτονικές παρουσιάζονται στον Πίνακα 3. Με βάση αυτά τα αποτελέσματα, το βέλτιστο μοντέλο νευρωνικών δικτύων είναι το 11-5-4-1 (Σχήμα 3) με συντελεστή συσχέτισης R του Pearson ίσο με 0,98258 (πρώτη γραμμή Πίνακα 3, Σχήμα 4). Το συγκεκριμένο δίκτυο αντιπροσωπεύει την περίπτωση αρχιτεκτονικής νευρωνικών δικτύων με δύο κρυφά επίπεδα και χωρίς τη χρήση κάποιας τεχνικής κανονικοποίησης.

Στο Σχήμα 5 παρουσιάζεται η σύγκριση των πειραματικών τιμών με τις αντίστοιχες του βέλτιστου μοντέλου 11-5-4-1. Η θλιπτική αντοχή 28 ημερών αυτοσυμπυκνούμενου σκυροδέματος με πρόσμικτα, η οποία εκτιμήθηκε με το νευρωνικό δίκτυο πολλαπλών επιπέδων με τροφοδότηση προς τα εμπρός, τείνει ευκρινώς στις πειραματικές τιμές.

Αξίζει να σημειωθεί ότι:

- το υπολογιστικό περιβάλλον επηρεάζει σημαντικά τις αρχιτεκτονικές των νευρωνικών δικτύων. Για διαφορετικούς υπολογιστές και με σταθερές όλες τις παραμέτρους προκύπτουν διαφορετικές αρχιτεκτονικές νευρωνικών δικτύων,
- η πλειοψηφία των είκοσι καλύτερων μοντέλων (18 από τα 20) αντιστοιχούν σε αρχιτεκτονικές νευρωνικών δικτύων με δυο κρυφά επίπεδα (hidden layers),
- επίσης οι αρχικές τιμές των βαρών επηρεάζουν σημαντικά τα αποτελέσματα. Διαφορετικές τιμές αρχικών βαρών για τον ίδιο υπολογιστή και όλες τις άλλες παραμέτρους του νευρωνικού δικτύου ίδιες, οδηγούν σε διαφορετικά αποτελέσματα,
- το σύνολο των είκοσι καλύτερων μοντέλων του Πίνακα 3 εκπαιδεύτηκαν για εύρος αριθμού εποχών μεταξύ 43 και 129, το οποίο σημαίνει ότι τα προκύπτοντα νευρωνικά δίκτυα μπορούν να εκτιμήσουν τη θλιπτική αντοχή των 28 ημερών (αυτοσυμπυκνούμενου σκυροδέματος με πρόσμικτα) με μικρότερα ποσοστά σφάλματος και αισθητά μειωμένο υπολογιστικό κόστος σε σύγκριση με τα μοντέλα της βιβλιογραφίας,
- και τα είκοσι βέλτιστα μοντέλα των ΤΝΔ είναι καλύτερα από τα μοντέλα της βιβλιογραφίας. Ειδικότερα, όλα τα μοντέλα προβλέπουν τη θλιπτική αντοχή του αυτοσυμπυκνούμενου σκυροδέματος, με τιμές συντελεστή συσχέτισης R μεταξύ 0,97698 και 0,98258 (βλέπε Πίνακα 3), ενώ οι καλύτερες τιμές στη βιβλιογραφία είναι 0,97 για νευρωνικά δίκτυα και 0,98 για μοντέλα ασαφούς λογικής (Malagavelli and Manalel 2014).

