



Πανεπιστήμιο Δυτικής Μακεδονίας
Τμήμα Μηχανολόγων Μηχανικών
Πολυτεχνική Σχολή

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Ανάπτυξη μοντέλων πεπερασμένων στοιχείων, για αναγνώριση και κατηγοριοποίηση ζημιών σε δικτυωτές κατασκευές μέσω εκπαίδευσης νευρωνικών δικτύων και προσομοίωση σφάλματος στην αξιοπιστία.



ΝΙΚΟΛΕΤΑ ΠΕΤΑΛΑ :Α.Ε.Μ. : 2481

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ : ΑΡΑΙΛΟΠΟΥΛΟΣ ΑΛΕΞΑΝΔΡΟΣ

ΚΟΖΑΝΗ, ΜΑΡΤΙΟΣ 2024



Πανεπιστήμιο Δυτικής Μακεδονίας
Τμήμα Μηχανολόγων Μηχανικών
Πολυτεχνική Σχολή

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Ανάπτυξη μοντέλων πεπερασμένων στοιχείων, για αναγνώριση και κατηγοριοποίηση ζημιών σε δικτυωτές κατασκευές μέσω εκπαίδευσης νευρωνικών δικτύων και προσομοίωση σφάλματος στην αξιοπιστία.

ΝΙΚΟΛΕΤΑ ΠΕΤΑΛΑ : Α.Ε.Μ. : 2481

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ : ΑΡΑΙΛΟΠΟΥΛΟΣ ΑΛΕΞΑΝΔΡΟΣ

ΚΟΖΑΝΗ, ΜΑΡΤΙΟΣ 2024

Περίληψη

Η παρούσα διπλωματική εργασία έχει ως αντικείμενο έρευνας τον έλεγχο της δομικής ακεραιότητας μίας δικτυωτής κατασκευής μέσω της κατάστρωσης μοντέλων πεπερασμένων στοιχείων για δημιουργία ταλαντωτικών δεδομένων απόκρισης και την εκπαίδευση ενός συνελκτικού νευρωνικού δικτύου βαθιάς μάθησης, ώστε να αναγνωρίζει και να ταξινομεί περιπτώσεις ζημιάς. Ακόμη, προσομοιώνεται το σφάλμα γενίκευσης σε πειραματικά δεδομένα και αξιολογείται η επίδραση του σφάλματος στην αξιοπιστία.

Στο θεωρητικό κομμάτι, γίνεται λόγος για τον κλάδο της Δομικής Ακεραιότητας Κατασκευών (Structural Health Monitoring) καθώς και για την μέθοδο των Πεπερασμένων Στοιχείων (FEM), που χρησιμοποιείται για την προσομοίωση των μοντέλων. Έπειτα, γίνεται αναφορά στη μηχανική μάθηση και τα νευρωνικά δίκτυα αλλά και πως αυτά εφαρμόζονται ως σύγχρονες μέθοδοι για τον έλεγχο της δομικής ακεραιότητας στις κατασκευές.

Ακολουθεί η περιγραφή του πειράματος, όπου ένα συμμετρικό αριθμητικό μοντέλο δικτυωτής κατασκευής προσομοιώνεται στην υγιή κατάστασή του και σε 12 περιπτώσεις ζημιάς από δύο κατηγορίες και προκύπτουν τα αντίστοιχα δεδομένα αποκρίσεων για κάθε μοντέλο. Τα δεδομένα αυτά οργανώνονται σε διαφορετικά σετ ανάλογα με την κατηγορία ζημιάς και χρησιμοποιούνται για την εκπαίδευση ενός συνελκτικού νευρωνικού δικτύου βαθιάς μάθησης, το οποίο μαθαίνει να αναγνωρίζει και να ταξινομεί της ζημιές.

Για τον έλεγχο της αξιοπιστίας του ταξινομητή λαμβάνονται δεδομένα από ένα ασύμμετρο αριθμητικό μοντέλο που προσομοιώνεται και περιγράφει ικανοποιητικά το πειραματικό μοντέλο της δικτυωτής κατασκευής. Τα δεδομένα εισέρχονται στο εκπαιδευμένο νευρωνικό δίκτυο και προκύπτουν τα αντίστοιχα αποτελέσματα για την αξιοπιστία του μοντέλου από το μέσο σφάλμα που προκύπτει, από τα οποία εξάγονται συμπεράσματα στην αντίστοιχη ενότητα.

Abstract

The present thesis aims to monitor the structural health of a space truss test structure with a Finite Element Model for simulated vibration data from states with damage. The data is used for the training of a Convolutional Neural Network in order to be able to identify and classify the class of the damage states. Furthermore, the generalization error when experimental data is to be used, is modeled appropriately and the effect of it on reliability is evaluated.

In the theoretical part, the discipline of Structural Health Monitoring (SHM) is discussed as well as the Finite Element Method (FEM), which is used to simulate the models. Then, Machine Learning and Neural Networks are mentioned, and it is discussed how they are applied as modern methods for structural integrity monitoring in structures.

This is followed by a description of the damage classification testing which has been executed. In this, a symmetric numerical model of a space truss is simulated in its healthy state as well as in 12 different cases of damage caused by two different classes. The corresponding data for each model are obtained. This data is organized into different sets of supervised learning depending on the damage category and is used to train a convolutional deep-learning neural network, which learns how to recognize and classify the damages.

Finally, to test the reliability of the classifier, data from an asymmetric numerical model is obtained which emulates disagreements between the nominal FE and a possible experimental space truss. The results of the mean prediction error when the asymmetric model inputs are used in the trained network are studied in the corresponding section, together with the conclusions drawn.

Ευχαριστίες

Σε αυτό το σημείο θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου κ. Αραϊλόπουλο Αλέξανδρο για την πολύτιμη βοήθειά του στην εκπόνηση της διπλωματικής μου εργασίας αλλά βεβαίως και τον κ. Σεβεντεκίδη Παναγιώτη, έναν εξαιρετικό επιστήμονα για την καθοδήγησή του σε όλα τα στάδια της εργασίας. Ένα μεγάλο ευχαριστώ στους καθηγητές του Πανεπιστημίου Δυτικής Μακεδονίας για την εκπαίδευση και τις γνώσεις που μου προσέφεραν όλα αυτά τα χρόνια.

Στην οικογένειά μου, που ήταν εκεί για εμένα με κάθε δυνατό τρόπο να στηρίζουν την προσπάθειά μου και στους φίλους μου για όλες τις όμορφες στιγμές που περάσαμε μαζί στην Κοζάνη.

Περιεχόμενα

1. Εισαγωγή	8
2. Θεωρητικό Υπόβαθρο	12
2.1 Θεωρία της Δομικής Ακεραιότητας Κατασκευών	12
2.2 Δικτυωτές Κατασκευές	15
2.2.1. Απλά δικτυώματα	15
2.2.2. Χωρικά δικτυώματα (Χωροδικτυώματα)	16
2.3. Μέθοδος πεπερασμένων στοιχείων	17
2.3.1. Θεωρία της μεθόδου	17
2.3.2. Εφαρμογή της μεθόδου στην εργασία	18
2.3.3. Βελτιστοποίηση μοντέλου FE	19
2.4. Δυναμικά Συστήματα	20
2.4.1 Εξισώσεις κίνησης ταλαντωτικού συστήματος	21
2.4.2. Ιδιοπρόβλημα/ Ιδιοσυχνότητες/ Ιδιοτιμές	21
2.5. Μηχανική μάθηση και Νευρωνικά Δίκτυα	23
2.5.1. Επεξήγηση των όρων	23
2.5.2. Δημιουργία του σετ δεδομένων εποπτευόμενης μάθησης από αποκρίσεις	26
2.5.3. Εξαγωγή χαρακτηριστικών δεδομένων βαθιάς μάθησης με χρήση συνέλιξης	28
2.5.4. Ταξινόμηση Deep Learning	29
3. Πείραμα	32
3.1. Συμμετρικό μοντέλο πεπερασμένων στοιχείων	36
3.1.1. Σχεδίαση της healthy κατάστασης του συμμετρικού μοντέλου	36
3.1.2. Σχεδίαση της πρώτης κατηγορίας ζημιών στο συμμετρικό μοντέλο	40
3.1.3. Σχεδίαση της δεύτερης κατηγορίας ζημιών στο συμμετρικό μοντέλο ...	42
3.1.4. Χρήση MATLAB για εξαγωγή δεδομένων	46
3.2 Ασύμμετρο μοντέλο πεπερασμένων στοιχείων	49
3.2.1. Σχεδίαση της healthy κατάστασης του ασύμμετρου μοντέλου	49

3.2.2. Σχεδίαση της πρώτης κατηγορίας ζημιών στο ασύμμετρο μοντέλο.....	51
3.2.3. Σχεδίαση της δεύτερης κατηγορίας ζημιών στο ασύμμετρο μοντέλο	58
3.2.3.1. Χρήση MATLAB για εξαγωγή δεδομένων	67
3.3. Εκπαίδευση νευρωνικού δικτύου	69
3.4. Testing set στο ασύμμετρο μοντέλο.....	74
4. Αποτελέσματα	74
5. Συμπεράσματα	87
6. Βιβλιογραφικές αναφορές	88

Επεξήγηση συντομογραφιών

AI Artificial Intelligence

ANN Artificial Neural Network

CAE Computer Aided Engineering

CEM Central Estimation Method

CMA-ES Covariance Matrix Adaptation Evolution Strategy

CM Condition Monitoring

CNN Convolutional Neural Network

DL Deep Learning

F Force

FE Finite Element

FEM Finite Element Method

GE Genetic Algorithm

ML Machine Learning

SHM Structural Health Monitoring

1. Εισαγωγή

Η παρακολούθηση της Δομικής Ακεραιότητας Κατασκευών, γνώστη και ως Structural Health Monitoring (SHM) σε παγκόσμιο επίπεδο, αποτελεί έναν σημαντικό επιστημονικό κλάδο της μηχανικής. Ο κλάδος αυτός αποβλέπει στην παροχή αξιόπιστων δεδομένων σχετικά με την ακεραιότητα κάθε τύπου κατασκευής, όπως γέφυρες, υδρολογικά έργα και άλλα δομικά έργα, με στόχο την επίβλεψη, την ασφάλεια και κατ' επέκταση την βιωσιμότητα των κατασκευών [8,9].

Στον τομέα αυτόν χρησιμοποιούνται προηγμένες τεχνολογίες και μέθοδοι ανάλυσης, όπως η μοντελοποίηση και προσομοίωση με υπολογιστή. Οι μέθοδοι αυτοί βασίζονται στην επεξεργασία σημάτων από αισθητήρες που έχουν τοποθετηθεί στην κατασκευή και μετρήσεις δόνησης για την αξιολόγηση της κατάστασης υγείας των κατασκευών. Κύριος στόχος είναι να ληφθούν οι απαραίτητες πληροφορίες από την ανάλυση των σημάτων απόκρισης, που μπορεί να αντιστοιχούν σε καταστάσεις υγείας των δομών ή σε περιπτώσεις όπου έχουμε αλλαγές στις βασικές παραμέτρους (π.χ. μέτρο ελαστικότητας, πυκνότητα) χωρίς όμως να έχουμε ξεκάθαρη παρατήρηση βλάβης. Αυτό επιτυγχάνεται, λοιπόν, με συνεχείς μετρήσεις σε αλλαγές στην δυναμική της κατασκευής, οι οποίες θα πρέπει να είναι έγκυρες ώστε να μην οδηγηθούμε σε εσφαλμένα συμπεράσματα ειδικά όταν πρόκειται για μικρά μεγέθη ζημιών [1,2].

Πιο αναλυτικά, οι τομείς της παρακολούθησης της υγείας των δομών (Structural Health Monitoring) και της κατάστασης τους (Condition Monitoring) μπορούν να συνδυαστούν με προηγμένα μοντέλα μηχανικής και βαθιάς μάθησης (Machine Learning, Deep Learning), τα οποία θα τροφοδοτούνται με δεδομένα που προέρχονται από προσομοιώσεις για την μετέπειτα εκπαίδευσή τους. Για τις προσομοιώσεις αριθμητικών μοντέλων της κατασκευής χρησιμοποιείται κατά κόρον η μέθοδος των Πεπερασμένων Στοιχείων (Finite Element Method) και προκύπτουν δεδομένα για χρονικές αποκρίσεις και χαρακτηριστικά της κατασκευής, όπως ιδιοσυχνότητες, ιδιομορφές κ.λπ. [3,4]. Έπειτα, τα δεδομένα αυτά χρησιμοποιούνται για την εκπαίδευση μοντέλων μηχανικής μάθησης. Να σημειωθεί ότι η χρήση αριθμητικών δεδομένων στον κλάδο SHM αποτελεί πολύ πρόσφατη εξέλιξη [5]. Το βασικό πλεονέκτημα των μεθόδων που βασίζονται σε προσομοιώσεις μοντέλων είναι η δυνατότητα πρόσβασης σε δεδομένα που δεν μπορούν να ληφθούν πειραματικά για διάφορους λόγους, καθώς και το γεγονός ότι δεν είναι απαραίτητη η κατασκευή κάθε δομής που αναλύεται.

Μία κατηγορία της μηχανικής μάθησης είναι η εποπτευόμενη μάθηση (Supervised Learning), όπου τα δεδομένα (Inputs) συνοδεύονται με ετικέτες (labels) και χρησιμοποιούνται σε προβλήματα ταξινόμησης και παλινδρόμησης. Σε προβλήματα ταξινόμησης, τα δεδομένα δημιουργούνται και κατηγοριοποιούνται με βάση την κλάση στην οποία ανήκει το καθένα. Στην εργασία αυτή, η κλάση θα αναφέρεται στην κατάσταση υγείας της κατασκευής. Έπειτα, τα επισημασμένα αυτά σύνολα δεδομένων χρησιμοποιούνται για την εκπαίδευση αλγορίθμων, όπως νευρωνικά δίκτυα και δέντρα απόφασης, που ταξινομούν δεδομένα ή κάνουν προβλέψεις με μεγάλη ακρίβεια. Τα επισημασμένα data υποδηλώνουν ότι κάποια δεδομένα εισόδου έχουν ήδη επισημανθεί με τη σωστή έξοδο. Κάθε δηλαδή σημείο δεδομένων εισόδου σχετίζεται με την αντίστοιχη ετικέτα (label) εξόδου. Το πλεονέκτημα που προκύπτει είναι το γεγονός ότι μπορούμε εύκολα να δημιουργήσουμε δεδομένα για καταστάσεις που δεν είναι εφικτό να αναλύσουμε με πειραματικό τρόπο, και συνεπώς μπορεί να παρέχεται πολύτιμη πληροφορία στα μοντέλα ML/DL για πιθανές εργασίες παρακολούθησης [18,19]. Παρ' όλ' αυτά θα πρέπει να αναλογιστούμε ότι προκειμένου να είναι αξιόπιστα τα μοντέλα ML/DL, θα πρέπει να έχουμε προσομοιώσει όσο πιο καλά γίνεται το αριθμητικό μοντέλο της κατασκευής με το αντίστοιχο πειραματικό. Αυτό σημαίνει ότι οι προσδιορισμοί σφαλμάτων και αβεβαιότητας του μοντέλου προσομοίωσης παίζουν κυρίαρχο ρόλο στο εάν ένα σύνολο δεδομένων που παράγεται αριθμητικά μπορεί να εφαρμοστεί στην πράξη ή όχι. Βεβαίως, η τελική δοκιμή θα πρέπει να παρέχεται σε πραγματικά πειραματικά δεδομένα υγείας.

Το σφάλμα που μπορεί να περιλαμβάνεται στα σήματα δόνησης, είναι ικανό να οδηγήσει σε λάθη ταξινόμησης, κυρίως όταν ο αλγόριθμος εποπτευόμενης μάθησης (νευρωνικά δίκτυα κ.ά.) προσπαθεί να εφαρμόσει τις γνώσεις του στα νέα πειραματικά δεδομένα. Με τον όρο «γενίκευση» αναφερόμαστε στην ικανότητα ενός εκπαιδευμένου ταξινομητή να κάνει ακριβείς προβλέψεις για δεδομένα που δεν έχει δει προηγουμένως. Είναι ουσιαστικά η ικανότητα του αλγορίθμου να γενικεύει τις γνώσεις του σε νέες καταστάσεις που ακόμη δεν έχει «δει». Η βελτίωση της ικανότητας γενίκευσης είναι ένας σημαντικός τομέας στον κλάδο των Τεχνητών Νευρωνικών Δικτύων ως μοντέλα βαθιάς μάθησης με πολλαπλά layers και περιλαμβάνει την χρήση διαφόρων τεχνικών, όπως η ρύθμιση των υπερπαραμέτρων του μοντέλου, η χρήση μεθόδων κανονικοποίησης αλλά και η ανάπτυξη πιο περίπλοκων αρχιτεκτονικών νευρωνικών δικτύων. Ωστόσο, η γενίκευση από ένα ήδη υπάρχον μοντέλο σε τελείως νέα πειραματικά δεδομένα κρίνεται αρκετά περίπλοκη, καθώς θα πρέπει να αναλογιστούμε και το σφάλμα που κουβαλάει το

αρχικό μοντέλο. Αυτό σημαίνει ότι προβλήματα Δομικής Ακεραιότητας και Υγείας των κατασκευών (SHM) με προσομοιωμένα δεδομένα είναι ουσιαστικά προβλήματα εκτίμησης της πραγματικής κατάστασης από την αριθμητική προσομοίωση.

Έχει παρατηρηθεί [7] ότι σε περίπτωση που υπάρχουν σφάλματα στο μοντέλο ήδη από τα αρχικά αριθμητικά δεδομένα, αυτό μετατοπίζεται συνεχώς στα νέα δεδομένα εισόδου με αποτέλεσμα το σύστημα να καταλήγει σε εσφαλμένα συμπεράσματα. Βασικός στόχος είναι να μειωθεί όσο το δυνατόν περισσότερο το σφάλμα αυτό του μοντέλου, το οποίο προκύπτει από την απόκλιση που μπορεί να παρουσιαστεί τελικά μεταξύ των αποκρίσεων του αριθμητικού μοντέλου και του πειραματικού. Αυτό επιτυγχάνεται με την βελτιστοποίηση του μοντέλου χρησιμοποιώντας τους αντίστοιχους αλγορίθμους βελτιστοποίησης [6]. Για τα μοντέλα πεπερασμένων στοιχείων (FE) τέτοια σφάλματα μπορεί να προκύψουν από τα υλικά χαρακτηριστικά, την γεωμετρία του μοντέλου ή και από συνοριακές συνθήκες. Παρόλο που η αναβάθμιση του μοντέλου αποτελεί σημαντικό κομμάτι στον τομέα της μηχανικής, εντούτοις στην πράξη, ενδέχεται να μην είναι εφικτό ένα ενημερωμένο μοντέλο FE που είναι τέλεια εφαρμοσμένο στην πειραματική διάταξη για όλα τα είδη δομών. Συνεπώς, προκειμένου να έχουμε ένα ικανοποιητικό μοντέλο πεπερασμένων στοιχείων που να δημιουργεί τα απαραίτητα αριθμητικά δεδομένα για ανάλυση SHM, θα πρέπει ο μηχανικός να καταβάλει μεγάλη προσπάθεια και χρόνο, λαμβάνοντας φυσικά υπόψη αυτά τα σφάλματα που πιθανόν να φέρει το μοντέλο.

Στην παρούσα εργασία γίνεται έλεγχος της δομικής ακεραιότητας μιας δικτυωτής κατασκευής πύργου. Με την κατάστρωση των απαραίτητων μοντέλων πεπερασμένων στοιχείων για την δικτυωτή κατασκευή δημιουργούνται ταλαντωτικά δεδομένα για διαφορετικές καταστάσεις υγείας του πύργου, ταξινομούνται σε ένα σετ ετικετών εποπτευόμενης μάθησης (Supervised Learning) και χρησιμοποιούνται για την εκπαίδευση ενός Συνελκτικού Νευρωνικού Δικτύου (Convolutional Neural Network) βαθιάς μάθησης για αναγνώριση και κατηγοριοποίηση ζημιών αλλά και τον εντοπισμό του μέσου σφάλματος στην ταξινόμηση του νευρωνικού. Πιο αναλυτικά, προσομοιώνεται στο λογισμικό ANSA της εταιρείας BETA CAE Systems ένα αριθμητικό μοντέλο της κατασκευής (συμμετρικό) στην ακέραη (υγιά) κατάσταση και σε 12 περιπτώσεις βλάβης που δεν έχουν ακόμη μετρηθεί πειραματικά. Από τα μοντέλα αυτά προκύπτουν με επίλυση του ιδιοπροβλήματος στο MSC Nastran δεδομένα αποκρίσεων για τις διαφορετικές καταστάσεις υγείας του πύργου και χρησιμοποιούνται ως σετ

δεδομένων εποπτευόμενης μάθησης (Supervised Learning) για την εκπαίδευση του νευρωνικού δικτύου. Έπειτα, προσομοιώνεται ένα δεύτερο πειραματικό μοντέλο της κατασκευής (ασύμμετρο), που περιγράφει καλύτερα την κατασκευή σε αληθινά δεδομένα λόγω των ανομοιογενών σε διάφορα σημεία που μπορεί να υπάρχουν. Ο εκπαιδευμένος ταξινομητής (στην περίπτωση αυτή το νευρωνικό δίκτυο), η μαθηματική δηλαδή συνάρτηση που χαρτογραφεί την εισαγωγή δεδομένων σε μία κατηγορία, ελέγχεται τελικά μέσω του ασύμμετρου μοντέλου, που έχει σχεδιαστεί και περιγράφει την πραγματική κατάσταση της κατασκευής, για να δει πόσο καλά αναγνωρίζει τις πραγματικές ζημιές και την κλάση τους. Μελετάται, λοιπόν, η σχέση μεταξύ της τάξης μεγέθους της βλάβης ανάλογα με την κατηγορία στην οποία ανήκει, με την αξιοπιστία του μοντέλου ανίχνευσης βλαβών όσον αφορά την κατηγοριοποίηση της ζημιάς, και προκύπτει το μέσο σφάλμα [7]. Μπορούμε να υποθέσουμε από τώρα, ότι όσο μεγαλύτερη είναι η ζημιά, τόσο πιο μειωμένη θα πρέπει να είναι η ακρίβεια και η προσαρμογή του μοντέλου. Τα αποτελέσματα και συμπεράσματα από την ανάλυση θα παρουσιαστούν και θα εξηγηθούν στις τελευταίες ενότητες, αφού πρώτα γίνει μία λεπτομερής περιγραφή της όλης διαδικασίας που ακολουθήθηκε.

