



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΒΕΛΤΙΩΣΗ ΜΟΝΤΕΛΟΥ ANFIS ΓΙΑ ΤΗΝ ΠΡΟΒΛΕΨΗ
ΜΗΧΑΝΙΚΩΝ ΙΔΙΟΤΗΤΩΝ ΔΟΚΙΜΙΩΝ ΠΡΟΣΘΕΤΙΚΗΣ
ΚΑΤΑΣΚΕΥΗΣ**

ΜΑΝΤΑΛΑΣ ΕΜΜΑΝΟΥΗΛ-ΜΑΡΙΝΟΣ
ΑΜ:19392205

Οκτώβριος 2024



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**ΒΕΛΤΙΩΣΗ ΜΟΝΤΕΛΟΥ ANFIS ΓΙΑ ΤΗΝ ΠΡΟΒΛΕΨΗ
ΜΗΧΑΝΙΚΩΝ ΙΔΙΟΤΗΤΩΝ ΔΟΚΙΜΙΩΝ ΠΡΟΣΘΕΤΙΚΗΣ
ΚΑΤΑΣΚΕΥΗΣ**

ΜΑΝΤΑΛΑΣ ΕΜΜΑΝΟΥΗΛ-ΜΑΡΙΝΟΣ
ΑΜ:19392205

Επιβλέποντες Καθηγητές
ΖΑΧΑΡΙΑ ΠΑΡΑΣΚΕΥΗ
ΣΑΓΙΑΣ ΒΑΣΙΛΕΙΟΣ
ΣΤΕΡΓΙΟΥ ΚΩΝΣΤΑΝΤΙΝΟΣ

Οκτώβριος 2024

Η Διπλωματική Εργασία έγινε αποδεκτή και βαθμολογήθηκε από την εξής τριμελή επιτροπή:

--	--	--

Περίληψη

Η διπλωματική εξετάζει την ενσωμάτωση τεχνολογιών Προσθετικής Κατασκευής (ΠΚ) με Τεχνητά Νευρωνικά Δίκτυα (ΤΝΔ) και Νευροασαφή Συστήματα (ANFIS) για τη βελτίωση της ακρίβειας, της αποδοτικότητας και των μηχανικών ιδιοτήτων των εξαρτημάτων που εκτυπώνονται με 3D εκτύπωση. Η Προσθετική Κατασκευή, μια διαδικασία δημιουργίας αντικειμένων με την προσθήκη υλικού στρώμα προς στρώμα, έχει φέρει επανάσταση στην παραγωγή πολύπλοκων γεωμετριών σε διάφορες βιομηχανίες. Ωστόσο, η βελτιστοποίηση των μηχανικών ιδιοτήτων και της ακρίβειας των εκτυπωμένων εξαρτημάτων παραμένει μια πρόκληση. Συνδυάζοντας τις ικανότητες μάθησης των ΤΝΔ με την ικανότητα λήψης αποφάσεων της ασαφούς λογικής, το μοντέλο ANFIS μπορεί να βελτιστοποιεί προσαρμοστικά τις παραμέτρους εκτύπωσης για τη βελτίωση της ποιότητας των εξαρτημάτων. Τα πειραματικά δεδομένα που συλλέγονται από τις διαδικασίες ΠΚ χρησιμοποιούνται για την εκπαίδευση του μοντέλου ANFIS, επιτρέποντάς του να προβλέπει αποτελέσματα όπως την τάση, την παραμόρφωση και το μέτρο ελαστικότητας υπό διάφορες συνθήκες εκτύπωσης. Η απόδοση του μοντέλου ANFIS αξιολογείται με τη χρήση δεικτών όπως το μέσο τετραγωνικό σφάλμα (RMSE) και το R-squared (R^2) για να διασφαλιστεί η ακρίβεια και η αξιοπιστία του σε πραγματικές εφαρμογές.

Λέξεις Κλειδιά: ANFIS, Προσθετική Κατασκευή, Νευροασαφή συστήματα, Μηχανικές ιδιότητες, Βελτιστοποίηση

Abstract

The thesis explores the integration of Additive Manufacturing (AM) technologies with Artificial Neural Networks (ANN) and Neuro-Fuzzy Inference Systems (ANFIS) to enhance the precision, efficiency, and mechanical properties of 3D-printed components. Additive Manufacturing, a process of creating objects by adding material layer by layer, has revolutionized the production of complex geometries in various industries. However, optimizing printed parts' mechanical properties and accuracy remains a challenge. By combining the learning capabilities of ANNs with the decision-making prowess of fuzzy logic, the ANFIS model can adaptively refine printing parameters to improve part quality. Experimental data collected from AM processes are used to train the ANFIS model, allowing it to predict outputs such as stress, strain, and deformation under various printing conditions. The performance of the ANFIS model is evaluated using metrics like root mean square error (RMSE) and R-squared (R^2) to ensure its accuracy and reliability in real-world applications.

Keywords: Additive Manufacturing, Artificial Neural Networks, ANFIS, 3D Printing, Mechanical Properties, Optimization, Intelligent Manufacturing Systems

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον Βασίλειο Σαγιά για την συν 'επίβλεψη αυτής της μελέτης. Η εμπειρία του στην Προσθετική Κατασκευή ήταν τόσο επωφελής για την κατανόηση της διαδικασίας. Επίσης τα παρεχόμενα πειραματικά δεδομένα, που επιτηρήθηκαν και διεξήχθησαν από τον ίδιο αποτέλεσαν τη βάση των αναπτυγμένων μοντέλων πρόβλεψης για αυτή τη μελέτη.

Επιπρόσθετα θα ήθελα να εκφράσω την εκτίμησή μου στην Παρασκευή Ζαχαρία, που πέρα από την συν 'επίβλεψη, η υποστήριξή της καθ' όλη τη διάρκεια εκπόνησης αυτής της διπλωματικής ήταν αξιοσημείωτη. Επίσης, θα ήθελα να ευχαριστήσω για την πολύτιμη καθοδήγηση της σχετικά με την δημιουργία και την αξιολόγηση των μοντέλων ANFIS.

Τέλος, με βαθιά ευγνωμοσύνη θέλω να ευχαριστήσω τους γονείς μου για την αμέριστη στήριξή τους καθ' όλη τη διάρκεια της εκπόνησης της διπλωματικής μου. Χωρίς την αγάπη, την κατανόηση και την ενθάρρυνσή τους, δεν θα είχα καταφέρει να φτάσω ως εδώ. Οι συμβουλές και η παρουσία τους ήταν πολύτιμες σε κάθε βήμα αυτής της διαδρομής.

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος ΜΑΝΤΑΛΑΣ ΕΜΜΑΝΟΥΗΛ-ΜΑΡΙΝΟΣ του ΕΥΣΤΡΑΤΙΟΥ, με αριθμό μητρώου 19392205 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανολόγων Μηχανικών, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ο Δηλών



Περιεχόμενα

Λίστα Εικόνων.....	6
Λίστα Διαγραμμάτων	6
1 Εισαγωγή	7
1.1 Αντικείμενο της Διπλωματικής Εργασίας.....	7
1.2 Σκοπός της Διπλωματικής Εργασίας.....	7
2 Προσθετική Κατασκευή.....	7
2.1 Γενικευμένη Διεργασία της Προσθετικής Κατασκευής	8
2.2 Τεχνολογίες Προσθετικής Κατασκευής.....	10
2.3 Εφαρμογές της Προσθετικής Κατασκευής.....	17
3 Τεχνητά Νευρωνικά Δίκτυα & Ασαφή Συστήματα	21
3.1 Κατηγορίες Νευρωνικών Δικτύων	24
3.2 (Νεύρο) Ασαφή Συστήματα – Ασαφής Λογική.....	28
3.3 Adaptive Neuro-Fuzzy Inference System (ANFIS).....	32
3.4 Εφαρμογές των ΤΝΔ & Νευροασαφή Συστημάτων	34
4 Εφαρμογές των ΤΝΔ στην Προσθετική Κατασκευή	36
5 Πειραματική Εφαρμογή.....	39
5.1 Πειραματικά Δεδομένα.....	39
5.2 Μοντέλο ANFIS	40
5.3 Βελτίωση και Αξιολόγηση Μοντέλου	40
6 Εφαρμογή – Μελέτη Περίπτωσης.....	41
6.1 Συλλογή Δεδομένων.....	41
6.2 Κατηγοριοποίηση Δεδομένων.....	42
6.2.1 Επιλογή κατάλληλου σετ (train/check) με χρήση ANFIS	44
6.3 Μοντέλο ANFIS	46
7 Συμπεράσματα - Συζήτηση.....	52
Βιβλιογραφία.....	55
Παράρτημα Α.....	56

Λίστα Εικόνων

Εικόνα 2.1: Γενικευμένη διεργασία AM σε 8 βήματα (Ian Gibson, 2017).....	10
Εικόνα 2.2: Απεικόνιση διαδικασίας FDM (I. John Solomon, 2021).....	11
Εικόνα 2.3: Απεικόνιση διαδικασίας SLA.....	12
Εικόνα 2.4: Απεικόνιση διεργασίας SLS.....	13
Εικόνα 2.5: Απεικόνιση διεργασίας MJ (Dassault Systems)	14
Εικόνα 2.6: Απεικόνιση διεργασίας BJ (Dassault Systems)	15
Εικόνα 2.7: Απεικόνιση διεργασίας DED (Pedersen, 2012).....	16
Εικόνα 2.8: Απεικόνιση διεργασίας SL	17
Εικόνα 2.9: Χρήση AM σε σπόνδυλο	18
Εικόνα 2.10: Απόκομμα αρχαίας προσωπίδας με την χρήση AM (www.artec3d.com/restoring-ancient-roman-mask)	20
Εικόνα 2.11: Καμπάνια Coca-Cola	21
Εικόνα 3.1: Κατηγορίες Εκπαίδευσης MM (Sara Nasiri, 2021)	22
Εικόνα 3.2: Αλγόριθμοι MM (Sara Nasiri, 2021).....	23
Εικόνα 3.3: Διεργασία MLP	24
Εικόνα 3.4: Διεργασία CNN	25
Εικόνα 3.5: Διεργασία RNN	26
Εικόνα 3.6: Διεργασία FNN.....	27
Εικόνα 3.7: Διεργασία DBN σε σύγκριση με την Boltzmann	28
Εικόνα 3.8: ANFIS.....	33
Εικόνα 4.1: The optimization for a femur bone reconstruction case. (a) The bone-scaffold system includes a femur bone, a bone fixation plate, screws and a scaffold. (b) The iteration history for scaffold design during the optimisation process (c) Comparison of the equivalent strains obtained from the initial and optimal designs. (e) The distributions of design variables in the optimised scaffold. (f) Comparison of the equivalent strain contours in the initial and optimal designs. (Chi Wu, 2023).....	37
Εικόνα 5.1: Λογικό Διάγραμμα της πειραματικής διαδικασίας	40
Εικόνα 6.1: Παράδειγμα [Train/Check 0.80 – High/Low 0.70 – Επαναλήψεις 16].....	44

Λίστα Διαγραμμάτων

Διάγραμμα 3-1: Κλασσικά σύνολα	30
Διάγραμμα 3-2: Ασαφή σύνολα	30
Διάγραμμα 3-3: Παραδείγματα συναρτήσεων	31
Διάγραμμα 3-4: FIS.....	32
Διάγραμμα 4-1: : Performance metrics of four different ML models for predicting fatigue of LPBF-AM Ti6Al4V (Yi Min, 2024)	37
Διάγραμμα 6-1: Κανονική Κατανομή για Μέγιστη Τάση (MPa)	43
Διάγραμμα 6-2: Επιλογή σετ για Max. Stress.....	45
Διάγραμμα 6-3: Επιλογή σετ για Max. Strain.....	45
Διάγραμμα 6-4: Επιλογή σετ για Young Modulus	45
Διάγραμμα 6-5: Συναρτήσεις μελών για πρόβλεψη Maximum Stress	47
Διάγραμμα 6-6: Συναρτήσεις μελών για πρόβλεψη Maximum Strain	48
Διάγραμμα 6-7: Συναρτήσεις μελών για πρόβλεψη Young Modulus	49

Διάγραμμα 6-8: Παράμετροι για πρόβλεψη Maximum Stress	50
Διάγραμμα 6-9: Παράμετροι για πρόβλεψη Maximum Strain	51
Διάγραμμα 6-10: Παράμετροι για πρόβλεψη Young Modulus	51

1 Εισαγωγή

1.1 Αντικείμενο της Διπλωματικής Εργασίας

Το αντικείμενο της διπλωματικής εργασίας είναι η ανάπτυξη και εφαρμογή μιας μεθοδολογίας που αξιοποιεί το Νευροασαφές Σύστημα (ANFIS) για τη δημιουργία ενός μοντέλου πρόβλεψης που θα μπορεί να ρυθμίζει σε πραγματικό χρόνο τις παραμέτρους της διαδικασίας AM. Αυτή η προσέγγιση στοχεύει στην αντιμετώπιση των υπάρχοντων προκλήσεων σχετικά με την ακρίβεια, τη συνέπεια και τη μηχανική αντοχή των τρισδιάστατων εκτυπωμένων εξαρτημάτων, ενώ παράλληλα επιδιώκεται η μείωση της ανάγκης για εκτεταμένη μετεπεξεργασία και χειροκίνητες προσαρμογές.

1.2 Σκοπός της Διπλωματικής Εργασίας

Ο κύριος σκοπός αυτής της διπλωματικής εργασίας είναι η διερεύνηση της χρήσης του νευροασαφούς συστήματος (ANFIS) για την πρόβλεψη και βελτίωση των μηχανικών ιδιοτήτων των εξαρτημάτων που παράγονται μέσω τεχνολογιών προσθετικής κατασκευής (AM). Συνδυάζοντας τις μαθησιακές δυνατότητες των Τεχνητών νευρωνικών δικτύων (ΤΝΔ) με τις δυνατότητες λήψης αποφάσεων της ασαφούς λογικής, το μοντέλο ANFIS σχεδιάστηκε για να προσαρμόζει παραμέτρους εκτύπωσης με σκοπό τη βελτίωση της ποιότητας των 3D εκτυπωμένων αντικειμένων. Η μελέτη αυτή στοχεύει στη μείωση της εξάρτησης από μεθόδους δοκιμής και σφάλματος στις κατασκευαστικές διαδικασίες, βελτιώνοντας την ακρίβεια των μηχανικών αποτελεσμάτων και ανοίγοντας το δρόμο για την ανάπτυξη πιο έξυπνων, αυτο-βελτιστοποιούμενων συστημάτων παραγωγής, τα οποία θα μπορούν να βελτιώσουν την παραγωγή βάσει δυναμικών και πολύπλοκων δεδομένων.

2 Προσθετική Κατασκευή

Η προσθετική κατασκευή (Additive Manufacturing) είναι ο γενικός όρος για εκείνες τις τεχνολογίες που ενώνουν διαδοχικά υλικό για την δημιουργία αντικειμένων, όπως καθορίζονται από τα δεδομένα του μοντέλου 3D. Κατά την διάρκεια της ανάπτυξης της τεχνολογίας προσθετικής κατασκευής, έχουν χρησιμοποιηθεί πολλοί διαφορετικοί όροι και ορισμοί, συχνά με αναφορά σε συγκεκριμένους τομείς εφαρμογής. Κατά το πρότυπο ASTM, προσθετική κατασκευή ορίζεται ως η

διαδικασία σύνδεσης υλικών για την κατασκευή εξαρτημάτων μέσω ενός 3D μοντέλου, συνήθως με την μέθοδο προσθήκης ενός στρώματος υλικού επί ενός άλλου και είναι αντίθετη διαδικασία από τις αφαιρετικές μεθοδολογίες κατασκευής και διαμορφωτικής κατασκευής. (ISO/ASTM, 2021)


Η βασική λειτουργία της προσθετικής κατασκευής ότι το κομμάτι δημιουργείται με την διαδοχική πρόσθεση υλικού σε στρώσεις (layers). Το κάθε επίπεδο αντιστοιχεί σε μια λεπτή διατομή (cross-section) του κομματιού που προκύπτει από τα αρχικά δεδομένα CAD. Προφανώς κάθε επίπεδο έχει συγκεκριμένο πάχος, οπότε το δημιουργημένο κομμάτι θα αποτελεί προσέγγιση των αρχικών δεδομένων. Όσο πιο λεπτό είναι το κάθε επίπεδο, τόσο πλησιέστερα προς την αρχική απεικόνιση είναι το τελικά δημιουργημένο κομμάτι. Η λειτουργία όλων των σύγχρονων εμπορικά διαθέσιμων μηχανών προσθετικής κατασκευής στηρίζεται στην στρωματική προσέγγιση, ενώ τα κύρια σημεία διαφοροποίησής τους είναι το υλικό που μπορούν να χρησιμοποιήσουν, καθώς και ο τρόπος με τον οποίο δημιουργούνται και συγκολλούνται μεταξύ τους οι στρώσεις. Οι παραπάνω διαφορές καθορίζουν στοιχεία του τελικού κομματιού, όπως η γεωμετρική ακρίβειά του (accuracy) και οι υλικές και μηχανικές ιδιότητές του. Καθορίζουν, επίσης παράγοντες όπως τον χρόνο κατασκευής, την έκταση της απαιτούμενης μετεπεξεργασίας (post-processing), το μέγεθος της χρησιμοποιούμενης μηχανής, το συνολικό κόστος της μηχανής και της όλης κατασκευαστικής διαδικασίας. (Ian Gibson, 2017)

Από το γεωμετρικό μοντέλο 3D CAD μέχρι το τελικό φυσικό προϊόν της AM μεσολαβούν αρκετά βήματα. Ανάλογα την διαφοροποίηση του προϊόντος η προσθετική κατασκευή εμπεριέχεται με διαφορετικό τρόπο και σε διαφορετικό βαθμό. Στα μικρά σε μέγεθος και σχετικά απλά προϊόντα, η προσθετική κατασκευή χρησιμοποιείται κυρίως για την κατασκευή μοντέλων απεικόνισης της μορφής τους, ενώ στα μεγάλα σε μέγεθος και περισσότερο πολύπλοκα προϊόντα, που παρουσιάζουν μεγαλύτερο τεχνολογικό ενδιαφέρον από τη σκοπιά του μηχανικού, η προσθετική κατασκευή εμπεριέχεται σε πολλές διαφορετικές φάσεις της επαναληπτικής διαδικασίας σχεδιασμού και ανάπτυξής τους. Επιπλέον στις αρχικές φάσεις της διαδικασίας ανάπτυξης ενός προϊόντος, κατά τη διάρκεια των οποίων απαιτούνται αδρά μόνο φυσικά μοντέλα, η προσθετική κατασκευή χρησιμοποιείται μόνο λόγω της κατασκευαστικής ταχύτητά της. Σε επόμενες φάσεις της διαδικασίας τα απαιτούμενα κομμάτια πιθανόν να χρειάζονται προσεκτικό καθάρισμα και μετεπεξεργασία προτού είναι σε θέση να χρησιμοποιηθούν. Στην περίπτωση αυτή η AM είναι χρήσιμη, διότι μπορεί να αντιμετωπίσει οποιαδήποτε μορφολογική πολυπλοκότητα χωρίς χρησιμοποίηση ειδικών εργαλείων.

2.1 Γενικευμένη Διεργασία της Προσθετικής Κατασκευής

Η γενικευμένη διεργασία της AM από ένα σύστημα CAD ως το τελικό κομμάτι συγκεντρώνεται σε 8 βήματα:

- I. CAD: Όλα τα κομμάτια που κατασκευάζονται με AM αρχίζουν από ένα ψηφιακό μοντέλο με το οποίο περιγράφεται η εξωτερική γεωμετρία τους. Προς τούτο μπορεί να χρησιμοποιηθεί σχεδόν οπουδήποτε επαγγελματικό λογισμικό CAD, το αποτέλεσμα του οποίου πρέπει να είναι μια 3D στερεά ή επιφανειακή αναπαράσταση.
- II. Μετατροπή σε αρχείο STL: Σχεδόν όλες οι μηχανές AM δέχονται ως δεδομένα αρχεία της μορφής STL, που έχει καθοριστεί από το πρότυπο ASTM. Το αρχείο αυτό περιγράφει την κλειστή εξωτερική επιφάνεια του αρχικού μοντέλου CAD και αποτελεί την βάση για τον υπολογισμό των στρώσεων.
- III. Μετατροπή σε μηχανή AM και επεξεργασία του αρχείου STL: Το αρχείο STL που περιγράφει το κομμάτι πρέπει να μεταφερθεί στη μηχανή AM. Εδώ, πρέπει το αρχείο να υποστεί μια επεξεργασία, ώστε το κομμάτι να έχει το κατάλληλο μέγεθος για την κατασκευή του, θέση και προσανατολισμό.
- IV. Προετημασία της μηχανής: Η μηχανή AM πρέπει να προετοιμαστεί κατάλληλα, προτού να αρχίσει η διαδικασία κατασκευής. Η προετοιμασία αυτή αναφέρεται σε κατασκευαστικές παραμέτρους όπως είναι οι περιορισμοί που εξαρτώνται από το υλικό κατασκευής, τη συγκεκριμένη πηγή ενέργειας, το πάχος του επιπέδου κλπ.
- V. Κατασκευή: Η κατασκευή του κομματιού είναι κυρίως μια αυτοματοποιημένη διαδικασία που εκτελείται χωρίς ουσιαστική επιτήρηση.
- VI. Απομάκρυνση: Όταν η μηχανή AM ολοκληρώσει την κατασκευή, το κομμάτι πρέπει να απομακρυνθεί από τη μηχανή.
- VII. Μετεπεξεργασία: Όταν τα κομμάτια απομακρυνθούν από την μηχανή, ενδέχεται να μην είναι κατάλληλα για άμεση χρήση και συνεπώς να χρειάζονται επιπλέον καθάρισμα.
- VIII. Εφαρμογή: Σε αυτό το στάδιο τα κομμάτια είναι έτοιμα για χρήση.



Εικόνα 2.1: Γενικευμένη διεργασία AM σε 8 βήματα (Ian Gibson, 2017)


2.2 Τεχνολογίες Προσθετικής Κατασκευής

Οι μηχανές που μπορούν να παράξουν προϊόντα προσθετικής κατασκευής (Additive Manufacturing), περιλαμβάνουν διάφορους τύπους, καθένας από τους οποίους χρησιμοποιεί διαφορετικές τεχνολογίες και υλικά. Οι κατηγορίες διαχωρισμού με βάση το διεθνές πρότυπο είναι οι παρακάτω:

I. Εξώθηση Υλικού - Material Extrusion (FFF/FDM)

Fused Deposition Modeling (FDM) γνωστό και ως Fused Filament Fabrication (FFF) θεωρείται μια τεχνολογία προσθετικής κατασκευής που χρησιμοποιεί την αρχή εξώθησης υλικού, δηλαδή την τήξη ενός θερμοπλαστικού υλικού σε μορφή νήματος και την εναπόθεση του επίπεδο-επίπεδο για να δημιουργηθεί ένα τρισδιάστατο αντικείμενο.

