ΕΚΤΕΝΗΣ ΠΕΡΙΛΗΨΗ

Πρόβλεψη διάρκειας ζωής σε κόπωση χαλύβων με μεθοδολογίες Τεχνητής Νοημοσύνης και Μηχανικής Μάθησης Κωνσταντίνος Αρβανίτης

Μια από τις συχνότερες αιτίες αστοχιών των μηχανικών κατασκευών είναι η κόπωση, η οποία συμβαίνει ξαφνικά, απρόβλεπτα και καταστροφικά, πολλές φορές εντός σύντομης διάρκειας ζωής του υλικού. Για τον λόγο αυτό, η πρόβλεψη της διάρκειας ζωής των κατασκευαστικών υλικών, και ιδιαίτερα των χαλύβων, αποτελεί σημαντικό αντικείμενο έρευνας και έχει οδηγήσει στην ανάπτυξη πολλών συμβατικών μοντέλων, τα οποία χρησιμοποιούνται κατά κόρον στους κώδικες δομικής σχεδίασης. Ωστόσο, η ραγδαία ανάπτυξη της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης τα τελευταία χρόνια έχει στρέψει το ενδιαφέρον των ερευνητών προς την εφαρμογή τους στο πρόβλημα της κόπωσης των υλικών.

ΜΟΝΤΕΛΑ ΚΟΠΩΣΗΣ

Ως κόπωση ορίζεται η διαδικασία των προοδευτικών τοπικών μόνιμων δομικών μεταβολών που συμβαίνουν στα υλικά που υποβάλλονται σε συνθήκες μεταβαλλόμενων τάσεων και παραμορφώσεων σε ένα ή περισσότερα σημεία και που μπορούν να οδηγήσουν σε ρωγμές ή πλήρη θραύση, μετά από ένα επαρκή αριθμό μεταβολών του φορτίου. Μια αρμονική μεταβολή της τάσης σε συνάρτηση με τον χρόνο απεικονίζεται στην Εικόνα 1.



Εικόνα 1. Αρμονική μεταβολή της τάσης με τον χρόνο.

Το πλάτος κύματος της τάσης συμβολίζεται με σ_a, ενώ η μέση τάση με σ_m. Επιπρόσθετα, το εύρος τάσης Δσ καθώς και η αναλογία τάσης R είναι μεταβλητές που χρησιμοποιούνται συχνά στην ανάλυση ενός κύκλου τάσης. Οι σχέσεις που συνδέουν όλες τις μεταβλητές της τάσης κατά την κόπωση έχουν ως εξής:

$$\sigma_m = \frac{\sigma_{max} + \sigma_{min}}{2}$$
$$\sigma_a = \frac{\sigma_{max} - \sigma_{min}}{2}$$
$$\Delta \sigma = \sigma_{max} - \sigma_{min}$$
$$R = \frac{\sigma_{min}}{\sigma_{max}}$$

Η απόκριση του υλικού σε μια ακολουθία κύκλων φόρτισης εξαρτάται σε μεγάλο βαθμό από τη φύση της εξωτερικής φόρτισης, η οποία μπορεί να είναι περιοδική, τυχαία, ή ακόμη και να αποτελείται από επαναλαμβανόμενα μπλοκ. Ανάλογα με τον αριθμό των κύκλων φόρτισης που απαιτούνται για τον σχηματισμό ρωγμής, η κόπωση διακρίνεται σε κόπωση χαμηλών αριθμού κύκλων (Low-Cycle fatigue) και υψηλού αριθμού κύκλων (High-Cycle fatigue). Το όριο μεταξύ των δύο κατηγοριών δεν είναι ευδιάκριτο, αλλά συνήθως ορίζεται στην τάξη των 10.000 κύκλων. Στην περίπτωση κόπωσης υψηλού αριθμού κύκλων, οι τάσεις είναι αρκετά χαμηλές ώστε η σχέση τάσης – παραμόρφωσης να μπορεί να θεωρηθεί ελαστική, ενώ η κόπωση χαμηλού αριθμού κύκλων φόρτισης χαρακτηρίζεται από επαναλαμβανόμενη πλαστική παραμόρφωση.