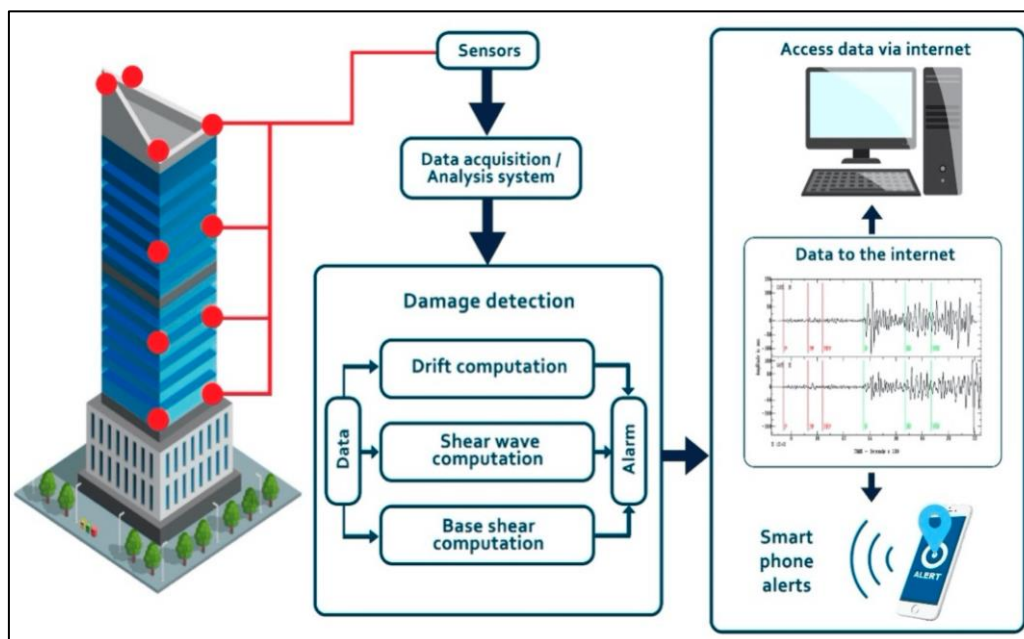
Στις επόμενες ενότητες ακολουθεί το θεωρητικό υπόβαθρο, όπου περιγράφεται αναλυτικά η διαδικασία παραγωγής δεδομένων μέσω ενός μοντέλου FE για την αναγνώριση ζημιών σε μία πολύπλοκη δικτυωτή κατασκευή με μορφή πύργου καθώς και το πειραματικό υπόβαθρο που επεξηγεί βήμα βήμα τα στάδια της ανάλυσης.

2. Θεωρητικό Υπόβαθρο


2.1 Θεωρία της Δομικής Ακεραιότητας Κατασκευών

Στην ενότητα αυτή θα γίνει μία πρώτη εισαγωγή στη θεωρία της Δομικής Ακεραιότητας Κατασκευών (SHM), προσφέροντας ένα υπόβαθρο γνώσης για την τεχνική αυτή. Θα γίνει μία συνοπτική αναφορά στις βασικές αρχές, τις μεθόδους και τις εφαρμογές του SHM [10], παρέχοντας ένα πλαίσιο κατανόησης για την συνέχεια της εργασίας.

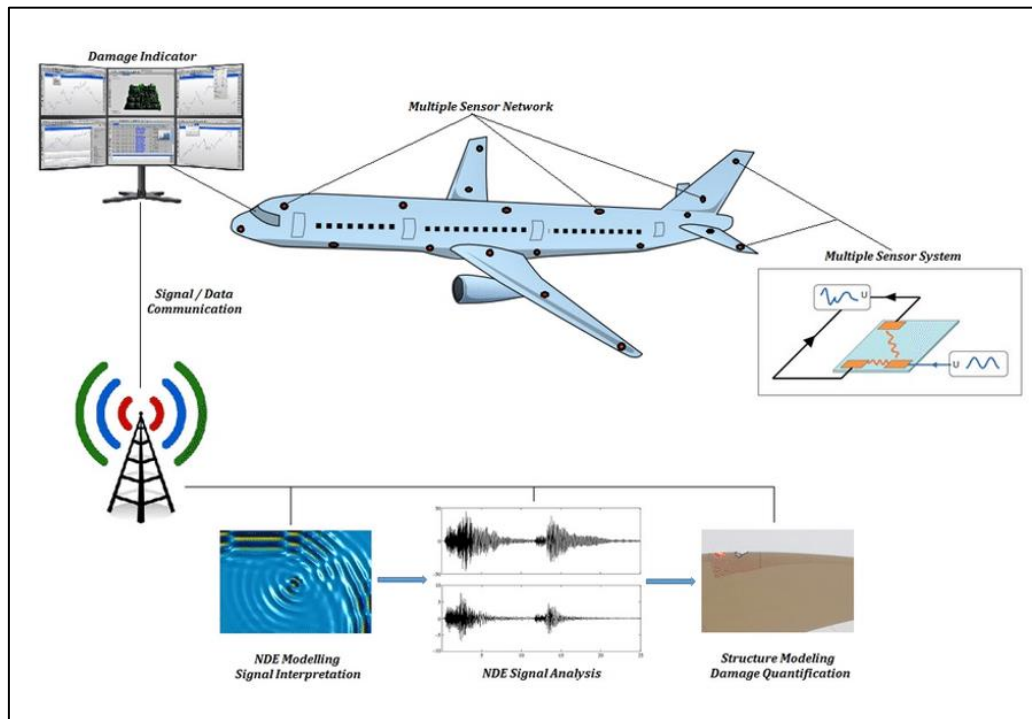
Τα τελευταία χρόνια, με τη συνεχή εξέλιξη της τεχνολογίας έχει καταστεί εφικτός ο έλεγχος της δομικής υγείας κατασκευών κτιρίων [11], γεφυρών [7], μηχανολογικών ακόμη και αεροδιαστημικών υποδομών [12] με επαναστατικές μεθόδους που τείνουν να αντικαταστήσουν τις ήδη υπάρχουσες διαδικασίες αξιολόγησης βλαβών. Οι μέθοδοι αυτοί χρησιμοποιούν προηγμένες τεχνολογίες μέτρησης σε κατασκευές, ώστε να συλλέγονται δεδομένα σχετικά με την συμπεριφορά τους στην πραγματική λειτουργία. Πιο αναλυτικά, μέσω περιοδικών δειγματοληπτικών μετρήσεων απόκρισης, όπως δονήσεις, παραμορφώσεις, αλλαγές σε παραμέτρους (π.χ. θερμοκρασία) που λαμβάνονται από αισθητήρες σε όλη την έκταση της κατασκευής συλλέγονται δεδομένα για την κατάσταση της υγείας των δομών και τον εντοπισμό πιθανών βλαβών. Οι μετρήσεις εκτελούνται ανά τακτά χρονικά διαστήματα και στην συνέχεια συγκρίνονται τα αποτελέσματα από διαφορετικά χρονικά σημεία.



Εικόνα 2.1.1. Έλεγχος Δομικής Ακεραιότητας σε κτίριο



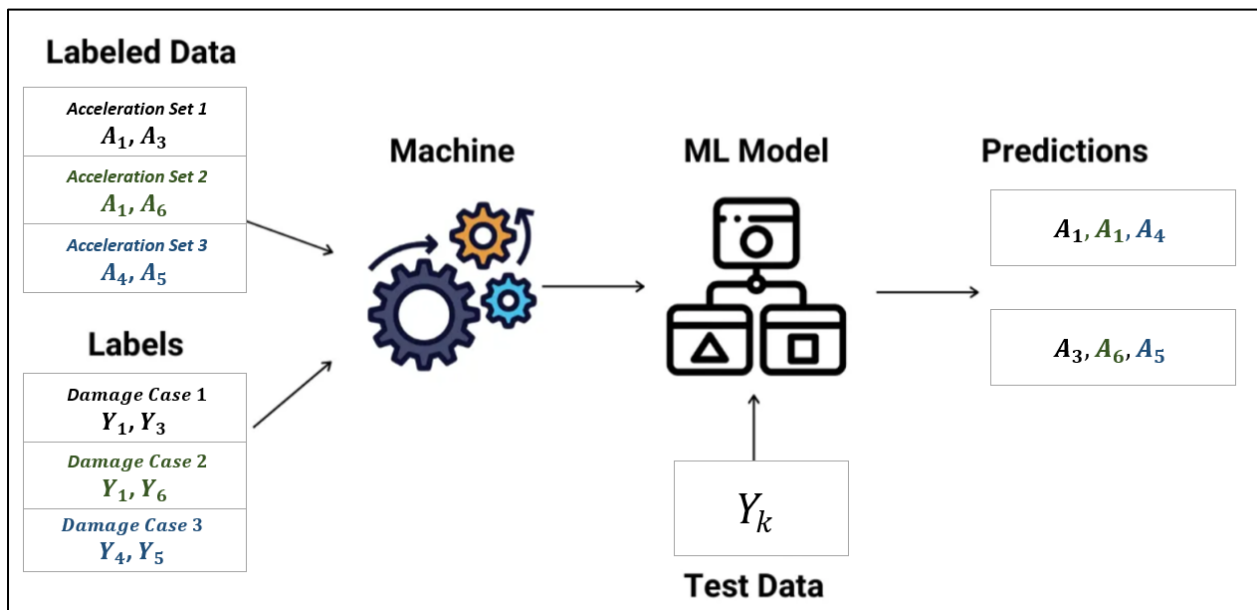
Εικόνα 2.1.2. Έλεγχος Δομικής Ακεραιότητας σε γέφυρα



Εικόνα 2.1.3. Έλεγχος Δομικής Ακεραιότητας σε αεροσκάφος

Τα δεδομένα που συλλέγονται αναλύονται με μαθηματικά μοντέλα, στατιστικές μεθόδους αλλά και μεθόδους τεχνητής νοημοσύνης, όπως η μηχανική μάθηση. Εστιάζοντας στη τελευταία, και συγκεκριμένα στην εφαρμογή μεθόδων εποπτευόμενης μάθησης (Supervised Learning), που αποτελεί υποκατηγορία του Machine Learning, για την επεξεργασία των δεδομένων από μετρήσεις μπορούμε να επιτύχουμε ακριβείς και εκτεταμένες αξιολογήσεις της κατάστασης υγείας της κατασκευής. Και το κομμάτι αυτό θα αναλυθεί περαιτέρω στη συνέχεια της εργασίας, καθώς για την επεξεργασία των δεδομένων εποπτευόμενης μάθησης

χρησιμοποιείται ένας αλγόριθμος deep learning και συγκεκριμένα ένα συνελκτικό νευρωνικό δίκτυο με πολλαπλά layers. Ο αλγόριθμος βαθιάς μάθησης, που έχει δημιουργηθεί με βάση των ανθρώπινο εγκέφαλο, εκπαιδεύεται αρχικά με το σετ δεδομένων για την αναγνώριση καταστάσεων υγείας και αργότερα θα είναι σε θέση να αναλύει νέα δεδομένα και να βγάζει αποτελέσματα κατηγοριοποίησης της ζημιάς. Η συλλογή δεδομένων προέρχεται από δονήσεις στην κατασκευή στην ακέραιη κατάστασή της και σε καταστάσεις ζημιών, έπειτα ακολουθεί η επεξεργασία των δεδομένων για την είσοδό τους στον αλγόριθμο deep learning (νευρωνικό δίκτυο), η εκπαίδευση του μοντέλου και τέλος η αξιολόγησή του. Δημιουργούνται 6 διαφορετικά σετ δεδομένων εποπτευόμενης μάθησης, όπου το κάθε σετ αποτελείται από δύο καταστάσεις υγείας και τις αντίστοιχες επιταχύνσεις για θέματα απλοποίησης. Το νευρωνικό θα εκπαιδευτεί να αναγνωρίζει σε ποια από τις δύο καταστάσεις υγείας αναφέρονται τα νέα δεδομένα που θα εισαχθούν μετά την εκπαίδευση.



Εικόνα 2.1.4. Εποπτευόμενη μάθηση σε νευρωνικό δίκτυο

Η Δομική Ακεραιότητα Κατασκευών έχει συμβάλει σημαντικά στην εξέλιξη της μηχανικής. Η πρόληψη και η επίλυση προβλημάτων στις κατασκευές μπορεί να εξοικονομήσει χρόνο, χρήμα και πόρους. Αυξάνεται η διάρκεια ζωής των κατασκευών και παράλληλα μειώνεται το κόστος συντήρησης. Παράλληλα, όμως, βοηθά στην πρόληψη ατυχημάτων και στην λήψη μέτρων πρόληψης και προστασίας για την αποφυγή δυσάρεστων γεγονότων.

2.2 Δικτυωτές Κατασκευές


Όπως αναφέρθηκε και προηγουμένως, στην παρούσα εργασία γίνεται χρήση της μεθόδου της Δομικής Ακεραιότητας Κατασκευών μέσω μηχανικής μάθησης για την αναγνώριση και κατηγοριοποίηση ζημιών σε μία τρισδιάστατη δικτυωτή κατασκευή. Πρώτα, όμως, θα πρέπει να αποσαφηνιστεί ο όρος «δικτύωμα».

2.2.1. Απλά δικτύωματα


Οι δικτυωτές κατασκευές ή απλούστερα δικτύωματα αποτελούν έναν από τους κυριότερους τύπους τεχνικών κατασκευών. Είναι συνήθως σταθερές και πλήρως δεσμευμένες κατασκευές που αποτελούνται αποκλειστικά από ευθύγραμμα μέλη συνδεδεμένα μεταξύ τους σε κόμβους (αρθρώσεις), οι οποίοι βρίσκονται στα άκρα κάθε μέλους. Επομένως, τα μέλη ενός δικτύωματος είναι μέλη δύο δυνάμεων, δηλαδή μέλη που υπόκεινται σε δύο ίσες και αντίθετες δυνάμεις, οι οποίες κατευθύνονται κατά μήκος του άξονά τους. Με πιο απλά λόγια, κάθε μέλος ενός δικτύωματος καταπονείται μόνο με μία σταθερή αξονική δύναμη.

Τα δικτύωματα προσφέρουν μια αποτελεσματική και οικονομική λύση σε πολλές περιπτώσεις που απασχολούν τους μηχανικούς, ιδιαίτερα στη σχεδίαση γεφυρών και κτιρίων.

Ένα δικτύωμα αποτελείται από ευθύγραμμα μέλη συνδεδεμένα μεταξύ τους με αρθρώσεις όπως φαίνεται στα παρακάτω σχήματα (εικόνα 2.2.1.1.). Τα μέλη των δικτυωμάτων συνδέονται μόνο στα άκρα τους και κανένα μέλος δεν συνεχίζει μέσα από τον κόμβο. Οι περισσότερες κατασκευές στην πράξη αποτελούνται από διάφορα δικτύωματα που συνδέονται μεταξύ τους σχηματίζοντας έναν αρθρωτό φορέα. Κάθε δικτύωμα είναι σχεδιασμένο έτσι ώστε να αναλαμβάνει φορτία που δρουν στο επίπεδό του και, ως εκ τούτου, μπορεί να θεωρηθεί ως μία κατασκευή δύο διαστάσεων.




Εικόνα 2.2.1.1. Ένα τυπικό δικτύωμα αποτελείται από ευθύγραμμα μέλη που συνδέονται μεταξύ τους με αρθρώσεις




Εικόνα 2.2.1.2. Δικτύωμα με μέλη δύο δυνάμεων που συνδέονται αρθρωτά με πύργους

2.2.2. Χωρικά δικτυώματα (Χωροδικτυώματα)

Όταν διάφορα ευθύγραμμα μέλη δικτυώματος συνδέονται μεταξύ τους στα άκρα τους για να σχηματίσουν μία διάταξη τριών διαστάσεων, η κατασκευή που προκύπτει ονομάζεται χωρικό δικτύωμα ή χωροδικτύωμα (εικόνα 2.2.2.1.). Χωροδικτυώματα χρησιμοποιούνται σε διάφορες εγκαταστάσεις, όπως σε πυλώνες μετάδοσης σημάτων και μεταφοράς ηλεκτρικού ρεύματος, σε γέφυρες ακόμη και σε εφαρμογές διαστημόπλοιων για εξαρτήματα. Στην παρούσα εργασία έχει αναλυθεί ένα χωρικό δικτύωμα μεταφοράς ηλεκτρικού ρεύματος, που θα αναφέρεται στην συνέχεια με τον όρο «πύργος».



Εικόνα 2.2.2.1. Χωροδικτύωμα



Εικόνα 2.2.2.2. Χωροδικτύωμα «πύργος» προς ανάλυση

2.3. Μέθοδος πεπερασμένων στοιχείων

Τα αριθμητικά και πειραματικά μοντέλα που αναλύθηκαν προσομοιώθηκαν με την μέθοδο των πεπερασμένων στοιχείων στο λογισμικό ANSA της εταιρίας BETA CAE Systems. Η επίλυση του ιδιοπροβλήματος γίνεται στο MSC Nastran και παίρνουμε αποτελέσματα για ιδιομορφές και αποκρίσεις.

2.3.1. Θεωρία της μεθόδου

Η μέθοδος πεπερασμένων στοιχείων ή σε διεθνείς όρους Finite Element Method (FEM) είναι μια αριθμητική μέθοδος για τον υπολογισμό προσεγγιστικών λύσεων μερικών διαφορικών εξισώσεων. Είναι άμεσα συνυφασμένη με τον κλάδο της μηχανικής, καθώς αποτελεί την πιο διαδεδομένη μέθοδο υπολογισμού της δυναμικής συμπεριφοράς συνεχών μέσων για την ανάλυση δομών, κατασκευών και άλλων συστημάτων. Η παραπάνω μέθοδος ταυτίζεται σήμερα με την έννοια CAE (Computer Aided Engineering) και αποτελεί εξέλιξη των προηγούμενων παραδοσιακών προσεγγιστικών μεθόδων επίλυσης προβλημάτων δυναμικής των κατασκευών, στις οποίες ήταν απαραίτητος ο καθορισμός της χωρικής εξάρτησης της απόκρισης σε όλη την έξοδο της κατασκευής.


Η βασική έννοια της μεθόδου είναι ότι μπορούμε να προσομοιώσουμε την πραγματική κατασκευή με ένα αριθμητικό μοντέλο που αποτελείται από στοιχεία πεπερασμένα σε αριθμό, τα οποία συνδέονται με κόμβους. Πιο αναλυτικά, ένα συνεχές μέσο κατά την ανάλυσή του υποδιαιρείται σε μικρότερα στοιχεία

(elements), τα οποία ονομάζονται «πεπερασμένα στοιχεία» και συνδέονται μεταξύ τους σε καθορισμένες αρθρώσεις που ονομάζονται κόμβοι (Nodes). Τα elements μπορεί να είναι τετράπλευρα ή τριγωνικά ενώ οι κόμβοι βρίσκονται στα άκρα τους. Έτσι προσομοιώνεται ένα συνεχές μέσο με ένα πεπερασμένο αριθμό διακριτών μεταβλητών (μετατοπίσεις, ταχύτητες, επιταχύνσεις κ.α.) και πλέον μπορεί να γίνει χρήση μητρικών (αριθμητικών) μεθόδων.

Στις αριθμητικές μεθόδους, όπως και στη μέθοδο των πεπερασμένων στοιχείων, δημιουργούνται πίνακες στιβαρότητας (K) και μάζας (M) για κάθε ένα στοιχείο και όλα μαζί οργανώνονται σε ένα γενικό πίνακα K και M για ολόκληρη την κατασκευή. Οι πίνακες είναι κρίσιμοι για την μετέπειτα δυναμική ανάλυση της κατασκευής και την ταλαντωτική της συμπεριφορά. Με την επίλυση του κατάλληλου συστήματος γραμμικών εξισώσεων που ικανοποιεί τις συνθήκες ισορροπίας και τις συνθήκες γεωμετρικής συμβιβαστότητας στο εσωτερικό των στοιχείων και στα σύνορα τους, παίρνουμε αποτελέσματα για τις ιδιομορφές του συστήματος. Τις φυσικές συχνότητες, δηλαδή, που καθορίζουν την δυναμική αντίδραση της κατασκευής σε διάφορες συνθήκες φόρτισης ή δυναμικών διεγέρσεων. Αναλύοντας τα αποτελέσματα, μπορούμε να προβλέψουμε την συμπεριφορά μιας πραγματικής κατασκευής στις αντίστοιχες συνθήκες φόρτισης και να εξάγουμε συμπεράσματα για την αντίδρασή της.

2.3.2. Εφαρμογή της μεθόδου στην εργασία

Στην παρούσα εργασία, η μέθοδος των πεπερασμένων στοιχείων χρησιμοποιείται προκειμένου να προσομοιωθεί το αριθμητικό μοντέλο της κατασκευής στον προεπεξεργαστή ANSA, ειδικό για τον σχεδιασμό με πεπερασμένα στοιχεία. Ο πύργος υποδιαιρείται σε μικρά στοιχεία (elements) με το καθένα από αυτά να έχει γνωστά χαρακτηριστικά για την γεωμετρία, τις ιδιότητες των υλικών (μέτρο ελαστικότητας E , πυκνότητα ρ , επιφάνειας διατομής A) και τους συνδέσμους με γειτονικά στοιχεία μέσω κόμβων (grids). Για τα στοιχεία ράβδου χρησιμοποιούνται CROD με τα αντίστοιχα PROD και Material. Ο πύργος σχεδιάζεται με τον πιο απλοποιημένο δυνατό τρόπο για την διακριτοποίηση του μοντέλου. Το σχήμα 2.3.2.1. δείχνει την κατασκευή υποδιαιρούμενη σε στοιχεία και κόμβους.



Εικόνα 2.3.2.1. Στοιχεία και κόμβοι στον πύργο

Για την καλύτερη προσομοίωση του αριθμητικού μοντέλου, γίνεται προσθήκη οριακών συνθηκών (αρθρώσεων) και της δύναμης κρουστικής διέγερσης F που θα αναλυθεί αργότερα για την λύση του ιδιοπροβλήματος.

Ακολουθεί η αριθμητική επίλυση του μοντέλου πεπερασμένων στοιχείων της δικτυωτής κατασκευής στο MSC Nastran με την επιλογή του κατάλληλου λύτη για το δυναμικό πρόβλημα στο Nastran Header. Για το δυναμικό πρόβλημα γίνεται χρήση του solver SOL112, το οποίο θα μας δώσει τις λύσεις του ιδιοπροβλήματος και θα κάνει υπέρθεση ιδιομορφών για τα αποτελέσματα των επιταχύνσεων.

Η ανάλυση του πειραματικού μοντέλου γίνεται και αυτή με πεπερασμένα στοιχεία καθώς δεν είναι εφικτή η πραγματική κατασκευή του πύργου. Συγκεκριμένα, σχεδιάζεται ένα ασύμμετρο μοντέλο FE, το οποίο αντιπροσωπεύει με ικανοποιητικό τρόπο την αληθινή κατασκευή και εξάγονται δεδομένα για την ταλαντωτική του συμπεριφορά από την επίλυση του ιδιοπροβλήματος με διαφορετικές παραμέτρους από το αριθμητικό μοντέλο. Έπειτα, προκύπτουν αποτελέσματα και συμπεράσματα από την σύγκριση των δύο μοντέλων.

2.3.3. Βελτιστοποίηση μοντέλου FE

Προκειμένου να ελαχιστοποιηθούν οι αποκλίσεις μεταξύ ενός αριθμητικού προσομοιωμένου μοντέλου πεπερασμένων στοιχείων με το αντίστοιχο πειραματικό μοντέλο της κατασκευής, γίνεται χρήση των αλγορίθμων βελτιστοποίησης για τις διάφορες παραμέτρους του μοντέλου. Ένας εκ τω πολλών εξελικτικών αλγορίθμων

βελτιστοποίησης είναι και ο Covariance Matrix Adaptation Evolution Strategy (CMA-ES) [14], ο οποίος είναι κατάλληλος κυρίως για προβλήματα υψηλής διάστασης όπου οι παράμετροι είναι πολλοί και σύνθετοι. Με την χρήση πολυμεταβλητών κανονικών κατανομών παράγει νέους συνδυασμούς παραμέτρων που χρησιμοποιούνται για αριθμητικά πειράματα με μοντέλα FE και τα αποτελέσματα που προκύπτουν συγκρίνονται με αληθινά πειραματικά δεδομένα. Άλλοι αλγόριθμοι βελτιστοποίησης είναι ο αλγόριθμος Βασισμένος σε Εκτίμηση Κεντρικού Σημείου (CEM-Central Estimation Method) [15] ή ο Γενετικός Αλγόριθμος (Genetic Algorithm-GE) [16].

