

**ΜΕΛΕΤΗ ΔΟΜΙΚΗΣ ΣΥΜΠΕΡΙΦΟΡΑΣ ΥΨΗΛΩΝ ΠΥΛΩΝΩΝ ΓΕΦΥΡΑΣ  
ΣΚΥΡΟΔΕΜΑΤΟΣ ΜΕ ΜΕΤΡΗΣΕΙΣ ΨΗΦΙΑΚΩΝ ΚΛΙΣΙΜΕΤΡΩΝ ΚΑΙ ΤΕΧΝΙΚΕΣ  
ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

Κεχαγιά Κυριακή

**Διπλωματική Εργασία**

Σχολή Αγρονόμων και Τοπογράφων Μηχανικών – Μηχανικών Γεωπληροφορικής

Εθνικό Μετσόβιο Πολυτεχνείο



School of Rural, Surveying and Geoinformatics Engineering

National Technical University of Athens

**Επιβλέπων:** Γκίκας Βασίλειος,

Καθηγητής ΕΜΠ

-Αθήνα, Ιούνιος 2021-

## ΕΥΧΑΡΙΣΤΙΕΣ

Με την συγγραφή της παρούσας διπλωματικής εργασίας, ολοκληρώνεται ένας πενταετής κύκλος προπτυχιακών σπουδών στην Σχολή Αγρονόμων και Τοπογράφων Μηχανικών - Μηχανικών Γεωπληροφορικής του Εθνικού Μετσόβιου Πολυτεχνείου. Ο κύκλος αυτός, ήταν καθοριστικός για εμένα, γνώρισα και συνεργάστηκα με εξαιρετικούς καθηγητές και συμφοιτητές, ενώ δέχθηκα την στήριξη πολλών ατόμων τα οποία οφείλω να ευχαριστήσω.

Πρωτίστως, ένα μεγάλο ευχαριστώ αξίζει στον Καθηγητή ΕΜΠ κ. Γκίκα Βασίλειο, για την εμπιστοσύνη του από την πρώτη στιγμή που ανέλαβα την παρούσα διπλωματική εργασία, την καθοδήγησή του και τις συμβουλές του για την συγγραφή της.

Επιπλέον, θα ήθελα να ευχαριστήσω τον Αναπληρωτή Καθηγητή της Στρατιωτικής Σχολής Ευελπίδων κ. Παπαδάκη Νικόλαο, για την καθοριστική του συμβολή και βοήθεια κατά τη διαδικασία συγγραφής του κώδικα επεξεργασίας των μετρήσεων. Οφείλω να αναφέρω πως τον ευχαριστώ ιδιαίτερα για την συνεχή του καθοδήγηση και την άψογη συνεργασία, καθώς και για την προσφορά του κώδικα που κατασκεύασε για χρήση στην παρούσα διπλωματική εργασία.

Τέλος, ένα μεγάλο ευχαριστώ αφιερώνεται στην οικογένειά μου, σε φίλους και συγγενείς. Στους γονείς μου, Δημήτρη και Ελένη, και στην αδερφή μου Κατερίνα, για την αδιάκοπη στήριξή τους, χάρη στους οποίους κατάφερα να σπουδάσω αυτό που αγαπώ. Στους κοντινούς μου συγγενείς και φίλους, με ειδική μνεία στην Ιωάννα, τον Σωκράτη και τη Δήμητρα, που παρά τις δυσκολίες με στήριξαν και με βοήθησαν μέχρι τέλους. Στα άτομα που γνώρισα μέσα από πολλές εθελοντικές δράσεις στον πανεπιστημιακό και μη χώρο, που με βοήθησαν να οραματιστώ ένα καλύτερο εκπαιδευτικό περιβάλλον και να χαράξω τη δική μου διαφορετική πορεία, που δεν είχα φανταστεί πριν.

## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία πραγματεύεται το αντικείμενο της Παρακολούθησης Δομικής Κατάστασης εφαρμοσμένη σε γέφυρες, από όπου απορρέουν συμπεράσματα και για την συμπεριφορά τους, καθώς και την αξιολόγηση της τεχνολογίας των ψηφιακών κλισιμέτρων και τεχνικών μηχανικής μάθησης συνδυαστικά με αυτήν. Αναλύεται πως αξιοποιείται στον κατασκευαστικό τομέα και μελετάται αναλυτικά ο κλάδος 8 της γέφυρας που βρίσκεται στον κόμβο της Μεταμόρφωσης και της Αττικής Οδού, όπου η χρήση εξοπλισμού παρακολούθησης οδήγησε στην εξαγωγή συμπερασμάτων και την πρόβλεψη της συμπεριφοράς της κατασκευής στο κοντινό μέλλον. Η πρόβλεψη πραγματοποιήθηκε προκειμένου να ληφθούν αποφάσεις για τη δομική συμπεριφορά του πυλώνα και την αρτιότητα της κατασκευής. Για την παρακολούθηση της γέφυρας τοποθετήθηκαν τέσσερα ψηφιακά κλισίμετρα (*Nivel220, Leica Geosystems*), ενώ χρησιμοποιήθηκε και ένα επιταχυνσιόμετρο, αισθητήρας για τη διέλευση των οχημάτων και αισθητήρες για την καταγραφή των μετεωρολογικών συνθηκών.

Ο σκοπός της μελέτης αυτής είναι η συλλογή και ανάλυση των δεδομένων πεδίου από τους προαναφερθέντες αισθητήρες, μέσω τεχνικών μηχανικής μάθησης, προκειμένου να υπολογισθούν οι ημι-στατικές κλίσεις στον πυλώνα Μ8 της γέφυρας. Όλη η επεξεργασία των δεδομένων και η πρόγνωση των επόμενων ημερών πραγματοποιείται με χρήση της γλώσσας προγραμματισμού *Python*.

## **ABSTRACT**

The current diploma thesis deals with the subject of Structural Health Monitoring applied in bridges, from which conclusion are drawn about their behaviour, while also the evaluation of the technology used by digital inclinometers and machine learning techniques in conjunction with it. It is analyzed how SHM is reclaimed in the construction sector and is studied in detail the branch No.8 of the bridge located at the Metamorfofis junction and Attiki Odos, where the use of monitoring equipment led in drawing conclusions and predicting the behavior of the bridge in the near future. The forecast was made in order to make decisions about the structural behavior of the branch and the perfection of the construction. For the bridge monitoring there have been located four digital inclinometers (Nivel220, Leica Geosystems), while there has also been used an accelerometer, a sensor for the surpassing vehicles and sensors to record the meteorological conditions.

The aim of this study is the collection and analysis of the field data from the aforementioned sensors, using machine learning techniques to calculate the semi-static inclinations of the M8 branch of the bridge. All data processing and forecasting of the next days is done through the Python programming language.

## ΠΕΡΙΕΧΟΜΕΝΑ

ΕΥΧΑΡΙΣΤΙΕΣ.....	2
ΠΕΡΙΛΗΨΗ.....	3
ABSTRACT .....	4
ΠΕΡΙΕΧΟΜΕΝΑ .....	5
ΕΥΡΕΤΗΡΙΟ ΠΙΝΑΚΩΝ .....	8
ΕΥΡΕΤΗΡΙΟ ΣΧΗΜΑΤΩΝ .....	9
ΕΙΣΑΓΩΓΗ.....	11
ΚΕΦΑΛΑΙΟ 1 - ΠΑΡΑΚΟΛΟΥΘΗΣΗ ΔΟΜΙΚΗΣ ΚΑΤΑΣΤΑΣΗΣ ΚΑΤΑΣΚΕΥΩΝ .....	13
1.1 Εισαγωγικά.....	13
1.2 Παρακολούθηση Δομικής Κατασκευών (ΠΔΚ) των Κατασκευών.....	13
1.2.1 Βασικές αρχές .....	13
1.2.2 Ταξινόμηση μεθόδων ΠΔΚ .....	15
1.3 Απόκριση των Κατασκευών έναντι Φορτίων.....	16
1.3.1 Ζημιόγιοι παράγοντες για την υγεία μίας κατασκευής .....	17
1.3.2 Συλλογή δεδομένων ενός συστήματος ΠΔΚ .....	18
1.4 Τεχνικές ΠΔΚ και η Συμβολή τους στην Ασφάλεια και την Επιμήκυνση της Λειτουργίας των Κατασκευών .....	20
1.4.1 Αρχές σχεδιασμού συστημάτων ΠΔΚ των κατασκευών .....	20
1.4.2 Στρατηγικές ΠΔΚ των κατασκευών .....	22
ΚΕΦΑΛΑΙΟ 2 - ΤΕΧΝΟΛΟΓΙΕΣ ΚΑΙ ΣΥΣΤΗΜΑΤΑ ΠΑΡΑΚΟΛΟΥΘΗΣΗΣ ΔΟΜΙΚΗΣ ΚΑΤΑΣΤΑΣΗΣ ΚΑΤΑΣΚΕΥΩΝ.....	26
2.1 Εισαγωγικά.....	26
2.2 Τοπογραφικές Μέθοδοι .....	27
2.2.1 Συστήματα συμβατικής και δορυφορικής γεωδαισίας .....	27
2.2.2 Επίγειοι σαρωτές Laser .....	31
2.2.3 Επίγειο σύστημα μικροκυματικού <i>radar</i> .....	32
2.2.4 Άλλες μέθοδοι .....	34
2.3 Μέθοδοι Πειραματικής Μηχανικής .....	35
2.3.1 Επιμηκυνσιόμετρα .....	36
2.3.2 Επιταχυνσιόμετρα.....	36
2.3.3 Ψηφιακά κλισιόμετρα.....	38

2.3.4 Αισθητήρες οπτικών ινών .....	38
2.4 Μετάδοση Δεδομένων .....	39
2.4.1 Ενσύρματη μετάδοση .....	39
2.4.2 Ασύρματη μετάδοση .....	40
2.5 Ολοκληρωμένα Συστήματα Παρακολούθησης των Κατασκευών .....	40
ΚΕΦΑΛΑΙΟ 3 - ΜΑΚΡΟΧΡΟΝΙΑ ΠΑΡΑΚΟΛΟΥΘΗΣΗ ΓΕΦΥΡΩΝ ΜΕ ΧΡΗΣΗ ΨΗΦΙΑΚΩΝ ΚΛΙΣΙΜΕΤΡΩΝ .....	42
3.1 Γενική Περιγραφή και Κατηγορίες Κλισιμέτρων .....	42
3.2 Ψηφιακά κλισίμετρα .....	45
3.3 Συστήματα Παρακολούθησης – Χρησιμοποιούμενες Τεχνολογίες .....	46
3.3.1 Κλισίμετρο Nivel220 .....	46
3.3.1.α Αρχές λειτουργίας .....	47
3.3.1.β Συνδεσμολογία .....	49
3.3.2 Αισθητήρες διασύνδεσης μετεωρολογικών .....	49
3.3.3 Λογισμικό καταγραφής <i>Nivel Tool</i> .....	51
ΚΕΦΑΛΑΙΟ 4 - ΜΕΘΟΔΟΙ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΧΡΟΝΟΣΕΙΡΕΣ ΣΤΗΝ ΠΔΚ .....	52
4.1 Εισαγωγικές Έννοιες .....	52
4.1.1 Παράμετροι και βασικές αρχές ανάλυσης χρονοσειρών .....	52
4.1.2 Τεχνητή νοημοσύνη στον κατασκευαστικό τομέα .....	54
4.2 Αναπτυσσόμενες Μέθοδοι Τεχνητής Νοημοσύνης για την Επεξεργασία Δεδομένων Χρονοσειρών .....	56
4.2.1 Αναγνώριση προτύπων .....	56
4.2.2 Μηχανική μάθηση .....	58
4.2.3 Βαθιά Μάθηση .....	61
4.3 Πρόβλεψη και Νευρωνικά Δίκτυα .....	62
4.4 Λογισμικό Πρόβλεψης <i>Prophet</i> .....	66
4.5 Μέθοδοι και Εργαλεία Επεξεργασίας Δεδομένων Χρονοσειρών στην ΠΔΚ .....	69
4.5.1 Ανάλυση δεδομένων στην ΠΔΚ .....	70
4.5.2 Εφαρμογές στις χρονοσειρές .....	71
ΚΕΦΑΛΑΙΟ 5 - ΠΕΡΙΓΡΑΦΗ ΓΕΦΥΡΑΣ ΜΕΛΕΤΗΣ ΚΑΙ ΠΡΩΤΟΓΕΝΗ ΔΕΔΟΜΕΝΑ .....	74
5.1 Περιγραφή Γέφυρας Μελέτης .....	74
5.1.1 Προπαρασκευαστικές διαδικασίες και εργασίες πεδίου .....	75
5.1.2 Επιλογή θέσεων και εγκατάσταση αισθητήρων .....	76
5.2 Πρωτογενή Δεδομένα Ψηφιακών Κλισιμέτρων .....	78

5.2.1 Πρωτογενείς παρατηρήσεις .....	79
5.2.2 Προεπεξεργασία δεδομένων .....	81
ΚΕΦΑΛΑΙΟ 6 - ΔΙΕΞΑΓΩΓΗ ΕΠΕΞΕΡΓΑΣΙΑΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΑΠΟΤΕΛΕΣΜΑΤΩΝ .....	85
6.1 Εισαγωγή.....	85
6.2 Επεξεργασία και πρόβλεψη δεδομένων κλίσης υψηλού πυλώνα .....	85
6.2.1 Πρόβλεψη με τη χρήση του λογισμικού πρόβλεψης <i>Prophet</i> .....	86
6.2.2 Πρόβλεψη με τη χρήση νευρωνικών δικτύων <i>LSTM</i> .....	95
ΚΕΦΑΛΑΙΟ 7 - ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΜΕΛΛΟΝΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ .....	98
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	101
ΔΙΑΔΙΚΤΥΟ.....	103
ΠΑΡΑΡΤΗΜΑ .....	104
Α' Μέρος: Πρόβλεψη με τη χρήση του λογισμικού <i>Prophet</i> .....	104
Β' Μέρος: Πρόβλεψη με τη χρήση νευρωνικών δικτύων <i>LSTM</i> .....	110

## ΕΥΡΕΤΗΡΙΟ ΠΙΝΑΚΩΝ

Πίνακας 5-1: Στατιστικά στοιχεία μετρηθέντων στοιχείων .....	80
Πίνακας 5-2: Συντελεστής συσχέτισης κλίσεων και περιβαλλοντικών παραμέτρων .....	84
Πίνακας 6-1: Σφάλμα <i>RRSE</i> για τις 10 ημέρες που προβλέφθηκαν με τη χρήση νευρωνικών δικτύων <i>LSTM</i> .....	97



## ΕΥΡΕΤΗΡΙΟ ΣΧΗΜΑΤΩΝ

<b>Σχήμα 1-1:</b> Υποσύνολα συστήματος ΠΔΚ .....	21
<b>Σχήμα 1-2:</b> Παράδειγμα των διάφορων παραγόντων που εμπλέκονται στην ΠΔΚ.....	23
<b>Σχήμα 1-3:</b> Στρατηγικές συντήρησης σύμφωνα με τον EN 13306 .....	24
<b>Σχήμα 1-4:</b> Διαδικασία τριών βημάτων για τη χρήση δεδομένων παρατήρησης συμπεριφοράς κατασκευής για συντήρηση βάσει των υφιστάμενων συνθηκών .....	25
<b>Σχήμα 2-1:</b> Ρομποτικός Γεωδαιτικός Σταθμός – Leica Nova TM50 .....	28
<b>Σχήμα 2-2:</b> Σχηματική απεικόνιση εφαρμογής GNSS σε παρακολούθηση δομικής κατάστασης γέφυρας.....	31
<b>Σχήμα 2-3:</b> 3D Επίγειος Σαρωτής Laser Διαφοράς Φάσης – Leica RTC360.....	32
<b>Σχήμα 2-4:</b> Απεικόνιση IBIS-S για την παρακολούθηση μετακινήσεων και παραμορφώσεων .....	33
<b>Σχήμα 2-5:</b> Επιμηκυνσιόμετρα .....	36
<b>Σχήμα 2-6:</b> Επιταχυνσιόμετρα.....	38
<b>Σχήμα 2-7:</b> Σύστημα GeoMos Monitoring Solution – Leica Geosystems AG .....	41
<b>Σχήμα 3-1:</b> Ηλεκτρολυτικά κλισίμετρα .....	43
<b>Σχήμα 3-2:</b> Κλισίμετρο εγκατεστημένο σε πυλώνα.....	44
<b>Σχήμα 3-3:</b> Οριζόντιο ψηφιακό κλισίμετρο.....	45
<b>Σχήμα 3-4:</b> Ψηφιακά κλισίμετρα ευαισθησίας Nivel 220 και Nivel 210.....	45
<b>Σχήμα 3-5:</b> Ψηφιακό κλισίμετρο υψηλής ευαισθησίας Nivel220, Leica Geosystems.....	47
<b>Σχήμα 3-6:</b> Εξαρτήματα του αισθητήρα Nivel220.....	48
<b>Σχήμα 3-7:</b> Εξαρτήματα του αισθητήρα Nivel220.....	48
<b>Σχήμα 3-8:</b> Συνδεσμολογία αισθητήρων Nivel220 και H/Y .....	49
<b>Σχήμα 3-9:</b> Αισθητήρας θερμοκρασίας και υγρασίας HMP 110, Vaisala .....	50
<b>Σχήμα 3-10:</b> Θέσεις τοποθέτησης αισθητήρων καταγραφής μετεωρολογικών .....	51
<b>Σχήμα 4-1:</b> Δομή τεχνολογιών τεχνητής νοημοσύνης .....	56
<b>Σχήμα 4-2:</b> Σχηματική απεικόνιση ενός συστήματος αναγνώρισης προτύπου .....	57
<b>Σχήμα 4-3:</b> Ερευνητικές δημοσιεύσεις σχετικά με τη χρήση της μηχανικής μάθησης και της αναγνώρισης μοτίβων.....	58
<b>Σχήμα 4-4:</b> Αναπαράσταση λειτουργίας αναδρομικών νευρωνικών δικτύων .....	64
<b>Σχήμα 4-5:</b> Απεικόνιση δομής νευρώνα LSTM .....	66
<b>Σχήμα 4-6:</b> Σχηματική απόδοση της analyst-in-the-loop προσέγγισης της πρόβλεψης υπό κλίμακα, που αξιοποιεί καλύτερα τις ανθρώπινες και αυτοματοποιημένες διαδικασίες .....	67
<b>Σχήμα 4-7:</b> Παράδειγμα κώδικα Stan για το πλήρες μοντέλο του Prophet .....	69
<b>Σχήμα 4-8:</b> Προτεινόμενη ροή επεξεργασίας μεγάλων δεδομένων στην ΠΔΚ γεφυρών .....	70
<b>Σχήμα 5-1:</b> Κόμβος Μεταμόρφωσης .....	75
<b>Σχήμα 5-2:</b> Τρισδιάστατη όψη κόμβου Μεταμόρφωσης .....	75
<b>Σχήμα 5-3:</b> Στοιχεία συστήματος ΠΔΚ .....	76
<b>Σχήμα 5-4:</b> Θέσεις ψηφιακών κλισιμέτρων στις στέψεις των πυλώνων M6, M7, M8 και του κλισιμέτρου αναφοράς .....	77
<b>Σχήμα 5-5:</b> Θέσεις εγκατάστασης αισθητήρων καταγραφής μετεωρολογικών .....	78
<b>Σχήμα 5-6:</b> Διατμητική επίδραση που παρατηρείται από τα δεδομένα κλίσης .....	79
<b>Σχήμα 5-7:</b> Οπτικοποίηση δεδομένων κλίσης.....	80
<b>Σχήμα 5-8:</b> Τάση στα δεδομένα χρονοσειράς για την κλίση στον άξονα x.....	82
<b>Σχήμα 5-9:</b> Τάση στα δεδομένα χρονοσειράς για την κλίση στον άξονα γ .....	82
<b>Σχήμα 5-10:</b> Δεδομένα διελεύσεων κατά την περίοδο μελέτης .....	83
<b>Σχήμα 6-1:</b> Άξονες καταγραφής κλίσεων .....	85

<b>Σχήμα 6-2:</b> Πρόβλεψη κλίσης άξονα x για 10 d με τη χρήση του Prophet, μαζί με τα ιστορικά δεδομένα.....	87
<b>Σχήμα 6-3:</b> Τάση, ημερήσια και εβδομαδιαία εποχικότητα και συμβολή εξωτερικών παλινδρομητών για την πρόβλεψη του Prophet του Σχήματος 6-2 .....	87
<b>Σχήμα 6-4:</b> Αλλαγές στην τάση για την κλίση στον άξονα x.....	88
<b>Σχήμα 6-5:</b> Πρόβλεψη κλίσης άξονα x με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet.....	89
<b>Σχήμα 6-6:</b> Ρίζα μέσης τετραγωνικής απόκλισης (RMSE) της πλήρους διασταυρωμένης επικύρωσης για την πρόβλεψη του Σχήματος 6-2 .....	90
<b>Σχήμα 6-7:</b> Πρόβλεψη κλίσης άξονα γ για 10 ημέρες με τη χρήση του Prophet, μαζί με τα ιστορικά δεδομένα .....	91
<b>Σχήμα 6-8:</b> Τάση, ημερήσια και εβδομαδιαία εποχικότητα και συμβολή εξωτερικών παλινδρομητών για την πρόβλεψη του Prophet του Σχήματος 6-7 <b>F</b> .....	91
<b>Σχήμα 6-9:</b> Αλλαγές στην τάση για την κλίση στον άξονα γ .....	92
<b>Σχήμα 6-10:</b> Ρίζα μέσης τετραγωνικής απόκλισης (RMSE) της πλήρους διασταυρωμένης επικύρωσης για την πρόβλεψη του Σχήματος 6-7 .....	93
<b>Σχήμα 6-11:</b> Πρόβλεψη κλίσης άξονα γ με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet.....	94
<b>Σχήμα 6-12:</b> Πρόβλεψη κλίσης άξονα γ με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet σε συνδυασμό με την παρουσίαση στατιστικών μεγεθών .....	95
<b>Σχήμα 6-13:</b> Πρόβλεψη κλίσης άξονα γ με χρήση LSTM για τις επόμενες 10 ημέρες .....	97

## ΕΙΣΑΓΩΓΗ

Οι γέφυρες, ως βασικοί πυλώνες του συστήματος μεταφορών, αποτελούν σημείο αναφοράς για όλες τις ανθρώπινες κοινωνίες. Η γεφύρωση δύο σημείων διευκολύνει τη διέλευση και μειώνει το χρόνο αυτής, την επικοινωνία και την ανάπτυξη τόσο κοινωνικά όσο και οικονομικά για μία περιοχή. Η συντήρηση μίας τέτοιας κατασκευής και άλλων αντίστοιχου μεγέθους, είναι αρκετά σημαντική εξαιτίας πολλαπλών παραγόντων εκτός όσων αναφέρθηκαν. Το υψηλό κόστος κατασκευής τους και η οικονομική τους αξία, επιβάλλει την παρακολούθηση των υφιστάμενων κατασκευών, ιδίως σε εποχές παγκόσμιας οικονομικής δυσμένειας.

Οι διαφορές που δημιουργούνται σε μία κατασκευή από το στάδιο μελέτης και κατασκευής και κατά την μετέπειτα χρήση της, που μπορεί να οφείλονται σε ατέλειες κατασκευαστικές, σε ανθρωπογενείς και περιβαλλοντικούς παράγοντες, προκαλούν ασάφειες όσον αφορά την στατική και δυναμική της φύση, άρα και την μελλοντική της συμπεριφορά. Βάσει όλων των παραπάνω και δεδομένου πως η τεχνολογία και η τεχνογνωσία έχει εξελιχθεί ραγδαία, η καταγραφή και αντιμετώπιση των μεταβολών που καταπονούν τις κατασκευές, οδηγούν στην παρακολούθησή τους με χρήση συστημάτων αισθητήρων, ως μέρος της γενικότερης παρακολούθησης της «υγείας» τους.

Η παρακολούθηση των κατασκευών αποτελεί ένα εξαιρετικά σημαντικό κομμάτι της μηχανικής, καθώς αφορά την αξιολόγησή τους και την μελέτη της συμπεριφοράς τους ως προς διάφορα φαινόμενα που τις καταπονούν. Τέτοια φαινόμενα μπορεί να είναι γεωλογικά, υδρολογικά, κλιματικά ή ανθρωπογενή, που επηρεάζουν τη λειτουργικότητα των κατασκευών και τη δομική τους ακεραιότητα. Με τη χρήση του όρου παρακολούθηση της «υγείας» των κατασκευών (*Structural Health Monitoring – SHM*) συμπεριλαμβάνεται ένα σύνολο ενεργειών και συστημάτων μέτρησης, μέσω του οποίου λαμβάνονται σε πραγματικό χρόνο πληροφορίες για την μεταβολή και τη δομική παραμόρφωσή τους, αλλά και του γήινου φλοιού.

Στα πλαίσια της παρούσας διπλωματικής εργασίας πραγματοποιείται ο σχεδιασμός, η ανάπτυξη και η εφαρμογή ενός συστήματος αισθητήρων υψηλής ακριβείας που μετρούν την κλίση, προκειμένου να πραγματοποιηθεί η καταγραφή της απόκρισης και η αξιολόγηση της ημι-στατικής συμπεριφοράς του υψηλού πυλώνα M8 των κλάδων 5 & 8 στον κόμβο της Μεταμόρφωσης με την Αττική Οδό ΑΕ. Συγκεκριμένα, δίνεται έμφαση στην απόκριση του πυλώνα σχετικά με περιβαλλοντικούς παράγοντες, δηλαδή τη θερμοκρασία, την υγρασία, το ύψος βροχής και την ατμοσφαιρική πίεση, αλλά και σε σχέση με τα διερχόμενα οχήματα για το διάστημα παρακολούθησης.

Στο πρώτο κεφάλαιο, αναφέρεται η έννοια της παρακολούθησης δομικής κατάστασης των κατασκευών, η αναγκαιότητά της και η διαδικασία που αυτή περιλαμβάνει. Γίνεται ειδική μνεία στους παράγοντες που επιβαρύνουν την «υγεία»

των κατασκευών και στον τρόπο με τον οποίο σχεδιάζεται ένα σύστημα παρακολούθησης δομικής κατάστασης και οι στρατηγικές που ακολουθούνται.

Στο δεύτερο κεφάλαιο, παρουσιάζονται οι τεχνολογίες που χρησιμοποιούνται για την εντοπισμό ενός συστήματος παρακολούθησης δομικής κατάστασης μίας κατασκευής. Ο βασικός διαχωρισμός γίνεται ανάμεσα σε τοπογραφικές μεθόδους και μεθόδους πειραματικής μηχανικής, όπου η κάθε μέθοδος αξιοποιεί διαφορετικά συστήματα αισθητήρων. Τέλος, αναφέρονται οι τρόποι μετάδοσης των δεδομένων, ενσύρματα ή ασύρματα και ολοκληρωμένα συστήματα παρακολούθησης κατασκευών που παρέχονται στο εμπόριο.

Στο τρίτο κεφάλαιο, εξετάζονται τα ψηφιακά κλισίμετρα υψηλής ακριβείας και οι δυνατότητές τους στην παρακολούθηση κατασκευών. Παρουσιάζονται τα χαρακτηριστικά των κλισιμέτρων, ψηφιακών και μη, ενώ ειδική αναφορά γίνεται στο κλισίμετρο *Nivel220*, το οποίο χρησιμοποιείται για την καταγραφή των μετρήσεων της παρούσας διπλωματικής εργασίας.

Στο τέταρτο κεφάλαιο, περιλαμβάνονται οι έννοιες της χρονοσειράς και της τεχνητής νοημοσύνης, καθώς και των χαρακτηριστικών που τις περιγράφουν. Αναλύονται μέθοδοι μελέτης των χρονοσειρών και εφαρμογές τους συνδυαστικά με μεθόδους τεχνητής νοημοσύνης, οι οποίες παρουσιάζονται εξίσου. Γίνεται εμβάθυνση στην αναγνώριση μοτίβων, την μηχανική και τη βαθιά μάθηση, αφού αυτές χρησιμοποιούνται περισσότερο στον κατασκευαστικό τομέα, ενώ περιγράφονται τα νευρωνικά δίκτυα και το λογισμικό πρόβλεψης *Prophet* ξεχωριστά, αφού χρησιμοποιούνται για την επεξεργασία των μετρήσεων στην συνέχεια.

Στο πέμπτο κεφάλαιο, παρέχονται πληροφορίες για την οδική γέφυρα κλάδου 5 & 8 του κόμβου της Μεταμόρφωσης με την Αττική Οδό. Ειδικότερα, παρουσιάζονται οι διαδικασίες που ακολουθήθηκαν πριν την τοποθέτηση του συστήματος αισθητήρων σε αυτήν, οι θέσεις τοποθέτησης των κλισιμέτρων, ο πυλώνας που μελετάται και οι πρωτογενείς μετρήσεις κλίσης, περιβαλλοντικών μεταβλητών και κυκλοφορίας που λήφθηκαν, πριν την οποιαδήποτε επεξεργασία τους. Τέλος, παρέχεται ο βαθμός συσχέτισης της κάθε μεταβλητής σε σχέση με την προσμετρώμενη κλίση σε κάθε άξονα.

Στο έκτο κεφάλαιο, παρουσιάζεται η επεξεργασία που πραγματοποιείται για τα δεδομένα παρακολούθησης, διάρκειας πέντε μηνών. Η επεξεργασία, περιέχει την πρόβλεψη της συμπεριφοράς της γέφυρας, ως προς την κλίση της, για τις επόμενες δέκα ημέρες. Η πρόβλεψη πραγματοποιείται με τη χρήση του λογισμικού *Prophet* της εταιρείας *Facebook* και ακολουθώντας την ομώνυμη διαδικασία πρόβλεψης, αλλά και με τη χρήση νευρωνικών δικτύων *LSTM* προς σύγκριση των αποτελεσμάτων.

Τέλος, στο έβδομο κεφάλαιο παρατίθενται τα συμπεράσματα που προκύπτουν από όλη την προηγούμενη ανάλυση και επεξεργασία, ενώ αναγράφονται και κάποιες μελλοντικές κατευθύνσεις όσον αφορά τον συνδυασμό της τεχνητής νοημοσύνης και της παρακολούθησης δομικής κατάστασης κατασκευών.

## ΚΕΦΑΛΑΙΟ 1 - ΠΑΡΑΚΟΛΟΥΘΗΣΗ ΔΟΜΙΚΗΣ ΚΑΤΑΣΤΑΣΗΣ ΚΑΤΑΣΚΕΥΩΝ

### 1.1 Εισαγωγικά

Στο παρόν κεφάλαιο γίνεται αναφορά στην αναγκαιότητα και το αντικείμενο που αφορούν την παρακολούθηση της δομικής κατάστασης τεχνικών έργων. Συγκεκριμένα, περιγράφεται η απόκριση των κατασκευών έναντι φορτίων και τους παράγοντες που τις επηρεάζουν. Ακόμη, αναλύονται οι διάφορες μέθοδοι παρακολούθησης δομικής κατάστασης και πως οι τεχνικές που χρησιμοποιούνται έχουν αντίκτυπο στην λειτουργία και τη χρήση της κατασκευής, μαζί με τα πλεονεκτήματα και τα μειονεκτήματά τους.

### 1.2 Παρακολούθηση Δομικής Κατασκευών (ΠΔΚ) των Κατασκευών

Η παρακολούθηση δομικής κατάστασης κατασκευών (ΠΔΚ ή *Structural Health Monitoring - SHM*) αποτελεί ένα επιστημονικό πεδίο μέσω του οποίου παρατηρείται η στατική ή δυναμική συμπεριφορά μίας κατασκευής. Σκοπός είναι η παροχή αξιόπιστων δεδομένων σχετικά με τη δομική κατάσταση των κατασκευών, ώστε να είναι εφικτός ο προσδιορισμός της συνέχειας χρήσης της κατασκευής, πιθανές επισκευές ή και η απόσυρσή της σε περίπτωση υψηλής επικινδυνότητας. Ο όρος αυτός, περιλαμβάνει πλέον όλες τις μεθόδους παρακολούθησης κατάστασης και όσον αφορά τις γέφυρες. Η ΠΔΚ εν γένει χρησιμοποιεί πολλές διαφορετικές μεθόδους για την ανάλυση της υγείας μίας κατασκευής, όπως παραδοσιακές ψηφιακές μεθόδους παρατήρησης για την εκτίμηση των εξωτερικών χαρακτηριστικών μίας γέφυρας και των μελών της, υπερηχητικά συστήματα παρακολούθησης ενισχύσεων των μελών της γέφυρας και συστήματα αισθητήρων παρακολούθησης για την μέτρηση των αποκρίσεων της κατασκευής (π.χ. παραμορφώσεις, επιταχύνσεις).

#### 1.2.1 Βασικές αρχές

Αντικείμενο της ΠΔΚ, είναι η καταγραφή της συμπεριφοράς μίας κατασκευής, η εκτίμηση της λειτουργίας της έναντι πολλαπλών φορτίων και η διάγνωση βλαβών, που περιλαμβάνει τον εντοπισμό, το είδος και τη σοβαρότητά τους. Οι βλάβες αυτές, μπορεί να εντοπίζονται τόσο στα υλικά κατασκευής και στα μέλη της κατασκευής, όσο και σε ολόκληρη την κατασκευή. Η κατάσταση του φορέα επιθυμείται να μείνει ίδια με αυτή που έχει κατασκευασθεί κατά την αρχική μελέτη, ωστόσο λόγω γήρανσης, τυχαίων επιδράσεων και περιβαλλοντικών παραγόντων η κατάστασή του μεταβάλλεται. Η παρακολούθηση της κατασκευής διαρκεί αρκετό χρονικό διάστημα ώστε να ληφθεί ολοκληρωμένο ιστορικό για αυτή και να παραχθεί μία πλήρης πρόγνωση, όσον αφορά τις φθορές, αστοχίες, τη διάρκεια ζωής κι άλλους παράγοντες ενδιαφέροντος.

Το διαγνωστικό εργαλείο της ΠΔΚ συντίθεται από ένα ολοκληρωμένο σύνολο καταγραφικών συσκευών και βοηθητικών συστημάτων, όπως συστήματα

αισθητήρων, καταγραφής δεδομένων, επεξεργασίας δεδομένων, επικοινωνίας και ανίχνευσης βλαβών. Όλα αυτά σε συνδυασμό, αξιοποιούνται προκειμένου να επιτυγχάνεται η ζητούμενη αμεσότητα και ευαισθησία στο σύστημα παρακολούθησης. Μέσω αυτών, ανιχνεύονται εγκαίρως ελαττώματα και αστοχίες που εντοπίζονται στην κατασκευή, με τον συντομότερο δυνατό τρόπο και με μειωμένο κόστος.

Ακόμη, σύμφωνα με την πηγή [1], θεωρείται πως με την ύπαρξη της ΠΔΚ για τουλάχιστον 20 χρόνια και τον μεγάλο όγκο βιβλιογραφίας γύρω από αυτήν, έχουν δημιουργηθεί κάποιες βασικές θεωρήσεις. Αυτά, αποτυπώνουν τη βασική αλήθεια γύρω από το αντικείμενο και τη μεθοδολογία του και συνίσταται η εφαρμογή τους για την εφαρμογή καλών πρακτικών στην ΠΔΚ.

- Θεώρηση I: Όλα τα υλικά έχουν έμφυτες ατέλειες ή ελαττώματα.
- Θεώρηση II: Η αξιολόγηση μίας βλάβης απαιτεί σύγκριση μεταξύ της κατάστασης δύο συστημάτων
- Θεώρηση III: Η ταυτοποίηση της ύπαρξης και της θέσης μίας βλάβης μπορεί να γίνει χρησιμοποιώντας μη-επιβλεπόμενους τρόπους μάθησης, αλλά η ταυτοποίηση των παρουσών βλαβών και της σοβαρότητας αυτών μπορεί εν γένει να πραγματοποιηθεί μόνο με επιβλεπόμενους τρόπους μάθησης.
- Θεώρηση IV α: Οι αισθητήρες δεν υπολογίζουν τη βλάβη. Η εξαγωγή χαρακτηριστικών μέσα από επεξεργασία σήματος και στατιστική ταξινόμηση είναι απαραίτητη ώστε να μετατραπούν τα δεδομένα από τους αισθητήρες σε πληροφορίες για τις βλάβες.
- Θεώρηση IV β: Χωρίς την εξαγωγή έξυπνων χαρακτηριστικών, όσο πιο ευαίσθητη είναι μία μέτρηση στη ζημία, τόσο πιο ευαίσθητη είναι στην αλλαγή λειτουργικών και περιβαλλοντικών συνθηκών.
- Θεώρηση V: Οι κλίμακες χρόνου και μήκους που είναι αφορούν την πηγή της βλάβης και την επέκτασή της υπαγορεύουν τις απαραίτητες ιδιότητες του συστήματος αισθητήρων της ΠΔΚ.
- Θεώρηση VI: Υπάρχει μία ισορροπία μεταξύ της ευαισθησίας στην ζημία ενός αλγόριθμου και στην ικανότητά του να απορρίψει τους θορύβους.
- Θεώρηση VII: Το μέγεθος μίας βλάβης που μπορεί να εντοπιστεί από αλλαγές στη δυναμικότητα του συστήματος είναι αντιστρόφως ανάλογο του εύρους συχνότητας διέγερσης.