Σε μηχανολογικές κατασκευές, ο σχεδιασμός για κόπωση βασίζεται συνήθως στον υπολογισμό της διάρκειας ζωής μέσω της εφαρμογής ενός νόμου συσσώρευσης βλάβης. Η ανίχνευση μικρορωγμών σε πραγματικό χρόνο, ιδίως σε κατασκευές υπεράκτιων και αεροδιαστημικών εφαρμογών, μπορεί να αποτελέσει πρόκληση. Ως εκ τούτου, μια αποτελεσματική προσέγγιση είναι η δημιουργία αξιόπιστων μοντέλων που προβλέπουν τον σχηματισμό ρωγμών σε μια κατασκευή. Τα αποτελέσματα των πειραμάτων κόπωσης για καθορισμό του αριθμού των κύκλων κατά τον οποίο σχηματίζεται ρωγμή παρουσιάζονται σε καμπύλες, οι οποίες είναι γνωστές ως καμπύλες Wohler. Οι καμπύλες παρουσιάζονται σε λογαριθμική κλίμακα και παρουσιάζουν τον αριθμό των κύκλων μέχρι την ανάπτυξη ρωγμής στον άξονα *x*, έναντι του πλάτους της τάσης στον *y*, όπως απεικονίζεται στην Εικόνα 2. Ως όριο κόπωσης ονομάζεται το μέγιστο πλάτος τάσης κατά το οποίο ένα υλικό μπορεί να υποστεί κόπωση χωρίς να αστοχήσει για άπειρο αριθμό κύκλων φόρτισης.



Εικόνα 2. Τυπική καμπύλη Wohler.

Τα μοντέλα κόπωσης μπορούν να διαχωριστούν σε δύο βασικές κατηγορίες, στα γραμμικά και τα μη γραμμικά. Ο κανόνας του Miner αποτελεί μια γραμμική προσέγγιση που χρησιμοποιείται ευρέως στην βιομηχανία λόγω της απλότητας του. Βασίζεται στην αρχή πως η βλάβη λόγω κόπωσης σχετίζεται με τον αθροιστικό λόγο κύκλων, όπως αναφέρεται στην παρακάτω έκφραση, όπου η βλάβη ορίζεται ως D, έτσι ώστε μια τιμή D=1 να ισοδυναμεί με την αστοχία του υλικού.

$$D = \sum \frac{n_i}{N_i}$$

όπου n_i είναι ο αριθμός των κύκλων που εφαρμόστηκαν και N_i ο αριθμός των κύκλων μέχρι την αποτυχία για σταθερό πλάτος τάσης σ_i . Παρά την απλότητα του κανόνα του Miner σε βιομηχανικές εφαρμογές, το μοντέλο αυτό δεν λαμβάνει υπόψη τις επιπτώσεις των ακολουθιών φόρτισης λόγω της γραμμικότητας του. Για τον λόγο αυτό, τείνει να υπερεκτιμά την εναπομένουσα διάρκεια ζωής λόγω κόπωσης στην περίπτωση όπου το πλάτος τάσης μειώνεται, ενώ αντίστροφα υποεκτιμά την διάρκεια ζωής στην περίπτωση όπου το πλάτος τάσης αυξάνεται.

Με στόχο την αντιμετώπιση των περιορισμού του κανόνα του Miner, πολλά μη γραμμικά μοντέλα έχουν προταθεί, αναμεσά τους ο μη γραμμικός κανόνας βλάβης (Nonlinear damage rule), ο κανόνας διπλής γραμμικής βλάβης (double-linear damage rule) και η προσέγγιση της καμπύλης βλάβης (damage curve approach). Μια πρόσφατη προσέγγιση για την μοντελοποίηση της συσσώρευσης βλάβης βασίζεται στην ιδέα των ισοκαταστροφικών γραμμών (isodamage lines), όπως απεικονίζονται στην Εικόνα 3. Η καμπύλη Wohler, ή αλλιώς καμπύλη S-N, αναπαριστά την περίπτωση αστοχίας, όπου D=1.



Εικόνα 3. Η έννοια των ισοκαταστροφικών γραμμών

Σε συνέχεια αυτής της έννοιας, και λαμβάνοντας υπόψη τις συνέπειες των μηχανισμών βλάβης σε μακροσκοπική κλίμακα, ένα νέο μοντέλο προτάθηκε από τον Pavlou ονόματι φάκελος βλάβης λόγω κόπωσης (fatigue damage envelope). Το μοντέλο αυτό προτείνει την έννοια των ισοκαταστροφικών καμπύλων (isodamage curves) έναντι των ισοκαταστροφικών γραμμών, όπως παρουσιάζεται στην Εικόνα 4.



Εικόνα 4. Η έννοια των ισοκαταστροφικών καμπύλων.

Καθώς η καμπύλη S-N αντιπροσωπεύει μια ισοκαταστροφική γραμμή με τιμή βλάβης ίση με 1, είναι λογικό οι ισοκαταστροφικές καμπύλες με τιμές κοντά στο 1 θα παρουσιάζουν σχεδόν γραμμικότητα. Κατά συνέπεια, η περιοχή HOK στην Εικόνα 4 μπορεί να θεωρηθεί ως φάκελος βλάβης που εμπεριέχει ισοκαταστροφικές καμπύλες με τιμές 0<D<1.