Ωστόσο δεν είναι πάντα εφικτή η βελτιστοποίηση των FE μοντέλων και υπάρχουν περιορισμοί στη χρήση των μεθόδων βελτιστοποίησης. Ένας από τους λόγους μπορεί να είναι η περιπλοκότητα που παρουσιάζουν αρκετές δομές, όπως οι μη περιοδικές δομές (quasi-periodic structures) [20] που περιλαμβάνουν στοιχεία που διακλαδώνονται και αλληλοεπιδρούν μεταξύ τους με σύνθετους τρόπους. Επιπλέον, στους λόγους συμπεριλαμβάνονται και γενικότερες αβεβαιότητες στα μοντέλα, όπως η χρήση του καταστατικού νόμου (constitutive law), που περιγράφει την συμπεριφορά των υλικών υπό διάφορες συνθήκες φόρτισης [7]. Ιδιαίτερα εάν ο καταστατικός νόμος είναι αρκετά περίπλοκος ή και μη γραμμικός πολλές φορές, η βελτιστοποίηση του μοντέλου κρίνεται αρκετά δύσκολη λόγω της δυσκολίας στην εκτίμηση της αντίδρασης του συστήματος. Τέλος, η δυσκολία για βελτιστοποίηση μπορεί να έγκειται και στο γεγονός ότι πολλά μοντέλα απλουστεύονται κατά την σχεδίαση τους με τις απλοποιήσεις να είναι αρκετά υπερβολικές και ενδεχομένως ανακριβείς.

2.4. Δυναμικά Συστήματα

Ως δυναμικό σύστημα ορίζεται το σύστημα το οποίο εξελίσσεται συνεχώς με την πάροδο του χρόνου. Οι τιμές των βασικών μεταβλητών του (θέση, ταχύτητα, επιτάχυνση και άλλες) αλλάζουν συνεχώς και η μεταβολή στις μεταβλητές οφείλεται σε εσωτερικές δυνάμεις ή εξωτερικές επιδράσεις που εφαρμόζονται στο σύστημα. Οι νόμοι που διέπουν το σύστημα περιγράφονται μαθηματικά, με την χρήση διαφορικών εξισώσεων, οι οποίες περιγράφουν ικανοποιητικά την συμπεριφορά τους με την πάροδο του χρόνου. Ενδιαφέρον παρουσιάζει η ταλαντωτική συμπεριφορά ενός δυναμικού συστήματος, όταν αυτό υποβληθεί σε διέγερση μέσω εξωτερικών δυνάμεων. Αυτή τη συμπεριφορά θα μελετήσουμε και για το δυναμικό σύστημα του πύργου, αφού υποβληθεί σε εξωτερική κρουστική διέγερση F . Με επίλυση των κατάλληλων εξισώσεων κίνησης του ταλαντωτικού συστήματος θα προκύψουν χαρακτηριστικές τιμές για επιταχύνσεις σε διαφορετικές περιπτώσεις.

2.4.1 Εξισώσεις κίνησης ταλαντωτικού συστήματος

Η γενική μορφή της χαρακτηριστικής εξίσωσης της κίνησης ενός ταλαντωτικού συστήματος υπό διέγερση σε μητρική μορφή είναι [17]:

$$\mathbf{M}_{(\rho,g)}\mathbf{A} + \mathbf{C}_{(M,K,\alpha,\beta)}\mathbf{V} + \mathbf{K}_{(E,g)}\mathbf{U} = \mathbf{F} \quad (2.1)$$

Όπου,

- \mathbf{A} : το διάνυσμα της επιτάχυνσης (\ddot{x})
- \mathbf{V} : το διάνυσμα της ταχύτητας (\dot{x})
- \mathbf{U} : το διάνυσμα της μετατόπισης (x)
- \mathbf{M} : το μητρώο μάζας του συστήματος
- \mathbf{K} : το μητρώο στιβαρότητας του συστήματος
- \mathbf{C} : το μητρώο απόσβεσης του συστήματος
- \mathbf{F} : το μητρώο των εξωτερικών διεγέρσεων

Οι παράγοντες \mathbf{M} , \mathbf{K} , \mathbf{C} που περιγράφουν το σύστημα αναφοράς εξαρτώνται από τις παραμέτρους του μοντέλου· πυκνότητα (ρ), μέτρο ελαστικότητας (E) και απόσβεση (α , β) ενώ η παράμετρος g μπορεί να περιλαμβάνει γεωμετρικά χαρακτηριστικά όπως το πάχος της διατομής, το μήκος των κομματιών και άλλες παραμέτρους που επηρεάζουν την απόκριση.

2.4.2. Ιδιοπρόβλημα/ Ιδιοσυχνότητες/ Ιδιοτιμές

Λόγω περιοδικής ταλάντωσης στο σύστημα που εξετάζεται, η εξίσωση κίνησης (2.1) που περιεγράφηκε στην προηγούμενη ενότητα έχει λύσεις της μορφής:

$$\overline{\mathbf{x}(t)} = \overline{\mathbf{x}} * \mathbf{cos}(\omega * t - \theta) \quad (2.2)$$

Αν τώρα αντικαταστήσουμε την (2.2) στη (2.1) προκύπτει η εξίσωση:

$$(\mathbf{K} - \omega^2 * \mathbf{M}) * \overline{\mathbf{x}} * \mathbf{cos}(\omega * t - \theta) = \mathbf{0} \quad (2.3)$$

και για να αποτελεί λύση της εξίσωσης κίνησης θα πρέπει:

$$(\mathbf{K} - \omega_n^2 * \mathbf{M}) * \overline{\mathbf{x}_n} = \mathbf{0} \quad (2.4)$$

Το παραπάνω αποτελεί και το ιδιοπρόβλημα που αντιστοιχεί στην εξίσωση κίνησης (2.1) και προκειμένου να έχει μη μηδενική λύση θα πρέπει αναγκαστικά να ισχύει:

$$|K - \omega_n^2| = 0 \quad (2.5)$$

Εάν η παραπάνω ορίζουσα επιλυθεί, δηλαδή $\det|K - \omega_n^2| = 0$, προκύπτει το ακόλουθο πολυώνυμο N-βαθμού ως προς ω^2 :

$$(\omega^2)^N + \alpha_{N-1} * (\omega^2)^{N-1} + \dots + \alpha_1 * \omega^2 + \alpha_0 = 0 \quad (2.6)$$

με θετικές ρίζες $0 < \omega_1^2 \leq \omega_2^2 \leq \dots \leq \omega_N^2$ (2.7) που ονομάζονται ιδιοτιμές ή ιδιοσυχνότητες και για κάθε ιδιοσυχνότητα αντιστοιχεί ένα ιδιοδιάνυσμα \bar{x}_n ή αλλιώς μία ιδιομορφή του δυναμικού συστήματος. Για τις ιδιοσυχνότητες και τις ιδιοτιμές ισχύει ότι εξαρτώνται αποκλειστικά και μόνο από τα στοιχεία των μητρώων μάζας και στιβαρότητας του συστήματος και μπορούν να γραφούν στη μορφή πινάκων:

$$X = \begin{bmatrix} x_{11} & \dots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{n1} & \dots & x_{nn} \end{bmatrix} \quad (2.8) \quad \text{και} \quad \Omega^2 = \begin{bmatrix} \omega_{11}^2 & \dots & \omega_{1n}^2 \\ \vdots & \ddots & \vdots \\ \omega_{n1}^2 & \dots & \omega_{nn}^2 \end{bmatrix} \quad (2.9)$$

Έπειτα γίνεται χρήση των συνθηκών ορθογωνικότητας των ιδιομορφών με την χρήση του δέλτα του Kronecker δ_{rs} , δημιουργείται νέος πίνακας ιδιομορφών με στοιχεία το σύνολο των ιδιομορφών που προέκυψαν και τελικά σχηματίζεται η παρακάτω συμπαγής μορφή από τα βήματα που αναφέρθηκαν.

$$X = [\widehat{x}_1 \widehat{x}_2 \dots \widehat{x}_n] \quad (2.10)$$

$$X^T M X = \widehat{M} \quad (2.11) \quad \text{και} \quad X^T K X = \widehat{K} \quad (2.12)$$

\widehat{M} , \widehat{K} είναι οι διαγώνιοι πίνακες με στοιχεία διαγωνίου $\widehat{m}_r, \widehat{k}_r$, όπου λαμβάνονται ίσοι με 1. Οι τελικές ιδιομορφές που προκύπτουν ονομάζονται ορθοκανονικές ιδιομορφές και συμβολίζονται με $\bar{\varphi}_R$ ή σε μορφή πίνακα ως:

$$\Phi = [\bar{\varphi}_1 \quad \bar{\varphi}_2 \quad \dots \quad \bar{\varphi}_n]$$

Στην εργασία το ιδιοπρόβλημα λύνεται αυτόματα στο λογισμικό MSC Nastran. Πιο αναλυτικά, αφού κάθε μοντέλο σχεδιαστεί στον προ-επεξεργαστή ANSA με όλα τα elements και τις συνθήκες που το χαρακτηρίζουν, ορίζεται ο Nastran Header όπου δίνονται οι κατάλληλες τιμές για τις μεταβλητές που απαιτούνται (αριθμός ιδιομορφών, χρονικό βήμα, μέτρα απόσβεσης ζ , τιμή κρουστικής διέγερση F) και επιλέγεται ο modal solver για την λύση του ιδιοπροβλήματος στο MSC Nastran. Επιλέγεται ο solver SOL112 για το δυναμικό πρόβλημα από το οποίο θα προκύψουν

αποτελέσματα ιδιομορφών και θα γίνει υπέρθεσή τους ώστε να ληφθούν δεδομένα απόκρισης σε μορφή επιταχύνσεων (βήματα 7, 8, 9 στην εικόνα 2.4.2.1.). Για την λύση στο MSC Nastran χρησιμοποιούνται εξελιγμένες αριθμητικές μέθοδοι επίλυσης για το ιδιοπρόβλημα και την χρονική απόκριση με υπέρθεση ιδιομορφών [13]. Οι επιταχύνσεις περιγράφουν την ταλαντωτική συμπεριφορά 8 διαφορετικών σημείων στον πύργο για κάθε μοντέλο, στα οποία έχουν τοποθετηθεί αισθητήρες μέτρησης, έπειτα από κρουστική διέγερση στο ήρεμο σύστημα. Παρακάτω περιγράφεται ο αλγόριθμος που χρησιμοποιήθηκε και δίνει τα αποτελέσματα των επιταχύνσεων λύνοντας το ιδιοπρόβλημα.

```

Input: Number of load cases  $n$  and statistical bounds for each parameter  $\rho, \zeta, E$ 
Output:  $n$  number of vibration responses and health labels  $s$ 
1. for  $i = 1 : n$ 
2.   sample  $E, \rho, g \rightarrow \mathbf{K} = \mathbf{K}(E, g), \mathbf{M} = \mathbf{M}(\rho, g)$ 
3.   sample modal damping  $\zeta$ 
4.   for  $j = 1 : s$ 
5.     define Health status  $\rightarrow \mathbf{Y}_{i,j}$ 
6.     define loads  $\rightarrow \mathbf{F}$ 
7.     solve eigenproblem  $\rightarrow [\mathbf{K} - \omega_m^2 \mathbf{M}] \Phi_m = \mathbf{0}$ 
8.     extract  $m$  natural frequencies and modes  $\rightarrow \omega_m, \Phi_m$ 
9.     solve modal equations and calculate accelerations  $\rightarrow \mathbf{A}$ 
10.    return  $\mathbf{A}_{i,j}$  and  $\mathbf{Y}_{i,j}$ 
11.  end

```

Εικόνα 2.4.2.1. : Αλγόριθμος που λύνει το ιδιοπρόβλημα και δίνει αποτελέσματα για τις επιταχύνσεις

2.5. Μηχανική μάθηση και Νευρωνικά Δίκτυα

2.5.1. Επεξήγηση των όρων

Ο κλάδος της Τεχνητής Νοημοσύνης (AI), που έχει λάβει τεράστιες διαστάσεις στις μέρες μας, ασχολείται με τον σχεδιασμό και την υλοποίηση υπολογιστικών συστημάτων με σκοπό την μίμηση ανθρώπινων συμπεριφορών και την εκτέλεση διάφορων λειτουργιών, όπως η αναγνώριση προτύπων, η εξαγωγή συμπερασμάτων, η μάθηση, και η λήψη αποφάσεων, παρόμοιες με αυτές που αναλαμβάνει ο ανθρώπινος εγκέφαλος. Μία υποκατηγορία της Τεχνητής Νοημοσύνης αποτελεί η Μηχανική μάθηση (Machine Learning), που ασχολείται με την μελέτη και την ανάπτυξη αλγορίθμων και μοντέλων τα οποία επιτρέπουν στα υπολογιστικά συστήματα να μαθαίνουν από δεδομένα και εμπειρία, χωρίς να προγραμματίζονται

ρητά με συγκεκριμένους κανόνες. Τα μοντέλα μηχανικής μάθησης μπορούν να αναγνωρίζουν πρότυπα στα δεδομένα, να κάνουν προβλέψεις ακόμη και να λύνουν προβλήματα χωρίς να χρειάζεται να προγραμματιστούν εξαρχής για κάθε πιθανή περίπτωση [18, 19]. Οι αλγόριθμοι που χρησιμοποιούνται βελτιώνονται αυτόματα συνεχώς μέσω της εμπειρίας από την χρήση νέων δεδομένων. Οι βασικές κατηγορίες της μηχανικής μάθησης είναι 3:

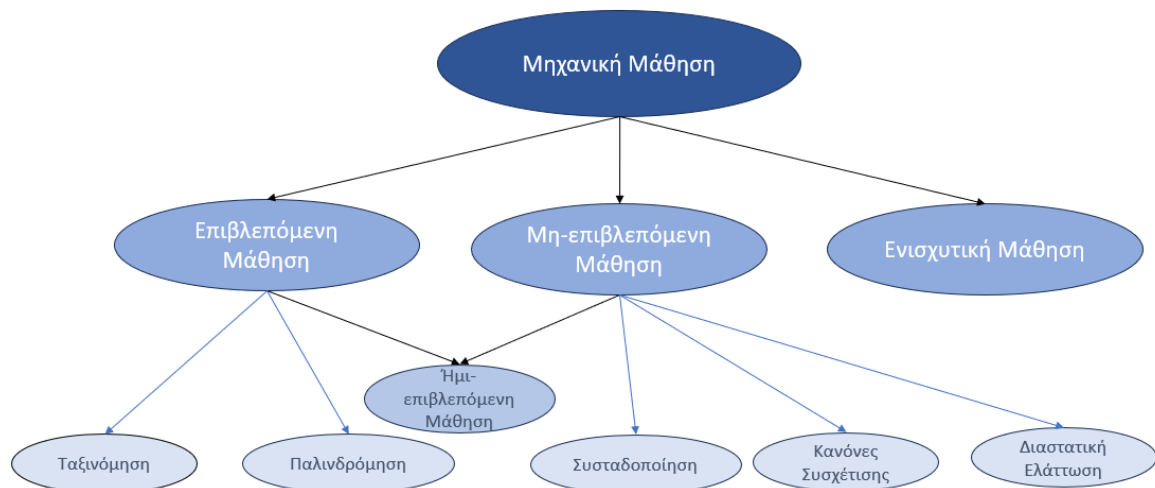
- **Εποπτευόμενη Μάθηση (Supervised Learning):** το μοντέλο εκπαιδεύεται από ένα σύνολο δεδομένων με χαρακτηριστικές εισόδους και αντίστοιχες επιθυμητές ετικέτες εξόδων. Με εξαγωγή χαρακτηριστικών στις εισόδους των αρχικών δεδομένων, το μοντέλο έχει σαν στόχο να βρίσκει παρόμοια χαρακτηριστικά στις εισόδους και να προβλέπει τις ετικέτες εξόδου από νέα δεδομένα με την μέγιστη ακρίβεια. Παραδείγματα εποπτευόμενης μάθησης είναι τα προβλήματα ταξινόμησης [21] και παλινδρόμησης [22].
- **Μη Εποπτευόμενη Μάθηση (Unsupervised Learning):** το μοντέλο εκπαιδεύεται από ένα σύνολο δεδομένων που δεν περιλαμβάνει ετικέτες. Μελετά τα δεδομένα εισόδου και προσπαθεί να εντοπίσει μοτίβα και να ανακαλύψει δομικές ή συντονιστικές πτυχές, όπως ομαδοποίηση (αλγόριθμος K-Means), διάσπαση (αλγόριθμος PCA) ή ανίχνευση ανωμαλιών [23]
 - **Ήμι-εποπτευόμενη μάθηση (Semi-Supervised Learning):** συνδυάζει τις δύο κατηγορίες μηχανικής μάθησης, εποπτευόμενη και μη εποπτευόμενη μάθηση, και χρησιμοποιεί μοντέλα που εκπαιδεύονται με ένα μικρό σύνολο από δεδομένα με ετικέτα και ένα μεγαλύτερο με δεδομένα χωρίς ετικέτα με σκοπό να προβλέψει τις άγνωστες ετικέτες [24]
- **Ενισχυτική Μάθηση (Reinforcement Learning):** στην κατηγορία αυτή το μοντέλο μάθησης προσπαθεί να μάθει μέσα από την άμεση αλληλεπίδραση με το περιβάλλον. Σε καταστάσεις που ο επιθυμητός στόχος του αλγορίθμου είναι σταθερός ή δυαδικός ("ναι" ή "όχι", 0 ή 1, "θετικό" ή "αρνητικό") είναι εφικτή η μάθηση μέσω του παραδείγματος. Σε άλλη περίπτωση με μεταβλητό επιθυμητό αποτέλεσμα, το μοντέλο μαθαίνει με την εμπειρία. Λαμβάνει feedback σε σχέση με τις ενέργειές του και προσπαθεί να μάθει τη βέλτιστη συμπεριφορά που θα το οδηγήσει στη μέγιστη ανταμοιβή [25]

Στην επιβλεπόμενη μάθηση οι δύο τύποι των αλγορίθμων που χρησιμοποιούνται ανάλογα με το πρόβλημα είναι η ταξινόμηση και η παλινδρόμηση. Για εργασίες ταξινόμησης οι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται μαθαίνουν από τα επισημασμένα δεδομένα και μπορεί να είναι:

- Δέντρα Απόφασης (Decision Trees)
- Ταξινομητές Τυχαίου Δάσους (Random Forest Classifiers)
- Νευρωνικά Δίκτυα

Αντίστοιχα, για εργασίες παλινδρόμησης οι αλγόριθμοι που χρησιμοποιούνται μαθαίνουν από το σετ δεδομένων αυτή τη φορά όμως για την πρόβλεψη συνεχών τιμών, π.χ. για την πώληση ενός ακινήτου βάσει συγκεκριμένων χαρακτηριστικών, τιμή μιας μετοχής κ.α. Οι αλγόριθμοι αυτοί μπορεί να είναι:

- Γραμμική παλινδρόμηση
- Υποστηρικτικές Μηχανές
- Δέντρα Απόφασης
- Νευρωνικά Δίκτυα



Εικόνα 2.5.1.1. : Διαγραμματική απεικόνιση κατηγοριών και εφαρμογών της μηχανικής μάθησης

Εστιάζοντας στην τελευταία κατηγορία αλγορίθμων εποπτευόμενης μάθησης, τα νευρωνικά δίκτυα αποτελούν δομικό στοιχείο της μηχανικής μάθησης και έχουν φέρει επανάσταση στον τρόπο λειτουργίας της τεχνητής νοημοσύνης [26, 27]. Εμπνευσμένα από τους βιολογικούς νευρώνες του ανθρώπινου εγκεφάλου δημιουργήθηκαν με σκοπό να μιμηθούν την διαδικασία μάθησης που ακολουθεί ένας ανθρώπινος εγκέφαλος, ώστε να είναι ικανά να επιλύσουν πολύπλοκα προβλήματα που οι παραδοσιακές μέθοδοι προγραμματισμού αδυνατούν να λύσουν. Αποτελούνται από διαφορετικά επίπεδα (layers) διασυνδεδεμένων κόμβων που αντιστοιχούν στους νευρώνες του ανθρώπινου εγκεφάλου, τα οποία λαμβάνουν

εισόδους, τις επεξεργάζονται και εκπέμπουν μία έξοδο. Στόχος της δημιουργίας τους είναι να αντιμετωπίζουν προβλήματα, όπως η αυτόματη αναγνώριση προτύπων, η ταξινόμηση δεδομένων, η πρόβλεψη και η εκτίμηση καταστάσεων μέσω της μοντελοποίησης περίπλοκων σχέσεων μεταξύ των δεδομένων εισόδου και εξόδου. Τα νευρωνικά δίκτυα μπορούν να εκπαιδευτούν μέσω της εποπτευόμενης μάθησης ως μέθοδος του machine learning για να συγκεντρώνουν και να ταξινομούν μεγάλο όγκο δεδομένων πολύ γρήγορα.

Στην παρούσα εργασία έχουν χρησιμοποιηθεί Τεχνητά Νευρωνικά Δίκτυα ως αλγόριθμοι εποπτευόμενης μάθησης προκειμένου να εκπαιδευτούν με τα κατάλληλα και επαρκή δεδομένα εισόδου-εξόδου (για τις εισόδους λήφθηκαν τιμές από επιταχύνσεις για διαφορετικά FE μοντέλα της κατασκευής και οι έξοδοι δηλώνουν τις διαφορετικές καταστάσεις υγείας των μοντέλων), ώστε αργότερα να μπορούν να αναγνωρίζουν αλλά και να ταξινομούν τις καταστάσεις ζημιών στην τρισδιάστατη δικτυωτή κατασκευή του πύργου που μελετήθηκε. Στις παρακάτω ενότητες γίνεται λεπτομερής επεξήγηση της όλης διαδικασίας που αφορά στην εποπτευόμενη μάθηση και στο νευρωνικό δίκτυο.

2.5.2. Δημιουργία του σετ δεδομένων εποπτευόμενης μάθησης από αποκρίσεις

Όπως έχει ήδη αναφερθεί, στην επιβλεπόμενη μάθηση χρησιμοποιούνται δεδομένα εκπαίδευσης, που περιλαμβάνουν τις εισόδους και τις αντίστοιχες έτοιμες εξόδους, επιτρέποντας στο μοντέλο να μαθαίνει με την πάροδο του χρόνου. Αρχικά συλλέγεται ένα μεγάλο σύνολο από δεδομένα εισόδων με τις ετικέτες εξόδου. Έπειτα, οι αλγόριθμοι επιβλεπόμενης μάθησης αναλύουν τα δεδομένα και εξάγουν χαρακτηριστικά (feature extraction) για κάθε σημείο των δεδομένων με βάση διάφορες παραμέτρους. Το μοντέλο μαθαίνει από τα δεδομένα και αφού εκπαιδευτεί κατάλληλα μπορεί να κάνει προβλέψεις για τις ετικέτες εξόδου νέων δεδομένων με βάση την αναγνώριση χαρακτηριστικών στην είσοδο.

Στην επιβλεπόμενη μάθηση, έναντι της μη επιβλεπόμενης, τα αρχικά δεδομένα με ετικέτα περιλαμβάνουν τα χαρακτηριστικά (X_i) αλλά και τον τελικό στόχο (Y_i).



Εικόνα 2.5.2.1. : Επιβλεπόμενη και μη επιβλεπόμενη μάθηση

Στην παρούσα εργασία, προκειμένου να οργανώσουμε το σετ δεδομένων εποπτευόμενης μάθησης, χρειαζόμαστε δεδομένα επιταχύνσεων από πλήθος διαφορετικών καταστάσεων υγείας (υγιής κατάσταση και περιπτώσεις ζημιάς) του πύργου με τυχαίες κάθε φορά τιμές παραμέτρων. Πιο αναλυτικά, χρησιμοποιείται τυχαία δειγματοληψία για διαφορετικές τιμές μέτρου ελαστικότητας (E), πυκνότητας (ρ) και μέτρου απόσβεσης ζ, ώστε για κάθε μία από αυτές να προκύπτουν διαφορετικοί πίνακες K (μητρώο στιβαρότητας) και M (μητρώο μάζας). Στη συνέχεια, λύνεται με την μέθοδο που παρουσιάστηκε στη ενότητα 2.4.2. το ιδιοπρόβλημα και προκύπτουν από τις ιδιομορφές οι επιταχύνσεις για τα 8 σημεία του πύργου στα οποία υπάρχουν αισθητήρες μέτρησης. Η διαδικασία επαναλαμβάνεται για κάθε αριθμητικό μοντέλο FE του πύργου που περιγράφει μια διαφορετική κατάσταση υγείας.