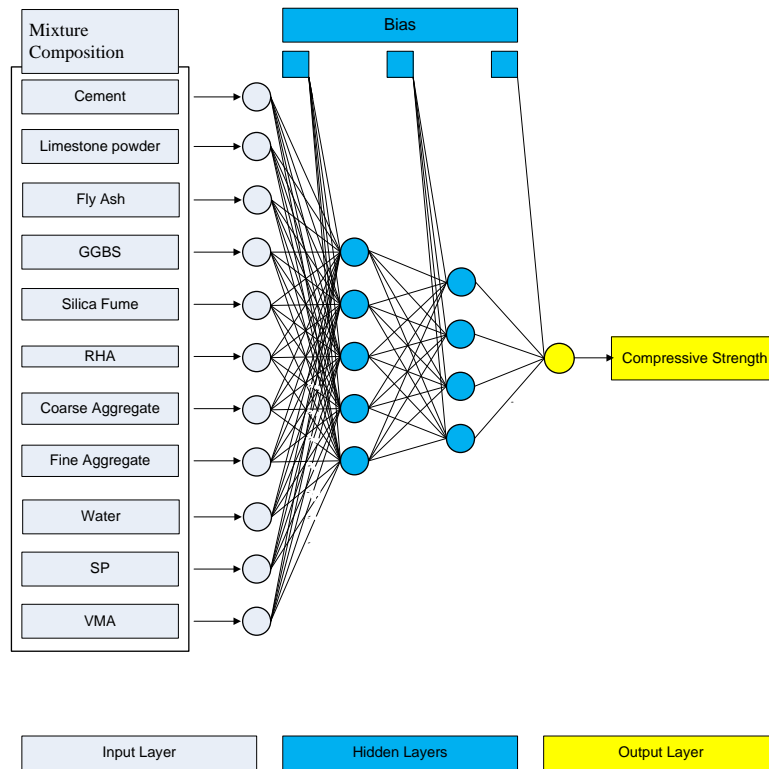
Πιν. 2: Παράμετροι εκπαίδευσης μοντέλων ΤΝΔ

Parameter	Value
Training Algorithm	Levenberg-Marquardt Algorithm
Number of Hidden Layers	1; 2
Number of Neurons per Hidden Layer	4 to 20 by step 1
Training Goal	0
Epochs	1000
Cost Function	MSE; SSE
Transfer Functions	Tansig (T); Logsig (L)
Initial Weights of Hidden Layers	0.10; 1.00
Initial Weights of Bias	0.10; 1.00


Note:
MSE: Mean Square Error; SSE: Sum Square Error
Tansig (T): Hyperbolic Tangent Sigmoid transfer function
Logsig (L): Log-sigmoid transfer function

Πιν. 3: Ταξινόμηση των 20 καλύτερων αρχιτεκτονικών ΤΝΔ βάσει του συντελεστή συσχέτισης R


Ranking	Computer	Preprocess	Cost Function	Training Functions	Initial Weights	Architecture (Code)	Pearson's R	Number of Epochs
1	C02	No	MSE	T-L-T	0.10	11-5-4-1	0.98258	72
2	C03	MinMax [-1, 1]	SSE	T-L-T	0.10	11-17-4-1	0.97952	52
3	C03	No	MSE	T-L-T	1.00	11-17-7-1	0.97883	81
4	C04	No	SSE	T-T-T	0.10	11-18-11-1	0.97867	86
5	C04	No	MSE	T-L-T	0.10	11-15-9-1	0.97830	43
6	C02	No	MSE	T-L-T	1.00	11-16-6-1	0.97822	79
7	C01	No	SSE	T-T	0.10	11-9-1	0.97821	65
8	C04	MinMax [-1, 1]	MSE	T-L-T	1.00	11-9-5-1	0.97814	81
9	C03	ZScore	MSE	T-L-T	0.10	11-20-17-1	0.97781	70
10	C03	MinMax [0, 1]	SSE	T-L-T	1.00	11-8-8-1	0.97774	64
11	C01	No	MSE	T-L-T	1.00	11-18-9-1	0.97770	80
12	C02	No	MSE	T-L-T	0.10	11-20-9-1	0.97762	50
13	C01	No	MSE	T-L-T	1.00	11-20-11-1	0.97757	91
14	C02	No	SSE	T-T-T	0.10	11-6-5-1	0.97747	67
15	C01	MinMax [-1, 1]	MSE	T-L-T	1.00	11-15-5-1	0.97735	69
16	C03	No	MSE	T-T	1.00	11-11-1	0.97729	70
17	C02	MinMax [-1, 1]	SSE	T-L-T	1.00	11-16-16-1	0.97720	129
18	C02	MinMax [0, 1]	MSE	T-T-T	0.10	11-19-15-1	0.97703	112
19	C03	ZScore	SSE	T-L-T	0.10	11-16-12-1	0.97701	45
20	C02	MinMax [0, 1]	SSE	T-L-T	1.00	11-13-8-1	0.97698	72