Πιο συγκεκριμένα, το τετηγμένο υλικό εξωθείται μέσω του ακροφυσίου και εναποτίθεται πάνω στην επιφάνεια κατασκευής, ακολουθώντας μια προκαθορισμένη διαδρομή που αντιστοιχεί στη γεωμετρία της διατομής του 3D μοντέλου. Με την ολοκλήρωση κάθε επιπέδου, η επιφάνεια κατασκευής κατεβαίνει ελαφρώς (ή το ακροφύσιο ανεβαίνει), επιτρέποντας στην εναπόθεση του επόμενου επιπέδου πάνω στο προηγούμενο. Καθώς το υλικό εξωθείται, ψύχεται και στερεοποιείται, σχηματίζοντας μια συμπαγή δομή. Η διαδικασία αυτή συνεχίζεται μέχρι να ολοκληρωθεί το αντικείμενο. (I. John Solomon, 2021)



Εικόνα 2.2: Απεικόνιση διαδικασίας FDM (I. John Solomon, 2021)


Η προσθετική κατασκευή με τη μέθοδο FDM προσφέρει πολλά πλεονεκτήματα, όπως το χαμηλό κόστος, την ευκολία χρήσης και τη μεγάλη ποικιλία υλικών. Χρησιμοποιώντας υλικά όπως το PLA, ABS, PETG, TPU και Nylon, μπορούμε να δημιουργήσουμε μια πληθώρα αντικειμένων. Ωστόσο, υπάρχουν και ορισμένοι περιορισμοί, όπως η χαμηλότερη ανάλυση και ακρίβεια σε σύγκριση με άλλες μεθόδους, η ανάγκη για στηρίξεις και η πιθανότητα θερμικής παραμόρφωσης ορισμένων υλικών. Παρά τους περιορισμούς αυτούς, η FDM παραμένει μια δημοφιλής μέθοδος λόγω της ευελιξίας και της προσιτότητάς της.

II. Φωτοπολυμερισμός – Vat Photopolymerization (SLA)

Η στερεολιθογραφία (SLA) είναι μια μέθοδος προσθετικής κατασκευής που χρησιμοποιεί υγρή φωτοπολυμεριζόμενη ρητίνη και ένα UV laser για να δημιουργήσει αντικείμενα υψηλής ακρίβειας και λεπτομέρειας. Φωτοπολυμερή υλικά, θεωρούνται τα πολυμερή τα οποία αλλάζουν τις μηχανικές και χημικές τους ιδιότητες, μέσω μίας χημικής αντίδρασης όταν εκτεθούν στο φως. Ουσιαστικά ένα μόριο φωτοεκκινητή στη ρητίνη ανταποκρίνεται στο εισερχόμενο φως και κατά την ακτινοβολία, τοπικά ενεργοποιεί την αντίδραση χημικού πολυμερισμού, η οποία οδηγεί σε σκλήρυνση μόνο των εκτεθειμένων περιοχών.

Πιο συγκεκριμένα, η SLA λειτουργεί με τη εστίαση μια δέσμης laser σε ένα υγρό φωτοπολυμερές που βρίσκεται σε δεξαμενή. Το laser σαρώνει την επιφάνεια του υγρού, προκαλώντας την επιλεκτική σκλήρυνση του υλικού σύμφωνα με τη

γεωμετρία του κάθε επιπέδου. Η πλατφόρμα κατασκευής κατεβαίνει ελαφρώς, επιτρέποντας στο υγρό φωτοπολυμερές να καλύψει ξανά ολόκληρη την επιφάνεια. Το laser, συνεχίζει να σαρώνει και να σκληραίνει τις επόμενες στρώσεις, επαναλαμβάνοντας την διαδικασία μέχρι να ολοκληρωθεί το αντικείμενο. Στην συνέχεια, το αντικείμενο αφαιρείται από την δεξαμενή και τοποθετείται σε φούρνο UV για περαιτέρω σκλήρυνση, εξασφαλίζοντας την πλήρη στερεοποίησή του. (Pedersen, 2012)




Εικόνα 2.3: Απεικόνιση διαδικασίας SLA

Η προσθετική κατασκευή με φωτοπολυμεριζόμενες ρητίνες προσφέρει εξαιρετικά αποτελέσματα, δημιουργώντας αντικείμενα με υψηλή ανάλυση και λεπτομέρεια, ιδανικά για περίπλοκες γεωμετρίες. Η επιφάνεια των εκτυπωμένων αντικειμένων είναι συνήθως πολύ λεία, χωρίς εμφανή σημάδια στρώσεων. Η διαθεσιμότητα μιας μεγάλης ποικιλίας ρητινών επιτρέπει την προσαρμογή των ιδιοτήτων του τελικού προϊόντος, όπως η σκληρότητα, η ελαστικότητα και η αντοχή στη θερμότητα. Ωστόσο, αυτή η τεχνολογία συνοδεύεται από ορισμένα μειονεκτήματα, όπως το υψηλότερο κόστος σε σύγκριση με την FDM, την ευθραυστότητα των υλικών και την ανάγκη για επιπλέον επεξεργασία μετά την εκτύπωση. Επιπλέον, τα εκτυπωμένα αντικείμενα μπορεί να έχουν περιορισμένη αντοχή σε αντίξοες περιβαλλοντικές συνθήκες.

III. Σύντηξη πούδρας σε σκόνη – Powder Bed Fusion (SLS, DMLS)

Η Selective Laser Sintering (SLS) είναι μια τεχνολογία προσθετικής κατασκευής, η οποία χρησιμοποιεί laser για να συγχωνεύσει πούδρες πολυμερών, μετάλλων ή κεραμικών και με την διεργασία της πυροσυσσωμάτωσης να δημιουργεί 3D αντικείμενα.

Η διαδικασία εκτύπωσης γίνεται ως εξής : Αρχικά, ένα λεπτό στρώμα πούδρας απλώνεται πάνω στην πλατφόρμα κατασκευής και το laser σαρώνει την επιφάνεια, επιλεκτικά θερμαίνοντας και συντήκοντας τα σωματίδια σκόνης στα σημεία που αντιστοιχούν στο τμήμα του κάθε επιπέδου του αντικειμένου. Μόλις ολοκληρωθεί η σύντηξη του πρώτου επιπέδου, η πλατφόρμα κατασκευής κατεβαίνει ελαφρώς και ένα νέο στρώμα πούδρας απλώνεται πάνω στην επιφάνεια. Η διαδικασία επαναλαμβάνεται μέχρι να ολοκληρωθεί η κατασκευή του αντικειμένου. Μετά την εκτύπωση, το αντικείμενο αφαιρείται από την πλεονάζουσα πούδρα, η οποία μπορεί να ανακυκλωθεί και να χρησιμοποιηθεί σε επόμενες εκτυπώσεις. (Ian Gibson, 2017)



Εικόνα 2.4: Απεικόνιση διεργασίας SLS


Η προσθετική κατασκευή με τη μέθοδο SLS προσφέρει τη δυνατότητα δημιουργίας ανθεκτικών και λειτουργικών τελικών αντικειμένων χρησιμοποιώντας μια ποικιλία υλικών όπως το Nylon, TPU, ανοξείδωτο ατσάλι, τιτάνιο, αλουμίνιο και διάφορα κράματα. Η απουσία στηρίξεων επιτρέπει την παραγωγή πολύπλοκων γεωμετριών σε σύντομο χρονικό διάστημα. Επιπλέον, η περίσσεια σκόνης μπορεί να ανακυκλωθεί, συμβάλλοντας στη μείωση του κόστους παραγωγής. Ωστόσο, η μέθοδος αυτή απαιτεί υψηλότερο αρχικό κόστος εξοπλισμού και υλικών σε σύγκριση με την FDM. Επιπλέον, τα εκτυπωμένα αντικείμενα μπορεί να απαιτούν επιπλέον επεξεργασία για την βελτίωση της επιφανειακής τους υφής και η διαδικασία εκτύπωσης απαιτεί υψηλές θερμοκρασίες, αυξάνοντας τις απαιτήσεις συντήρησης του εξοπλισμού.

IV. Εναπόθεση υλικού – Material Jetting (MJ)

Η τεχνολογία εναπόθεση υλικού MJ είναι μια μέθοδος προσθετικής κατασκευής που λειτουργεί με τρόπο που θυμίζει έναν συμβατικό εκτυπωτή inject. Σε αυτή τη διαδικασία, σταγονίδια υλικού εκτοξεύονται και κατατίθενται επίπεδο – επίπεδο

πάνω σε μια επιφάνεια κατασκευής, δημιουργώντας το αντικείμενο σύμφωνα με το 3D μοντέλο.

Η MJ λειτουργεί εκτοξεύοντας μικροσκοπικά σταγονίδια υγρού φωτοπολυμερούς από πολυάριθμες κεφαλές εκτύπωσης, τα οποία κατατίθενται επίπεδο – επίπεδο πάνω στην επιφάνεια κατασκευής. Καθώς το υλικό κατατίθεται, εκτίθεται αμέσως σε υπεριώδες (UV) φως, που το σκληραίνει και το μετατρέπει σε στερεό. Αυτή η διαδικασία επαναλαμβάνεται για κάθε επίπεδο μέχρι την ολοκλήρωση του αντικειμένου. Παράλληλα, εκτυπώνονται και στηρίξεις για να υποστηρίξουν τις πιο περίπλοκες γεωμετρίες, τα οποία αφαιρούνται εύκολα μετά την εκτύπωση. Μετά την ολοκλήρωση, το αντικείμενο μπορεί να απαιτεί καθαρισμό και επιπλέον σκλήρυνση όπως στην SLA για την τελική βελτίωση των μηχανικών του ιδιοτήτων. (Pedersen, 2012)




Εικόνα 2.5: Απεικόνιση διεργασίας MJ (Dassault Systems)

Η προσθετική κατασκευή με τη μέθοδο MJ προσφέρει υψηλή ανάλυση και εξαιρετική ποιότητα επιφάνειας, καθιστώντας την ιδανική για την παραγωγή αντικειμένων με λεπτομερή χαρακτηριστικά. Όπως και στην SLA (Stereolithography), χρησιμοποιούνται διάφορες φωτοπολυμεριζόμενες ρητίνες, επιτρέποντας την προσαρμογή των ιδιοτήτων του τελικού προϊόντος ανάλογα με την εφαρμογή. Παρόλα αυτά, η μέθοδος MJ ενέχει και ορισμένα μειονεκτήματα. Το υψηλότερο κόστος εξοπλισμού και υλικών σε σύγκριση με την FDM καθιστά την MJ μια πιο εξειδικευμένη λύση. Επιπλέον, τα υλικά που χρησιμοποιούνται στην MJ μπορεί να μην προσφέρουν τις ίδιες μηχανικές ιδιότητες με τα υλικά που χρησιμοποιούνται σε άλλες μεθόδους, όπως η SLS ή η FDM. Τέλος, η εκτύπωση πολύπλοκων γεωμετριών μπορεί να είναι χρονοβόρα.

V. Εναπόθεσης συγκολλητικής ουσίας – Binder Jetting (BJ)

Η τεχνολογία εναπόθεσης συγκολλητικής ουσίας BJ είναι μια μέθοδος προσθετικής κατασκευής που λειτουργεί με τον ίδιο τρόπο όπως η MJ, με την μόνη διαφορά ότι αντί να εκτοξεύονται σταγονίδια υλικού από τα ακροφύσια, εδώ εκτοξεύεται η συγκολλητική ουσία.

Η BJ λειτουργεί με την εκτόξευση σταγονιδίων συνδετικού υλικού πάνω σε λεπτά στρώματα σκόνης, τα οποία απλώνονται διαδοχικά σε μια επιφάνεια κατασκευής. Το συνδετικό υλικό ενώνει τα σωματίδια σκόνης στα επιλεγμένα σημεία, δημιουργώντας επίπεδο προς επίπεδο τη γεωμετρία του αντικειμένου. Μόλις ολοκληρωθεί η εκτύπωση, το αντικείμενο βρίσκεται μέσα σε περίσσεια σκόνης, η οποία αφαιρείται, και το αντικείμενο μπορεί να υποστεί πρόσθετη επεξεργασία, όπως θερμική κατεργασία για αύξηση της μηχανικής αντοχής ή εμποτισμό με ρητίνες για βελτίωση της επιφάνειας. (Ian Gibson, 2017)




Εικόνα 2.6: Απεικόνιση διεργασίας BJ (Dassault Systems)

Η τρισδιάστατη εκτύπωση με τη μέθοδο Binder Jetting προσφέρει σημαντικά πλεονεκτήματα όπως την ταχεία παραγωγή μεγάλων και πολύπλοκων αντικειμένων, τη δυνατότητα χρήσης μιας ευρείας γκάμας υλικών, όπως μέταλλα, κεραμικά, πολυμερή και άμμο, και την απουσία ανάγκης για θερμική ενέργεια κατά τη διαδικασία εκτύπωσης. Ωστόσο, υπάρχουν και ορισμένα μειονεκτήματα. Η μέθοδος αυτή παράγει αντικείμενα με πορώδη υφή, απαιτώντας επιπλέον επεξεργασία για την αύξηση της αντοχής τους. Επιπλέον, η συγκέντρωση μικρών σωματιδίων σκόνης γύρω από το εκτυπωμένο αντικείμενο απαιτεί προσεκτικό καθαρισμό. Τέλος, τα υλικά που χρησιμοποιούνται στην Binder Jetting μπορεί να μην προσφέρουν τις ίδιες μηχανικές ιδιότητες με τα υλικά που χρησιμοποιούνται σε άλλες μεθόδους, όπως η SLS ή η FDM.

VI. Εναπόθεσης με κατευθυνόμενη ενεργειακή δέσμη – Direct Energy Deposition (LENS, LBMD)

Η τεχνολογία με κατευθυνόμενη ενεργειακή δέσμη άμεση εναπόθεση ενέργειας ορίζεται στο πρότυπο ως «διαδικασία κατά την οποία η εστιασμένη θερμική ενέργεια χρησιμοποιείται για τη σύντηξη υλικών με τήξη καθώς εναποτίθενται» (ISO/ASTM, 2021). Η «εστιασμένη θερμική ενέργεια» μπορεί να ερμηνευθεί ως μια γενική πηγή ενέργειας όπως ένα laser, πλάσμα ή δέσμη ηλεκτρονίων. Η διαδικασία που βασίζεται σε laser είναι η πιο γνωστή και αποτελεί εξέλιξη των τεχνολογιών συγκόλλησης.

Η μέθοδος λειτουργεί αρχικά με την εναπόθεση υλικού σε μορφή σκόνης ή νήματος σε συγκεκριμένα σημεία. Έπειτά χρησιμοποιώντας μία εστιασμένη πηγή ενέργειας, όπως ένα λέιζερ ή μία δέσμη ηλεκτρονίων ή ένα τόξο πλάσματος, το υλικό τήκεται την ίδια στιγμή που εναποτίθεται από ένα ακροφύσιο. Αυτή η διαδικασία επαναλαμβάνεται μέχρι να στερεοποιηθούν τα στρώματα και τελικά να δημιουργήσουν ένα τρισδιάστατο αντικείμενο. (Carbajo, 2024)




Εικόνα 2.7: Απεικόνιση διεργασίας DED (Pedersen, 2012)

Η τρισδιάστατη εκτύπωση με τη μέθοδο DED (Direct Energy Deposition) προσφέρει σημαντικά πλεονεκτήματα όπως η παραγωγή αντικειμένων με εξαιρετική μηχανική αντοχή λόγω της συγκόλλησης του υλικού, η μεγάλη ευελιξία στη χρήση διαφόρων υλικών, συμπεριλαμβανομένων μετάλλων, πολυμερών και κεραμικών, και η σχετική ευκολία στην επιδιόρθωση και συντήρηση του εξοπλισμού. Ωστόσο, υπάρχουν και ορισμένα μειονεκτήματα. Το υψηλό κόστος απόκτησης και λειτουργίας του εξοπλισμού την καθιστά μια ακριβότερη λύση σε σύγκριση με άλλες μεθόδους. Επιπλέον, η ακρίβεια κατασκευής των εκτυπωμένων αντικειμένων μπορεί να είναι χαμηλότερη σε σχέση με άλλες τεχνολογίες. Τέλος, η διαδικασία εκτύπωσης DED

είναι πολύπλοκη και απαιτεί εξειδικευμένες γνώσεις για τη ρύθμιση των πολλών παραμέτρων που επηρεάζουν το τελικό αποτέλεσμα.

VII. Διεργασίες επάλληλων φύλλων – Sheet Lamination (LOM,UAM)

Η τεχνολογία Sheet Lamination είναι μια προσθετική κατασκευαστική διαδικασία που βασίζεται στη συγκόλληση λεπτών στρωμάτων υλικού, συνήθως σε μορφή φύλλων, τα οποία τοποθετούνται το ένα πάνω στο άλλο για να δημιουργήσουν το τελικό αντικείμενο. Η συγκόλληση των φύλλων γίνεται μέσω θερμότητας, πίεσης, ή συγκολλητικών ουσιών, και στη συνέχεια κόβονται στο επιθυμητό σχήμα χρησιμοποιώντας τεχνικές όπως laser cut ή μηχανική κατεργασία.



Εικόνα 2.8: Απεικόνιση διεργασίας SL

Η LOM είναι μια τεχνολογία τρισδιάστατης εκτύπωσης που προσφέρει υψηλή ακρίβεια και λεπτομέρεια στην κατασκευή αντικειμένων, επιτρέποντας τη χρήση μιας ευρείας γκάμας υλικών όπως μέταλλα, κεραμικά, πλαστικά και σύνθετα υλικά. Είναι ιδανική για την παραγωγή πρωτοτύπων και εξατομικευμένων προϊόντων, όπως ιατρικά εμφυτεύματα. Ωστόσο, το υψηλό κόστος του εξοπλισμού και των υλικών, καθώς και οι περιορισμοί στο πάχος των φύλλων, αποτελούν σημαντικά μειονεκτήματα. Επιπλέον, η ανάγκη για υποστήριξη κατά τη διάρκεια της εκτύπωσης μπορεί να αυξήσει την πολυπλοκότητα της διαδικασίας. (Pedersen, 2012)


2.3 Εφαρμογές της Προσθετικής Κατασκευής

Οι τεχνολογίες προσθετικής κατασκευής χρησιμοποιούνται σήμερα για διάφορες εφαρμογές στη βιομηχανία μηχανικής καθώς και σε άλλους τομείς της κοινωνίας, όπως η ιατρική, η εκπαίδευση, η αρχιτεκτονική, η χαρτογραφία, τα παιχνίδια και η ψυχαγωγία.

Ιατρική / Οδοντιατρική

Στην ιατρική, οι προσθετικές κατασκευές χρησιμοποιούνται για την παραγωγή εξατομικευμένων προσθετικών μελών, οδοντικών εμφυτευμάτων, οδοντικών συσκευών και χειρουργικών εργαλείων. Τα τεχνητά μέλη γίνονται απόλυτα παραμετροποιήσιμα και παρέχουν εξατομικευμένες λύσεις, οι οποίες σχεδιάζονται πάνω στον ασθενή και προσομοιάζουν τον κάθε μυ. Τα υλικά που χρησιμοποιούνται είναι κυρίως τιτάνιο, ανθρακόνημα και ABS.

Οι 3D εκτυπωτές μπορούν να δημιουργήσουν βιοσυμβατά υλικά που προσαρμόζονται στις ατομικές ανάγκες των ασθενών, στοχεύοντας στην ανάπτυξη ζωντανών ιστών ή οργάνων και βελτιώνοντας έτσι την ποιότητα ζωής και την αποτελεσματικότητα των θεραπειών. Επίσης, η δυνατότητα εκτύπωσης μοντέλων οργάνων για χειρουργική προετοιμασία επιτρέπει στους γιατρούς να σχεδιάσουν και να εξασκηθούν σε πολύπλοκες επεμβάσεις, μειώνοντας τον κίνδυνο και τον χρόνο χειρουργικής επέμβασης.



Εικόνα 2.9: Χρήση AM σε σπόνδυλο


Βιομηχανικές κατασκευές / Prototyping

Οι εφαρμογές του 3D printing στη βιομηχανία και στο prototyping έχουν επεκταθεί σημαντικά τα τελευταία χρόνια, προσφέροντας νέες δυνατότητες και αυξημένη αποτελεσματικότητα στην παραγωγή και ανάπτυξη προϊόντων. Στον τομέα της βιομηχανικής κατασκευής, χρησιμοποιείται κυρίως για τη δημιουργία προτύπων, εξαρτημάτων και εργαλείων με αυξημένη ταχύτητα και μειωμένο κόστος. Οι μηχανικοί και οι σχεδιαστές μπορούν να παράγουν ακριβή πρωτότυπα μοντέλα και να τα δοκιμάσουν πριν την τελική κατασκευή, εξοικονομώντας χρόνο και πόρους.

Μια από τις βασικές εφαρμογές του 3D printing είναι στο rapid prototyping. Οι εταιρείες μπορούν να δημιουργούν πρωτότυπα προϊόντων σε λίγες ώρες, αντί για

εβδομάδες, και να τα εξετάζουν λειτουργικά και αισθητικά. Αυτή η διαδικασία επιταχύνει σημαντικά την έρευνα και ανάπτυξη, ενώ διευκολύνει την αλλαγή σχεδίων με βάση την αξιολόγηση των πελατών ή άλλες δοκιμές.

Επιπλέον, το 3D printing χρησιμοποιείται για τη δημιουργία εξατομικευμένων εξαρτημάτων και εργαλείων σε γραμμές παραγωγής. Η προσαρμοστικότητα της τεχνολογίας επιτρέπει την παραγωγή εξαρτημάτων με μοναδικά γεωμετρικά χαρακτηριστικά, τα οποία δεν θα μπορούσαν να κατασκευαστούν με τις παραδοσιακές μεθόδους. Αυτό βοηθάει ιδιαίτερα στις μικρές παραγωγές όπου το κόστος δημιουργίας παραδοσιακών καλουπιών είναι απαγορευτικό. (D.M.C. Santos, 2005)



Σε βιομηχανικές κατασκευές, το AM έχει εφαρμογή και στην παραγωγή ελαφρύτερων υλικών, ειδικά στον τομέα της αεροναυπηγικής και της αυτοκινητοβιομηχανίας. Τα σύνθετα υλικά που χρησιμοποιούνται μπορούν να παράγουν ανθεκτικά αλλά ταυτόχρονα ελαφριά εξαρτήματα, βελτιώνοντας την απόδοση και μειώνοντας το κόστος καυσίμων. Τέλος, ενισχύει τη μαζική προσαρμογή (mass customization), επιτρέποντας στις βιομηχανίες να κατασκευάζουν προϊόντα που προσαρμόζονται στις ακριβείς ανάγκες των πελατών, χωρίς να χρειάζεται να διακόψουν τη γραμμή παραγωγής.