Αφού υπολογιστούν οι επιταχύνσεις μπορεί να δημιουργηθεί πλέον το σετ δεδομένων. Η τελική μορφή του επισημασμένου σετ δεδομένων θα είναι:

$$\mathbf{Train_set} = \{(A_{1,1}, Y_{1,1}), (A_{1,2}, Y_{1,2}), \dots, (A_{n,s}, Y_{n,s})\} \quad (2.13)$$

όπου,

- A: η επιτάχυνση
- Y: η κατάσταση υγείας
- n: ο αισθητήρας μέτρησης
- s: η περίπτωση ζημιάς που μελετάται στο μοντέλο

Το επισημασμένο σετ δεδομένων είναι έτοιμο για την εκπαίδευση του νευρωνικού δικτύου.

2.5.3. Εξαγωγή χαρακτηριστικών δεδομένων βαθιάς μάθησης με χρήση συνέλιξης

Ένα μονοδιάστατο (1D) συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network/ CNN) εφαρμόζεται στο σετ δεδομένων εποπτευόμενης μάθησης, όπου οι χαρακτηριστικές τιμές των αποκρίσεων προέκυψαν από τις προσομοιώσεις. Λεπτομέρειες σχετικά με την ακριβή λειτουργία των Τεχνητών Νευρωνικών Δικτύων καθώς και τις μαθηματικές διατυπώσεις που τα διέπουν μπορούν να εντοπισθούν σε σχετικά άρθρα και εγχειρίδια [27, 28] ή σε προηγούμενες εργασίες SHM [7,29]. Ο στόχος είναι η αναγνώριση και η ταξινόμηση των καταστάσεων ζημιάς στην κατασκευή. Το CNN εκπαιδεύεται να αντιστοιχίσει τις εισόδους (χαρακτηριστικά των αποκρίσεων) με τις επιθυμητές ετικέτες ζημιάς, προσαρμόζοντας τα βάρη των επιπέδων του δικτύου με σκοπό να ελαχιστοποιήσει το σφάλμα της πρόβλεψης. Το CNN εξάγει αυτόματα σημαντικά χαρακτηριστικά από τις εισόδους, τα οποία είναι χρήσιμα για την αναγνώριση των διαφόρων καταστάσεων ζημιάς στην κατασκευή.

Πιο αναλυτικά, το δίκτυο αποτελείται από πολλά επίπεδα (layers) διασυνδεδεμένων κόμβων καθένα από τα οποία επεξεργάζεται ένα διακριτό μονοδιάστατο σήμα εισόδου in (input) εφαρμόζοντας ένα φίλτρο (ή πυρήνα) w_k γνωστό και ως «βάρος». Τότε κάθε τελικός νευρώνας του δικτύου παράγει ένα αποτέλεσμα εξόδου (output) f_k μήκους t σύμφωνα και με την διαδικασία συνέλιξης:

$$f_k = w_k * in \text{ with } (w_k * in)[t] = \sum_j in(j) w_k(t - j + 1) \quad (2.14)$$

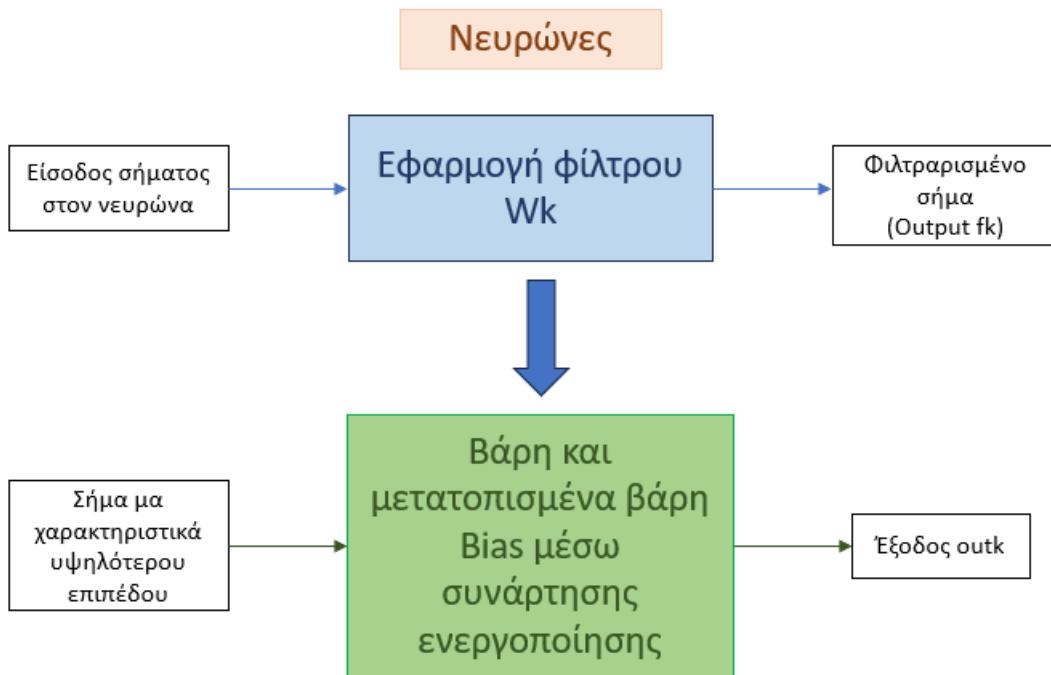
όπου k ο νευρώνας.

Το φιλτραρισμένο πλέον σήμα, που περιέχει χαρακτηριστικά υψηλότερου επιπέδου, επεξεργάζεται από την συνάρτηση ενεργοποίησης του νευρώνα $a_k = a(f_k)_k$ με την παράμετρο μετατόπισης bias b_k για να πάρει το αποτέλεσμα εξόδου στο τελικό επίπεδο σύμφωνα με την εξίσωση:

$$out_k = a(w_k * in + b_k)_k \quad (2.15)$$

Η έξοδος κάθε σταδίου μεταφέρεται στα επόμενα συνελκτικά επίπεδα, όπου χρησιμοποιείται σαν είσοδος με την διαδικασία να επαναλαμβάνεται σε κάθε layer. Πρέπει να γίνει σαφές ότι οι έξοδοι από τα προηγούμενα επίπεδα αθροίζονται και συνολικά χρησιμοποιούνται σαν είσοδοι στο επόμενο επίπεδο. Αυτό σημαίνει ότι ένας μονός συνελκτικός νευρώνας δημιουργεί μία μόνο έξοδο ανεξαρτήτως του

αριθμού των εισόδων (γνωστό και ως «βάθος» ή "depth"). Τα επεξεργασμένα σήματα ή αλλιώς τα αποτελέσματα των εξόδων των συνελκτικών νευρώνων που προκύπτουν είναι γνωστά και ως «χάρτες χαρακτηριστικών» ή "feature maps" και από εδώ και στο εξής θα συμβολίζονται με το γράμμα h . Οι χάρτες χαρακτηριστικών περιέχουν τις επονομαζόμενες πληροφορίες-υψηλού-επιπέδου, που αποκαλύπτουν σταδιακά χρήσιμα χαρακτηριστικά στην είσοδο (input).



Εικόνα 2.5.3.1. : Δημιουργία εξόδου στο νευρωνικό δίκτυο

2.5.4. Ταξινόμηση Deep Learning

Μετά την εκπαίδευση, το CNN μπορεί να χρησιμοποιηθεί για την ταξινόμηση νέων δεδομένων, εφαρμόζοντας όλα όσα έχει μάθει κατά την εκπαίδευσή του. Συγκεκριμένα, θα μπορεί να αναγνωρίζει τα χαρακτηριστικά των νέων εισόδων και να τα κατηγοριοποιεί με βάση την περίπτωση ζημιάς που υπάρχει στην κατασκευή.

Για την μέθοδο της ταξινόμησης χρησιμοποιούνται οι νευρώνες ταξινόμησης perceptrons και μέσω μιας συνάρτησης ενεργοποίησης υπολογίζονται οι νέες έξοδοι του νευρώνα από το γινόμενο των διανυσμάτων εισόδου και των συντελεστών βαρύτητας. Πιο αναλυτικά εξάγει δεδομένα σύμφωνα με την παρακάτω εξίσωση:

$$\mathbf{a}_k = \mathbf{a}(W_k * \mathbf{h} + \mathbf{b}_k)_k \quad (2.16)$$

Όπου,

- \mathbf{a}_k η έξοδος του νευρώνα k ,
- \mathbf{a} η συνάρτηση ενεργοποίησης,
- \mathbf{W}_k τα βάρη,
- \mathbf{h} η είσοδος (που μπορεί να είναι ίδια με τους χάρτες χαρακτηριστικών υψηλού επιπέδου όπως με την χρήση των CNN στην εποπτευόμενη μάθηση),
- \mathbf{b}_k το μετατοπισμένο βάρος (bias)

Μετά την επεξεργασία των εισόδων από τους νευρώνες ταξινόμησης perceptrons στο τελικό επίπεδο ταξινόμησης ολοκληρώνεται η διαδικασία της «Προς τα εμπρός προώθησης» του δικτύου ή αλλιώς "Forward Propagation/ FP". Αυτό σημαίνει ότι οι πληροφορίες που σχηματίστηκαν από τα προηγούμενα επίπεδα συνεχίζουν να διαδίδονται προς τα εμπρός μέσω του δικτύου. Κατά την διαδικασία της «προς τα εμπρός προώθησης» οι εισοδοί περνούν από τους νευρώνες ταξινόμησης στο τελικό επίπεδο του δικτύου. Όπως περιγράφεται και από την σχέση (2.16), κάθε νευρώνας υπολογίζει τις νέες εξόδους συναρτήσει των βαρών και των εισόδων, προσθέτοντας ένα μετατοπισμένο βάρος \mathbf{b}_k . Κάθε μία από τις νέες εξόδους που προκύπτουν περνάει μέσω μίας συνάρτησης ενεργοποίησης, όπως η συνάρτηση Softmax, για να δώσει σαν αποτέλεσμα μία πρόβλεψη για την ετικέτα υγείας. Η συνάρτηση Softmax μετασχηματίζει τις τιμές των εξόδων των νευρώνων ταξινόμησης σε πιθανότητες, ώστε να προκύψουν οι προβλέψεις για τις ετικέτες υγείας. Το αποτέλεσμα της συνάρτησης είναι ένα διάνυσμα πιθανοτήτων σ που δίνει τις τελικές προβλέψεις. Παρακάτω περιγράφεται η συνάρτηση:

$$\sigma_i = \frac{e^{x_i^{lc}}}{\sum_{j=1}^{N_{lc}} e^{x_j^{lc}}} \quad (i=1,2, \dots, N_{lc}) \quad (2.17)$$

Όπου, \mathbf{l}_c το επίπεδο ταξινόμησης σύμφωνα με τον αριθμό των νευρώνων N_{lc} .

Ωστόσο, το δίκτυο θα πρέπει να έχει «μάθει» επαρκώς τις κατάλληλες τιμές των χαρακτηριστικών που αναφέρθηκαν προηγουμένως στην ενότητα 2.4.2., δηλαδή των φίλτρων w_k , τα βάρη \mathbf{W}_k και τα μετατοπισμένα βάρη bias \mathbf{b}_k ώστε να προβλέψει τις σωστές ετικέτες υγείας. Η αποτελεσματικότητα των φίλτρων επηρεάζει την ικανότητα του δικτύου να εξάγει χαρακτηριστικά από τα δεδομένα. Το ίδιο συμβαίνει και με τα βάρη και μετατοπισμένα βάρη κάθε νευρώνα ταξινόμησης, καθώς επηρεάζουν τον τρόπο με τον οποίο από την είσοδο θα προκύψει η έξοδος. Η

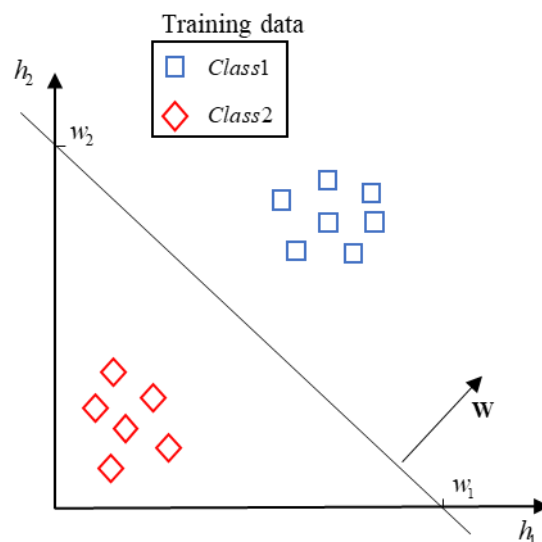
διαδικασία της μάθησης του δικτύου προσαρμόζει κάθε φορά τις τιμές των βαρών για να βελτιστοποιήσει την απόδοση του δικτύου και επιτυγχάνεται με την διαδικασία της Αντίστροφης Διάδοσης Σφάλματος (Backpropagation). Ουσιαστικά, η μέθοδος αυτή χρησιμοποιείται για να μειώσει την απόκλιση μεταξύ των πραγματικών ετικετών υγείας Y_i και των προβλεπόμενων ετικετών σ_i , με i ο αριθμός της κλάσης, και επιτυγχάνεται με το να ενημερώνει κάθε φορά τα βάρη W_k του δικτύου. Το μέτρο της απόκλισης μεταξύ των ετικετών μπορεί να μετρηθεί με την διαδικασία της Κατηγορηματικής Απώλειας (Categorical Cross Entropy) σύμφωνα με την εξίσωση:

$$CE = \sum_N Y_i \ln(\sigma_i) \quad (2.18)$$

και να ελαχιστοποιείται με την διαδικασία της Αντίστροφης Διάδοσης (Backpropagation) για την αποτελεσματική εκπαίδευση του δικτύου.

Ένα καλά εκπαιδευμένο Συνελκτικό Νευρωνικό Δίκτυο ως προς την αρχιτεκτονική και τα δεδομένα μάθησης του μπορεί να γενικευτεί και για τις πραγματικές κατασκευές, δεδομένου ότι η παρέμβαση του σφάλματος μοντέλου είναι μικρή. Το πόσο μικρή είναι αυτή η παρέμβαση ερευνάται ενδελεχώς σε αυτή την εργασία σε μία κατασκευή πύργου για την αναγνώριση των περιπτώσεων βλαβών.

Παρακάτω περιγράφεται η όλη διαδικασία που αναφέρθηκε με τη μορφή σχεδιαγράμματος και εικόνας.



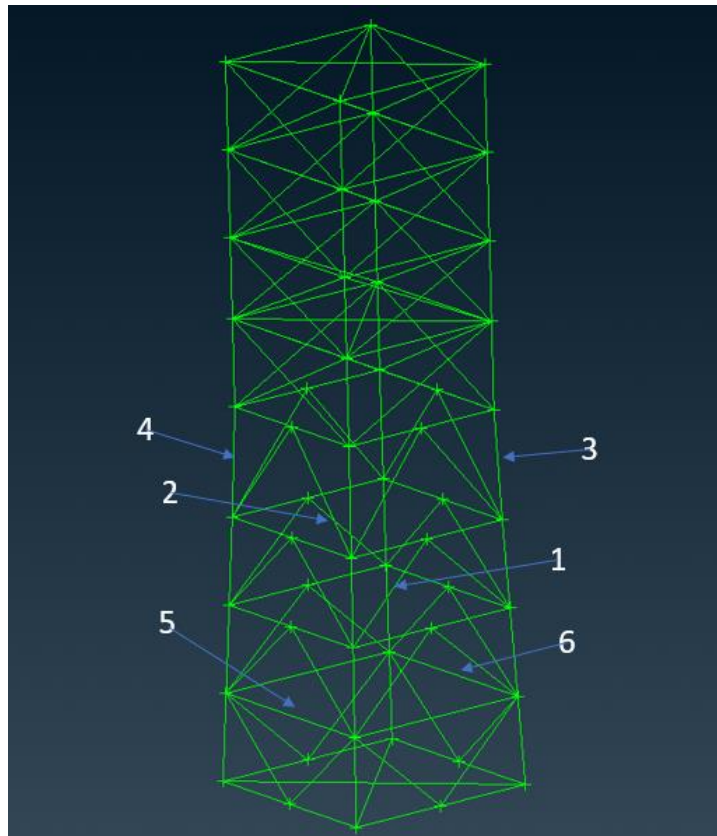
Εικόνα 2.5.4.2. : Όριο απόφασης W για ένα πρόβλημα δυαδικής ταξινόμησης για ένα απλοποιημένο πρόβλημα κατηγοριοποίησης βλάβης.

Για όλες τις διατυπώσεις του Συνελκτικού Νευρωνικού Δικτύου (CNN) που αναφέρθηκαν, έγινε χρήση της βιβλιοθήκης ανοιχτού κώδικα Python Keras [30].

3. Πείραμα

Για την παρακολούθηση της δομικής ακεραιότητας της δικτυωτής κατασκευής του πύργου χρησιμοποιήθηκαν προηγμένες τεχνολογίες και μέθοδοι ανάλυσης για την μοντελοποίηση και την ανάλυση αριθμητικών δεδομένων που προκύπτουν, για τις οποίες έγινε λόγος στα προηγούμενα κεφάλαια. Τα μοντέλα που αναπτύχθηκαν, με την μέθοδο των πεπερασμένων στοιχείων, αποτυπώνουν με ακρίβεια και αξιοπιστία τις καταστάσεις υγείας αλλά και τις καταστάσεις βλαβών που μπορεί να προκύψουν σε μία αληθινή κατασκευή. Με την χρήση των αριθμητικών δεδομένων που προκύπτουν μπορούμε να εξάγουμε σημαντικά αποτελέσματα και συμπεράσματα που αφορούν στον έλεγχο της δομικής ακεραιότητας της κατασκευής.

Αρχικά, σχεδιάζεται με την χρήση του λογισμικού ANSA της εταιρείας BETA CAE Systems ένα συμμετρικό μοντέλο πεπερασμένων στοιχείων του πύργου που περιγράφει την κατάσταση υγείας του. Έπειτα, στο ίδιο συμμετρικό μοντέλο σχεδιάζονται 12 διαφορετικές καταστάσεις ζημιάς που χωρίζονται σε δύο κατηγορίες. Η πρώτη κατηγορία αφορά σε περιπτώσεις μεγάλης ζημιάς στην κατασκευή λόγω απώλειας υλικού σε 6 διαφορετικά, κάθε φορά, σημεία του δικτύματος, ενώ η δεύτερη κατηγορία αναφέρεται σε μικρότερες περιπτώσεις ζημιάς, λόγω διαφορετικών τιμών στο μέτρο ελαστικότητας E και στη πυκνότητα ρ στα αντίστοιχα 6 στοιχεία (elements) του πύργου. Το συμμετρικό μοντέλο, λοιπόν, αποτελείται από 1 κατάσταση υγείας και 12 καταστάσεις ζημιάς, 6 από την πρώτη κατηγορία (el_1, el_2 μέχρι el_6) και 6 από την δεύτερη (pid_1, pid_2 μέχρι pid_6). Στη συνέχεια, καθώς δεν είναι εφικτή η δημιουργία μιας αληθινής κατασκευής του πύργου σε πραγματικά δεδομένα, προσομοιώνεται ξανά με την χρήση της μεθόδου των πεπερασμένων στοιχείων ένα ασύμμετρο αυτή τη φορά μοντέλο, το οποίο λαμβάνει υπόψη τις ατέλειες μιας πραγματικής κατασκευής. Και στο ασύμμετρο μοντέλο σχεδιάζονται από την αρχή η υγιής κατάστασή του και οι αντίστοιχες 12 περιπτώσεις ζημιάς όπως στο συμμετρικό στα ίδια ακριβώς σημεία.



Εικόνα 3.1. : Μοντέλο FE πύργου με τις θέσεις ζημιάς

Περίπτωση ζημιάς	Μέλος που αφαιρείται	Μέλος με διαφορετικό PROD
1η κατηγορία ζημιάς	e1_1	1
	e1_2	2
	e1_3	3
	e1_4	4
	e1_5	5
	e1_6	6
2η κατηγορία ζημιάς	pid_1	1
	pid_2	2
	pid_3	3
	pid_4	4
	pid_5	5
	pid_6	6

Εικόνα 3.2. : Περιπτώσεις ζημιάς στις αντίστοιχες θέσεις του πύργου

Μετά τον σχεδιασμό των μοντέλων πεπερασμένων στοιχείων στον προ επεξεργαστή ANSA, λύνεται το ιδιοπρόβλημα σε κάθε αρχείο με την χρήση του modal solver SOL112 στο Nastran για κρουστική διέγερση F. Προκύπτουν, λοιπόν, οι αντίστοιχες ιδιομορφές της κατασκευής και οι επιταχύνσεις από υπέρθεσή τους σε 8 σημεία μέτρησης. Μέσα στα αρχεία .nas περιλαμβάνονται αρχεία κειμένου .bdf τα οποία προκύπτουν από το MATLAB και έχουν μέσα τυχαίες τιμές για τις βασικές παραμέτρους της κατασκευής (μέτρο ελαστικότητας E, πυκνότητα ρ, συντελεστής απόσβεσης ζ) για κάθε μοντέλο FE που σχεδιάστηκε. Η τυχαιότητα αυτή της διακύμανσης του $\pm 5\%$ στις παραμέτρους μας επιτρέπει να προσομοιώνουμε διαφορετικές συμπεριφορές στα μοντέλα και να εξάγουμε έναν μεγάλο όγκο δεδομένων από επαναλήψεις. Οι τιμές αυτές θα αναφερθούν αργότερα για κάθε μοντέλο. Έπειτα, τα αρχεία .nas εισάγονται στο MATLAB όπου με επαναλήψεις της διαδικασίας λύνεται το ιδιοπρόβλημα για την ίδια κρουστική διέγερση, με διαφορετικές όμως συνθήκες στα μοντέλα FE και προκύπτει ένας μεγάλος όγκος δεδομένων για τις επιταχύνσεις των σημείων μέτρησης. Στην επόμενη εικόνα περιγράφονται τα μέχρι τώρα βήματα.

```

Input: Number of load cases  $n$  and statistical bounds for each parameter  $\rho, \zeta, E$ 
Output:  $n$  number of vibration responses and health labels  $s$ 
1. for  $i = 1 : n$ 
2.   sample  $E, \rho, g \rightarrow \mathbf{K} = \mathbf{K}(E, g), \mathbf{M} = \mathbf{M}(\rho, g)$ 
3.   sample modal damping  $\zeta$ 
4.   for  $j = 1 : s$ 
5.     define Health status  $\rightarrow \mathbf{Y}_{i,j}$ 
6.     define loads  $\rightarrow \mathbf{F}$ 
7.     solve eigenproblem  $\rightarrow [\mathbf{K} - \omega_m^2 \mathbf{M}] \Phi_m = \mathbf{0}$ 
8.     extract  $m$  natural frequencies and modes  $\rightarrow \omega_m, \Phi_m$ 
9.     solve modal equations and calculate accelerations  $\rightarrow \mathbf{A}$ 
10.    return  $\mathbf{A}_{i,j}$  and  $\mathbf{Y}_{i,j}$ 
11.  end

```

Εικόνα 3.3. : Εξάγωγή δεδομένων για επιταχύνσεις και καταστάσεις υγείας

Αφού ληφθούν οι τιμές για τις επιταχύνσεις αντιστοιχίζονται με τις καταστάσεις υγείας στις οποίες αναφέρονται και οργανώνεται το σετ εποπτευόμενης μάθησης.