Αν και τα μη γραμμικά μοντέλα προσφέρουν πλεονεκτήματα λαμβάνοντας υπόψη τα αποτελέσματα της ακολουθίας φόρτισης, οι κώδικες σχεδιασμού δεν έχουν ενσωματώσει κανένα από αυτά λόγω της εγγενούς πολυπλοκότητάς τους. Για τον λόγο αυτό, μια νέα θεωρία από τον Pavlou προτείνει την εφαρμογή συναρτήσεων βάρους στον κανόνα του Miner. Αυτό έχει ως αποτέλεσμα την γραμμικότητα του αθροίσματος των βλαβών, ενώ ταυτόχρονα το ιστορικό βλάβης του υλικού να λαμβάνεται υπόψη. Ενώ η συσσώρευση βλάβης ακολουθεί ένα γραμμικό μοτίβο, η συνολική εκτίμηση της πραγματικής συσσώρευσης βλάβης σε ολόκληρο το ιστορικό τάσεων είναι μη γραμμική. Ο καθορισμός των συναρτήσεων βάρους βασίζεται στην διακριτοποίηση των ισοτασικών καμπυλών, όπως παρουσιάζεται στην Εικόνα 5.



Εικόνα 5. Διακριτοποίηση των ισοτασικών καμπυλών.

Η κλίση κάθε ευθύγραμμου τμήματος αντικατοπτρίζει την μνήμη του υλικού από την προηγούμενη συσσώρευση βλάβης. Με βάση αυτήν την έννοια, ο συντελεστής βάρους για την διόρθωση του κανόνα του Miner εντός μιας ζώνης βλάβης συμβολίζεται ως:

$$w_i = \frac{tan\varphi_i}{tan45^o}$$

Όπου το φ_i δείχνει την κλίση του ευθύγραμμου τμήματος που σχετίζεται με το πλάτος τάσης σ_i εντός μια ζώνης βλάβης. Η συνολική βλάβη μπορεί να υπολογιστεί με το άθροισμα των επιμέρους προσαυξήσεων ζημιάς σε όλες τις ζώνες. Τελικά ο συντελεστής βάρους εκφράζεται ως:

$$w_{ij} = \frac{D_j - D_{j-1}}{D_j^{1/q(\sigma_i)} - D_{j-1}^{1/q(\sigma_i)}}$$

όπου j είναι η ζώνη βλάβης.

Η συνάρτηση $q(\sigma_i)$ ορίζεται ως

$$q(\sigma_i) = \left(\frac{\sigma_i}{S_u}\right)^{-0.75}$$

όπου S_u το όριο κόπωσης.

ΜΟΝΤΕΛΑ ΤΝ ΚΑΙ ΜΜ

Όπως αναφέρθηκε, η διαρκής ανάπτυξη της τεχνολογίας στον τομέα της μηχανολογίας έχει οδηγήσει στην ανάπτυξη μοντέλων ΤΝ και ΜΜ που προβλέπουν αποτελεσματικά την διάρκεια ζωής λόγω κόπωσης. Η πρώτη μέθοδος που χρησιμοποιήθηκε στην παρούσα διπλωματική εργασία είναι η Πολυωνυμική Παλινδρόμηση. Η μέθοδος αυτή στηρίζεται στο απλό μοντέλο της Γραμμικής Παλινδρόμησης, με μόνη διαφορά την μετατροπή των εισόδων του συστήματος σε πολυωνυμικούς παράγοντες. Για παράδειγμα, αν η είσοδος *x* αποτελείται από δύο συντελεστές $x = [x_1, x_2]$ και επιλέγεται ένα πολυώνυμο δευτέρου βαθμού, τότε η νέα είσοδος θα είναι:

$$X = p(x) = [1 \ x_1 \ x_2 \ x_1^2 \ x_1 x_2 \ x_2^2]^T$$

Στην συνέχεια, η εφαρμογή της Γραμμικής Παλινδρόμησης γίνεται ως εξής:

$$X\boldsymbol{\beta} = \boldsymbol{y}$$
$$\hat{\boldsymbol{\beta}} = \arg\min_{\boldsymbol{b}\in\mathbb{R}^p} S(\boldsymbol{b}) = (X^T X)^{-1} X^T \boldsymbol{y}$$

όπου y στην περίπτωση του προβλήματος της κόπωσης είναι ο αριθμός κύκλων μέχρι την αστοχία ενώ στον πίνακα X περιλαμβάνονται τα μηχανικά χαρακτηριστικά του υλικού, καθώς και οι παράμετροι των πειραμάτων. Η Πολυωνυμική Παλινδρόμηση επιτυγχάνει την εύρεση πολύπλοκων σχέσεων μεταξύ των χαρακτηριστικών εισόδου, ενώ παράλληλα αποτελεί μια μέθοδο που απαιτεί μικρό υπολογιστικό κόστος.