Αρχαιολογία / Διατήρηση Πολιτιστικής Κληρονομιάς

Κάθε αρχαιολογικός χώρος περιέχει ένα πλούτο πληροφοριών σχετικά με το παρελθόν, και το περιβάλλον είναι το κλειδί. Ένα μαχαίρι που βρέθηκε δίπλα από ένα πέτρινο τζάκι έχει να μας πει μια διαφορετική ιστορία από ένα που βρέθηκε δίπλα σε έναν ανθρώπινο σκελετό. Δυστυχώς, οι ανασκαφές που γίνονται σε μια περιοχή για να αποκαλύψουν την ιστορία της, την καταστρέφουν επίσης. Οι λεπτομερείς καταγραφές είναι ο μόνος τρόπος οι αρχαιολόγοι να κρατήσουν την αρχαιολογία μακριά από τη διαγραφή του παρελθόντος και να επιτρέψουν τη διατήρησή του. Σήμερα, η 3D σάρωση και η ψηφιακή μοντελοποίηση σε συνδυασμό

με τις τεχνολογίες 3D εκτύπωσης βοηθούν τους αρχαιολόγους να τεκμηριώσουν και να διατηρήσουν τις πληροφορίες που βρίσκονται σε μια τοποθεσία.

Οι ιστορικοί μπορούν τώρα να εισάγουν τα πρωτότυπα σχέδια είτε με 3D σάρωση είτε με άμεσο 3D modeling σε ηλεκτρονικούς υπολογιστές και να ελέγξουν τον σχεδιασμό με λογισμικό CAD, και έπειτα με τη χρήση 3D εκτυπωτών ιστορικά μνημεία, κτίρια, αγάλματα, έργα τέχνης και κάθε είδους τρισδιάστατα αντικείμενα μπορούν να αναδημιουργηθούν κομμάτι-κομμάτι και στρώμα με στρώμα χρησιμοποιώντας τη διαδικασία της προσθετικής κατασκευής. Επειδή η τεχνολογία μπορεί να χρησιμοποιήσει μια ποικιλία από χρώματα και υφές, συγκεκριμένα δείγματα τα είδη πέτρας μπορούν να αναπαραχθούν με ακρίβεια

Μουσεία και άλλα ακαδημαϊκά ιδρύματα επίσης οφελούνται. Η τεχνολογία προσφέρει ευκολότερη επισκευή και τεχνικές διατήρησης για κατεστραμμένα αρχαία αντικείμενα. Ακριβή αντίγραφα επίσης θα μπορούσαν να εμφανίζονται στην θέσεις των αντικειμένων που είναι πολύ εύθραυστα για να μείνουν σε μόνιμη έκθεση.



Εικόνα 2.10: Απόκομμα αρχαίας προσωπίδας με την χρήση AM (www.artec3d.com/restoring-ancient-roman-mask)

Ψυχαγωγία / Διαφήμιση

Ο κλάδος της Ψυχαγωγίας και εκείνος της Διαφήμισης έχουν ορισμένα κοινά χαρακτηριστικά. Ένα από τα βασικά τους είναι ότι για να πετύχουν το στόχο τους, πρέπει να εντυπωσιάσουν μέσα από την καινοτομία. Αυτή τη διαφορετικότητα την παρέχει τώρα απλόχερα η τρισδιάστατη εκτύπωση.

Το 3D printing υπάρχει ως τεχνική και τεχνολογία από τα πρώτα 80s, αλλά για να ενταχθεί στον κόσμο του business πέρασε αρκετός καιρός. Το Hollywood και η Coca Cola είναι από τους πρώτους που το χρησιμοποίησαν για διαφήμιση.

Χαρακτηριστικό ήταν το Coca Cola project που λεγόταν "mini me award", έτρεχε ως καμπάνια στο Ισραήλ.

Η καμπάνια «Mini-Me» της Coca-Cola μετέτρεψε τους πελάτες σε μινιατούρες εκδοχές του εαυτού τους. Οι νικητές συμμετέχοντες σαρώθηκαν και εκτυπώθηκαν σε 3D χρησιμοποιώντας την πιο σύγχρονη τεχνολογία σάρωσης. Οι νικητές τοποθετήθηκαν σε μια περιστρεφόμενη βάση σε ένα προσωρινό εργαστήριο, ενώ έπαιρναν μια πόζα. (Lam, 2013)

Το συγκεκριμένο project ήταν ιδιαίτερα δημοφιλές σε σούπερ μάρκετ και σε αγορές της Μεγάλης Βρετανίας αργότερα. Άλλες εταιρείες που αξιοποίησαν τις τεχνολογίες προσθετικής κατασκευής ως πρακτική marketing είναι οι Warner Bros., eBay, Volkswagen και όχι μόνο.



Εικόνα 2.11: Καμπάνια Coca-Cola

3 Τεχνητά Νευρωνικά Δίκτυα & Ασαφή Συστήματα

Τα συστήματα τεχνητής νοημοσύνης (TN), γενικά, είναι μηχανικά συστήματα που παράγουν αποτελέσματα όπως περιεχόμενο, προβλέψεις, συστάσεις ή αποφάσεις για ένα δεδομένο σύνολο στόχων που καθορίζονται κυρίως από κάποιον ανθρώπινο παράγοντα.

Κλάδο της τεχνητής νοημοσύνης αποτελεί η μηχανική μάθηση, η οποία χρησιμοποιεί υπολογιστικές τεχνικές για να επιτρέψει στα συστήματα να μάθουν μέσα από δεδομένα. Με άλλα λόγια, τα συστήματα μηχανικής μάθησης αναπτύσσονται μέσω της βελτιστοποίησης αλγορίθμων ώστε να ταιριάζουν στα δεδομένα εκπαίδευσης ή να βελτιώσουν την απόδοσή τους. Οι μέθοδοι μηχανικής

μάθησης περιλαμβάνουν και το κομμάτι της βαθιάς μάθησης (Deep Learning). (ISO/IEC, 2022)

Η μηχανική μάθηση χωρίζεται σε τρεις κατηγορίες εκπαίδευσης, ανάλογα τις διαφορετικές λειτουργίες που λαμβάνουν τα δεδομένα της.

I. Εποπτευόμενη Μάθηση (Supervised Learning)

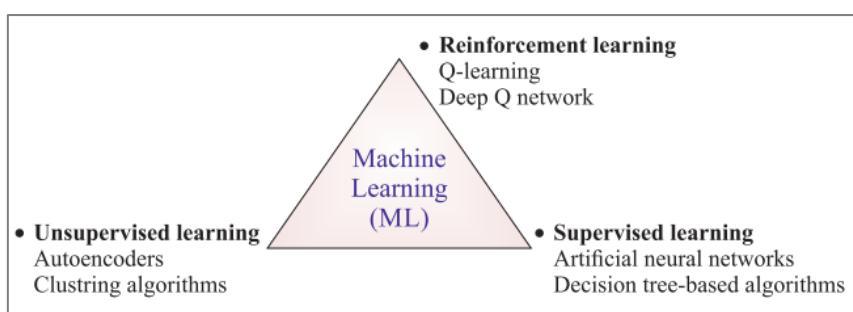
Η εποπτευόμενη μάθηση περιλαμβάνει την εκπαίδευση ενός αλγορίθμου με τη χρήση δεδομένων που είναι ομαδοποιημένα, δηλαδή κάθε παράδειγμα εκπαίδευσης συνοδεύεται από το σωστό αποτέλεσμα ή την κατηγορία στην οποία ανήκει. Ο στόχος είναι να μάθει ο αλγόριθμος τη συσχέτιση ανάμεσα στα χαρακτηριστικά των δεδομένων και στις αντίστοιχες ομάδες έτσι ώστε να μπορεί να προβλέπει τη σωστή ετικέτα για νέα, άγνωστα δεδομένα.

II. Μη Εποπτευόμενη Μάθηση (Unsupervised Learning)

Η μη εποπτευόμενη μάθηση περιλαμβάνει την εκπαίδευση ενός αλγορίθμου με δεδομένα που δεν έχουν ομαδοποιηθεί, δηλαδή δεν υπάρχουν προκαθορισμένα σωστά αποτελέσματα. Ο αλγόριθμος προσπαθεί να βρει μοτίβα ή δομές μέσα στο δεδομένα, όπως ομάδες ή συσχετίσεις, χωρίς να έχει εξωτερική καθοδήγηση.

III. Ενισχυτική Μάθηση (Reinforcement Learning)

Η ενισχυτική μάθηση βασίζεται στην αλληλεπίδραση του αλγορίθμου με το περιβάλλον του. Ο αλγόριθμος μαθαίνει μέσω της διαδικασίας δοκιμής και σφάλματος (trial and error), λαμβάνοντας ενέργειες που επηρεάζουν το περιβάλλον και στη συνέχεια λαμβάνοντας ανατροφοδότηση με τη μορφή επιβράβευσης ή επίπληξης. Ο στόχος είναι να μεγιστοποιηθεί η συνολική επιβράβευση μακροπρόθεσμα.



Εικόνα 3.1: Κατηγορίες Εκπαίδευσης ΜΜ (Sara Nasiri, 2021)

Στην κατασκευή ενός συστήματος μηχανικής μάθησης, η επιλογή ενός κατάλληλου αλγορίθμου είναι ένα κρίσιμο ζήτημα, καθώς κάθε αλγόριθμος έχει σημαντική επίδραση στην ακρίβεια του αποτελέσματος. Κάθε αλγόριθμος έχει τα δικά του πλεονεκτήματα για μια συγκεκριμένη εφαρμογή και δεν υπάρχει αλγόριθμος που να είναι κατάλληλος για όλα τα προβλήματα. Οι ευρέως χρησιμοποιούμενοι αλγόριθμοι

μηχανικής μάθησης στην μηχανολογία μπορούν να χωριστούν στις ακόλουθες κατηγορίες: i) παλινδρόμηση (regression), ii) εκτίμηση (estimation), iii) ταξινόμηση (classification) και iv) ομαδοποίηση (clustering). (Sara Nasiri, 2021)

I. Παλινδρόμηση (Regression)

Η παλινδρόμηση χρησιμοποιείται για την πρόβλεψη μιας συνεχούς εξαρτημένης μεταβλητής, δηλαδή τιμές που κυμαίνονται σε ένα συνεχές φάσμα όπως παραδείγματος χάρη η θερμοκρασία, σε σχέση με μία ή περισσότερες ανεξάρτητες μεταβλητές.

II. Εκτίμηση (Estimation)

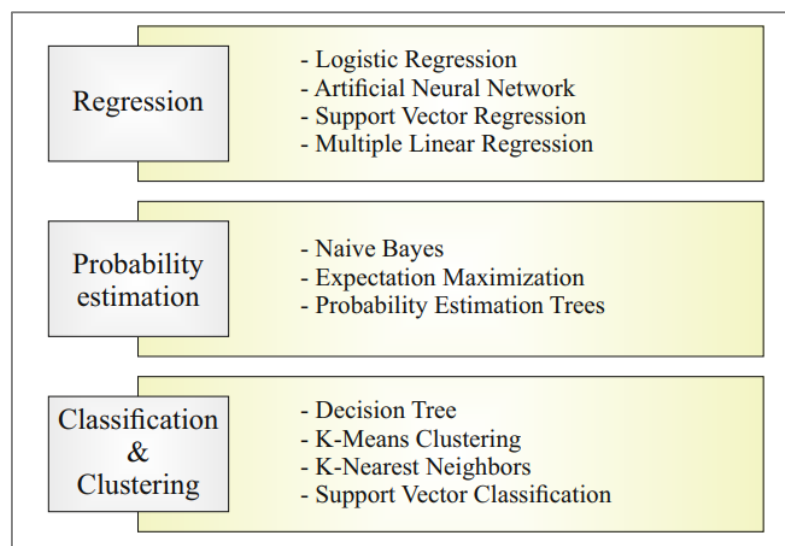
Ο αλγόριθμος εκτίμησης αφορά την πρόβλεψη παραμέτρων ή την εύρεση κατανομών για τα δεδομένα, χωρίς να απαιτείται κάποια καθορισμένη εξαρτημένη μεταβλητή. Στόχος του είναι η κατανόηση της δομής των δεδομένων και η εκτίμηση των παραμέτρων ενός μοντέλου.

III. Ταξινόμηση (Classification)

Η ταξινόμηση χρησιμοποιείται για την κατηγοριοποίηση δεδομένων σε μία ή περισσότερες διακριτές κλάσεις ή κατηγορίες, με βάση τα χαρακτηριστικά των δεδομένων.

IV. Ομαδοποίηση (Clustering)

Η αλγόριθμος αυτός αφορά την ομαδοποίηση δεδομένων, παρατηρήσεων ή αντικειμένων με βάση την ομοιότητά τους ή άλλα κοινά χαρακτηριστικά.



Εικόνα 3.2: Αλγόριθμοι ΜΜ (Sara Nasiri, 2021)


3.1 Κατηγορίες Νευρωνικών Δικτύων

Η μηχανική μάθηση και τα νευρωνικά δίκτυα είναι στενά συνδεδεμένα, καθώς τα νευρωνικά δίκτυα αποτελούν μια υποκατηγορία αλγορίθμων μηχανικής μάθησης που είναι εμπνευσμένα από τη δομή και λειτουργία του ανθρώπινου εγκεφάλου και αποτελούνται από ένα σύνολο συνδεδεμένων τεχνητών νευρώνων. Εκπαιδεύονται μέσω εποπτευόμενης μάθησης για να προσεγγίζουν σύνθετες συναρτήσεις, αναγνωρίζοντας μη γραμμικά μοτίβα στα δεδομένα. Οι πιο συνηθισμένοι τύποι ΤΝΔ είναι οι παρακάτω:

I. Πολυστρωματικά Δίκτυα Πρόσθιας Τροφοδότησης (MLP)

Η μέθοδος MLP είναι ένας τύπος πλήρως συνδεδεμένου νευρωνικού δικτύου, όπου κάθε νευρώνας ενός στρώματος συνδέεται με κάθε νευρώνα του επόμενου στρώματος.

Ένα MLP, αποτελείται από τρία βασικά είδη στρωμάτων: το εισαγωγικό στρώμα, ένα ή περισσότερα κρυφά στρώματα και το στρώμα εξόδου. Το εισαγωγικό στρώμα λαμβάνει τα δεδομένα εισόδου, όπου κάθε νευρώνας αντιπροσωπεύει ένα χαρακτηριστικό του συνόλου δεδομένων. Τα κρυφά στρώματα αποτελούνται από νευρώνες που είναι πλήρως συνδεδεμένοι με τους νευρώνες του προηγούμενου στρώματος και κάθε νευρώνας εκτελεί ένα γραμμικό συνδυασμό των εισόδων του, ακολουθούμενος από μια μη γραμμική συνάρτηση ενεργοποίησης. Το στρώμα εξόδου παράγει την τελική πρόβλεψη του δικτύου, είτε πρόκειται για ταξινόμηση είτε για παλινδρόμηση.



Εικόνα 3.3: Διεργασία MLP

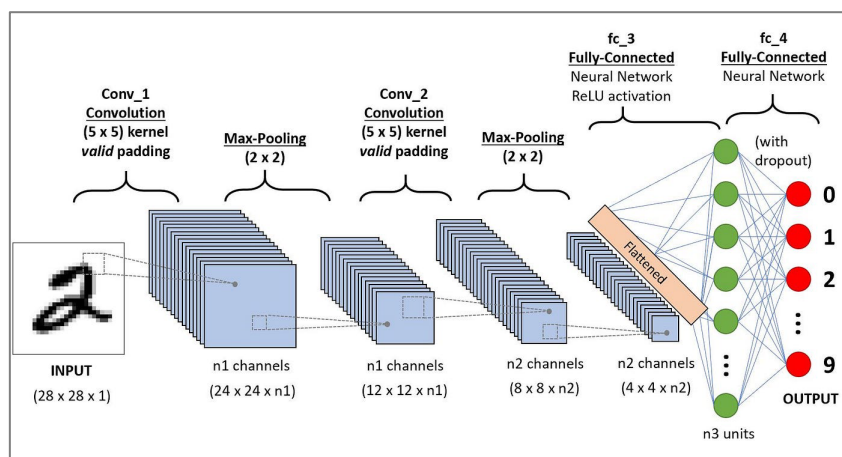
Η δομή ενός MLP επιτρέπει στο δίκτυο να μάθει σύνθετες σχέσεις στα δεδομένα, καθώς τα κρυφά στρώματα δρουν ως αφαιρετικά φίλτρα που εξαγουν χαρακτηριστικά σε διαφορετικά επίπεδα αφαίρεσης. Το MLP μαθαίνει μέσα από την εκπαίδευση, χρησιμοποιώντας την αντίστροφη διάδοση για να αναπροσαρμόσει τα

βάρος των συνδέσεων μεταξύ των νευρώνων, με στόχο τη βελτίωση της ακρίβειας των προβλέψεων του. (Haykin, 2009)

II. Συνελικτικά Νευρωνικά Δίκτυα (CNN)

Τα CNN χρησιμοποιούνται κυρίως για την επεξεργασία και την ανάλυση δεδομένων που έχουν χωρική δομή, όπως εικόνες και βίντεο. Είναι ιδιαίτερα δημοφιλή στον τομέα της μηχανικής όρασης, αλλά μπορούν να εφαρμοστούν και σε άλλα είδη δεδομένων με κατάλληλη διαμόρφωση.

Ένα CNN αποτελείται από τρία κύρια είδη στρωμάτων: τα συνελικτικά στρώματα, τα στρώματα υποδειγματοληψίας (pooling layers) και τα πλήρως συνδεδεμένα. Τα συνελικτικά στρώματα χρησιμοποιούν φίλτρα για να εκτελούν συνελίξεις πάνω στα δεδομένα εισόδου, όπως εικόνες, εξάγοντας τοπικά χαρακτηριστικά, όπως ακμές και γωνίες. Αυτοί οι χάρτες χαρακτηριστικών που παράγονται στην συνέχεια περνούν από τα στρώματα υποδειγματοληψίας, τα οποία μειώνουν τις διαστάσεις τους, διατηρώντας παράλληλα τα βασικά χαρακτηριστικά και μειώνοντας την υπολογιστική πολυπλοκότητα.



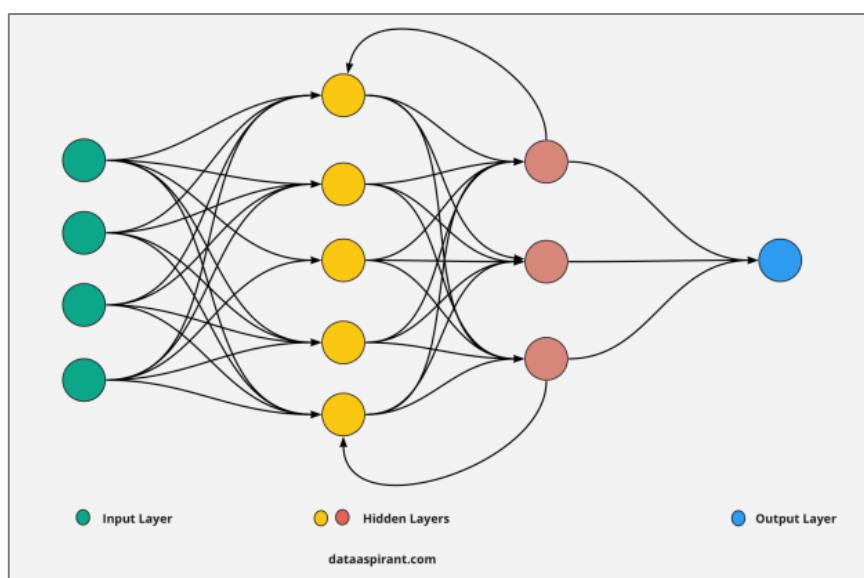
Εικόνα 3.4: Διεργασία CNN

Μετά από μερικές επαναλήψεις συνελικτικών και υποδειγματοληπτικών στρωμάτων, οι χάρτες χαρακτηριστικών επιπεδοποιούνται και τροφοδοτούνται σε πλήρως συνδεδεμένα στρώματα, τα οποία αναλαμβάνουν να συνδυάσουν τα εξαγόμενα χαρακτηριστικά για την τελική πρόβλεψη, δηλαδή την κατηγοριοποίηση εικόνων. Η δομή του CNN επιτρέπει στο δίκτυο να μαθαίνει ιεραρχίες χαρακτηριστικών σε διαφορετικά επίπεδα αφαίρεσης, καθιστώντας το εξαιρετικά αποτελεσματικό για προβλήματα επεξεργασίας και ανάλυσης δεδομένων. (Haykin, 2009)

III. Αναδρομικά Νευρωνικά Δίκτυα (RNN)

Τα RNN είναι ένας τύπος ΤΝΔ που είναι σχεδιασμένος για να επεξεργάζεται δεδομένα που έχουν αλληλουχία, όπως σειρές χρόνου, κείμενο και ήχο. Η κύρια διαφορά των RNN από άλλα νευρωνικά δίκτυα είναι η δυνατότητά τους να διατηρούν πληροφορίες από προηγούμενες επαναλήψεις της ακολουθίας, γεγονός που τα καθιστά ιδανικά για προβλήματα όπου η σειρά των δεδομένων παίζει σημαντικό ρόλο.

Η δομή ενός RNN αποτελείται από επαναλαμβανόμενες μονάδες (neurons) που είναι διατεταγμένες σε αλληλουχία, όπου η έξοδος από κάθε μονάδα σε ένα χρονικό βήμα γίνεται είσοδος για την ίδια μονάδα στο επόμενο βήμα. Αυτή η δομή επιτρέπει στο μοντέλο να διατηρεί μια "μνήμη" των προηγούμενων βημάτων στην ακολουθία, καθιστώντας το ικανό να επεξεργάζεται δεδομένα με χρονική εξάρτηση.



Εικόνα 3.5: Διεργασία RNN

Η βασική μονάδα ενός RNN λαμβάνει μια τρέχουσα είσοδο και την έξοδο από το προηγούμενο χρονικό βήμα, υπολογίζοντας την τρέχουσα κατάσταση (state), η οποία στη συνέχεια ενημερώνει το επόμενο βήμα. Η εκπαίδευση του RNN γίνεται μέσω της αντίστροφης διάδοσης μέσω χρόνου (BPTT), όπου το σφάλμα διαδίδεται πίσω στο χρόνο, ενημερώνοντας τα βάρη των συνδέσεων για να βελτιώσει την ακρίβεια των προβλέψεων του δικτύου. Τα RNN είναι ιδανικά για εφαρμογές όπως η επεξεργασία φυσικής γλώσσας και πρόβλεψης σειρών χρόνου, όπου η αλληλουχία των δεδομένων παίζει σημαντικό ρόλο. (Haykin, 2009)


Επιπρόσθετα υποκατηγορία του RNN αποτελούν τα Νευρωνικά Δίκτυα με Μνήμη Βραχείας Διάρκειας (LSTM). Το LSTM είναι μια εξειδικευμένη μορφή αναδρομικού νευρωνικού δικτύου RNN που έχει σχεδιαστεί για να ξεπεράσει τα προβλήματα που συνήθως αντιμετωπίζουν τα παραδοσιακά RNN, όπως το πρόβλημα της εξασθένισης των βαθμίδων (vanishing gradients). Τα LSTM είναι ιδιαίτερα χρήσιμα για την επεξεργασία και την πρόβλεψη σε σειρές δεδομένων όπου υπάρχει

σημαντική εξάρτηση από χρονικές στιγμές, όπως η ανάλυση κειμένου, η ομιλία και η πρόβλεψη χρόνου.