Training Case	Label
Επιταχύνσεις	Κατάσταση Υγείας
A	Υ (υγιής)
A1	Υ1
A2	Υ2
A3	Υ3
A4	Υ4
A5	Υ5
A6	Υ6
A7	Υ7
A8	Υ8
A9	Υ9
A10	Υ10
A11	Υ11
A12	Υ12

Εικόνα 3.4. : Οργάνωση του σετ δεδομένων

Έπειτα, ακολουθεί το στάδιο της εκπαίδευσης του συνελκτικού νευρωνικού δικτύου. Επειδή είναι δύσκολη και χρονοβόρα η εκπαίδευσή του και για τις 13 διαφορετικές καταστάσεις υγείας και για απλοποίηση της διαδικασίας, επιλέγονται 6 διαφορετικοί συνδυασμοί με δύο μόνο καταστάσεις υγείας στον καθένα που θα αναφερθούν παρακάτω. Το πρόβλημα ταξινόμησης μετασχηματίζεται σε δυαδικό. Πιο αναλυτικά, τα labels στην προκειμένη περίπτωση θα είναι διανύσματα με δύο μόνο θέσεις, όπου και τα δύο θα αφορούν σε καταστάσεις ζημιάς από την ίδια κατηγορία με το νευρωνικό να είναι σε θέση αργότερα να αναγνωρίζει από τα νέα δεδομένα σε ποια από τις δύο καταστάσεις υγείας αναφέρεται το μοντέλο. Έτσι οργανώνονται τα παρακάτω labels.

Για την πρώτη κατηγορία ζημιών δημιουργούνται τα labels:

$$\bar{Y} = [\overline{Y_{el_1}} \quad \overline{Y_{el_3}}] : \text{Κατάσταση } el_1 \text{ με } el_3$$

$$\bar{Y} = [\overline{Y_{el_1}} \quad \overline{Y_{el_6}}] : \text{Κατάσταση } el_1 \text{ με } el_6$$

$$\bar{Y} = [\overline{Y_{el_4}} \quad \overline{Y_{el_5}}] : \text{Κατάσταση } el_4 \text{ με } el_5$$

Για την δεύτερη κατηγορία ζημιών δημιουργούνται τα labels:

$$\bar{Y} = \left[\overline{Y_{pid_1}} \quad \overline{Y_{pid_3}} \right] : \text{Κατάσταση pid_1 με pid_3}$$

$$\bar{Y} = \left[\overline{Y_{pid_1}} \quad \overline{Y_{pid_6}} \right] : \text{Κατάσταση pid_1 με pid_6}$$

$$\bar{Y} = \left[\overline{Y_{pid_4}} \quad \overline{Y_{pid_5}} \right] : \text{Κατάσταση pid_4 με pid_5}$$

Τα labels με τις αντίστοιχες επιταχύνσεις σαν είσοδοι, χρησιμοποιούνται για να εκπαιδεύσουν το νευρωνικό, ώστε να αναγνωρίζει κάθε φορά ποια από τις δύο καταστάσεις υγείας χαρακτηρίζουν το μοντέλο με τα νέα δεδομένα που εισάγονται. Για την εκπαίδευση χρησιμοποιούνται έτοιμες ρουτίνες που δεν θα παρουσιαστούν εκτενέστερα στην παρούσα εργασία αλλά θα αναφερθούν. Το νευρωνικό εκπαιδεύεται 30 φορές για την αναζήτηση του καλύτερου φίλτρου w_k και άρα την καλύτερη ακρίβεια. Έπειτα, παίρνουμε inputs από το ασύμμετρο μοντέλο ξεχωριστά για τις δύο κατηγορίες ζημιών (μεγάλη, μικρή) και τα εισάγουμε στο νευρωνικό, ώστε να ελεγχθεί κατά πόσο αναγνωρίζει σωστά σε ποια κατάσταση υγείας αναφέρεται από τους συνδυασμούς που δημιουργήθηκαν και τι μέσο σφάλμα προκύπτει στις δύο περιπτώσεις. Τα συμπεράσματα που προκύπτουν θα παρουσιαστούν και θα σχολιαστούν στην τελευταία ενότητα.

3.1. Συμμετρικό μοντέλο πεπερασμένων στοιχείων

Το συμμετρικό μοντέλο σχεδιάζεται για να προσομοιώσει αριθμητικά με την μέθοδο των πεπερασμένων στοιχείων την κατασκευή. Δημιουργούνται 13 αρχεία συμμετρικού μοντέλου στον προ-επεξεργαστή ANSA, όπου το πρώτο αναφέρεται στην υγιή κατάσταση, τα 6 επόμενα σε περιπτώσεις μεγάλης ζημιάς και τα 6 τελευταία σε καταστάσεις μικρότερης ζημιάς. Έπειτα λύνεται το ιδιοπρόβλημα στο MSC Nastran.

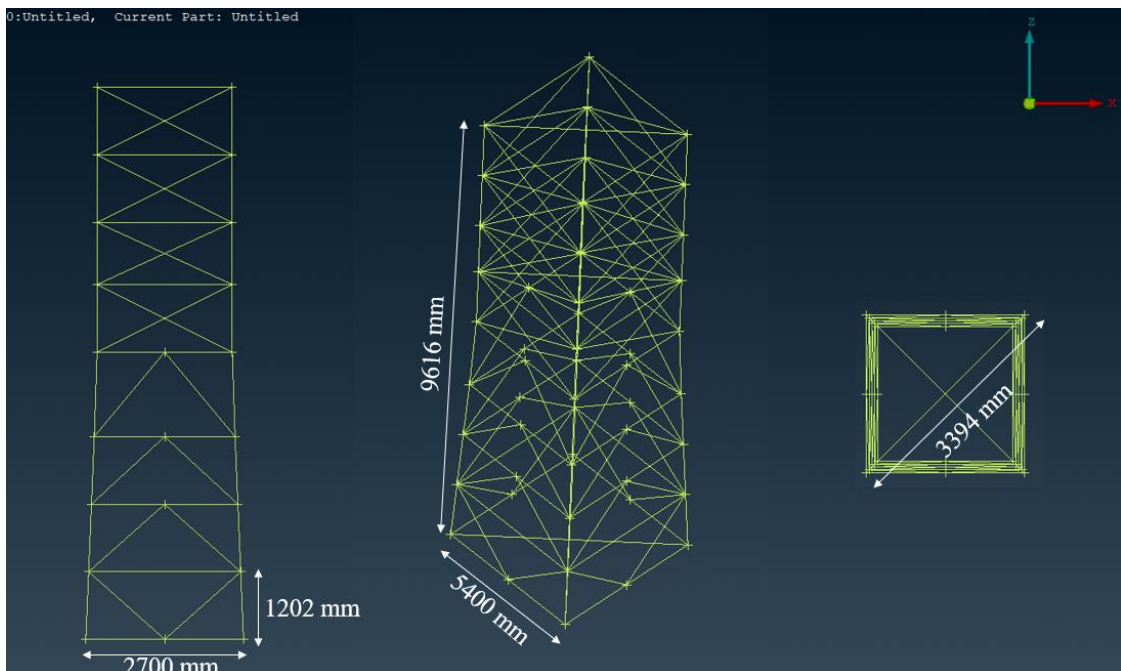
3.1.1. Σχεδίαση της healthy κατάστασης του συμμετρικού μοντέλου

Ο πύργος σχεδιάζεται στο ANSA και αποτελείται από 52 κόμβους (GRIDS) που συνδέονται μεταξύ τους με 154 στοιχεία ράβδου (CROD elements) σχηματίζοντας ένα τρισδιάστατο δικτύωμα. Κάθε element έχει διαφορετικό μήκος ανάλογα με τους κόμβους που ενώνει. Για όλα τα στοιχεία ράβδου CROD χρησιμοποιείται το ίδιο υλικό PROD με τις τιμές στις βασικές παραμέτρους να είναι ίδιες σε όλη την κατασκευή.

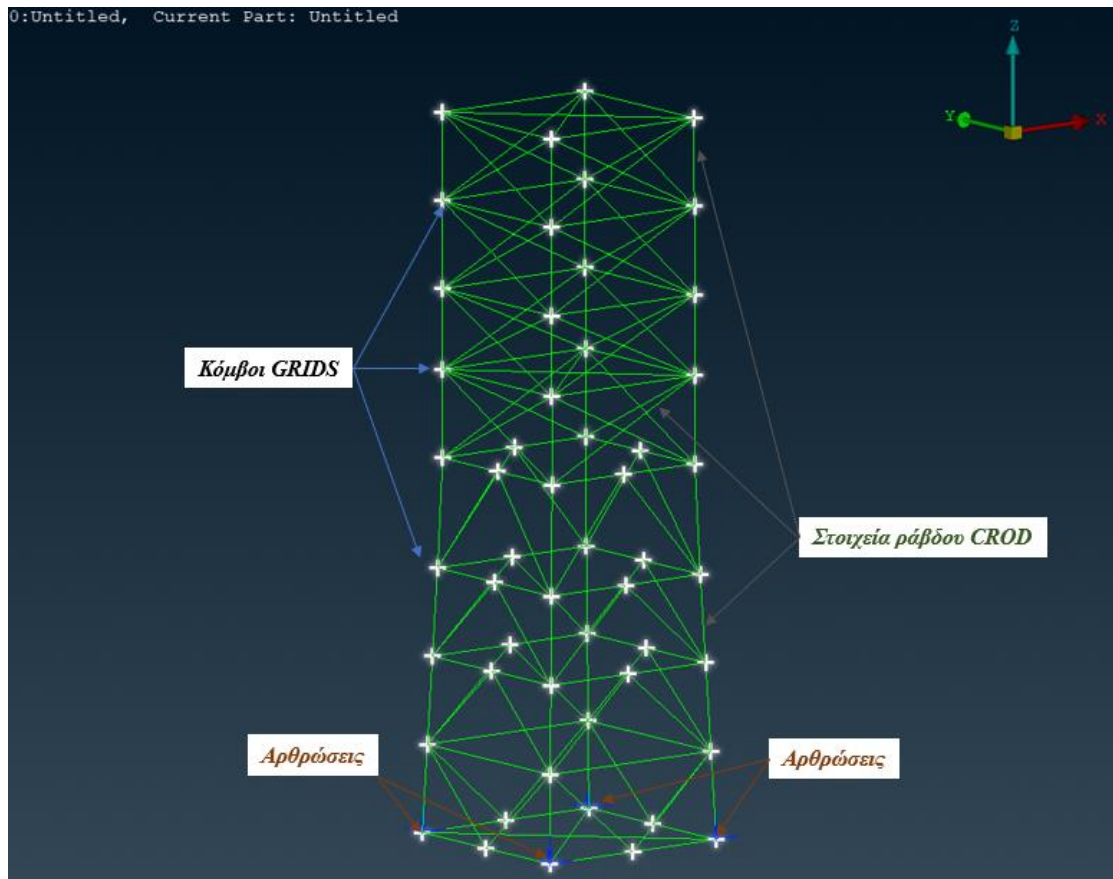
- το μέτρο ελαστικότητας E ίσο με $E = 210 \text{ GPa}$,
- η πυκνότητα ρ ίση με $\rho = 7800 \text{ kg/m}^3$,

- η διάμετρος της διατομής ίση με $d=10\text{mm}$
- το πάχος της διατομής ίσο με $t=2\text{mm}$.

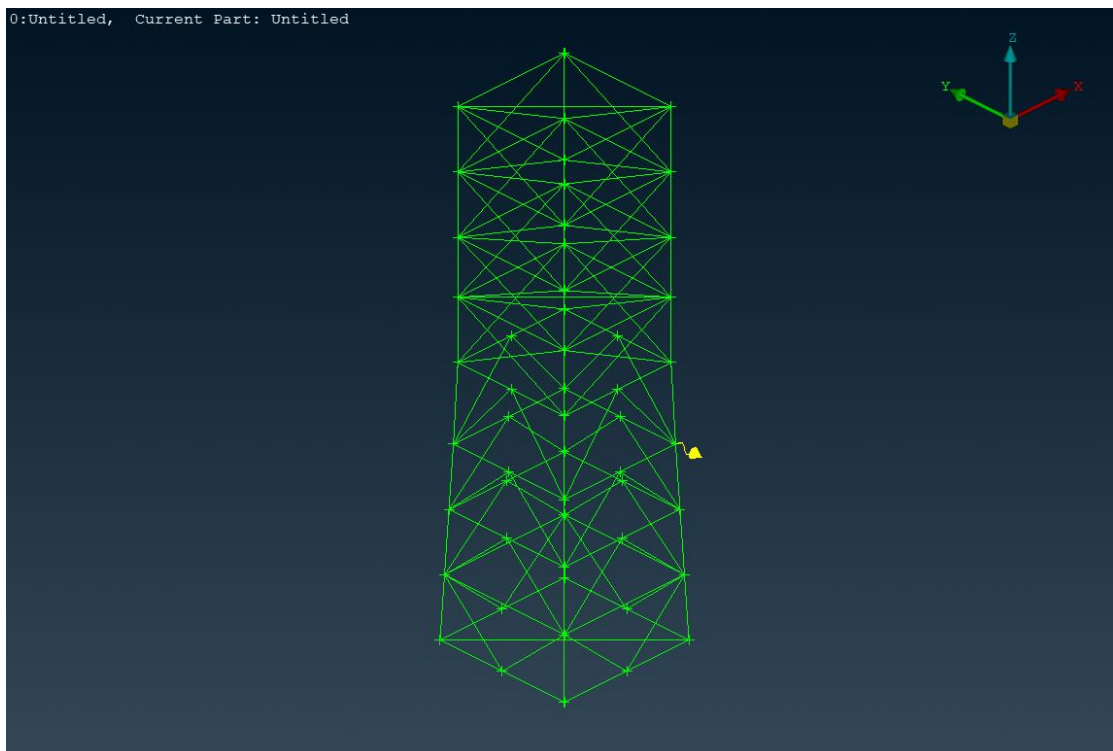
Έχουν τοποθετηθεί αρθρώσεις σε 4 σημεία του πύργου και 8 αισθητήρες μέτρησης κατά μήκος της κατασκευής σε διαφορετικά σημεία που καλύπτουν το μεγαλύτερο μέρος της. Εφαρμόστηκε κρουστική στιγμιαία διέγερση F στον κόμβο 22 για την ανάλυση των ιδιομορφών, όπου ο χρόνος δράσης της πάνω στην κατασκευή (t_0) είναι πολύ μικρός σε σχέση με τον χρόνο απόκρισης (ως χρόνος απόκρισης του ταλαντωτή θεωρείται η ιδιοπερίοδος του T_0). Ισχύει δηλαδή $t_0 \ll T_0$. Οι εικόνες που ακολουθούν περιγράφουν όσα αναφέρθηκαν.



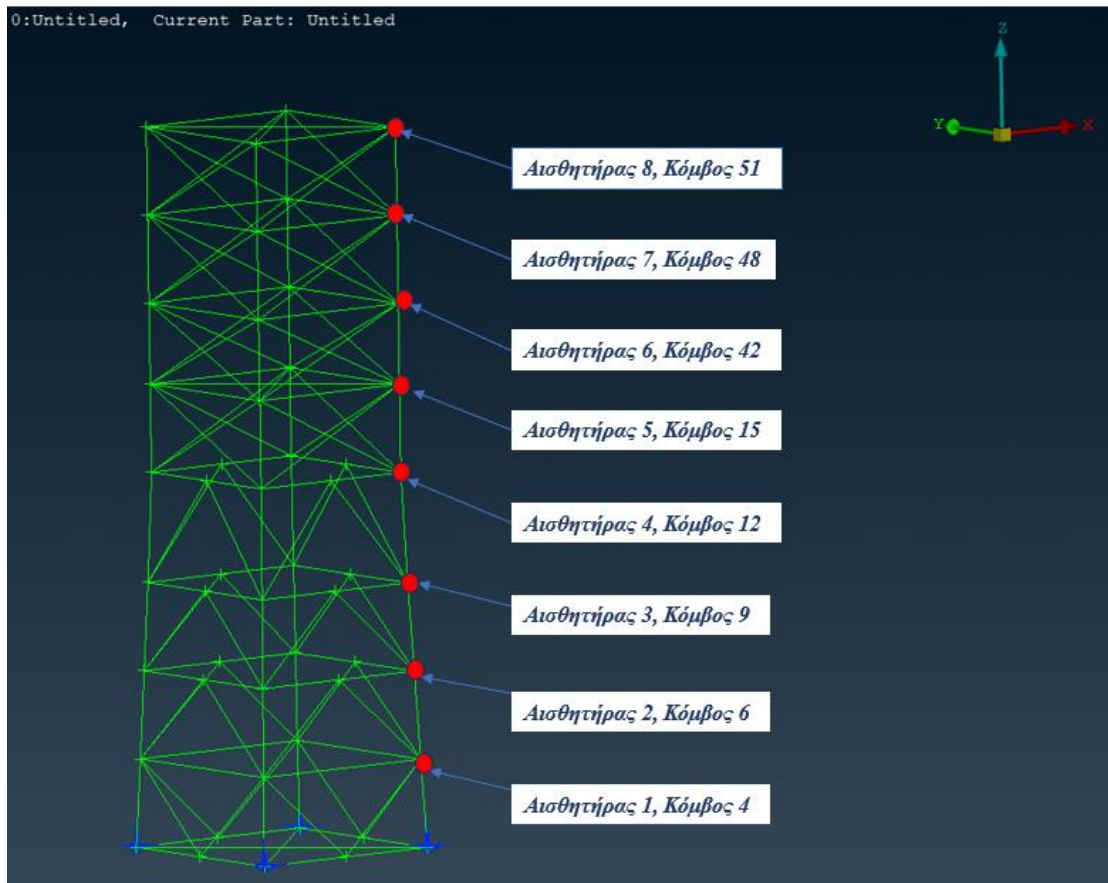
Εικόνα 3.1.1.1.: Διαστάσεις του πύργου



Εικόνα 3.1.1.2.: Συμμετρικό μοντέλο στην υγιή κατάσταση στο περιβάλλον του ANSA

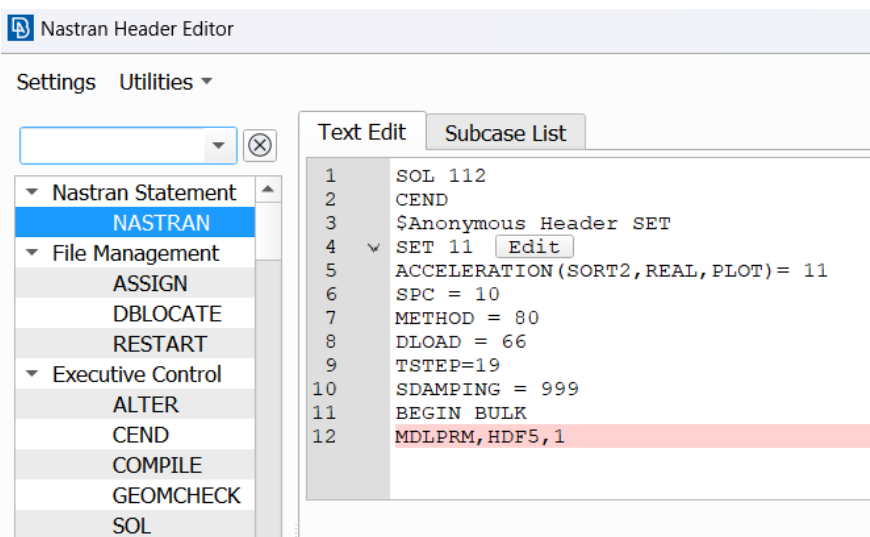


Εικόνα 3.1.1.3.: Κρουστική διέγερση στον κόμβο 22



Εικόνα 3.1.1.4.: Αισθητήρες μέτρησης

Για την επίλυση του δυναμικού προβλήματος χρησιμοποιείται το Nastran Header με solver SOL112. Ο SOL112 είναι ένας modal solver του λογισμικού MSC Nastran που λύνει το ιδιοπρόβλημα για δυναμικά προβλήματα και κάνει υπέρθεση ιδιομορφών.



Εικόνα 3.1.1.5.: Nastran Header

Αφού λυθεί το ιδιοπρόβλημα στο MSC Nastran αποθηκεύεται το αρχείο Truss_healthy_symmetric.nas που θα χρησιμοποιηθεί αργότερα στο MATLAB.


3.1.2. Σχεδίαση της πρώτης κατηγορίας ζημιών στο συμμετρικό μοντέλο

Η διαδικασία που περιεγράφηκε προηγουμένως επαναλαμβάνεται και για τις καταστάσεις ζημιάς στο συμμετρικό μοντέλο. Στην πρώτη κατηγορία ζημιών, δημιουργούνται 6 περιπτώσεις βλάβης όπου σε κάθε μια από αυτές έχει διαγραφεί ένα element από τον πύργο. Αυτή η κατηγορία ζημιών θεωρείται σημαντική και μεγάλη, όπως θα δείξουν αργότερα τα αποτελέσματα των αναλύσεων.

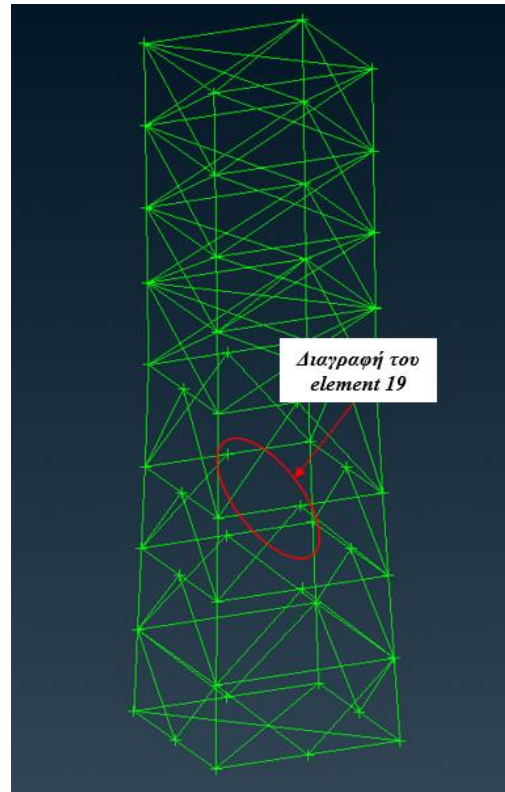
Περίπτωση ζημιάς	Μέλος που αφαιρείται	Μέλος με διαφορετικό PROD
1η κατηγορία ζημιάς	el_1	1
	el_2	2
	el_3	3
	el_4	4
	el_5	5
	el_6	6
2η κατηγορία ζημιάς	pid_1	-
	pid_2	-
	pid_3	-
	pid_4	-
	pid_5	-
	pid_6	-

Εικόνα 3.1.2.1...: Πρώτη κατηγορία ζημιών


Το συμμετρικό μοντέλο σχεδιάζεται, λοιπόν, με τις βασικές παραμέτρους να λαμβάνουν ίδιες τιμές όπως στην υγιή κατάσταση, δηλαδή για το μέτρο ελαστικότητας ισχύει $E = 210 \text{ GPa}$, για την πυκνότητα $\rho = 7800 \text{ kg/m}^3$, εμβαδόν επιφάνειας διατομής $A=3927 \text{ mm}^2$ και πάχος της διατομής ίσο με $t=2 \text{ mm}$. Σε όλη την έκταση του πύργου το υλικό είναι το ίδιο (MAT1), οι αρθρώσεις, η κρουστική διέγερση και οι αισθητήρες μέτρησης βρίσκονται στα ίδια σημεία με το υγιές μοντέλο και για το Header Nastran χρησιμοποιήθηκε ο solver SOL 112. Οι επόμενες εικόνες δείχνουν τις 6 περιπτώσεις ζημιάς στα διαφορετικά element του πύργου.