Η επόμενη μέθοδος που χρησιμοποιήθηκε είναι η Παλινδρόμηση Διανυσμάτων Υποστήριξης (Support Vector Regression). Το μοντέλο αυτό αποσκοπεί στην εύρεση μιας συνάρτησης που μοντελοποιεί τη σχέση μεταξύ εισόδου και συνεχούς μεταβλητής εξόδου, με στόχο την ελαχιστοποίηση του σφάλματος πρόβλεψης. Προσπαθεί να εντοπίσει ένα υπερ-επίπεδο το οποίο αποτυπώνει αποτελεσματικά τα σημεία δεδομένων σε έναν συνεχή χώρο. Χειρίζεται μη γραμμικές σχέσεις χρησιμοποιώντας μια συνάρτηση πυρήνα (kernel function) και χρησιμοποιεί την έννοια του περιθωρίου (margin) ώστε να αποτυπώσει τα δεδομένων τα σημεία δεδομένων που βρίσκονται πιο κοντά στην ευθεία παλινδρόμησης και καθορίζουν το περιθώριο. Η διαχείριση του σφάλματος γίνεται στο πλαίσιο ορισμένων περιορισμών, διασφαλίζοντας πως το απόλυτο σφάλμα περιορίζεται ώστε να είναι μικρότερο ή ίσο με ένα καθορισμένο περιθώριο, το οποίο αναφέρεται ως ε. Το πρόβλημα βελτιστοποίησης για την Παλινδρόμηση Διανυσμάτων Υποστήριξης περιλαμβάνει την εύρεση της βέλτιστης ισορροπίας μεταξύ της ελαχιστοποίησης των συντελεσμάν.

$$\begin{array}{l} \text{minimize } \frac{1}{2} \|w\|^2 \\ \text{subject to } |y_i - \langle w, x_i \rangle - b| \leq \varepsilon \end{array} \tag{31}$$

Ωστόσο, σε ορισμένες περιπτώσεις, οι περιορισμοί αυτοί δεν είναι δυνατοί. Για τον λόγο αυτό, ορίστηκαν οι μεταβλητές ξ_i και ξ_i^{*}, για τον χειρισμό δυνητικά ανέφικτων περιορισμών στο παραπάνω πρόβλημα βελτιστοποίησης, όπως απεικονίζεται και στην Εικόνα 6.



Εικόνα 6. Χρήση των μεταβλητών ξ_i και ${\xi_i}^*$

Χρησιμοποιώντας μη γραμμικές συναρτήσεις πυρήνα (kernels), όπως απεικονίζεται στην Εικόνα 7, η τελική εξίσωση η οποία περιγράφει την σχέση μεταξύ ανεξάρτητων εισόδων και εξαρτημένης μεταβλητής του συστήματος μπορεί να εκφραστεί ως:

$$f(x) = \sum_{i=1}^{N_{SV}} (\alpha_i - \alpha_i^*) k(x_i, x)$$

όπου N_{SV} είναι ο αριθμός των Διανυσμάτων Υποστήριξης, τα α_i και α_i^* αντιπροσωπεύουν μη μηδενικούς πολλαπλασιαστές Lagrance και k(.,.) είναι η συνάρτηση πυρήνα.



Εικόνα 7. Χρήση συνάρτησης πυρήνα (kernel)