IV. Νευρωνικά Δίκτυα Ανάδρασης (FNN)

Τα FNN είναι μια από τις πιο βασικές και θεμελιώδεις αρχιτεκτονικές ΤΝΔ. Αποτελούνται από στρώματα νευρώνων, όπου οι πληροφορίες ρέουν προς μία μόνο κατεύθυνση, δηλαδή από το εισαγωγικό στρώμα, μέσω ενός ή περισσοτέρων κρυφών στρωμάτων και τελικά στο στρώμα εξόδου. Στα FNN δεν υπάρχουν αναδρομικές συνδέσεις ή βρόχοι στο δίκτυο, γεγονός που τα διαφοροποιεί από άλλες πιο σύνθετες αρχιτεκτονικές όπως τα RNN.

Όπως και σε όλες τις άλλες μεθόδους έτσι και εδώ έχουμε τρία βασικά στρώματα. Το εισαγωγικό στρώμα λαμβάνει τα δεδομένα εισόδου, όπου κάθε νευρώνας αντιπροσωπεύει ένα χαρακτηριστικό των δεδομένων. Οι νευρώνες σε κάθε κρυφό στρώμα συνδέονται πλήρως με τους νευρώνες του προηγούμενου στρώματος και εφαρμόζουν μια γραμμική συνάρτηση ακολουθούμενη από μια μη γραμμική συνάρτηση ενεργοποίησης (ReLU, Sigmoid) επιτρέποντας στο δίκτυο να μάθει σύνθετες σχέσεις. Τέλος, το στρώμα εξόδου παράγει την τελική απόκριση του δικτύου, ανάλογα με το πρόβλημα που επιλύεται. (Haykin, 2009)

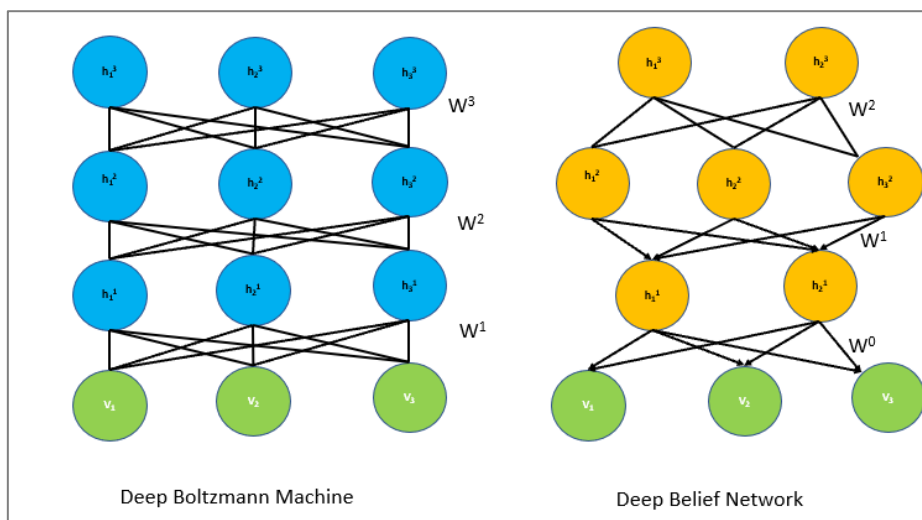


Εικόνα 3.6: Διεργασία FNN

V. Νευρωνικά Δίκτυα Βαθιάς Εκμάθησης (DBN)

Τα DBN είναι ένα είδος γενετικού ΝΔ που αποτελείται από πολλαπλά στρώματα τυχαίων, ασύμμετρων δικτύων τα οποία είναι οργανωμένα με τέτοιο τρόπο που να επιτυγχάνεται η αποτελεσματική εκπαίδευση του μοντέλου. Τα DBN μπορούν να θεωρηθούν ως ένα είδος στοίβας από Restricted Boltzmann Machines ή Autoencoders, όπου κάθε στρώμα μαθαίνει μια αφαιρετική αναπαράσταση των εισόδων του.

Η δομή ενός DBN αρχίζει με ένα εισαγωγικό στρώμα που δέχεται τα δεδομένα και στη συνέχεια περνάς αυτά τα δεδομένα μέσα από μια σειρά από κρυφά στρώματα, καθένα από τα οποία αποτελείται από νευρώνες που μαθαίνουν στατιστικά χαρακτηριστικά των δεδομένων από το προηγούμενο στρώμα. Η εκπαίδευση πραγματοποιείται αρχικά μέσω με εποπτευόμενης μάθησης, όπου κάθε RBM εκπαιδεύεται ανεξάρτητα και στη συνέχεια ακολουθεί εποπτευόμενη μάθηση για βελτίωση της απόδοσης σε συγκεκριμένα καθήκοντα.



Εικόνα 3.7: Διεργασία DBN σε σύγκριση με την Boltzmann

Τα κρυφά στρώματα της DBN λειτουργούν ως ιεραρχικά επίπεδα που εξάγουν όλο και πιο σύνθετα χαρακτηριστικά από τα δεδομένα καθώς προχωρούν προς το στρώμα εξόδου.

3.2 (Νεύρο) Ασαφή Συστήματα – Ασαφής Λογική

Τα ασαφή σύνολα εισήχθησαν από τον Zadeh (1965), για να αναπαραστήσουν και να χειριστούν δεδομένα και πληροφορίες στα οποία υπάρχουν διάφορες εναλλακτικές αβεβαιότητες. Δέκα χρόνια αργότερα (1975), εισήγαγε την ασαφή λογική που βασίζεται στην θεωρία των ασαφών συνόλων. Τα ασαφή συστήματα (fuzzy systems), τα οποία αποτελούν υλοποίηση των ασαφών συνόλων και της ασαφούς λογικής, είναι μια προσπάθεια αποτελεσματικής περιγραφής της ασάφειας του πραγματικού κόσμου. Τα ασαφή σύνολα αποτελούν γενίκευση των κλασικών συνόλων: στα κλασικά σύνολα ένα στοιχείο είτε ανήκει είτε δεν ανήκει σε ένα σύνολο. Αντίθετα, στα ασαφή σύνολα ένα στοιχείο "συμμετέχει" στο σύνολο με ένα ποσοστό (βαθμό) που υπάγεται στο διάστημα $[0,1]$. (Μαστοροκότσας, 2015)

Η ασαφής λογική αποτελεί γενίκευση της κλασικής λογικής και παρέχει μηχανισμούς προσεγγιστικού συλλογισμού (approximate reasoning) και εξαγωγής συμπεράσματος (decision making). Ο προσεγγιστικός συλλογισμός είναι μία προσπάθεια να μοντελοποιηθεί ο ανθρώπινος τρόπος σκέψης και συμπερασμού,

καθώς είναι γνωστό ότι ο ανθρώπινος εγκέφαλος πραγματοποιεί περισσότερο προσεγγιστικούς συλλογισμούς με βάση ποιοτικά κριτήρια αντίληψης, παρά ακριβείς συλλογισμούς βασισμένους σε πληθώρα δεδομένων. (Μαστοροκώστας, 2015)

Η θεωρία ασαφών συνόλων και οι ασαφείς μεθοδολογίες που χρησιμοποιούνται στην παρούσα διπλωματική περιγράφονται παρακάτω.

I. Ασαφείς Μεταβλητές (Fuzzy Variables)


Οι ασαφείς μεταβλητές δεν είναι περιορισμένες σε συγκεκριμένες τιμές όπως στην κλασική λογική. Αντίθετα, μπορούν να λαμβάνουν οποιαδήποτε τιμή μέσα σε ένα εύρος. Για παράδειγμα, αντί να λέμε ότι η θερμοκρασία είναι "υψηλή" ή "χαμηλή", στην ασαφή λογική μπορούμε να έχουμε μια μεταβλητή που περιγράφει την θερμοκρασία ως "μεσαία", "σχετικά υψηλή", ή "πολύ υψηλή" με αντίστοιχους βαθμούς ελευθερίας.

II. Ασαφή Σύνολα (Fuzzy Sets)


Ένα ασαφές σύνολο είναι ένα σύνολο όπου κάθε στοιχείο έχει έναν βαθμό συμμετοχής που κυμαίνεται μεταξύ 0 και 1. Τα ασαφή σύνολα μπορούν να θεωρηθούν ως επέκταση της θεωρίας των κλασικών συνόλων. Για παράδειγμα, σε ένα πρόβλημα ύψους των ανδρών, για να προσδιοριστεί αν ένα άτομο (x) ανήκει ή δεν ανήκει στο σύνολο "ψηλός" (A), η σχέση $\mu_A(x)$ του ατόμου (x) στο σύνολο (A) δίνεται από τον τύπο:

$\mu_A(x) = 1$, αν το άτομο (x) ανήκει πλήρως στο σύνολο
 $\mu_A(x) = 0$, αν το άτομο (x) δεν ανήκει πλήρως στο σύνολο
 $0 < \mu_A(x) < 1$, αν το άτομο (x) ανήκει μερικός στο σύνολο

Αν όμως αλλάξουμε το σύνολο (A) σε «ύψος > 180 εκατ. τότε είναι ψηλός άνδρας», τότε αυτή η δήλωση μπορεί να αναπαρασταθεί ως ψηλός = $\{x | x \geq 180\}$. Το [Διάγραμμα 2.1](#) δείχνει πώς τα ευκρινή σύνολα επιβάλλουν ένα απότομο όριο. Ωστόσο στην μεθοδολογία ασαφούς συνόλου, εφαρμόζεται η έννοια του βαθμού συμμετοχής. Στο [Διάγραμμα 2.2](#) παρουσιάζονται τα ασαφή σύνολα με βαθμό συμμετοχής που επιτρέπει τον ορισμό ασαφών ή θολών ορίων



Διάγραμμα 3-1: Κλασσικά σύνολα

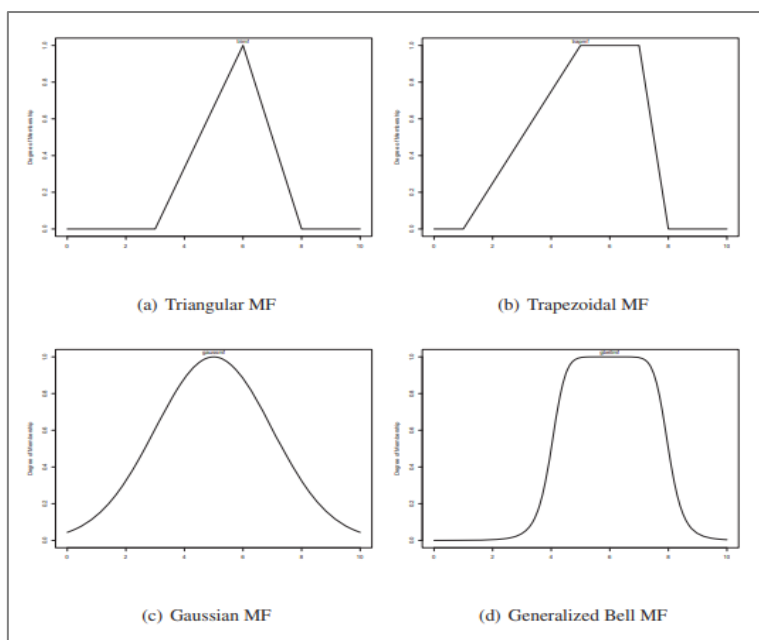


Διάγραμμα 3-2: Ασαφή σύνολα

III. Συναρτήσεις Μελών (Membership Functions)

Οι συναρτήσεις μελών, που συχνά δίνεται η ονομασία μ , είναι η ουσία των ασαφών συνόλων. Μια συνάρτηση μέλους είναι μια καμπύλη που καθορίζει τον τρόπο με τον οποίο κάθε σημείο στο χώρο εισόδου αντιστοιχίζεται σε έναν βαθμό συμμετοχής που συνήθως λαμβάνεται ως πραγματικός αριθμός στο διάστημα $[0, 1]$.

Η επιλογή του τύπου της συνάρτησης για ασαφή σύνολα εξαρτάται συνήθως από την καταλληλότητά του, όπως η απλότητα, η ευκολία, η ταχύτητα και η αποτελεσματικότητα. Αυτές οι συναρτήσεις μπορεί να έχουν διάφορα σχήματα, όπως τριγωνικές, τραπεζοειδείς ή καμπύλες Gauss. Για παράδειγμα, μια τριγωνική συνάρτηση μέλους μπορεί να χρησιμοποιηθεί για να περιγράψει το βαθμό με τον οποίο μια συγκεκριμένη θερμοκρασία θεωρείται "μέτρια". (Hazlina Hamdan, 2013)



Διάγραμμα 3-3: Παραδείγματα συναρτήσεων

IV. Λογικές Συναρτήσεις και Τελεστές

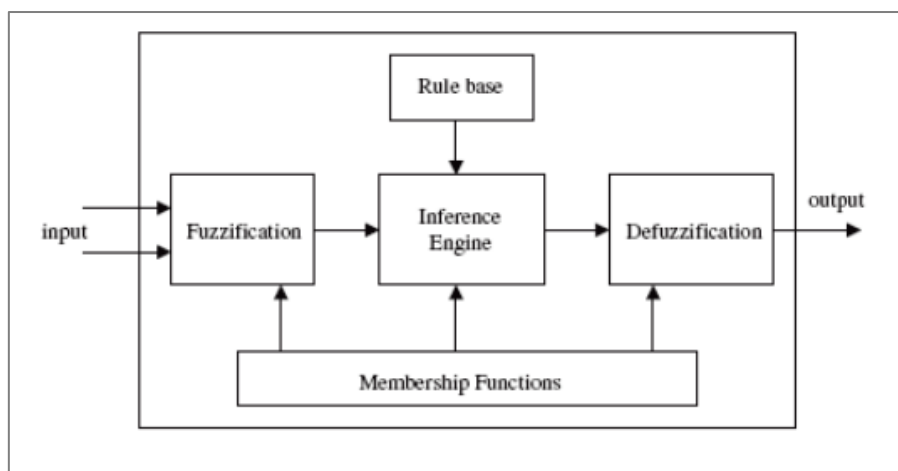
Στην ασαφή λογική, χρησιμοποιούνται ασαφείς τελεστές (όπως "AND", "OR", "NOT") για τη σύνθεση και τον συνδυασμό των ασαφών συνόλων. Οι ασαφείς τελεστές επιτρέπουν την εκτέλεση πράξεων όπως η ασαφής σύζευξη, η ασαφής διάζευξη, και η ασαφής άρνηση.

V. Κανόνες Ασαφούς Λογικής (Fuzzy Rules)

Οι κανόνες ασαφούς λογικής συνδυάζουν τα ασαφή σύνολα και τις συναρτήσεις μελών για να δημιουργήσουν IF-THEN κανόνες. Για παράδειγμα, ένας κανόνας μπορεί να είναι: "Αν η θερμοκρασία είναι υψηλή ΚΑΙ η υγρασία είναι υψηλή, τότε ο ανεμιστήρας θα πρέπει να λειτουργεί σε υψηλή ταχύτητα". Αυτοί οι κανόνες είναι ιδιαίτερα χρήσιμοι για τη λήψη αποφάσεων σε σύνθετα περιβάλλοντα. Η ερμηνεία ενός IF-THEN κανόνα περιλαμβάνει δύο διακριτά μέρη: πρώτον, την αξιολόγηση του προηγούμενου, η οποία περιλαμβάνει την ασάφεια της εισόδου και δεύτερον, την εφαρμογή αυτού του αποτελέσματος στο επακόλουθο γνωστό ως συνεπαγωγή. (Hazlina Hamdan, 2013)

VI. Συμπερασματολογία (Inference)

Στην ασαφή λογική, η συμπερασματολογία αναφέρεται στη διαδικασία εφαρμογής των κανόνων ασαφούς λογικής σε πραγματικά δεδομένα για τη λήψη αποφάσεων. Αυτό περιλαμβάνει τη διαδικασία της αποασαφοποίησης (defuzzification), όπου οι ασαφείς τιμές μετατρέπονται σε ακριβείς, κλασικές τιμές που μπορούν να χρησιμοποιηθούν για την εκτέλεση συγκεκριμένων ενεργειών.



Διάγραμμα 3-4: FIS

Οι δύο τύποι ασαφών συμπερασμάτων που χρησιμοποιούνται συχνότερα είναι η μέθοδος Mamdani και η μέθοδος Sugeno. Η διαφορά μεταξύ αυτών των δύο ασαφών μεθοδολογιών είναι ο προσδιορισμός του επακόλουθου μέρους. Στην μέθοδο Mamdani, τα επακόλουθα είναι ασαφή σύνολα και η τελική καθαρή έξοδος βασίζεται στην αποασάφεια της συνολικής εξόδου. Αντίθετα στην μέθοδο Sugeno, τα επακόλουθα ασαφή σύνολα είναι πραγματικοί αριθμοί, οι οποίοι μπορεί να είναι είτε γραμμικοί είτε σταθεροί. Η τελική έξοδος είναι ο σταθμισμένος μέσος όρος της εξόδου κάθε κανόνα.

Τα νευροασαφή συστήματα συνδυάζουν τις αρχές των νευρωνικών δικτύων και της ασαφούς λογικής για να δημιουργήσουν ισχυρά εργαλεία επεξεργασίας δεδομένων και λήψης αποφάσεων. Τα νευρωνικά δίκτυα είναι μοντέλα που εμπνέονται από τον ανθρώπινο εγκέφαλο και χρησιμοποιούνται για την αναγνώριση προτύπων και τη μάθηση από δεδομένα. Όταν συνδυάζονται με την ασαφή λογική, τα συστήματα αυτά μπορούν να επεξεργάζονται αβέβαιες πληροφορίες και να βελτιώνουν τις επιδόσεις τους μέσω της μάθησης.

Ο συνδυασμός αυτός είναι εξαιρετικά χρήσιμος σε περιπτώσεις όπου τα δεδομένα είναι περίπλοκα και αβέβαια, όπως στην αναγνώριση προτύπων, στη διαχείριση γνώσης, και στον έλεγχο πολύπλοκων συστημάτων.

3.3 Adaptive Neuro-Fuzzy Inference System (ANFIS)

Το ANFIS (Adaptive Neuro-Fuzzy Inference System) είναι ένα υβριδικό σύστημα που συνδυάζει τη δύναμη των νευρωνικών δικτύων με τις δυνατότητες των ασαφών συστημάτων. Στόχος του ANFIS είναι να χρησιμοποιήσει την ικανότητα των νευρωνικών δικτύων να μαθαίνουν από δεδομένα για να προσαρμόζει και να βελτιώνει τους κανόνες ενός ασαφούς συστήματος. Αυτό το καθιστά ένα πολύ ισχυρό εργαλείο για εφαρμογές όπου απαιτείται απόφαση υπό συνθήκες αβεβαιότητας ή όταν τα δεδομένα είναι μη γραμμικά.

Η αρχιτεκτονική του ANFIS συνδυάζει ένα ασαφές σύστημα με πέντε στρώσεις, όπου κάθε επίπεδο έχει συγκεκριμένο ρόλο:

I. Επίπεδο 1 (Fuzzification Layer)

Σε αυτό το επίπεδο, τα εισερχόμενα δεδομένα εισάγονται στις ασαφείς συναρτήσεις συμμετοχής (membership functions). Κάθε κόμβος στο επίπεδο αυτό αντιπροσωπεύει μια ασαφή συνάρτηση, που προσδιορίζει πόσο κάθε δεδομένο ανήκει σε μια συγκεκριμένη ασαφή κατηγορία (π.χ., "χαμηλό", "μέτριο", "υψηλό").

II. Επίπεδο 2 (Rule Layer)

Αυτό το επίπεδο αντιστοιχεί στους κανόνες ασαφούς λογικής του συστήματος. Οι κόμβοι εδώ αντιπροσωπεύουν τους κανόνες, και το σύστημα υπολογίζει το βαθμό στον οποίο οι εισροές ικανοποιούν κάθε κανόνα.

III. Επίπεδο 3 (Normalization Layer)


Στο επίπεδο αυτό, οι τιμές που παράγονται από το Επίπεδο 2 κανονικοποιούνται, ώστε να αποδίδεται ένας βαθμός εμπιστοσύνης σε κάθε κανόνα. Η κανονικοποίηση γίνεται μέσω της σύγκρισης των σχετικών βαρών όλων των κανόνων.

IV. Επίπεδο 4 (Defuzzification Layer)

Στο επίπεδο αυτό, οι κανονικοποιημένοι κανόνες χρησιμοποιούνται για να υπολογιστούν τα συναρτησιακά συμπεράσματα (outputs) του συστήματος. Αυτό το Επίπεδο προσδιορίζει το αποτέλεσμα για κάθε κανόνα, βασισμένο στις κανονικοποιημένες τιμές.

V. Επίπεδο 5 (Output Layer)

Το τελικό Επίπεδο είναι υπεύθυνη για τη σύνθεση όλων των αποτελεσμάτων των κανόνων, για να παραχθεί η τελική έξοδος του συστήματος. Σε αυτή τη φάση, τα συμπεράσματα όλων των κανόνων συνδυάζονται για να δώσουν την τελική απόφαση ή πρόβλεψη.



Εικόνα 3.8: ANFIS

Η εκπαίδευση του ANFIS πραγματοποιείται συνήθως με τη χρήση ενός συνόλου δεδομένων εκπαίδευσης, που περιέχει τα επιθυμητά αποτελέσματα (εποπτευόμενη μάθηση). Το σύστημα μαθαίνει με τη βοήθεια των παρακάτω διαδικασιών:

I. Forward Pass (Πρώθηση)

Σε αυτή τη φάση, τα δεδομένα εισόδου διατρέχουν το δίκτυο και υπολογίζονται οι τιμές εξόδου για κάθε επίπεδο. Αυτό δίνει τις προβλέψεις του συστήματος, βασισμένες στις αρχικές παραμέτρους των ασαφών συναρτήσεων συμμετοχής και των κανόνων.

II. Backward Pass (Ανάδραση)

Με βάση τη διαφορά μεταξύ των προβλεπόμενων αποτελεσμάτων και των πραγματικών αποτελεσμάτων από το σύνολο δεδομένων εκπαίδευσης (σφάλμα), το ANFIS προσαρμόζει τις παραμέτρους του. Αυτό γίνεται συνήθως με τη χρήση του αλγορίθμου backpropagation ή/και με τη μέθοδο ελαχίστων τετραγώνων (least squares), για να μειωθεί το σφάλμα και να βελτιωθεί η ακρίβεια του μοντέλου.

3.4 Εφαρμογές των ΤΝΔ & Νευροασαφή Συστημάτων

Τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks - ANN) και τα νευροασαφή συστήματα (Neuro-Fuzzy Systems) βρίσκουν εφαρμογές σε πολλούς τομείς λόγω της ικανότητάς τους να προσομοιώνουν την ανθρώπινη νοημοσύνη και να χειρίζονται αβεβαιότητες και πολύπλοκα δεδομένα.