Εικόνα 3.1.2.2.: *Truss_el_1_symmetric*




Εικόνα 3.1.2.3.: *Truss_el_2_symmetric*




Εικόνα 3.1.2.4.: *Truss_el_3_symmetric*



Εικόνα 3.1.2.5.: *Truss_el_4_symmetric*



Εικόνα 3.1.2.6.: *Truss_el_5_symmetric*



Εικόνα 3.1.2.7.: *Truss_el_6_symmetric*

Ο modal solver SOL112 του Nastran λύνει το ιδιοπρόβλημα και κάνει υπέρθεση των ιδιομορφών, δίνοντας αποτελέσματα επιταχύνσεων για καθένα από τα 6 αρχεία.

Με εξαγωγή των δεδομένων παίρνω τα αντίστοιχα αρχεία *Truss_el_1_symmetric.nas*, *Truss_el_2_symmetric.nas*, *Truss_el_3_symmetric.nas*, *Truss_el_4_symmetric.nas*, *Truss_el_5_symmetric.nas*, *Truss_el_6_symmetric.nas* που θα χρησιμοποιηθούν αργότερα στο MATLAB.

3.1.3. Σχεδίαση της δεύτερης κατηγορίας ζημιών στο συμμετρικό μοντέλο

Η δεύτερη κατηγορία ζημιών περιγράφει λιγότερο σημαντικές καταστάσεις βλάβης, όπου εφαρμόζονται στοιχεία ράβδου με διαφορετικό υλικό και τιμές παραμέτρων σε 6 σημεία της κατασκευής. Για την μετέπειτα επεξεργασία των δεδομένων που θα προκύψουν, τα 6 αυτά σημεία στα οποία εφαρμόζεται η ζημιά (λεπτότερη ράβδος) είναι τα ίδια σημεία που μελετήθηκαν στην προηγούμενη ενότητα για τις καταστάσεις ζημιάς λόγω διαγραφής του element.

Περίπτωση ζημιάς	Μέλος που αφαιρείται	Μέλος με διαφορετικό PROD
1η κατηγορία ζημιάς	eI_1	1
	eI_2	2
	eI_3	3
	eI_4	4
	eI_5	5
	eI_6	6
2η κατηγορία ζημιάς	pid_1	-
	pid_2	-
	pid_3	-
	pid_4	-
	pid_5	-
	pid_6	-

Εικόνα 3.1.3.1...: Δεύτερη κατηγορία ζημιών


Σε κάθε σχέδιο δημιουργήθηκαν δύο ξεχωριστά στοιχεία ράβδου CROD με διαφορετικά PROD (Properties) το πρώτο με PID=1, εμβαδόν επιφάνειας διατομής $A=3927 \text{ mm}^2$, μέτρο ελαστικότητας $E = 210 \text{ GPa}$ και πυκνότητα $\rho = 7800 \text{ kg/m}^3$, ενώ το δεύτερο με τιμές PID=2, εμβαδόν επιφάνειας διατομής $A=2500 \text{ mm}^2$, μέτρο ελαστικότητας $E = 210 \text{ GPa}$ και πυκνότητα $\rho = 7800 \text{ kg/m}^3$ αντίστοιχα. Για τα στοιχεία ράβδου με PROD1 χρησιμοποιήθηκε υλικό MAT1, ενώ για το PROD2 υλικό MAT2. Οι αρθρώσεις, η κρουστική διέγερση και οι αισθητήρες μέτρησης βρίσκονται στα ίδια σημεία και για το Header Nastran χρησιμοποιήθηκε ξανά ο solver SOL 112.

	Επιφάνεια Διατομής A	Μέτρο Ελαστικότητας E	Πυκνότητα ρ	Υλικό
PROD1	3927 mm^2	210 GPa	7800 kg/m^3	MAT1
PROD2	2500 mm^2	210 GPa	7800 kg/m^3	MAT2


Εικόνα 3.1.3.2.: Τιμές βασικών παραμέτρων

Αυτή η ασυμμετρία στην εφαρμογή των υλικών προκαλεί μία ποικιλία σεναρίων και επιδράσεων στη συμπεριφορά της κατασκευής όταν υποβληθεί σε κρουστική διέγερση. Η παρουσία ενός δεύτερου στοιχείου ράβδου με μικρότερη επιφάνεια διατομής μπορεί να έχει σημαντικές επιπτώσεις στην συνολική ακεραιότητα και


αντοχή της κατασκευής. Ακολουθούν εικόνες από τις 6 περιπτώσεις ζημιάς στο συμμετρικό μοντέλο του πύργου.




Εικόνα 3.1.3.3.: *Truss_pid_1_symmetric*




Εικόνα 3.1.3.4.: *Truss_pid_2_symmetric*



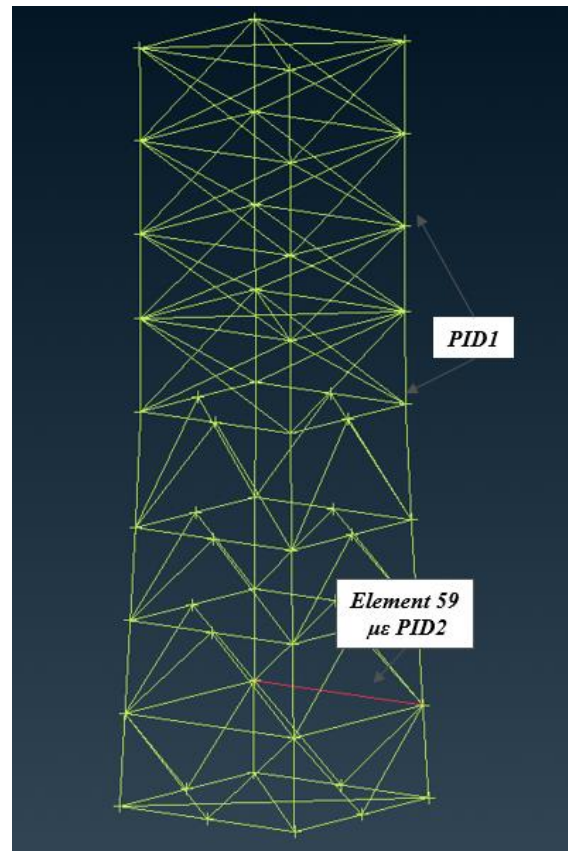
Εικόνα 3.1.3.5.: *Truss_pid_3_symmetric*



Εικόνα 3.1.3.6.: *Truss_pid_4_symmetric*



Εικόνα 3.1.3.7.: *Truss_pid_5_symmetric*



Εικόνα 3.1.3.8.: *Truss_pid_6_symmetric*

Ο modal solver SOL112 του Nastran λύνει το ιδιοπρόβλημα και κάνει υπέρθεση των ιδιομορφών, δίνοντας αποτελέσματα επιταχύνσεων και στα 6 αρχεία.

Με εξαγωγή των δεδομένων κάθε μοντέλου από το MSC Nastran παίρνω τα αντίστοιχα αρχεία `Truss_pid_1_symmetric.nas`, `Truss_pid_2_symmetric.nas`, `Truss_pid_3_symmetric.nas`, `Truss_pid_4_symmetric.nas`, `Truss_pid_5_symmetric.nas`, `Truss_pid_6_symmetric.nas`, που θα χρησιμοποιηθούν αργότερα στο MATLAB.


3.1.4. Χρήση MATLAB για εξαγωγή δεδομένων

Μετά τη λύση του ιδιοπροβλήματος από τον modal solver στο Nastran, τα αρχεία `Truss_symmetric.nas` επεξεργάζονται στο MATLAB για την εξαγωγή περισσότερων δεδομένων επιταχύνσεων και την οργάνωσή τους.

Στην εικόνα 3.3, ο αλγόριθμος που περιγράφεται για την δημιουργία επιταχύνσεων χρησιμοποιεί ένα επαναλαμβανόμενο σύστημα 2000 επαναλήψεων για κάθε κατάσταση υγείας του συμμετρικού μοντέλου με την ίδια δύναμη κρουστικής διέγερσης στον solver, που δημιουργεί περιπτώσεις φόρτισης με τυχαία κάθε φορά δειγματοληψία για τις τιμές των παραμέτρων· μέτρο ελαστικότητας E , πυκνότητα ρ και μέτρο απόσβεσης ζ . Η τιμή της κρουστικής διέγερσης F για το ιδιοπρόβλημα είναι ίδια σε κάθε επανάληψη. Για το μέτρο ελαστικότητας E λαμβάνεται μία τυχαία τιμή σε κάθε επανάληψη με απόκλιση $\pm 5\%$ της τιμής των 210 GPa και για την πυκνότητα ρ τυχαία τιμή με απόκλιση $\pm 5\%$ του 7800 kg/m^3 . Οι τυχαίες τιμές για το μέτρο απόσβεσης υπολογίζονται με μία απόκλιση του $\pm 10\%$ από την αρχική τιμή που λήφθηκε ίση με $\zeta=0.015$. Στην εικόνα που ακολουθεί παρουσιάζονται οι τιμές για το μέτρο απόσβεσης ζ που υπολογίστηκε σε μία τυχαία επανάληψη για 10 διαφορετικά σημεία με τιμές συχνοτήτων από 0 μέχρι 2000 Hz για την περίπτωση `Truss_el_1_symmetric`. Για το εύρος συχνοτήτων των ιδιομορφών της κατασκευής μεταξύ των τιμών 0-2000 Hz λαμβάνονται τιμές με γραμμική παρεμβολή αυτόματα από τον solver.


Συχνότητα (Hz)	Μέτρο απόσβεσης ζ
0	0.015
20	0.0155
40	0.0131
60	0.01275
80	0.00832
100	0.01314
120	0.02088
140	0.01416
160	0.01309
2000	0.01309

Εικόνα 3.1.4.1.: Τυχαίες τιμές απόσβεσης για μία τυχαία επανάληψη στο *Truss_el_1_symmetric*




Εικόνα 3.1.4.2.: Διάγραμμα γραμμικής παρεμβολής για ζ

Αφού τρέξουν οι 2000 επαναλήψεις το MATLAB πλοτάρει τις αποκρίσεις των 8 σημείων μέτρησης στον χρόνο για κάθε κατάσταση υγείας. Ενδεικτικά, οι αποκρίσεις του σημείου με τον αισθητήρα 1 για το μοντέλο *Truss_el_1_symmetric.nas* για τις 2000 επαναλήψεις και 1100 σημεία στο χρόνο φαίνονται στο παρακάτω σχήμα:



Εικόνα 3.1.4.2.: Διάγραμμα αποκρίσεων στον χρόνο για το *Truss_el_1_symmetric* από τον αισθητήρα 1



Εικόνα 3.1.4.3.: Διάγραμμα αποκρίσεων στον χρόνο για το *Truss_el_2_symmetric* από τον αισθητήρα 1

Τα δεδομένα για τις επιταχύνσεις που προκύπτουν σε κάθε επανάληψη για τα σημεία με τους αισθητήρες για κάθε κατάσταση υγείας και για τις 2000 επαναλήψεις με διαφορετικά δεδομένα στις βασικές παραμέτρους, οργανώνονται και αποθηκεύονται στον φάκελο results για την εκπαίδευση του νευρωνικού.

3.2 Ασύμμετρο μοντέλο πεπερασμένων στοιχείων

Στο επόμενο βήμα σχεδιάστηκε ένα ασύμμετρο μοντέλο πεπερασμένων στοιχείων του πύργου με την χρήση και πάλι του λογισμικού ANSA, το οποίο έχει σαν στόχο να περιγράψει την πραγματική κατασκευή με τις πιθανές αστοχίες που μπορεί να προκύψουν κατά την δημιουργία της. Όπως καθίσταται κατανοητό δεν ήταν δυνατή η κατασκευή της πραγματικής δικτυωτής κατασκευής του πύργου λόγω περιορισμένων πόρων, χρημάτων και χρόνου. Ωστόσο, είναι αναγκαίο να ληφθούν δεδομένα για το πειραματικό μοντέλο και να συγκριθούν με τα προηγούμενα δεδομένα του αριθμητικού μοντέλου.

Οι ασυμμετρίες του μοντέλου έχουν να κάνουν με την χρήση διαφορετικών υλικών κατά μήκος της κατασκευής, σε μια προσπάθεια να περιγράψουν τις πιθανές ατέλειες και αστοχίες που θα μπορούσαν να προκύψουν κατά την κατασκευή και να επηρεάσουν την συμπεριφορά της. Το ασύμμετρο μοντέλο περιλαμβάνει αντίστοιχα μία κατάσταση υγείας, 6 περιπτώσεις μεγάλης ζημιάς λόγω διαγραφής ενός στοιχείου και 6 περιπτώσεις μικρότερης ζημιάς με διαφορετικές διατομές στις ράβδους όπως και στο συμμετρικό. Έπειτα λύνεται το ιδιοπρόβλημα στο MSC Nastran.

3.2.1. Σχεδίαση της healthy κατάστασης του ασύμμετρου μοντέλου

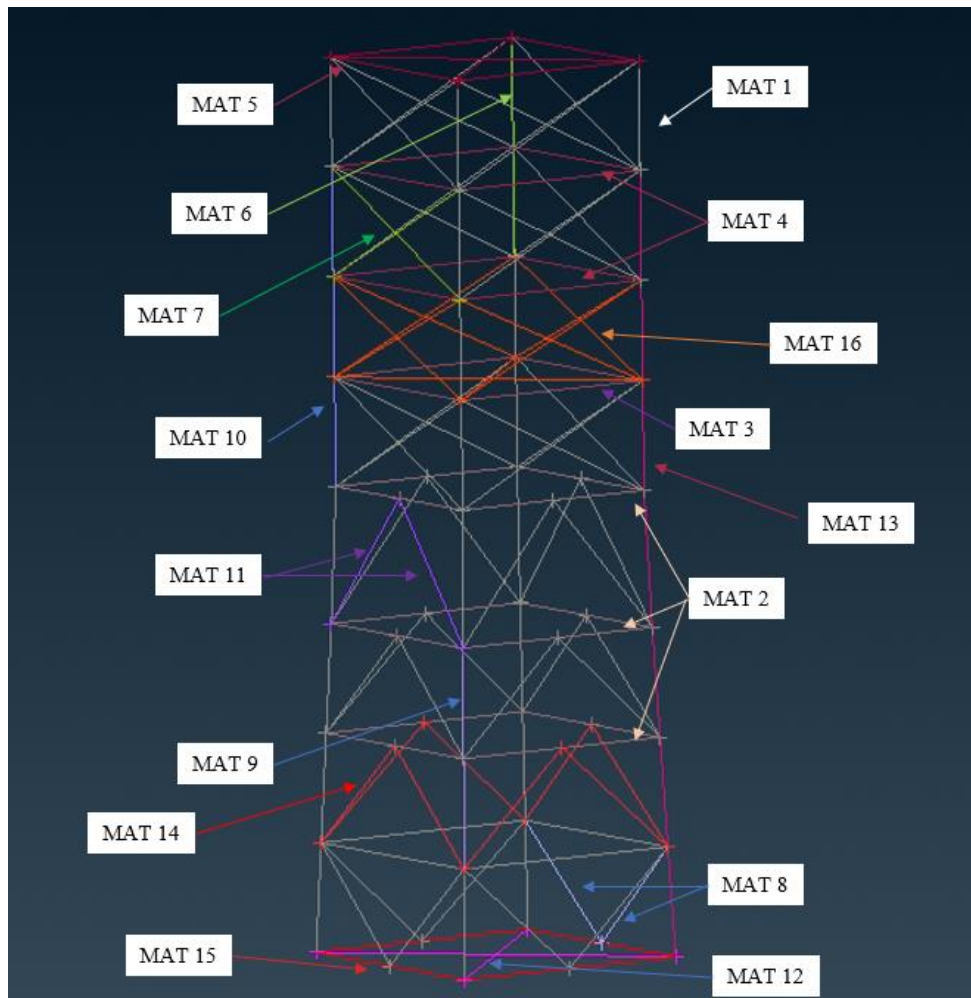
Για το ασύμμετρο μοντέλο σχεδιάστηκε εκ νέου η ίδια διάταξη της δικτυωτής κατασκευής που χρησιμοποιήθηκε και για το συμμετρικό αυτή τη φορά όμως εφαρμόστηκαν διαφορετικά υλικά (materials) σε κάποια σημεία της κατασκευής. Η χρήση των υλικών αυτών υποδηλώνει την παρουσία αστοχιών στην κατασκευή, όπως ισχύει σε πειραματικά μοντέλα. Στον πίνακα που ακολουθεί παρουσιάζονται τα υλικά με τις αντίστοιχες τιμές στις βασικές παραμέτρους. Να σημειωθεί ότι οι τιμές στις βασικές παραμέτρους (μέτρο ελαστικότητας E και πυκνότητα ρ) προκύπτουν τυχαία με την βοήθεια ενός κώδικα που θα χρησιμοποιηθεί μετέπειτα στο πρόγραμμα MATLAB και εισάγεται με την μορφή κειμένου .bdf στα αρχεία .nas μόνο για το ασύμμετρο μοντέλο, ώστε σε κάθε επανάληψη αργότερα να προκύπτουν διαφορετικές συνθήκες για την ίδια κατάσταση ζημιάς και άρα διαφορετικές τιμές αποκρίσεων. Στα σημεία με διαφορετικό υλικό τα στοιχεία ράβδου PROD αλλάζουν και αυτά. Οι αρθρώσεις, η κρουστική διέγερση και οι αισθητήρες μέτρησης βρίσκονται στα ίδια σημεία με το υγιές μοντέλο και για το Header Nastran χρησιμοποιήθηκε ο solver SOL 112 για την λύση του ιδιοπροβλήματος και της υπέρθεση ιδιομορφών.

Id	Name	DEFINED	E	RHO	__type__
1	Default MAT1	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MAT2	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MAT3	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MAT4	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MAT5	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MAT6	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MAT7	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MAT9	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MAT9	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MAT10	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MAT11	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MAT12	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MAT13	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MAT14	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MAT15	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MAT16	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1

Εικόνα 3.2.1.1.: Τιμές των παραμέτρων των υλικών στο ασύμμετρο μοντέλο για μία επανάληψη

Id	Name	T	MID1	MID	__type__
1	PROD			1	PROD
2	PROD			2	PROD
3	PROD			3	PROD
4	PROD			4	PROD
5	PROD			5	PROD
6	PROD			6	PROD
7	PROD			7	PROD
8	PROD			8	PROD
9	PROD			9	PROD
10	PROD			10	PROD
11	PROD			11	PROD
12	PROD			12	PROD
13	PROD			13	PROD
14	PROD			14	PROD
15	PROD			15	PROD
16	PROD			16	PROD

Εικόνα 3.2.1.2.: Στοιχεία ράβδου PROD με διαφορετικά PID




Εικόνα 3.2.1.3.: Ασύμμετρο μοντέλο στην healthy κατάσταση με διαφορετικά material

Αφού λυθεί το πρόβλημα δημιουργείται το αρχείο `Truss_healthy_asymmetric.nas`, που χρησιμοποιείται αργότερα στο MATLAB.

3.2.2. Σχεδίαση της πρώτης κατηγορίας ζημιών στο ασύμμετρο μοντέλο

Η διαδικασία επαναλαμβάνεται και για την πρώτη κατηγορία ζημιών, όπως στο συμμετρικό μοντέλο. Τα elements που διαγράφονται σε κάθε μία από τις 6 περιπτώσεις μεγάλης ζημιάς στο ασύμμετρο είναι τα ίδια με τις περιπτώσεις του συμμετρικού, προκειμένου να μπορεί να γίνει αργότερα η σύγκριση τους (αριθμητικό και πειραματικό). Οι τιμές στις παραμέτρους των διαφορετικών υλικών, και εδώ, επιλέγονται με τυχαίο τρόπο σε κάθε επανάληψη με το ίδιο ακριβώς αρχείο `.bdf` να συγκαταλέγεται στα αρχεία `.nas` που θα προκύψουν για τις καταστάσεις βλάβης. Το εμβαδόν επιφάνειας διατομής είναι $A=3927 \text{ mm}^2$ και το πάχος της διατομής ίσο με $t=2\text{mm}$. Οι αρθρώσεις, η κρουστική διέγερση και οι αισθητήρες μέτρησης βρίσκονται στα ίδια σημεία με το υγιές μοντέλο και για το Header Nastran χρησιμοποιήθηκε ο solver SOL 112. Οι επόμενες εικόνες δείχνουν τις 6 περιπτώσεις

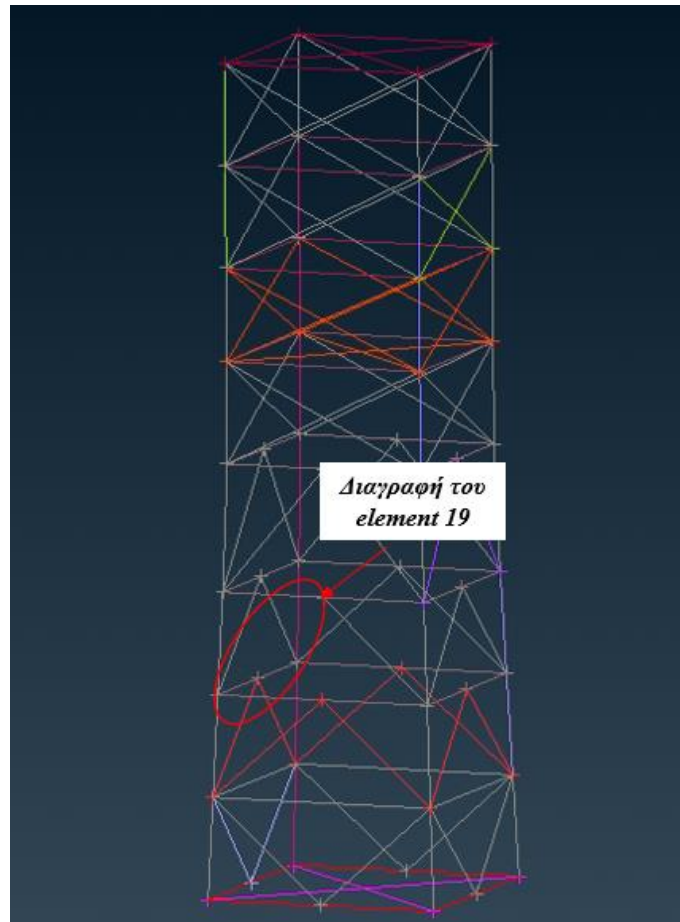
ζημιάς στα διαφορετικά element του πύργου και τις τυχαίες τιμές των παραμέτρων για κάθε load case.



Εικόνα 3.2.2.1.: Truss_el_1_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MAT1	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MAT2	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MAT3	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MAT4	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MAT5	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MAT6	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MAT7	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MAT8	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MAT9	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MAT10	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MAT11	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MAT12	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MAT13	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MAT14	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MAT15	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MAT16	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1


Εικόνα 3.2.2.2.: Τιμές των παραμέτρων των υλικών για το load case el_1



Εικόνα 3.2.2.3.: *Truss_el_2_asymmetric*

	Id	Name	DEFINED	E	RHO	__type__
■	1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
■	2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
■	3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
■	4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
■	5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
■	6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
■	7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
■	8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
■	9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
■	10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
■	11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
■	12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
■	13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
■	14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
■	15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
■	16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1


Εικόνα 3.2.2.4.: Τιμές των παραμέτρων των υλικών για το load case el_2



Εικόνα 3.2.2.5.: *Truss_el_3_asymmetric*

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1


Εικόνα 3.2.2.6.: Τιμές των παραμέτρων των υλικών για το load case *el_3*



Εικόνα 3.2.2.7.: *Truss_el_4_asymmetric*

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1


Εικόνα 3.2.2.8.: Τιμές των παραμέτρων των υλικών για το load case el_4



Εικόνα 3.2.2.9.: *Truss_el_5_asymmetric*

	Id	Name	DEFINED	E	RHO	__type__
■	1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
■	2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
■	3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
■	4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
■	5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
■	6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
■	7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
■	8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
■	9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
■	10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
■	11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
■	12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
■	13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
■	14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
■	15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
■	16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1

Εικόνα 3.2.2.10.: Τιμές των παραμέτρων των υλικών για το load case *el_5*



Εικόνα 3.2.2.11.: Truss_el_6_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1

Εικόνα 3.2.2.12.: Τιμές των παραμέτρων των υλικών για το load case el_6

Μετά την λύση του ιδιοπροβλήματος στο Nastran παίρνω τα αντίστοιχα αρχεία
Truss_el_1_asymmetric.nas, Truss_el_2_asymmetric.nas,
Truss_el_3_asymmetric.nas, Truss_el_4_asymmetric.nas,
Truss_el_5_asymmetric.nas, Truss_el_6_asymmetric.nas.