Για την κατανόηση της σημασίας της ΠΔΚ, αξίζει να σημειωθεί το παράδειγμα της γέφυρας *Morandi* στην Ιταλία, όπου το 2018 λόγω καταστροφών σε αυτήν σκοτώθηκαν 43 άτομα και τραυματίστηκαν δεκάδες άλλοι. Ακόμη, εκτός από τις δραματικές συνέπειες που ακολούθησαν με την κατάρρευση της γέφυρας, την αναστάτωση στο εθνικό συγκοινωνιακό δίκτυο, ιδίως στις κύριες αρτηρίες του, είχε μεγάλη επίπτωση και στην οικονομική ανάπτυξη και την καθημερινότητα των πολιτών της περιοχής. [2]

Επομένως, η αντίληψη του τρόπου λειτουργίας των μεγάλων κατασκευών, όπως οι γέφυρες, για την απόκρισή τους έναντι πολλών διαφορετικών λειτουργικών και περιβαλλοντικών μεταβολών, καθιστούν δυνατή τη διατήρηση της ασφάλειας και της λειτουργικότητάς τους. Οι μέθοδοι και οι τεχνικές που έχουν αναπτυχθεί γύρω από την ΠΔΚ, όπως αναλύονται και στην συνέχεια, οδηγούν στην αποτελεσματική συντήρηση και διαχείριση των δομικών έργων.

### 1.2.2 Ταξινόμηση μεθόδων ΠΔΚ

Ένα σύστημα ΠΔΚ υποδιαιρείται σε τέσσερα υποσυστήματα, όπως παρατίθενται παρακάτω.

- Στατικές δοκιμές της κατασκευής
- Δυναμικές δοκιμές της κατασκευής
- Περιοδική παρακολούθηση
- Συνεχής παρακολούθηση

Το πρώτο υποσύστημα, αφορά δοκιμές απόκρισης, διαγνωστικές δοκιμές και δοκιμές επαλήθευσης. Το δεύτερο, δοκιμές ιστορικού τάσεων, μεταβολής της δυναμικής φόρτισης, περιβαλλοντικές διεγέρσεις και ελεύθερης ταλάντωσης (*pullout*). Το τρίτο αφορά δοκιμές πεδίου και για διακρίβωση αλλαγών στην κατασκευή, ενώ το τέταρτο την ενεργή και παθητική παρακολούθηση.

Ο βασικός διαχωρισμός ανάμεσα στα θεωρούμενα συστήματα ΠΔΚ και άλλα συστήματα δομικής παρακολούθησης, βασίζεται στο γεγονός ότι με τα συστήματα ΠΔΚ είναι εφικτός ο καθορισμός της αντοχής της κατασκευής και η διακρίβωση βλάβης που είναι πιθανό να εμφανιστεί, εκτός από την ανίχνευση των ήδη υπάρχοντων βλαβών. Ανάλογα με την πολυπλοκότητα του υποσυστήματος που χρησιμοποιείται, η ικανότητα ανίχνευσης βλαβών κατατάσσεται σε κάποια επίπεδα, όπως αυτά παρουσιάζονται ακολούθως. [3]

- Επίπεδο 1: Εντοπισμός βλαβών, όταν η ύπαρξη βλάβης έχει διαγνωσθεί.
- Επίπεδο 2: Θέση βλάβης, όταν η θέση της βλάβης έχει προσδιοριστεί.
- Επίπεδο 3: Τύπος βλάβης, όταν έχει εκτιμηθεί ποσοτικά η βλάβη.
- Επίπεδο 4: Έκταση βλάβης, όταν η σοβαρότητα της βλάβης έχει αξιολογηθεί.

Στη διεθνή βιβλιογραφία αναφέρονται κι άλλες κατηγορίες, με την πέμπτη κατηγορία να αφορά την εναπομένουσα ζωή της κατασκευής. Όσο υψηλότερο είναι το επίπεδο αξιολόγησης τόσο περισσότερες πληροφορίες μπορούν να αντληθούν από την παρακολούθηση για την κατασκευή που μελετάται. Αντίστοιχα, αυτό υποδεικνύει τη μεγαλύτερη δυσκολία στη λήψη δεδομένων και πληροφοριών, ενώ κάθε επίπεδο απαιτεί τη γνώση των προηγούμενων για να βρεθεί. Ωστόσο, το πρώτο επίπεδο από μόνο του δεν είναι αρκετά σαφές, δημιουργεί όμως υποψίες για τις βλάβες που υπάρχουν. Αυτό σημαίνει πως οι μέθοδοι που χρησιμοποιούνται στο επίπεδο αυτό δείχνουν την υψηλή πιθανότητα για ύπαρξη βλάβης, όμως αφού πραγματοποιηθεί

περαιτέρω έρευνα μπορεί να ταυτοποιηθεί η υποψία αυτή και ύστερα να βρεθεί η θέση και η σοβαρότητα της βλάβης.

### **Πλεονεκτήματα της μεθόδου ΠΔΚ κατασκευών**

Προκειμένου να ελαχιστοποιηθεί η παύση λειτουργίας των κατασκευών λόγω επισκευών και συντηρήσεων, είναι αναγκαία η εξέλιξη της παρακολούθησης δομικής κατάστασής τους. Σύμφωνα με τον *Chang* (1999), η παραγωγικότητα της κατασκευής αυξάνεται με την μείωση του χρόνου διακοπής λειτουργίας της και με τη βελτίωση της αξιοπιστίας. [4]

Μέσω ενός συστήματος ΠΔΚ, όπως προαναφέρθηκε, λαμβάνονται άμεσα πληροφορίες σχετικά με τη λειτουργική κατάσταση της κατασκευής, την ασφάλεια και την ανθεκτικότητα, βοηθώντας έτσι τους μηχανικούς να αντιμετωπίσουν προβλήματα που εμφανίζονται εγκαίρως. Ακόμη, μέσω της παρακολούθησης κατά τη διάρκεια λειτουργίας της κατασκευής, δύναται να αξιοποιηθούν οι διαθέσιμοι πόροι με το βέλτιστο τρόπο, όσον αφορά την επισκευή, αποκατάσταση ή αντικατάστασή της, ενώ παράλληλα μπορεί να υπολογισθεί και το κόστος για τον κύκλο ζωής της.

Τα σημαντικότερα πλεονεκτήματα που πηγάζουν άμεσα από την αξιοποίηση ενός συστήματος ΠΔΚ είναι [4]:

- Παρακολούθηση και αναφορά σε πραγματικό χρόνο.
- Μείωση χρόνου διακοπής λειτουργίας για τακτική επιθεώρηση.
- Βελτίωση της ασφάλειας και αξιοπιστίας και μείωση του κόστους συντήρησης.
- Προληπτική παρακολούθηση των δομικών επιδόσεων από λειτουργικές και περιβαλλοντικές παραλλαγές.
- Επεκτείνεται η εναπομένουσα διάρκεια ζωής της κατασκευής, μειώνοντας τις αστοχίες λόγω έγκαιρης ανίχνευσης.
- Μείωση περιττών δαπανών συντήρησης και εκτίμηση κύκλου ζωής των στοιχείων της κατασκευής.

Αξιοσημείωτο είναι το γεγονός ότι τα δεδομένα που καταγράφονται και τα αποτελέσματα που προκύπτουν από ένα σύστημα ΠΔΚ, παρέχουν πληροφορίες που ανταποκρίνονται στην πραγματική συμπεριφορά της κατασκευής. Για το λόγο αυτό, η ΠΔΚ κρίνεται χρήσιμη και για την βελτίωση του σχεδιασμού μελλοντικών κατασκευών.

### **1.3 Απόκριση των Κατασκευών έναντι Φορτίων**

Οι κατασκευές υπόκεινται σε πολλαπλές πιέσεις από τη στιγμή που κατασκευάζονται, ανεξάρτητα από την ηλικία τους. Η αντοχή των υλικών τους και η ικανότητά τους να αντέξουν στις ασκούμενες πιέσεις είναι αντικείμενο εξαιρετικά υψηλής σημασίας, όπως και αυξανόμενης ανησυχίας όσον αφορά την συνολική τους βιωσιμότητα και



όλα αυτά παράλληλα με την μείωση του κατασκευαστικού χρόνου και κόστους. Η κατάσταση μίας κατασκευής υποβιβάζεται εξαιτίας πολλών παραγόντων, όπως η διάβρωση και το φορτίο, αλλά και από φυσικά φαινόμενα, όπως σεισμούς. Η αστοχία στις γέφυρες ευθύνεται κατά το 70% σε ανθρωπογενείς παράγοντες (θέματα σχετικά με την κατασκευή, σχεδίαση, συντήρηση και επιθεώρηση) και 30% σε φυσικά αίτια.

### **1.3.1 Ζημιογόνοι παράγοντες για την υγεία μίας κατασκευής**

Ξεκινώντας με τα φυσικά φαινόμενα, όπως σεισμοί, τυφώνες, περιβαλλοντική θερμοκρασία, αρκετά από αυτά μπορούν να αποβούν καταστροφικά για τις κατασκευές. Ταυτόχρονα, τα δυναμικά φορτία που προέρχονται από διάφορες ανθρωπίνες δραστηριότητες είναι πολύ πιο πιθανό να προκαλέσουν ανεπανόρθωτη ζημία σε μία κατασκευή, όσον αφορά τη λειτουργικότητά της.

Οι μεγάλες κατασκευές, όπως οι γέφυρες, συχνά υπόκεινται σε πολύ μεγάλες μεταβολές περιβαλλοντικών συνθηκών, όπως η αλλαγή της θερμοκρασίας. Οι μεταβολές αυτές οφείλονται σε κλιματικούς παράγοντες, όπως η ηλιακή ακτινοβολία, η θερμοκρασία του αέρα, η ταχύτητα του αέρα και η ακτινοβολία της θερμότητας μεγάλου κύματος. Η επίδραση που έχουν τα παραπάνω στις κατασκευές μεταφράζονται μέσω συστολών και διαστολών, αλλά μπορούν να προκαλέσουν και καμπτικές παραμορφώσεις.

Τα θερμικά φορτία είναι ένας βασικός παράγοντας, ο οποίος πρέπει να λαμβάνεται υπόψιν κατά τον σχεδιασμό και την αξιολόγηση της κατάστασης μίας κατασκευής, ιδίως στις γέφυρες. Οι κατασκευές πλέον είναι σχεδιασμένες έτσι ώστε να έχουν αρκετά μεγάλη διάρκεια ζωής, επομένως, είναι αναπόφευκτη η έκθεσή τους σε καθημερινά, μηνιαία και ετήσια επαναλαμβανόμενα φαινόμενα θέρμανσης και ψύξης, συμπεριλαμβανομένης και της περιβαλλοντικής θερμοκρασίας και του αέρα γύρω τους. Οι αυξομειώσεις αυτές μπορεί να προκαλέσουν φορτία που επηρεάζουν σε μεγάλο βαθμό τις κατασκευές, αποτελώντας μία από τις βασικές παραμέτρους που επηρεάζουν τη λειτουργία τους.

Βάσει αποτελεσμάτων έρευνας σε γέφυρα που πραγματοποιήθηκε από Κινέζους μηχανικούς [5], αλλαγές στα δυναμικά χαρακτηριστικά γεφυρών εξαιτίας βλαβών στους πυλώνες ή στα καλώδια, μπορεί να είναι μικρότερες από αυτές που προκαλούνται από τις μεταβολές της θερμοκρασίας. Ακόμη, αναφέρεται πως οι μεταβολές της θερμοκρασίας προκαλούν θερμικές πιέσεις αν η θερμική παραμόρφωση των μελών της γέφυρας είναι περιορισμένη, το οποίο μπορεί να είναι συγκρίσιμο με αυτό που παράγεται από ζωντανό ή μη φορτίο. Σε γέφυρες από σκυρόδεμα, αυτές οι πιέσεις μπορούν αρχικά να προκαλέσουν εφελκυστικές αστοχίες, λόγω της χαμηλής εφελκυστικής αντοχής του υλικού. Αυτές οι μικρές ρωγμές, λόγω της πίεσης, μπορεί στην συνέχεια να μεγαλώσουν εκθέτοντας έτσι τον οπλισμό σε πιθανή διάβρωση. Λόγω της πολυπλοκότητας των θερμικών φορτίων, είναι πολύ δύσκολη η πρόβλεψή τους, ώστε να αποτυπωθούν με κάποιο μαθηματικό μοντέλο.

Περνώντας στους ανθρωπογενείς παράγοντες που καταπονούν τις κατασκευές, μείζονος σημασίας είναι τα δυναμικά φορτία, με αποτέλεσμα να είναι αναγκαία η ανάλυση τις δυναμικής απόκρισης αυτών, καθώς και ο υπολογισμός της εντατικής και της παραμορφωσιακής τους κατάστασης. Τέτοια φορτία παράγονται από την περιστροφική κίνηση μηχανών, τις εκρήξεις, τις κινήσεις οχημάτων, την ανεμοποίηση και την κίνηση της στήριξης ενός φορέα λόγω σεισμικής δραστηριότητας.

Τα δυναμικά φορτία κατηγοριοποιούνται ανάλογα με την προέλευσή τους και ύστερα με την χρονική τους εξέλιξη ως εξής βάσει της πηγής [6]:

- Περιβαλλοντικά/Ανθρώπινη δραστηριότητα
- Περιοδικά/Μη-περιοδικά
- Πλήγματα/Μεγάλης χρονικής διάρκειας
- Τυχηματικά/Αιτιοκρατικά

Η μελέτη της δυναμικής απόκρισης είναι χρήσιμη για τον σχεδιασμό των κατασκευών, καθώς υπό συγκεκριμένες συνθήκες η ταλαντούμενη κίνηση μπορεί να προκαλέσει υψηλές τάσεις και μετακινήσεις στις κατασκευές. Ακόμη, οι επαναλαμβανόμενες φορτίσεις μετρίου μεγέθους, σε περιπτώσεις μεγάλου αριθμού επαναλήψεων, που μπορεί να δεχθούν οι κατασκευές, είναι ικανές να οδηγήσουν σε αστοχίες των δομικών υλικών λόγω κόπωσης.

### 1.3.2 Συλλογή δεδομένων ενός συστήματος ΠΔΚ

Η συλλογή των δεδομένων σε ένα σύστημα ΠΔΚ αφορά και την προετοιμασία πριν την έναρξη των εργασιών για τις θέσεις εγκατάστασης των διάφορων αισθητήρων. Οι τοποθετούμενοι αισθητήρες μετρούν είτε απόλυτες τιμές, είτε μεταβολές ο καθένας ενός εκ των παρακάτω μεγεθών:

- Ανηγμένες επιμηκύνσεις
- Παραμορφώσεις
- Επιταχύνσεις
- Θερμοκρασίες
- Υγρασία
- Ακουστικές εκπομπές (περιβαλλοντικές διεγέρσεις)
- Χρόνο
- Ηλεκτρικό δυναμικό
- Φορτίσεις
- Άλλα χαρακτηριστικά της κατασκευής

Όπως αναλύεται και σε επόμενο κεφάλαιο, οι αισθητήρες που επιλέγονται για την συλλογή των δεδομένων πρέπει να παρέχουν την απαιτούμενη πληροφορία για την δομική κατάσταση στην οποία βρίσκεται η κατασκευή. Στο εμπόριο διατίθενται διάφοροι τύποι αισθητήρων, ωστόσο δεν είναι όλοι κατάλληλοι για την ενορχήστρωση ενός συστήματος αισθητήρων ΠΔΚ. Για παράδειγμα, τα

επιμηκυνσιόμετρα που διατίθενται δεν είναι πάντοτε ικανά να διατηρηθούν για μεγάλο χρονικό διάστημα πάνω σε μία κατασκευή, καθώς από κάποιο χρονικό σημείο και ύστερα ξεκινούν να παρουσιάζουν παραμορφώσεις στις μετρήσεις που καταγράφουν. Προκειμένου αυτό να αποφευχθεί, απαιτείται συνεχής ενημέρωση και έρευνα ώστε να επιλέγονται οι κατάλληλοι αισθητήρες τόσο από άποψη αξιοπιστίας, όσο και από την οικονομική σκοπιά, για την παρακολούθηση της απόκρισης της κατασκευής που μελετάται.

Για την μέτρηση της απόκρισης μίας γέφυρας υπάρχει η δυνατότητα μέτρησης εντατικών μεγεθών, επιταχύνσεων και παραμορφώσεων. Τα μεγέθη αυτά μπορούν να μετρηθούν άμεσα ή να υπολογισθούν εκ των υστέρων με τη χρήση μετρήσεων από διάφορες θέσεις. Σε περίπτωση που χρησιμοποιηθεί η δεύτερη μέθοδος, μετρούνται οι παραμορφώσεις και από αυτές προκύπτει το εντατικό μέγεθος που τις προκαλεί. Ενδεικτικά, στις κατασκευές τα εντατικά μεγέθη που αναπτύσσονται είναι η ροπή, η τέμνουσα και η αξονική δύναμη.

Πέραν των μεγεθών παραμόρφωσης και έντασης, είναι εφικτός ο υπολογισμός των δυναμικών φορτίσεων, όταν μετράται η απόκριση φορέων γεφυρών. Στην προκειμένη περίπτωση μετράται η επιτάχυνση στην θέση που εγκαθίσταται ο αισθητήρας. Εξαιρετικής σημασίας είναι ο υπολογισμός της επιτάχυνσης σε σημεία μακριά από το έδαφος, όπου είναι απαλλαγμένα από την επιτάχυνση του εδάφους, επομένως είναι σημαντική η ύπαρξη αισθητήρων στο έδαφος ή σε σημείο άλλο από όπου να προκύπτουν οι επιταχύνσεις της ανωδομής. Μέσα από τον υπολογισμό της επιτάχυνσης, είναι δυνατή η εξαγωγή τιμών ταχύτητας και μετατόπισης, οι οποίες δίνουν πληροφορίες για την ένταση που αναπτύσσεται στον φορέα και τον τρόπο παραμόρφωσής του.

Ειδικότερα, σε μία κατασκευή από οπλισμένο σκυρόδεμα, οι ποσότητες που μετρούνται είναι:

- Παραμόρφωση
- Μετακίνηση
- Εντοπισμός και μέτρηση ρωγμών
- Δυνάμεις
- Θερμοκρασία
- Ερπυσμός και συστολή ξήρανσης
- Ιδιότητες υλικών
- Δυναμική απόκριση

Για την μέτρηση των παραπάνω μεγεθών, τα τελευταία χρόνια, με την εξέλιξη της τεχνολογίας, διατίθενται στο εμπόριο πολλών ειδών αισθητήρες που χρησιμοποιούνται και σε άλλες βιομηχανίες, από απλά χειροκίνητα όργανα μέχρι ηλεκτρονικές συσκευές. Οι αισθητήρες αυτοί, καλύπτουν τόσο τα κριτήρια αξιοπιστίας όσο και τα οικονομικά, όμως όταν πρόκειται για πολύ μεγάλες κατασκευές απαιτείται η χρήση μίας σειράς αυτών.

Τέλος, για την μεταφορά των δεδομένων συχνά χρησιμοποιούνται ειδικά καλώδια που συνδέουν τον εκάστοτε αισθητήρα με την καταγραφική μονάδα. Ωστόσο, σε πιο πολύπλοκα συστήματα, όπου συμμετέχουν πολλοί αισθητήρες, υπάρχει μεγάλη πιθανότητα με αυτή την μέθοδο να υπάρξουν σημαντικά σφάλματα στην συσχέτιση μεταξύ της απόκρισης των αισθητήρων και των δεδομένων που συλλέγονται. Το πρόβλημα αυτό επιλύεται με την επιλογή ασύρματης επικοινωνίας μεταξύ αισθητήρων και καταγραφικής μονάδας.

## **1.4 Τεχνικές ΠΔΚ και η Συμβολή τους στην Ασφάλεια και την Επιμήκυνση της Λειτουργίας των Κατασκευών**

Προκειμένου να σχεδιαστεί ένα σύστημα ΠΔΚ, πρέπει να λαμβάνονται υπόψιν κάθε φορά τα αντικείμενα που ενδιαφέρουν να παρατηρηθούν, καθώς και τα χαρακτηριστικά της κάθε κατασκευής. Μέσα στις ανάγκες που μπορεί να έχει μία κατασκευή είναι η συντήρηση, η επισκευή ή η αντικατάστασή της ή μέρους αυτής. Επομένως, γίνεται αντιληπτό πως ένα σύστημα ΠΔΚ πρέπει να είναι αρκετά ακριβές, ώστε να παρέχει τις απαραίτητες πληροφορίες για τη δυναμική ή την στατική συμπεριφορά των δομικών στοιχείων της υπό μελέτη κατασκευής. Ιδανικά, το σύστημα ΠΔΚ θα πρέπει να παρέχει πληροφορίες για όλες τις ενέργειες που απαιτείται να εφαρμοσθούν σχετικά με τις υπάρχουσες ζημιές στην κατασκευή.

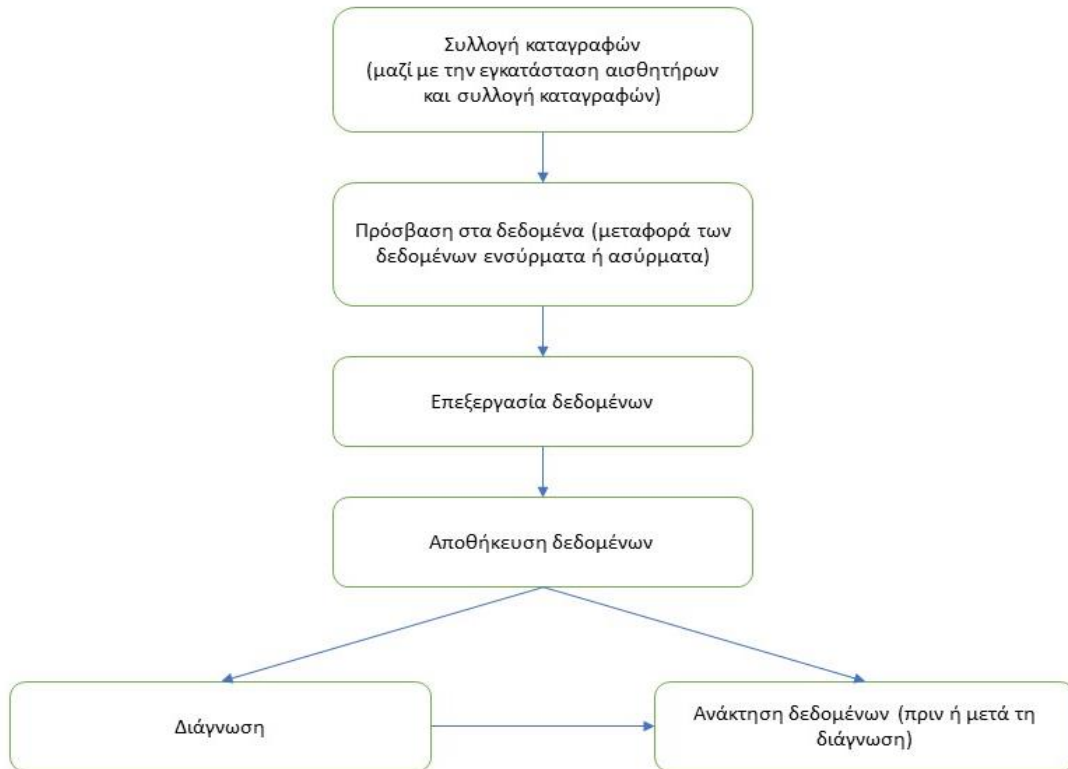
### **1.4.1 Αρχές σχεδιασμού συστημάτων ΠΔΚ των κατασκευών**

Με την εγκατάσταση ενός συστήματος ΠΔΚ σε μία κατασκευή, λαμβάνονται σε πραγματικό χρόνο πληροφορίες σχετικά με τη δομική κατάστασή της, μέσω τοπικού δικτύου ή με διαβίβαση αυτομάτως σε απομακρυσμένη θέση. Η ανάπτυξη ενός τέτοιου συστήματος απαιτεί γνώσεις που αγγίζουν πολλαπλούς επιστημονικούς κλάδους όσον αφορά τις κατασκευές, τα υλικά, τους αισθητήρες, την ανίχνευση βλαβών, την επεξεργασία των δεδομένων και την καταγραφή τους, τις επικοινωνίες και τους υπολογιστές.

Ένα σύστημα ΠΔΚ απαρτίζεται από αρκετά σύνολα, μερικά εκ των οποίων είναι:

- Η συλλογή των δεδομένων
- Η επικοινωνία των δεδομένων
- Η κατάλληλη επεξεργασία των δεδομένων
- Η αποθήκευση των επεξεργασμένων δεδομένων
- Η διάγνωση
- Η ανάκτηση των δεδομένων

Τα σύνολα αυτά αναλύονται περαιτέρω στο Σχήμα 1-1 και είναι φανερό πως η ροή των διαδικασιών λήψης της πληροφορίας μπορεί να ακολουθεί περισσότερες από μία διαδρομές.



**Σχήμα 1-1:** Υποσύνολα συστήματος ΠΔΚ  
**Figure 1-1:** Subsets of an SHM system

Ακόμη, ένα σύστημα ΠΔΚ αποτελείται από διάφορες διατάξεις και μετρητικά όργανα, όπως:

- Σύστημα αισθητήρων
- Σύστημα συλλογής μετρήσεων
- Σύστημα διασύνδεσης και ρύθμισης του συστήματος αισθητήρων για την μεταφορά των δεδομένων
- Σύστημα επεξεργασίας και ανάλυσης δεδομένων
- Σύστημα αξιολόγησης και εκτίμησης των αποτελεσμάτων

Προκειμένου να επιλεγεί το κατάλληλο σύστημα, μέσα από την πληθώρα αισθητήρων και τεχνικών που υφίστανται, πρέπει να αξιολογηθούν κάποιοι παράγοντες. Αρχικά, τα γεωμετρικά χαρακτηριστικά, οι διαστάσεις και τα υλικά της κατασκευής, ορίζουν την στατική και δυναμική συμπεριφορά της κατασκευής, επομένως είναι οι βασικότεροι παράγοντες που πρέπει να λαμβάνονται υπόψιν. Τα χαρακτηριστικά αυτά, συνδέονται άμεσα και εξαρτώνται από το πεδίο στο οποίο μπορεί να μετρήσει το όργανο, την απαιτούμενη συχνότητα δειγματοληψίας και το εύρος στο οποίο γίνονται οι μετρήσεις από τον αισθητήρα.

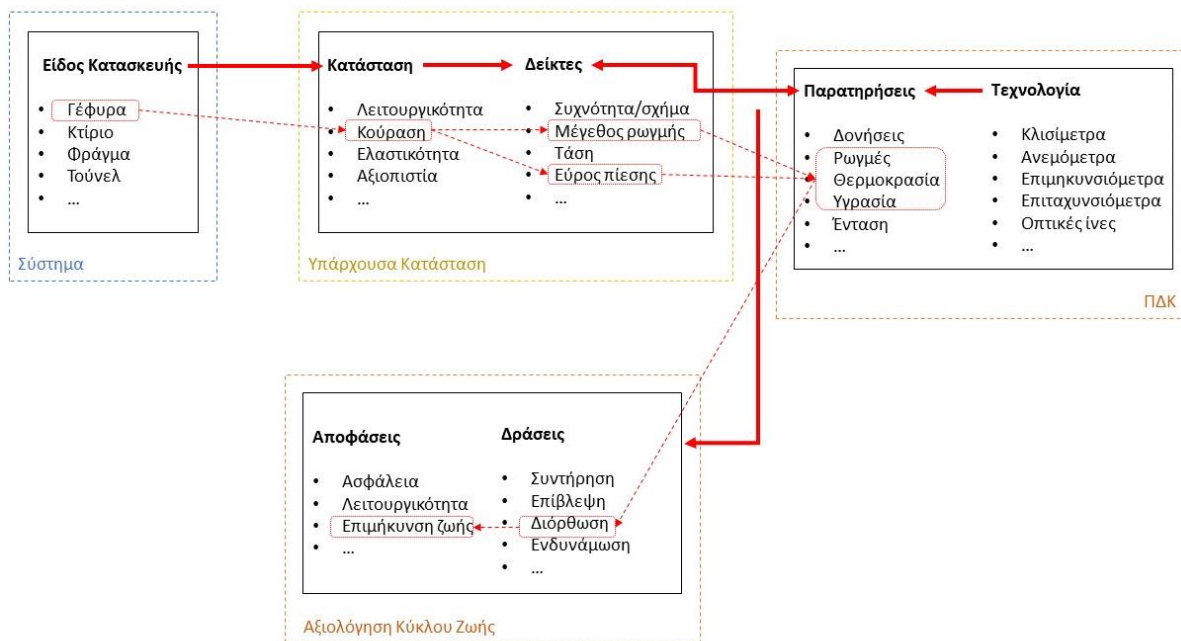
Ακόμη, η επιλογή των κατάλληλων σημείων για την εγκατάσταση του συστήματος αισθητήρων, είναι αρκετά σημαντική, ώστε να αποτυπώνεται σωστά η συμπεριφορά της κατασκευής. Η χρονική διάρκεια κατά την οποία θα παραμείνουν οι αισθητήρες στο χώρο μέτρησης, αλλά και οι επικρατούσες περιβαλλοντικές συνθήκες για την περίοδο αυτή είναι εξίσου σημαντικοί παράγοντες, όπως και η ακρίβεια που επιθυμείται να επιτευχθεί. Όλοι οι παραπάνω παράγοντες καθορίζουν τελικά και τα όργανα τα οποία μπορούν να χρησιμοποιηθούν.

#### **1.4.2 Στρατηγικές ΠΔΚ των κατασκευών**

Προκειμένου να επιτευχθούν οι βασικοί στόχοι της παρακολούθησης δομικής κατάστασης σε μία κατασκευή, είναι σημαντικό να χρησιμοποιηθούν οι κατάλληλες στρατηγικές ΠΔΚ σε αυτήν. Μία καλή στρατηγική παρακολούθησης μπορεί να βοηθήσει στη βέλτιστη διαχείριση των ήδη υπαρχόντων πόρων, όπως στην επιλογή αισθητήρων. Η επιλογή αυτή, εξαρτάται από πολλούς παράγοντες, συμπεριλαμβανομένου του είδους της κατασκευής, τα λειτουργικά φορτία, τις περιβαλλοντικές επιδράσεις, πιθανές πηγές φθορών και μηχανισμούς αλλοίωσης που είναι πιθανό να εμφανιστούν κατά τη διάρκεια ζωής της κατασκευής.

Η παρακολούθηση μεγάλων υπαρχόντων κατασκευών είναι πολύ σημαντική για την οικονομία και την κοινωνία. Η επίγνωση της «υγείας» και της ακεραιότητας μίας κατασκευής ακόμη και από την στιγμή που κατασκευάζεται και λειτουργεί είναι μείζονος σημασίας. Κατασκευές όπως γέφυρες, ψηλά κτίρια, αυτοκινητόδρομοι και υπόγεια τούνελ, συχνά υπόκεινται σε πολύπλοκα φορτία λόγω του σκληρού περιβάλλοντος στο οποίο βρίσκονται. Επομένως, λόγω της ποικιλομορφίας των κατασκευών και των συνθηκών στις οποίες η κάθε μία βρίσκεται, δεν μπορεί να υπάρχει μία καθολική στρατηγική για τη διαχείρισή τους. Ωστόσο, η κατάλληλη στρατηγική ΠΔΚ πρέπει να επιλεγεί ώστε να πραγματοποιηθεί ουσιαστική αξιολόγηση για την κάθε κατασκευή.

Η κατάλληλη, λοιπόν, στρατηγική μπορεί να επιλεγεί μέσα από την αναλυτική μελέτη όλων των εναλλακτικών μέσα από τη γνώση και την εμπειρία του μηχανικού. Με την πάροδο των ετών, υπάρχει μεγάλη τεχνολογική εξέλιξη γύρω από τον τομέα της ΠΔΚ, με αποτέλεσμα να μπορούν να αξιοποιηθούν όλο και περισσότερες στρατηγικές σε μία κατασκευή. Στο Σχήμα 1-2 παρουσιάζονται οι διαφορετικές δομές και ο τρόπος με τον οποίο μπορούν να εξετασθούν οι διαφορετικές επιλογές και λύσεις σε ένα σύστημα ΠΔΚ.



**Σχήμα 1-2:** Παράδειγμα των διάφορων παραγόντων που εμπλέκονται στην ΠΔΚ  
**Figure 1-2:** Example of the different components involved in SHM

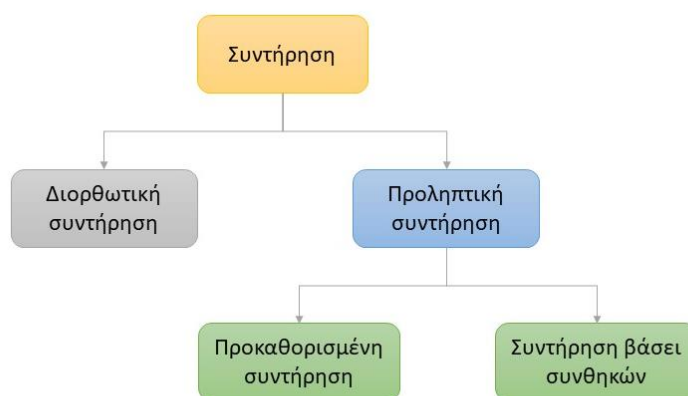
Όπως αναφέρθηκε και παραπάνω, υπάρχουν τέσσερα υποσυστήματα που απαρτίζουν ένα σύστημα ΠΔΚ. Το πρώτο υποσύστημα, που αφορά τις μεθόδους στατικών δοκιμών, υποδιαιρείται σε δοκιμές απόκρισης, διαγνωστικές δοκιμές και δοκιμές επαλήθευσης. Το δεύτερο, οι δυναμικές δοκιμές της κατασκευής, υποδιαιρείται σε δοκιμές ιστορικού τάσεων, ανοχής δυναμικών φορτίσεων, περιβαλλοντικών διεγέρσεων και ελεύθερης ταλάντωσης (*pull back*).

Η περιοδική παρακολούθηση, η οποία χρησιμοποιήθηκε στην μελέτη της παρούσας διπλωματικής εργασίας μαζί με συνεχή παρακολούθηση, πραγματοποιείται για την διερεύνηση αλλαγών που είναι επιβλαβείς και μπορεί να συμβαίνουν στην κατασκευή ή στην λειτουργική της κατάσταση. Η συνεχής παρακολούθηση συχνά εφαρμόζεται μόνο σε κατασκευές μεγάλης σπουδαιότητας ή όταν υπάρχουν αμφιβολίες για τη δομική τους ακεραιότητα. Σε περίπτωση που ισχύει το δεύτερο, η κατασκευή θα πρέπει πριν να έχει πιθανότητα εκτεθεί σε ακραία φυσικά φαινόμενα, όπως σεισμούς ή τυφώνες, ή κατά τον σχεδιασμό της να εφαρμόστηκαν νέες τεχνικές οι οποίες σε βάθος χρόνου αποφάνθηκαν μη λειτουργικές. Αντίστοιχα, με την περιοδική παρακολούθηση μπορούν να ελεγχθούν γέφυρες οι οποίες να έχουν κατασκευαστεί με καινοτόμες τεχνικές, ενώ σε συνδυασμό με τις δοκιμές πεδίου μπορούν να επεκτείνουν το χρόνο ζωής μίας κατασκευής της οποίας η δομική κατάσταση επιδεινώνεται σχετικά γρήγορα.

Η περιοδική καταγραφή για την απόκριση μίας γέφυρας μπορεί να αξιοποιηθεί για τον προσδιορισμό αλλαγών στην συμπεριφορά της. Τονίζεται πως όταν μελετώνται

με αυτή την τεχνική περιβαλλοντικές διεγέρσεις, τα όργανα δεν πρέπει να μετακινηθούν από τις θέσεις στις οποίες εγκαθίστανται αρχικά, όταν έχουν προσδιοριστεί οι κρίσιμες θέσεις. Όταν μελετώνται και φορτία που μεταδίδονται στη γέφυρα από την κυκλοφορία οχημάτων, ένα μέτρο αποδοτικότητας αποτελεί ο τρόπος με τον οποίο κατανέμονται στις δοκούς τα φορτία από τα οχήματα. Τέλος, η εφαρμογή στατικών δοκιμών σε συνδυασμό με την περιοδική παρακολούθηση είναι αρκετά σπάνια καθώς είναι και αρκετά δαπανηρή, ωστόσο υπάρχουν εφαρμογές που τις συνδυάζουν και αφορούν παρακολούθηση επεμβάσεων και διεύρυνση ρηγματώσεων.

Όσον αφορά τις στρατηγικές συντήρησης μίας κατασκευής, όπως παρουσιάζονται και στο Σχήμα 1-3, τα δεδομένα που αξιοποιούνται συλλέγονται μέσα από την παρακολούθηση της συμπεριφοράς της κατασκευής.



**Σχήμα 1-3:** Στρατηγικές συντήρησης σύμφωνα με τον EN 13306  
**Figure 1-3:** Maintenance strategies according to EN 13306  
(Πηγή: [7])


Η στρατηγικές αυτές βασίζονται στον εντοπισμό αλλαγών στην συμπεριφορά της κατασκευής μελέτης, οι οποίες όμως μαρτυρούν απόκλιση από την κανονική λειτουργική πορεία. Σε συνδυασμό με την παρακολούθηση των δομικών στοιχείων του φορέα, χρησιμοποιείται διαγνωστικός εξοπλισμός προκειμένου να συσχετιστούν οι παρατηρήσεις με τα σφάλματα που παρουσιάζονται. Ουσιαστική η χρήση αυτών των στρατηγικών μπορεί να θεωρηθεί πως ακολουθεί τρία βήματα, όπως φαίνονται και στο Σχήμα 1-4.

- Συλλογή δεδομένων και αποθήκευσή τους, όπως τα εύρη δονήσεων που παρατηρήθηκαν σε ένα συγκεκριμένο συστατικό στοιχείο της κατασκευής.
- Επεξεργασία των δεδομένων προκειμένου να επιλεγεί ποια δεδομένα πρόκειται να χρησιμοποιηθούν μέσα από τον μεγάλο όγκο που έχει καταγραφεί. Μέσα από αυτή τη διαδικασία, προκύπτουν αρκετά στοιχεία από τα αρχικά ακατέργαστα δεδομένα, τα οποία αποτυπώνουν την κατάσταση του



παρακολουθούμενου φορέα. Ακόμη, είναι απαραίτητο ένα βήμα διάγνωσης, όπου θα γίνει συσχέτιση των παρατηρήσεων με τα σφάλματα που εμφανίζονται. Επομένως, το βήμα αυτό καλύπτει την ανάλυση των δεδομένων και την ερμηνεία τους, σκοπεύοντας στον εντοπισμό πιθανών φθορών που αναπτύσσονται και την ανίχνευσή τους.