Αναγνώριση Προτύπων

Τα τεχνητά νευρωνικά δίκτυα είναι εξαιρετικά χρήσιμα για την αναγνώριση προτύπων, κάτι που περιλαμβάνει την αναγνώριση εικόνας και φωνής. Στον τομέα της αναγνώρισης εικόνας, τα νευρωνικά δίκτυα μπορούν να αναλύσουν και να κατηγοριοποιήσουν εικόνες με ακρίβεια, χρησιμοποιούμενα σε εφαρμογές όπως η αναγνώριση προσώπου και αντικειμένων, όπως σε πλατφόρμες κοινωνικών δικτύων (π.χ., Facebook) και προγράμματα ανάλυσης εικόνας. Στην αναγνώριση φωνής, χρησιμοποιούνται για τη μετατροπή ομιλίας σε κείμενο, με γνωστά παραδείγματα όπως το Siri της Apple και το Google Assistant. Επίσης, τα νευρωνικά δίκτυα συμβάλλουν στην αναγνώριση χειρόγραφων κειμένων μέσω της τεχνολογίας OCR (Optical Character Recognition)

Πρόβλεψη και Πρόγνωση

Στον τομέα των οικονομικών, τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούνται για την πρόβλεψη τιμών μετοχών, τάσεων αγοράς και άλλων οικονομικών δεικτών, επιτρέποντας την καλύτερη λήψη αποφάσεων για επενδύσεις. Στον τομέα της πρόγνωσης ζήτησης, χρησιμοποιούνται για την εκτίμηση της κατανάλωσης ηλεκτρικής ενέργειας και άλλων πόρων, συμβάλλοντας στην αποτελεσματικότερη

διαχείριση των ενεργειακών πόρων. Επίσης, τα νευρωνικά δίκτυα εφαρμόζονται στις κλιματικές προβλέψεις, όπου βοηθούν στην ανάλυση και πρόβλεψη καιρικών συνθηκών και κλιματικών αλλαγών.

Αυτόματη Οδήγηση

Η τεχνολογία της αυτόματης οδήγησης επωφελείται σε μεγάλο βαθμό από τα νευρωνικά δίκτυα. Τα συστήματα αυτόματης οδήγησης, όπως αυτά που αναπτύσσονται από την Tesla και άλλες εταιρείες, χρησιμοποιούν νευρωνικά δίκτυα για να επεξεργάζονται δεδομένα από αισθητήρες, κάμερες και ραντάρ. Αυτό επιτρέπει την αναγνώριση πινακίδων, πεζών και άλλων συνθηκών κυκλοφορίας, συμβάλλοντας στην ασφαλή και αυτόνομη οδήγηση

Ιατρικές Εφαρμογές

Στον τομέα της ιατρικής, τα τεχνητά νευρωνικά δίκτυα παίζουν κρίσιμο ρόλο στη διάγνωση και την προσωπική θεραπεία. Στην ανάλυση ιατρικών εικόνων, χρησιμοποιούνται για την ανίχνευση ασθενειών όπως ο καρκίνος, αναλύοντας ακτινογραφίες και μαγνητικές τομογραφίες με μεγάλη ακρίβεια. Επίσης, τα νευρωνικά δίκτυα συμβάλλουν στην εξατομίκευση θεραπειών μέσω της ανάλυσης γονιδιακών δεδομένων, επιτρέποντας την ανάπτυξη πιο αποτελεσματικών και στοχευμένων θεραπειών.

Ανάλυση Μεγάλων Δεδομένων (Big Data)

Η ανάλυση μεγάλων δεδομένων αποτελεί ένα από τα πιο δυναμικά πεδία εφαρμογής των τεχνητών νευρωνικών δικτύων. Εταιρείες όπως η Google, η Amazon και η Netflix χρησιμοποιούν νευρωνικά δίκτυα για να επεξεργάζονται τεράστιες ποσότητες δεδομένων, παρέχοντας εξατομικευμένες προτάσεις και βελτιώνοντας την εμπειρία του χρήστη. Επιπλέον, τα νευρωνικά δίκτυα αναλύουν δεδομένα για να αναγνωρίσουν μοτίβα και τάσεις, χρησιμοποιούμενα στην ανίχνευση απάτης σε οικονομικές συναλλαγές.

Επεξεργασία Φυσικής Γλώσσας (NLP)

Στον τομέα της επεξεργασίας φυσικής γλώσσας, τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούνται για τη μετάφραση κειμένων, όπως στο Google Translate, επιτρέποντας την ακριβή και αυτοματοποιημένη μετάφραση μεταξύ διαφορετικών γλωσσών. Επίσης, βοηθούν στην ανάλυση συναισθημάτων σε σχόλια και κριτικές προϊόντων, καθώς και στη λειτουργία chatbots που εξομοιώνουν διάλογο με ανθρώπους, παρέχοντας υποστήριξη και αλληλεπίδραση με τους χρήστες.

Παιχνίδια και Διασκέδαση

Τα τεχνητά νευρωνικά δίκτυα επηρεάζουν σημαντικά τον τομέα των παιχνιδιών και της διασκέδασης. Χρησιμοποιούνται για την ανάπτυξη πιο έξυπνων και προσαρμόσιμων αντιπάλων σε βιντεοπαιχνίδια, βελτιώνοντας την εμπειρία του

παιχνιδιού. Επίσης, συμβάλλουν στη δημιουργία πιο ρεαλιστικών και διαδραστικών περιβαλλόντων στην εικονική πραγματικότητα (VR).

Ασφάλεια

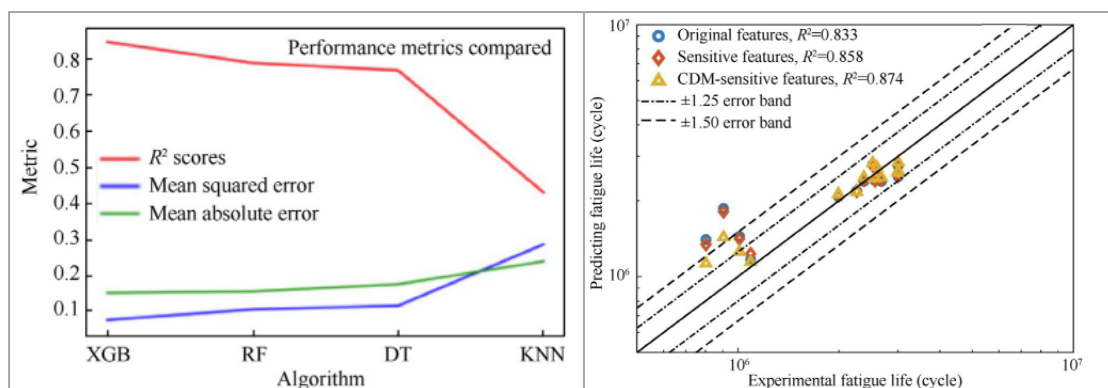
Στον τομέα της ασφάλειας, τα τεχνητά νευρωνικά δίκτυα εφαρμόζονται στην ανίχνευση απάτης σε χρηματοοικονομικές συναλλαγές, εντοπίζοντας ύποπτες δραστηριότητες και προστατεύοντας από οικονομικές επιθέσεις. Επίσης, χρησιμοποιούνται σε συστήματα ανίχνευσης εισβολών για την προστασία δικτύων υπολογιστών από κακόβουλες επιθέσεις.

4 Εφαρμογές των ΤΝΔ στην Προσθετική Κατασκευή

Η ενσωμάτωση των νευρωνικών δικτύων στην προσθετική κατασκευή προσφέρει σημαντικά πλεονεκτήματα, όπως η αυτοματοποίηση της διαδικασίας, η βελτιστοποίηση σχεδιασμού και η πρόβλεψη ελαττωμάτων. Τα νευρωνικά δίκτυα αναλύουν δεδομένα σε πραγματικό χρόνο, επιτρέποντας την άμεση διόρθωση σφαλμάτων και τη βελτίωση της ακρίβειας και αποδοτικότητας της παραγωγής. Με τη συνεχή μάθηση από προηγούμενες διαδικασίες, αυτά τα συστήματα προσαρμόζονται για καλύτερη απόδοση, μειώνοντας τα απόβλητα και εξοικονομώντας πόρους, συμβάλλοντας έτσι σε πιο ακριβείς και βιώσιμες μεθόδους κατασκευής.

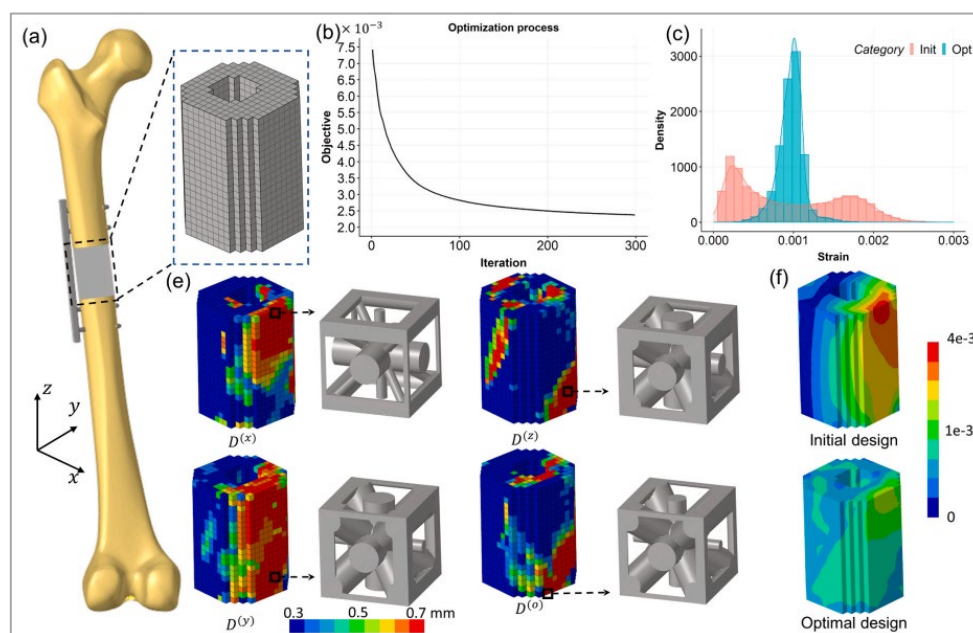
Για παράδειγμα, ο (Nohut, 2024) χρησιμοποιεί τα μοντέλα μηχανικής μάθησης για την πρόβλεψη της συρρίκνωσης και του πορώδους σε δείγματα αλουμίνιας, τροποποιώντας ορισμένες παραμέτρους ως δεδομένα εισόδου, που μπορούν να χρησιμοποιηθούν για τον σχεδιασμό και την παραγωγή σύνθετων κεραμικών μερών που αποτελούνται από πορώδη σε συνδυασμό με τη αλουμίνια. Για την πρόβλεψη, χρησιμοποιήθηκαν οι αλγόριθμοι SVN, LR, GP, DT και NN που προσεγγίστηκαν με τους συντελεστές συσχέτισης R, MAE, RMSE. Σύμφωνα με την ακρίβεια των δοκιμών οι DT και NN παρατηρηθήκαν ως τα πιο ακριβή μοντέλα.

Μια ακόμη προσέγγιση, που είναι παρεμφερής με την συγκεκριμένα μελέτη, είναι η χρήση των ΤΝΔ για πρόβλεψη μηχανικών ιδιοτήτων. Πιο συγκεκριμένα, ο (Yi Min, 2024) χρησιμοποίησε την ΤΝΔ για την πρόβλεψη των ιδιοτήτων της κόπωσης (διάρκεια ζωής και ρυθμό ανάπτυξης ρωγμών) σε μεταλλικά υλικά προσθετικής κατασκευής (κράμα Ti, κράμα Al, χάλυβα κλπ.) καθώς επίσης και τις συσχετίσεις τους με τις μικροδομές τους, μεταβάλλοντας τις παραμέτρους επεξεργασίας και του φορτίου κόπωσης. Παρατηρήθηκε ότι τα μοντέλα μηχανικής μάθησης, είναι ικανά να χρησιμοποιηθούν σε τέτοιες εφαρμογές καθώς η ακρίβεια των μοντέλων ανέρχεται κατά μέσο όρο άνω του 75%.



Διάγραμμα 4-1: Performance metrics of four different ML models for predicting fatigue of LPBF-AM Ti6Al4V (Yi Min, 2024)

Στον τομέα της ιατρικής η χρήση των ΤΝΔ και της προσθετικής κατασκευής είναι εκτενής. Με την χρήση του αλγορίθμου DANN επιτρέπεται η πρόβλεψη στις ομογενοποιημένες ιδιότητες υλικού των μοναδιαίων κυψελών, αλλά και την ευαισθησία των ιδιοτήτων των υλικών όσον αφορά τις μεταβλητές σχεδιασμού για τη βελτιστοποίηση της τοπολογίας του αντικειμένου. Για παράδειγμα στην μελέτη του (Chi Wu, 2023) με την χρήση του αλγορίθμου DANN επιτεύχθηκε η πρόβλεψη στις ομογενοποιημένες ιδιότητες υλικού των μοναδιαίων κυψελών, αλλά και την ευαισθησία των ιδιοτήτων των υλικών όσον αφορά τις μεταβλητές σχεδιασμού για τη βελτιστοποίηση της τοπολογίας του αντικειμένου. Αρχικά μελετήθηκε η αποτελεσματικότητά του αλγορίθμου μέσω πειραματικών δοκιμών σε 3D εκτυπωμένα πρωτότυπα. Στη συνέχεια, διερευνήθηκε περαιτέρω ο σχεδιασμός των δύο οστικών ικριωμάτων ασθενών ή/και συγκεκριμένων περιοχών, γεγονός που κατέδειξε σημαντικές δυνατότητες για σενάρια πραγματικών περιπτώσεων.



Εικόνα 4.1: The optimization for a femur bone reconstruction case. (a) The bone-scaffold system includes a femur bone, a bone fixation plate, screws and a scaffold. (b) The iteration history for scaffold design during the

optimisation process (c) Comparison of the equivalent strains obtained from the initial and optimal designs. (e) The distributions of design variables in the optimised scaffold. (f) Comparison of the equivalent strain contours in the initial and optimal designs. (Chi Wu, 2023)

Μελλοντικές εφαρμογές / Industry 4.0

Αξιοποιώντας όλα τα προνόμια που έχει να προσφέρει η σύνδεση των δύο πεδίων ο (Ma, 2024) εφάρμοσε ένα τέτοιο σενάριο σε ένα υποθετικό σύγχρονο εργοστάσιο.

Σε ένα Έξυπνο Εργοστάσιο Προσθετικής Κατασκευής (SAMF), προηγμένες τεχνολογίες όπως η μηχανική μάθηση (ML), η βαθιά μάθηση (DL) και το Διαδίκτυο των Πραγμάτων (IoT) ενσωματώνονται στενά για τη βελτιστοποίηση ολόκληρης της διαδικασίας παραγωγής. Το εργοστάσιο διαθέτει διάφορες τεχνολογίες τρισδιάστατης εκτύπωσης, όπως FDM, SLS και SLM, με μοντέλα CAD που προσαρμόζονται για την προσθετική κατασκευή μέσω αλγορίθμων μηχανικής μάθησης. Αυτά τα μοντέλα ετοιμάζονται για εκτύπωση αποτελεσματικά για να διασφαλιστεί η βέλτιστη χρήση υποστηριγμάτων, η εξοικονόμηση ενέργειας και η ελαχιστοποίηση των χρόνων παράδοσης. Όλες οι μηχανές, συμπεριλαμβανομένων των εκτυπωτών, είναι διασυνδεδεμένες και παρακολουθούνται, ενώ δεδομένα από αισθητήρες συλλέγονται και επεξεργάζονται σε πραγματικό χρόνο, διασφαλίζοντας ομαλή λειτουργία και υψηλή ακρίβεια στην παραγωγή. (Yim, 2023)

Η εκτεταμένη χρήση συσκευών IoT και αποθήκευσης δεδομένων στο cloud επιτρέπει τη συλλογή και ανάλυση μεγάλων δεδομένων, τα οποία χρησιμοποιούνται για προγνωστική συντήρηση και ανίχνευση σφαλμάτων. Εάν προκύψει κάποιο σφάλμα, όπως έλλειψη υλικού ή βλάβη σε μηχανή, οι ειδοποιήσεις σε πραγματικό χρόνο οδηγούν σε άμεση ανθρώπινη ή ρομποτική παρέμβαση. Τα συστήματα βαθιάς μάθησης επιτρέπουν επιπλέον την ανίχνευση σφαλμάτων σε πραγματικό χρόνο και τις αυτόματες προσαρμογές για τη βελτίωση της ποιότητας του προϊόντος κατά τη διαδικασία. Αυτός ο δυναμικός βρόχος ανατροφοδότησης, που υποστηρίζεται από τη μηχανική μάθηση, βελτιώνει τη λήψη αποφάσεων και μειώνει τα λάθη, διασφαλίζοντας μεγαλύτερη ακρίβεια στα αποτελέσματα της κατασκευής. (Mehta, 2022)

Η αυτοματοποίηση παίζει κρίσιμο ρόλο στη μείωση της ανθρώπινης παρέμβασης, ειδικά για επικίνδυνες ή επαναλαμβανόμενες εργασίες. Ρομποτικοί βραχίονες θα χειρίζονται τη φόρτωση και εκφόρτωση υλικών, τις ρυθμίσεις των μηχανών και τις προετοιμασίες για την εκτύπωση, ενώ τα Αυτόματα Κατευθυνόμενα Οχήματα (AGVs) μεταφέρουν τα έτοιμα μέρη στους σταθμούς μετεπεξεργασίας. (Massey, 2022) Αυτή η αυτοματοποίηση όχι μόνο βελτιώνει την ασφάλεια και την αποτελεσματικότητα αλλά επίσης μειώνει σημαντικά τους χρόνους παραγωγής και τη σπατάλη, καθιστώντας τη διαδικασία κατασκευής ταχύτερη και πιο βιώσιμη. Η απρόσκοπτη ενσωμάτωση λογισμικού, υλικού και μοντέλων μηχανικής μάθησης επιτρέπει στους

χειριστές να αξιοποιούν υπολογιστικές υποδομές υψηλής απόδοσης (HPC) χωρίς να απαιτούνται δαπανηρές εγκαταστάσεις.

Επιπλέον, η γενετική τεχνητή νοημοσύνη και τα μεγάλα γλωσσικά μοντέλα (LLMs), όπως το GPT-4, βοηθούν τους ανθρώπινους χειριστές στη μοντελοποίηση 3D, την αξιολόγηση σχεδίων και την ανάπτυξη υλικών, καθιστώντας την κατασκευή πιο διαισθητική και ευέλικτη. Αυτά τα LLMs βοηθούν σε σύνθετα καθήκοντα, όπως η προμήθεια εξαρτημάτων, ο προγραμματισμός παραγωγής και η βελτιστοποίηση σχεδίων. Η βαθιά ενσωμάτωση της τεχνητής νοημοσύνης και της μηχανικής μάθησης σε κάθε πτυχή του SAMF έχει μεταμορφώσει το τοπίο της προσθετικής κατασκευής, δημιουργώντας ένα πιο έξυπνο, αποδοτικό και φιλικό προς το περιβάλλον περιβάλλον παραγωγής, όπου μηχανές και άνθρωποι συνεργάζονται αρμονικά. (Sugucu, 2023)

5 Πειραματική Εφαρμογή

Η μεθοδολογία που ακολουθήθηκε για την ανάπτυξη και βελτίωση του μοντέλου ANFIS περιλαμβάνει αρκετά στάδια, τα οποία διασφαλίζουν την ακρίβεια και την αποτελεσματικότητα του μοντέλου στη πρόβλεψη των μηχανικών ιδιοτήτων των 3D-printed κομματιών.

Η βιβλιογραφική έρευνα που διεξήχθη εστιάστηκε σε δύο κύριους τομείς: την προσθετική κατασκευή AM και τα νευρωνικά δίκτυα, συμπεριλαμβανομένου και του ANFIS. Στον τομέα της προσθετικής κατασκευής, μελετήθηκαν εκτενώς οι παράγοντες που επηρεάζουν τις μηχανικές ιδιότητες των εκτυπωμένων κομματιών, όπως οι παράμετροι εκτύπωσης, τα υλικά και οι τεχνικές επεξεργασίας. Παράλληλα, η έρευνα στα νευρωνικά δίκτυα και το ANFIS επικεντρώθηκε στις μεθόδους πρόβλεψης και μοντελοποίησης, εξετάζοντας πώς οι αλγόριθμοι μάθησης και οι δομές των νευροασαφή μοντέλων μπορούν να βελτιώσουν την ακρίβεια και την αξιοπιστία των προβλέψεων.

5.1 Πειραματικά Δεδομένα

Αρχικά, πραγματοποιήθηκε συλλογή δεδομένων από πειράματα που πραγματοποιήθηκαν στο εργαστήριο. Τα δεδομένα αυτά περιλάμβαναν τις παραμέτρους εκτύπωσης και τις αντίστοιχες μηχανικές ιδιότητες των παραγόμενων κομματιών, όπως η αντοχή, η σκληρότητα και η ελαστικότητα. Στη συνέχεια, τα συλλεχθέντα δεδομένα υποβλήθηκαν σε μια διαδικασία κατηγοριοποίησης, χωριζόμενα σε δύο ομάδες: δεδομένα εκπαίδευσης και δεδομένα ελέγχου. Για την επίτευξη αυτής της κατηγοριοποίησης, εφαρμόστηκαν κατάλληλες στατιστικές μέθοδοι, με στόχο την προετοιμασία των δεδομένων για περαιτέρω ανάλυση μέσω του αλγορίθμου ANFIS στο MATLAB.

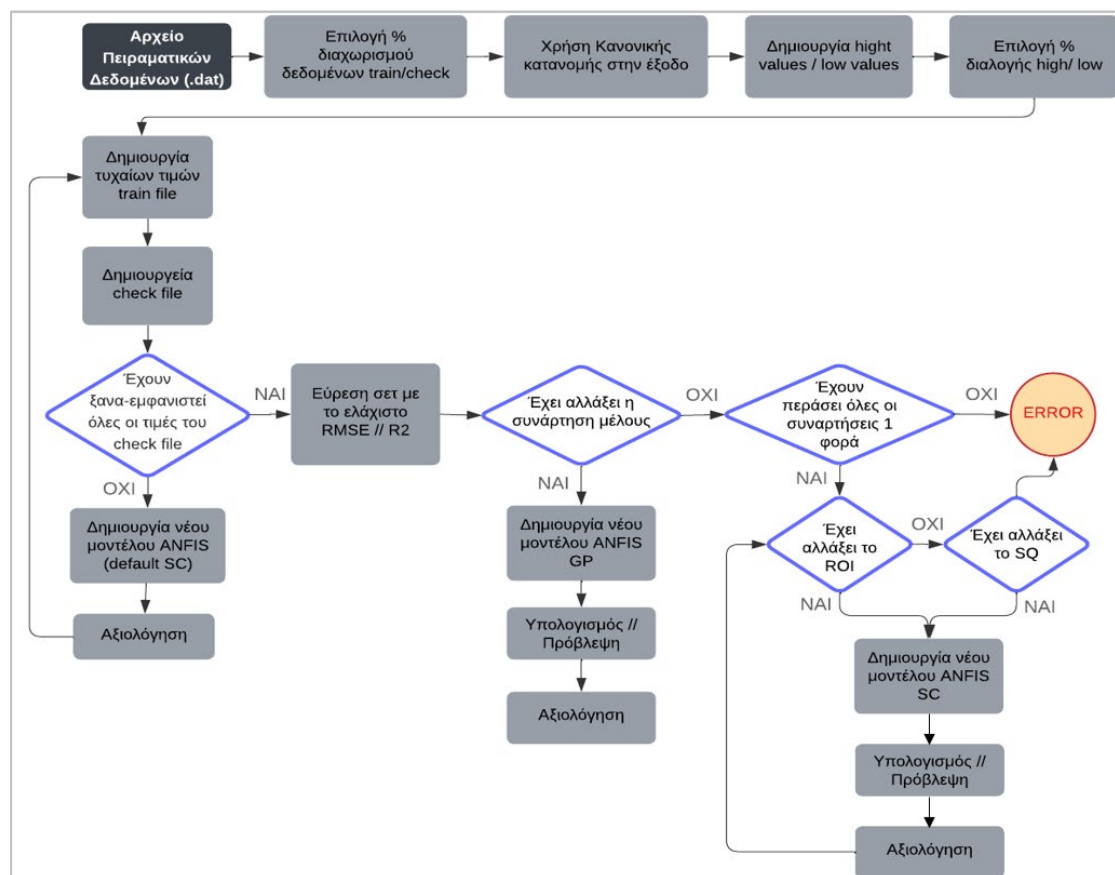
5.2 Μοντέλο ANFIS

Βασισμένο στα συλλεχθέντα δεδομένα, δημιουργήθηκε ένα αρχικό μοντέλο ANFIS. Το μοντέλο αυτό χρησιμοποίησε μια αρχική δέσμη κανόνων και συναρτήσεων συμμετοχής για να προβλέψει τις μηχανικές ιδιότητες με βάση τις παραμέτρους εκτύπωσης. Στη συνέχεια, το μοντέλο εκπαιδεύτηκε χρησιμοποιώντας ένα υποσύνολο των δεδομένων. Για την αξιολόγηση της απόδοσής του, χρησιμοποιήθηκαν διάφορα μετρικά, όπως το σφάλμα των μέσων όρων τετραγώνων (RMSE) και τον συντελεστή ακρίβειας (R^2).