3.2.3. Σχεδίαση της δεύτερης κατηγορίας ζημιών στο ασύμμετρο μοντέλο

Όπως έχει ήδη αναφερθεί, στο ασύμμετρο μοντέλο έχουν εφαρμοστεί 16 διαφορετικά υλικά σε τυχαία σημεία του πύργου για την αναπαράσταση αστοχιών της πραγματικής κατασκευής. Οι τιμές για τις βασικές παραμέτρους των υλικών επιλέγονται τυχαία σε κάθε επανάληψη της ανάλυσης. Για την δεύτερη κατηγορία ζημιών υιοθετείται η ίδια λογική όπως στο αριθμητικό μοντέλο. Εφαρμόζεται σε ένα element ένα διαφορετικό στοιχείο ράβδου CROD με διαφορετικό PROD από την υπόλοιπη κατασκευή. Η διαδικασία επαναλαμβάνεται 6 φορές. Στο ασύμμετρο μοντέλο, λόγω των πρόσθετων υλικών, έχουν ήδη χρησιμοποιηθεί διαφορετικά στοιχεία ράβδου PROD συνολικά 16 σε αριθμό που αντιστοιχούν στα 16 υλικά (MAT1 μέχρι MAT16). Το 17^ο PROD εφαρμόζεται σε ένα από τα έξι elements στα οποία γίνεται η ανάλυση της μικρότερης ζημιάς και οι τιμές για το υλικό MAT17 δεν είναι τυχαίες αλλά λαμβάνονται ίσες με $E = 210 \text{ GPa}$, $\rho = 7800 \text{ kg/m}^3$ και $A=2500\text{mm}^2$. Οι αρθρώσεις, η κρουστική διέγερση και οι αισθητήρες μέτρησης βρίσκονται στα ίδια σημεία και για το Header Nastran χρησιμοποιήθηκε ο solver SOL 112. Η διαδικασία είναι ίδια με αυτή για την δεύτερη κατηγορία ζημιών στο συμμετρικό μοντέλο.

Οι τιμές για το εμβαδόν διατομής της επιφάνειας κάθε ράβδου καθώς και τα διαφορετικά υλικά στην κατασκευή παρουσιάζονται παρακάτω.

Id	Name	MID	A
1	PROD	1	3926.991
2	PROD	2	3900.
3	PROD	3	3900.
4	PROD	4	3900.
5	PROD	5	3900.
6	PROD	6	3900.
7	PROD	7	3900.
8	PROD	8	3900.
9	PROD	9	3900.
10	PROD	10	3900.
11	PROD	11	3900.
12	PROD	12	3900.
13	PROD	13	3900.
14	PROD	14	3900.
15	PROD	15	3900.
16	PROD	16	3900.
17	PROD	17	2500.

Εικόνα 3.2.3.1.: Στοιχεία ράβδου PROD με διαφορετικά PID και διατομές


Id	Name	DEFINED	E	RHO	__type
1	Default MAT1	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MAT2	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MAT3	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MAT4	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MAT5	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MAT6	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MAT7	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MAT8	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MAT9	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MAT10	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MAT11	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MAT12	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MAT13	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MAT14	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MAT15	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MAT16	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MAT17 Material	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1

Εικόνα 3.2.3.2.: Τιμές των παραμέτρων των υλικών για ένα τυχαίο load case

Θα πρέπει να παρατηρήσουμε ότι για τον βασικό κορμό της κατασκευής το στοιχείο ράβδου PROD 1 που χρησιμοποιήθηκε έχει τιμή περίπου 3927 mm^2 και τα στοιχεία ράβδου PROD από 2 μέχρι 16, που περιγράφουν τις πιθανές αστοχίες της κατασκευής, έχουν τιμή πολύ κοντά σε αυτό μόλις 3900 mm^2 . Ωστόσο, για την προσομοίωση της ζημιάς το στοιχείο ράβδου PROD 17 έχει τιμή αρκετά μικρότερη

από τις υπόλοιπες με $A=2500 \text{ mm}^2$. Αυτό έγινε σκοπίμως ώστε να γίνει εμφανή η περίπτωση ζημιάς στα αποτελέσματα που θα προκύψουν.


Ακολουθούν οι 6 περιπτώσεις μικρότερης ζημιάς και οι αντίστοιχες τυχαίες παράμετροι (E, ρ) για κάθε load case για το ασύμμετρο μοντέλο. Οι τιμές για τις επιφάνειες διατομής κάθε στοιχείου ράβδου είναι οι ίδιες για όλα τα load case, όπως φαίνεται στην εικόνα 3.2.3.1.



Εικόνα 3.2.3.3.: Truss_pid_1_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MAT1	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MAT2	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MAT3	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MAT4	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MAT5	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MAT6	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MAT7	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MAT8	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MAT9	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MAT10	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MAT11	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MAT12	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MAT13	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MAT14	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MAT15	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MAT16	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MAT17 Material	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1

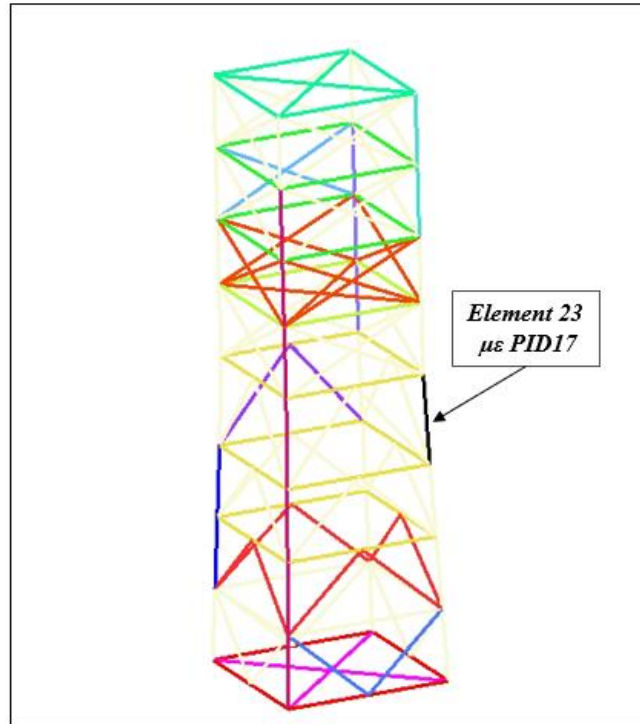
Εικόνα 3.2.3.4.: Τιμές των παραμέτρων των υλικών για το load case pid_1



Εικόνα 3.2.3.5.: Truss_pid_2_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MAT1	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MAT2	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MAT3	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MAT4	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MAT5	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MAT6	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MAT7	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MAT8	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MAT9	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MAT10	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MAT11	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MAT12	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MAT13	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MAT14	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MAT15	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MAT16	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MAT17 Material	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1


Εικόνα 3.2.3.6.: Τιμές των παραμέτρων των υλικών για το load case pid_2



Εικόνα 3.2.3.7.: Truss_pid_3_asymmetric

	Id	Name	DEFINED	E	RHO	__type__
■	1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
■	2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
■	3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
■	4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
■	5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
■	6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
■	7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
■	8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
■	9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
■	10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
■	11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
■	12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
■	13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
■	14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
■	15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
■	16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
■	17	Default MA...	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1


Εικόνα 3.2.3.8.: Τιμές των παραμέτρων των υλικών για το load case pid_3



Εικόνα 3.2.3.9.: Truss_pid_4_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MA...	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1


Εικόνα 3.2.3.10.: Τιμές των παραμέτρων των υλικών για το load case pid_4



Εικόνα 3.2.3.11.: *Truss_pid_5_asymmetric*

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MA...	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1

Εικόνα 3.2.3.12.: *Τιμές των παραμέτρων των υλικών για το load case pid_5*



Εικόνα 3.2.3.13.: Truss_pid_6_asymmetric

Id	Name	DEFINED	E	RHO	__type__
1	Default MA...	<input checked="" type="checkbox"/>	218233.7	7.446E-9	MAT1
2	Default MA...	<input checked="" type="checkbox"/>	239453.9	8.0381E-9	MAT1
3	Default MA...	<input checked="" type="checkbox"/>	237589.9	7.826E-9	MAT1
4	Default MA...	<input checked="" type="checkbox"/>	237683.1	8.091E-9	MAT1
5	Default MA...	<input checked="" type="checkbox"/>	237868.9	7.6014E-9	MAT1
6	Default MA...	<input checked="" type="checkbox"/>	234107.8	8.1526E-9	MAT1
7	Default MA...	<input checked="" type="checkbox"/>	236203.5	7.6842E-9	MAT1
8	Default MA...	<input checked="" type="checkbox"/>	227336.2	8.1588E-9	MAT1
9	Default MA...	<input checked="" type="checkbox"/>	241154.5	7.6544E-9	MAT1
10	Default MA...	<input checked="" type="checkbox"/>	223341.7	7.8245E-9	MAT1
11	Default MA...	<input checked="" type="checkbox"/>	219881.	7.5596E-9	MAT1
12	Default MA...	<input checked="" type="checkbox"/>	219583.6	7.5935E-9	MAT1
13	Default MA...	<input checked="" type="checkbox"/>	231600.	7.7244E-9	MAT1
14	Default MA...	<input checked="" type="checkbox"/>	223775.4	8.0088E-9	MAT1
15	Default MA...	<input checked="" type="checkbox"/>	231100.6	7.9338E-9	MAT1
16	Default MA...	<input checked="" type="checkbox"/>	234448.7	7.8564E-9	MAT1
17	Default MA...	<input checked="" type="checkbox"/>	210000.	7.85E-9	MAT1

Εικόνα 3.2.3.14.: Τιμές των παραμέτρων των υλικών για το load case pid_6

Μετά την λύση του ιδιοπροβλήματος στο MSC Nastran και την υπέρθεση των ιδιομορφών παίρνω τα αντίστοιχα αρχεία Truss_pid_1_asymmetric.nas, Truss_pid_2_asymmetric.nas, Truss_pid_3_asymmetric.nas,

Truss_pid_4_asymmetric.nas,
Truss_pid_6_asymmetric.nas.

Truss_pid_5_asymmetric.nas,

3.2.3.1. Χρήση MATLAB για εξαγωγή δεδομένων

Μετά την δημιουργία των αρχείων Truss_asymmetric.nas και την επίλυση του ιδιοπροβλήματος ακολουθεί η επεξεργασία στο MATLAB. Εκεί, πραγματοποιούνται 2000 επαναλήψεις, όπου για κάθε κατάσταση υγείας λύνεται το ιδιοπρόβλημα με τυχαίες και διαφορετικές τιμές στις βασικές μεταβλητές (E, ρ, ζ) όπως στην ενότητα 3.1.4. και λαμβάνονται οι αντίστοιχες επιταχύνσεις στα 8 σημεία μέτρησης. Οι τιμές των επιταχύνσεων οργανώνονται και αποθηκεύονται στο αρχείο results. Να σημειωθεί ότι η τυχειότητα στις τιμές των μεταβλητών σε κάθε επανάληψη ισχύει και για τις τιμές των παραμέτρων του ασύμμετρου μοντέλου στα σημεία με διαφορετικό στοιχείο ράβδου PROD και το αντίστοιχο υλικό MAT. Το MAT17 του στοιχείου ράβδου PROD17 που περιγράφει την περίπτωση ζημιάς λαμβάνει σταθερή τιμή για E και ρ σε όλες τις επαναλήψεις.


MAT1	Epsilon	2.02E+05	Density	7.9985
MAT2	Epsilon2	2.39E+05	Density2	8.0721
MAT3	Epsilon3	2.37E+05	Density3	7.8428
MAT4	Epsilon4	2.34E+05	Density4	7.5611
MAT5	Epsilon5	2.19E+05	Density5	8.1064
MAT6	Epsilon6	2.39E+05	Density6	7.9320
MAT7	Epsilon7	2.34E+05	Density7	7.8441
MAT8	Epsilon8	2.25E+05	Density8	7.9216
MAT9	Epsilon9	2.27E+05	Density9	7.9766
MAT10	Epsilon10	2.22E+05	Density10	7.5581
MAT11	Epsilon11	2.29E+05	Density11	8.0838
MAT12	Epsilon12	2.26E+05	Density12	7.8198
MAT13	Epsilon13	2.31E+05	Density13	7.7301
MAT14	Epsilon14	2.31E+05	Density14	7.4575
MAT15	Epsilon15	2.21E+05	Density15	7.4922
MAT16	Epsilon16	2.26E+05	Density16	7.7922
MAT17	Epsilon	2.10E+05	Density	7.90

Εικόνα 3.2.3.1.1.: Τυχαίες τιμές E, ρ για τα MAT σε μία επανάληψη στο Truss_pid_6_asymmetric

Συχνότητα (Hz)	Μέτρο απόσβεσης ζ
0	0.0166
20	0.0166
40	0.0204
60	0.009
80	0.0136
100	0.0162
120	0.0195
140	0.0148
160	0.0179
2000	0.0179

Εικόνα 3.2.3.1.2.: Τυχαίες τιμές απόσβεσης για μία τυχαία επανάληψη στο *Truss_pid_6_asymmetric*

Η διαδικασία συνεχίζεται όπως περιεγράφηκε στην ενότητα 3.1.4. Τα αποτελέσματα των επιταχύνσεων από τις 2000 οργανώνονται στον φάκελο results. Οι αποκρίσεις του σημείου με τον αισθητήρα 2 για το μοντέλο *Truss_el_3_symmetric.nas* για τις 2000 επαναλήψεις και 1100 σημεία στο χρόνο φαίνονται στο παρακάτω σχήμα:



Εικόνα 3.2.3.1.4.: Διάγραμμα αποκρίσεων στον χρόνο για το *Truss_el_3_symmetric* από τον αισθητήρα 2

3.3. Εκπαίδευση νευρωνικού δικτύου

Αφού εξήχθησαν τα αποτελέσματα των επιταχύνσεων από την λύση του ιδιοπροβλήματος για κάθε κατάσταση υγείας του συμμετρικού μοντέλου από 2000 επαναλήψεις (load cases) που έτρεξαν στο MATLAB και οργανώθηκε το σετ εποπτευόμενης μάθησης, σειρά είχε η εκπαίδευση του νευρωνικού. Όπως αναφέρθηκε και στην ενότητα 3. Πείραμα δημιουργούνται τρία διαφορετικά σετ δεδομένων (επιταχύνσεων-καταστάσεων υγείας) για εκπαίδευση του νευρωνικού, που αναφέρονται σε δύο μόνο καταστάσεις υγείας για απλοποίηση της διαδικασίας. Τα σετ δεδομένων για κάθε πρόβλημα αναγνώρισης ζημιάς στην κατασκευή φαίνονται παρακάτω:

Για την πρώτη κατηγορία ζημιών το νευρωνικό εκπαιδεύεται με τα σετ δεδομένων:

$$\mathbf{Train_set}^{el_1-el_3} = \{ (A_{1,1}^{el_1}, Y_{1,1}), (A_{1,2}^{el_3}, Y_{1,2}), \dots, (A_{2000,2}^{el_3}, Y_{1000,2}) \}$$

$$\mathbf{Train_set}^{el_1-el_6} = \{ (A_{1,1}^{el_1}, Y_{1,1}), (A_{1,2}^{el_6}, Y_{1,2}), \dots, (A_{2000,2}^{el_6}, Y_{1000,2}) \}$$

$$\mathbf{Train_set}^{el_4-el_5} = \{ (A_{1,1}^{el_4}, Y_{1,1}), (A_{1,2}^{el_5}, Y_{1,2}), \dots, (A_{2000,2}^{el_5}, Y_{1000,2}) \}$$

Για την δεύτερη κατηγορία ζημιών αντίστοιχα:

$$\mathbf{Train_set}^{pid_1-pid_3} = \{ (A_{1,1}^{pid_1}, Y_{1,1}), (A_{1,2}^{pid_3}, Y_{1,2}), \dots, (A_{2000,2}^{pid_3}, Y_{1000,2}) \}$$

$$\mathbf{Train_set}^{pid_1-pid_6} = \{ (A_{1,1}^{pid_1}, Y_{1,1}), (A_{1,2}^{pid_6}, Y_{1,2}), \dots, (A_{2000,2}^{pid_6}, Y_{1000,2}) \}$$

$$\mathbf{Train_set}^{pid_4-pid_5} = \{ (A_{1,1}^{pid_4}, Y_{1,1}), (A_{1,2}^{pid_5}, Y_{1,2}), \dots, (A_{2000,2}^{pid_5}, Y_{1000,2}) \}$$

Το συνελκτικό νευρωνικό δίκτυο που χρησιμοποιείται εκπαιδεύεται ώστε να αναγνωρίζει την κατάσταση υγείας στην οποία αναφέρεται κάθε τιμή επιτάχυνσης από το αντίστοιχο σετ δεδομένων με δύο διαφορετικές περιπτώσεις ζημιάς. Για τον σχεδιασμό της αρχιτεκτονικής του νευρωνικού δημιουργήθηκαν 9 διαφορετικά layers από τρεις κατηγορίες: convolutional, pooling και perceptron layer με τρεις νευρώνες το καθένα και αρχική τιμή για το φίλτρο kernel w_k ίση με 30 (αναλυτικότερα στην ενότητα 2.5.3.). Η παρακάτω εικόνα περιγράφει την δομή του δικτύου:

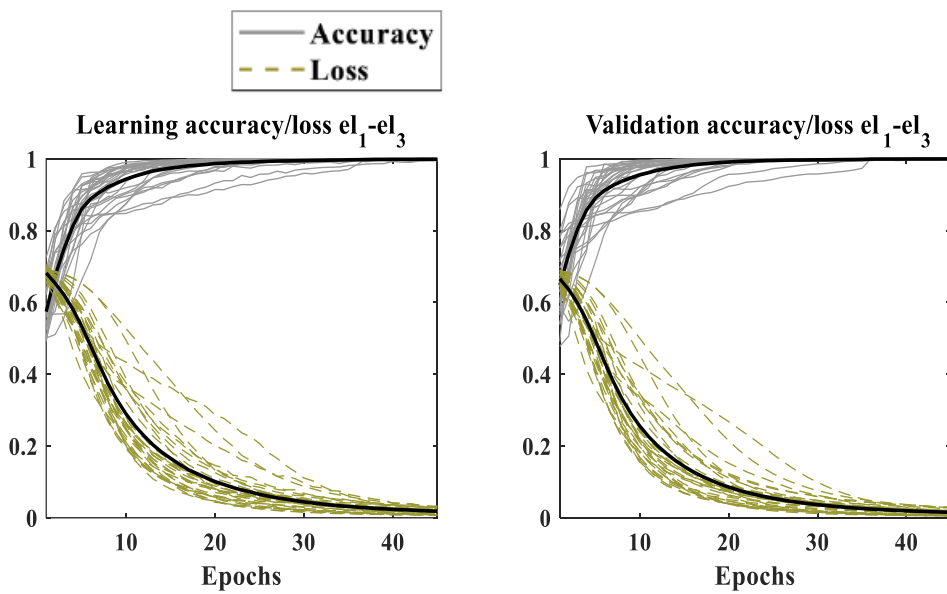
Layer type	Filter length (time steps)	Neurons	Magnitude/Activation	Other
Convolutional	30	3	tanh	Trainable parameters817
Pooling	-	-	3	
Convolutional	30	3	tanh	Batch size50
Pooling	-	-	3	
Convolutional	30	1	tanh	Batch size50
Pooling	-	-	3	
Perceptron	-	5	tanh	
Perceptron	-	5	tanh	
Classification	-	1	Sigmoid/Softmax	
Loss function	Categorical Cross-entropy	-		

Εικόνα 3.3.1.: Αρχιτεκτονική συνελκτικού νευρωνικού δικτύου

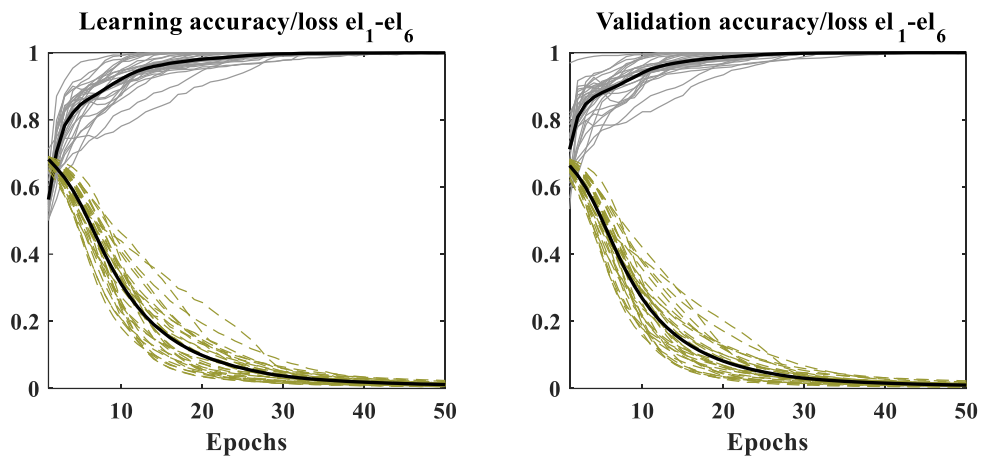
Για την ολοκληρωμένη εκπαίδευση του νευρωνικού δικτύου έγιναν 45 επαναλήψεις εκπαίδευσης (epochs) με διαφορετικά δεδομένα (inputs) σε κάθε epoch για κάθε ένα από τα έξι σετ δεδομένων. Στόχος των επαναλήψεων είναι να βρεθούν οι καλύτερες τιμές για τα φίλτρα ώστε να πετύχουμε την μέγιστη ακρίβεια με την διαδικασία της Back and Forward Propagation (ενότητα 2.5.4.). Από τις 30 εκπαιδύσεις του νευρωνικού δικτύου, με τυχαία αρχική τιμή για το φίλτρο w_k σε κάθε εκπαίδευση, λαμβάνεται η μέση πρόβλεψη για την τιμή του φίλτρο ώστε στο τέλος να έχω μέγιστη ακρίβεια. Στο τέλος μίας καλής εκπαίδευσης θα πρέπει η καμπύλη της ακρίβειας (accuracy) να αυξάνεται και η καμπύλη της απόκλισης (loss) να μειώνεται.