- Τελικό βήμα είναι η πρόγνωση της εναπομένουσας ζωής της κατασκευής, που προκύπτει μέσα από τα δεδομένα της παρακολούθησης της συμπεριφοράς της, προκειμένου να πραγματοποιηθεί η συντήρηση και βελτιστοποίησή της. Με τα δεδομένα του προηγούμενου βήματος, δηλαδή τις αναπτυσσόμενες φθορές και την ανίχνευση των ήδη υπαρχόντων, το βήμα αυτό στοχεύει στον υπολογισμό της χρονικής περιόδου κατά την οποία αυτές θα εμφανιστούν.



**Σχήμα 1-4:** Διαδικασία τριών βημάτων για τη χρήση δεδομένων παρατήρησης συμπεριφοράς κατασκευής για συντήρηση βάσει των υφιστάμενων συνθηκών

**Figure 1-4:** Three-step process of condition monitoring data utilization for condition-based maintenance (Πηγή: [7])

## ΚΕΦΑΛΑΙΟ 2 - ΤΕΧΝΟΛΟΓΙΕΣ ΚΑΙ ΣΥΣΤΗΜΑΤΑ ΠΑΡΑΚΟΛΟΥΘΗΣΗΣ ΔΟΜΙΚΗΣ ΚΑΤΑΣΤΑΣΗΣ ΚΑΤΑΣΚΕΥΩΝ

### 2.1 Εισαγωγικά

Εστιάζοντας στις γέφυρες, ως μεγάλα τεχνικά έργα, εμφανίζουν φθορές με το πέρας του χρόνου και ως φυσικό επόμενο, ελαττώνεται ο χρόνος ζωής τους και το επίπεδο εξυπηρέτησής τους. Οι φθορές αυτές, όπως αναφέρθηκε στο προηγούμενο κεφάλαιο, οφείλονται σε πολλαπλούς παράγοντες όπως λόγω των υλικών κατασκευής, του κυκλοφοριακού φόρτου, επιδράσεις περιβαλλοντικών συνθηκών, έλλειψη συντήρησης ή και λάθη που προέρχονται από τον σχεδιασμό και την κατασκευή. Προκειμένου να διορθωθούν όλα τα προαναφερθέντα, απαιτούνται συστήματα παρακολούθησης της δομικής κατάστασης των γεφυρών.

Για την παρακολούθηση των γεφυρών χρησιμοποιούνται διάφορες τεχνικές, όπως ο οπτικός έλεγχος, ο ενόργανος οπτικός έλεγχος και τα έξυπνα συστήματα παρακολούθησης, όπου χρησιμοποιούνται σύγχρονα τεχνολογικά μέσα και η επεξεργασία των μετρητικών δεδομένων πραγματοποιείται μέσω προσομοιωμάτων σε υπολογιστές. Ο οπτικός έλεγχος, αφορά την επιφανειακή επιθεώρηση της κατασκευής και την συμπλήρωση ερωτηματολογίων, από όπου μέσω βαθμολογίας οδηγεί στην κρίση της κατάστασης της κατασκευής. Η δεύτερη τεχνική, ο ενόργανος οπτικός έλεγχος, είναι πιο λεπτομερής της πρώτης, καθώς οι εκτιμήσεις της κατάστασης των μελών της κατασκευής πραγματοποιούνται μέσω πειραματικών στοιχείων. Τα δεδομένα συγκεντρώνονται σε βάσεις δεδομένων, όπου μετά από την επεξεργασία τους δίνεται η τελική εκτίμηση για τη φέρουσα ικανότητα της γέφυρας που μελετάται. Στις ίδιες βάσεις δεδομένων αποθηκεύονται και στοιχεία για τις πιθανές μορφές βλαβών και τους τρόπους συντήρησης που μπορούν να εφαρμοσθούν ανάλογα με την βλάβη που έχει εμφανιστεί.

Η πρώτη τεχνική, ο οπτικός έλεγχος, εφαρμόζεται από έμπειρους μηχανικούς οι οποίοι μετά από επιφανειακή επιθεώρηση της γέφυρας εντοπίζουν βλάβες ή φθορές που ενδέχεται να έχουν εμφανιστεί. Για αποφυγή της υποκειμενικής κρίσης του ελεγκτή μηχανικού, η έρευνα συνοδεύεται από φωτογραφικό υλικό, video και ειδικά διαμορφωμένα ερωτηματολόγια. Ο έλεγχος αυτός στηρίζεται κατά μεγάλο μέρος στην εμπειρία του ελεγκτή με συνέπεια την ανεπαρκή διάγνωση μη επιφανειακών φθορών. Η δεύτερη τεχνική, ο ενόργανος οπτικός έλεγχος, είναι προτιμότερος της πρώτης και απαιτεί λεπτομερή σχεδιασμό από εξίσου έμπειρους μηχανικούς και συνεργείο για τον χειρισμό των εργαλείων και τον έλεγχο συγκεκριμένων σημείων. Το μειονέκτημα αυτής της τεχνικής, είναι η μεγάλη διασπορά των τιμών των αποτελεσμάτων, ωστόσο ελέγχονται στατιστικά και για το λόγο αυτό απαιτείται μεγάλος όγκος παρατηρήσεων.

Η τρίτη τεχνική, όπου χρησιμοποιούνται διάφορα όργανα για τη λήψη των μετρήσεων και απαιτείται πριν την έναρξή τους να ενεργοποιηθούν όσα συστήματα χρησιμοποιούνται με κάποια διέγερση. Ύστερα, ακολουθεί η επεξεργασία των

δεδομένων, από όπου προκύπτει η δυναμική απόκριση της γέφυρας λόγω τυχαίων διεγέρσεων και ακόμη, πραγματοποιείται η λεγόμενη «ιδιομορφική αναγνώριση» (*modal identification*). Τέλος, γίνεται μία αναθεώρηση του αρχικού μοντέλου από το οποίο θα πραγματοποιηθεί η διάγνωση βλαβών και η διαδικασία στατικής ανεπάρκειας της κατασκευής. Τα χρησιμοποιούμενα όργανα ανήκουν σε δύο κατηγορίες, αυτά που συνδέονται ενσύρματα με τις μονάδες παρακολούθησης και αυτά που συνδέονται ασύρματα με τις οθόνες ελέγχου. Ωστόσο, το κόστος για τη χρήση οποιασδήποτε από τις δύο κατηγορίες είναι αρκετά υψηλό, καθιστώντας την τεχνική αυτή αρκετά σπάνια σε εφαρμογή σε σύγκριση με όλα τα είδη ελέγχων που γίνονται στις γέφυρες.

Σε γενικό πλαίσιο στην ΠΔΚ, οι μέθοδοι παρακολούθησης της συμπεριφοράς των κατασκευών μπορούν να διαχωριστούν σε τοπογραφικές μεθόδους και μεθόδους πειραματικής μηχανικής.

## 2.2 Τοπογραφικές Μέθοδοι

Οι τοπογραφικές μέθοδοι αποτελούν τον πιο συνηθισμένο τρόπο παρακολούθησης της δομικής κατάστασης τεχνικών έργων. Έχουν εδραιωθεί αρκετές μέθοδοι βασιζόμενες κυρίως στα συστήματα δορυφορικού εντοπισμού *GNSS*, σε ρομποτικούς γεωδαιτικούς σταθμούς ακριβείας (*RTS – Robotic Total Station*), σε επίγεια μικροκυματικά *radar* και σαρωτές *laser*, όπως αναλύονται και στην συνέχεια.

Βασικό πλεονέκτημα των μεθόδων αυτών έναντι της αποκλειστικής χρήσης αισθητήρων αποτελεί το γεγονός ότι παρέχουν άμεσα μετρήσεις που αναφέρονται σε προκαθορισμένο σύστημα αναφοράς. Επομένως, μεγέθη όπως η μετακίνηση, η ταχύτητα και η επιτάχυνση, προκύπτουν άμεσα αποφεύγοντας πολύπλοκους υπολογισμούς.

### 2.2.1 Συστήματα συμβατικής και δορυφορικής γεωδαισίας

- Ρομποτικοί Γεωδαιτικοί Σταθμοί (RTS)

Οι Ρομποτικοί Γεωδαιτικοί Σταθμοί (*RTS – Robotic Total Station*) αποτελούν την εξέλιξη των απλών γεωδαιτικών σταθμών και χαρακτηρίζονται από τη δυνατότητα προγραμματισμού ανίχνευσης και παρακολούθησης κινούμενου στόχου, με συχνότητα καταγραφής έως και 10 Hz και τηλεχειρισμού. Τα τελευταία χρόνια χρησιμοποιούνται αρκετά στην παρακολούθηση μετακινήσεων κτιρίων και εδάφους, ιδίως κατά τη διάρκεια κατασκευής σηράγγων και ορυχείων, καθώς και για την παρακολούθηση της δομικής κατάστασης γεφυρών και φραγμάτων.



**Σχήμα 2-1:** Ρομποτικός Γεωδαιτικός Σταθμός – Leica Nova TM50  
**Figure 2-1:** Robotic Total Station – Leica Nova TM50  
(Πηγή: [www.leica-geosystems.com](http://www.leica-geosystems.com))

Η βασική αρχή λειτουργίας τους είναι όμοια με αυτή των απλών γεωδαιτικών σταθμών, όσον αφορά την μέτρηση και καταγραφή γωνιών και μηκών. Επιπλέον, παρέχεται αυτόματη περιστροφή του τηλεσκοπίου στους δύο άξονες, πρωτεύοντα και δευτερεύοντα, αυτόματη αναγνώριση και παρακολούθηση στόχου (*ATR – Automatic Target Recognition*) και τηλεχειρισμό. Η λειτουργία των *RTS* βασίζεται στο σερβοκινητήρα και σε έναν μικρο-επεξεργαστή που επιτρέπουν όλες τις παραπάνω αυτοματοποιημένες κινήσεις. Ακόμη, από το όργανο εκπέμπεται μία δέσμη *laser* η οποία ανακλάται από τον στόχο και επιστρέφει στο γεωδαιτικό σταθμό. Με την μέθοδο των πολικών συντεταγμένων, μετρώντας μήκη και γωνίες, είναι επίσης εφικτός ο εντοπισμός των σημείων και ο ορισμός των συντεταγμένων τους σε τοπικό σύστημα αναφοράς που ορίζεται με τη βοήθεια *H/Y*.

Η εφαρμογή των ρομποτικών γεωδαιτικών σταθμών παρουσιάζει πληθώρα πλεονεκτημάτων, για τον λόγο αυτό θεωρούνται και ιδανικά για την μελέτη της ακεραιότητας κατασκευών. Κάποια από τα πλεονεκτήματα τους είναι τα εξής:

- Είναι κατάλληλοι για την ακριβή παρακολούθηση ταλαντώσεων και δυναμικών κινήσεων, αφού μπορούν να καταγράψουν με πολύ υψηλή ακρίβεια το εύρος τους ακόμα και όταν πρόκειται για μικρές ταλαντώσεις.
- Ακόμη και σε χαμηλής συχνότητας ταλαντώσεις, μπορεί να προσδιοριστεί η συχνότητα διέγερσης με ακρίβεια, ενώ για υψηλής συχνότητας το *RTS* απαιτεί διαφορετική διάταξη και χρήση κατάλληλου λογισμικού.
- Δίνεται η δυνατότητα βελτίωσης των μετρήσεων με την τοποθέτηση του οργάνου σε απόσταση τέτοια ώστε να είναι ακριβής η κίνηση του σημείου παρακολούθησης, ακόμα και σε μεγάλα εύρη ταλάντωσης.

Τέλος, κάποια μειονεκτήματα της μεθόδου είναι τα εξής:

- Πρέπει να τοποθετηθεί πρίσμα στο σημείο ελέγχου, γεγονός που δυσκολεύει τη διαδικασία αφού αυτό δεν είναι εφικτό σε όλες τις περιπτώσεις.
  - Η ποιότητα των μετρήσεων επηρεάζεται σε μεγάλο βαθμό από τις καιρικές συνθήκες.
  - Η συμπεριφορά της κατασκευής μελετάται από μόνο ένα σημείο παρατήρησης.
- Δορυφορικό Σύστημα Εντοπισμού (GNSS – Global Navigation Satellite System)

Με τη χρήση των δορυφορικών συστημάτων πλοήγησης, είναι πλέον δυνατός ο εντοπισμός της θέσης και ταχύτητας ενός αντικειμένου σε πραγματικό χρόνο, αλλά και η καταγραφή της τροχιάς του. Με την αναφορά σε δορυφορικά συστήματα εντοπισμού θέσης εννοείται ο προσδιορισμός των τρισδιάστατων συντεταγμένων ενός σημείου στην επιφάνεια της Γης, που προκύπτει μέσω επεξεργασίας μετρήσεων ή από τεχνητούς δορυφόρους.

Το δορυφορικό σύστημα που χρησιμοποιείται κατά κόρον σήμερα είναι το NAVSTAR GPS (*NAVigation Satellite Timing and Ranging, Global Positioning System*) ή GPS. Το σύστημα αυτό αναπτύχθηκε από το Υπουργείο Αμύνης των ΗΠΑ κατά το 1980 και πρόκειται για ένα στρατιωτικό και πολιτικό σύστημα με βασικό στόχο την κάλυψη αναγκών πλοήγησης σε στρατιωτικό και πολιτικό τομέα. Ακόμη, έχει ιδρυθεί το ρωσικό σύστημα GLONASS, το οποίο ακόμη δεν είναι το ίδιο επιχειρησιακό με το διαδεδομένο GPS. Στην Ευρωπαϊκή Ένωση έχει επίσης ιδρυθεί το πρώτο δορυφορικό σύστημα εντοπισμού θέσης και πλοήγησης για πολιτική χρήση, το *EGNOS (European Geostationary Navigation Overlay Service)* και το σύστημα *GALILEO*, που είναι τα ανερχόμενα συστήματα που πρόκειται να χρησιμοποιούνται για μία γκάμα νέων υπηρεσιών. Στα ίδια πλαίσια, η Λαϊκή Δημοκρατία της Κίνας κατασκευάζει από το 2010 στην επέκταση ενός δικού τους τοπικού συστήματος, του *BEIDOU*, το παγκόσμιο σύστημα εντοπισμού *COMPASS*.

Τα τελευταία χρόνια τα συστήματα δορυφορικού εντοπισμού χρησιμοποιούνται σε αρκετές μελέτες για την παρακολούθηση δομικής κατάστασης τεχνικών έργων, όπως γέφυρες, φράγματα και ψηλά κτίρια. Με την μέτρηση των τρισδιάστατων συντεταγμένων, τα GNSS είναι κατάλληλα για στατικές ή δυναμικές μελέτες και καθιστούν δυνατή την αξιολόγηση της δομικής συμπεριφοράς της υπό μελέτη κατασκευής, βάσει των δυναμικών φορτίων που δέχεται ή και από ημι-στατικά φαινόμενα.

Για την λειτουργία τους, απαιτούνται δύο επίγειοι δέκτες, όπου ο ένας θεωρείται ο σταθμός αναφοράς και ο άλλος ο κινούμενος δέκτης. Ο πρώτος τοποθετείται σε κάποιο σταθερό σημείο εκτός της κατασκευής, ενώ ο δεύτερος σε σημείο που επιθυμείται να ελεγχθεί, χωρίς να απαιτείται να υπάρχει ορατότητα μεταξύ τους. Στην ΠΔΚ αξιοποιούνται κατά βάση ο κινηματικός εντοπισμός σε πραγματικό χρόνο


(RTK – Real Time Kinematic) και η δικτυακή τεχνική RTK – NRTK. Με τη χρήση των GNSS επιτυγχάνεται η απόκριση των δυναμικών φαινομένων έως και 50 Hz.

Τα κύρια πλεονεκτήματα της μεθόδου δορυφορικού εντοπισμού είναι τα ακόλουθα:

- Η συχνότητα καταγραφής είναι υψηλή (20 Hz και σε ερευνητικό επίπεδο έως 100 Hz) προκειμένου να καλύπτει και τις ιδιοσυχνότητες των κατασκευών.
- Ανεξάρτητη των καιρικών συνθηκών.
- Δεν απαιτείται χρονοβόρα προετοιμασία.
- Απλή διαδικασία λήψης μετρήσεων.
- Συνδυάζεται με άλλα συστήματα προσδιορισμού θέσης και άλλες εφαρμογές.
- Δεν είναι αναγκαία η αμοιβαία ορατότητα μεταξύ των δεκτών κατά τη διάρκεια των μετρήσεων, αλλά μόνο η ορατότητα προς τουλάχιστον 4 κοινούς δορυφόρους.
- Οι μετρήσεις λαμβάνονται οποιαδήποτε ώρα, μέρα ή και νύχτα.
- Δίνεται καλή ακρίβεια στα οριζοντιογραφικά δεδομένα.

Ωστόσο, υπάρχουν και μειονεκτήματα στην μέθοδο, όπως:

- Η απαίτηση ανοικτού ορίζοντα, προκειμένου να επιτυγχάνεται η οπτική επαφή με ικανοποιητικό αριθμό δορυφόρων από κάθε δέκτη, γεγονός που την καθιστά δύσκολη για εφαρμογές σε πυκνοδομημένες περιοχές.
- Το σήμα που αποστέλλουν οι δορυφόροι επηρεάζεται από την ηλεκτρομαγνητική ακτινοβολία που ενδέχεται να υφίσταται σε περιοχές που εγκαθίσταται ο δέκτης.
- Το σήμα των δορυφόρων αν ανακλαστεί πολλές φορές πριν φτάσει στον δέκτη εμφανίζει το φαινόμενο των πολλαπλών διαδρομών.
- Τα υψόμετρα δεν λαμβάνονται με καλή ακρίβεια σε σύγκριση με τα οριζοντιογραφικά στοιχεία.
- Οι μετρήσεις που λαμβάνονται ενδέχεται να περιέχουν σφάλματα προερχόμενα από τη γεωμετρία των δορυφόρων, γεγονός που οδηγεί σε αναξιόπιστα αποτελέσματα.



**Σχήμα 2-2:** Σχηματική απεικόνιση εφαρμογής GNSS σε παρακολούθηση δομικής κατάστασης γέφυρας  
**Figure 2-2:** Schematic presentation of GNSS application for bridge monitoring

### 2.2.2 Επίγειοι σαρωτές *laser*

Οι επίγειοι σαρωτές *laser* είναι ένα είδος οργάνων που καταγράφουν και αποτυπώνουν τον τρισδιάστατο χώρο και παρέχουν σε πραγματικό χρόνο τα 3D δεδομένα στο χρήστη. Τα τελευταία χρόνια χρησιμοποιούνται σε αρκετές εφαρμογές παρακολούθησης δομικών έργων, ενώ τα μήκη κύματος που χρησιμοποιούν για τις εφαρμογές αυτές είναι το ορατό και το υπέρυθρο φάσμα της ηλεκτρομαγνητικής ακτινοβολίας.

Εκτός των πολικών συντεταγμένων, που μετρούνται μέσα από μετρήσεις αποστάσεων και γωνιών, τα όργανα αυτά μετρούν και την ανακλαστικότητα του κάθε σημείου και έχουν τη δυνατότητα να βγάλουν ψηφιακές φωτογραφίες του αντικειμένου που αποτυπώνεται. Τα δεδομένα συλλέγονται ομοιόμορφα κατανεμημένα 3D είτε έγχρωμα, είτε *gray-scaled* σημεία με την ανάλυση που ζητείται, αποτελώντας έτσι ένα νέφος σημείων. Το πλήθος των καταγραφόντων σημείων εξαρτάται από τη γωνιακή ανάλυση του οργάνου, η οποία αναλύεται συναρτήσει του γωνιακού βήματος των κινητήρων που περιστρέφουν τη μετρητική κεφαλή γύρω από τον κατακόρυφο και τον οριζόντιο άξονα και από την ανάλυση του δίσκου κώδικα *Gray* που είναι τοποθετημένος σε κάθε άξονα. Κάθε σύγχρονος σαρωτής μπορεί να καταγράψει από μερικές εκατοντάδες σημεία έως μερικά εκατομμύρια ανά στάση σάρωσης.

Οι επίγειοι σαρωτές *laser* χωρίζονται σε δύο είδη σαρωτών, που εξαρτώνται από τον τρόπο εκπομπής της δέσμης *laser*:

- **Σαρωτές διαφοράς φάσης (Phase shift laser scanners):** οι σαρωτές αυτοί πετυχαίνουν πολύ υψηλή ακρίβεια στα τελικά τους προϊόντα, καθιστώντας τους κατάλληλους για την παρακολούθηση φαινομένων δυναμικής μετατόπισης. Η συχνότητα καταγραφής τους αγγίζει τα 1000K σημεία/sec, ενώ μοναδικό μειονέκτημά τους είναι η μικρή τους εμβέλεια, που φτάνει περίπου τα 70 m.



**Σχήμα 2-3:** 3D Επίγειος Σαρωτής Laser Διαφοράς Φάσης – Leica RTC360  
**Figure 2-3:** Terrestrial Phase-shift 3D Laser Scanner – Leica RTC360  
 (Πηγή: [www.leica-geosystems.com](http://www.leica-geosystems.com))

- **Σαρωτές *time-of light* (ToF laser scanners):** οι σαρωτές αυτοί μετρούν τη χρονική διαφορά μεταξύ του εκπεμπόμενου και του λαμβανόμενου σήματος και βάσει της ταχύτητας του φωτός. Η μέτρηση της διαφοράς χρόνου πραγματοποιείται με διάφορες τεχνικές, με πιο διαδεδομένη αυτή της μετάδοσης παλμού και της διαμόρφωσης του φέροντος κύματος. Η χρήση τους έγκειται κυρίως στη γεωμετρική τεκμηρίωση κατασκευών, ενώ στο πεδίο είναι σχετικά αργοί στην καταγραφή με συχνότητα καταγραφής 40-50.000 σημεία/sec.

Η ακρίβεια προσδιορισμού των συντεταγμένων με χρήση επίγειων σαρωτών *laser* είναι διαφορετική ανάλογα με το αντικείμενο που σαρώνεται, όμως μπορεί να φτάσει έως και το επίπεδο των μερικών mm. Η ακρίβεια μπορεί να επηρεαστεί από τη μέθοδο σάρωσης που εφαρμόζεται, την απόσταση από το αντικείμενο, τον αριθμό των μετρήσεων, την ταχύτητα σάρωσης και το υλικό της επιφάνειας που σαρώνεται.

### 2.2.3 Επίγειο σύστημα μικροκυματικού *radar*

Το επίγειο *radar* πραγματικού ή συνθετικού ανοίγματος (*GB-RAR/SAR*) λειτουργεί βάσει των αρχών της μικροκυματικής συμβολομετρίας. Χρησιμοποιείται στην παρακολούθηση κατασκευών όπως γέφυρες. Τα επίγεια συστήματα *radar* (*Ground based SAR*) χάρη στην βάση λειτουργίας τους μπορούν να ανιχνεύουν μετακινήσεις σε μία διεύθυνση με αρκετά υψηλή χωρική ανάλυση και ακρίβεια που αγγίζει έως



και το δέκατο του χιλιοστού. Μέσα από τη χρήση τους λαμβάνονται πληροφορίες που αφορούν την παραμόρφωση της επιφάνειας που μετράται.

Η κατηγοριοποίησή του γίνεται σε τρεις τεχνικές:

- Διαμόρφωση ηλεκτρομαγνητικής ακτινοβολίας (*Stepped-Frequency Continuous Wave – SF-CW*) για τον υπολογισμό του εύρους ανάλυσης
- Συμβολομετρία (*interometry technique*), για τον προσδιορισμό της μετατόπισης ενός αντικειμένου με υψηλή ακρίβεια
- *GB-SAR* για την απόκτηση του αζιμουθίου ή την τομή δύο επιπέδων για υψηλότερη ακρίβεια, καθώς μετρά σε δύο διευθύνσεις

Η τεχνολογία που χρησιμοποιείται από τα επίγεια μικροκυματικά *radar* ονομάζεται *Image By Interferometric Survey* ή *IBIS*, η οποία είναι διαφορετική από τις υπόλοιπες που εφαρμόζονται για την μέτρηση μετακινήσεων σε κατασκευές όσον αφορά τις στατικές και τις δυναμικές μετατοπίσεις. Για την στατική παρακολούθηση των κατασκευών πραγματοποιούνται έλεγχοι για τα φορτία που επενεργούν σε αυτές και ελέγχονται πιθανοί κίνδυνοι αστοχίας. Για τη δυναμική παρακολούθηση προσδιορίζεται η συμπεριφορά των υπό επίβλεψη κατασκευών σε πραγματικό χρόνο, μετρώντας το φάσμα συχνοτήτων ταλάντωσης, την επιτάχυνση και την μετατόπιση κάποιων σημαντικών σημείων. Η απόσταση που μπορεί να μετρήσει φτάνει τα 500 m, με συχνότητα δειγματοληψίας μέχρι 200 Hz ανεξαρτήτως φωτός και καιρικών συνθηκών.



**Σχήμα 2-4:** Απεικόνιση IBIS-S για την παρακολούθηση μετακινήσεων και παραμορφώσεων  
**Figure 2-4:** View of IBIS-S for monitoring movements and displacements  
(Πηγή: [www.idsgeoradar.com](http://www.idsgeoradar.com))

Η τεχνική *IBIS* χρησιμοποιείται σε εφαρμογές παρακολούθησης δομικής κατάστασης μεγάλων τεχνικών έργων όπως γέφυρες και φράγματα, για τον προσδιορισμό των ιδιομορφών και των ιδιοσυχνοτήτων των κατασκευών, αλλά και για παρακολούθηση

δραστηριοτήτων όπως εξορύξεις και καθιζήσεις εδάφους ή φραγμάτων. Ακόμη, αξιοποιείται για την παρακολούθηση αστοχιών του εδάφους, ηφαιστειών και κατολισθήσεις.

Κάποια από τα πλεονεκτήματα της τεχνικής αυτής έναντι άλλων είναι:

- Υψηλή ακρίβεια μετακινήσεων έως 1/10 mm.
- Συχνότητα δειγματοληψίας έως 200 Hz.
- Παρακολουθεί εξ αποστάσεως τις ταλαντώσεις της κατασκευής.
- Μετρά μετατοπίσεις πολλών σημείων ταυτόχρονα και όχι μόνο ενός επιλεγμένου σημείου.
- Δυνατότητα ταυτόχρονης παρακολούθησης όλων των στόχων εντός ακτίνας με υψηλή ακρίβεια και χωρική ανάλυση.
- Λαμβάνει μετρήσεις ανεξαρτήτως ώρας και καιρικών συνθηκών.

Ταυτόχρονα, κάποια μειονεκτήματα που παρουσιάζονται είναι:

- Η ακρίβεια μέτρησης εξαρτάται άμεσα από την ελαστικότητα του υλικού.
- Ο υπολογισμός των ταλαντώσεων γίνεται μόνο σε μία διεύθυνση.
- Η ατμοσφαιρική καθυστέρηση επιδρά στις μετρήσεις αυξάνοντας το σφάλμα και έτσι απαιτείται η διόρθωση των μετρήσεων από αυτήν και η χρήση επιπλέον αισθητήρων ή σταθερών στόχων.
- Έχει πολύ υψηλό κόστος.
- Όταν ζητείται πολύ υψηλή ακρίβεια ενδέχεται να χρειαστεί να εγκατασταθούν ανακλαστές σε κάποια σημεία ελέγχου. Ενώ η τεχνική αυτή μειώνει το θόρυβο του σήματος λόγω ανακλαστικότητας, αφαιρεί το πλεονέκτημα της μέτρησης εξ αποστάσεως, χωρίς να χρειαστεί να πλησιάσει κανείς το αντικείμενο μέτρησης.

#### **2.2.4 Άλλες μέθοδοι**

Κάποιες ακόμη μέθοδοι παρακολούθησης της συμπεριφοράς των κατασκευών που χρησιμοποιούνται είναι η βιντεομετρία, τα *UAV-Drones* και ακόμη μία με τη χρήση ψηφιακών εικόνων.

Η πρώτη μέθοδος, της βιντεομετρίας, βασίζεται στις αρχές της φωτογραμμετρίας και ανάλυσης εικόνας και αφορά μετρήσεις σε κοντινές αποστάσεις. Τα συστήματα αυτά περιέχουν ψηφιακές βιντεοκάμερες υψηλής ευκρίνειας, που προσδίδουν τη δυνατότητα παρακολούθησης αντικειμένων έως και μεγέθους 1 mm και με συχνότητα δειγματοληψίας έως και 15 Hz. Λόγω του συνδυασμού τεχνικών ανάλυσης εικόνας με τη φωτογραμμετρία, η μέθοδος αυτή κατέχει μεγάλο πλεονέκτημα, ενώ δεν είναι αναγκαία η πρόσβαση στο σημείο που μελετάται. Ωστόσο, είναι αρκετά δύσκολη και χρονοβόρα η διαδικασία αποκατάστασης της κλίμακας μεταξύ εικόνας και αντικειμένου.

Η δεύτερη μέθοδος, με τη χρήση μη επανδρωμένων αεροσκαφών (*UAV – Unmanned Aerial Vehicles*) χρησιμοποιούνται τα τελευταία 10 έτη για εφαρμογές παρακολούθησης δομικών έργων. Έχουν αποδειχθεί πολύ χρήσιμα για την επιθεώρηση γεφυρών, καθώς παλαιότερα ήταν εφικτή μόνο από το κάτω μέρος αυτής ή εφαρμόζοντας αρκετά ριψοκίνδυνες τεχνικές, ενώ τώρα πραγματοποιούνται γρήγορα, με ασφάλεια και ακρίβεια. Τα μη επανδρωμένα αεροσκάφη κατέχουν κάμερες υψηλής ανάλυσης με καλή απόδοση σε χαμηλούς φωτισμούς ή και με δικό τους φωτισμό, ενώ ταυτόχρονα υπάρχει και η δυνατότητα σύνδεσης βίντεο σε πραγματικό χρόνο.

Τέλος, η τρίτη μέθοδος, εφαρμόζεται σε μεγάλο εύρος πεδίων μετρήσεων τριών διαστάσεων, εξάγοντας την πληροφορία από φωτογραφίες των κατασκευών σε δύο διαστάσεις. Για την υλοποίηση της μεθόδου χρησιμοποιούνται κάμερες για την καταγραφή ψηφιακών εικόνων της κατασκευής μελέτης, οι οποίες στην συνέχεια αναλύονται με εξειδικευμένες τεχνικές. Μέσα από αυτές τις μεθόδους λαμβάνονται αρκετές πληροφορίες για τη γέφυρα και τη λειτουργία της, αφού μπορούν να υποδείξουν τη θέση, τον αριθμό και τα είδη οχημάτων που κινούνται σε μία γέφυρα, πληροφορίες οι οποίες μπορούν να συνδυαστούν με τις μετρήσεις δομικής απόκρισης για την ανίχνευση αστοχιών. Οι τεχνικές αυτές είναι ακόμη ιδανικές για την μελέτη περιβαλλοντικών συνθηκών, ιδιαίτερα όσων οφείλονται στις επιδράσεις της θερμοκρασίας.

### 2.3 Μέθοδοι Πειραματικής Μηχανικής

Στην συνέχεια παρουσιάζονται και αναλύονται οι πιο διαδεδομένες μέθοδοι πειραματικής μηχανικής που εφαρμόζονται στην παρακολούθηση τεχνικών έργων. Οι μέθοδοι αυτοί βασίζονται σε μετρήσεις από συστήματα αισθητήρων όπως επιταχυνσιόμετρα, επιμηκυνσιόμετρα, ψηφιακά κλισίμετρα, ανεμόμετρα και οπτικές ίνες. Η κάθε μέθοδος μπορεί να λειτουργήσει αποτελεσματικά τόσο μόνη της όσο και σε συνδυασμό με τις υπόλοιπες.

Τα κύρια χαρακτηριστικά που επηρεάζουν την αποδοτικότητα των αισθητήρων είναι:

- **Ευαισθησία (*sensitivity*):** είναι το πηλίκο της ηλεκτρικής τάσης εξόδου προς το μηχανικό μέγεθος που μετράται από τον αισθητήρα (επιτάχυνση, ταχύτητα, μετατόπιση).
- **Εγκάρσια ευαισθησία (*cross-axis or transverse sensitivity*):** είναι η ευαισθησία σε κίνηση παράλληλη προς το επίπεδο που είναι κάθετο στο επίπεδο που ορίζει η κύρια ευαισθησία.
- **Διακριτικότητα (*resolution*):** είναι η ελάχιστη μεταβολή στο μετρούμενο μέγεθος που μπορεί να παράξει την μικρότερη μεταβολή στο ηλεκτρικό σήμα εξόδου που μπορεί να καταγραφεί.
- **Απόκριση συχνοτήτων (*frequency response*):** είναι το εύρος συχνοτήτων πάνω από την τιμή του οποίου το ηλεκτρικό σήμα εξόδου έχει σταθερή τιμή για σταθερή μηχανική κίνηση.


- **Μετάθεση φάσης (*phase shift*):** είναι η χρονική καθυστέρηση που μεσολαβεί από τη δημιουργία της κίνησης μέχρι την παραγωγή του ηλεκτρικού σήματος.
- **Απαιτήσεις βαθμονόμησης (*calibration requirements*):** είναι η επιτρεπόμενη διακύμανση στο ηλεκτρικά παραγόμενο σήμα από σταθερού εύρους μηχανική κίνηση, όταν αλλάζει το εύρος συχνοτήτων των δεδομένων, οι περιβαλλοντικές συνθήκες, το εύρος των δεδομένων ή και η ώρα συλλογής των δεδομένων.
- **Περιβαλλοντική ευαισθησία (*environmental sensitivity*):** είναι η απόκριση του αισθητήρα σε συνθήκες υγρασίας, θερμοκρασίας και στον ακουστικό θόρυβο.
- **Μέγεθος και μάζα:** αφορούν τον αισθητήρα και ανάλογα με το μέγεθός τους αλλάζει η ευαισθησία του σε χαμηλές συχνότητες.

[Σαλονικιός, 2009]

### 2.3.1 Επιμηκυνσιόμετρα

Τα επιμηκυνσιόμετρα (Σχήμα 2-5) χρησιμοποιούνται για την μέτρηση μετατοπίσεων σε εύκαμπτες κατασκευές και γέφυρες, όταν επηρεάζουν διάφορες φορτίσεις. Τα πιο διαδεδομένα είναι εκείνα που η κατασκευή τους αποτελείται από φύλλα αλουμινίου. Το μεγαλύτερο πλεονέκτημα αυτών, είναι το χαμηλό κόστος τους για τις απλές μορφές τους.

Ωστόσο, τα επιμηκυνσιόμετρα είναι ικανά να μετρήσουν μόνο σε μία θέση την καταπόνηση μίας δομής και μετρούν τις επιμηκύνσεις ενός φορέα για μικρό χρόνο. Οι πληροφορίες που λαμβάνονται από αυτούς τους αισθητήρες μπορούν να συνδυαστούν με μοντέλα πεπερασμένων στοιχείων της δομής ώστε να γίνει ανίχνευση φθορών στην κατασκευή.



**Σχήμα 2-5:** Επιμηκυνσιόμετρα  
**Figure 2-5:** Strain-gauges  
 (Πηγή: [www.omega.nl](http://www.omega.nl))

### 2.3.2 Επιταχυνσιόμετρα

Τα επιταχυνσιόμετρα αποτελούν την πιο διαδεδομένη μέθοδο μέτρησης των μετακινήσεων για μία κατασκευή, καθώς χρησιμεύουν στην μέτρηση, την απεικόνιση

και την ανάλυση της επιτάχυνσης σε μία, δύο ή και τρεις διευθύνσεις. Ο διαχωρισμός τους γίνεται βάσει του πεδίου εφαρμογής τους και τον τρόπο κατασκευής, όμως έχουν κοινή αρχή λειτουργίας κατά την οποία όταν μία μάζα διεγείρεται από μία δύναμη καταγράφεται η επιτάχυνσή της. Η διαφοροποίησή τους βρίσκεται στον τρόπο με τον οποίο μετρούν την επιτάχυνση, γεγονός που διαχωρίζει και τα πεδία εφαρμογής του καθενός και τα όρια λειτουργίας τους.

Μερικά είδη επιταχυνσιομέτρων είναι:

- **Επιμηκνσιομετρικός επιταχυνσιογράφος** (*strain gauge accelerometer*): αποτελείται από ένα μονοβάθμιο ταλαντωτή (μάζας-ελατηρίου-αποσβεστήρα).
- **Πιεζοηλεκτρικά επιταχυνσιόμετρα** (*piezoelectric accelerometer*): είναι το πιο γνωστό είδος επιταχυνσιομέτρων. Η λειτουργία του βασίζεται σε ένα κρύσταλλο που όταν διεγείρεται από την μάζα που ταλαντώνεται και πιέζεται, παράγεται ηλεκτρικό ρεύμα, τάσης ανάλογης της επιτάχυνσης της διέγερσης. Κάποια πλεονεκτήματά τους είναι ο μικρό τους μέγεθος, η ανθεκτικότητα, η υψηλή τους απόδοση, η ευρεία εμβέλεια συχνοτήτων και η ικανότητα παρακολούθησης ενός ευρέως φάσματος δυναμικών φαινομένων.
- **Πιεζωμικά επιταχυνσιόμετρα** (*piezoresistive accelerometer*): αποτελείται από ένα ηλεκτρικό κύκλωμα, στο οποίο η μάζα που ταλαντώνεται λειτουργεί ως διακόπτης. Όταν αυτή διεγείρεται ανοιγοκλείνει το κύκλωμα και η παραγόμενη τάση είναι ανάλογη της επιτάχυνσης. Το μεγάλο τους πλεονέκτημα είναι το μικρό τους μέγεθος και η δυνατότητά τους να καταγράφουν και μικρότερες συχνότητες.