5.3 Βελτίωση και Αξιολόγηση Μοντέλου

Ακολούθησε η βελτίωση του μοντέλου μέσω της τροποποίησης των συναρτήσεων συμμετοχής. Διεξήχθησαν πολλαπλές δοκιμές με διάφορες μεθόδους, με στόχο την επίτευξη της μέγιστης ακρίβειας στις προβλέψεις. Μετά από κάθε βελτίωση, το μοντέλο υποβλήθηκε σε νέους ελέγχους με ανεξάρτητα δεδομένα ελέγχου. Η σύγκριση των αποτελεσμάτων αυτών με τα πραγματικά δεδομένα επέτρεψε την εκτίμηση της βελτίωσης της ακρίβειας των προβλέψεων.

Η παραπάνω πειραματική εφαρμογή μπορεί εκφραστεί πιο συνοπτικά με το παρακάτω λογικό διάγραμμα, το οποίο αποτελεί και την διαδικασία υλοποίησης τόσο της μελέτης περίπτωσης όσο και του προγραμματιστικού κώδικα.



Εικόνα 5.1: Λογικό Διάγραμμα της πειραματικής διαδικασίας

6 Εφαρμογή – Μελέτη Περίπτωσης

Αυτή η μελέτη βασίζεται σε 45 πειράματα που είχαν μελετηθεί προηγουμένως και διεξήχθησαν ακολουθώντας την μεθοδολογία σχεδιασμού πειραμάτων Taguchi. Σε αυτή την συλλογή και τα 45 πειράματα πραγματοποιήθηκαν με την προσθετική τεχνολογία FFF/FDM και καταπονήθηκαν σε δοκιμές καμπτικών φορτίων. Όσο αναφορά το υλικό εκτύπωσης, χρησιμοποιήθηκε σε όλα το PLA. (Tempeloudis, 2022)

Τα δεδομένα συλλέχθηκαν, ταξινομήθηκαν, κανονικοποιήθηκαν και υποβλήθηκαν σε επεξεργασία ώστε να είναι λειτουργικά ως δεδομένα εκπαίδευσης και ελέγχου για την ανάπτυξη ενός ANFIS. Στη συνέχεια πραγματοποιήθηκαν πολυάριθμες δοκιμές, χρησιμοποιώντας διάφορα μοντέλα και ρυθμίσεις, με στόχο την αναζήτηση της πιο αποδοτικής προσέγγισης που οδήγησε τελικά σε βέλτιστη σύγκλιση.

6.1 Συλλογή Δεδομένων

Τα πειραματικά δεδομένα αφού υποβλήθηκαν σε εκτενέστερη επεξεργασία, διαχωρίστηκαν σε δεδομένα εισόδου και εξόδου για το μοντέλο ANFIS. Τα δεδομένα εξόδου αποτελούνται από τις μηχανικές ιδιότητες του υλικού και είναι η μέγιστη τάση, η μέγιστη τροπή και το μέτρο ελαστικότητας

Όσον αφορά τους παραμέτρους για τα δεδομένα εισόδου είναι οι παράμετροι της διαδικασίας της 3D εκτύπωσης για το εκάστοτε πείραμα. (Tempeloudis, 2022) Αντικατοπτρίζουν τους πιο αποτελεσματικούς παράγοντες για το τελικό προϊόν, όπως προέκυψε μετά από τη βιβλιογραφική έρευνα. Οι εννέα παράγοντες είναι οι εξής:

- **Input 1, Infill Pattern:** Αντιπροσωπεύει το εσωτερικό μοτίβο του εξαρτήματος, για το οποίο οι διαθέσιμες γεωμετρίες είναι η ευθύγραμμη, η τριγωνική, η κηρήθρα, η σπείρα, ο σταυρός και το διαμάντι.
- **Input 2, Infill Percentage:** Το ποσοστό της μάζας του αντικειμένου που έχει επιλεγεί να γεμιστεί με υλικό. Αυτή η τιμή μπορεί να κυμαίνεται έως και 100%.
- **Input 3, Layer Thickness:** Αποτυπώνει το πάχος των διαδοχικών στρωμάτων και εκφράζεται σε χιλιοστά (mm).
- **Input 4, Speed:** Είναι η ταχύτητα του ακροφυσίου και εκφράζεται σε χιλιοστά ανά δευτερόλεπτο (mm/s).
- **Input 5, Extruder Temperature:** Είναι η θερμοκρασία του εκτυπωτή σε βαθμούς Κελσίου και χρησιμοποιείται μόνο για τις τεχνολογίες AM που χρησιμοποιούν αυτή τη λειτουργία.

- **Input 6, Bed Temperature:** Είναι η θερμοκρασία του κρεβάτι εκτύπωσης σε βαθμούς Κελσίου. Εάν αυτή η παράμετρος δεν εφαρμόζεται, τότε μπαίνει η θερμοκρασία δωματίου, 25°C.
- **Input 7, Position on Printer Bed:** Αποτυπώνει τη θέση του εξαρτήματος πάνω στο τραπέζι σε σχέση με το επίπεδο XY. Οι γωνίες σε σχέση με τον άξονα X είναι 0°, 30°, 45°, 60° και 90° (παράλληλα στον άξονα Y).
- **Input 8, Incline against Printer Bed:** Αποτυπώνει τη θέση του εξαρτήματος πάνω στο τραπέζι σε σχέση με το επίπεδο XZ. Οι γωνίες σε σχέση με τον άξονα X είναι 0°, 30°, 45°, 60° και 90° (παράλληλα στον άξονα Z).
- **Input 9, Raster Angle:** Εκφράζει τη γωνία κατά την οποία το εκτυπωμένο υλικό κατατίθεται σε σχέση με τον άξονα του κέντρου βάρους του.

INPUT 1	INPUT 2	INPUT 3	INPUT 4	INPUT 5	INPUT 6
Infill Pattern	Infill %	Layer thickness (mm)	Speed (mm/s)	Extruder Temperature	Bed Temperature
2	50	0.07	50	200	60
2	75	0.07	50	200	60
3	100	0.07	50	200	60
2	75	0.2	50	200	60
2	100	0.2	50	200	60

INPUT 7	INPUT 8	INPUT 9	OUTPUT 1	OUTPUT 2	OUTPUT 3
Position on Printer Bed	Incline against Printer Bed	Raster Angle	Max Stress (Mpa)	Elongation (%) Strain	Young modulus (GPa)
1	1	5	14.00	5.80	6.03
3	1	5	12.00	7.00	4.29
5	1	7	13.00	5.00	6.50
5	1	5	13.00	8.50	3.82
1	1	5	8.50	5.00	4.25

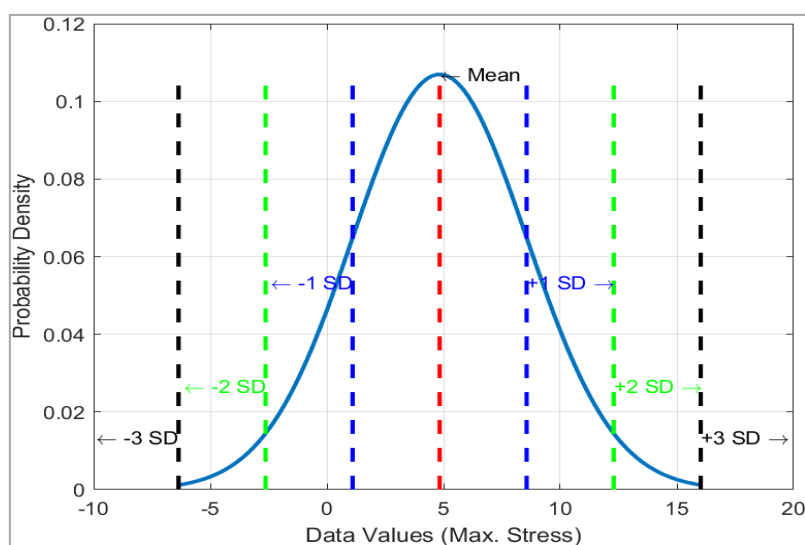
Πίνακας 6-1: Δείγμα από τα δεδομένα εισόδου κα εξόδου

6.2 Κατηγοριοποίηση Δεδομένων

Τρία επιμέρους σύνολα δεδομένων προκύπτουν από το σύνολο δεδομένων του [Πίνακα 1](#), ένα για κάθε εξεταζόμενη μηχανική ιδιότητα. Στην πραγματικότητα, οι εννέα στήλες παραμένουν ίδιες και μόνο η τελευταία είναι διαφορετική καθώς περιέχει τις τιμές είτε για μέγιστη τάση, για μέγιστη τροπή ή για μέτρο ελαστικότητας αντίστοιχα. Κάθε ένα από τα σύνολα δεδομένων αποθηκεύεται ως κείμενο με την επέκταση αρχείου ".dat" προκειμένου να είναι συμβατό με το MATLAB.

Γίνεται χρήση εξατομικευμένου κώδικα, ο οποίος έχει ως κύριο στόχο να διαχωρίσει ένα σύνολο σε δύο υποσύνολα: ένα για εκπαίδευση (train) και ένα για έλεγχο (check). Αρχικά πρέπει να οριστεί το ποσοστό πλήρωσης του συνόλου των δεδομένων σε train/ check, το οποίο με βάση την βιβλιογραφία ανέρχεται περίπου στο 80%/ 20% αντίστοιχα.

Ο στόχος εδώ, ήταν να προσομοιωθεί η ανθρώπινη τυχαία επιλογή για αυτά τα δύο υποσύνολα. Γιαυτό λοιπόν, για να έχουν και τα δύο υποσύνολα αντιπροσωπευτικό δείγμα από όλο το εύρος των δεδομένων του συνόλου επιλέχθηκε η χρήση της στατιστικής πιθανότητας κανονικής κατανομής. Πιο συγκεκριμένα, η κανονική κατανομή εφαρμόστηκε στα δεδομένα εξόδου.



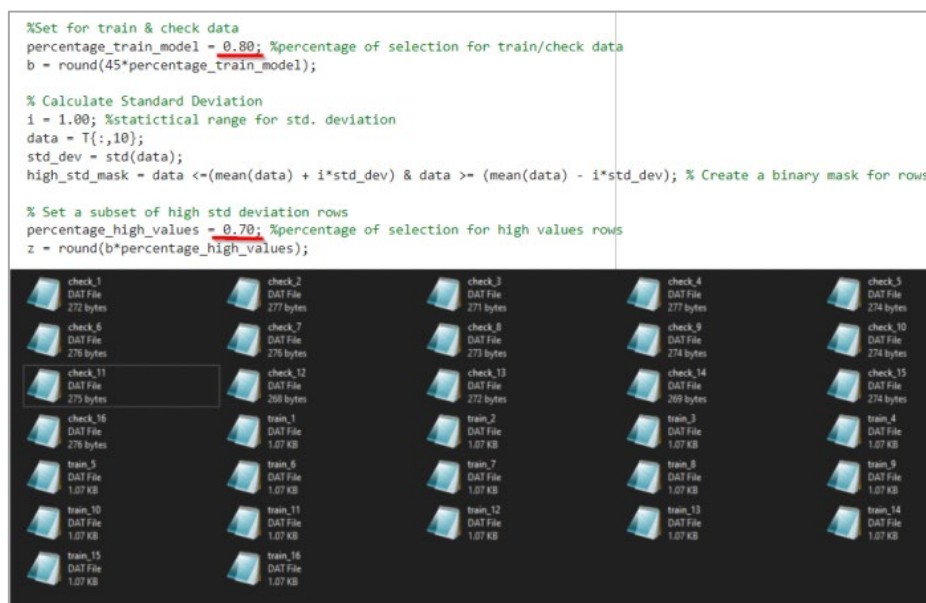
Διάγραμμα 6-1: Κανονική Κατανομή για Μέγιστη Τάση (MPa)

Υπολογίζεται η τυπική απόκλιση και ορίστηκε το διάστημα εμπιστοσύνης. Με βάση την διεθνή βιβλιογραφία και τον εμπειρικό κανόνα (Ibe, 2014), το διάστημα εμπιστοσύνης θα είναι ίσο με $\mu \pm 1\sigma$. Έτσι δημιουργούνται δύο πίνακες τιμών, όπου ο ένας περιέχει τα δεδομένα που ανήκουν εντός του διαστήματος εμπιστοσύνης (high values) και ο άλλος τα δεδομένα που δεν ανήκουν (low values).

Στην συνέχεια, οι δύο αυτοί πίνακες διαιρούνται με ένα ποσοστό έτσι ώστε να αυξηθεί η τυχαιότητα των δεδομένων των υποσυνόλων. Η διαίρεση αυτή γίνεται με τέτοιο τρόπο ώστε και τα δύο υποσύνολα (train/ check) να περιέχουν ένα ποσοστό δεδομένων με υψηλή τυπική απόκλιση (high values) και ένα με χαμηλή (low values). Έτσι κάθε υποσύνολο περιέχει δεδομένα από όλο το φάσμα τιμών.

Η παραπάνω διαδικασία πραγματοποιείται ώστε να διαμορφωθεί πρώτα το υποσύνολο με τα δεδομένα εκπαίδευσης (train) και στην συνέχεια με τα δεδομένα που υπολείπονται διαμορφώνεται και το υποσύνολο ελέγχου (check). Η διαδικασία επαναλαμβάνεται και κατ' επέκταση δημιουργούνται αντίστοιχα σετ υποσυνόλων

train/ check ώσου όλα τα δεδομένα από το αρχικό σύνολο βρεθούν έστω και μία φορά στο υποσύνολο ελέγχου.




Εικόνα 6.1: Παράδειγμα [Train/Check 0.80 – High/Low 0.70 – Επαναλήψεις 16]


6.2.1 Επιλογή κατάλληλου σετ (train/check) με χρήση ANFIS

Το κάθε μοντέλο ANFIS, χρειάζεται μόνο ένα σετ τιμών για να λειτουργήσει. Για να επιλεγεί το πιο κατάλληλο σετ τιμών από την επαναληπτική διαδικασία που προηγήθηκε θα πρέπει να χρησιμοποιηθεί μια μέθοδος σύγκρισης. Πιο συγκεκριμένα, επιλέχθηκε η χρήση ενός απλού σταθερού μοντέλου subtractive clustering μέσω του ANFIS και κάθε σετ αξιολογείται για την απόδοσή του, χρησιμοποιώντας, ως μετρικό σύστημα, το σφάλμα των μέσων όρων τετραγώνων (RMSE) και τον συντελεστή ακρίβειας (R^2).

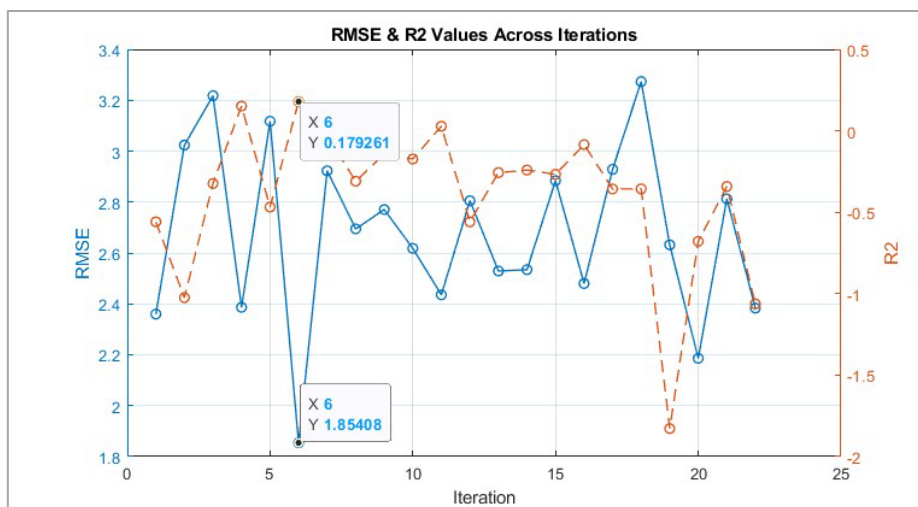
Με αυτό τον τρόπο η αξιολόγηση είναι αντικειμενική καθώς χρησιμοποιείται ο ίδιος αλγόριθμος για κάθε σετ τιμών και διασφαλίζεται η χρήση της βέλτιστης τοποθέτησης τιμών τόσο για τα δεδομένα εκπαίδευσης όσο και για τα δεδομένα ελέγχου. Συνεπώς, για τα τρία σύνολα μελέτης (μέγιστη τάση, μέγιστη τροπή, μέτρο ελαστικότητας) και με παραμέτρους 80% train/check και 70% high/low, παρουσιάζεται η επαναληπτική διαδικασία καθώς και το βέλτιστο σετ τιμών (train/check).



Διάγραμμα 6-2: Επιλογή σει για Max. Stress



Διάγραμμα 6-3: Επιλογή σει για Max. Strain



Διάγραμμα 6-4: Επιλογή σει για Young Modulus

Στα παραπάνω διαγράμματα, παρατηρείται η συσχέτιση των μετρικών RMSE και R^2 σε κάθε ένα από τα δεδομένα πρόβλεψης. Η σχέση μεταξύ τους είναι αντιστρόφως ανάλογη, δηλαδή όσο μικρότερο είναι το μέσο σφάλμα των τιμών πρόβλεψης τόσο μεγαλύτερη θα είναι η ακρίβεια του μοντέλου. Επιπρόσθετα, όταν η ακρίβεια R^2 είναι κάτω που μηδενός αυτό σημαίνει ότι ο συγκεκριμένος αλγόριθμος και κατ' επέκταση το ίδιο το μοντέλο δεν είναι κατάλληλο για αυτά τα δεδομένα.

Πιο συγκεκριμένα, στο [Διάγραμμα 6-2](#) παρατηρείται ότι το κάθε σετ τιμών διαφέρει αρκετά από τα υπόλοιπα. Στις επαναλήψεις 4, 9, 15 το μέσο σφάλμα μπορεί να είναι πολύ κοντά με απόκλιση ± 0.3 όμως έχουν διαφορετική ακρίβεια σε όλο το φάσμα του μοντέλου. Επίσης η επανάληψη 15 έχει το μικρότερο σφάλμα όμως η ακρίβεια της είναι πολύ χαμηλή. Αν η σύγκριση γινόταν μόνο στο ένα μετρικό, το RMSE, τότε θα είχαμε ναι μεν μαθητικά το μικρότερο σφάλμα, αλλά το μοντέλο μας δεν θα ήταν κατάλληλο για την λύση αυτού του προβλήματος. Αυτό μας δείχνει την αναγκαιότητα της χρήσης και των δύο μετρικών για να υπάρχει μια πιο αντικειμενική αξιολόγηση του κάθε μοντέλου.

Στο [Διάγραμμα 6-3](#) παρατηρείται η ίδια ακολουθία, με αρκετές επαναλήψεις να παράγουν περίπου τα ίδια αποτελέσματα. Από επανάληψη σε επανάληψη μεταβάλλονται αρκετά τα μετρητικά, γεγονός που δείχνει την διαφορετικότητα των κάθε σετ και την επίτευξη της τυχαίας επιλογής τιμών.

Τέλος στο [Διάγραμμα 6-4](#) παρατηρείται ότι η ακρίβεια του μοντέλου είναι πάρα πολύ χαμηλά της τάξεως του 0.2. Αυτό σημαίνει ότι για τα συγκεκριμένα δεδομένα η χρήση ενός τέτοιου μοντέλου δεν καθιστάτε σωστή καθώς είναι πάρα πολύ αδύναμο στην πρόβλεψη των τιμών για το μέτρο ελαστικότητας. Επιπρόσθετα, έχοντας ήδη αυτή την πληροφορία αναμένεται περαιτέρω εξέταση για την συνολική βελτίωση του μοντέλου.