Η επόμενη μέθοδος που χρησιμοποιήθηκε είναι η παλινδρόμηση τύπου XGB. Το όνομα XGB, ή αλλιώς XGBoost, προέργεται από τον ορισμό «Extreme Gradient Boosting» και αποτελεί ένα βελτιωμένο μοντέλο του Gradient Boosting. Αποτελείται από ένα σύνολο Δέντρων Παλινδρόμησης, καθένα από τα οποία αντιστοιχίζει ένα σημείο δεδομένων εισόδου σε ένα από τα φύλλα του, το οποίο περιέχει μια συνεχή βαθμολογία. Αυτή η μέθοδος ελαχιστοποιεί μια συνάρτηση – στόγο, ρυθμισμένη με ποινές τύπου L1 και L2. Η διαδικασία εκπαίδευσης επαναλαμβάνεται με την προσθήκη νέων δέντρων, τα οποία συνδυάζονται με τα προηγούμενα ώστε να γίνει η τελική πρόβλεψη. Το Gradient Boosting χρησιμοποιεί έναν αλγόριθμο βαθμιαίας καθόδου για την ελαχιστοποίηση των απωλειών κατά την προσθήκη νέων μοντέλων. Η διαδικασία περιλαμβάνει τον συνδυασμό πολυάριθμων μοντέλων με αδύναμους ρυθμούς μάθησης, που υποδηλώνουν πως η επόμενη επανάληψη μαθαίνει πιο αργά από την προηγούμενη. Ως εκ τούτου, δημιουργείται ένα ισχυρό μοντέλο που παρέχει τις τελικές προβλέψεις και χαρακτηρίζεται ως μοντέλο boosting. Σε αντίθεση με τεχνικές bagging, όπως η Random Forest, όπου τα δέντρα αναπτύσσονται στην μέγιστη έκταση, οι τεχνικές boosting κάνουν χρήση δέντρων με λιγότερες διασπάσεις (splits). Αυτά τα μικρά δέντρα, που δεν χαρακτηρίζονται από εκτεταμένο βάθος, παρουσιάζουν πολλές παραμέτρους που μπορούν να βελτιστοποιηθούν, όπως ο ρυθμός μάθησης και το βάθος τους. Επιπλέον, η XGBoost παρουσιάζει ανώτερη ταχύτητα σε σύγκριση με άλλους αλγορίθμους, και είναι σημαντικά ταχύτερη από άλλα μοντέλα Gradient Boosting. Αυτό αποδίδεται στην ικανότητα της για παράλληλους υπολογισμούς, επιτρέποντας σε πολλούς επεξεργαστές ενός υπολογιστή να εργάζονται ταυτόχρονα, επιλύοντας έτσι αποτελεσματικά μεγαλύτερα προβλήματα, με την ολοκλήρωση πολλαπλών μικρότερων υπολογισμών.



Εικόνα 8. Διάγραμμα ροής παλινδρόμησης τύπου XGB.

Δεδομένου ενός συνόλου δεδομένων με n δείγματα και m χαρακτηριστικά $D = \{(x_i, y_i)\}$ $(|D| = n, x_i \in \mathbb{R}^m, y_i \in \mathbb{R})$, ένα μοντέλο δέντρων χρησιμοποιεί K προσθετικές συναρτήσεις για να κάνει προβλέψεις

$$\widehat{y}_i = \varphi(x_i) = \sum_{k=1}^{K} f_k(x_i), \ f_k \in \mathcal{F}$$

όπου $\mathcal{F} = \{f(x) = w_{q(x)}\}(q: \mathbb{R}^m \to T, w \in \mathbb{R}^T)$ είναι ο χώρος των δέντρων παλινδρόμησης, γνωστός και ως CART. Το q δηλώνει την δομή κάθε δέντρου και το T αντιπροσωπεύει τον αριθμό των φύλλων του δέντρου.

Για τον καθορισμό του συνόλου των συναρτήσεων που χρησιμοποιούνται στο μοντέλο, στόχος είναι η ελαχιστοποίηση του ακόλουθου κανονικοποιημένου στόχου.

$$Obj = \sum_{i} l(\hat{y}_{i}, y_{i}) + \sum_{k} \Omega(f_{k})$$
$$\delta \pi ov \ \Omega(f) = \gamma T + \frac{1}{2} \lambda ||w||^{2}$$

Το *l* είναι μια διαφορίσιμη κυρτή συνάρτηση απωλειών που μετρά την διαφορά μεταξύ της προβλεπόμενης τιμής \hat{y}_i και της πραγματικής τιμής y_i . Ο όρος Ω επιβάλλει μια ποινή στην πολυπλοκότητα του μοντέλου, στοχεύοντας στις συναρτήσεις των δέντρων παλινδρόμησης. Ο πρόσθετος όρος κανονικοποίησης είναι ζωτικής σημασίας για την εξομάλυνση των τελικών βαρών, λειτουργώντας ως προληπτικό μέτρο κατά της υπερπροσαρμογής (overfitting).