Μερικά μειονεκτήματα που έχουν τα επιταχυνσιόμετρα, είναι:

- Λόγω της δυσκαμψίας του ελατηρίου και της απόσβεσης του ταλαντωτή, μπορούν να καταγράψουν κυρίως κινήσεις υψηλής συχνότητας ( $>0.5-1$  Hz) και όχι χαμηλόσυχνες ( $<0.1-0.2$  Hz) που προκαλούνται από ανεμοπιέσεις, μεταβολές θερμοκρασίας κ.α.
- Τα ρολόγια των οργάνων ξεκινούν να εμφανίζουν σφάλματα με την πάροδο του χρόνου.
- Η εγκατάστασή τους πρέπει να γίνεται πάνω στην κατασκευή μελέτης, ενώ απαιτείται και η συχνή διακοπή λειτουργίας της κατασκευής για αρκετές ώρες. Ακόμη, αν είναι δυσπρόσιτα τα σημεία τοποθέτησης του οργάνου είναι αναγκαία η εγκατάσταση και χρήση αρκετά ακριβών ικριωμάτων.
- Οι εκτιμήσεις για την ταχύτητα και την μετακίνηση περιλαμβάνουν σφάλματα από την καταγραφή της επιτάχυνσης και της αστάθειας δειγματοληψίας. Λόγω του νόμου μετάδοσης των σφαλμάτων, η συσσώρευση αυτών των σφαλμάτων μεταφέρεται και στην τελική εκτίμηση της μετατόπισης, η οποία προκύπτει ανάλογη του τετραγώνου του χρόνου της καταγραφής και αρκετές φορές στατιστικά μη σημαντική.



**Σχήμα 2-6:** Επιταχυνσιόμετρα  
**Figure 2-6:** Accelerometers  
(Πηγή: [www.elektormagazine.com](http://www.elektormagazine.com))

### 2.3.3 Ψηφιακά κλισίμετρα

Τα ψηφιακά κλισίμετρα είναι απλές διατάξεις ή όργανα που μετρούν γωνίες κλίσης. Τα κλισίμετρα έχουν αρκετά ευαίσθητους αισθητήρες, προκειμένου να καταγράφεται η παραμικρή αλλαγή κλίσης, έχοντας ανάλυση κοντά στο 0.0001 deg. Η τελική ακρίβεια εξαρτάται από το είδος του οργάνου που χρησιμοποιείται και το εύρος των μετρήσεων που καταγράφει και μπορεί να φτάσει έως 0.01 deg. Τα πιο σύγχρονα κλισίμετρα μπορούν να καταγράφουν ταυτόχρονα μετρήσεις κλίσης, θερμοκρασίας και διεύθυνσης μετακίνησης σε οπτοηλεκτρονική μέθοδο. Έχουν εφαρμογή σε παρακολούθηση μεγάλων κατασκευών όπως γέφυρες και φράγματα, όπου είναι αναγκαίες υψηλής ακριβείας πληροφορίες για την κλίση και τη διεύθυνση των μετατοπίσεων. Στο Κεφάλαιο 3 γίνεται ειδική αναφορά στα κλισίμετρα και τις ιδιότητές τους.

### 2.3.4 Αισθητήρες οπτικών ινών

Οι οπτικές ίνες είναι αισθητήρες που αξιοποιούνται για τον υπολογισμό αρκετών μεγεθών, όπως μετακινήσεις και ταχύτητες, ενώ ανάλογα με το μέγεθος που επιθυμείται να μετρηθεί αλλάζουν και οι λειτουργίες τους.

Αποτελούνται από ένα ζεύγος καλωδίων οπτικών ινών το οποίο συνδέεται με έναν ενισχυτή ή αισθητήρα και τα δύο καλώδια τοποθετούνται δίπλα το ένα στο άλλο. Οι αισθητήρες οπτικών ινών έχουν ευρεία χρήση στην παρακολούθηση δομικής ακεραιότητας τεχνικών έργων, αλλά και σε μνημεία, καθώς μπορούν εύκολα να εγκατασταθούν σε δύσβατα σημεία, σε οποιαδήποτε κατασκευή και μετρητική διάταξη. Ακόμη, υπολογίζουν σχετικές μετακινήσεις για τα τμήματα μίας κατασκευής και όχι ως προς κάποιο ανεξάρτητο σύστημα αναφοράς. Αρκετά σημαντικό χαρακτηριστικό είναι η αντοχή που έχει η οπτική ίνα, καθώς δεν επηρεάζεται από

ηλεκτρομαγνητικά πεδία και το νερό, πλεονέκτημα που την ξεχωρίζει από τα υπόλοιπα συμβατικά όργανα δομικής παρακολούθησης.

Πλεονεκτήματα της χρήσης αισθητήρων οπτικών ινών στην ΠΔΚ, είναι τα εξής:

- Υψηλή ακρίβεια προσδιορισμού της μετακίνησης του αντικειμένου, έως την τάξη του mm.
- Μικρό μέγεθος και αμελητέο βάρος, άρα μπορεί να τοποθετηθεί οπουδήποτε.
- Ανθεκτικότητα σε θερμοκρασίες  $>50^{\circ}\text{C}$ , επομένως δεν επηρεάζεται από τις καιρικές συνθήκες.
- Δεν εκπέμπουν ηλεκτρομαγνητική ακτινοβολία, επομένως είναι φιλικές προς το περιβάλλον.
- Αγγίζουν υψηλές ταχύτητες μετρήσεων, προσφέροντας τη δυνατότητα επανάληψής τους κατά τη διάρκεια ενός φαινομένου όπως σεισμό, διέλευση μεγάλου οχήματος, άνεμοι.
- Μειώνουν αρκετά το κόστος συντήρησης των τεχνικών έργων και μνημείων.
- Είναι εφικτός η επιτήρηση και ο χειρισμός από απόσταση, μέσω συμβατικών τηλεπικοινωνιακών μέσων.

Ωστόσο, όταν πρόκειται για μία αρκετά εύκαμπτη κατασκευή, οι αισθητήρες αυτοί μπορούν να χρησιμοποιηθούν, αλλά δεν είναι δυνατή η κατασκευή διάταξης παρακολούθησης μίας μεγάλης κατασκευής.

## **2.4 Μετάδοση Δεδομένων**

Οι περισσότεροι αισθητήρες που χρησιμοποιούνται για την παρακολούθηση της δομικής κατάστασης των κατασκευών παράγουν αναλογικά σήματα για τις μετρήσεις που καταγράφουν, οπότε για τον λόγο αυτό απαιτείται η χρήση αρκετά εξελιγμένων συστημάτων επεξεργασίας σήματος για την ψηφιοποίησή τους. Στις περιπτώσεις αυτές, ο επεξεργαστής πρέπει να βρίσκεται κοντά στους αισθητήρες, ώστε να μπορούν να επικοινωνούν με ειδικά καλώδια, γεγονός που δυσκολεύει τη διαδικασία και τις επιλογές θέσεων εγκατάστασης των αισθητήρων. Έτσι, η ενσύρματη μεταφορά δεδομένων αυξάνει τους θορύβους και την πολυπλοκότητα του εξοπλισμού, όσον αφορά τα διαθέσιμα καλώδια και την υπολογιστική ισχύ που απαιτείται για να υποστηριχθούν όλα κατάλληλα. Με την ασύρματη επικοινωνία δύναται να λαμβάνονται τα δεδομένα και ένα κομμάτι της επεξεργασίας τους κατευθείαν από την πηγή, δηλαδή από τους αισθητήρες.

### **2.4.1 Ενσύρματη μετάδοση**

Τα δεδομένα που μετρούνται από τους αισθητήρες συλλέγονται και αποθηκεύονται στον κεντρικό επεξεργαστή. Στο σύστημα της ενσύρματης επικοινωνίας, συχνά γίνεται χρήση του δικτύου μέσω ειδικών καλωδίων Ethernet LAN προκειμένου να αποφευχθεί η χρήση πολλών και διαφορετικών καλωδίων που μπορεί να προκαλέσει

σύγχυση, καθώς και ηλεκτρομαγνητικές παρεμβολές. Σημειώνεται πως σε περιπτώσεις που τα μήκη των καλωδίων είναι πολύ μεγάλα, εκτίθενται σε περιβαλλοντικές συνθήκες και το μεταδιδόμενο σήμα προφανώς περιέχει σφάλματα. Στην περίπτωση αυτή ακόμη προκύπτουν αρκετά υψηλά κόστη επισκευής και συντήρησης του συστήματος σε περίπτωση βλάβης.

#### **2.4.2 Ασύρματη μετάδοση**

Λόγω των εμποδίων που δημιουργούνται με την ενσύρματη μεταφορά των δεδομένων και την εισαγωγή αρκετών σφαλμάτων όταν πρόκειται για μεγάλες αποστάσεις, η ασύρματη μετάδοση είναι απαραίτητη. Η σύνδεση των αισθητήρων με το κέντρο λήψης των δεδομένων γίνεται μέσω ραδιοσυχνοτήτων, ενώ το βασικό σύστημα αισθητήρων αποτελείται και από άλλα υποσυστήματα αισθητήρων, τα οποία επικοινωνούν με την μονάδα επεξεργασίας και μεταξύ τους. Σε κάθε υποσύστημα περιλαμβάνεται ένας μικροεπεξεργαστής και ένας ασύρματος πομποδέκτης. Με αυτό τον τρόπο, κάθε υποσύστημα μπορεί να έχει και δική του αυτονομία, ώστε να επεξεργάζονται και να αποστέλλονται τα δεδομένα του ξεχωριστά. Ωστόσο, μεγάλη πρόκληση προκαλεί ο συγχρονισμός των σημάτων των αισθητήρων όταν πρόκειται να χρησιμοποιηθούν τεχνικές που πραγματοποιούνται σε πραγματικό χρόνο.

### **2.5 Ολοκληρωμένα Συστήματα Παρακολούθησης των Κατασκευών**

Για την παρακολούθηση τεχνικών έργων είναι αναγκαία η παρακολούθηση των δεδομένων σε πραγματικό χρόνο, προκειμένου οι επιβλέποντες να έχουν επίγνωση σε πραγματικό χρόνο για την αντίδραση της κατασκευής στα πολλαπλά φορτία που δέχεται, αλλά και για να μπορούν να αντιληφθούν τη λειτουργία της εύκολα. Για τον λόγο αυτό, είναι απαραίτητη η χρήση συστημάτων που παρέχουν συνεχή ή περιοδικό τρόπο τα δεδομένα, παρέχοντας μία ολοκληρωμένη εικόνα της κατασκευής με υψηλή ακρίβεια και αξιοπιστία.

Τα συστήματα αυτά, περιέχουν ένα βασικό λογισμικό το οποίο συνδέεται με αισθητήρες γεωδαιτικούς, γεωτεχνικούς, περιβαλλοντικούς ή οποιουδήποτε άλλου τύπου, προκειμένου να αποκτηθούν τα δεδομένα με την μέγιστη δυνατή ακρίβεια κατευθείαν από αυτούς. Ακόμη, παρέχεται η δυνατότητα οπτικοποίησης των δεδομένων ώστε να πραγματοποιηθεί η τεκμηρίωσή τους, η ανίχνευση και η άμεση πρόσβασή τους από οποιαδήποτε απομακρυσμένη τοποθεσία, σε πραγματικό χρόνο. Τα δεδομένα που συλλέγονται μπορούν να αποθηκευτούν τόσο τοπικά στο υπολογιστικό σύστημα που χρησιμοποιείται, όσο και σε κάποιο αποθηκευτικό χώρο στο διαδίκτυο, κάνοντας τα δεδομένα προσβάσιμα οποιαδήποτε ώρα.

Τα συστήματα αυτά, μπορούν να χρησιμοποιηθούν σε σύνδεση με οποιονδήποτε αισθητήρα, όπως GNSS, ρομποτικούς γεωδαιτικούς σταθμούς, άλλα συστήματα και εργαλεία παρακολούθησης. Ενδεικτικά, ένα τέτοιο σύστημα είναι το GeoMos της εταιρείας Leica Geosystems AG.





**Σχήμα 2-7:** Σύστημα GeoMos Monitoring Solution – Leica Geosystems AG  
**Figure 2-7:** GeoMos Monitoring Solution system – Leica Geosystems AG  
(Πηγή: <https://leica-geosystems.com/>)

## ΚΕΦΑΛΑΙΟ 3 - ΜΑΚΡΟΧΡΟΝΙΑ ΠΑΡΑΚΟΛΟΥΘΗΣΗ ΓΕΦΥΡΩΝ ΜΕ ΧΡΗΣΗ ΨΗΦΙΑΚΩΝ ΚΛΙΣΙΜΕΤΡΩΝ

Στο κεφάλαιο αυτό, περιγράφονται τα ψηφιακά κλισίμετρα, ως προς τον τρόπο λειτουργίας τους και ως προς τη χρήση τους σε δομικά έργα. Γίνεται ανάλυση των ειδών των κλισιμέτρων που διατίθενται στο εμπόριο, στα είδη λειτουργίας τους και στις υπηρεσίες που προσφέρουν, μαζί με πλεονεκτήματα και μειονεκτήματα που κατέχουν ανά περίπτωση. Ειδική μνεία γίνεται στα ψηφιακά κλισίμετρα Nivel 220 που χρησιμοποιήθηκαν κατά τις μετρήσεις που παρέχονται για την παρούσα διπλωματική εργασία.

### 3.1 Γενική Περιγραφή και Κατηγορίες Κλισιμέτρων

Το κλισίμετρο είναι ένα όργανο που τοποθετείται σε κατασκευές για την μέτρηση αλλαγής κλίσης και τον έλεγχό της μαζί με την κατακόρυφη περιστροφή. Τα κλισίμετρα, είτε μετράνε σε έναν άξονα είτε σε δύο, παράγουν ουσιαστικά ένα ηλεκτρικό σήμα το οποίο είναι αναλογικό της τιμής της κλίσης που υφίστανται στον εκάστοτε άξονα. Η κλίση μετράται σε σύγκριση με την αρχική τους θέση, που είναι το σημείο αναφοράς τους. Στις κατασκευές η κλίση μετράται κατά κύριο λόγο για να υπολογιστούν οι διαφορές που υφίστανται σε αυτές από άλλες κατασκευαστικές διαδικασίες, όπως τούνελ, εκσκαφές, υπόγεια νερά κι άλλα, τα οποία επηρεάζουν το έδαφος στο οποίο στηρίζονται. Εκτός αυτών, τα κλισίμετρα αξιοποιούνται και από τη μηχανουργία, τη δασολογία, την αεροπορία, τη ναυσιπλοΐα, την ηφαιστειολογία κ.α.

Γενικά, τα κλισίμετρα χωρίζονται σε δύο μεγάλες κατηγορίες, ανάλογα με τον τρόπο με τον οποίο ορίζουν την κατακόρυφη ή οριζόντια διεύθυνση. Συγκεκριμένα, η πρώτη κατηγορία αφορά κλισίμετρα που για τον προσδιορισμό της κατακόρυφης διεύθυνσης χρησιμοποιούν κάποια μάζα, όπως το νήμα της στάθμης, ενώ στη δεύτερη ανήκουν όσα περιέχουν κάποιο υγρό για τον σκοπό αυτό. Στα δεύτερα, μέσα από τη θέση ισορροπίας του υγρού ορίζεται το οριζόντιο επίπεδο.




**Σχήμα 3-1:** Ηλεκτρολυτικά κλισίμετρα  
**Figure 3-1:** Electrolytic tilt sensors  
(Πηγή: <https://www.bestech.com.au/>)

Τα κλισίμετρα μπορούν να μετρήσουν κλίση εύρους  $\pm 15^\circ$ , καθώς κινούνται μαζί με την κατασκευή όταν παράγεται κάποια κίνηση, αλλάζοντας όμως την κλίση των εσωτερικών του αισθητήρων. Για τα κλισίμετρα δύο αξόνων, όπως αυτά που αξιοποιήθηκαν και παρουσιάζονται στην συνέχεια, ο ένας αισθητήρας είναι τοποθετημένος σε γωνία  $90^\circ$  από τον δεύτερο και μετρά κίνηση στον οριζόντιο άξονα, σε ορθογώνια κατεύθυνση. Όταν τοποθετούνται πάνω στην κατασκευή, προγραμματίζονται να μετρούν κοντά στο μηδέν, που είναι η μεσαία τιμή τους. [8]

Μερικές εφαρμογές στις οποίες χρησιμοποιούνται κλισίμετρα, είναι :

- Η ανίχνευση κίνησης τοίχων, κτισμάτων, κολώνων κατά τη διάρκεια εκσκαφών, σηράγγων
- Μέτρα σταθεροποίησης
- Παρακολούθηση κατασκευής λόγω εσωτερικών ή εξωτερικών φορτίων, παραμορφώσεων σε τοίχους αντιστήριξης
- Παρακολούθηση φαινομένων σύγκλισης και άλλων κινήσεων μέσα σε σήραγγες
- Σταθερότητα κατασκευών σε εδάφη με κατολισθήσεις
- Αξιολόγηση κατάστασης γεφυρών και στύλων υπό φορτίο
- Υπολογισμός γωνιακής παραμόρφωσης σε ράγες τρένων και τούνελ



**Σχήμα 3-2:** Κλισίμετρο εγκατεστημένο σε πυλώνα  
**Figure 3-2:** Tilt sensor being installed in a pier  
(Πηγή: [8])

Οι συγκεκριμένες συσκευές μπορούν να επιτύχουν πολύ μεγάλη ακρίβεια, με αποτέλεσμα να είναι ικανές να χρησιμοποιηθούν ακόμα και σε ανώμαλες επιφάνειες. Η χρήση τους είναι αρκετά εδραιωμένη εδώ και σχεδόν δύο δεκαετίες, ενώ προκειμένου να χρησιμοποιηθούν λαμβάνονται υπόψιν οι άξονες στους οποίους επιθυμείται να υπολογισθεί η γωνία κλίσης και το εύρος αυτής. Ανάλογα με τα παραπάνω κριτήρια, επιλέγεται και η αντίστοιχη συσκευή, δηλαδή μονοαξονικό ή διαξονικό κλισίμετρο.


Ο κύριος παράγοντας που επηρεάζει τις μετρήσεις των κλισιμέτρων είναι η θερμοκρασία και το ηλιακό φως. Κατά την τοποθέτηση του αισθητήρα, προτείνεται να μη βρίσκεται σε μέρος όπου έχει έντονο ηλιακό φως, αλλιώς να χρησιμοποιείται ένα προστατευτικό κάλυμμα ώστε να αποφευχθούν αλλαγές ανά εποχή εξαιτίας της θερμοκρασίας. Μετά την τοποθέτησή του, πρέπει να καταγράφονται οι αρχικές μετρήσεις θερμοκρασίας προκειμένου να χρησιμοποιηθούν σε περιπτώσεις που απαιτείται διόρθωση στις μελλοντικές. Συνήθως, οι καλύτερες και ακριβέστερες μετρήσεις θερμοκρασίας λαμβάνονται πολύ νωρίς το πρωί, διότι η κατασκευή βρίσκεται σε θερμική ισορροπία με τις περιβάλλουσες συνθήκες.

Ουσιαστικά, με την αλλαγή της θερμοκρασίας, προκαλείται αλλαγή της ηλεκτρικής αντίστασης που γίνεται αντιληπτή από το σύστημα του κλισιμέτρου, το οποίο την μετατρέπει σε μέτρηση ακριβείας του μεγέθους και της διεύθυνσης κλίσης. Ακόμη, οι αυξομειώσεις της θερμοκρασίας προκαλούν διαστολή και συστολή του υγρού εντός του κλισιμέτρου. Οι μικρές αλλαγές που αντιλαμβάνεται ο αισθητήρας σε

σχέση με την αρχική του τιμή, που ορίζεται ως μηδέν, αποτελούν το αποτέλεσμα της μέτρησης.

### 3.2 Ψηφιακά κλισίμετρα

Χαρακτηριστικό των ψηφιακών κλισιμέτρων που τα διαχωρίζει από τα υπόλοιπα, είναι πως τόσο το σήμα όσο και τα δεδομένα τους είναι ψηφιακά. Ακόμη, η κατασκευή τους είναι ιδιαίτερα ανθεκτική και στιβαρή, ώστε να έχει αυξημένη αντοχή και να διευκολύνει τη χρήση του. Αξιοποιούνται σε δομικά έργα για τον έλεγχο γωνιών και κλίσεων, τόσο αυτόνομα όσο και σε συνδυασμό με άλλα συστήματα αισθητήρων. Τα αποτελέσματά τους αγγίζουν πολύ υψηλή ακρίβεια ( $\leq 0.001$  mrad), ενώ όπως και τα παραδοσιακά κλισίμετρα, κατηγοριοποιούνται σε μονοαξονικά και διαξονικά. Καθίστανται ιδανικά για στατικές εφαρμογές, ενώ θεωρούνται λιγότερο αξιόπιστα για δυναμικές εφαρμογές, όπως την παρακολούθηση της συμπεριφοράς μίας κατασκευής λόγω ανέμων, το οποίο επεξηγείται παρακάτω. Εφαρμογή έχουν ακόμη και σε έργα όπως κατολισθήσεις, εκσκαφές σιράγγων, ηφαιστειακές, υδραυλικής κ.α.



**Σχήμα 3-3:** Οριζόντιο ψηφιακό κλισίμετρο  
**Figure 3-3:** Horizontal digital inclinometer  
(Πηγή: <http://www.tjskl.org.cn/>)



**Σχήμα 3-4:** Ψηφιακά κλισίμετρα ευαισθησίας Nivel 220 και Nivel 210  
**Figure 3-4:** Digital inclinometers of high sensitivity Nivel 220 and Nivel 210  
(Πηγή: <https://leica-geosystems.com/>)

Κατά βάση η λειτουργία τους βασίζεται στη θεωρία και τις ιδιότητες των αγώγιμων υγρών, καθώς όλες οι αλλαγές που καταγράφονται από την ηλεκτρική αγωγιμότητα του νερού σηματοδοτούν την αλλαγή κλίσης. Η κλίση προσδιορίζεται πλήρως μέσω του υπολογισμού της ηλεκτρικής αντίστασης μεταξύ των ηλεκτροδίων στην επιφάνεια του αγώγιμου υγρού που βρίσκεται εντός του οργάνου, του οποίου το επίπεδο ισορροπίας ορίζει και την οριζόντια διεύθυνση.

Φυσικά, οι μετρήσεις που λαμβάνονται από τα ψηφιακά κλισίμετρα, παρά την υψηλή τους ακρίβεια περιέχουν και διαφόρων ειδών σφάλματα. Τα σημαντικότερα προέχονται από απότομες μεταβολές της θερμοκρασίας, λανθασμένη αρχική τοποθέτηση του κλισιμέτρου όπου δεν οριζοντιώθηκε ορθά, προκαλώντας έτσι αποκλίσεις από την κατακόρυφο και σφάλματα απόκλισης από την οριζόντια διεύθυνση, εάν η επιφάνεια του υγρού στο εσωτερικό του οργάνου δε βρισκόταν σε οριζόντια θέση κατά την εγκατάσταση.


Ωστόσο, παρά την μεγάλη ακρίβεια και όλα τα πλεονεκτήματα που αναφέρθηκαν παραπάνω, τα ψηφιακά κλισίμετρα παρουσιάζουν μεγάλη ευαισθησία στην μεταβολή της θερμοκρασίας, από όπου πηγάζει και ένα από τα βασικά σφάλματα που παρουσιάζονται κατά τη χρήση τους. Ακόμη, στις δυναμικές εφαρμογές, τονίσθηκε η ακαταλληλότητά τους, η οποία οφείλεται στο γεγονός πως αδυνατούν να παρουσιάσουν μεγάλη ακρίβεια όταν η δυναμικότητα ξεπερνά τα 5 Hz, εξαιτίας της αδράνειας του υγρού στο εσωτερικό και της μικρής συχνότητας που λαμβάνεται το δείγμα. Τέλος, παρακολουθούν μετακινήσεις μόνο στους άξονες x και y, οπότε δε λαμβάνονται πληροφορίες για τον άξονα z και το εύρος μέτρησής τους είναι σχετικά μικρό.

### **3.3 Συστήματα Παρακολούθησης – Χρησιμοποιούμενες Τεχνολογίες**

Για την πραγματοποίηση της μελέτης, αξιοποιήθηκαν ψηφιακά κλισίμετρα υψηλής ευαισθησίας Nivel220 της εταιρίας Leica Geosystems. Σε συνδυασμό με αυτά, προκειμένου να γίνει καταγραφή των μετεωρολογικών δεδομένων, εγκαταστάθηκε και ένα σύστημα αισθητήρων θερμοκρασίας/ πίεσης (DTM, STS) και ένα σύστημα αισθητήρων θερμοκρασίας/ υγρασίας (HMP 110, Vaisala). Ακόμη, για τη λήψη των μετρήσεων χρησιμοποιήθηκε το λογισμικό Nivel Tool του αισθητήρα Nivel220.

#### **3.3.1 Κλισίμετρο Nivel220**

Το κύριο όργανο όπου βασίστηκε η παρούσα μελέτη, είναι το ψηφιακό κλισίμετρο Nivel 220 της εταιρίας Leica Geosystems. Το συγκεκριμένο αποτελεί μέρος της σειράς ψηφιακών κλισιμέτρων Nivel200, είναι διαξονικό, υψηλής ακριβείας και είναι ιδανικό για τη λήψη συνεχών μετρήσεων κλίσης, της κατεύθυνσής της και θερμοκρασίας, στηριζόμενο στην οπτικοακουστική φύση του. Παρέχει ακρίβεια της τάξης των  $\pm 0.0047$  mrad, δεδομένα σε πραγματικό χρόνο και μπορεί να χρησιμοποιηθεί σε συνδυασμό με το λογισμικό παρακολούθησης της όμοιας εταιρείας Leica GeoMos για την επεξεργασία των δεδομένων.




**Σχήμα 3-5:** Ψηφιακό κλισίμετρο υψηλής ευαισθησίας Nivel220, Leica Geosystems  
**Figure 3-5:** Digital inclinometer high sensitivity Nivel220, Leica Geosystems  
(Πηγή: [9])

Για την καταγραφή των επιθυμητών μεγεθών μέσω συστήματος αισθητήρων, χρησιμοποιήθηκαν τέσσερα ψηφιακά κλισίμετρα *Nivel220*. Από αυτά τα τρία τοποθετήθηκαν στις βάσεις των τριών πυλώνων της γέφυρας, ενώ το τέταρτο σε κοντινή θέση με σταθερό έδαφος για να αξιοποιηθεί ως σημείο αναφοράς. Λόγω της υψηλής ακρίβειας των μετρήσεων που λαμβάνονται από αυτό, μέσω σύνδεσης με το πρόγραμμα *GeoMos* της ίδιας εταιρείας, μπορούν να λαμβάνονται δεδομένα σε πραγματικό χρόνο σε συνεχή βάση και με σταθερότητα. Καθίστανται ιδανικά για επίβλεψη μεγάλων κατασκευών, όπως γέφυρες και φράγματα.

Μέσω του χρησιμοποιούμενου λογισμικού, έγινε δυνατή η άμεση οπτικοποίηση των δεδομένων που καταγράφονταν από τους αισθητήρες, ενώ ταυτόχρονα γινόταν και η απαραίτητη επίβλεψη εξ αποστάσεως. Όλα τα δεδομένα μεταφέρονταν σε συνδεδεμένους υπολογιστές στο Εθνικό Μετσόβιο Πολυτεχνείο, όπου πραγματοποιούταν η επεξεργασία και ανάλυσή τους.


### **3.3.1.α Αρχές λειτουργίας**

Ο αισθητήρας Nivel220 αποτελείται από κάποια εξαρτήματα, τα οποία απεικονίζονται στο Σχήμα 3.6 και 3.7.



**Σχήμα 3-6:** Εξαρτήματα του αισθητήρα Nivel220  
**Figure 3-6:** Sensor Nivel220 components  
 (Πηγή: [9])

Ο αισθητήρας *Nivel220* βασίζει τη λειτουργία του στην οπτοηλεκτρονική. Το οριζόντιο επίπεδο, όπως έχει αναφερθεί και παραπάνω, ορίζεται μέσω της θέσης ισορροπίας του υγρού στο εσωτερικό του και η γωνία που σχηματίζεται μεταξύ αυτού και του αισθητήρα αλλάζει αναλόγως με την κλίση του αντικειμένου στο οποίο έχει εγκατασταθεί ο αισθητήρας.




**Σχήμα 3-7:** Εξαρτήματα του αισθητήρα Nivel220  
**Figure 3-7:** Sensor Nivel220 components  
 (Πηγή: [9])

Από τα απεικονιζόμενα μέλη, το γραμμικό στοιχείο μέσα από το πρίσμα (ε) και η επιφάνεια του υγρού (στ) προβάλλονται πάνω στη διάταξη CCD (α) μέσα από τη διάταξη φακών (δ). Το γραμμικό στοιχείο (γ) φωτίζεται μέσω ενός LED και είναι ενσωματωμένο σε πρίσμα, ενώ η επιφάνεια του υγρού (στ) είναι οριζόντια, ασχέτως με την κλίση που έχει ο αισθητήρας, με σκοπό η γωνία κλίσης που σχηματίζεται να αντιστοιχεί στη γωνία της επιφάνειας του υγρού και της βάσης του αισθητήρα.



### 3.3.1.β Συνδεσμολογία

Ο συγκεκριμένος αισθητήρας ανταποκρίνεται επαρκώς όταν πρόκειται για εφαρμογές παρακολούθησης με διασύνδεση πολλών αισθητήρων, όπως είναι η ενόργανη παρακολούθηση κατασκευών. Για τον σκοπό αυτό, προκειμένου να καλυφθεί αυτή η σύνδεση όλων των αισθητήρων χρησιμοποιείται μία RS485 διασύνδεση (interface). Παρακάτω αναπαρίσταται η συνδεσμολογία του αισθητήρα και του ηλεκτρονικού υπολογιστή.



**Σχήμα 3-8:** Συνδεσμολογία αισθητήρων Nivel220 και Η/Υ  
**Figure 3-8:** Connection between Nivel220 sensors and PC  
(Πηγή: [9])

Κάθε χρησιμοποιούμενο καλώδιο χαρακτηρίζεται από έναν μοναδικό κωδικό ώστε να διευκολύνεται η συνδεσμολογία βάσει του εγχειριδίου χρήσης. Τέλος, η συνδεσμολογία μπορεί να θεωρηθεί πλήρης μόλις τοποθετηθεί μία τερματική αντίσταση στο τέλος της σειράς.

### 3.3.2 Αισθητήρες διασύνδεσης μετεωρολογικών

Εκτός των τεσσάρων ψηφιακών κλισιμέτρων, τοποθετήθηκε ένα σύστημα αισθητήρων θερμοκρασίας και πίεσης (DTM, STS) και ένα σύστημα αισθητήρων υγρασίας και θερμοκρασίας (HMP 110, Vaisala), αντί για μετεωρολογικούς αισθητήρες ενσωματωμένους στα κλισίμετρα. Ο τελευταίος αισθητήρας, θεωρείται ιδανικός για εφαρμογές μεγάλου όγκου ή ενσωμάτωσης σε εξοπλισμό άλλου κατασκευαστή, αλλά και για θερμοκήπια, θαλάμους ζύμωσης και σταθερότητας, καταγραφείς δεδομένων και θερμοκοιτίδες (<https://www.vaisala.com/>).



**Σχήμα 3-9:** Αισθητήρας θερμοκρασίας και υγρασίας HMP 110, Vaisala  
**Figure 3-9:** Meteorological sensor HMP 110, Vaisala  
(Πηγή: <https://www.vaisala.com/>)

Στον πυλώνα M7 της γέφυρας μελέτης τοποθετήθηκαν οι αισθητήρες θερμοκρασίας και πίεσης (*DTM, STS*). Ο αισθητήρας αυτός σε σύνδεση με το λογισμικό *GeoMos* της *Leica Geosystems* μπορεί να παραμετροποιηθεί και να ελεγχθεί η λειτουργία του, ενώ η συχνότητα καταγραφής του για την περιβαλλοντική θερμοκρασία και πίεση είναι ανά 10 λεπτά (1 measurement/10 min).

Ακόμη, προκειμένου να καταγραφούν οι συνθήκες λειτουργίας του πυλώνα M8, τοποθετήθηκε σε αυτό το δεύτερο σύστημα αισθητήρων καταγραφής θερμοκρασίας και υγρασίας (*HMP 110, Vaisala*), μέσα σε ειδικό περίβλημα στην κορυφή του συγκεκριμένου πυλώνα. Στον ίδιο πυλώνα, έχουν τοποθετηθεί και επιταχυνσιόμετρα, ώστε να είναι εφικτή η ψηφιοποίηση του σήματος του αισθητήρα αυτού, καθώς πρόκειται για έναν αναλογικό αισθητήρα. Έτσι, η συχνότητα λήψης του δείγματος που παρέχεται είναι 200 cycles/second (Hz). Τέλος, ο αισθητήρας αυτός επιτρέπει την καταγραφή υγρασίας από 0 έως 100% RH και θερμοκρασίας από -40°C έως +80°C, ενώ διαθέτει μεταλλική θήκη με διαβαθμίσεις IP65.



**Σχήμα 3-10:** Θέσεις τοποθέτησης αισθητήρων καταγραφής μετεωρολογικών  
**Figure 3-10:** Installation points of the meteorological sensors

### 3.3.3 Λογισμικό καταγραφής *Nivel Tool*

Το συγκεκριμένο λογισμικό, *Nivel Tool*, του αισθητήρα *Nivel220*, είναι σχεδιασμένο με σκοπό τη καθοδήγηση του χρήστη κατά τη διαδικασία των μετρήσεων. Δίνεται η δυνατότητα ρύθμισης από τον χρήστη όλων των σημαντικών παραμέτρων για τη λήψη μετρήσεων, ενώ παράλληλα είναι εφικτός και ο χειρισμός του οργάνου εξ αποστάσεως. Ακόμη, παρέχονται κάποιες πρόσθετες λειτουργίες όπως η ηλεκτρονική αεροστάθμη, η δυνατότητα ρύθμισης του αισθητήρα ως προς την ονομασία, τη θύρα σύνδεσης κ.α., η ρύθμιση των παραμέτρων συλλογής δεδομένων, όπως η διάρκεια κ.α., αλλά και η στιγμή έναρξης και λήξης συλλογής δεδομένων.

Εάν για την διεκπεραίωση των μετρήσεων απαιτούνται παραπάνω από ένας αισθητήρες, τότε προγραμματίζεται ο καθένας ξεχωριστά και ύστερα πραγματοποιείται η διασύνδεσή τους.

## ΚΕΦΑΛΑΙΟ 4 - ΜΕΘΟΔΟΙ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΚΑΙ ΧΡΟΝΟΣΕΙΡΕΣ ΣΤΗΝ ΠΔΚ

### 4.1 Εισαγωγικές Έννοιες

Οι χρονοσειρές είναι μία σειρά παρατηρήσεων που έχουν αποδοθεί σε χρονική σειρά. Συνήθως, μία χρονοσειρά είναι μία ακολουθία που λαμβάνεται σε πολύ ακριβή και συγκεκριμένα χρονικά διαστήματα. Συχνά απεικονίζονται με γραμμικά διαγράμματα και χρησιμοποιούνται στην στατιστική, την επεξεργασία σήματος, αναγνώριση προτύπων, πρόβλεψη καιρού και άλλα. Η χαρακτηριστική τους ιδιότητα είναι πως τα δεδομένα δεν είναι ανεξάρτητα και η διασπορά τους διαφέρει κατά το πέρασ του χρόνου.

Η ανάλυση των χρονοσειρών περιλαμβάνει μεθόδους ανάλυσης δεδομένων με σκοπό την εξαγωγή εξηγήσιμων στατιστικών και άλλων χαρακτηριστικών των δεδομένων. Χρησιμοποιείται η προηγούμενη συμπεριφορά μίας μεταβλητής προκειμένου να προβλεφθεί η μελλοντική της τιμή, το οποίο αποτελεί και το κεντρικό πρόβλημα. Κατά την ανάλυση των χρονοσειρών, λαμβάνεται μία μηδενική υπόθεση, η οποία καλείται να καταρριφθεί ή όχι στην πορεία, κατά την οποία θεωρείται πως η μεταβολή των τιμών είναι τυχαία, άρα δεν υπάρχει συστηματική απόκλιση. Τέλος, σημαντικό είναι πως εφόσον τα δεδομένα συσχετίζονται μεταξύ τους, στατιστικές μέθοδοι που δεν επιτρέπουν την εξάρτηση των δεδομένων δεν μπορούν να χρησιμοποιηθούν.

Τα τελευταία χρόνια ο τομέας της τεχνητής νοημοσύνης εξελίσσεται συνεχώς, αποτελώντας μία δυναμική επιστήμη, καθώς βρίσκει εφαρμογή σε πολλαπλούς τομείς, όπως την μηχανική, την οικονομία, τη γενετική και την ιατρική. Η μηχανική μάθηση, ως κλάδος της τεχνητής νοημοσύνης, κάνει εφικτό για τα υπολογιστικά συστήματα να αντιλαμβάνονται και να επεξηγούν φαινόμενα και δεδομένα χωρίς να απαιτείται η παρέμβαση χειριστή. Η έλλειψη ανθρώπινης παρέμβασης καθιστά δυνατή τη βελτιστοποίηση των διαδικασιών που επενεργούνται, καθώς το ανθρώπινο σφάλμα είναι περιορισμένο.