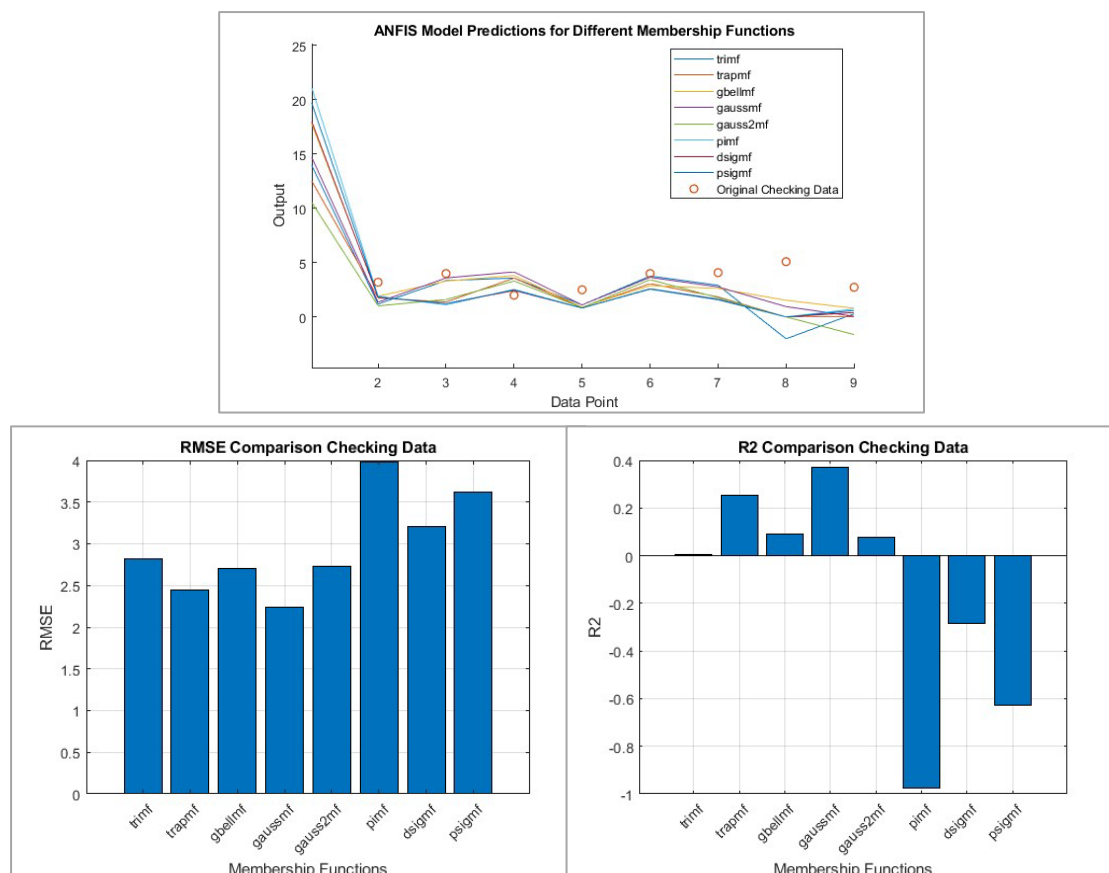
6.3 Μοντέλο ANFIS

Σε ένα μοντέλο ANFIS πέρα από τα δεδομένα εισόδου και εξόδου χρειάζεται να προσδιορίσουμε και τον αλγόριθμο που θα χρησιμοποιήσει για την επίλυση του μοντέλου. Οι διαθέσιμες επιλογές στο συγκεκριμένο νευρωνικό δίκτυο είναι grid partition και subtractive clustering. Στο κομμάτι της βελτίωσης του μοντέλου, θα χρησιμοποιηθούν και οι δύο αλγόριθμοι και θα συγκριθούν με σκοπό την καλύτερη απόδοση στα συγκεκριμένα δεδομένα.

Grid Partition

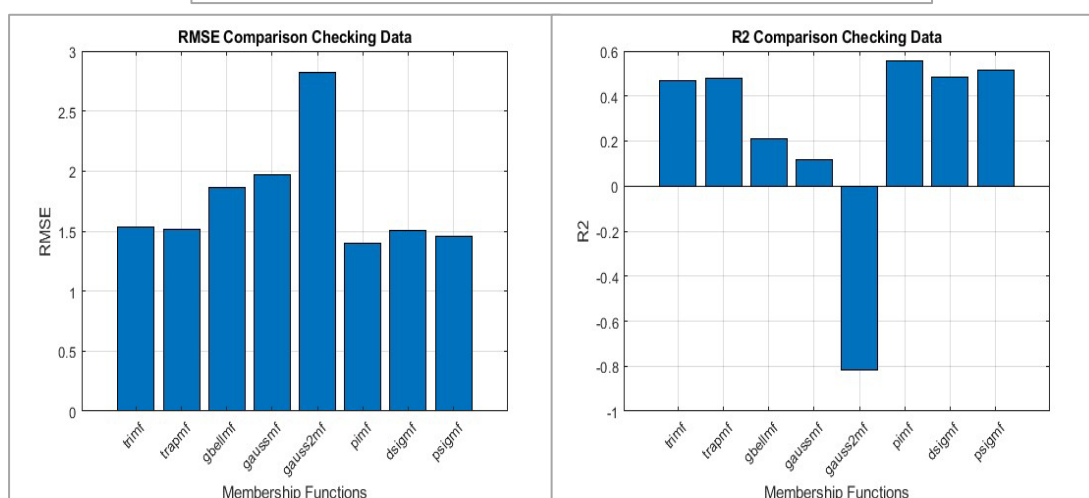

Στο grid partition οι παράμετροι που επηρεάζουν το μοντέλο είναι το είδος και το πλήθος των συναρτήσεων μελών. Για την απλοποίηση του προβλήματος το πλήθος των συναρτήσεων είναι σταθερό και ίσο με 2 και η συσχέτιση γίνεται στα διάφορα είδη των συναρτήσεων μελών. Οι συναρτήσεις όπου συγκρίθηκαν είναι: trimf, trapmf, gbellmf, gaussmf, gauss2mf, pimf, dsigmf, psigmf. ([Παράρτημα Α](#)) Όπως και

προηγουμένως έτσι και εδώ κάθε συνάρτηση μέλος αξιολογείται για την απόδοσή της στα αποτελέσματα της πρόβλεψης με τους δείκτες (RMSE) και (R^2).



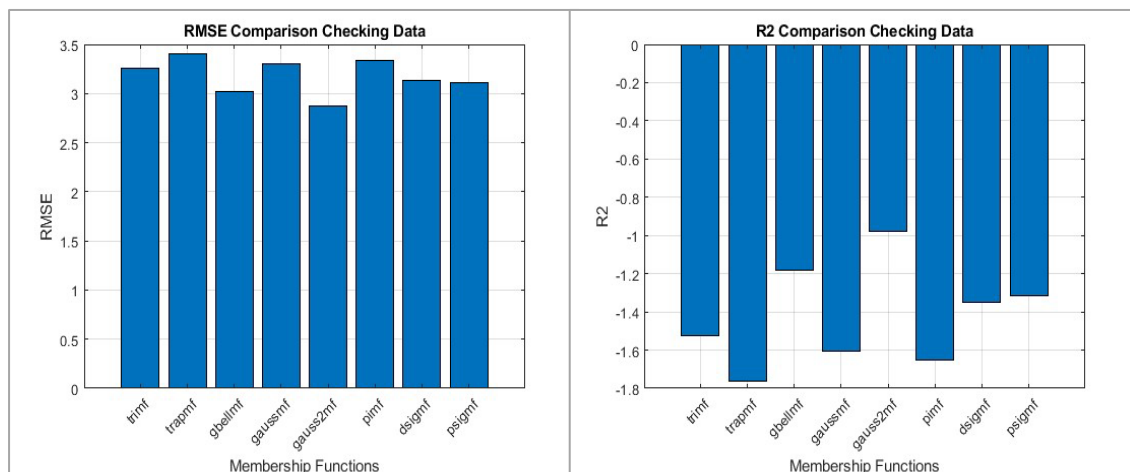
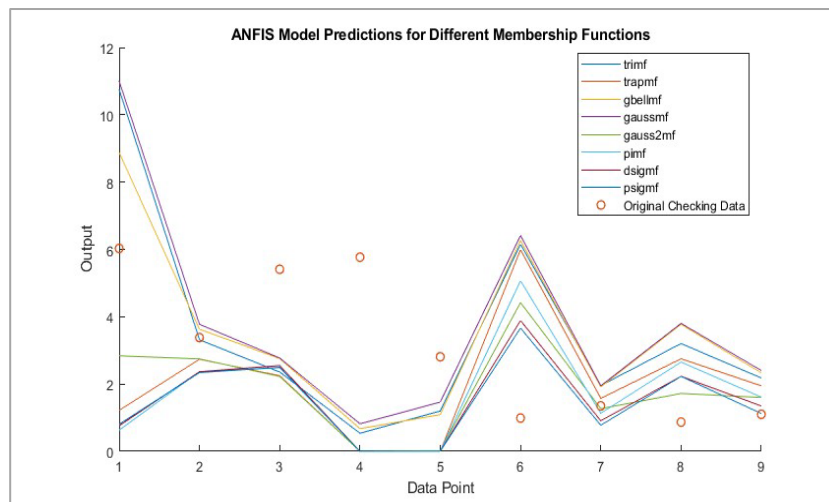
Διάγραμμα 6-5: Συναρτήσεις μελών για πρόβλεψη Maximum Stress

Στο πρώτο γράφημα αποτυπώνεται οι προβλέψεις των συναρτήσεων μελών συναρτήση με τα πραγματικά προβλεπόμενα αποτελέσματα. Παρατηρείται ότι σχεδόν όλες οι συναρτήσεις μέλη έχουν παρόμοια κυματομορφή και η ουσιαστική διαφορά είναι η απόκλιση τους από το πραγματικά δεδομένα. Όσο αναφορά το μέσο σφάλμα τιμών, οι πιο συνηθισμένες συναρτήσεις τριγωνική, τραπεζοειδής και γκαουσιανή έχουν και τα μικρότερα σφάλματα με ελάχιστο αυτό τις γκαουσιανής στα ± 2.24 MPa. Αντίστοιχα, η ακρίβεια του μοντέλου είναι αρκετά χαμηλή της τάξεως του 0.37. Με την σύγκριση αυτή, παρατηρήθηκε ότι οι συναρτήσεις ρ_i , ρ_{si} , d_{si} δεν υποστηρίζουν στα μέγιστα το μοντέλο, ενώ στην συνέχεια η βελτίωση θα επικεντρωθεί στην γκαουσιανή συνάρτηση με χρήση άλλου αλγορίθμου για να εξεταστεί αν θα υπάρξουν καλύτερα αποτελέσματα.



Διάγραμμα 6-6: Συναρτήσεις μελών για πρόβλεψη Maximum Strain

Για το μοντέλο πρόβλεψης της μέγιστης τροπής, παρατηρείται μια διαφορά στις κυματομορφές των συναρτήσεων μελών. Πιο συγκεκριμένα, φαίνεται πιο ξεκάθαρα ο τρόπος που προσεγγίζει η κάθε συνάρτηση μέλος τα δεδομένα καθώς επίσης και την δυνατότητα πρόβλεψης του μοντέλου συνολικά. Στις ακραίες τιμές του σετ των δεδομένων φαίνεται το μοντέλο να παρουσιάζει τις μεγαλύτερες αποκλίσεις, ενώ στις πιο συνήθεις είναι πάρα πολύ κοντά. Όσο αναφορά το μέσο σφάλμα τιμών, η συνάρτηση μέλος π είναι αυτή που έχει τις μικρότερες αποκλίσεις στα ± 1.39 και ακολουθούν η τριγωνική και τραπεζοειδής. Αντίστοιχα, η ακρίβεια του μοντέλου είναι ικανοποιητική στο 0.55. Τέλος, με την σύγκριση αυτή παρατηρήθηκε ότι οι γκαουσιανές συναρτήσεις με την χρήση του συγκεκριμένου αλγορίθμου δεν υποστηρίζουν στα μέγιστα το μοντέλο γεγονός που διαφοροποιεί αρκετά σε σχέση με αυτό των μέγιστων τάσεων.



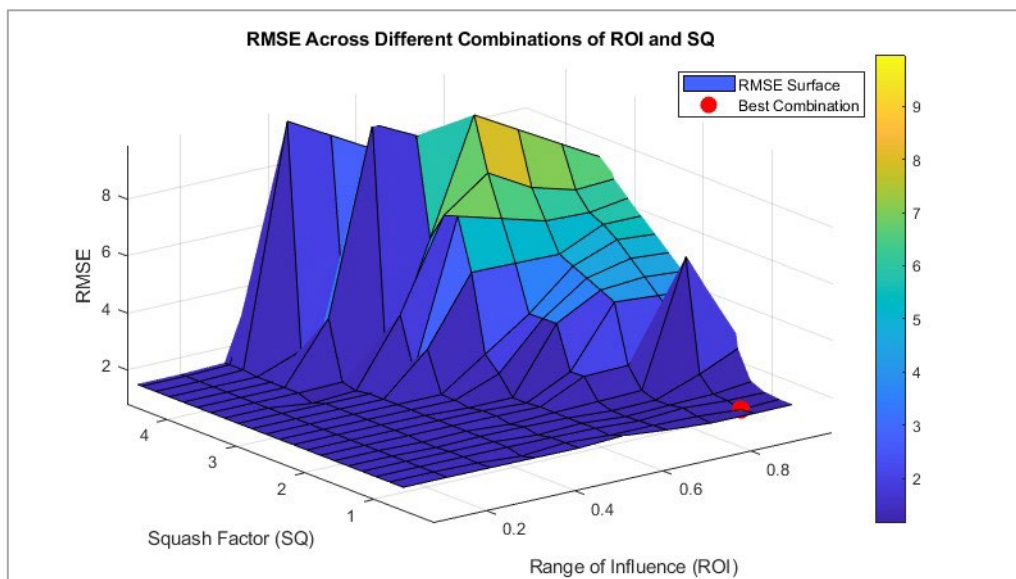
Διάγραμμα 6-7: Συναρτήσεις μελών για πρόβλεψη Young Modulus

Για το μοντέλο πρόβλεψης του μέτρου ελαστικότητας, παρατηρείται έντονη απόκλιση στις κυματομορφές των συναρτήσεων μελών με βάση τα πραγματικά δεδομένα, ενώ όλες οι συναρτήσεις μέλη σχεδόν πολύ παρόμοια συμπεριφορά. Αυτό διατυπώνεται και στο γράφημα του RMSE όπου το μικρότερο μέσο σφάλμα τιμών ανέρχεται στα ± 2.87 GPa. Γενικότερα, μετά την μελέτη που έγινε φανερώνεται η αδυναμία του συγκεκριμένου αλγορίθμου για το συγκεκριμένο μοντέλο πρόβλεψης καθώς δεν υπάρχει καθόλου ακρίβεια στο τελικό μοντέλο.

Subtractive Clustering

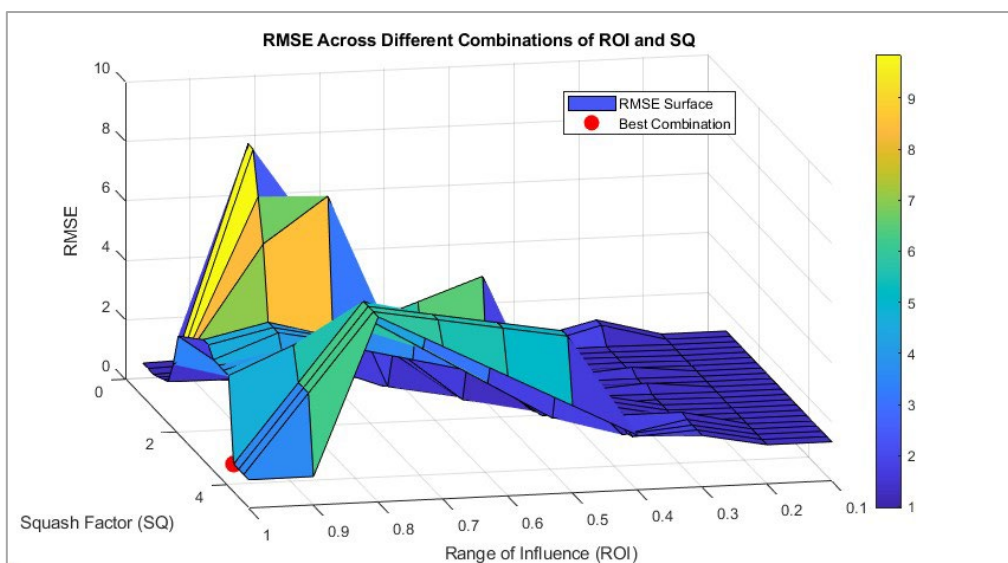
Στο subtractive clustering οι παράμετροι που επηρεάζουν το μοντέλο είναι range of influence, squash factor, accept ratio και reject ratio. Η διερεύνηση και η βελτίωση επικεντρώθηκε στο range of influence (ROI) και squash factor (SQ). Το ROI μπορεί να πάρει τιμές από 0 έως 1 και το SQ από 0.7 έως 5. Αντίστοιχα το accept ratio έχει σταθερή τιμή και ίση με 0.5 και το reject ratio έχει σταθερή τιμή και ίση με 0.15. Σε αυτό το στάδιο η βελτίωση γίνεται με τον εξής τρόπο. Αφού έχουν οριστεί τα

κατάλληλα βήματα ακολουθίας (Tempeloudis, 2022) για κάθε παράμετρο και συγκεκριμένα βήμα 0.1 και 0.2 για το ROI και SQ αντίστοιχα, υπολογίζονται όλοι οι πιθανοί συνδυασμοί και γίνεται αξιολόγηση για κάθε έναν συνδυασμό με τους δείκτες (RMSE) και (R^2). (Παράρτημα Α)



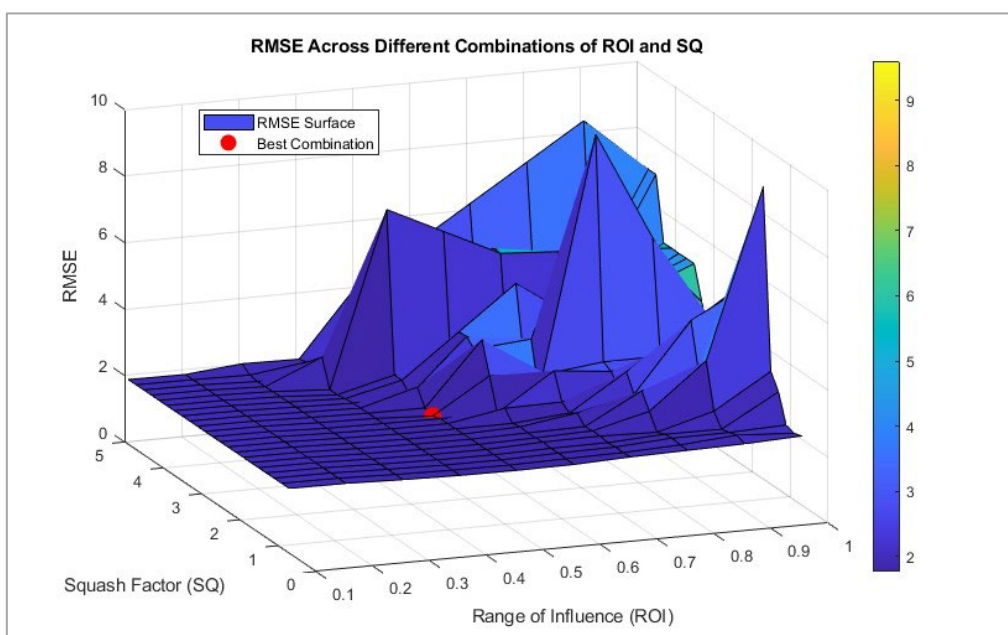
Διάγραμμα 6-8: Παράμετροι για πρόβλεψη Maximum Stress

Στο παραπάνω διάγραμμα, παρατίθεται η συσχέτιση των δυο κύριων παραμέτρων ROI, SQ με το μέσο σφάλμα. Όπως φαίνεται, είναι δύο παράμετροι που επηρεάζουν άμεσα την απόδοση του μοντέλου και δρουν κατά κύριο λόγο ανάλογα. Με άλλα λόγια, όταν υπάρχει μεγάλη τιμή και στα δύο το σφάλμα ανεβαίνει αισθητά και μερικές φορές καθιστά και τον αλγόριθμο ακατάλληλο λόγω ακρίβειας. Αντίθετα σε χαμηλές τιμές και τον δύο υπάρχει μια καλύτερη εξομάλυνση των αποτελεσμάτων. Έπειτα από την αξιολόγηση που έγινε, ο καλύτερος συνδυασμός είναι ROI = 0.9 και SQ = 0.9, τα οποία μας εξάγουν ένα μέσο σφάλμα τιμών στα ± 1.15 MPa και με ακρίβεια μοντέλου στο 0.83.



Διάγραμμα 6-9: Παράμετροι για πρόβλεψη Maximum Strain

Σε αντίθεση με το προηγούμενο διάγραμμα, σε αυτό παρατηρείται ότι σε χαμηλές τιμές SQ και υψηλές ROI έχουμε μεγαλύτερο σφάλμα, ενώ όσο μικραίνει ROI το φάσμα των σφαλμάτων γίνεται μικρότερο σε όλο το εύρος τιμών SQ. Επιπρόσθετα, το μοντέλο αυτό διαφέρει πολύ από αυτό των τάσεων καθώς εδώ το πλήθος των σφαλμάτων δύναται να κυμαίνονται στην μεσαία ζώνη πιο πολύ, σε αντίθεση με των τάσεων που ήταν στην χαμηλή ζώνη. Πιο αναλυτικά μετά την αξιολόγηση που έγινε, ο καλύτερος συνδυασμός είναι ROI = 1.0 και SQ = 4.30, τα οποία μας εξάγουν ένα μέσο σφάλμα τιμών στα ± 0.96 και με ακρίβεια μοντέλου στο 0.78.



Διάγραμμα 6-10: Παράμετροι για πρόβλεψη Young Modulus

Όσο αναφορά το μοντέλο για την πρόβλεψη του μέτρου ελαστικότητας, παρατηρήθηκε ότι επί το πλείστον η απόκλιση από τις πραγματικές τιμές παραμένει σε χαμηλές τιμές και μόνο όταν οι δύο συντελεστές αρχίζουν να παίρνουν τις μέγιστες/ακραίες τιμές τότε υπάρχει και το μεγαλύτερο σφάλμα. Σε αντίθεση με τα προηγούμενα γραφήματα, ο καλύτερος συνδυασμός του ROI και SQ βρίσκεται στο κέντρο των τιμών μελέτης και όχι σε όριο του πεδίου. Πιο συγκεκριμένα, αποτελείται από ROI = 0.5 και SQ = 2.90, τα οποία μας δίνουν ένα μέσο σφάλμα τιμών στα ± 1.77 GPa και με ακρίβεια μοντέλου στο 0.25.

7 Συμπεράσματα - Συζήτηση

Η παρούσα μελέτη αναδεικνύει τη συμβολή του Νευροασαφούς Συστήματος (ANFIS) στη βελτιστοποίηση των παραμέτρων της Προσθετικής Κατασκευής, προσφέροντας μια καινοτόμο προσέγγιση στη διαχείριση πολύπλοκων προβλημάτων μηχανικών ιδιοτήτων των εκτυπωμένων εξαρτημάτων. Τα πειραματικά δεδομένα και τα αποτελέσματα που προέκυψαν επιβεβαιώνουν την εγκυρότητα και την αξιοπιστία του ANFIS στη βελτίωση της ακρίβειας και της αποδοτικότητας των διεργασιών εκτύπωσης.

Συγκεκριμένα, η μελέτη έδειξε ότι το ANFIS κατάφερε να προσαρμόσει τις παραμέτρους εκτύπωσης ανάλογα με τις εκάστοτε συνθήκες, οδηγώντας σε σημαντική βελτίωση των μηχανικών ιδιοτήτων όπως η τάση, η παραμόρφωση και το μέτρο ελαστικότητας. Οι δείκτες αξιολόγησης, όπως το μέσο τετραγωνικό σφάλμα (RMSE) και ο συντελεστής ακρίβειας (R^2), απέδειξαν ότι το μοντέλο μπορεί να προβλέπει αξιόπιστα τις συμπεριφορές των εκτυπωμένων εξαρτημάτων υπό διαφορετικές συνθήκες. Παρά τους περιορισμούς που παρουσιάστηκαν λόγω του περιορισμένου μεγέθους του δείγματος, η αξιολόγηση των αποτελεσμάτων αναδεικνύει τη δυνατότητα περαιτέρω βελτίωσης του μοντέλου με μεγαλύτερα δείγματα και πιο εκτεταμένες δοκιμές.