Σχ. 3. Το βέλτιστο ΤΝΔ με δύο κρυφά επίπεδα (11-5-4-1) με βάση το συντελεστή συσχέτισης R του Pearson.



Σχ. 4. Ο συντελεστής συσχέτισης R του Pearson για το βέλτιστο ΤΝΔ με δύο κρυφά επίπεδα (11-5-4-1)



Σχ. 5. Πειραματικές και εκτιμώμενες τιμές θλιπτικής αντοχής για το βέλτιστο ΤΝΔ με δύο κρυφά επίπεδα (11-5-4-1)

Συμπεράσματα

Στην παρούσα εργασία προτείνεται η χρήση των Τεχνητών Νευρωνικών Δικτύων για την εκτίμηση της θλιπτικής αντοχής των δοκιμών από αυτοσυμπυκνόμενο σκυρόδεμα. Ειδικότερα, προτάθηκε ένας νέος αλγόριθμος για την εύρεση της βέλτιστης αρχιτεκτονικής των νευρωνικών δικτύων. Στα κυριότερα συμπεράσματα της παρούσας εργασίας συγκαταλέγεται ότι ο προτεινόμενος ευρετικός αλγόριθμος συντελεί στην εύρεση της βέλτιστης αρχιτεκτονικής του Τεχνητού Νευρωνικού Δικτύου και μάλιστα έχοντας ως αποτέλεσμα την πιο αξιόπιστη εκτίμηση της θλιπτικής αντοχής του αυτοσυμπυκνόμενου σκυροδέματος σε σχέση με τις διαθέσιμες ημιεμπειρικές ή και αναλυτικές προτάσεις.

Ευχαριστίες

Η παρούσα εργασία υλοποιήθηκε στο πλαίσιο του Προγράμματος Μεταπτυχιακών Σπουδών (ΠΜΣ) στην Εφαρμοσμένη Υπολογιστική Δομική Μηχανική που διοργανώνεται από το Τμήμα Εκπαιδευτικών Πολιτικών Μηχανικών της Ανώτατης Σχολής Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης και χρηματοδοτήθηκε μερικώς από την Επιτροπή Ερευνών της Ανώτατης Σχολής Παιδαγωγικής & Τεχνολογικής Εκπαίδευσης.