#### 4.1.1 Παράμετροι και βασικές αρχές ανάλυσης χρονοσειρών

Προκειμένου να πραγματοποιηθεί η ανάλυση των χρονοσειρών, η μεταβλητή που χρησιμοποιείται πρέπει να παρέχεται σε κάποιες προηγούμενες χρονικές στιγμές, ώστε να προβλεφθεί η συμπεριφορά της στο μέλλον. Η δυσκολία κατά την ανάλυση, είναι η εκτίμηση του συστήματος που παράγει τη χρονοσειρά και τελικά, να γίνει η σωστή πρόβλεψη για το υπό μελέτη μέγεθος. Με σκοπό να είναι ουσιαστική η ανάλυση μίας χρονοσειράς, η πρώτη υπόθεση που πρέπει να απορριφθεί είναι πως η μεταβολή των τιμών του μελετώμενου μεγέθους είναι πλήρως τυχαία, άρα ζητείται να αποδειχθεί πως τα δεδομένα συσχετίζονται. Όπως αναφέρθηκε, η ιδιότητά τους να έχουν διαφορετική διασπορά στο πέρασ του χρόνου και η εξάρτηση των δεδομένων, οδηγεί στην απόρριψη στατιστικών διαδικασιών που υποθέτουν πως τα δεδομένα είναι ανεξάρτητα και ομοίως κατανεμημένα.

Η ανάλυση χρονοσειρών έχει δύο στόχους, πρώτον τον προσδιορισμό της φύσης του μελετώμενου φαινομένου, όπως αυτό προκύπτει μέσα από τα δεδομένα παρατήρησης και δεύτερον την πρόβλεψη των τιμών που θα λάβει αυτό στο μέλλον, βάσει της προηγούμενης συμπεριφοράς του. Για την επίτευξη αυτών, απαιτούνται δεδομένα με την μέγιστη δυνατή ακρίβεια, προκειμένου να είναι δυνατή η ερμηνεία και η ενσωμάτωση κι άλλων δεδομένων στα ήδη υπάρχοντα. [10]

Όπως σε όλες τις αναλύσεις δεδομένων, έτσι και στην ανάλυση χρονοσειρών, τα δεδομένα αποτελούνται από ένα σύνολο αναγνωρίσιμων στοιχείων (συστηματικό σχήμα) και από τυχαίο θόρυβο, ο οποίος δυσκολεύει τη διαδικασία εύρεσης του μοτίβου. Στις περισσότερες τεχνικές ανάλυσης χρονοσειρών ο θόρυβος φιλτράρεται προκειμένου να μετατραπεί σε λευκό θόρυβο (*white noise*) ώστε το σχήμα να είναι πιο ξεκάθαρο. Ακόμη, οι χρονοσειρές μέσα από τα δεδομένα τους περιγράφουν δύο κατηγορίες στοιχείων που είναι οι εξής:

- **Τάση** (*trend*): αντιπροσωπεύει μία συστηματική διαδικασία γραμμικών ή μη στοιχείων που μεταβάλλεται με το πέρασ του χρόνου και δεν εμφανίζει επαναλήψεις ή τουλάχιστον δεν εμφανίζει επαναλήψεις εντός των χρονικών ορίων που έχουν ληφθεί τα στοιχεία.
- **Εποχικότητα** (*seasonality*): είναι παρόμοια της τάσης, με τη διαφορά πως επαναλαμβάνεται σε συστηματικά διαστήματα με το πέρασ του χρόνου.

Περνώντας στις τεχνικές ανάλυσης της τάσης, υπάρχει η μέθοδος εξομάλυνσης, η οποία περιλαμβάνει μίας μορφής μέσο όρο προκειμένου τα συστηματικά στοιχεία των δεδομένων να αλληλοαναιρούνται. Η συνηθέστερη τεχνική είναι ο **κινούμενος μέσος όρος** όπου κάθε στοιχείο της σειράς αντικαθίσταται από τον απλό ή τον σταθμισμένο μέσο όρο των  $n$  στοιχείων γύρω του, με  $n$  το πλάτος εξομάλυνσης. Στην τεχνική αυτή, αντί για τη χρήση μέσων όρων μπορεί να αξιοποιηθεί και η **διάμεση εξομάλυνση**, δηλαδή οι διάμεσοι, οι οποίοι αποδίδουν αποτελέσματα περισσότερο αμερόληπτα από τις ακραίες τιμές, σε σχέση με αυτά που δίνει ο κινούμενος μέσος όρος. Συνεπώς, σε περίπτωση που εντοπίζονται ακραίες τιμές στα δεδομένα, λόγω σφαλμάτων μέτρησης για παράδειγμα, η διάμεση εξομάλυνση προσφέρει πιο αξιόπιστη καμπύλη από τον κινούμενο μέσο όρο. Ωστόσο, το μειονέκτημα της διάμεσης εξομάλυνσης είναι πως αν δεν υπάρχουν ακραίες τιμές παράγει περισσότερο ακανόνιστες καμπύλες από τον κινούμενο μέσο όρο και δεν αφήνει περιθώρια για την στάθμιση των δεδομένων.

Σε περιπτώσεις που το σφάλμα μέτρησης είναι αρκετά μεγάλο, τότε μπορεί να εφαρμοστεί η μέθοδος εξομάλυνσης μέσω των σταθμισμένων ελαχίστων τετραγώνων ή η αρνητικά εκθετικά σταθμισμένη τεχνική εξομάλυνσης. Αυτές οι δύο μέθοδοι μέσα από το φιλτράρισμα του θορύβου μετατρέπουν τα δεδομένα σε μία ομαλή καμπύλη, που είναι ανεπηρέαστη από τις ακραίες τιμές τους.

Όσον αφορά την εποχικότητα, ορίζεται από ένα βαθμό  $k$  και υπολογίζεται μέσω του συντελεστή αυτοσυσχέτισης. Αν δεν υπάρχει μεγάλο σφάλμα στις μετρήσεις, τότε η

εποχικότητα ενδέχεται να είναι εμφανής στη χρονοσειρά ως ένα φαινόμενο που επαναλαμβάνεται ανά  $k$  στοιχεία. Οι εποχιακές τάσεις των δεδομένων μίας χρονοσειράς, μπορούν να εξεταστούν μέσω διαγραμμάτων συσχέτισης, τα οποία εμφανίζονται γραφικά και αριθμητικά στην **συνάρτηση συσχέτισης (ACF)**. Ένας ακόμη τρόπος για την μέτρηση των εξαρτήσεων είναι μέσω της **συνάρτησης μερικής αυτοσυσχέτισης (PACF)**, η οποία διαφοροποιείται ελάχιστα από αυτή της συσχέτισης.

#### 4.1.2 Τεχνητή νοημοσύνη στον κατασκευαστικό τομέα

Η τεχνητή νοημοσύνη (*Artificial Intelligence - AI*) είναι δυνατό να προσδιοριστεί ως η προσομοίωση της εγκεφαλικής νοημοσύνης. Ο όρος αυτός είναι αρκετά γενικευμένος, καθώς περιλαμβάνει όλα τα είδη μη βιολογικής νοημοσύνης, άρα μέσα από αυτόν ορίζεται και η Υπολογιστική Νοημοσύνη (YN) που χρησιμοποιήθηκε πρώτη φορά από τον *J. Bezdek* (1992).

Η τεχνητή νοημοσύνη, ουσιαστικά, αλλάζει τον τρόπο λειτουργίας των μηχανών έτσι, ώστε να μπορούν να μαθαίνουν από την εμπειρία, να προσαρμόζονται κατάλληλα στα δεδομένα που τους δίνονται και να εκτελούν διαδικασίες όπως θα το έκανε ο άνθρωπος. Φυσικά, η τεχνητή νοημοσύνη έχει διαφορετικό υπόβαθρο από την ανθρώπινη, αλλά βασίζεται στις αρχές αυτής. Ωστόσο, σύμφωνα με την *Melanie Mitchell*, καθηγήτρια ρομποτικής στο πανεπιστήμιο του MIT, η τεχνητή νοημοσύνη και όσα καλούνται «μάθηση» και «ευφυΐα» όταν πραγματοποιούνται από μηχανήματα δεν είναι ανάλογα των ανθρωπίνων δυνατοτήτων. Οι δυνατότητες μίας μηχανής είναι σαφώς περιορισμένες, με συγκεκριμένα καθήκοντα με μικρή μεταφορά σε παρόμοιες αλλά διαφορετικές προκλήσεις.

Η υπολογιστική νοημοσύνη (YN) ορίζεται ως «ο επιστημονικός χώρος που προσφέρει τις τεχνικές για την επίλυση δύσκολων προβλημάτων, με τη μηχανή να μιμείται απλώς, βιολογικές διεργασίες, χωρίς να είναι απαραίτητο να επιδεικνύει γενική νοημοσύνη». [11] Η YN χρησιμοποιεί ένα εύρος συμπληρωματικών τεχνικών όπως τα τεχνητά νευρωνικά δίκτυα, ασαφή λογική, μαθησιακή θεωρία, εξελικτικό υπολογισμό και πιθανοτικές μεθόδους [12] και είναι ικανή να επιλύει μη γραμμικά προβλήματα, μαθαίνοντας στα υπολογιστικά συστήματα την ανθρώπινη ευφυΐα. Ωστόσο, όπως είπε ο *Bezdek*, αποτελεί υποσύνολο της τεχνητής νοημοσύνης.

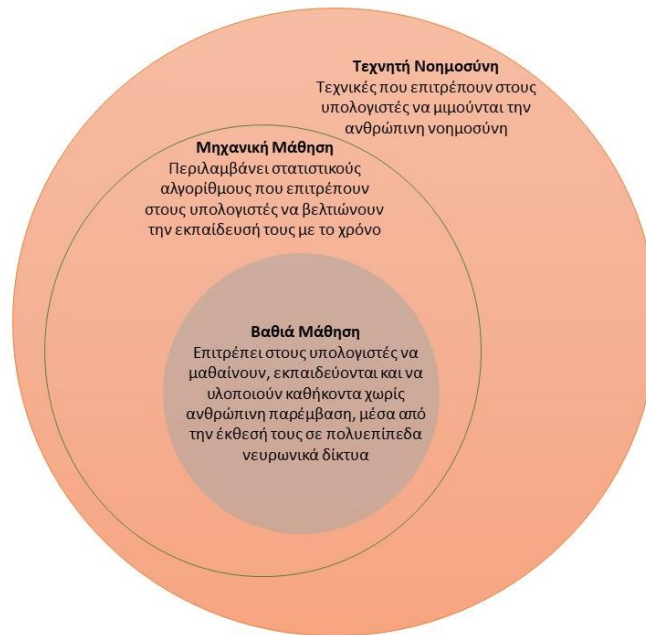
Αναφορικά με τον κατασκευαστικό τομέα υφίστανται αμέτρητα προβλήματα που επηρεάζονται από αβεβαιότητες. Αυτά τα προβλήματα προκειμένου να επιλυθούν απαιτούν το συνδυασμό πολλών τομέων και την εμπειρία του μηχανικού που τα επιβλέπει. Ωστόσο, οι υπολογιστές πλέον κατέχουν αρκετή δύναμη προκειμένου να λύσουν προβλήματα που εντοπίζονται στην καθημερινότητα μέσω πολλαπλών διεργασιών. Έτσι, η τεχνητή νοημοσύνη και οι κλάδοι της μπορούν να χρησιμοποιηθούν αποτελεσματικά για να βελτιστοποιηθούν οι ήδη υπάρχουσες λύσεις, λαμβάνοντας υπόψιν την ποιότητα των δεδομένων, ενώ παράλληλα βοηθούν

και στη μείωση του χρόνου και κόστους εντός εργαστηρίου ή στο ύπαιθρο σε πολλές εργασίες πεδίου.

Φυσικά, τα σφάλματα δε γίνεται να εξαλειφθούν πλήρως, καθώς υφίστανται σε όλα τα φυσικά μεγέθη. Έτσι και στην ΠΔΚ υπάρχουν αβεβαιότητες εντός του θορύβου των παρατηρήσεων, που προέρχονται από πολλαπλές πηγές. Η τεχνητή νοημοσύνη παρέχει μεθόδους που είναι ικανές να λύσουν προβλήματα αβεβαιοτήτων που ορίζονται για παράδειγμα στον εντοπισμό βλαβών και της ταυτοποίησης συστήματος χρησιμοποιώντας πεπερασμένα στοιχεία ανανέωσης μοντέλου [13]. Ακόμη, χρησιμοποιείται συχνά η τεχνική ανανέωσης του μοντέλου προκειμένου να εντοπιστούν φυσικές παράμετροι που μπορεί να μαρτυρούν ενδεχόμενη βλάβη κατά την μείωση της τιμής τους. Ωστόσο, πρέπει να μελετάται και να υπολογίζεται η αβεβαιότητα κάθε υπολογισμού που παρουσιάζει μείωση κατά τη διαδικασία αυτή, ώστε να αναγνωρίζεται αν οφείλεται σε πραγματική βλάβη.

Μερικά υποσύνολα της τεχνητής νοημοσύνης που χρησιμοποιούνται στην παρακολούθηση της δομικής συμπεριφοράς των κατασκευών είναι η μηχανική μάθηση (*machine learning – ML*), η αναγνώριση προτύπου (*pattern recognition – PR*), τα νευρωνικά δίκτυα, η βαθιά μάθηση (*deep learning – DL*), οι πιθανοτικές μέθοδοι, τα δένδρα αποφάσεων, η ασαφής λογική, η μαθησιακή θεωρία και ο εξελικτικός υπολογισμός. Η χρήση όλων των παραπάνω με την πάροδο των χρόνων αυξήθηκε σημαντικά, ενώ τα νευρωνικά δίκτυα έχουν κεντρίσει περισσότερο από όλα το ενδιαφέρον μηχανικών και ερευνητών ιδίως τις τελευταίες δεκαετίες. Ακόμη, η βαθιά μάθηση, η μηχανική μάθηση και η αναγνώριση προτύπου έχουν εξίσου εξελιχθεί και χρησιμοποιηθεί σε μεγάλο βαθμό τα τελευταία χρόνια, όμως παρακάτω θα γίνει εστίαση κυρίως στην μηχανική μάθηση, τη βαθιά μάθηση και τα νευρωνικά δίκτυα, που αξιοποιούνται και αργότερα κατά την επεξεργασία των δεδομένων της διπλωματικής αυτής.

Συνοψίζοντας, η τεχνητή νοημοσύνη είναι η προσομοίωση της ανθρώπινης νοημοσύνης από μηχανήματα. Αυτή εκφράζεται μέσα από διαδικασίες οργάνωσης, εκμάθησης και επίλυσης προβλημάτων. Η μηχανική μάθηση είναι ένας εξειδικευμένος τομέας της τεχνητής νοημοσύνης, που περιλαμβάνει και την αναγνώριση προτύπων, όπου το υπολογιστικό σύστημα εκπαιδεύεται μέσα από μεγάλο όγκο δεδομένων πως να φέρνει εις πέρας συγκεκριμένα καθήκοντα. Η βαθιά μάθηση, μπορεί να θεωρηθεί μία ακόμη πιο εξειδικευμένη μορφή της μηχανικής μάθησης, που χρησιμοποιεί περισσότερες διαστάσεις προκειμένου να λύσει πιο πολύπλοκα προβλήματα τα οποία ήταν δύσκολο να αντιμετωπιστούν με απλά μοντέλα μηχανικής μάθησης.



**Σχήμα 4-1:** Δομή τεχνολογιών τεχνητής νοημοσύνης  
**Figure 4-1:** Structure of AI technologies

## 4.2 Αναπτυσσόμενες Μέθοδοι Τεχνητής Νοημοσύνης για την Επεξεργασία Δεδομένων Χρονοσειρών

Όπως αναφέρθηκε και παραπάνω, η αναγνώριση προτύπων, η μηχανική μάθηση και η βαθιά μάθηση, είναι οι τρεις τομείς της τεχνητής νοημοσύνης που γνωρίζουν την μεγαλύτερη εξέλιξη και χρήση. Βρίσκουν εφαρμογή σε αναρίθμητους τομείς, όπως και τον κατασκευαστικό τομέα και την ανάλυση παρατηρήσεων χρονοσειρών αυτού. Παρακάτω, περιγράφονται οι τρεις αυτοί τομείς και η χρήση του καθενός σε κατασκευαστικά προβλήματα παρακολούθησης κατασκευών.

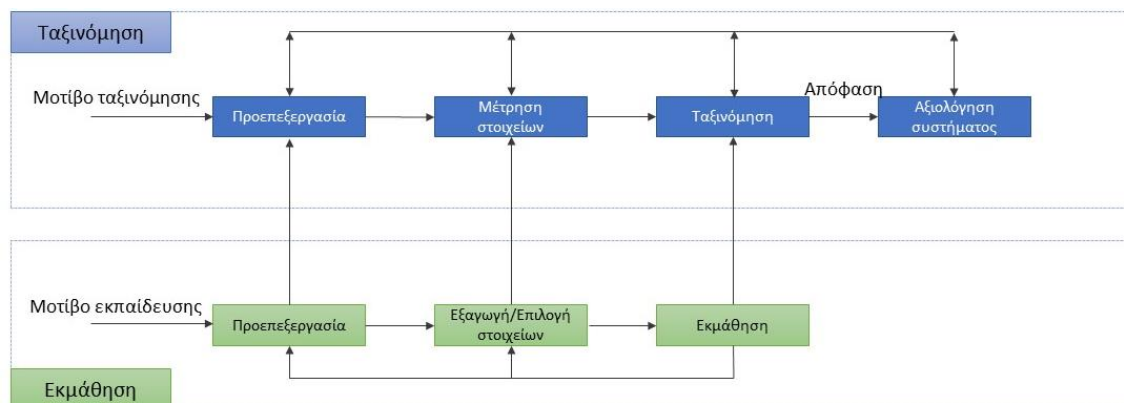
### 4.2.1 Αναγνώριση προτύπων

Η αναγνώριση προτύπων είναι η διαδικασία αναγνώρισής τους χρησιμοποιώντας κάποιον αλγόριθμο μηχανικής μάθησης. Η αναγνώριση προτύπων ορίζεται και ως η ταξινόμηση των δεδομένων με βάση τη γνώση που έχει ήδη αποκτηθεί ή σε στατιστικές πληροφορίες που προκύπτουν από μοτίβα και την αναπαράστασή τους.

Ο σκοπός της αναγνώρισης προτύπων είναι να ταξινομήσει τα δεδομένα σε έναν αριθμό τάξεων ή κατηγοριών. Τα δεδομένα μπορεί να προέρχονται από εικόνες, ηχητικά σήματα, γραπτά κείμενα ή μετρήσεις. Θεωρείται πως κάθε πρότυπο αντιπροσωπεύεται από κάποια χαρακτηριστικά, ενώ χρησιμοποιούνται έννοιες από τη θεωρία της στατιστικής προκειμένου να οριστούν τα όρια μεταξύ των τάξεων των προτύπων.



Το σύστημα αναγνώρισης αποτελείται από δύο λειτουργίες, την μάθηση (*training*) και την ταξινόμηση (*testing*), όπως φαίνεται και στο Σχήμα 4-1. Σε κάθε λειτουργία, τα χαρακτηριστικά που είναι κατάλληλα για την αναπαράσταση των μοτίβων εισόδου ανακαλύπτονται μέσω της διαδικασίας εξαγωγής και επιλογής των στοιχείων και ο ταξινομητής είναι εκπαιδευμένος να χωρίσει το χώρο των στοιχείων. Στη λειτουργία ταξινόμησης, τα μοτίβα εισόδου αντιστοιχίζονται σε μία από τις δημιουργημένες τάξεις χρησιμοποιώντας τον εκπαιδευμένο ταξινομητή, ενώ η απόδοση του σχεδιασμένου ταξινομητή, για παράδειγμα το ποσοστό σφάλματος της ταξινόμησης, αξιολογείται από το σύστημα αξιολόγησης της λειτουργίας αυτής.




**Σχήμα 4-2:** Σχηματική απεικόνιση ενός συστήματος αναγνώρισης προτύπου  
**Figure 4-2:** Schematic of a pattern recognition system

Γενικά, οι μέθοδοι που χρησιμοποιούνται από την αναγνώριση προτύπων μπορούν να ενταχθούν σε δύο ευρύτερες κατηγορίες, την επιβλεπόμενη αναγνώριση προτύπου και την μη επιβλεπόμενη. Ο όρος επιβλεπόμενη ουσιαστικά παραπέμπει στην κατάσταση υπό την οποία ένα σύνολο εκπαιδευμένων δεδομένων είναι διαθέσιμα. Όταν δεν είναι γνωστή κάποια πληροφορία για την τάξη που ανήκουν οι κατηγορίες και τα δεδομένα εκπαίδευσης δεν είναι κατηγοριοποιημένα, τότε πρόκειται για μη επιβλεπόμενη αναγνώριση προτύπου, ή ταξινόμηση.

Μία ακόμη διαφορά στις μεθόδους αναγνώρισης προτύπου είναι αυτή των γενετικών μοντέλων και των διακριτικών μοντέλων, που εξαρτάται από τον σκοπό που γίνεται η μελέτη. Αν ο σκοπός είναι η εύρεση της κατανομής των μοτίβων που παρουσιάζονται σε ένα μοντέλο, τότε αυτό υποδεικνύει πως πρέπει να χρησιμοποιηθεί η επιβλεπόμενη μέθοδος. Αντίστοιχα, στην μη επιβλεπόμενη, ο σκοπός είναι να προσδιοριστεί το μοντέλο που ορίζει τα όρια των αποφάσεων, ενώ να εκπαιδευτεί στη λειτουργία και τις παραμέτρους των ορίων απόφασης.

Τα τελευταία χρόνια, το ενδιαφέρον γύρω από τη χρήση της αναγνώρισης μοτίβων στον κατασκευαστικό τομέα όλο και αυξάνεται, ιδίως σε περιπτώσεις που αφορούν την ενόργανη παρακολούθηση δομικών έργων, τον εντοπισμό βλαβών σε κατασκευές, τους σεισμούς και τον αντισεισμικό σχεδιασμό, την δομική αξιοπιστία και την αξιολόγηση της κατάστασης μίας κατασκευής.



**Σχήμα 4-3:** Ερευνητικές δημοσιεύσεις σχετικά με τη χρήση της μηχανικής μάθησης και της αναγνώρισης μοτίβων

**Figure 4-3:** Research publication on the use of machine learning and pattern recognition (Πηγή: [12])

Υπάρχουν δύο κύριες προσεγγίσεις όσον αφορά την αναγνώριση βλαβών. Η πρώτη ονομάζεται αντίστροφη προσέγγιση, επίσης γνωστή ως ταυτοποίηση συστήματος (*system identification*), ενώ η δεύτερη ως ευθεία προσέγγιση, η οποία βασίζεται στην εξαγωγή πληροφοριών από την υπό παρακολούθηση κατασκευή. [14] Έτσι, όταν πρόκειται για εντοπισμό βλαβών και τη χρήση ΠΔΚ σε συνδυασμό με την αναγνώριση προτύπων, αξιοποιείται κατά βάση η δεύτερη προσέγγιση.

Τα πλεονεκτήματα της μεθόδου αναγνώρισης προτύπων είναι πως μπορεί να εφαρμοστεί σε παραδοσιακά και βασιζόμενα σε δεδομένα συστήματα ΠΔΚ, δεν απαιτείται γιγάντιος όγκος δεδομένων και μπορεί αποτελεσματικά να αξιοποιηθεί για την ταξινόμηση των δεδομένων και την αναγνώριση προβλημάτων. Αντίστοιχα, κάποια μειονεκτήματα είναι πως δεν μπορεί να συγχωνευτεί άμεσα σε πολλές «έξυπνες» εφαρμογές και δεν αντιπροσωπεύει την μάθηση, δηλαδή δεν μαθαίνει από αυτήν το υπολογιστικό σύστημα.

#### 4.2.2 Μηχανική μάθηση

Περνώντας στις πιο διαδεδομένες μεθόδους τεχνητής νοημοσύνης που χρησιμοποιούνται στον κατασκευαστικό τομέα, αρχικά αναλύεται η μηχανική μάθηση (*Machine Learning – ML*). Σύμφωνα με τον *Tom Mitchell*, «το πεδίο της μηχανικής μάθησης ασχολείται με τις ερωτήσεις του πως να κατασκευαστούν προγράμματα ηλεκτρονικών υπολογιστών που βελτιώνονται αυτομάτως μέσω της εμπειρίας».

Η μηχανική μάθηση είναι μέθοδος ανάλυσης δεδομένων που αυτοματοποιεί τη δόμηση αναλυτικών μοντέλων. Είναι ο κυριότερος κλάδος της τεχνητής νοημοσύνης

και βασίζεται στην ιδέα ότι τα συστήματα μπορούν να μάθουν από δεδομένα, να εντοπίσουν πρότυπα και να πάρουν αποφάσεις με ελάχιστη ανθρώπινη παρέμβαση και χρησιμοποιώντας δεδομένα εκπαίδευσης. Χρησιμοποιείται κυρίως για τον εντοπισμό μίας τάσης που ακολουθούν τα δεδομένα, αλλά επικεντρώνονται και στην πρόβλεψη βάσει γνωστών πληροφοριών που μαθαίνουν από τα δεδομένα εκπαίδευσης.

Στην μηχανική μάθηση, πολύ σημαντικός είναι ο επαναληπτικός παράγοντας, καθώς τα μοντέλα που κατασκευάζονται εκτίθενται σε νέα δεδομένα και μπορούν αυτόνομα να προσαρμοστούν στις ανάγκες τους. Μαθαίνουν, ουσιαστικά, από προηγούμενους υπολογισμούς να παράγουν αξιόπιστα επανειλημμένες αποφάσεις και αποτελέσματα.

Η μηχανική μάθηση διαφοροποιείται από άλλες μεθόδους, όπως η βαθιά μάθηση και η αναγνώριση προτύπων, ενώ είναι αρκετά πιο γενική μέθοδος τεχνητής νοημοσύνης σε σχέση με άλλες υπάρχουσες ως προς τους στόχους της. Οι δύο προαναφερθείσες μέθοδοι μοιάζουν μεταξύ τους, με την αναγνώριση προτύπων να ασχολείται με μεθόδους ταξινόμησης, ενώ η μηχανική μάθηση με αλγόριθμους που στοχεύουν στην εκμάθηση από τους εαυτούς τους. Η βαθιά μάθηση μπορεί να θεωρηθεί υποσύνολο της μηχανικής μάθησης, όπου το υπολογιστικό σύστημα είναι δυνατόν να εκπαιδευτεί μέσα από την αναπαράσταση των δεδομένων. Πρακτικά, ακόμη, η βαθιά μάθηση είναι ικανή να μετατρέψει ένα πρόβλημα περισσότερων διαστάσεων σε ένα αντίστοιχο με λιγότερες διαστάσεις.

Λόγω των νέων τεχνολογιών, η μηχανική μάθηση στη νέα εποχή έχει εξελιχθεί ραγδαία. Αρχικά, γεννήθηκε μέσα από πρότυπα αναγνώρισης και τη θεωρία πως οι υπολογιστές είναι ικανοί να μάθουν χωρίς να έχουν προγραμματιστεί να εκτελέσουν συγκεκριμένα καθήκοντα. Κατά αυτό τον τρόπο, ερευνητές του χώρου θέλησαν να ανακαλύψουν εάν οι υπολογιστές μπορούν να μάθουν από δεδομένα.

Το έντονο ενδιαφέρον γύρω από την μηχανική μάθηση οφείλεται σε πολλαπλούς παράγοντες, που την κάνουν να βοηθά σε μεγάλο βαθμό την επεξεργασία και την ενίσχυση των δεδομένων. Μερικοί από αυτούς είναι η αύξηση του θορύβου και της ποσότητας των υπαρχόντων δεδομένων, η υπολογιστική επεξεργασία που είναι πιο οικονομική και πιο ικανή, αλλά και ο προσιτός χώρος αποθήκευσης δεδομένων. Οι περισσότεροι ερευνητικοί τομείς διεθνώς που δουλεύουν με μεγάλες ποσότητες δεδομένων καθημερινά έχουν αναγνωρίσει την αξία της. Με την επίβλεψη των δεδομένων που λαμβάνουν, συνήθως σε πραγματικό χρόνο, είναι ικανές να λειτουργήσουν και να διοικήσουν καλύτερα τις επιχειρήσεις τους με σημαντικό πλεονέκτημα έναντι τρίτων.

Η μηχανική μάθηση χρησιμοποιείται σε οικονομικές υπηρεσίες, όπως τράπεζες, προκειμένου να εντοπίσουν σημαντικές λεπτομέρειες στα δεδομένα τους, που ωφελούν σε επενδύσεις, και να αποφύγουν την υποκλοπή. Ακόμη, οι κυβερνήσεις τη χρησιμοποιούν για ζητήματα δημόσιας ασφάλειας και λειτουργίες που έχουν συγκεκριμένες ανάγκες για μηχανική μάθηση εφόσον έχουν πολλές πηγές

δεδομένων που μπορούν να αναζητήσουν ενδείξεις. Μερικές ακόμη βιομηχανίες που χρησιμοποιούν την μηχανική μάθηση είναι η υγεία, το εμπόριο, οι μεταφορές και η ενέργεια. Ωστόσο, δεν περιορίζεται η εφαρμογή της μόνο σε αυτές, καθώς με την εξέλιξη της τεχνολογίας διεισδύει σε όλο και περισσότερες.

Οι διάφορες κατηγορίες της μηχανικής μάθησης, δηλαδή εκπαίδευσης νευρωνικών δικτύων, παραδοσιακά χωρίζονται σε τρεις μεγάλες κατηγορίες ανάλογα με τη φύση των πληροφοριών που διατίθενται για το σύστημα εκμάθησης.

- Επιβλεπόμενη μάθηση (Supervised Learning): Παρέχονται από το χειριστή στον υπολογιστή παραδείγματα από δεδομένα και τα επιθυμητά τους αποτελέσματα με στόχο να εκπαιδευτεί στο γενικό κανόνα που αποτυπώνει τα δεδομένα εισόδου και εξόδου.
- Μη επιβλεπόμενη μάθηση (Unsupervised Learning): Δε δίνονται κατευθύνσεις στον υπολογιστή για το επιθυμητό αποτέλεσμα, επιτρέποντάς του να κατασκευάσει μόνος του ένα μοντέλο για τα δεδομένα εισόδου και να αναγνωρίσει τη δομή τους. Έχει εφαρμογή συχνά σε προβλήματα ανάλυσης-σύνδεσης και ταξινόμησης.
- Ενισχυτική Μάθηση (Reinforcement Learning): Ένα υπολογιστικό πρόγραμμα αλληλοεπιδρά με ένα δυναμικό περιβάλλον εντός του οποίου πρέπει να εκτελέσει έναν συγκεκριμένο στόχο (π.χ. ο έλεγχος κίνησης ρομπότ), όπου ο αλγόριθμος εξοικειώνεται με μία στρατηγική ενεργειών. Καθώς ανακαλύπτει το χώρο του προβλήματος, ο υπολογιστής δίνει πληροφορίες για αυτό που είναι ανάλογες του κέρδους που θα έχει από την επίτευξη του στόχου, το οποίο προσπαθεί να μεγιστοποιήσει.

Η επιβλεπόμενη μάθηση χρησιμοποιείται όταν τα δεδομένα εισόδου  $X$  και εξόδου  $Y$  ενώνονται από την σχέση:

$$Y = f(X) \quad (4.1)$$

Υπάρχουν δύο κατηγορίες επιβλεπόμενης μάθησης, η ταξινόμηση (*classification*) και η παλινδρόμηση (*regression*). Μέσω της ταξινόμησης προσεγγίζεται μία λειτουργία χαρτογράφησης από τα δεδομένα εισόδου σε μεμονωμένα δεδομένα εξόδου που κατέχει το καθένα από μία διαφορετική «ταμπέλα». Χρησιμοποιείται στην καθημερινότητα, για παράδειγμα για τον διαχωρισμό του είδους μηνυμάτων ηλεκτρονικού ταχυδρομείου, τον εντοπισμό ιών και άλλα. Με την παλινδρόμηση, αντί να προβλέπονται διακριτές τιμές εξόδου, επικεντρώνεται το σύστημα στην πρόβλεψη μίας συνεχούς ποσότητας, ενώ μπορεί να είναι γραμμική ή μη γραμμική. Βρίσκει χρήση σε οικονομικές προβλέψεις ή στην εύρεση συσχετίσεων μεταξύ δύο αντικειμένων.

Η μηχανική μάθηση στα πλαίσια της ΠΔΚ εκφράζεται ως δημιουργία γνώσης από προηγούμενες παρατηρήσεις και εμπειρίες, μαθαίνοντας τις παραμέτρους που αφορούν το προς εξέταση μοντέλο και τέλος, την πρόβλεψη νέων δεδομένων. Τόσο η επιβλεπόμενη, όσο και η μη επιβλεπόμενη μάθηση χρησιμοποιούνται στον τομέα

αυτό και στις εφαρμογές του. Αλγόριθμοι που περιλαμβάνουν τεχνητά νευρωνικά δίκτυα, τη μέθοδο πλησιέστερου γείτονα κι άλλες, αξιοποιούνται κυρίως για τον εντοπισμό δομικών βλαβών σε συνδυασμό με την μηχανική μάθηση, λόγω της αποτελεσματικότητάς τους και της αξιοπιστίας τους όταν περιέχονται στα δεδομένα θόρυβοι, αβεβαιότητες και ελλιπείς πληροφορίες.

Πλεονεκτήματα που πηγάζουν από τη χρήση της μηχανικής μάθησης για την ανάλυση ενός συστήματος μίας κατασκευής είναι πως μπορεί να εφαρμοστεί σε παραδοσιακά και βασιζόμενα σε δεδομένα συστήματα ΠΔΚ, όπως και η αναγνώριση προτύπων, μπορεί να συνδυαστεί με άλλες τεχνολογικές μεθόδους, είναι ιδανική για την οπτικοποίηση δεδομένων, δε χρειάζεται απαραίτητως μεγάλο όγκο δεδομένων και τέλος, είναι υπολογιστικά αποδοτική. Στον αντίποδα, τα μειονεκτήματα που αφορούν τη μέθοδο αυτή έγκεινται μόνο στο γεγονός ότι δεν μπορεί να χρησιμοποιηθεί σε νέα συστήματα οπτικά ΠΔΚ που βασίζονται σε εικόνες. [12]

#### 4.2.3 Βαθιά Μάθηση

Η βαθιά μάθηση (*Deep Learning – DL*) είναι η αποτελεσματική εξαγωγή συγκεκριμένων πληροφοριών ή χαρακτηριστικών από τα δεδομένα, όπως και με την μεταφορά της γνώσης, μέσω μεθόδων πυρήνα σε δομές διανυσμάτων υποστήριξης που υλοποιούν το στάδιο προσαρμοζόμενης ανάλυσης – κατηγοριοποίησης των δεδομένων μέσω των νέων αρχιτεκτονικών νευρωνικών δικτύων. [15]

Επί της ουσίας, είναι ένας κλάδος της μηχανικής μάθησης, που χρησιμοποιεί μεγαλύτερους όγκους δεδομένων και απαιτεί τον προσδιορισμό περισσότερων παραμέτρων για την εκπαίδευση του μοντέλου. Ακόμη, στη βαθιά μάθηση ο υπολογιστής εκπαιδεύεται αυτόματα για στοιχεία που περιλαμβάνονται στα δεδομένα εκπαίδευσης προκειμένου να κάνει μία πρόβλεψη, σε αντίθεση με την μηχανική μάθηση που η διαδικασία αυτή πρέπει να εισαχθεί από τον χειριστή. Έτσι, μέσω της βαθιάς μάθησης εξοικονομείται πολύς χρόνος και η διαδικασία πρόβλεψης διευκολύνεται.

Τα εργαλεία βαθιάς μάθησης αποδεικνύονται να είναι αποτελεσματικότερα στην αναπαράσταση μερικών κατηγοριών συναρτήσεων, ιδίως όσων αφορούν οπτική αναγνώριση, αφού έχουν την ικανότητα να αναγνωρίζουν πιο εύκολα συναρτήσεις που είναι πιο πολύπλοκες σε πολλές εφαρμογές τεχνητής νοημοσύνης.

Η βαθιά μάθηση βρίσκει εφαρμογή σε τομείς όπως το *computer vision*, επεξεργασίας ομιλίας, βιοϊατρική πληροφορική κι άλλους. Η πλειοψηφία των εφαρμογών αυτών περιλαμβάνουν τρία βασικά συστατικά, που αφορούν την αποτελεσματικότητα, την ελαστικότητα και την ακρίβεια του συστήματος. Αυτές οι ιδιότητες παρουσιάζονται με τις ακόλουθες αρχές (*Bengio et al., 2006; SAP SE, 2015*):

- Τα συστήματα βαθιάς μάθησης είναι ικανά να μαθαίνουν από περίπλοκες και πολύ διαφορετικές λειτουργίες.

- Αναλύουν αφηρημένες πληροφορίες χαμηλού, ενδιάμεσου και υψηλού επιπέδου, με ελάχιστη ανθρώπινη παρέμβαση.
- Επεξεργάζονται ένα πολύ μεγάλο σύνολο παραδειγμάτων, χρησιμοποιώντας κυρίως δεδομένα χωρίς ετικέτα.
- Εκμεταλλεύονται τις συνέργειες που πραγματοποιούνται σε μεγάλο αριθμό εργασιών.

Η χρήση της βαθιάς μάθησης για πρώτη φορά συνδυαστικά με τον κατασκευαστικό τομέα έγινε από τον *Sarkar et al.*, προκειμένου να εντοπιστούν ρωγμές σε σύνθετα υλικά. Αργότερα, χρησιμοποιήθηκε και σε πολλές περισσότερες εφαρμογές που αφορούν τον εντοπισμό βλαβών, ρωγμές κατασκευών από σκυρόδεμα και για την εκτίμηση των ζημιών. Σε όλα τα παραπάνω, υπάρχουν αναλυτικές μελέτες, μέσα από τις οποίες προκύπτει πως η βαθιά μάθηση αποτελεί ένα αποτελεσματικό εργαλείο για την παρακολούθηση της κατάστασης μίας κατασκευής και ανοίγουν το δρόμο για την εξέλιξη των μεθόδων ΠΔΚ.