Η συμβολή αυτής της μελέτης στην έρευνα για την Προσθετική Κατασκευή είναι καθοριστική, ανοίγοντας νέους δρόμους για την ανάπτυξη αυτόματων και αυτοβελτιούμενων συστημάτων παραγωγής. Επιπλέον, τα ευρήματα ενισχύουν την εμπιστοσύνη στην εφαρμογή του ANFIS σε πραγματικές βιομηχανικές εφαρμογές, όπου απαιτείται υψηλή ακρίβεια και προσαρμοστικότητα.

Το πρώτο πράγμα που ξεχωρίζει είναι η μοναδικότητα και η ιδιαιτερότητα της κάθε περίπτωσης ξεχωριστά. Όπως μελετήθηκε και εδώ θα ήταν λάθος να θεωρηθεί ένα κοινό μοντέλο νευροασαφούς και για τις τρεις περιπτώσεις εξόδων. Ήδη από τα πρώτα διαγράμματα επιλογής τιμών και καθορισμού των σετ, η κάθε μια μελέτη πρόβλεψης είχε μεγάλη διαφορά σε σχέση με τις άλλες δύο και μας έδωσαν πολύ διαφορετικά αρχικά δεδομένα όπως φάνηκε και στα διαγράμματα [6.2](#), [6.3](#), [6.4](#). Εν

συνεχεία, ήταν γνωστό ότι το σύνολο δεδομένων με τις 45 τιμές, είναι ένα αρκετά μικρό σύνολο για να καλυφθούν επαρκώς οι ανάγκες ενός τέτοιου μοντέλου με αποτελεσματικότητα και ακρίβεια. Αυτό παρατηρήθηκε πιο έντονα στα διαγράμματα [6.5](#), [6.6](#), [6.7](#) όπου η ακρίβεια του μοντέλου αρκετές φορές έφτανε σε αρνητικές τιμές και οι αποκλίσεις από τα αρχικά δεδομένα ελέγχου ήταν μεγάλες.

Πρόβλεψη Μέγιστης Τάσης (Maximum Stress)

Το αρχικό μοντέλο ANFIS ξεκίνησε με μέσο σφάλμα τιμών στο ± 1.35 MPa και ακρίβειας στο 0.77 και κατέληξε με μέσο σφάλμα τιμών στο ± 1.15 MPa και ακρίβειας στο 0.83. Για την συγκεκριμένη μελέτη η βελτίωση που επιτεύχθηκε είναι ότι μειώθηκε το σφάλμα κατά 14% και αυξήθηκε η ακρίβεια κατά 7%.

	<i>RMSE (MPa)</i>	<i>R²</i>
<i>Initial (Set Selection)</i>	1.35	0.77
<i>Grid Partition</i>	2.24	0.37
<i>Subtractive Clustering</i>	1.15	0.83

Επιπρόσθετα, αξίζει να σημειωθεί η συσχέτιση των ίδιων των αλγορίθμων. Πιο συγκεκριμένα όπως φάνηκε και στο [διάγραμμα 6.2](#) η καλύτερη συνάρτηση μέλος για τον αλγόριθμο grid partition ήταν η γκαουσιανή με μέσο σφάλμα στο ± 2.24 MPa και ακρίβεια στο 0.37. Από την άλλη πλευρά ο αλγόριθμος του subtractive clustering χρησιμοποιεί και αυτός γκαουσιανή συνάρτηση με τα αποτελέσματα που προαναφέρθηκαν και με διαφορές 49% και 55% στο μέσο σφάλμα και την ακρίβεια αντίστοιχα. Αυτό σημαίνει ότι καθοριστικό ρόλο παίζει η χρήση όχι μόνο της σωστής συνάρτησης μέλους αλλά του σωστού αλγορίθμου μηχανικής μάθησης ώστε να αποτυπωθούν καλύτερα τα δεδομένα του προβλήματος. Το τελευταίο στάδιο της βελτίωσης ολοκληρώθηκε με την περαιτέρω ανάλυση στις παραμέτρους του subtractive clustering όπως αυτές αποτυπώνονται στο [διάγραμμα 6.8](#).

Πρόβλεψη Μέγιστης Τροπής (Maximum Strain)

Όσο αναφορά το αρχικό μοντέλο ANFIS για την μέγιστη τροπή ξεκίνησε με μέσο σφάλμα τιμών στο ± 1.34 και ακρίβειας στο 0.58 και κατέληξε με μέσο σφάλμα τιμών στο ± 0.96 και ακρίβειας στο 0.78. Για την συγκεκριμένη μελέτη η βελτίωση που επιτεύχθηκε είναι ότι μειώθηκε το σφάλμα κατά 28% και αυξήθηκε η ακρίβεια κατά 25%.

	<i>RMSE</i>	<i>R²</i>
<i>Initial (Set Selection)</i>	1.34	0.58
<i>Grid Partition</i>	1.39	0.55

Subtractive Clustering | 0.96 | 0.78

Σε αυτή την περίπτωση, η καλύτερη συνάρτηση μέλος ήταν η π για τον αλγόριθμο του grid partition ενώ για το subtractive clustering παρέμεινε η γκαουσιανή. Οι δυο αλγόριθμοι έχουν διαφορετικό τρόπο που διαχειρίζονται τα υποσύνολα των δεδομένων και διαφορετική κατηγοριοποίηση, συνεπώς είναι λογικό να ικανοποιούνται με διαφορετικές συναρτήσεις μελών καθώς αλλάζει η μαθηματική προσέγγιση του μοντέλου αυτού καθαυτού. Αξίζει να σημειωθεί ότι η τροπή είναι ένα αδιάστατο μέγεθος εξ-ορισμού και η πρόβλεψη του δυσκολεύει τα μαθηματικά μοντέλα των αλγορίθμων.

Πρόβλεψη Μέτρου Ελαστικότητας (Young Modulus)

Το μοντέλο για το μέτρο ελαστικότητας ξεκίνησε με μέσο σφάλμα τιμών στο ± 1.85 GPa και ακρίβειας στο 0.17 και κατέληξε με μέσο σφάλμα τιμών στο ± 1.77 GPa και ακρίβειας στο 0.25. Για την συγκεκριμένη μελέτη η βελτίωση που επιτεύχθηκε είναι ότι μειώθηκε το σφάλμα κατά 5% και αυξήθηκε η ακρίβεια κατά 32%.

	RMSE (GPa)	R^2
<i>Initial (Set Selection)</i>	1.85	0.17
<i>Grid Partition</i>	2.87	-0.95
<i>Subtractive Clustering</i>	1.77	0.25

Σε αυτό το μοντέλο, η επιλογή του δεύτερου αλγορίθμου είναι μονόδρομος. Από το [διάγραμμα 6.7](#), παρατηρείται η αστοχία του αλγορίθμου με μεγάλα σφάλματα και καθόλου ακρίβεια. Έπειτα από αρκετές πειραματικές προσπάθειες και με τον αλγόριθμο subtractive clustering, επιτεύχθηκε η τελική ακρίβεια να μην αυξημένη αλλά παρέμεινε πολύ χαμηλή σε σχέση με τα υπόλοιπα μοντέλα. Αυτό δείχνει ότι πιθανόν η χρήση του συγκεκριμένου τεχνητού νευρωνικού δικτύου να μην είναι κατάλληλη για τέτοιου τύπου δεδομένα και να απαιτείται η χρήση ενός άλλου αλγορίθμου ή ενός άλλου μοντέλου προσέγγισης NN.

Συνολικά και στις τρεις περιπτώσεις μελέτης ο καταλληλότερος αλγόριθμος μεταξύ των δυο, έχοντας υπόψιν τις παραδοχές που έγιναν, είναι ο subtractive clustering. Το συγκεκριμένο αποτέλεσμα θα μπορούσε να ήταν διαφορετικό ή να μην υπήρχε διαφορά ανάμεσα στους αλγορίθμους. Ένας από τους περιορισμούς, που επηρέασαν και τις παραδοχές της μελέτης, ήταν η υπολογιστική δύναμη. Λόγω των πολλαπλών δεδομένων εισόδου στον αλγόριθμο grid partition, επιλέχθηκε η κάθε είσοδος να αναπαριστάτε από δύο ίδιες συναρτήσεις μέλους. Οι μέγιστες δυνατές συναρτήσεις ισούνται με τον αριθμό των δεδομένων, δηλαδή 36. Ένα τέτοιο μοντέλο είναι εξαιρετικά δύσκολο και απαιτεί εξελιγμένα μηχανήματα. Έπειτα από πειραματικές

δοκιμές τόσο στον χρόνο όσο και στην αντοχή της υπολογιστικής μηχανής επιλέχθηκαν οι 2.

Συμπερασματικά, η παρούσα διπλωματική εργασία ανέδειξε την αποτελεσματικότητα της ενσωμάτωσης του (ANFIS) με τις τεχνολογίες Προσθετικής Κατασκευής (AM) για τη βελτιστοποίηση των μηχανικών ιδιοτήτων των 3D εκτυπωμένων εξαρτημάτων δημιουργώντας το βέλτιστο μοντέλο για τον συγκεκριμένο τύπο δεδομένων. Η χρήση του ANFIS επέτρεψε την προσαρμοστική ρύθμιση των παραμέτρων εκτύπωσης βάσει των δεδομένων που συλλέχθηκαν, παρέχοντας αυξημένη ακρίβεια και αξιοπιστία στα αποτελέσματα. Ωστόσο, παραμένουν περιθώρια για περαιτέρω έρευνα και ανάπτυξη σε αυτό το πεδίο.

Μελλοντικά, η εφαρμογή του ANFIS και των σχετικών τεχνολογιών μηχανικής μάθησης στην Προσθετική Κατασκευή μπορεί να επεκταθεί με την ενσωμάτωση περισσότερων δεδομένων σε πραγματικό χρόνο και την ανάπτυξη πιο σύνθετων μοντέλων πρόβλεψης. Ένα πιθανό βήμα είναι η δημιουργία αυτόνομων συστημάτων κατασκευής, όπου οι μηχανές AM θα μπορούν να προσαρμόζονται αυτόματα σε νέα υλικά και γεωμετρίες χωρίς ανθρώπινη παρέμβαση.

Βιβλιογραφία

Carbajo, J. , N. S. H. F. N. X., 2024. Fabrication of Micro-Perforated Panel (MPP) sound absorbers using Digital Light Processing (DLP) 3D printing technology. *Applied Acoustics*, Τόμος 2016.

Chi Wu, J. L., 2023. Topology optimisation for design and additive manufacturing of functionally graded lattice structures using derivative-aware machine learning algorithms. *Additive Manufacturing*, Τόμος 78.

D.M.C. Santos, A. P., 2005. The development of 3D models through rapid prototyping concepts. *Materials Processing Technology*, 168(2), pp. 270-272.

Haykin, S., 2009. *Neural Networks & Learning Machines*. 3rd επιμ. s.l.:Pearson Education.

Hazlina Hamdan, B., 2013. *An Exploration of the Adaptive Neuro-Fuzzy - Thesis Phd*, s.l.: The University of Nottingham.

I. John Solomon, P. S., 2021. A review on the various processing parameters in FDM. *Materials Today*.

Ian Gibson, D. R. B. S., 2017. *Τεχνολογίες Προσθετικής Κατασκευής*. 1η Έκδοση επιμ. Αθήνας: Εκδόσεις Κριτική.

Ibe, O. C., 2014. *Fundamentals of Applied Probability and Random Processes*. 2nd επιμ. s.l.:Elsevier.

ISO/ASTM, 2021. *ISO/ ASTM 52900*, s.l.: s.n.

ISO/IEC, 2022. *ISO/ IEC 23053*, s.l.: s.n.

Lam, A., 2013. *Trend Hunter*. [Ηλεκτρονικό]

Available at: <https://www.trendhunter.com/trends/coca-cola-mini-me>

Ma, Q.-P., 2024. A bibliometric review on application of machine learning in additive. *Applied Materials Today*, Τόμος 40.

Massey, C. E., 2022. Understanding the role of segmentation on process-structure–property predictions made via machine learning. *The International Journal of Advanced Manufacturing Technology*, Τόμος 120, pp. 4011-4021.

Mehta, M., 2022. Federated learning-based semantic segmentation for pixel-wise defect detection in additive manufacturing. *Journal of Manufacturing Systems*, Τόμος 64, pp. 197-210.

Nohut, S., 2024. Machine learning assisted material development for lithography-based. *Open Ceramics*, Τόμος 18.

Pedersen, D. B., 2012. *Additive Manufacturing - Multi Material Processing and Part Quality Control*. PhD thesis, s.l.: Technical University of Denmark.

Sara Nasiri, M. R. K., 2021. Machine learning in predicting mechanical behavior of additively manufactured parts. *Journal of Materials Research and Technology*, p. 17.

Surucu, O., 2023. Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances. *Expert Systems with Applications*, Τόμος 221.

Tempeloudis, A., 2022. *ANFIS Methodology Development for Predicting and Optimizing the Mechanical Properties of AM Specimens*, s.l.: Thesis - UNIVERSITY OF WEST ATTICA – KINGSTON UNIVERSITY LONDON.

Yi Min, M. X. P. C. Y. S., 2024. Machine learning for predicting fatigue properties. *Chinese Journal of Aeronautics*, 37(4), pp. 1-22.

Yim, S., 2023. Effect of powder morphology on flowability and spreading behavior in powder bed fusion additive manufacturing process: A particle-scale modeling study. *Additive Manufacturing*, Τόμος 72.

Μαστοροκώστας, Π., 2015. *Εισαγωγή στην ασαφή λογική- ασαφή σύνολα- συναρτήσεις συμμετοχής*. s.l.:Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις.

Παράρτημα Α

Κώδικας Matlab

Αρχικοποίηση τιμών

```
T = readtable('stress.dat', 'Delimiter', '\t');
```

```
rmseValues = [];  
R2Values = [];  
iteration = 0;  
totalRows = height(T);  
seen_in_check = false(totalRows, 1);  
  
%Set for train & check data  
percentage_train_model = 0.80; %percentage of selection for train/check  
data  
b = round(45*percentage_train_model);  
  
% Calculate Standard Deviation  
i = 1.00; %statistical range for std. deviation  
data = T{:,10};  
std_dev = std(data);  
high_std_mask = data <=(mean(data) + i*std_dev) & data >= (mean(data) -  
i*std_dev); % Create a binary mask for rows  
  
% Set a subset of high std deviation rows  
percentage_high_values = 0.70; %percentage of selection for high values  
rows  
z = round(b*percentage_high_values);  
  
while any(~seen_in_check)  
    high_std_indices = find(high_std_mask); % Select rows with high values  
    num_high_std = min(z, length(high_std_indices)); % Select a subset of  
high values rows  
    selected_high_std_indices =  
high_std_indices(randperm(length(high_std_indices), num_high_std));  
    remaining_indices = setdiff(1:totalRows, selected_high_std_indices); %  
Select remaining rows  
    num_remaining = b - num_high_std;  
    selected_remaining_indices =  
remaining_indices(randperm(length(remaining_indices), num_remaining));  
  
    train_indices = [selected_high_std_indices;  
selected_remaining_indices'];  
    train = T(train_indices, :);  
    check_indices = setdiff(1:totalRows, train_indices);  
    check = T(check_indices, :);  
  
    if any(~seen_in_check(check_indices))  
        seen_in_check(check_indices) = true;  
        \  
        iteration = iteration + 1;  
        train_file = sprintf('train_%d.dat', iteration);  
        writetable(train, train_file, 'WriteVariableNames', false,  
'Delimiter', ' ');  
        check_file = sprintf('check_%d.dat', iteration);  
        writetable(check, check_file, 'WriteVariableNames', false,  
'Delimiter', ' ');  
  
        trainData = load(train_file);  
        checkData = load(check_file);  
        trainInput = trainData(:, 1:end-1);  
        trainOutput = trainData(:, end);  
        checkInput = checkData(:, 1:end-1);
```

```

checkOutput = checkData(:, end);

% Generate FIS using subtractive clustering with default settings
fis = genfis2(trainInput, trainOutput, 0.5);
fis = anfis([trainInput trainOutput], fis, 30);
predictedOutput = evalfis(checkInput, fis);

rmse = sqrt(mean((predictedOutput - checkOutput).^2));
rmseValues = [rmseValues; rmse];
SStot = sum((checkOutput - mean(checkOutput)).^2);
SSres = sum((predictedOutput - checkOutput).^2);
R2 = 1 - (SSres / SStot);
R2Values = [R2Values; R2];
end
end

iterationNumbers = (1:iteration)';
rmseTable1 = table(iterationNumbers, rmseValues, 'VariableNames',
{'Iteration', 'RMSE'});
iterationNumbers = (1:iteration)';
r2Table1 = table(iterationNumbers, R2Values, 'VariableNames', {'Iteration',
'R2'});

% Plot the RMSE values across iterations
figure;
yyaxis left
plot(iterationNumbers, rmseValues, '-o', 'LineWidth', 1);
title('RMSE & R2 Values Across Iterations');
xlabel('Iteration');
ylabel('RMSE');
yyaxis right % Plot the R2 values across iterations
plot(iterationNumbers, R2Values, '--o', 'LineWidth', 1);
ylabel('R2');
grid on;

% Find the index of the minimum RMSE value
[~, min_rmse_index] = min(rmseValues);
file_number = num2str(min_rmse_index); % Convert the index to a string (for
file naming)
train_file = strcat('train_', file_number, '.dat');
check_file = strcat('check_', file_number, '.dat');

```

Grid Partition

```

%% MFTypes Grid Partition
train_Data = load(train_file);
check_Data = load(check_file);

xTrain = train_Data(:, 1:end-1); % All columns except the last are inputs
yTrain = train_Data(:, end); % Last column is the output
xCheck = check_Data(:, 1:end-1);
yCheck = check_Data(:, end);

% Initialization
mfTypes =
{'trimf', 'trapmf', 'gbellmf', 'gaussmf', 'gauss2mf', 'pimf', 'dsigmf', 'psigmf',}
; % List of different membership functions

```

```
numMFs = 2;
epoch = 50;
rmseTable = table();
R2Table = table();
legendEntries = {};
figure; % Set up a figure for combined prediction plot
hold on;

% Loop over different membership function types
for i = 1:length(mfTypes)
    mfType = mfTypes{i};

    fis = genfis1([xTrain, yTrain], numMFs, mfType);
    anfisModel = anfis([xTrain, yTrain], fis, epoch);
    yTrainPred = evalfis(xTrain, anfisModel);
    yCheckPred = evalfis(xCheck, anfisModel);

    trainRMSE = sqrt(mean((yTrainPred - yTrain).^2));
    checkRMSE = sqrt(mean((yCheckPred - yCheck).^2));
    rmseTable = [rmseTable; {mfType, trainRMSE, checkRMSE}];
    SStot2 = sum((yCheck - mean(yCheck)).^2);
    SSres2 = sum((yCheckPred - yCheck).^2);
    R2 = 1 - (SSres2 / SStot2);
    R2Table = [R2Table; {mfType, R2}];

    % Plot predictions for all membership functions on the same figure
    plot(1:length(yCheck), yCheckPred, '-'); % Plot predicted outputs
    legendEntries{end + 1} = mfType; % Add a legend entry
end

% Plot the original data for comparison
plot(1:length(yCheck), yCheck, 'o', 'LineWidth', 1); % Plot original check
data
legendEntries{end + 1} = 'Original Checking Data'; % Add a legend entry
for the original data
title('ANFIS Model Predictions for Different Membership Functions');
xlabel('Data Point');
ylabel('Output');
legend(legendEntries, 'Location', 'bestoutside')
hold off;

rmseTable.Properties.VariableNames = {'MembershipFunction', 'TrainingRMSE',
'CheckingRMSE'};
R2Table.Properties.VariableNames = {'MembershipFunction', 'R2'};

figure;
bar(rmseTable.CheckingRMSE);
ylabel('RMSE');
xticks(1:length(mfTypes));
xticklabels(rmseTable.MembershipFunction);
xtickangle(45);
xlabel('Membership Functions');
title('RMSE Comparison Checking Data');
grid on

figure;
bar(R2Table.R2);
```

```
ylabel('R2');  
xticks(1:length(mfTypes));  
xticklabels(R2Table.MembershipFunction);  
xtickangle(45);  
xlabel('Membership Functions');  
title('R2 Comparison Checking Data');  
grid on
```

Subtractive Clustering

```
% Subtractive Clustering
```

```
train_Data = load(train_file);  
check_Data = load(check_file);
```

```
% Separate inputs (x) and outputs (y)  
xTrain = trainData(:, 1:end-1); % All columns except the last are inputs  
yTrain = trainData(:, end); % Last column is the output  
xCheck = checkData(:, 1:end-1);  
yCheck = checkData(:, end);
```

```
% Initialization  
rmseValues = [];  
R2Values = [];  
combinationROI = [];  
combinationSQ = [];  
minRMSE = inf;  
bestCombination = [];  
ROI = (0.1:0.1:1)'; % Range of Influence  
SQ = 0.7:0.2:5; % Squash Factor  
AR = 0.5; % Accept Ratio  
RR = 0.15; % Reject Ratio  
epoch = 50;
```

```
for i = 1:length(ROI)  
    for j = 1:length(SQ)  
        roi = ROI(i);  
        sq = SQ(j);  
  
        opt = genfisOptions('SubtractiveClustering');  
        opt.ClusterInfluenceRange = roi;  
        opt.SquashFactor = sq;  
        opt.AcceptRatio = AR;  
        opt.RejectRatio = RR;  
        fis = genfis(xTrain, yTrain, opt);  
        fis = anfis([xTrain yTrain], fis, epoch);  
        predictedOutput = evalfis(xCheck, fis);  
  
        rmse = sqrt(mean((predictedOutput - yCheck).^2));  
        rmseValues = [rmseValues; rmse];  
        combinationROI = [combinationROI; roi];  
        combinationSQ = [combinationSQ; sq];  
        SStot = sum((yCheck - mean(yCheck)).^2);  
        SSres = sum((predictedOutput - yCheck).^2);  
        R2 = 1 - (SSres / SStot);  
        R2Values = [R2Values; R2];
```

```
    if rmse < minRMSE    %minimum RMSE
        minRMSE = rmse;
        bestCombination = [roi, sq]; % Store the best ROI and SQ
    end
end
end

% Display the best combination
fprintf('Best ROI: %.2f, Best SQ: %.2f, Minimum RMSE: %.4f\n',
bestCombination(1), bestCombination(2), minRMSE);

% Filter RMSE values that are <= 10
validIndices = rmseValues <= 10;
filteredROI = combinationROI(validIndices);
filteredSQ = combinationSQ(validIndices);
filteredRMSE = rmseValues(validIndices);
filteredR2 = R2Values(validIndices);
[roiGrid, sqGrid] = meshgrid(ROI, SQ);
rmseGrid = griddata(filteredROI, filteredSQ, filteredRMSE, roiGrid,
sqGrid);

% Plot the surface of RMSE values
figure;
surf(roiGrid, sqGrid, rmseGrid);
xlabel('Range of Influence (ROI)');
ylabel('Squash Factor (SQ)');
zlabel('RMSE');
title('RMSE Across Different Combinations of ROI and SQ');
colorbar;

% Highlight the best combination on the surface plot
hold on;
plot3(bestCombination(1), bestCombination(2), minRMSE, 'ro', 'MarkerSize',
10, 'MarkerFaceColor', 'r');
legend('RMSE Surface', 'Best Combination', 'Location', 'best');
hold off;
```