Βιβλιογραφία

- Akkurt, S., Tayfur, G., Can, S. (2004). Fuzzy logic model for the prediction of cement compressive strength, *Cement and Concrete Research*, 34 (8), pp. 1429-1433.
- Alyamac, K.E., Ince, R. (2009). A preliminary concrete mix design for SCC with marble powders. *Constr. Build. Mater.* 23: 1201-1210.
- Asteris, P.G., Plevris, V. (2013). Neural network approximation of the masonry failure under biaxial compressive stress, *ECCOMAS Special Interest Conference - SEECCM 2013: 3rd South-East European Conference on Computational Mechanics, Proceedings - An IACM Special Interest Conference*, pp. 584-598.
- Asteris, P.G., Tsaris, A.K., Cavaleri, L., Repapis, C.C., Papalou, A., Di Trapani, F., Karypidis, D.F. (2016). Prediction of the fundamental period of infilled rc frame structures using artificial neural networks, *Computational Intelligence and Neuroscience*, 2016, 5104907.
- Asteris, P.G., Plevris, V. (2016). Anisotropic Masonry Failure Criterion Using Artificial Neural Networks, *Neural Computing and Applications (NCAA)*, DOI: 10.1007/s00521-016-2181-3.
- Baskar, I., Ramanathan, P., Venkatasubramani, R. (2012). Influence of silica fume on properties of self-compacting concrete. *Int. J. Emerg. Trends Eng. Dev.*, 4: 757-767.
- Baykal, G., Döven, A.G. (2000). Utilization of fly ash as pelletization process; theory, application, areas and research results, *Resour. Conserv. Recycl.* 30 59-77.
- Baykasoğlu, A., Dereli, T.U., Taniş, S. (2004). Prediction of cement strength using soft computing techniques, *Cement and Concrete Research*, 34 (11), pp. 2083-2090.
- Berry, M.J.A., Linoff, G. (1997). *Data Mining Techniques*, NY: John Wiley & Sons.
- Blum, A. (1992). *Neural Networks in C++*, NY: Wiley.
- Boger, Z., Guterman, H. (1997). Knowledge extraction from artificial neural network models, *IEEE Systems, Man, and Cybernetics Conference*, Orlando, FL, USA.
- Boukendakdji, O., Kenai, S., Kadri, E.H., Rouis, F. (2009). Effect of slag on the rheology of fresh self-compacted concrete, *Constr. Build. Mater.* 23: 2593-2598.
- Boukendakdji, O., Kadri, E.H., Kenai, S. (2012). Effects of granulated blast furnace slag and superplasticizer type on the fresh properties and compressive strength of self-compacting concrete, *Constr. Build. Mater.* 34: 583-590.
- Brouwers, H.J.H., Radix, H.J. (2005). Self-compacting concrete: Theoretical and experimental study. *Cem. Concr. Res.*, 35: 2116-2136.
- Cavaleri, L., Chatzarakis, G.E., Di Trapani, F., Douvika, M.G., Foskolos, F.M., Fotos, A., Giovanis, D.G., Karypidis, D.F., Livieratos, S., Roinos, K., Tsaris, A.K., Vaxevanidis, N.M., Vougioukas, E., Asteris, P.G. (2016). Surface Roughness Prediction of Electro-discharge Machined Components Using Artificial Neural Networks, *5th International Conference on Integrity, Reliability and Failure*, Faculty of Engineering / U. Porto, 24-28 July 2016.
- Chen, Z. (2013). An overview of bayesian methods for neural spike train analysis, *Computational Intelligence and Neuroscience*, Volume 2013, 2013, Article number 251905.
- Delen, D., Sharda, R., Bessonov, M. (2006). Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks, *Accident Analysis and Prevention*, 38 (3), pp. 434-444.
- Dias, W.P.S., Pooliyadda, S.P. (2001). Neural networks for predicting properties of concretes with admixtures, *Construction and Building Materials*, 15 (7), pp. 371-379.
- Dinakar, P., Sethy, K.P., Sahoo, U.C. (2013). Design of self-compacting concrete with ground granulated blast furnace slag, *Materials and Design* 43: 161-169.
- Fathi, A., Shafiq, N., Nuruddin, M.F., Elheber, A. (2013). Study the effectiveness of the different pozzolanic material on self-compacting concrete. *ARNP J. Eng. Applied Sci.*, 8: 229-305.
- Felekoglu, B., Turkel, S., Baradan, B. (2007). Effect of water/cement ratio on the fresh and hardened properties of self-compacting concrete, *Build. Environ.*, 42: 1795-1802.
- Gandage, A.S., Ram, V.V., Sivakumar, M.V.N., Vasan, A., Venu, M., Yaswanth, A.B. (2013). Optimization of class C flyash dosage in self-compacting concrete for pavement applications, *Proceedings of the International Conference on Innovations in Concrete for Meeting Infrastructure Challenge*, October 23-26, 2013, Hyderabad, Andhra Pradesh, India, pp: 213-226.
- Gesoglu, M., Ozbay, E. (2007). Effects of mineral admixtures on fresh and hardened properties of self-compacting concretes: Binary, ternary and quaternary systems, *Mater. Struct.*, 40: 923-937.