Όπως και για την μηχανική μάθηση, η βαθιά μάθηση έχει τα πλεονεκτήματα πως μπορεί να συνδυαστεί με άλλες τεχνολογικές εφαρμογές, είναι υπολογιστικά αποδοτική και μπορεί να ανταπεξέλθει σε εφαρμογές που χρησιμοποιούνται μεγάλοι όγκοι δεδομένων. Ακόμη, μπορεί να εφαρμοστεί σε εφαρμογές οπτικών συστημάτων ΠΔΚ που βασίζονται σε εικόνες και σε εφαρμογές με τη χρήση μεγάλων δεδομένων για «έξυπνες» πόλεις. Τα μειονεκτήματα, ωστόσο, της μεθόδου αυτής, περιορίζονται στο γεγονός ότι δεν συνδυάζονται με τις παραδοσιακές μεθόδους συστημάτων ΠΔΚ και πως χρειάζονται μεγάλο όγκο δεδομένων προκειμένου να παρουσιάσουν επαρκή αποτελέσματα και συμπεράσματα.

### **4.3 Πρόβλεψη και Νευρωνικά Δίκτυα**

Η πρόβλεψη αποτελεί εν γένει μία συνηθισμένη διαδικασία στην ανάλυση δεδομένων προκειμένου να τεθούν στόχοι και να εντοπιστούν ανωμαλίες σε πάρα πολλούς τομείς. Ωστόσο, παρά την αξία και τη βαρύτητα που έχει μία πρόβλεψη, υπάρχουν αρκετά εμπόδια όσον αφορά την αξιοπιστία και την ακρίβειά της.

Οι πλήρως αυτοματοποιημένες μέθοδοι πρόβλεψης ενδέχεται να μην μπορούν να συντονιστούν στις απαιτήσεις των δεδομένων και συχνά, είναι αδύνατον να συμπεριλάβουν σημαντικές υποθέσεις ή χαρακτηριστικά. Ταυτόχρονα, οι χρήστες που εφαρμόζουν την πρόβλεψη αρκετές φορές δεν είναι εξοικειωμένοι με την πρόβλεψη δεδομένων χρονοσειρών, με αποτέλεσμα να μην αντιλαμβάνονται την ειδική σημασία των χρονοσειρών και την εμπειρία που πρέπει να κατέχει κανείς για το χειρισμό τους.

Προκειμένου να ξεπεραστούν αυτές οι δυσκολίες, πρέπει να χρησιμοποιούνται εργαλεία και μέθοδοι οι οποίοι προσδίδουν μία πρακτική προσέγγιση σε κάθε πρόβλεψη και αποδίδουν τα κατάλληλα αποτελέσματα, ανάλογα με τα χρησιμοποιούμενα δεδομένα.

Προκειμένου να τεθεί δυνατή η μαθηματική μοντελοποίηση των συστημάτων, θεωρούνται κάποιες παραδοχές σχετικά με τη χρήση τους: [16]

- Γραμμικότητα (*linearity*),
- Στασιμότητα (*stationarity*),
- Κανονική κατανομή (*gaussianity*).

Οι παραδοχές αυτές, δεν ισχύουν σε όλες τις περιπτώσεις και στην πραγματικότητα, επαρκούν όμως για να δημιουργηθεί ένα μαθηματικό μοντέλο που να εκφράζει επαρκώς τα ζητούμενα και να συμβάλει στην βελτίωση των υπαρχόντων συστημάτων επεξεργασίας σημάτων και τη δημιουργία νέων.

Η νέα τεχνολογία που καθίσταται ιδανική για την υλοποίηση των παραπάνω είναι τα Τεχνητά Νευρωνικά Δίκτυα. Ειδικά στην πρόβλεψη χρονοσειρών εμφανίζουν πλεονεκτήματα έναντι άλλων συμβατικών μεθόδων πρόβλεψης σε υψηλό βαθμό, καθώς έχουν την δυνατότητα μοντελοποίησης διεργασιών που δεν ακολουθούν τις παραδοχές που τέθηκαν νωρίτερα. Ακόμη, έχουν καλύτερη επίδοση σε σχέση με άλλες μεθόδους όταν στις χρονοσειρές εντοπίζονται θόρυβοι και χαοτικές συμπεριφορές. Οι μέθοδοι πρόβλεψης χρονοσειρών χαρακτηρίζονται από διάφορες κατηγορίες, με κυριότερες τις ακόλουθες:

- Εκθετική εξομάλυνση (*Exponential Smoothing*)
- Ανάλυση παλινδρόμησης (*Regression Analysis*)
- Χρήση αναπροσαρμοζόμενων φίλτρων (*Adaptive Filtering*)
- Κινητός μέσος όρος (*Moving Average*)
- Μέθοδοι Διαχωρισμού (*Decomposition*)
- Τεχνικές *Box-Jenkins*
- Τεχνητά νευρωνικά δίκτυα

Εστιάζοντας στα τεχνητά νευρωνικά δίκτυα και συνοψίζοντας όλα τα παραπάνω, αρχικός στόχος είναι η εκπαίδευση του νευρωνικού δικτύου βάσει μίας σειράς παρατηρήσεων, προκειμένου να προβλεφθεί το άγνωστο μέλλον. Ύστερα, εξάγονται πληροφορίες για το σύστημα που παράγει τη νέα χρονοσειρά.


Τα τεχνητά νευρωνικά δίκτυα (*artificial neural networks - ANN*) είναι εμπειρικά ημι-παραμετρικά μοντέλα που χρησιμοποιούνται σε πολλά διαφορετικά πεδία [16]. Αποτελούν μηχανές που προσπαθούν να μιμηθούν την λειτουργία του ανθρωπίνου εγκεφάλου, ενώ ορίζονται ως αλγόριθμοι που βασίζονται σε μαθησιακές διαδικασίες και εφαρμόζονται μέσω ηλεκτρονικών υπολογιστών, αξιοποιώντας τη λογική και αναλυτικές διαδικασίες.

Με την πάροδο του χρόνου έχουν αναπτυχθεί κι άλλες κατηγορίες, ενώ μερικές φορές, ανάλογα την εφαρμογή, μπορεί να χρησιμοποιηθεί και ο συνδυασμός κάποιων για την επίτευξη του επιθυμητού αποτελέσματος.

Στην πηγή [17] παρουσιάστηκε ένα μοντέλο αξιολόγησης χωρίς βλάβες για συστήματα ΠΔΚ σε γέφυρες, που βασίζεται στα *ANN*. Τα *ANN* εκπαιδεύτηκαν με μεθόδους μη επιβλεπόμενης μάθησης χρησιμοποιώντας δεδομένα από μία γέφυρα, τα σφάλματα είχαν προσδιορισθεί με τη διαδικασία του *Gauss* και οι εμφανιζόμενες βλάβες συγκρίθηκαν με ένα κατώφλι που είχε ορισθεί για τον εντοπισμό τους. Οι σχετικές μελέτες που έγιναν πάνω στη μέθοδο αυτή τονίζουν την σημαντικότητα της μηχανικής μάθησης για την αξιοποίηση των δεδομένων ΠΔΚ και τις τεχνικές αξιολόγησης βλαβών. Παρόλα αυτά, πολλοί αλγόριθμοι ML έχουν δοκιμαστεί ανά τα χρόνια για τη δημιουργία εργαλείων πρόβλεψης της κατάστασης του σκυροδέματος στις κατασκευές, παράγοντας πολλές μελέτες ξεχωριστές για το κάθε ένα. Το κοινό συμπέρασμα όλων, είναι πως οι τεχνικές μηχανικής μάθησης αποτελούν αξιόπιστα και έγκυρα εργαλεία για την εκτίμηση των μηχανικών ιδιοτήτων του σκυροδέματος, χωρίς να επηρεάζονται από τη φύση και την πολυπλοκότητα των δεδομένων.

Τα Αναδρομικά Νευρωνικά Δίκτυα (*RNN*) είναι μία κατηγορία τεχνητών νευρωνικών δικτύων τα οποία αξιοποιούν την τοπολογία, η οποία είναι εμπνευσμένη από τον ανθρώπινο εγκέφαλο, στοχεύοντας στην μάθηση μέσα από τα δεδομένα που τους δίνονται και με την σειρά με την οποία αυτά προσλαμβάνονται, προσπαθώντας να δημιουργήσουν νέο περιεχόμενο βάσει αυτών. Γενικά η ονομασία *RNN* δίνεται συχνά όταν πρόκειται για δύο κατηγορίες δεδομένων που παρουσιάζουν κοινή δομή, όπου το ένα έχει πεπερασμένη ώθηση ενώ το άλλο άπειρη ώθηση, ενώ και οι δύο παρουσιάζουν δυναμική συμπεριφορά.

Τα *RNN* είναι σχεδιασμένα για να δουλεύουν με ακολουθιακά δεδομένα, όπως χρονοσειρές, γραφή, φωνή, οπτική πληροφορία, που προκύπτει από μία δράση ή κίνηση. Ο τρόπος λειτουργίας τους διαφέρει από τα απλά νευρωνικά δίκτυα, καθώς στέλνει το τελικό αποτέλεσμα πίσω στον εαυτό του, ενώ τα κελιά που λαμβάνουν αυτά τα αποτελέσματα ονομάζονται κελιά μνήμης. Εφόσον στο νέο νευρώνα εισάγονται δεδομένα από προηγούμενο, αυτό σημαίνει πως υπάρχει μία μορφή μνήμης σε αυτά και ιστορικών δεδομένων.



**Σχήμα 4-4:** Αναπαράσταση λειτουργίας αναδρομικών νευρωνικών δικτύων  
**Figure 4-4:** Representation of the RNN function



Μαθηματικά αυτό χαρακτηρίζεται από την ακόλουθη σχέση, όπου  $x_t$  είναι η είσοδος τη χρονική στιγμή  $t$ ,  $f(\cdot)$  η συνάρτηση που περιγράφει την επίδραση του αναδρομικού νευρωνικού δικτύου στην είσοδο και  $h_t$  η έξοδος:

$$h_t = f(x_t, h_{t-1}) = f(x_t, f(x_{t-1}, h_{t-2})) = \dots = f(x_t, f(x_{t-1}, \dots, (f(x_1, h_0)) \dots)) \quad (4.2)$$

Ωστόσο, όταν ένα *RNN* εκπαιδεύεται, μετά από λίγο «ξεχνά» τα αρχικά δεδομένα που εισήχθησαν σε αυτό, άρα με κάθε επόμενο βήμα το *RNN* χάνει μία ποσότητα πληροφορίας. Ακόμη, λόγω του προβλήματος που εμφανίζουν, ονομαζόμενο ως εξαφάνιση ή εκτόξευση της κλίσης (*vanishing and exploding gradient problem*), τα αναδρομικά νευρωνικά δίκτυα κατά τη διαδικασία εκπαίδευσης δεν εντοπίζουν σε ικανοποιητικό βαθμό καλές τιμές για τα βάρη του μοντέλου. Για τους λόγους αυτούς, είναι αναγκαία μία μορφή μακράς μνήμης για τα δίκτυα προκειμένου να διορθωθούν αυτές οι δυσλειτουργίες.

Οι νευρώνες μακράς-βραχείας διάρκειας μνήμης (*Long Short-Term Memory - LSTM*), προτάθηκαν για πρώτη φορά από τους *Schmidhuber* και *Hochreiter*, αξιοποιούνται προκειμένου να παραχθεί αποτέλεσμα που να είναι κατανοητό, ώστε το δίκτυο να γνωρίζει τόσο το αντικείμενο που εισάγεται εκείνη την στιγμή, όσο και όλο το ιστορικό πίσω από αυτό. Ένας νευρώνας *LSTM* ουσιαστικά επεκτείνει την μνήμη ενός *RNN* και μπορεί επιλεκτικά να διατηρήσει ή να ξεχάσει πληροφορίες μέσα από κάποιες δομές που περιέχει, που ονομάζονται κύτταρα και θύρες, όπως παρουσιάζονται στην συνέχεια.

Στα *LSTM* δεδομένα εισόδου αποτελούν, όπως και στα αναδρομικά δίκτυα, το  $x_t$  και  $h_{t-1}$ , όμως εδώ εισάγεται και μία τρίτη μεταβλητή το  $c_{t-1}$ . Αρχικά, αποφασίζεται ποιες πληροφορίες θα «ξεχαστούν» από τις δύο πρώτες εισόδους. Ουσιαστικά, ένας νευρώνας *LSTM* κάποια χρονική στιγμή  $t$  θεωρείται πως είναι μία συλλογή διανυσμάτων του χώρου  $\mathbb{R}^d$  και αποτελείται από:

- Θύρα εισόδου  $i_t$
- Θύρα λησμόνησης  $f_t$
- Ένα κύτταρο μνήμης  $c_t$
- Θύρα εξόδου  $o_t$
- Κατάσταση ή κρυφή κατάσταση  $h_t$

Οι μη γραμμικές συναρτήσεις που χρησιμοποιούνται, είναι η σιγμοειδής συνάρτηση  $\sigma(\cdot)$  και η υπερβολική εφαπτομένη  $\tanh(\cdot)$ . Οι εξισώσεις που χαρακτηρίζουν έναν νευρώνα *LSTM* είναι:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4.3)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4.4)$$

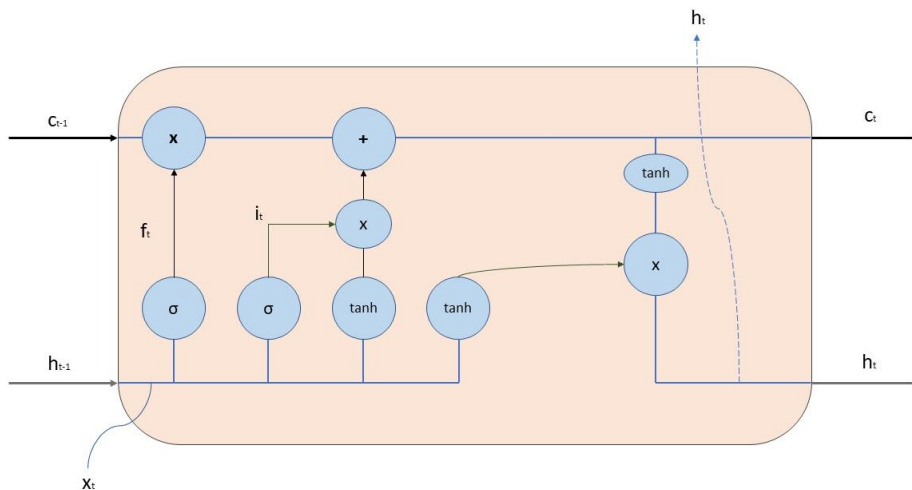
$$\bar{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4.5)$$

$$c_t = f_t * c_{t-1} + i_t * \bar{c}_t \quad (4.6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4.7)$$

$$h_t = o_t * \tanh(C_t) \quad (4.8)$$

Όπου  $x_t$  είναι η είσοδος τη χρονική στιγμή  $t$  και  $b$  ένα διάνυσμα πόλωσης, ενώ  $*$  το γινόμενο *Hadamard*. Ουσιαστικά, μπορεί να θεωρηθεί πως αρχικά η θύρα λησμόνησης ελέγχει κατά πόσο πρέπει να ληφθούν υπόψιν στα επόμενα βήματα οι παρελθούσες καταστάσεις και η θύρα εισόδου ελέγχει ποια διανύσματα θα αλλάξουν και κατά πόσο. Στην συνέχεια, αποφασίζεται ποιες νέες πληροφορίες θα αποθηκευτούν στο κύτταρο μνήμης και μετά ανανεώνεται η πληροφορία που περιέχει το παλαιότερο κύτταρο μνήμης. Τέλος, επιλέγεται τι θα εξέλθει από τον νευρώνα, δηλαδή μέσω της κρυφής κατάστασης ελέγχεται η εξωτερίκευση της εσωτερικής πληροφορίας του κυττάρου, η οποία εξαρτάται από την είσοδο  $x_t$  και όλες τις λειτουργίες πριν από αυτήν.



**Σχήμα 4-5:** Απεικόνιση δομής νευρώνα LSTM  
**Figure 4-5:** Illustration of LSTM neuron structure

#### 4.4 Λογισμικό Πρόβλεψης *Prophet*


Η εταιρεία *Facebook* κατασκεύασε ένα λογισμικό, με το όνομα *Prophet*, που περιέχει την ομώνυμη διαδικασία πρόβλεψης που δημιούργησαν, προκειμένου να πραγματοποιεί προγνώσεις για εταιρικά δεδομένα που είναι στην μορφή που αξιοποιεί η εταιρεία. Παραδείγματα της μορφής αυτών των δεδομένων είναι χρονοσειρές ημερήσιες, ανά λεπτό και γιγάντια σετ δεδομένων.

Το *Prophet* χρησιμοποιεί ένα αρθρωτό μοντέλο παλινδρόμησης, που συχνά δουλεύει με τις προκαθορισμένες παραμέτρους. Επιτρέπει στους αναλυτές να επιλέξουν τα χαρακτηριστικά που είναι σχετικά με το μέγεθος που θέλουν να προβλέψουν και να κάνουν εύκολες προσαρμογές όπου αυτό απαιτείται. Το δεύτερο μέρος του πακέτου αυτού, είναι ένα σύστημα υπολογισμού της ακρίβειας της παραγόμενης πρόγνωσης, ενώ σημειώνονται οι προβλέψεις που πρέπει να ελεγχθούν χειροκίνητα από τον

χειριστή για να εφαρμοστούν πρόσθετες βελτιώσεις. Το μοντέλο αυτό που χρησιμοποιείται, έχει τέσσερις κύριες συνιστώσες:

- Μία γραμμική ή λογιστικής ανάπτυξης καμπύλη τάσης, μέσω των οποίων εντοπίζει αυτόματα τις αλλαγές στην τάση, επιλέγοντας τα σημεία αλλαγής από τα δεδομένα.
- Μία ετήσια εποχική συνιστώσα που έχει μοντελοποιηθεί χρησιμοποιώντας τις σειρές του *Fourier*.
- Μία εβδομαδιαία εποχική συνιστώσα χρησιμοποιώντας ψευδομεταβλητές.
- Μία λίστα σημαντικών εορτών που παρέχεται από τον χρήστη.

Ουσιαστικά, η διαδικασία που ακολουθείται, όπως φαίνεται και στο Σχήμα 4-6, ξεκινά με την μοντελοποίηση των χρονοσειρών αξιοποιώντας προκαθορισμένες τιμές, που έχουν ερμηνεία στην ανθρώπινη φύση, για όλες τις χρησιμοποιούμενες παραμέτρους. Ύστερα, παράγονται προβλέψεις για το μοντέλο και μία σειρά λογικών ορίων, μέσα από ένα πλήθος προσομοιωμένων προβλέψεων ημερομηνιών που έχουν διατηρηθεί ως ιστορικό, ενώ αξιολογείται και η απόδοση της πρόβλεψης. Όταν η απόδοση είναι χαμηλή ή άλλα σκέλη της πρόβλεψης απαιτούν ανθρώπινη παρέμβαση, επισημαίνονται τα πιθανά προβλήματα με μία σειρά σημαντικότητας και προτεραιότητας ώστε να διορθωθούν. Η προσέγγιση αυτή, ονομάζεται από τους δημιουργούς της «*analyst-in-the-loop*».



**Σχήμα 4-6:** Σχηματική απόδοση της *analyst-in-the-loop* προσέγγισης της πρόβλεψης υπό κλίμακα, που αξιοποιεί καλύτερα τις ανθρώπινες και αυτοματοποιημένες διαδικασίες

**Figure 4-6:** Schematic view of the *analyst-in-the-loop* approach to forecasting at scale, which best makes use of human and automated tasks  
(Πηγή: [18])

Ως μοντέλο πρόγνωσης, χρησιμοποιείται ένα μοντέλο αποσύνθεσης χρονοσειρών με τρία βασικά συστατικά, την τάση  $g(t)$ , την εποχικότητα  $s(t)$  και τις διακοπές  $h(t)$ , που συνδέονται με την ακόλουθη μαθηματική σχέση:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (4.9)$$

Ο όρος  $\varepsilon_t$  αφορά οποιαδήποτε σφάλματα ή αλλαγές εμφανίζονται που δεν μπορούν να προσδιοριστούν από το μοντέλο και είναι προκαθορισμένο να ακολουθεί την κανονική κατανομή.

Το συγκεκριμένο μοντέλο, που δεν ακολουθεί άλλα γενετικά μοντέλα (π.χ. ARIMA), έχει κάποια πλεονεκτήματα έναντι άλλων, όπως αναφέρεται στην πηγή [18]:

- Ευελιξία: Μπορούν να προσδιοριστούν εξίσου εύκολα εποχικότητες με πολλές περιόδους και επιτρέπει στον αναλυτή να πραγματοποιήσει διαφορετικές υποθέσεις για τις τάσεις.
- Σε αντίθεση με τα μοντέλα ARIMA, οι παρατηρήσεις των δεδομένων δε χρειάζεται να έχουν συγκεκριμένη χρονική απόσταση μεταξύ τους, και δε χρειάζεται να γίνει παρεμβολή προκειμένου να εισαχθούν χαμένες παρατηρήσεις.
- Προσαρμόζεται πολύ γρήγορα, επιτρέποντας στον αναλυτή να ανακαλύψει περισσότερες λειτουργίες του μοντέλου. (Chang et al, 2015)
- Το μοντέλο πρόγνωσης έχει παραμέτρους που μπορούν να αλλαχθούν εύκολα, ανάλογα με τις ανάγκες του κάθε αναλυτή προκειμένου να κάνει τις δικές του υποθέσεις για την πρόγνωση. Επίσης, οι αναλυτές που έχουν εμπειρία με την παλινδρόμηση, μπορούν εύκολα να επεκτείνουν τα περιεχόμενα του μοντέλου.

Ακόμη, το *Prophet* περιέχει δύο μοντέλα που προσδιορίζουν την τάση, τα οποία καλύπτουν πληθώρα εφαρμογών που χρησιμοποιεί η εταιρεία, ένα μοντέλο κορεσμού ανάπτυξης (μη-γραμμικό) και ένα γραμμικό μοντέλο. Όσον αφορά την εποχικότητα, προσδιορίζεται μέσω μίας τυπικής σειράς *Fourier*, η οποία ακολουθεί την μαθηματική σχέση (4.10). Ακόμη, λαμβάνονται υπόψιν και οι διακοπές και τα σημαντικά γεγονότα κατά τη διάρκεια του χρόνου, καθώς αυτά μπορούν να επηρεάσουν σε μεγάλο βαθμό μία χρονοσειρά και πρέπει να συμπεριλαμβάνονται στις προβλέψεις.

$$s(t) = \sum_{n=1}^N (a_n \cos\left(\frac{2\pi nt}{R}\right) + b_n \sin\left(\frac{2\pi nt}{R}\right)) \quad (4.10)$$

Για την προσαρμογή του μοντέλου, όταν συνδυάζονται η εποχικότητα και οι διακοπές σε έναν πίνακα  $X$ , μπορεί να εκφραστεί μέσα από μερικές μόνο γραμμές κώδικα *Stan* (Carpenter et al. 2017), όπως φαίνεται στο Σχήμα 4-7.

```

// Priors
k ~ normal(0, 5);
m ~ normal(0, 5);
epsilon ~ normal(0, 0.5);
delta ~ double_exponential(0, tau);
beta ~ normal(0, sigma);

// Logistic likelihood
y ~ normal(C ./ (1 + exp(-(k + A *
    delta) .* (t - (m + A * gamma)))) + X
    * beta, epsilon);
// Linear likelihood
y ~ normal((k + A * delta) .* t + (m +
    A * gamma) + X * beta, sigma);
}

```

**Σχήμα 4-7:** Παράδειγμα κώδικα Stan για το πλήρες μοντέλο του Prophet  
**Figure 4-7:** Example Stan code for the complete Prophet model  
 (Πηγή: [18])

Τέλος, προσφέρονται κάποιες αυτοματοποιημένες λειτουργίες για την αξιολόγηση των προβλέψεων που παράγονται. Αυτές αφορούν τα όρια που τίθενται για τις προβλέψεις, την ακρίβεια του μοντέλου πρόβλεψης, προσομοιωμένες προβλέψεις μέσα από το ιστορικό και τον εντοπισμό μεγάλων λαθών στις προβλέψεις.

#### 4.5 Μέθοδοι και Εργαλεία Επεξεργασίας Δεδομένων Χρονοσειρών στην ΠΔΚ

Ο μεγάλος όγκος δεδομένων που λαμβάνονται από την εφαρμογή ΠΔΚ σε γέφυρες αξιοποιούνται μέσα από τεχνικές μεγάλων δεδομένων (*Big Data - BD*), επομένως η ΠΔΚ μπορεί να θεωρηθεί πως υπάγεται σε αυτή την μεγάλη κατηγορία δεδομένων και ειδικότερα, ένα είδος βιομηχανικών μεγάλων δεδομένων (*IBD*). Τα *IBD* είναι τα δεδομένα που λαμβάνονται από μία κατασκευή, μέσω αισθητήρων που έχουν τοποθετηθεί σε αυτήν. Η ανάλυσή τους εμβαθύνει περισσότερο στην επεξεργασία χρονοσειρών και τα αντικείμενα μελέτης τους έχουν πολύ μικρότερη συχνότητα εμφάνισης σε σχέση με άλλων ειδών, το οποίο τα καθιστά πιο πολύπλοκα και ενδιαφέροντα.

Η ΠΔΚ στις γέφυρες σκοπεύει να εντοπίσει αποτελεσματικά βλάβες που υφίστανται στην κατασκευή και να εκτιμήσει την υφιστάμενη κατάστασή τους. Όσον αφορά τον εντοπισμό βλαβών, οι ως τώρα τεχνικές δεν επαρκούν και όταν εφαρμόζονται συνήθως σε υπαρκτές γέφυρες, σημειώνονται πολύ λίγες επιτυχίες.

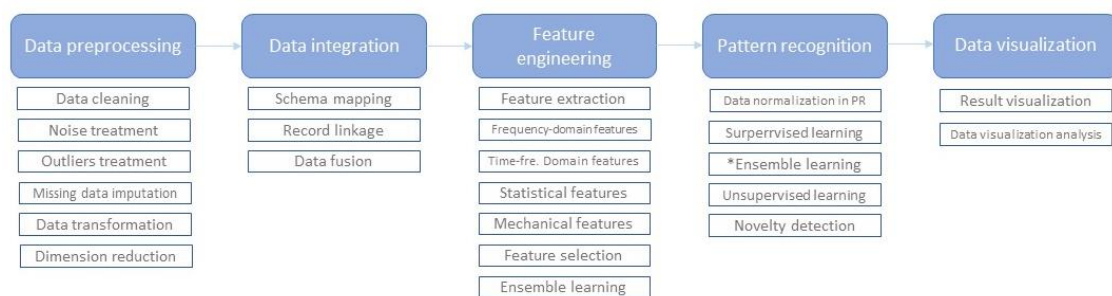
Στην ΠΔΚ έχουν χρησιμοποιηθεί πολλά μοντέλα μηχανικής μάθησης κατά το πέρασ των τελευταίων δεκαετιών. Παράλληλα, τα ήδη υπάρχοντα βελτιώνονται

στοχεύοντας στη δημιουργία νέων πιο αποτελεσματικών, ώστε να μπορούν να επεξεργάζονται μεγαλύτερο όγκο και συνδυασμούς δεδομένων.

#### 4.5.1 Ανάλυση δεδομένων στην ΠΔΚ

Η ανάλυση των δεδομένων που λαμβάνονται από ένα σύστημα ΠΔΚ προκειμένου να χρησιμοποιηθούν και να επεξεργαστούν με μεθόδους τεχνητής νοημοσύνης, ακολουθούν μία διαδικασία με συγκεκριμένες τεχνικές επεξεργασίας. Οι τεχνικές αυτές εφαρμόζονται στην ΠΔΚ σε στάδια όπως η διάγνωση βλαβών, ανάλυση αξιοπιστίας, αναγνώριση προτύπου φόρτου, ανάλυση επίδρασης φόρτου, έγκαιρη προειδοποίηση, εκτίμηση δομικού εξοπλισμού και εντοπισμός σφαλμάτων αισθητήρων. Η σειρά που ακολουθείται είναι η εξής:

- Προεπεξεργασία δεδομένων (*data preprocessing*)
- Ένωση δεδομένων (*data integration*)
- Τεχνική χαρακτηριστικών (*feature engineering*)
- Αναγνώριση προτύπου (*pattern recognition*)
- Οπτικοποίηση δεδομένων (*data visualization*)



**Σχήμα 4-8:** Προτεινόμενη ροή επεξεργασίας μεγάλων δεδομένων στην ΠΔΚ γεφυρών  
**Figure 4-8:** Suggested pipeline of Big Data analysis in bridge SHM  
 (Πηγή: [19])

Η προεπεξεργασία των δεδομένων στοχεύει στην σωστή προετοιμασία των δεδομένων για μεταγενέστερες αναλύσεις. Περιλαμβάνει την εκκαθάριση των δεδομένων, λόγω θορύβου, τάσεων και χαμένων τιμών, την μεταμόρφωση των δεδομένων και την μείωση των διαστάσεών τους, τα οποία είναι αρκετά δύσκολες διαδικασίες που πρέπει να απαλειφθούν από την ανάλυση των δεδομένων ενός συστήματος ΠΔΚ, καθώς είναι χρονοβόρα.

Η δεύτερη τεχνική που εφαρμόζεται, αφορά την ένωση των δεδομένων, ουσιαστικά ενώνει ετερογενή δεδομένα προερχόμενα από διαφορετικές πηγές. Στην τεχνική αυτή συμπεριλαμβάνεται η χαρτογράφηση του σχήματος που αποτυπώνουν τα δεδομένα, η συγχώνευση δεδομένων και η καταγραφή της σύνδεσης που έχουν τα δεδομένα μεταξύ τους.

Η τεχνική χαρακτηριστικών είναι η διαδικασία χρήσης βασικών γνώσεων για την εξαγωγή στοιχείων (χαρακτηριστικά, ιδιότητες, γνωρίσματα) από τα ακατέργαστα δεδομένα. Ένα στοιχείο είναι μια ιδιότητα μοιρασμένη από ανεξάρτητες μονάδες στις οποίες πρέπει να γίνει ανάλυση ή πρόβλεψη. Τα στοιχεία χρησιμοποιούνται από μοντέλα πρόβλεψης και επηρεάζουν τα αποτελέσματα που προκύπτουν από αυτά. Έχει δύο στόχους, να προετοιμάσει κατάλληλα τα δεδομένα εισόδου και να βελτιώσει την απόδοση των μοντέλων μηχανικής μάθησης.

Η αναγνώριση προτύπων, έγκειται στην μέθοδο τεχνητής νοημοσύνης που αναφέρθηκε και νωρίτερα και πρόκειται για μία από τις πιο πολυχρησιμοποιημένες στον τομέα της ΠΔΚ. Όπως αναφέρθηκε, περιέχει τις μεθόδους της επιβλεπόμενης και της μη επιβλεπόμενης μάθησης, ενώ χρησιμοποιείται η κατάλληλη ανάλογα με τον όγκο των δεδομένων που είναι γνωστή η ταυτότητά τους.

Τέλος, η οπτικοποίηση των δεδομένων, ουσιαστικά παρουσιάζει τα αποτελέσματα από όλη την ανάλυση που προηγήθηκε σε γραφική μορφή. Κατά το πέρασ των δεκαετιών, έχουν αναπτυχθεί πολλές μέθοδοι οπτικοποίησης των αποτελεσμάτων και εξακολουθούν όλες να αναπτύσσονται και να βελτιώνονται. Νέες μέθοδοι στην ανάλυση συστημάτων ΠΔΚ που επιτρέπουν την ανθρώπινη παρέμβαση κατά την οπτικοποίηση, μπορεί να προσφέρουν μία νέα εικόνα και μεγάλη βελτίωση στην αποτελεσματικότητα των προτύπων αναγνώρισης που χρησιμοποιούνται.

#### **4.5.2 Εφαρμογές στις χρονοσειρές**

Από τη δεκαετία του 1980, οι τεχνικές μηχανικής μάθησης έχουν διεισδύσει σε ποικίλες εφαρμογές προβλημάτων που υφίστανται στον πραγματικό κόσμο. Κάποιοι παράγοντες που επηρέασαν τη χρήση τους είναι:

- Η ανάγκη για ανάπτυξη μεθόδων που μπορούν να εξελιχθούν μελλοντικά και να μαθαίνουν μέσα από ήδη υπάρχοντα δεδομένα που τους παρέχονται, όπως τα νευρωνικά δίκτυα
- Η αυξημένη επίδραση της τεχνολογίας στην καθημερινότητα, η οποία οδηγεί στην ύπαρξη μεγάλου όγκου δεδομένων καθημερινά
- Πολύπλοκες εφαρμογές που προκύπτουν καθημερινά, όπου η λύση τους απαιτεί μεθόδους και τεχνικές πιο ανθεκτικές σε θορύβους και σε μη γραμμικές επιλύσεις
- Η εξέλιξη της υπολογιστικής δύναμης που παρέχεται, ώστε να υποστηρίζει τεχνικές μηχανικής μάθησης

Στις χρονοσειρές που αφορούν τη δομική μηχανική, οι μέθοδοι της μηχανικής μάθησης και ιδίως της βαθιάς μάθησης, εφαρμόζονται κατά βάση για τον εντοπισμό βλαβών σε κατασκευές μέσω ταξινόμησης ή εξαγωγής στοιχείων. Με τις μεθόδους αυτές, το μοντέλο εκπαιδεύεται από τα πρωτογενή δεδομένα για τις τελικές αποφάσεις που θα εξάγει.

Τόσο η επιβλεπόμενη όσο και η μη επιβλεπόμενη μάθηση εφαρμόζονται προκειμένου να αντιμετωπιστούν διάφορα περίπλοκα προβλήματα που προκύπτουν καθημερινά. Στην επιβλεπόμενη μάθηση αναφέρονται προβλήματα των οποίων οι κατηγορίες διαχωρισμού είναι γνωστές εξ αρχής, ενώ στην μη επιβλεπόμενη όχι. Χωρίς αυτές, θα ήταν πολύ δύσκολο, χρονοβόρο και οικονομικά δαπανηρό να γίνει ο διαχωρισμός για κάθε πρόβλημα, ενώ τα μη κατηγοριοποιημένα δεδομένα δε θα ήταν εύχρηστα.

Οι εφαρμογές αυτές, ανήκουν σε πολλαπλούς τομείς, όπως τα οικονομικά, τη βιοϊατρική, τον εντοπισμό ανωμαλιών, τον αθλητισμό, τη πρόγνωση του καιρού. Εστιάζοντας στον εντοπισμό ανωμαλιών, που συγχέεται άμεσα και με τη δομική μηχανική, οι αλγόριθμοι μηχανικής μάθησης χρησιμοποιούνται προκειμένου να εντοπίσουν αυτόματα λάθη και αστοχίες, αλλά και μέσω του ιστορικού να υπολογίσουν τυπικές αποκλίσεις.

Μία προσέγγιση για τον εντοπισμό ανωμαλιών στην συμπεριφορά του αντικειμένου μελέτης, είναι μέσω της μοντελοποίησης της κανονικής συμπεριφοράς του αντικειμένου και ύστερα να γίνει φιλτράρισμα των τιμών που αποκλίνουν σημαντικά από την αναμενόμενη συμπεριφορά. Οι ανωμαλίες είναι σημαντικό να εντοπίζονται ώστε να αγνοούνται προκειμένου να μην επηρεάσουν το κομμάτι της μετέπειτα πρόβλεψης, αλλά και για να μην συσσωρευτεί η προσοχή του συστήματος σε αυτές ενώ δεν αντικατοπτρίζουν την πραγματικότητα.

Στις υπάρχουσες εφαρμογές μηχανικής μάθησης σε συνδυασμό με νευρωνικά δίκτυα που χρησιμοποιούνται στην ΠΔΚ, χρησιμοποιούνται τα συνελκτικά νευρωνικά δίκτυα (*convolutional neural networks – CNN*) και τα αναδρομικά νευρωνικά δίκτυα (*recurrent neural networks – RNN*). Τα πρώτα είναι περισσότερο χρησιμοποιημένα για εφαρμογές ταξινόμησης, ενώ τα δεύτερα περισσότερο σε συστήματα ΠΔΚ σε γέφυρες. Φυσικά, υπάρχουν κι άλλες τεχνικές που χρησιμοποιούνται, ιδίως μέσα από τη βαθιά μάθηση, που δε θα αναλυθούν σε αυτή τη διπλωματική.

Μερικά παραδείγματα εφαρμογών, αποτελούν η εφαρμογή των *Wang* και *Cha* (2018), χρησιμοποιώντας μη επιβλεπόμενη μάθηση με *CNN* δίκτυα, προκειμένου να δημιουργήσουν ένα πειραματικό μοντέλο γέφυρας, αλλά και του *Abdeljaber et al.* (2017), με στόχο την μελέτη της κατάστασης βλαβών σε γέφυρες. Παρόμοιες μελέτες, με τη χρήση μηχανικής και βαθιάς μάθησης, έχουν γίνει από τους *Gulgec et al.* (2017) και *Lin et al.* (2017) για την μελέτη της κατάστασης βλαβών και τον εντοπισμό τους σε κατασκευές. Με τη χρήση άλλων τεχνικών, έχουν επίσης πραγματοποιηθεί εφαρμογές αναφορικά με την μελέτη των υλικών μίας κατασκευής και τη συχνότητα της επιτάχυνσης.

Σημειώνεται, πως η αναγνώριση προτύπων, που παρουσιάστηκε παραπάνω στο Κεφάλαιο αυτό, έχει εφαρμοστεί σε πολλαπλές εφαρμογές στον κατασκευαστικό τομέα. Αναφορικά, εφαρμογές όπου εφαρμόζεται, στο πεδίο της ΠΔΚ αφορούν τη μελέτη της κατασκευής γεφυρών, εντοπισμό βλαβών, μηχανισμούς αστοχίας, εντοπισμό βλαβών από σεισμούς, μοντελοποίηση της θερμοκρασίας, αντοχή σε



σεισμό και άλλες. Σε όλες τις παραπάνω έχουν χρησιμοποιηθεί διάφοροι μέθοδοι προκειμένου να υλοποιηθεί η αναγνώριση προτύπου, όπως η ανάλυση χρονοσειρών, τα τεχνητά νευρωνικά δίκτυα, η ανάλυση *PCA*, η μέθοδος *Bayes* και άλλες.