Στην πράξη, το δέντρο αναπτύσσεται με «άπληστο» τρόπο, ξεκινώντας αρχικά με ένα δέντρο βάθους 0. Η αλλαγή της συνάρτησης-στόχου μετά την προσθήκη της διάσπασης είναι:

$$Gain = \frac{G_L^2}{H_L + \lambda} + \frac{G_L^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} - \gamma$$

Όπου ο όρος $\frac{G_L^2}{H_L+\lambda}$ δηλώνει την βαθμολογία του αριστερού κλαδιού της διάσπασης, ενώ ο όρος $\frac{G_L^2}{H_R+\lambda}$ την βαθμολογία του δεξιού, και ο όρος $\frac{(G_L+G_R)^2}{H_L+H_R+\lambda}$ την βαθμολογία αν δεν συμβεί διάσπαση. Ο όρος G συμβολίζει το άθροισμα των κλίσεων (gradients) σε έναν κόμβο (node), ο όρος H το άθροισμα των Hessians και το γ αντιπροσωπεύει το κόστος πολυπλοκότητας με την προσθήκη ενός πρόσθετου φύλλου.

Για να συνεχιστεί η ανάπτυξη ενός κλάδου, η βαθμολογία για την καλύτερη διάσπαση πρέπει να είναι θετική και μεγαλύτερη από το γ, διαφορετικά η ανάπτυξη διακόπτεται. Ο αλγόριθμος ονομάζεται «Exact Greedy Algorithm». Συμπερασματικά, η πρόβλεψη για μια νέα περίπτωση x σε ένα σύνολο με T δέντρα καθορίζεται από την εξίσωση

$$\hat{y}(x) = \sum_{t=1}^{T} \varepsilon f_t(x)$$

όπου το ε αντιπροσωπεύει τον ρυθμό εκμάθησης, έναν μικρό θετικό αριθμό μεταξύ 0 και 1 που ρυθμίζει την επιρροή της πρόβλεψης κάθε δέντρου στην τελική έξοδο.

Η τελευταία μέθοδος που χρησιμοποιήθηκε είναι το Τεχνητό Νευρωνικό Δίκτυο, ένας κλάδος μοντέλων Τεχνητής Νοημοσύνης που βασίζεται στην μίμηση με τον οποίο οι βιολογικοί νευρώνες στέλνουν σήματα ο ένας στον άλλον. Όμοια με τον βιολογικό νευρώνα, ο τεχνητός νευρώνας δέχεται ένα σετ τιμών εισόδου, τις επεξεργάζεται μέσω συναρτήσεων ενεργοποίησης και βαρών, και τελικά παράγει μια έξοδο.



Εικόνα 9. Βιολογικός και τεχνητός νευρώνας.

Τα ΤΝΔ αποτελούνται από διασυνδεδεμένους νευρώνες οργανωμένους σε επίπεδα (layers). Η πληροφορία ρέει μέσω αυτών τον κόμβων και το δίκτυο προσαρμόζει την ισχύ των συνδέσεων (βάρη) κατά τη διάρκεια της εκπαίδευσης ώστε να μάθει από τα δεδομένα, επιτρέποντάς του να αναγνωρίζει μοτίβα, να κάνει προβλέψεις και να επιλύει διάφορες εργασίες στη Μηχανική Μάθηση και την Τεχνητή Νοημοσύνη. Υπάρχουν τρεις τύποι επιπέδων σε ένα ΤΝΔ: (α) ένα επίπεδο εισόδου που δέχεται ως είσοδο τα ακατέργαστα δεδομένα και τα μεταβιβάζει στο υπόλοιπο δίκτυο, (β) ένα ή περισσότερα κρυφά επίπεδα που βρίσκονται ενδιάμεσα μεταξύ της εισόδου και της εξόδου και επεξεργάζονται τα δεδομένα εφαρμόζοντας σύνθετες μη γραμμικές

συναρτήσεις σε αυτά και (γ) ένα επίπεδο εξόδου που παράγει τα τελικά αποτελέσματα. Τα κρυφά επίπεδα αποτελούν τον καθοριστικό παράγοντα που επιτρέπει σε ένα TNΔ να μαθαίνει σύνθετες εργασίες και να επιτυγχάνει εξαιρετικές επιδόσεις.



Εικόνα 10. Τυπική δομή ενός ΤΝΔ.

Ο Perceptron αποτελεί την πιο βασική μορφή νευρωνικού δικτύου, όπως φαίνεται στην Εικόνα 11. Περιλαμβάνει *n* αριθμό εισόδων, έναν μόνο νευρώνα και μια έξοδο. Τα ΤΝΔ κατασκευάζονται με την διασύνδεση πολλαπλών perceptrons σε επίπεδα. Η διαδικασία μετάδοσης των δεδομένων μέσω του νευρωνικού δικτύου αναφέρεται ως προς τα εμπρός διάδοση (forward propagation). Για κάθε είσοδο, η τιμή x_i πολλαπλασιάζεται με τα αντίστοιχα βάρη w_i και τα προϊόντα που προκύπτουν αθροίζονται, ενώ προστίθεται και ένας όρος προκατάληψης (bias). Τα βάρη υποδηλώνουν την ισχύ της σύνδεσης μεταξύ των νευρώνων και καθορίζουν το βαθμό στον οποίο μια δεδομένη είσοδος επηρεάζει την έξοδο του νευρώνα.

$$z = \sum_{i=1}^{n} x_i \cdot w_i + b$$

όπου το n αντιπροσωπεύει τον αριθμό των δεδομένων εισόδου.