- Gesoglu, M., Guneyisi, E., Ozbay, E. (2009). Properties of self-compacting concretes made with binary, ternary and quaternary cementitious blends of fly ash, blast furnace slag and silica fume, *Construct. Build. Mater.*, 23: 1847-1854.
- Gettu, R., Izquierdo, J., Gomes, P.C.C., Josa, A. (2002). Development of high-strength self-compacting concrete with fly ash: A four-step experimental methodology, *Proceedings of the 27th Conference on Our World in Concrete and Structures*, August 29-30, 2002, Singapore, pp: 217-224.
- Giovanis, D.G., Papadopoulos, V. (2015). Spectral representation-based neural network assisted stochastic structural mechanics, *Engineering Structures*, Volume 84, Pages 382-394.
- Grdic, Z., Despotovic, I., Curcic, G.T. (2008). Properties of self-compacting concrete with different types of additives. *Facta Universitatis-Ser.: Archit. Civil Eng.*, 6: 173-177.
- Güneyisi, E., Gesoglu, M., Ali Azez, O., Öznur Öz, H. (2016). Effect of nano silica on the workability of self-compacting concretes having untreated and surface treated lightweight aggregates, *Constr. Build. Mater.* 115: 371-380.
- Iruansi, O., Guadagnini, M., Pilakoutas, K., Neocleous, K. (2010). Predicting the Shear Strength of RC Beams without Stirrups Using Bayesian Neural Network, in *4th International Workshop on Reliable Engineering Computing (REC 2010)*.
- Joseph, G., Ramamurthy, K. (2009). Influence of fly ash on strength and sorption characteristics of cold-bonded fly ash aggregate concrete, *Constr. Build. Mater.* 23: 1862-1870.
- Kayali, O. (2008). Fly ash lightweight aggregates in high performance concrete, *Constr. Build. Mater.* 22: 2393-2399.
- Lamanna, J., Malgaroli, A., Cerutti, S., Signorini, M.G. (2012). Detection of fractal behavior in temporal series of synaptic quantal release events: A feasibility study, *Computational Intelligence and Neuroscience*, Volume 2012, 2012, Article number 704673.
- Lee, S.C. (2003). Prediction of concrete strength using artificial neural networks, *Engineering Structures*, 25 (7), pp. 849-857.
- Lourakis, M.I.A. (2005). A Brief Description of the Levenberg-Marquardt Algorithm Implemented by levmar. Institute of Computer Science Foundation for Research and Technology - Hellas (FORTH), < available at: <http://www.ics.forth.gr/~lourakis/levmar/levmar.pdf>>.
- Malagavelli, V., Manalel, P.A. (2014). Modeling of compressive strength of admixture-based self compacting concrete using fuzzy logic and artificial neural networks, *Asian Journal of Applied Sciences*, 7 (7), pp. 536-551.
- Memon, S.A., Shaikh, M.A., Akbar, H. (2011). Utilization of rice husk ash as viscosity modifying agent in self compacting concrete, *Constr. Build. Mater.*, 25: 1044-1048.
- Özcan, F., Atiş, C.D., Karahan, O., Uncuoğlu, E., Tanyildizi, H. (2009). Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete, *Advances in Engineering Software*, 40 (9), pp. 856-863.
- Papadopoulos, V., Giovanis, D.G., Lagaros, N.D., Papadarakakis, M. (2012). Accelerated subset simulation with neural networks for reliability analysis, *Computer Methods in Applied Mechanics and Engineering*, Volume 223-224, Pages 70-80.
- Pattnaik, S., Karunakar, D.B., Jha, P.K. (2014). A prediction model for the lost wax process through fuzzy-based artificial neural network, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 228 (7), pp. 1259-1271.
- Phadke, M.S. (1989). Quality engineering using design of experiments. In *Quality Control, Robust Design, and the Taguchi Method*, 31-50, Springer US.
- Phani, S.S., Sekhar, S.T., Rao, S., Sravana, P. (2013). High strength self-compacting concrete using mineral admixtures, *Indian Concr. J.*, 87: 42-47.
- Plevris, V., Asteris, P.G. (2014). Modeling of masonry compressive failure using Neural Networks, *OPT-i 2014 - 1st International Conference on Engineering and Applied Sciences Optimization*, Proceedings, pp. 2843-2861.
- Plevris, V., Asteris, P.G. (2014). Modeling of masonry failure surface under biaxial compressive stress using Neural Networks, *Construction and Building Materials*, 55, pp. 447-461.
- Plevris, V., Asteris, P. (2015). Anisotropic failure criterion for brittle materials using Artificial Neural Networks, *COMPADYN 2015 - 5th ECCOMAS Thematic Conference on Computational Methods in Structural Dynamics and Earthquake Engineering*, pp. 2259-2272.