## ΚΕΦΑΛΑΙΟ 5 - ΠΕΡΙΓΡΑΦΗ ΓΕΦΥΡΑΣ ΜΕΛΕΤΗΣ ΚΑΙ ΠΡΩΤΟΓΕΝΗ ΔΕΔΟΜΕΝΑ

Στο παρόν κεφάλαιο, παρουσιάζεται η οδική γέφυρα κλάδου 5 & 8 στον κόμβο της Μεταμόρφωσης Αττικής που μελετήθηκε, μαζί με τα βασικά χαρακτηριστικά της. Γίνεται μία γενική περιγραφή της κατασκευής και των δομικών της στοιχείων, ενώ περιγράφονται και οι εργασίες πεδίου που έλαβαν χώρα και όλες οι προπαρασκευαστικές διαδικασίες. Στην συνέχεια, παρουσιάζονται οι πρωτογενείς μετρήσεις, όπως αυτές λήφθηκαν από τους αισθητήρες και τα πρώτα συμπεράσματα που λαμβάνονται από αυτές. Για την εισαγωγή και απεικόνιση των δεδομένων χρησιμοποιήθηκε η γλώσσα προγραμματισμού *Python* και το *Microsoft Excel*.

### 5.1 Περιγραφή Γέφυρας Μελέτης

Οι γέφυρες είναι αναμφίβολα βασικοί πυλώνες της μεταφοράς στην σύγχρονη εποχή, σηματοδοτώντας τοπική, οικονομική και κοινωνική ανάπτυξη. Συγκεκριμένα, στην Αττική Οδό, σύμφωνα με στοιχεία της ίδιας, σε συνολικό μήκος 70 km, έχουν κατασκευαστεί οδικές γέφυρες για 100 άνω διαβάσεις και 25 κάτω διαβάσεις, 38 γέφυρες σιδηροδρομικών γραμμών, 21 γέφυρες ρεμάτων και 12 πεζογέφυρες. Συνολικά στην Ελλάδα, καταγράφηκε το Νοέμβριο του 2019 πως περισσότερες από 7.000 γέφυρες βρίσκονται στο «κόκκινο», καθώς παρέμεναν άγνωστες οι φθορές τους και είχαν ξεπεράσει το όριο ζωής τους. Ωστόσο, για την Αττική Οδό και την υπό μελέτη γέφυρα δεν ισχύει κάτι τέτοιο, καθώς καταγράφονται και παρακολουθούνται συνεχώς τα τεχνικά της έργα και οι Δείκτες Απόδοσής τους, στοχεύοντας τη βελτίωση των παρεχόμενων υπηρεσιών και έχοντας βραβευθεί για αυτή την πολιτική.


Η υπό μελέτη γέφυρα, βρίσκεται επί του αυτοκινητοδρόμου της Αττικής Οδού ΑΕ στο ύψος της Μεταμόρφωσης. Η γέφυρα αυτή αποτελεί την ένωση της Αττικής Οδού στην περιοχή της Μεταμόρφωσης με τον αυτοκινητόδρομο της Εθνικής Οδού από την Αθήνα στη Θεσσαλονίκη.

Συγκεκριμένα, βρίσκεται στην Αττική Οδό στον κόμβο της Μεταμόρφωσης, ο οποίος είναι κατασκευασμένος σε τέσσερα επίπεδα. Οι κλάδοι 5 & 8 υπάγονται στο 4<sup>ο</sup> επίπεδο, ενώ κατασκευάστηκαν πάνω από τις ήδη υπάρχουσες γέφυρες των κλάδων 1 & 2 που ανήκουν στο 3<sup>ο</sup> επίπεδο. Η γέφυρα Α.Δ. της Εθνικής Οδού Αθηνών – Λαμίας ανήκει στο 2<sup>ο</sup> επίπεδο και η Ε.Λ.Ε.Σ.Σ. (Ελεύθερη Λεωφόρος Ελευσίνιας – Σταυρού – Σπάτων) μαζί με τον προαστιακό σιδηρόδρομο καταλαμβάνουν το 1<sup>ο</sup> επίπεδο.

Η γέφυρα κλάδου 5 είναι συνολικού μήκους 465 m, με μεσαία ανοίγματα 47.50 m και η γέφυρα κλάδου 8 είναι συνολικού μήκους 470 m, με μεσαία ανοίγματα 61.40 m. Οι φορείς τους είναι κατασκευασμένοι από προεντεταμένο σκυρόδεμα, εδράζονται μέσω εφεδράνων σε μονόστυλα βάθρα και η θεμελίωση έχει γίνει με έγχυτους πασσάλους.



**Σχήμα 5-1:** Κόμβος Μεταμόρφωσης  
**Figure 5-1:** Metamorfofi junction



**Σχήμα 5-2:** Τρισδιάστατη όψη κόμβου Μεταμόρφωσης  
**Figure 5-2:** 3D view of the Metamorfofi junction  
(Πηγή: Google Earth)

### 5.1.1 Προπαρασκευαστικές διαδικασίες και εργασίες πεδίου

Αναμφισβήτητα η διαδικασία συλλογής δεδομένων αποτελεί ένα βασικό πυλώνα όλων των διαδικασιών που αποτελούν μία μελέτη, ώστε το αποτέλεσμα που θα παραχθεί να είναι άρτιο, πλήρες και αξιόπιστο. Βάσει αυτής της λογικής, διαμορφώνεται η διαδικασία κατά την οποία συλλέχθηκαν τα δεδομένα πεδίου για την ενόργανη παρακολούθηση του πυλώνα Μ8 της γέφυρας κλάδου 8 στον κόμβο της Μεταμόρφωσης. Προκειμένου οι μετρήσεις να είναι αξιόπιστες, απαιτείται η διενέργεια προπαρασκευαστικών εργασιών, οι οποίες περιλαμβάνουν την προετοιμασία στο εργαστήριο, στο πεδίο, αλλά και τον εξοπλισμό και την υλοποίηση όλων των απαιτούμενων ενεργειών.

Ο αρχικός σχεδιασμός περιλαμβάνει την επιλογή των οργάνων που θα τοποθετηθούν στην κατασκευή, τις θέσεις τους ώστε να λαμβάνονται ικανοποιητικά δεδομένα

βάσει του σκοπού της μελέτης και αμοιβαίας ορατότητας, τα σενάρια παρατήρησης, επιλογή ημερών και ωρών για την πραγματοποίηση των μετρήσεων ιδίως ανάλογα με τις καιρικές συνθήκες και τέλος, ζητήματα συγχρονισμού των αισθητήρων.

Σε ένα σύστημα ενόργανης παρακολούθησης κατασκευής εμπεριέχονται κάποια στοιχεία, όπως αναφέρθηκε και στο Κεφάλαιο 1, τα οποία παρουσιάζονται στο Σχήμα 5-3.



**Σχήμα 5-3:** Στοιχεία συστήματος ΠΔΚ  
**Figure 5-3:** SHM components

Επομένως, βάσει όλων των παραπάνω, σχεδιάσθηκαν τρία στάδια για την υλοποίηση των μετρήσεων της γέφυρας μελέτης.

Κατά το πρώτο στάδιο, πραγματοποιήθηκε η επιλογή του συστήματος αισθητήρων που αξιοποιήθηκαν, η μεταφορά των δεδομένων και η διαχείριση των παραγόμενων μετρήσεων. Στον σχεδιασμό, εμπεριέχεται τόσο η επιλογή του εξοπλισμού, όσο και οι θέσεις που θα τοποθετηθούν οι αισθητήρες, όπως προαναφέρθηκε, προκειμένου να είναι αποτελεσματικές οι μετρήσεις.

Κατά το δεύτερο στάδιο, περιλαμβάνεται η εγκατάσταση των αισθητήρων στα σημεία που επιλέχθηκαν, η διασύνδεσή τους και η ρύθμιση του συστήματος που ορίζουν οι αισθητήρες.

Τέλος, στο τρίτο στάδιο, περιλαμβάνεται η λήψη, επεξεργασία και ανάλυση των μετρήσεων της συνεχούς και περιοδικής καταγραφής που πραγματοποιήθηκε για το προκαθορισμένο χρονικό διάστημα.

### 5.1.2 Επιλογή θέσεων και εγκατάσταση αισθητήρων

Πριν την μεμονωμένη μελέτη του πυλώνα M8, είχε προηγηθεί μελέτη και των τριών υψηλών πυλώνων της γέφυρας μελέτης, ωστόσο οι αισθητήρες του πυλώνα M8 παρέμειναν στις ίδιες θέσεις. Εφόσον επιλέχθηκαν οι θέσεις εγκατάστασης των

αισθητήρων, τοποθετήθηκαν στους τρεις πυλώνες M6, M7 και M8 του κλάδου Ελευσίνα προς Λαμία τρία διαξονικά ψηφιακά κλισίμετρα (*Nivel220, Leica Geosystems, ±0.0047 mrad*), ένα στον κάθε πυλώνα. Μέσω των ψηφιακών κλισιμέτρων παρακολουθήθηκε η στατική και ημιστατική μετακίνηση των κορυφών των τριών υψηλών πυλώνων. Τα τρία κλισίμετρα τοποθετήθηκαν στο άνω και βορινό μέρος του κάθε πυλώνα και εντός ειδικά κατασκευασμένων μεταλλικών κλωβών, προκειμένου να μην εκτίθενται στον ήλιο. Ακόμη, τοποθετήθηκε και ένα τέταρτο κλισίμετρο εκτός της κατασκευής και σε σταθερό σημείο, προκειμένου να ελεγχθεί η επίδραση περιβαλλοντικών παραγόντων στις μετρήσεις.

Για την οριζοντίωση των κλισιμέτρων χρησιμοποιήθηκε το λογισμικό Nivel Tool της εταιρείας *Leica Geosystems*. Οι άξονες των κλισιμέτρων προσανατολίστηκαν με τέτοιο τρόπο ώστε ο οριζόντιος άξονας x να είναι σε παραλληλία με τον άξονα του κλάδου που μελετήθηκε και ο κατακόρυφος άξονας y να είναι κάθετος σε αυτόν. Σημειώνεται πως η διεύθυνση +x θεωρήθηκε στην κατεύθυνση προς Ελευσίνα. Τα κλισίμετρα κατέγραψαν μετρήσεις μεταβολής μεταξύ της στατικής και της ημιστατικής γωνιακής απόκλισης στην κορυφή του κάθε πυλώνα συγκριτικά με την κατακόρυφο.

Τα τέσσερα κλισίμετρα συνδέθηκαν μεταξύ τους, προκειμένου να επιτευχθεί η μεταφορά των δεδομένων, με τον υποδοχέα πρωτοκόλλου RS485 εντός του κλωβού του κλισιμέτρου αναφοράς. Στο τέλος της σειράς των κλισιμέτρων, στο κλισίμετρο του πυλώνα M8, τοποθετήθηκε μία τερματική αντίσταση ώστε να ολοκληρωθεί η συνδεσμολογία τους. Στον ίδιο πυλώνα, τοποθετήθηκε και ένα επιταχυνσιόμετρο του οποίου τα δεδομένα δεν αναλύονται στην παρούσα διπλωματική.



**Σχήμα 5-4:** Θέσεις ψηφιακών κλισιμέτρων στις στέψεις των πυλώνων M6, M7, M8 και του κλισιμέτρου αναφοράς

**Figure 5-4:** Locations of the digital inclinometers at the caps of the piers M6, M7, M8 and of the reference inclinometer

(Πηγή: Google Earth)

Όπως αναφέρθηκε και στο Κεφάλαιο 3, για την καταγραφή των μετεωρολογικών χρησιμοποιήθηκαν αισθητήρες θερμοκρασίας – πίεσης (*DTM, STS*) και αισθητήρες θερμοκρασίας – υγρασίας (*HMP 110, Vaisala*). Οι αισθητήρες αυτοί τοποθετήθηκαν στους πυλώνες M7 και M8, αντίστοιχα.

Στον πυλώνα M8, όπως σημειώθηκε παραπάνω, τοποθετήθηκε ένα επιταχυνσιόμετρο υψηλής ευαισθησίας για την παρακολούθηση των συνθηκών λειτουργίας του και ειδικοί αισθητήρες θερμοκρασίας – υγρασίας. Οι αισθητήρες *HMP 110, Vaisala* εγκαταστάθηκαν μέσα σε ειδικό περίβλημα στην κορυφή του πυλώνα M8.



Σχήμα 5-5: Θέσεις εγκατάστασης αισθητήρων καταγραφής μετεωρολογικών  
Figure 5-5: Installation locations of meteorological recording sensors

## 5.2 Πρωτογενή Δεδομένα Ψηφιακών Κλισιμέτρων


Τα δεδομένα που λήφθηκαν μετά από παρακολούθηση 4 μηνών του υψηλού πυλώνα της γέφυρας μελέτης, αποτελούνται από 4 χρονοσειρές που περιέχουν στην κλίση του πυλώνα στους άξονες x και y, την θερμοκρασία, την ατμοσφαιρική πίεση, την υγρασία και το ύψος βροχής. Τέλος, παρέχονται και δεδομένα για την κυκλοφορία κατά το ίδιο διάστημα από μεμονωμένο αισθητήρα που είχε τοποθετηθεί στο οδόστρωμα.

Από τα αρχικά δεδομένα, παρατηρώντας το χρόνο λήψης των μετρήσεων, διαπιστώνεται πως η συχνότητα καταγραφής δεν ήταν ίδια για όλους τους αισθητήρες. Ακόμη, παρατηρείται πως τα δεδομένα ακολουθούν μία τάση (*trend*), καθώς παρουσιάζουν και εποχικότητες (*seasonalities*). Ωστόσο, προκειμένου να ληφθούν πιο συγκεκριμένα αποτελέσματα, ήταν αναγκαία η ένωση όλων των δεδομένων σε ένα ενιαίο πλαίσιο, κάνοντας κάποια σύμβαση για τους διαφορετικούς χρόνους λήψης δείγματος. Κατά αυτό τον τρόπο, θα είναι δυνατή η πρόβλεψη της πορείας των μεταβλητών που ενδιαφέρουν να μελετηθούν. Η οπτικοποίηση και επεξεργασία των δεδομένων έγινε με τη χρήση της γλώσσας προγραμματισμού Python και με τεχνικές Μηχανικής Μάθησης, που αναλύονται σε επόμενο κεφάλαιο.

### 5.2.1 Πρωτογενείς παρατηρήσεις

Όπως αναφέρθηκε και παραπάνω, από την παρακολούθηση της γέφυρας μελέτης λήφθηκαν 4 διαφορετικές χρονοσειρές. Οι χρονοσειρές αυτές περιέχουν δεδομένα κλίσης στους άξονες  $x$  και  $y$ , θερμοκρασίας, ατμοσφαιρικής πίεσης, υγρασίας και ύψους βροχής. Τα δεδομένα των κλισιμέτρων λήφθηκαν ύστερα από συνεχή καταγραφή από τον Μάρτιο 2019 έως και τον Ιούνιο 2019. Στην παρούσα διπλωματική εργασία θα μελετηθούν τα δεδομένα κλίσεων και τα μετεωρολογικά δεδομένα που τα συνοδεύουν για το διάστημα καταγραφής που αναφέρθηκε και αφορά τον υψηλό πυλώνα M8 του κλάδου 8.

Όπως αναφέρθηκε και στο Κεφάλαιο 3, τα κλισίμετρα καταγράφουν μετρήσεις που αντιστοιχούν στη γωνία που σχηματίζεται ανάμεσα στο κατακόρυφο επίπεδο και στο επίπεδο που υλοποιεί ο αισθητήρας, η οποία επηρεάζεται από την κλίση του πυλώνα στον οποίο είναι τοποθετημένος ο αισθητήρας. Κάθε κλισίμετρο κατέγραψε μετρήσεις στους δύο άξονες  $x$  και  $y$ , που σχηματίζουν δύο κάθετες μεταξύ τους διευθύνσεις, και αντιστοιχούν σε μετρήσεις γωνιών κλίσης κατά πλάτος και μήκος (Σχήμα 5-6).



Σχήμα 5-6: Διατμητική επίδραση που παρατηρείται από τα δεδομένα κλίσης  
Figure 5-6: Shear effect on inclinometer observations  
(Πηγή: Gikas et al., 2019)

Σύμφωνα με τα τεχνικά χαρακτηριστικά που παρουσιάζει ο αισθητήρας *Nivel220* που χρησιμοποιήθηκε, έχει εύρος μέτρησης  $\pm 1.51$  mrad, επομένως κρίθηκε σκόπιμο να διατηρηθούν όσες μετρήσεις έχουν τιμές έως  $\pm 1.50$  mrad ( $\pm 960$   $^{\circ}$ ).


Από τις ληφθείσες σειρές μετρήσεων από το συνολικό διάστημα καταγραφής, έγινε από 4 κλισίμετρα στις κορυφές των πυλώνων και τον μετεωρολογικό σταθμό στην στέψη του υψηλού πυλώνα M8 και αποδόθηκαν 159,740 παρατηρήσεις κλίσης, 174,170 παρατηρήσεις μετεωρολογικών στοιχείων (θερμοκρασία, ατμοσφαιρική πίεση), 171,315 παρατηρήσεις υγρασίας και 122 παρατηρήσεις ύψους βροχής. Στην συνέχεια παρουσιάζονται οπτικά τα αρχικά δεδομένα, όπως προέκυψαν πριν οποιαδήποτε επεξεργασία.

Στον ακόλουθο Πίνακα 5-1, παρατίθενται τα στατιστικά στοιχεία για τα μετρηθέντα στοιχεία, όπως προέκυψαν από τις μετρήσεις που λήφθηκαν από τους αισθητήρες κατά το διάστημα Μάρτιος 2019 έως Ιούνιος 2019. Τα στοιχεία αυτά προκύπτουν μετά από συνένωση των τεσσάρων σειρών δεδομένων σε μία, όπως παρουσιάζεται στην συνέχεια.

	Ατμοσφαιρική Πίεση [mbar]	Ύψος βροχής [mm]	Υγρασία [%]	Κλίση άξονα x [rad]	Κλίση άξονα y [rad]	Θερμοκρασία [ $^{\circ}$ C]
Μέση τιμή	999.8	3	61.12	-0.00006	-0.00029	17.9
Μέγιστη τιμή	1013.4	8	94.12	0.00059	0.00029	33.8
Ελάχιστη τιμή	916.7	0	22.15	-0.00082	-0.00106	3.4
Τυπική απόκλιση	4.8	4	13.03	0.00005	0.00010	6.6

Πίνακας 5-1: Στατιστικά στοιχεία μετρηθέντων στοιχείων  
Table 5-1: Calculated values statistics

Η πρώτη χρονοσειρά, που αφορά τα δεδομένα κλίσης, δεν είναι ξεκάθαρο από την αρχική τους όψη αν ακολουθείται κάποια εποχικότητα ή τάση (Σχήμα 5-7).



Σχήμα 5-7: Οπτικοποίηση δεδομένων κλίσης  
Figure 5-7: Visualization of inclination data



### 5.2.2 Προεπεξεργασία δεδομένων

Πριν από την διαδικασία επεξεργασίας των δεδομένων, προκειμένου να αναλυθούν τα δεδομένα μίας χρονοσειράς και να δημιουργηθούν μοντέλα πρόγνωσης, είναι αρκετά βοηθητικό να εντοπιστούν και να απομονωθούν κάποιοι ενδογενείς παράγοντες οι οποίοι επηρεάζουν την συμπεριφορά τους. Ουσιαστικά, παρακάτω παρουσιάζεται μία αποσύνθεση των διαθέσιμων χρονοσειρών, όπου απομονώνονται χαρακτηριστικά όπως η τάση, από τα δεδομένα κλίσης.

Η τάση, όπως αναφέρθηκε και στον Κεφάλαιο 4, είναι ένα μοτίβο στα δεδομένα που δείχνει τη μετακίνηση μιας χρονοσειράς σε σχετικά υψηλότερες ή χαμηλότερες τιμές για μεγάλο χρονικό διάστημα. Με άλλα λόγια, μια τάση παρατηρείται όταν υπάρχει μια αυξανόμενη ή μειωμένη κλίση στις χρονοσειρές. Η τάση συνήθως δεν επαναλαμβάνεται, ενώ συμβαίνει για κάποιο χρονικό διάστημα και μετά εξαφανίζεται.

Για την εύρεση της τάσης στα δεδομένα, χρησιμοποιήθηκε το φίλτρο *Hodrick-Prescott*. Με το φίλτρο αυτό, η χρονοσειρά ( $y_t$ ) χωρίζεται σε δύο στοιχεία, την τάση ( $\tau_t$ ) και το κυκλικό στοιχείο ( $c_t$ ), ενώ ισχύει η σχέση:


$$y_t = \tau_t + c_t \quad (5.1)$$

Τα στοιχεία προσδιορίζονται ελαχιστοποιώντας την ακόλουθη συνάρτηση τετραγωνικής απώλειας, όπου  $\lambda$  είναι μία παράμετρος εξομάλυνσης.


$$\min \tau_t \sum_{t=1}^T (c_t^2) + \lambda \sum_{t=1}^T [(\tau_t - \tau_{t-1}) - (\tau_{t-1} - \tau_{t-2})]^2 \quad (5.2)$$

Η παράμετρος  $\lambda$  ουσιαστικά διαχειρίζεται τις μεταβολές που παρουσιάζονται στο ρυθμό αύξησης της τάσης. Όταν τα δεδομένα που αναλύονται αναφέρονται σε τρίμηνα, η προκαθορισμένη τιμή για το  $\lambda$  είναι 1600, ενώ όταν πρόκειται για ετήσια δεδομένα 6.25 και για μηνιαία 129,600.

Για την εύρεση της τάσης στα δεδομένα κλίσης, αρχικά εφαρμόστηκε η παραπάνω μέθοδος στην κλίση του άξονα  $x$  (Σχήμα 5-8) και για τον άξονα  $y$  (Σχήμα 5-9) και αποδόθηκαν τα ακόλουθα αποτελέσματα.



**Σχήμα 5-8:** Τάση στα δεδομένα χρονοσειράς για την κλίση στον άξονα x  
**Figure 5-8:** Trend in the timeseries data for the inclination of the x-axis



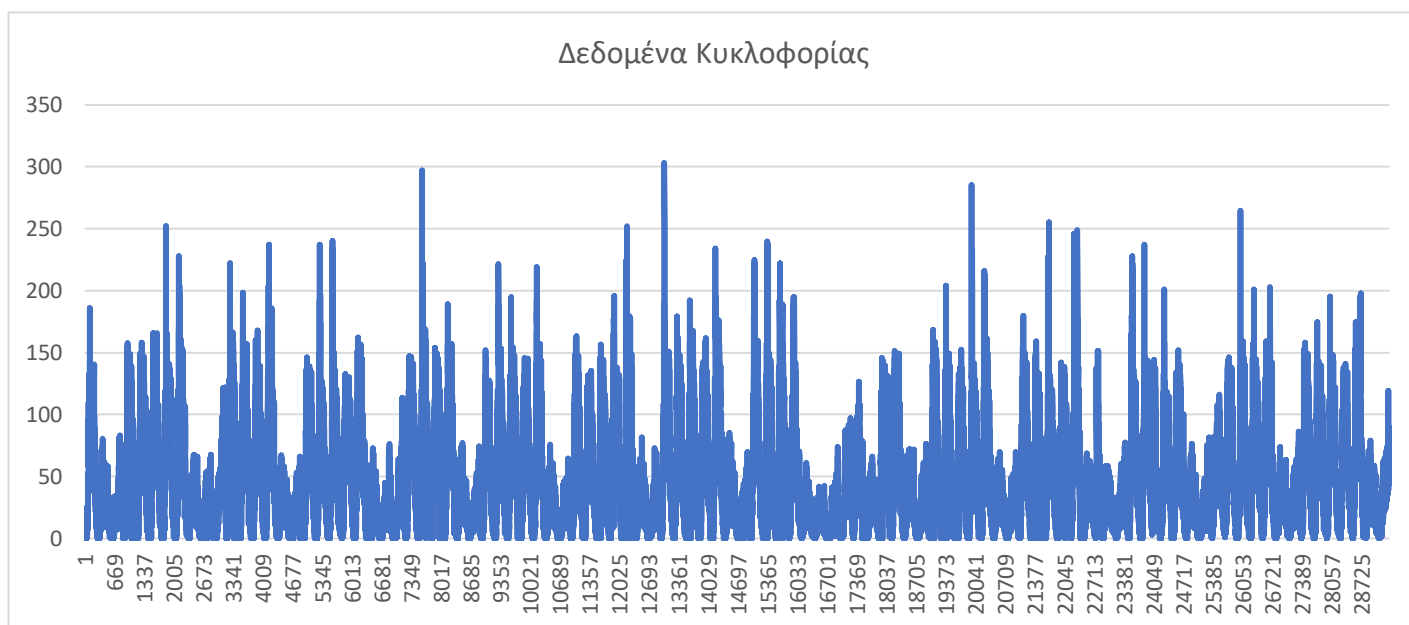
**Σχήμα 5-9:** Τάση στα δεδομένα χρονοσειράς για την κλίση στον άξονα y  
**Figure 5-9:** Trend in the timeseries data for the inclination of the y-axis

Από τα παραπάνω διαγράμματα, παρατηρείται πως υπάρχει μία γενική πτώση στην τιμή της γωνίας κλίσης όσο πλησιάζουν οι θερινοί μήνες. Τόσο για τα δεδομένα της

κλίσης του οριζόντιου άξονα x, όσο και του άξονα y, παρατηρούνται έντονες διακυμάνσεις μεταξύ των ημερών, ωστόσο στα πρώτα είναι αισθητά μεγαλύτερες. Συγκεκριμένα, στον πυλώνα που μελετάται παρατηρείται πως το εύρος κλίσης για τη διεύθυνση y είναι 1.362 mrad, με μέγιστη τιμή τα 0.298 mrad και ελάχιστη τα -1.064 mrad, ενώ στον άξονα x είναι 1.410 mrad, με μέγιστη τιμή τα 0.592 mrad και ελάχιστη τα -0.818 mrad. Οι διακυμάνσεις αυτές, μπορούν να οφείλονται τόσο στην κυκλοφορία, η οποία μεταβάλλεται κατά τη διάρκεια της ημέρας, άρα επιβαρύνεται διαφορετικά η γέφυρα, όσο και σε περιβαλλοντικούς παράγοντες, όπως την περιβαλλοντική θερμοκρασία και πίεση, και δομικούς, όπως έχουν αναλυθεί και στο Κεφάλαιο 1.

Ακόμη, από τα Σχήματα 5-8 και 5-9 των πρωτογενών δεδομένων κλίσης για τον πυλώνα M8, παρατηρείται πως εντός των δεδομένων υπάρχει μεγάλος όγκος θορύβου ο οποίος πρόκειται να απαλειφθεί κατά την περαιτέρω επεξεργασία.

Εκτός των δεδομένων κλίσης, λήφθηκαν δεδομένα και για την κυκλοφορία κατά το διάστημα των μετρήσεων, με συχνότητα καταγραφής 1 μέτρηση ανά 5 λεπτά. Στα δεδομένα αυτά έγινε διαχωρισμός των διελεύσεων επιβατηγών Ι.Χ. οχημάτων και φορτηγών. Παρακάτω, στο Σχήμα 5-6, παρουσιάζει το άθροισμα όλων των οχημάτων που πέρασαν από το σημείο καταγραφής από 01/03/2019 στις 00:00 h έως και 30/06/2019 στις 23:55 h, δηλαδή το διάστημα κατά το οποίο λήφθηκαν και οι μετρήσεις κλίσης.



**Σχήμα 5-10:** Δεδομένα διελεύσεων κατά την περίοδο μελέτης  
**Figure 5-10:** Transit data during the study period

Βάσει του Σχήματος 5-6, παρατηρείται πως κατά τη διάρκεια της ημέρας η κυκλοφορία αλλάζει, προκαλώντας τοπικά μέγιστα κατά τις ώρες και μέρες αιχμής. Συγκεκριμένα, σχεδόν καθόλη τη διάρκεια μελέτης, οι λιγότερες διελεύσεις παρατηρούνται μεταξύ 22:30 h και 7:15 h της επόμενης ημέρας, ενώ οι περισσότερες

κατά τις μεσημεριανές ώρες και έως το βράδυ αν πρόκειται για καθημερινές, ενώ τα Σαββατοκύριακα καθόλη τη διάρκεια της ημέρας έως το βράδυ, με μέγιστα το μεσημέρι. Ακόμη, κατά τη διάρκεια των διακοπών του Πάσχα παρατηρείται μία πτώση στις διελεύσεις, όπου στο παραπάνω διάγραμμα εντοπίζεται μετά την μέτρηση 16033 (25/04/2019 – Μεγάλη Πέμπτη απόγευμα) και έως την 17100 (29/04/2019 – Δευτέρα του Πάσχα πρωί).

Τέλος, υπολογίσθηκε η συσχέτιση μεταξύ της κάθε μετρημένης παραμέτρου και των κλίσεων, ώστε να μπορεί να αποδειχθεί ποια από αυτές επηρεάζει περισσότερο τα αποτελέσματα που πρόκειται να προκύψουν από την επεξεργασία τους. Οι τιμές που λαμβάνονται για την συσχέτιση δύο μεταβλητών βρίσκονται μεταξύ των τιμών -1 και 1, όπου:

- -1 υποδηλώνει πως υπάρχει μία πλήρως αρνητικά γραμμική συσχέτιση μεταξύ των μεταβλητών
- 0 υποδηλώνει πως δεν υπάρχει συσχέτιση
- 1 υποδηλώνει τη θετική γραμμική συσχέτιση μεταξύ των δύο μεταβλητών

Όσο πιο μακριά βρίσκεται η τιμή του συντελεστή συσχέτισης από τη μηδενική τιμή, τόσο πιο ισχυρή είναι η σχέση μεταξύ των δύο μεταβλητών.

Συντελεστής Συσχέτισης	Κλίση x άξονα	Κλίση y άξονα
Ατμοσφαιρική πίεση	0.24	0.26
Ύψος βροχής	0.60	0.72
Υγρασία	0.59	0.74
Θερμοκρασία	-0.60	-0.81
Κυκλοφοριακά Δεδομένα	0.10	0.10
Κλίση άλλου άξονα	0.60	0.60

Πίνακας 5-2: Συντελεστής συσχέτισης κλίσεων και περιβαλλοντικών παραμέτρων  
Table 5-2: Correlation coefficient between inclinations and environmental variables


## ΚΕΦΑΛΑΙΟ 6 - ΔΙΕΞΑΓΩΓΗ ΕΠΕΞΕΡΓΑΣΙΑΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

### 6.1 Εισαγωγή

Στο παρόν κεφάλαιο παρουσιάζονται τα στάδια ανάλυσης των πρωτογενών δεδομένων των ψηφιακών κλισιμέτρων. Όπως προαναφέρθηκε, για την επεξεργασία, ανάλυση και οπτικοποίηση των αποτελεσμάτων χρησιμοποιήθηκε η γλώσσα προγραμματισμού *Python* και το εργαλείο *Jupyter Notebooks*. Το κεφάλαιο αυτό περιλαμβάνει τη διαδικασία που ακολουθήθηκε καθόλη την επεξεργασία των μετρήσεων, χρησιμοποιώντας τα νευρωνικά δίκτυα *LSTM* και το ανοιχτό λογισμικό πρόβλεψης *Prophet* της εταιρείας *Facebook*. Ακόμη, περιλαμβάνονται τα στατιστικά δεδομένα αυτών και τα τελικά σφάλματα που προκύπτουν από τις δύο μεθόδους πρόβλεψης.

### 6.2 Επεξεργασία και πρόβλεψη δεδομένων κλίσης υψηλού πυλώνα

Προκειμένου να εξετασθούν όλα τα δεδομένα που επηρεάζουν την κλίση του πυλώνα μελέτης, έγινε αρχικά συνένωση των δεδομένων. Κατά αυτό τον τρόπο, δημιουργήθηκε μία σειρά μετρήσεων που περιέχει όλα τα μετρηθέντα δεδομένα και το χρόνο καταγραφής του καθενός ξεχωριστά. Κατά την ένωση, λόγω των μεγάλων κενών που παρατηρούνται, καθώς τα δεδομένα δεν είχαν ίδια συχνότητα καταγραφής, είναι απαραίτητος ο διαχωρισμός τους βάσει της βασικής μεταβλητής που επιθυμείται να μελετηθεί και προβλεφθεί. Η μεταβλητή αυτή είναι η κλίση του πυλώνα, επομένως διατηρούνται οι χρόνοι καταγραφής της κλίσης σε δύο διευθύνσεις,  $x$  και  $y$ , ενώ αφαιρούνται όλα τα δεδομένα που δεν αντιστοιχούν στους χρόνους αυτούς.



**Σχήμα 6-1:** Άξονες καταγραφής κλίσεων  
**Figure 6-1:** Inclination recording axes

Ακόμη, με σκοπό να συμπληρωθούν τα κενά που προέκυψαν στις υπόλοιπες μεταβλητές εκτός της κλίσης από την αφαίρεση κάποιων τιμών, εφαρμόζεται παρεμβολή (*interpolation*). Συγκεκριμένα, η μέθοδος που εφαρμόστηκε χρησιμοποιεί την επόμενη έγκυρη μέτρηση σε μία στήλη προς συμπλήρωση της προηγούμενης κενής.


Στην συγκεκριμένη εργασία, μελετάται η απόκριση του πυλώνα σχετικά με όλους τους περιβαλλοντικούς παράγοντες που καταγράφηκαν. Επομένως, για την πρόβλεψη που πραγματοποιείται έχουν χρησιμοποιηθεί όλες οι υπόλοιπες παράμετροι ως παλινδρομητές (*regressors*). Υπενθυμίζεται πως οι παράμετροι αυτοί είναι η θερμοκρασία, η υγρασία, η ατμοσφαιρική πίεση και το ύψος βροχής, ενώ τα ψηφιακά κλισίμετρα ακριβείας που χρησιμοποιήθηκαν παρουσιάζουν υψηλή ευαισθησία στις θερμοκρασιακές μεταβολές. Ακόμη, έχουν ληφθεί και δεδομένα κυκλοφορίας για τον αριθμό των διερχόμενων οχημάτων.

Για την αξιολόγηση των αποτελεσμάτων, χρησιμοποιείται η ρίζα του σχετικού τετραγωνικού σφάλματος (*RRSE*), το μέσο τετραγωνικό σφάλμα (*MSE*), το μέσο απόλυτο σφάλμα (*MAE*) και το μέσο απόλυτο ποσοστιαίο σφάλμα (*MAPE*).

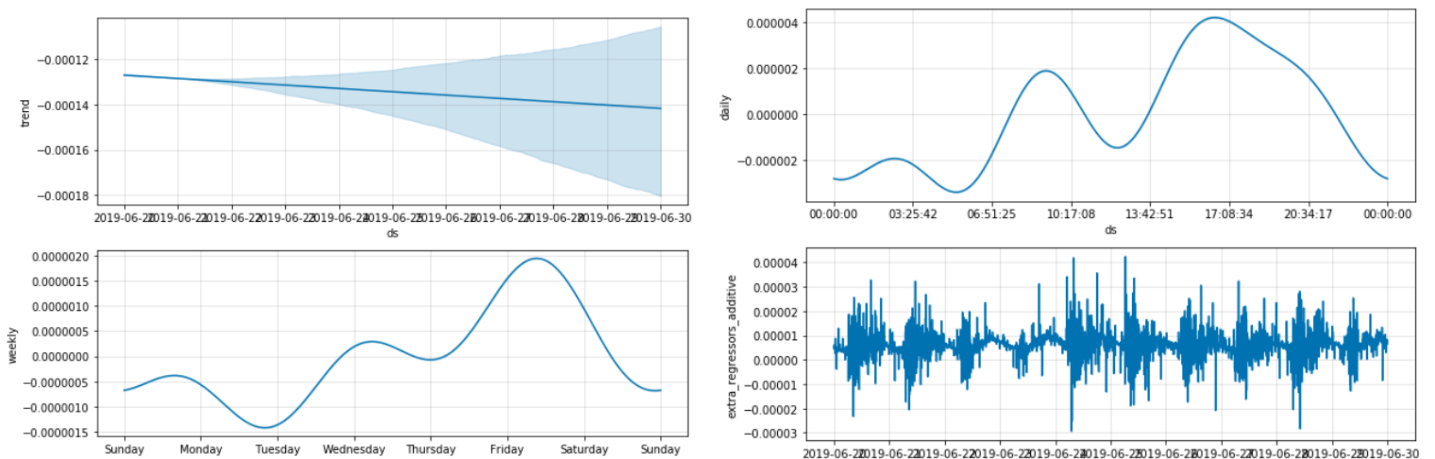
### **6.2.1 Πρόβλεψη με τη χρήση του λογισμικού πρόβλεψης *Prophet***

Με τη χρήση του ανοιχτού λογισμικού *Prophet*, έγιναν δύο ξεχωριστές προβλέψεις για την κάθε διεύθυνση κλίσης και θεωρώντας όλες τις υπόλοιπες παραμέτρους κάθε φορά ως εξωτερικούς παλινδρομητές (*external regressors*). Παράλληλα, γίνεται προσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης μέσω της διαδικασίας που εφαρμόζεται από το *Prophet* πριν την πρόβλεψη, χρήσιμη προκειμένου το μοντέλο μηχανικής μάθησης που πρόκειται να εφαρμοστεί να μπορεί να κατανοήσει τα δεδομένα και να παράγει αντίστοιχα αυτών με τα οποία εκπαιδεύτηκε. Τα δεδομένα εκπαίδευσης λήφθηκαν από την αρχή των καταγραφών, δηλαδή από 01/03/2019 00:00 h έως πριν τις 20/06/2019, ενώ από αυτή την ημέρα μέχρι το τέλος των μετρήσεων θεωρήθηκαν τα δεδομένα ελέγχου.