Στην συνέχεια, το μέγεθος z εισάγεται σε μια μη γραμμική συνάρτηση ενεργοποίησης, και τελικά η έξοδος εκφράζεται ως εξής.

$$\hat{y} = \sigma(z)$$

Οι μη γραμμικοί μετασχηματισμοί της συνάρτησης ενεργοποίησης στην είσοδο δίνουν την δυνατότητα στο δίκτυο να μαθαίνει και να εκτελεί πιο περίπλοκες διαδικασίες.



Εικόνα 11. Το μοντέλο Perceptron.

Για να καθοριστούν τα βέλτιστα βάρη και προκατάληψη (bias) πρέπει να γνωρίζουμε πως αλλάζει η συνάρτηση κόστους σε σχέση με αυτές τις μεταβλητές. Αυτό γίνεται με την βοήθεια των κλίσεων (gradients), δηλαδή τον ρυθμό μεταβολής ενός μεγέθους σε σχέση με ένα άλλο. Η κλίση της συνάρτησης κόστους *C* σε σχέση με το βάρος w_i προσδιορίζεται με την χρήση μερικών παραγώγων και του κανόνα της αλυσίδας.

$$\frac{\partial C}{\partial w_i} = \frac{\partial C}{\partial \hat{y}} \times \frac{\partial \hat{y}}{\partial z} \times \frac{\partial z}{\partial w_i}$$

Οι ενημερώσεις του βάρους και της προκατάληψης ακολουθούν μια καθορισμένη διαδικασία και η διαδικασία «κατάβασης κλίσης» (gradient descent) επαναλμβάνεται μέχρι την σύγκλιση όπως φαίνεται και στην Εικόνα 12.

$$w_{i} = w_{i} - \left(\varepsilon \times \frac{\partial C}{\partial w_{i}}\right)$$
$$b = b - \left(\varepsilon \times \frac{\partial C}{\partial b}\right)$$



Εικόνα 12. Διαδικασία «κατάβασης κλίσης» (gradient descent)

ΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ – ΑΠΟΤΕΛΕΣΜΑΤΑ

Στην παρούσα διπλωματική εργασία έγινε χρήση του συνόλου δεδομένων για κόπωση από το National Institute of Material Science (NIMS). Το σύνολο αυτό περιλαμβάνει συνθήκες επεξεργασίας και μηχανικά χαρακτηριστικά από κατασκευαστικούς χάλυβες, πειραματικές παραμέτρους καθώς και τον αριθμό των κύκλων φόρτισης μέχρι την αστοχία. Επιπρόσθετα, το σύνολο δεδομένων ενισχύθηκε από μια σειρά πειραμάτων που διεξήχθησαν στο Πανεπιστήμιο του Σταβάνγκερ (UiS) σε χάλυβα τύπου NV D36. Δοκιμάστηκε ένα μεγάλο εύρος τιμών τάσεων σε συχνότητες 5-50 Hz, ενώ τα πειράματα περιλάμβαναν περιπτώσεις μονοαξονικής φόρτισης, καθώς και περιστρεφόμενης στρέψης. Το τελικό φύλλο δεδομένων περιείχε 2794 πειραματικά δεδομένα, με 17 χαρακτηριστικά και 1 ιδιότητα-στόχο, δηλαδή τον αριθμό των κύκλων φόρτισης μέχρι την αστοχία.

Πριν την εφαρμογή των μεθόδων MM και TN, εφαρμόστηκε ένας λογαριθμικός μετασχηματισμός στην ιδιότητα-στόχο, λόγω των πολύ μεγάλων τιμών της σε σχέση με τις υπόλοιπες ιδιότητες. Επιπρόσθετα, οι ακραίες τιμές του συνόλου αντιμετωπίστηκαν με την μέθοδο IQR (Interquartile Range) και εφαρμόστηκαν δύο τεχνικές για την επιλογή των κατάλληλων χαρακτηριστικών για ανάλυση: ανάλυση συσχέτισης (correlation analysis) και ανάλυση αμοιβαίας πληροφορίας (mutual information analysis). Μέσω της ανάλυσης συσχέτισης επιλέγονται τα χαρακτηριστικά που παρέχουν μοναδικού είδους πληροφορίες για το υλικό και την πειραματική διαδικασία, ενώ με την βοήθεια της ανάλυσης αμοιβαίας πληροφορίας επιλέγονται αυτά που

συνδέονται σε μεγαλύτερο βαθμό με την ιδιότητα-στόχο, δηλαδή τους κύκλους φόρτισης μέχρι την αστοχία.