- Rahman, M.E., Muntohar, A.S., Pakrashi, V., Nagaratnam, B.H., Sujan, D. (2014). Self compacting concrete from uncontrolled burning of rice husk and blended fine aggregate, *Mater. Des.*, 55: 410-415.
- Rao, N.V.R., Rao, P.S., Sravana, P., Sekhar, T.S. (2009). Studies on relationship of water-powder ratio and compressive strength of self compacted concrete, *Proceedings of the 34th Conference on Our World in Concrete and Structures, August 16-18, 2009, Singapore*, pp: 1-8.
- Rouis, F. (2009). Effect of slag on the rheology of fresh self-compacted concrete, *Constr. Build. Mater.* 23: 2593-2598.
- Sahmaran, M., Yaman, I.O., Tokyay, M. (2009). Transport and mechanical properties of self consolidating concrete with high volume fly ash, *Cem. Concr. Compos.*, 31: 99-106.
- Sfikas, I.P., Trezos, K.G. (2013). Effect of composition variations on bond properties of self-compacting concrete specimens, *Constr. Build. Mater.*, 41: 252-262.
- Siddique, R. (2011). Properties of self-compacting concrete containing class F fly ash, *Mater. Des.*, 32: 1501-1507.
- Sonebi, M. (2004). Medium strength self-compacting concrete containing fly ash: Modelling using factorial experimental plans, *Cem. Concr. Res.*, 34: 1199-1208.
- Sukumar, B., Nagamani, K., Raghavan, R.S. (2008). Evaluation of strength at early ages of self-compacting concrete with high volume fly ash. *Constr. Build. Mater.*, 22: 1394-1401.
- Topçu, I.B., Saridemir, M. (2008). Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic, *Computational Materials Science*, 41 (3), pp. 305-311.
- Trtnik, G., Kavčič, F., Turk, G. (2009). Prediction of concrete strength using ultrasonic pulse velocity and artificial neural networks, *Ultrasonics*, 49 (1), pp. 53-60.
- Valcuende, M., Marco, E., Parra, C., Serna, P. (2012). Influence of limestone filler and viscosity-modifying admixture on the shrinkage of self-compacting concrete, *Cem. Concr. Res.*, 42: 583-592.
- Waszczyszyn, Z., Ziemiański, L. (2001). Neural networks in mechanics of structures and materials - New results and prospects of applications, *Computers and Structures*, 79 (22-25), pp. 2261-2276.
- Zhao, H., Sun, W., Wu, X., Gao, B. (2015). The properties of the self-compacting concrete with fly ash and ground granulated blast furnace slag mineral admixtures, *Journal of Cleaner Production* 95: 66-74.