Όπως έχει ήδη αναφερθεί για κάθε σετ καταστάσεων έτρεξαν 2000 επαναλήψεις για την κάθε περίπτωση στο MATLAB. Συνολικά για τις δύο περιπτώσεις σε κάθε σετ αντίστοιχα έτρεξαν 4000 επαναλήψεις, λήφθηκαν δηλαδή 4000 διαφορετικές αποκρίσεις από διαφορετικά μοντέλα FE με τυχαίες διακυμάνσεις στις ιδιότητες. Οι 45 επαναλήψεις (epochs) στο δίκτυο για την εύρεση των καλύτερων τιμών στα φίλτρα w_k γίνονται με το 70% των δεδομένων από τις συνολικές επαναλήψεις που πραγματοποιήθηκαν (δηλαδή τις 2800 από τις 4000) και αυτό αποτελεί το κομμάτι του *learning accuracy* στο δίκτυο. Με τις ίδιες τιμές στα φίλτρα w_k που προέκυψαν κάνω έλεγχο στο υπόλοιπο 30% των δεδομένων για να δω εάν βγάξω τις ίδιες τιμές

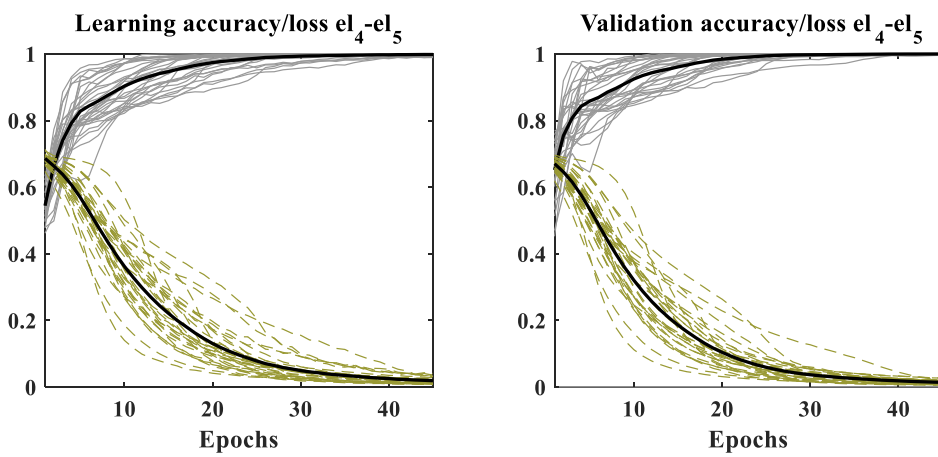
ακρίβειας, το κομμάτι του **validation accuracy**. Μία καλή εκπαίδευση νευρωνικού εκτιμάται στο κατά πόσο όμοια και κοντά στη μονάδα είναι τα αποτελέσματα που προκύπτουν μεταξύ του learning accuracy και του validation accuracy. Πραγματοποιήθηκαν 30 εκπαιδεύσεις νευρωνικών δικτύων με τυχαίες κάθε φορά αρχικές τιμές για το φίλτρο w_k . Από αυτές προέκυψε η μέση απόκριση με την μορφή καμπύλης ακρίβειας και απόκλισης. Τα επόμενα διαγράμματα δείχνουν τις καμπύλες ακρίβειας-απόκλισης σε 45 επαναλήψεις (epochs) για κάθε εκπαίδευση για όλα τα σετ δεδομένων.




Εικόνα 3.3.2.: Καμπύλες εκπαίδευσης για το πρώτο σετ el_1 , el_3




Εικόνα 3.3.3.: Καμπύλες εκπαίδευσης για το δεύτερο σετ el_1 , el_6




Εικόνα 3.3.4.: Καμπύλες εκπαίδευσης για το τρίτο σετ el_4 , el_5



Εικόνα 3.3.5.: Καμπύλες εκπαίδευσης για το τέταρτο σετ pid_1 , pid_3



Εικόνα 3.3.6.: Καμπύλες εκπαίδευσης για το πέμπτο σετ pid_1 , pid_6



Εικόνα 3.3.7.: Καμπύλες εκπαίδευσης για το έκτο σετ pid_4 , pid_5

3.4. Testing set στο ασύμμετρο μοντέλο

Μετά την εκπαίδευση του νευρωνικού δικτύου, για την ακρίβεια 30 νευρωνικά δίκτυα εκπαιδεύτηκαν κατ' επανάληψη, σειρά έχει ο έλεγχος για την αξιοπιστία του στην αναγνώριση καταστάσεων υγείας. Ο έλεγχος πραγματοποιείται με την εισαγωγή 1000 δεδομένων (inputs) του ασύμμετρου μοντέλου για κάθε περίπτωση ζημιάς σε όλα τα σετ. Δηλαδή προκύπτουν 2000 inputs σε κάθε σετ αφού το καθένα αποτελείται από δύο καταστάσεις υγείας (el_1 και el_3 , el_1 και el_6 , el_4 και el_5 , pid_1 και pid_3 , pid_1 και pid_6 , pid_4 και pid_5). Οι καταστάσεις υγείας 1 και 2 θα ονομάζονται από εδώ και στο εξής $class1$ και $class2$ αντίστοιχα για κάθε σετ. Τα αποτελέσματα των προβλέψεων που κάνει το νευρωνικό δίκτυο για κάθε σετ οργανώνονται σε δύο ξεχωριστούς φακέλους για το $class1$ και $class2$ και εξάγονται με την μορφή διαγράμματος. Μαζί με τα διαγράμματα προκύπτει και το μέσο σφάλμα (error) από τις προβλέψεις και παρουσιάζονται στην επόμενη ενότητα.

4. Αποτελέσματα


Στα αποτελέσματα παρουσιάζονται τα ιστογράμματα, που δείχνουν τις προβλέψεις που κάνει το εκπαιδευμένο νευρωνικό δίκτυο για το $class$ στο οποίο ταξινομεί τα δεδομένα (inputs) που εισάγονται από το κάθε σετ καταστάσεων υγείας. Τα classes είναι δύο, $class1$ και $class2$ και αναφέρονται στις καταστάσεις υγείας 1 και 2 από το κάθε σετ αντίστοιχα. Ανάλογα με το $class$ στο οποίο αναφέρεται το ιστόγραμμα, θα

θέλαμε οι προβλέψεις να είναι όσο το δυνατόν περισσότερες για αυτό, δηλαδή το χρώμα που χαρακτηρίζει το εκάστοτε class να υπερισχύει.

➤ 1ο σετ καταστάσεων ζημιάς [el_1, el_3]



Στο πρώτο σετ το class1 αναφέρεται στη κατάσταση ζημιάς el_1 και περιγράφεται με το πράσινο χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς el_3 και περιγράφεται με το κίτρινο χρώμα. Ακολουθούν τα ιστογράμματα των προβλέψεων από το νευρωνικό για κάθε class.

- Ιστόγραμμα για προβλέψεις για του class1



Παρατηρούμε, δηλαδή για παράδειγμα, ότι για το 162ο input από τα 1000 που αναφέρονται σε class1 και εισάγεται στο νευρωνικό για το σετ [el_1, el_3], αυτό έκανε πρόβλεψη ότι κατά 70% είναι class1, ενώ κατά 30% είναι class2.

- Ιστόγραμμα για προβλέψεις για του class2





Για το 194ο input, για παράδειγμα, από τα 1000 που αναφέρονται σε class2 το νευρωνικό έκανε πρόβλεψη ότι κατά 98% είναι class2, ενώ κατά 2% είναι class1. Τα ποσοστά αυτά δείχνουν ότι η πρόβλεψη ήταν αρκετά σωστή και το σφάλμα για τις προβλέψεις εκτιμάται να είναι αρκετά μικρό για το class2 συνολικά. Πράγματι, όπως μπορούμε να δούμε από τα αποτελέσματα που προκύπτουν και για το μέσο σφάλμα σε κάθε class αυτό θα είναι:

	Μέσο σφάλμα πρόβλεψης %
class1	23%
class2	16%

➤ 2ο σετ καταστάσεων ζημιάς [el_1, el_6]


Στο δεύτερο σετ το class1 αναφέρεται στη κατάσταση ζημιάς el_1 και περιγράφεται με μπλε χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς el_6 και περιγράφεται με πράσινο χρώμα. Ακολουθούν τα ιστογράμματα για κάθε class.

- Ιστόγραμμα για προβλέψεις για το class1



Παρατηρούμε π.χ. ότι για το 260ο input από τα 1000 που αναφέρονται σε class1 και εισάγεται στο νευρωνικό για το σετ [el_1, el_6], αυτό έκανε πρόβλεψη ότι κατά 80% είναι class1, ενώ κατά 20% είναι class2.

- Ιστόγραμμα για προβλέψεις για του class2





Εδώ, για το 145ο input από τα 1000 που αναφέρονται σε class2 το νευρωνικό έκανε πρόβλεψη ότι κατά 98% είναι class2, ενώ κατά 2% είναι class1. Τα ποσοστά αυτά μας δείχνουν ξανά ότι η πρόβλεψη ήταν αρκετά σωστή και το μέσο σφάλμα εκτιμάται να είναι αρκετά μικρό ιδιαίτερα για το class2.

	Μέσο σφάλμα πρόβλεψης %
class1	23%
class2	9%

➤ 3ο σετ καταστάσεων ζημιάς [el 4, el 5]



Στο τρίτο σετ το class1 αναφέρεται στη κατάσταση ζημιάς el_4 και περιγράφεται με μπλε χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς el_5 και περιγράφεται με κόκκινο χρώμα. Ακολουθούν τα ιστογράμματα για κάθε class.

- Ιστόγραμμα για προβλέψεις για το class1



Προβλέψεις του νευρωνικού για την κλάση του 194ο μέχρι το 202ο input.

- Ιστόγραμμα για προβλέψεις για το class2



Το αντίστοιχο μέσο σφάλμα για τις προβλέψεις του 3^{ου} σετ ανάλογα με το class είναι:



	Μέσο σφάλμα πρόβλεψης %
class1	30%
class2	26%

Ακολουθούν τα αποτελέσματα για τα σετ από την δεύτερη κατηγορία ζημιών (μικρότερες ζημιές).

➤ 4ο σετ καταστάσεων ζημιάς [pid_1, pid_3]

Στο πρώτο σετ το class1 αναφέρεται στη κατάσταση ζημιάς pid_1 και περιγράφεται με μπλε χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς pid_3 και περιγράφεται με κίτρινο χρώμα. Ακολουθούν τα ιστογράμματα για κάθε class.


- Ιστόγραμμα για προβλέψεις για το class1



Παρατηρούμε π.χ. ότι για το 90ο input από τα 1000 που αναφέρονται σε class1 το οποίο εισήχθη στο νευρωνικό για το σετ [pid_1, pid_6], αυτό έκανε πρόβλεψη ότι κατά 53% είναι class1, ενώ κατά 47% είναι class2. Τα ποσοστά αυτά μας δείχνουν

ότι το νευρωνικό δεν μπορεί να ξεχωρίσει με ευκολία την κατάσταση ζημιάς και οι προβλέψεις του είναι σχεδόν στην τύχη.

- Ιστόγραμμα για προβλέψεις για του class2





Για το 144ο input από τα 1000 που αναφέρονται σε class2 η πρόβλεψη είναι ότι κατά 60% είναι class1, ενώ κατά 40% είναι class2. Τα ποσοστά αυτά μας δείχνουν ότι το νευρωνικό έκανε λάθος πρόβλεψη για το συγκεκριμένο input και παρατηρούμε μία δυσκολία να ταξινομήσει σωστά τις καταστάσεις ζημιάς. Περιμένουμε το μέσο σφάλμα για τις προβλέψεις να είναι αρκετά υψηλό. Όντως για κάθε class αυτό προκύπτει:

	Μέσο σφάλμα πρόβλεψης %
class1	44%
class2	53%



➤ 5ο σετ καταστάσεων ζημιάς [pid 1, pid 6]

Στο πρώτο σετ το class1 αναφέρεται στη κατάσταση ζημιάς pid_1 και περιγράφεται με κόκκινο χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς pid_6 και περιγράφεται με κίτρινο χρώμα. Ακολουθούν τα ιστογράμματα για κάθε class.

- Ιστόγραμμα για προβλέψεις για το class1



- Ιστόγραμμα για προβλέψεις για το class2





Το μέσο σφάλμα για τις προβλέψεις προβλέπεται να είναι μεγάλο ειδικά για το class2 όπως δείχνουν οι προβλέψεις στο ιστόγραμμα, και όντως:

	Μέσο σφάλμα πρόβλεψης %
class1	35%
class2	62%



➤ 60 σετ καταστάσεων ζημιάς [pid 4, pid 5]

Στο πρώτο σετ το class1 αναφέρεται στη κατάσταση ζημιάς pid_4 και περιγράφεται με μαύρο χρώμα, ενώ το class2 αναφέρεται στη κατάσταση ζημιάς pid_5 και περιγράφεται με ροζ χρώμα. Ακολουθούν τα ιστογράμματα για κάθε class.

- Ιστόγραμμα για προβλέψεις για του class1



- Ιστόγραμμα για προβλέψεις για του class2



Το μέσο σφάλμα για τις προβλέψεις προκύπτει:

	Μέσο σφάλμα πρόβλεψης %
class1	48%
class2	53%

5. Συμπεράσματα

Εάν ανατρέξουμε στην προηγούμενη ενότητα και συγκεκριμένα στα αποτελέσματα που προκύπτουν για το μέσο σφάλμα πρόβλεψης όσον αφορά τα class1 και class2 από κάθε σετ δεδομένων διαφορετικής κατηγορίας ζημιών, θα παρατηρήσουμε μεγάλη διαφορά στις τιμές. Πιο αναλυτικά, για τα σετ δεδομένων που αναφέρονται σε καταστάσεις μεγάλης ζημιάς από την πρώτη κατηγορία, δηλαδή όταν έλειπε κομμάτι από τις ράβδους στην κατασκευή, το μέσο σφάλμα πρόκυπτε μικρό της τάξης του 20-30%. Το νευρωνικό, δηλαδή, αναγνώριζε σωστά την κατηγορία στην οποία ανήκε η βλάβη από κάθε input με μικρή κάθε φορά απόκλιση. Απεναντίας, όταν καλούνταν να αναγνωρίζει την κατηγορία της ζημιάς από τα σετ δεδομένων που αναφέρονται σε μικρότερες βλάβες στην κατασκευή, δηλαδή διαφορετικές τιμές στις βασικές παραμέτρους μεταξύ δύο στοιχείων ράβδου, το μέσο σφάλμα της πρόβλεψης υπολογιζόταν αρκετά υψηλό μεταξύ 40-50%. Τέτοια τάξη μεγέθους στο μέσο σφάλμα προδίδει ότι το νευρωνικό σχεδόν μαντεύει το αποτέλεσμα, γεγονός που δείχνει αναξιοπιστία στα αποτελέσματα που προκύπτουν ως προς την κατηγορία ζημιάς. Το γενικό συμπέρασμα, λοιπόν, που προκύπτει είναι ότι η αξιοπιστία του μοντέλου που μελετήθηκε ως προς την αναγνώριση και κατηγοριοποίηση ζημιών σε μία δικτυωτή κατασκευή έγκειται στην τάξη μεγέθους της βλάβης και ότι μεγαλύτερες ζημιές μπορούν να ταξινομηθούν πιο σωστά από ένα εκπαιδευμένο νευρωνικό δίκτυο. Το σφάλμα του μοντέλου FE δηλαδή, αναμένεται να έχει μειωμένη επίδραση για μεγάλες ζημιές όταν χρησιμοποιούμε αριθμητικά δεδομένα εκπαίδευσης. Αυτό θα πρέπει να λαμβάνεται υπόψη από τον χρήστη. Το γεγονός αυτό ενισχύεται από τα αποτελέσματα της παρούσας εργασίας, τα οποία συμπληρώνουν τα διαθέσιμα αποτελέσματα από παλιότερες μελέτες που υπάρχουν διαθέσιμες [7,31] πάνω στο συγκεκριμένο θέμα.

6. Βιβλιογραφικές αναφορές

- [1]: Azhar, A. S., Kudus, S. A., Jamadin, A., Mustaffa, N. K., & Sugiura, K. (2024). Recent vibration-based structural health monitoring on steel bridges: Systematic literature review. In *Ain Shams Engineering Journal* (Vol. 15, Issue 3). Ain Shams University. <https://doi.org/10.1016/j.asej.2023.102501>
- [2]: Mendler, A., Döhler, M., & Ventura, C. E. (2021). A reliability-based approach to determine the minimum detectable damage for statistical damage detection. *Mechanical Systems and Signal Processing*, 154. <https://doi.org/10.1016/j.ymsp.2020.107561>
- [3]: Seventekidis, P., & Giagopoulos, D. (2021). A combined finite element and hierarchical Deep learning approach for structural health monitoring: Test on a pin-joint composite truss structure. *Mechanical Systems and Signal Processing*, 157. <https://doi.org/10.1016/j.ymsp.2021.107735>
- [4]: Fernandez-Navamuel, A., Zamora-Sánchez, D., Omella, Á. J., Pardo, D., Garcia-Sanchez, D., & Magalhães, F. (2022). Supervised Deep Learning with Finite Element simulations for damage identification in bridges. *Engineering Structures*, 257. <https://doi.org/10.1016/j.engstruct.2022.114016>
- [5]: Li, Z. D., He, W. Y., Ren, W. X., Li, Y. L., Li, Y. F., & Cheng, H. C. (2023). Damage detection of bridges subjected to moving load based on domain-adversarial neural network considering measurement and model error. *Engineering Structures*, 293. <https://doi.org/10.1016/j.engstruct.2023.116601>
- [6]: Li, D., & Zhang, J. (2023). Finite element model updating through derivative-free optimization algorithm. *Mechanical Systems and Signal Processing*, 185. <https://doi.org/10.1016/j.ymsp.2022.109726>
- [7]: Seventekidis, P., & Giagopoulos, D. (2023). Model error effects in supervised damage identification of structures with numerically trained classifiers. *Mechanical Systems and Signal Processing*, 184. <https://doi.org/10.1016/j.ymsp.2022.109741>
- [8]: Chen, H., Kurt, M., Lee, Y. S., McFarland, D. M., Bergman, L. A., & Vakakis, A. F. (2014). Experimental system identification of the dynamics of a vibro-impact beam with a view towards structural health monitoring and damage detection. *Mechanical Systems and Signal Processing*, 46(1), 91–113. <https://doi.org/10.1016/j.ymsp.2013.12.014>
- [9]: Figuli, L., Papán, D., Vavák, B., Dvorák, Z., Ottaviano, E., & Daponte, P. (2023). Long life structural health monitoring of selected bridges. *Transportation Research Procedia*, 74, 1524–1531. <https://doi.org/10.1016/j.trpro.2023.11.133>
- [10]: Giordano, P. F., Quqa, S., & Limongelli, M. P. (2023). The value of monitoring a structural health monitoring system. *Structural Safety*, 100. <https://doi.org/10.1016/j.strusafe.2022.102280>
- [11]: Mishra, M., Lourenço, P. B., & Ramana, G. v. (2022). Structural health monitoring of civil engineering structures by using the internet of things: A review. In *Journal of Building Engineering* (Vol. 48). Elsevier Ltd. <https://doi.org/10.1016/j.jobe.2021.103954>
- [12]: Liu, Z., Shao, T., Yin, L., & Liu, C. (2023). Local structural health monitoring system in aircraft based on fiber Bragg grating array. *Results in Optics*, 11. <https://doi.org/10.1016/j.rio.2023.100393>
- [13]: MSC Nastran 2021 - Reference Guide . (n.d.). Retrieved March 4, 2024, from https://help-be.hexagonmi.com/bundle/MS_C_Nastran_2021_Reference_Guide/raw/resource/enus/MS_C_Nastran_2021_Reference_Guide.pdf

- [14]: Giagopoulos, D., & Arailopoulos, A. (2017). Computational framework for model updating of large scale linear and nonlinear finite element models using state of the art evolution strategy. *Computers and Structures*, 192, 210–232. <https://doi.org/10.1016/j.compstruc.2017.07.004>
- [15]: Ereiz, S., Duvnjak, I., & Fernando Jiménez-Alonso, J. (2022). Review of finite element model updating methods for structural applications. In *Structures* (Vol. 41, pp. 684–723). Elsevier Ltd. <https://doi.org/10.1016/j.istruc.2022.05.041>
- [16]: Malekzehtab, H., & Golafshani, A. A. (2013). Damage detection in an offshore jacket platform using genetic algorithm based finite element model updating with noisy modal data. *Procedia Engineering*, 54, 480–490. <https://doi.org/10.1016/j.proeng.2013.03.044>
- [17]: Klaus-Jürgen Bathe. (2014). *Finite Element Procedures* (Klaus-Jürgen Bathe, Ed.; Second, Vol. 1043). Klaus-Jürgen Bathe.
- [18]: Ereiz, S., Duvnjak, I., & Fernando Jiménez-Alonso, J. (2022). Review of finite element model updating methods for structural applications. In *Structures* (Vol. 41, pp. 684–723). Elsevier Ltd. <https://doi.org/10.1016/j.istruc.2022.05.041>
- [19]: Santos, A., Figueiredo, E., Silva, M. F. M., Sales, C. S., & Costa, J. C. W. A. (2016). Machine learning algorithms for damage detection: Kernel-based approaches. *Journal of Sound and Vibration*, 363, 584–599. <https://doi.org/10.1016/j.jsv.2015.11.008>
- [20]: Zhao, Q., Li, C., & Li, X. (2024). Quasi-periodic solutions of a discrete integrable equation with a finite-dimensional integrable symplectic structure. *Physica D: Nonlinear Phenomena*, 458. <https://doi.org/10.1016/j.physd.2023.133992>
- [21]: Waegeman, W., Verwaeren, J., Slabbinck, B., & de Baets, B. (2011). Supervised learning algorithms for multi-class classification problems with partial class memberships. *Fuzzy Sets and Systems*, 184(1), 106–125. <https://doi.org/10.1016/j.fss.2010.11.012>
- [22]: Ross-Veitía, B. D., Palma-Ramírez, D., Arias-Gilart, R., Conde-García, R. E., Espinel-Hernández, A., Nuñez-Alvarez, J. R., Hernández-Herrera, H., & Llosas-Albuérne, Y. E. (2024). Machine learning regression algorithms to predict emissions from steam boilers. *Heliyon*, 10(5), e26892. <https://doi.org/10.1016/j.heliyon.2024.e26892>
- [23]: Festa, D., Novellino, A., Hussain, E., Bateson, L., Casagli, N., Confuorto, P., del Soldato, M., & Raspini, F. (2023). Unsupervised detection of InSAR time series patterns based on PCA and K-means clustering. *International Journal of Applied Earth Observation and Geoinformation*, 118. <https://doi.org/10.1016/j.jag.2023.103276>
- [24]: Qiu, L., Yu, T., & Lan, C. (2024). A semi-supervised load identification method with class incremental learning. *Engineering Applications of Artificial Intelligence*, 131. <https://doi.org/10.1016/j.engappai.2023.107768>
- [25]: Tanskanen, A. J. (2022). Deep reinforced learning enables solving rich discrete-choice life cycle models to analyze social security reforms. *Social Sciences and Humanities Open*, 5(1). <https://doi.org/10.1016/j.ssaho.2022.100263>
- [26]: Navarin, N., Mulders, D., & Oneto, L. (2024). Advances in artificial neural networks, machine learning and computational intelligence. In *Neurocomputing* (Vol. 571). Elsevier B.V. <https://doi.org/10.1016/j.neucom.2023.127098>

- [27]: M.T. Hagan, H. B. D. M. H. B. O. D. J. (2014). Neural Network Design. In Neural Network Design. https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=neural+network+design+Hagan&btnG=
- [28]: Charu C. Aggarwal. (n.d.). Neural Networks and Deep Learning: A textbook. In Springer (Ed.), Neural Networks and Deep Learning: A textbook (2018th ed.).
- [29]: Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M., & Inman, D. J. (2017). Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. Journal of Sound and Vibration, 388, 154–170. <https://doi.org/10.1016/j.jsv.2016.10.043>
- [30]: F. Chollet. (2015). Keras. GitHub. <https://github.com/fchollet/keras>
- [31]: Ponsi, F., Bassoli, E., & Vincenzi, L. (2023). Mitigation of model error effects in neural network-based structural damage detection. Frontiers in Built Environment, 8. <https://doi.org/10.3389/fbuil.2022.1109995>