Στην συνέχεια, εφαρμόζονται οι τεχνικές που προαναφέρθηκαν για την πρόβλεψη του αριθμού των κύκλων μέχρι την αστοχία. Αρχικά, υλοποιούνται διαφορετικές αρχιτεκτονικές για το TNΔ, με στόχο την ανάδειξη αυτού με την μεγαλύτερη ακρίβεια. Προκύπτει πως το TNΔ με 4 κρυφά επίπεδα που αποτελούνται από 256 νευρώνες το καθένα, είναι το πιο αποτελεσματικό.

Τέλος, υλοποιούνται και οι υπόλοιπες τεχνικές MM, αφού πρώτα καθοριστούν οι βέλτιστες παράμετροι για το καθένα. Τα αποτελέσματα για κάθε μοντέλο παρουσιάζονται αναλυτικά στον παρακάτω πίνακα. Επιπρόσθετα, παρουσιάζεται ένα διάγραμμα με τις διαφορές μεταξύ προβλεπόμενων και πραγματικών τιμών του λογαρίθμου των κύκλων φόρτισης μέχρι την αποτυχία, για κάθε μοντέλο.

Method	MSE	RMSE	MAE	\mathbb{R}^2
Polynomial Regression	0.071628	0.267635	0.188218	0.730316
SVR	0 070431	0 265389	0 173458	0 734825
	0.070431	0.20000	0.102500	0.75+025
XGB Regression	0.06934	0.263326	0.183799	0.73893
ANN	0.070522	0.265561	0.189114	0.726841

TT /	1 4 17	10 10
Πινακας	Ι Αποτελεσματα	$\lambda 10$ KOHE HOVLEVO
TITTORCOC	1. 1 110 10100 ματα	100 1000 401 10100.



Εικόνα 13. Διάγραμμα σύγκρισης προβλεπόμενων και πραγματικών τιμών για κάθε μοντέλο.

Όλες οι μέθοδοι παρουσιάζουν ικανοποιητική επίδοση, με την Παλινδρόμηση τύπου XGB να επιδεικνύει την μεγαλύτερη αποτελεσματικότητα με τιμή Μέσου Τετραγωνικού Σφάλματος 0.006934. Επιπρόσθετα, η Πολυωνυμική Παλινδρόμηση παρέχει ιδιαίτερα ικανοποιητικά αποτελέσματα, σχεδόν πανομοιότυπα με το Τεχνητό Νευρωνικό Δίκτυο, απαιτώντας σημαντικά λιγότερη υπολογιστική ισχύ. Συνολικά, η προτεινόμενη μεθοδολογία αξιοποιεί αποτελεσματικά τα χαρακτηριστικά των υπό εξέταση χαλύβων, καθώς και τις πειραματικές συνθήκες, ώστε να παρέχει ακριβείς προβλέψεις της εναπομένουσας διάρκειας ζωής λόγω κόπωσης σε κατασκευές.

ΠΙΝΑΚΑΣ ΜΕ ΕΠΕΞΗΓΗΣΕΙΣ ΤΗΣ ΟΡΟΛΟΓΙΑΣ

Αγγλικά	Ελληνικά	
Κόπωση υλικών	Fatigue of materials	
Ισοκαταστροφικές καμπύλες	Isostress curves	
Τεχνητή Νοημοσύνη	Artificial Intelligence	
Μηχανική Μάθηση	Machine Learning	
Πολυωνυμική Παλινδρόμηση	Polynomial Regression	
Παλινδρόμηση Διανυσμάτων Υποστήριξης	Support Vector Regression	
Παλινδρόμηση τύπου XGB	XGB Regression	
Τεχνητό Νευρωνικό Δίκτυο	Artificial Neural Network	
Συνάρτηση πυρήνα	Kernel	
Περιθώριο	Margin	
Υπερπροσαρμογή	Overfitting	
Νευρώνας	Neuron	
Εμπρός Διάδοση	Forward Propagation	
Κατάβαση κλίσης	Gradient Descent	
Ανάλυση συσχέτισης	Correlation analysis	
Ανάλυση αμοιβαίας πληροφορίας	Mutual Information analysis	