Η πρόβλεψη με τη χρήση της διαδικασίας αυτής γίνεται πολύ εύκολα και γρήγορα, ενώ είναι εφικτή και η οπτικοποίηση των συνιστωσών που χαρακτηρίζουν τα δεδομένα που προβλέφθηκαν. Στο Σχήμα 6-2 παρουσιάζεται η πρόβλεψη των δεδομένων της κλίσης για τον άξονα x, χωρίς να αλλαχθούν οι προκαθορισμένες παράμετροι του χρησιμοποιούμενου μοντέλου που έχει κατασκευαστεί από την εταιρεία, ενώ στο Σχήμα 6-3 απεικονίζονται οι συνιστώσες που προκύπτουν από την ανάλυση των δεδομένων. Οι συνιστώσες στο Σχήμα 6-3, αφορούν την εποχικότητα που παρουσιάζουν τα δεδομένα σε ημερήσια και εβδομαδιαία βάση, η τάση και η συμβολή των εξωτερικών παραμέτρων που εισήχθησαν στην πρόβλεψη.



**Σχήμα 6-2:** Πρόβλεψη κλίσης άξονα x για 10 d με τη χρήση του Prophet, μαζί με τα ιστορικά δεδομένα  
**Figure 6-2:** Prophet prediction on inclination of x-axis for 10 d, including the historical data



**Σχήμα 6-3:** Τάση, ημερήσια και εβδομαδιαία εποχικότητα και συμβολή εξωτερικών παλιδρομητών για την πρόβλεψη του Prophet του Σχήματος 6-2  
**Figure 6-3:** Trend, daily and weekly seasonality and contribution of the extra regressors for the Prophet prediction on Figure 6-2

Από την ανάλυση που φαίνεται στο Σχήμα 6-3 για όσα εμπεριέχονται στην πρόβλεψη που αφορά τον άξονα x, παρατηρείται στο διάγραμμα της τάσης (*trend*) πως η αβεβαιότητα αυξάνει, όσο αυξάνει και ο χρονικός ορίζοντας αυτής. Συγκεκριμένα, η αβεβαιότητα φτάνει έως και  $\pm 0.00018$  rad, για πρόβλεψη σε βάθος 10 d. Η ακρίβεια αυτή, εμφανώς είναι αρκετά ικανοποιητική.

Από τα διαγράμματα που αφορούν την ημερήσια και εβδομαδιαία εποχικότητα, παρατηρούνται οι περίοδοι αιχμής. Πιο συγκεκριμένα, σε διάστημα 24 h,


παρατηρείται αλλαγή στην κλίση κατά τις πρωινές (06:00-11:00 h) και απογευματινές (16:00-20:00 h) ώρες, δηλαδή τις ώρες αιχμής κατά τις οποίες οι μετακινήσεις έχουν αποδειχθεί και σε προηγούμενο κεφάλαιο πως είναι αυξημένες.

Μετά την πρόβλεψη, η οποία αφορά διάστημα 10 d, υπολογίζονται τα σφάλματα *RMSE* και *MAPE*, τα οποία λαμβάνουν τις ακόλουθες τιμές.

- *RMSE*:  $4.909 \times 10^{-5}$  rad
- *MAPE*: 21.254 %

Προκειμένου να γίνει αντιληπτό αν η τιμή της ρίζας της μέσης τετραγωνικής απόκλισης (*RMSE*) λαμβάνει αποδεκτή τιμή, υπολογίζεται και η τιμή του μέσου από τα δεδομένα ελέγχου για την τιμή της κλίσης του άξονα x. Παρατηρείται πως η διαφορά τους έγκειται σε μία τάξη μεγέθους, αφού ο μέσος προκύπτει  $-1.23 \times 10^{-4}$  rad, επομένως θεωρείται πως η τιμή του *RMSE* είναι αρκετά καλή, άρα και η πρόβλεψη είναι αρκετά ικανοποιητική και αξιόπιστη.

Ακόμη, για τις σημαντικές αλλαγές της τάσης στα δεδομένα, δημιουργήθηκε το παρακάτω διάγραμμα, που δείχνει πότε παρατηρείται αλλαγή σε αυτή και την πορεία της κατά την περίοδο πρόβλεψης (Σχήμα 6-4). Όπως παρατηρείται, η τάση φαίνεται να μεταβάλλεται σημαντικά κάθε 3-4 ημέρες, ενώ στην περίοδο πρόβλεψης παραμένει σταθερή.




**Σχήμα 6-4:** Αλλαγές στην τάση για την κλίση στον άξονα x  
**Figure 6-4:** Trend changing for the inclination of the x-axis

Η συνολική πρόβλεψη παρουσιάζεται στο ακόλουθο Σχήμα 6-5, μαζί με τις πραγματικές τιμές και τις τιμές των σφαλμάτων *MAPE* και *MAE*. Για την δημιουργία της, χρησιμοποιήθηκε η εκτίμηση πυκνότητας πυρήνα (*KDE*) που αποτελεί ένα μέσο εύρεσης της πιθανότητας πυκνότητας σε τυχαίες μεταβλητές, χρησιμοποιώντας τους



πυρήνες *Gauss*. Ουσιαστικά, μέσω αυτού, έγινε εκτίμηση και της πυκνότητας πυρήνα *Gauss* στα δεδομένα κλίσης, εκτός από την απλή πρόβλεψη που έγινε και παραπάνω.

Με κόκκινη γραμμή σηματοδοτείται ο διαχωρισμός των δεδομένων εκπαίδευσης από τα δεδομένα ελέγχου, με πορτοκαλί χρώμα απεικονίζεται η πρόβλεψη των δεδομένων κλίσης και με μπλε χρώμα τα πραγματικά δεδομένα, όπως λήφθηκαν από τα ψηφιακά κλισίμετρα για την κλίση του άξονα x.




**Σχήμα 6-5:** Πρόβλεψη κλίσης άξονα x με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet  
**Figure 6-5:** Predicting inclination of the x-axis with external regressors using the Prophet procedure

Από την παραπάνω πρόβλεψη, το μέσο τετραγωνικό σφάλμα (*MAE-Mean absolute error*) προκύπτει ίσο με  $2.73 \times 10^{-5}$  rad, το οποίο επιβεβαιώνει την ικανοποιητική ακρίβεια της πρόβλεψης, αφού η τιμή του είναι σχεδόν μηδενική άρα πάρα πολύ καλή.

Το λογισμικό *Prophet*, εκτός από τη διαδικασία πρόβλεψης, προσφέρει και μία διαδικασία αυτοματοποιημένων διαγνωστικών. Συγκεκριμένα, γίνεται μία διασταύρωση των στοιχείων που προβλέπονται από τις χρονοσειρές, υπολογίζοντας το σφάλμα της πρόγνωσης μέσα από ιστορικά δεδομένα (*initial*). Αυτό είναι εφικτό μέσα από την επιλογή σημείων όπου η ιστορία «διακόπτεται», γίνεται προσαρμογή του μοντέλου στα προηγούμενα δεδομένα και τότε συγκρίνονται οι τιμές που προβλέφθηκαν με τις πραγματικές. Με την εφαρμογή αυτού, για περίοδο εκπαίδευσης 90 d, πρόβλεψη σε ορίζοντα 10 d και απόσταση μεταξύ των διακοπών, 10 d, προέκυψε το ακόλουθο σφάλμα *RMSE*, που φαίνεται στο Σχήμα 6-6. Η περίοδος διακοπής επιλέχθηκε στις 10 d, καθώς η αναλογία του μήκους των συνολικών δεδομένων με τις προβλέψεις προκύπτει περίπου 12, άρα ήταν μία ικανοποιητική

περίοδος σε σχέση με τα δεδομένα που δίνονται και το εύρος που μπορεί να προβλεφθεί.




**Σχήμα 6-6:** Ρίζα μέσης τετραγωνικής απόκλισης (*RMSE*) της πλήρους διασταυρωμένης επικύρωσης για την πρόβλεψη του Σχήματος 6-2

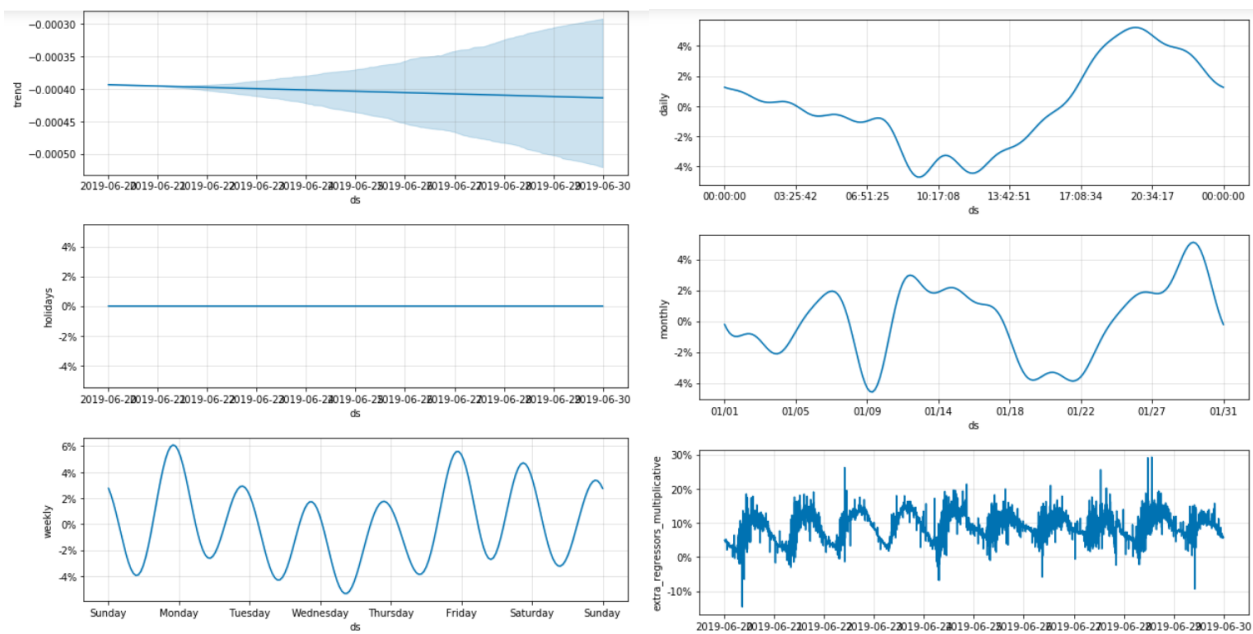
**Figure 6-6:** Root mean squared error (*RMSE*) of the cross-validation for the prediction of Figure 6-2

Ως αξιολογητής της επικύρωσης αυτής επιλέχθηκε το *RMSE*, το οποίο όπως φαίνεται από το παραπάνω σχήμα παίρνει τιμή μικρότερη του  $10^{-4}$ , παραμένοντας σε όλη τη διάρκεια των επιπρόσθετων προβλέψεων κοντά στην ίδια τιμή, χωρίς δραματικές αλλαγές. Ακόμη, το εύρος της πρόβλεψης αφορά 10 d, όπως προαναφέρθηκε, άρα 240 h, όπως αναγράφεται στον οριζόντιο άξονα του διαγράμματος.

Για την πρόβλεψη της κλίσης του άξονα  $y$ , με τον ίδιο τρόπο και λαμβάνοντας τις ίδιες περιόδους για τα δεδομένα εκπαίδευσης και ελέγχου, επιλέχθηκαν κάποιες διαφορετικές παράμετροι στο μοντέλο του *Prophet*, όπως φαίνονται στο σχετικό κομμάτι κώδικα στο Παράρτημα. Συγκεκριμένα, επιλέγεται η αύξηση να είναι γραμμική, το μοντέλο εποχικότητας πολλαπλασιαστικό, να συμπεριλαμβάνονται οι ημερήσιες, εβδομαδιαίες και μηνιαίες εποχικότητες, με την αντίστοιχη περίοδο στην κάθε μία και τέλος, προστέθηκαν οι διακοπές που αντιστοιχούν στις ελληνικές. Έτσι, προέκυψε η αρχική πρόβλεψη της κλίσης του άξονα  $y$  όπως παρουσιάζεται στο Σχήμα 6-7, που αντιστοιχεί σε διάστημα 10 d και η ανάλυση αυτών με τις σχετικές παραμέτρους στο Σχήμα 6-8.



**Σχήμα 6-7:** Πρόβλεψη κλίσης άξονα γ για 10 ημέρες με τη χρήση του Prophet, μαζί με τα ιστορικά δεδομένα  
**Figure 6-7:** Prophet prediction on inclination of  $\gamma$ -axis, including the historical data



**Σχήμα 6-8:** Τάση, ημερήσια και εβδομαδιαία εποχικότητα και συμβολή εξωτερικών παλιδρομητών για την πρόβλεψη του Prophet του Σχήματος 6-7  
**Figure 6-8:** Trend, daily and weekly seasonality and contribution of the extra regressors for the Prophet prediction on Figure 6-7

Από την ανάλυση που φαίνεται στο Σχήμα 6-8 για όσα εμπεριέχονται στην πρόβλεψη που πραγματοποιήθηκε, παρατηρείται στο διάγραμμα της τάσης (*trend*) πως η αβεβαιότητα αυξάνει, όσο αυξάνει και ο χρονικός ορίζοντας αυτής. Συγκεκριμένα, η

αβεβαιότητα φτάνει έως και  $\pm 0.0005$  rad, για πρόβλεψη σε βάθος 10 d, τιμή αποδεκτή και ικανοποιητική.

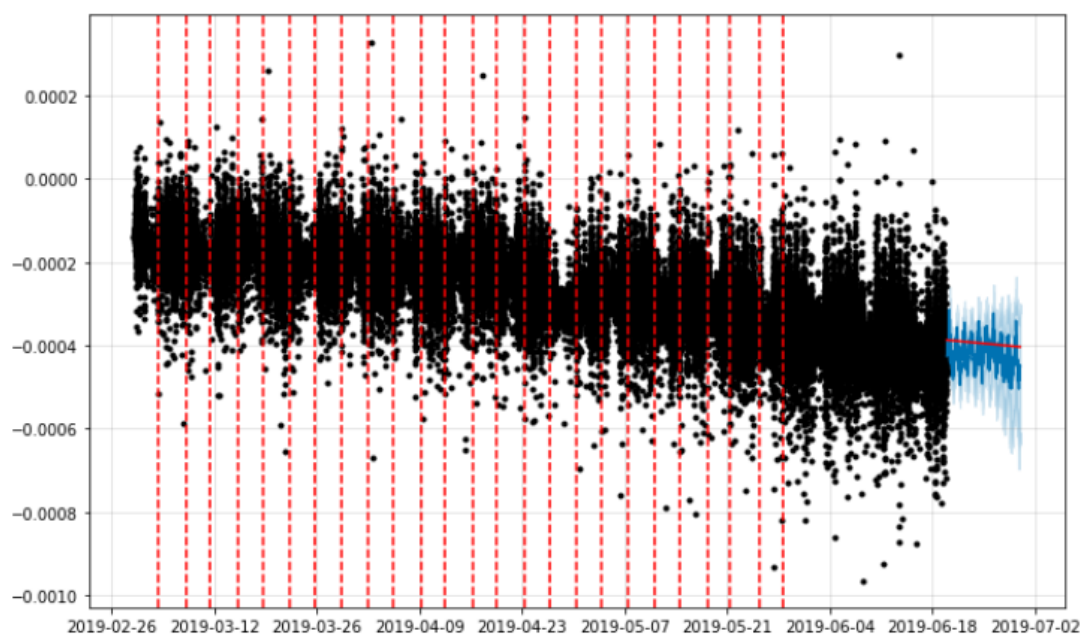
Από τα διαγράμματα που αφορούν την ημερήσια, εβδομαδιαία και μηνιαία εποχικότητα, παρατηρούνται οι περίοδοι αιχμής. Πιο συγκεκριμένα, σε διάστημα 24 h, παρατηρείται μεγάλη αλλαγή στην κλίση κατά τις πρωινές και απογευματινές ώρες, δηλαδή τις ώρες αιχμής κατά τις οποίες οι μετακινήσεις έχουν αποδειχθεί και σε προηγούμενο κεφάλαιο πως είναι αυξημένες. Κατά τη διάρκεια μίας εβδομάδας, παρατηρούνται καθημερινά αυξομειώσεις στην κλίση, γεγονός εξίσου αναμενόμενο, καθώς η γέφυρα βρίσκεται σε κομβικό σημείο από όπου καθημερινά διέρχονται εκατοντάδες οχήματα. Τέλος, το τελευταίο διάγραμμα αφορά τους εξωτερικούς παλινδρομητές (*regressors*) που έχουν χρησιμοποιηθεί κατά την πρόβλεψη.

Μετά την πρόβλεψη, η οποία αφορά διάστημα 10 d, υπολογίζονται τα σφάλματα *RMSE* και *MAPE*, τα οποία λαμβάνουν τις ακόλουθες τιμές.

- *RMSE*:  $6.091 \times 10^{-5}$  rad
- *MAPE*: 9.055 %


Η τιμή του *RMSE*, προκύπτει ξανά μία τάξη μικρότερη από την τιμή του μέσου για την κλίση του άξονα  $\gamma$  και συγκεκριμένα  $6.05 \times 10^{-5}$ , γεγονός που καθιστά την πρόβλεψη αξιόπιστη και ικανοποιητική.

Ακόμη, πραγματοποιείται ανάλυση της αλλαγής της τάσης των δεδομένων, η οποία απεικονίζεται στο Σχήμα 6-9. Παρατηρείται ξανά πως κατά την περίοδο πρόβλεψης η τάση παραμένει σταθερή, ενώ κατά την προηγούμενη περίοδο σημειώνονται μόνο οι σημαντικότερες αλλαγές της.



**Σχήμα 6-9:** Αλλαγές στην τάση για την κλίση στον άξονα  $\gamma$   
**Figure 6-9:** Trend changing for the inclination of the  $\gamma$ -axis

Ακολουθώντας τις ίδιες διαδικασίες με αυτές που περιεγράφηκαν παραπάνω για την κλίση του άξονα  $x$ , υπολογίστηκαν και για την κλίση  $y$  κάποιοι διαγνωστικοί δείκτες και εφαρμόστηκε μία νέα διαδικασία πρόβλεψης προκειμένου να επικυρωθεί η ακρίβεια της πρώτης, διατηρώντας τα ίδια διαστήματα με αυτά νωρίτερα. Η τιμή του  $RMSE$  για τη διασταυρωμένη επικύρωση αποτυπώνεται στο Σχήμα 6-10.



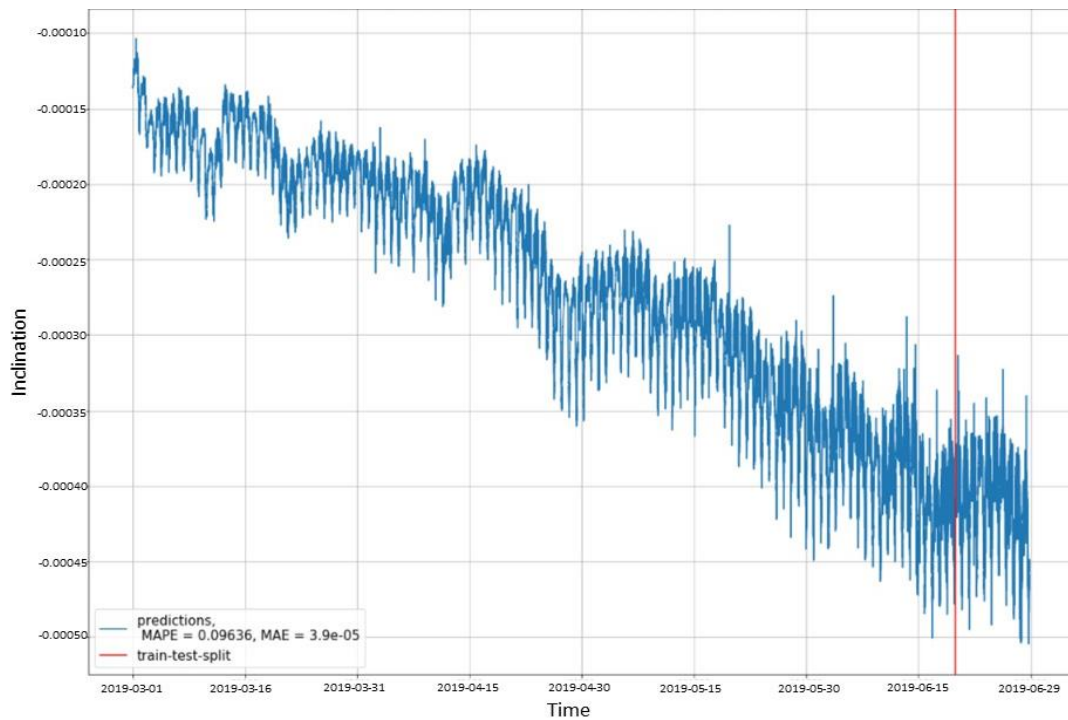
**Σχήμα 6-10:** Ρίζα μέσης τετραγωνικής απόκλισης ( $RMSE$ ) της πλήρους διασταυρωμένης επικύρωσης για την πρόβλεψη του Σχήματος 6-7

**Figure 6-10:** Root mean squared error ( $RMSE$ ) of the cross-validation for the prediction of Figure 6-7

Όπως φαίνεται, υπάρχουν κάποιες αυξομειώσεις στην τιμή του  $RMSE$  οι οποίες είναι κατά τόπους σημαντικές. Ωστόσο, η διάρκειά τους δεν είναι εξαιρετικά μεγάλη και ύστερα η τιμή του σφάλματος μειώνεται ξανά. Αύξησή του παρουσιάζεται και στο τέλος της πρόβλεψης, πλησιάζοντας την τιμή  $\pm 0.0001$  rad. Ωστόσο, οι τιμές αυτές εξακολουθούν να είναι αρκετά καλές και η αξιολόγηση της πρόβλεψης να αποδεικνύει πως είναι αξιόπιστη.

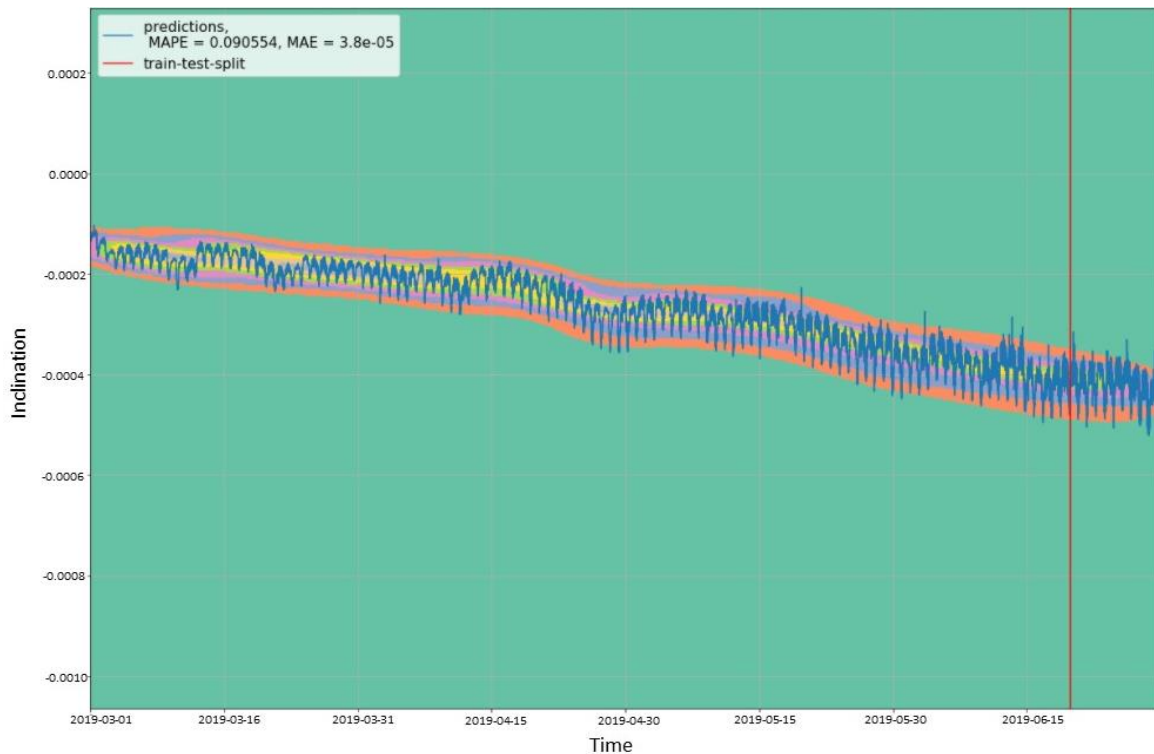
Τέλος, παράγεται η τελική πρόβλεψη για την κλίση στον άξονα  $y$ , χρησιμοποιώντας ως εξωτερικούς παλινδρομητές (*regressors*) όλες τις υπόλοιπες παραμέτρους που υπολογίστηκαν κατά τις μετρήσεις. Η πρόβλεψη παρουσιάζεται με μπλε χρώμα στο Σχήμα 6-11, με κόκκινο η γραμμή διαχωρισμού των δεδομένων εκπαίδευσης και της περιόδου πρόβλεψης και σημειώνονται και τα σφάλματα  $MAPE$  και  $MAE$ .

Σημειώνεται, πως το σφάλμα  $MAE$  προέκυψε ίσο με  $3.892 \times 10^{-5}$  rad, όπως σημειώνεται και πάνω στα Σχήματα 6-11 και 6-12, άρα σχεδόν μηδενικό που είναι πάρα πολύ καλή τιμή.



**Σχήμα 6-11:** Πρόβλεψη κλίσης άξονα γ με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet  
**Figure 6-11:** Predicting inclination of the γ-axis with external regressors using the Prophet procedure

Στο Σχήμα 6-12, παρουσιάζεται η παραπάνω πρόβλεψη συμπληρωμένη με κάποιες ακόμη ενδείξεις. Συγκεκριμένα, γύρω από τις τιμές της κλίσης του άξονα γ, οι πορτοκαλί ενδείξεις αποτυπώνουν την τάση τα δεδομένα, ενώ οι κίτρινες των μέσο όρο τους.



**Σχήμα 6-12:** Πρόβλεψη κλίσης άξονα γ με εξωτερικούς παλινδρομητές χρησιμοποιώντας τη διαδικασία Prophet σε συνδυασμό με την παρουσίαση στατιστικών μεγεθών

**Figure 6-12:** Predicting inclination of the  $\gamma$ -axis with external regressors using the Prophet procedure in combination with the presentation of some statistical features

### 6.2.2 Πρόβλεψη με τη χρήση νευρωνικών δικτύων LSTM

Χάρη πληρότητας, εφόσον η διαδικασία *Prophet* δεν αξιοποιεί τα νευρωνικά δίκτυα αλλά άλλες τεχνικές της μηχανικής μάθησης, εφαρμόστηκαν και τα νευρωνικά δίκτυα *LSTM* προς σύγκριση των αποτελεσμάτων των δύο μεθοδολογιών. Ο κώδικας των νευρωνικών δικτύων *LSTM* γράφτηκε από τον κύριο Παπαδάκη Νικόλαο και προσαρμόστηκε στα δεδομένα της παρούσας διπλωματικής εργασίας.

Η δεύτερη μέθοδος, λοιπόν, που χρησιμοποιήθηκε για την επεξεργασία των μετρήσεων και την πρόβλεψη της επόμενης περιόδου ήταν μέσω νευρωνικών δικτύων *LSTM*. Αρχικά, έγινε κλιμάκωση των δεδομένων εντός του εύρους της μέγιστης και ελάχιστης τιμής τους, μεταμορφώθηκαν κατάλληλα ώστε να ληφθεί η κλιμακωτή μορφή τους και ύστερα, διαμορφώθηκε το μοντέλο το οποίο εκπαιδεύτηκε.

Με το διαχωρισμό των δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου, πρέπει οι παραγόμενες προβλέψεις να ακολουθούν το ίδιο χρονικό πλαίσιο με τις μετρήσεις. Έτσι, δημιουργήθηκε μία λειτουργία στην οποία με την εισαγωγή του αριθμού δεδομένων εισόδου και των δεδομένων εκπαίδευσης, παράγει τις προβλέψεις σε σωστό χρονικό ορίζοντα, δηλαδή με 1 min διαφορά η κάθε μία από την επόμενη.

Επίσης, κατασκευάστηκε το μοντέλο που πρόκειται να εκπαιδευτεί, το οποίο περιλαμβάνει ένα επίπεδο (*layer*) *LSTM* νευρώνα, ο οποίος ενώνεται με δύο επίπεδα *Dense* πριν σταλεί στην συνάρτηση ενεργοποίησης, η οποία θα μετατρέψει την έξοδο από το τελευταίο σε πρόβλεψη. Ακόμη, συμπεριλαμβάνονται όλες οι πληροφορίες σε αυτό σχετικά με το επιθυμητό μήκος δείγματος και του αποτελέσματος.

Για την αξιολόγηση των αποτελεσμάτων, χρησιμοποιείται η ρίζα του σχετικού τετραγωνικού σφάλματος (*RRSE*), το μέσο τετραγωνικό σφάλμα (*MSE*), το μέσο απόλυτο σφάλμα (*MAE*) και το μέσο απόλυτο ποσοστιαίο σφάλμα (*MAPE*) ως συνάρτηση κόστους στα νευρωνικά δίκτυα, για να αναγκάσουν το μοντέλο να κάνει προβλέψεις όσο πιο κοντά στα δεδομένα εκπαίδευσης γίνεται. Τέλος, δημιουργείται μία λειτουργία αξιολόγησης των παραγόμενων προβλέψεων, η οποία υπολογίζει το σχετικό τετραγωνικό σφάλμα (*RSE*) και τη ρίζα αυτού (*RRSE*), ανάμεσα στις πραγματικές τιμές και τις προβλέψεις και τελικά τις συγκρίνει μέσω του δεύτερου.

Από το σύνολο των δεδομένων, το 20% αυτών θεωρήθηκαν δεδομένα ελέγχου, ενώ τα υπόλοιπα επιλέχθηκαν ως δεδομένα εκπαίδευσης. Έγινε η εκπαίδευση του μοντέλου εισάγοντας τις παραμέτρους που ορίστηκαν σε αυτό, δηλαδή τα δεδομένα για τον άξονα  $x$ , τον άξονα  $y$  και τον αριθμό εισόδων που καθορίστηκε 120, δηλαδή ο νευρώνας *LSTM* να χρησιμοποιήσει μόνο αυτές τις μετρήσεις. Ύστερα, υπολογίστηκαν οι προβλέψεις και το σφάλμα *RRSE* ανά μέτρηση και το συνολικό.

Το σφάλμα *RRSE* (*root relative squared error*) παρέχει το τετραγωνικό σφάλμα των προβλέψεων σε σχέση με ένα απλοϊκό μοντέλο που προέβλεψε τη μέση τιμή για κάθε σημείο δεδομένων. Λαμβάνει τιμές από το 0 έως το άπειρο, με καλύτερες αυτές που προσεγγίζουν το μηδέν σε σχέση με τις μεγαλύτερες τιμές.


Από την εκπαίδευση του μοντέλου, βάσει όλων των παραπάνω παραμέτρων, σε 500 περιόδους, προέκυψαν τελικά τα σφάλματα του μοντέλου που ακολουθούν:

- *RRSE*: 0.6136 rad
- *MSE*:  $5.2877 \times 10^{-4}$  rad
- *MAE*: 0.0116 rad
- *MAPE*: 3798.6558

Ακόμη, με τη δημιουργία μίας ακόμα λειτουργίας θα πραγματοποιεί πρόβλεψη της επόμενης εβδομάδας, μέσα από τις τιμές που προέκυψαν από το μοντέλο που δημιουργήθηκε και εκπαιδεύτηκε.

Ακολουθώντας όλη την παραπάνω διαδικασία, γίνεται η πρόβλεψη και οπτικοποίηση της κλίσης του άξονα  $y$  για τις επόμενες 10 ημέρες, όπως φαίνονται και παρακάτω στο Σχήμα 4-10.





**Σχήμα 6-13:** Πρόβλεψη κλίσης άξονα γ με χρήση *LSTM* για τις επόμενες 10 ημέρες  
**Figure 6-13:** Prediction the inclination of the  $\gamma$ -axis using *LSTM* neural networks for the next 10 days

Παρατηρείται πως οι τιμές των προβλέψεων δε διαφέρουν σημαντικά από τις πραγματικές. Από την πρόβλεψη αυτή, προκύπτει γενικό σφάλμα *RRSE* 0.618 rad, όπως και για την κάθε μία πρόβλεψη ξεχωριστά προκύπτει ξανά περίπου 0.6 rad. Συγκεκριμένα, τα σφάλματα για την κάθε μέτρηση είναι αυτά που παρουσιάζονται στον Πίνακα 6-1.

Πρόβλεψη	RRSE (rad)
1	0.58375
2	0.62405
3	0.61534
4	0.64006
5	0.61317
6	0.61193
7	0.60879
8	0.63050
9	0.63139
10	0.62167

**Πίνακας 6-1:** Σφάλμα *RRSE* για τις 10 ημέρες που προβλέφθηκαν με τη χρήση νευρωνικών δικτύων *LSTM*  
**Table 6-1:** *RRSE* error for the next 10 days that were predicted using *LSTM* neural networks

## ΚΕΦΑΛΑΙΟ 7 - ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΜΕΛΛΟΝΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ

Στο παρόν κεφάλαιο παρατίθενται τα συμπεράσματα που λαμβάνονται βάσει των αποτελεσμάτων που προέκυψαν και παρουσιάστηκαν στα προηγούμενα Κεφάλαια. Τα συμπεράσματα αυτά, πηγάζουν από τη μέθοδο καταγραφής, συλλογής και επεξεργασίας των δεδομένων, αλλά και από την απόκριση της κατασκευής κατά το διάστημα μελέτης. Όλες οι παραπάνω εφαρμογές πραγματοποιήθηκαν προκειμένου να μελετηθεί η δομική συμπεριφορά του υψηλού πυλώνα Μ8 της γέφυρας κλάδων 5&8 στον κόμβο της Μεταμόρφωσης με την Αττική Οδό ΑΕ.

Όπως αποδεικνύεται μετά την συλλογή, επεξεργασία και ανάλυση των δεδομένων, η οποία πραγματοποιήθηκε με τη χρήση μεθόδων μηχανικής μάθησης, προκύπτουν τα ακόλουθα συμπεράσματα ως προς την χρήση των ψηφιακών κλισιμέτρων και των αποτελεσμάτων που λήφθηκαν, αλλά και από την σύγκριση των δύο μεθόδων που εφαρμόστηκαν.

Αναφορικά με τις δύο μεθοδολογίες που χρησιμοποιήθηκαν:

- Το *Prophet*, το οποίο περιέχει ένα μοντέλο παλινδρόμησης, είναι αρκετά πιο εύχρηστο ακόμη κι από άτομα που δε γνωρίζουν εις βάθος τη μηχανική μάθηση, προσφέροντας άμεσα και γρήγορα έγκυρες προβλέψεις για το κοντινό μέλλον. Ακόμη, είναι εφικτό να λειτουργήσει αποτελεσματικά διατηρώντας και τις προκαθορισμένες παραμέτρους του για την εφαρμογή της διαδικασίας πρόβλεψης.
- Τα νευρωνικά δίκτυα *LSTM* μπορούν να συμπεριλάβουν στην επεξεργασία τους πολλαπλές παραμέτρους, τις οποίες πρέπει να εισάγει ο χειριστής, ενώ είναι πιο εξειδικευμένα στη χρήση τους και απαιτούν εμπειρία. Η ακρίβεια προσδιορισμού της πρόβλεψης μπορεί να είναι υψηλή, ανάλογα με το μέγεθος του δείγματος και τις επαναλήψεις που γίνονται για την εκπαίδευση του μοντέλου.
- Η διαδικασία πρόβλεψης του *Prophet* είναι κατάλληλη για προβλέψεις σε κοντινό χρονικό διάστημα, ενώ τα νευρωνικά δίκτυα *LSTM* μπορούν να χρησιμοποιηθούν και για προβλέψεις μεγαλύτερης κλίμακας, διατηρώντας μεγάλη ακρίβεια. Στην παρούσα πρόβλεψη και οι δύο μέθοδοι απέδωσαν ικανοποιητικά, με καλύτερες τιμές να λαμβάνονται από την πρόβλεψη με τη χρήση της διαδικασίας *Prophet*.
- Οι παραπάνω μέθοδοι, όπως κι άλλες μέθοδοι τεχνητής νοημοσύνης, μπορούν να αξιοποιηθούν για την μελέτη πεπερασμένων στοιχείων (*finite element method – FEM*) κατασκευών. Με τη χρήση βαθιάς μάθησης μπορούν, για παράδειγμα, να υπολογισθούν προβλήματα που απαιτούν μεγάλο υπολογιστικό όγκο στην *FEM*, σε συνδυασμό με τη χρήση συνελκτικών νευρωνικών δικτύων.

Όσον αφορά τα ψηφιακά κλισίμετρα που χρησιμοποιήθηκαν:

- Τα συγκεκριμένα κλισίμετρα, *Nivel220* της εταιρείας *Leica Geosystems*, είναι εύχρηστα και αποδίδουν ικανοποιητικά όταν πρόκειται για την παρακολούθηση φαινομένων χαμηλής δυναμικής. Το γεγονός αυτό, οφείλεται στην υψηλή ευαισθησία και ακρίβειά τους, χάρη στην μικρή τους μάζα που είναι εύκολη στην τοποθέτηση. Φυσικά, είναι απαραίτητη η εμπειρία στην χρήση και τοποθέτηση του οργάνου κατά τις εργασίες πεδίου και στην μετέπειτα εργασία στο γραφείο.
- Το γεγονός πως τα συγκεκριμένα κλισίμετρα είναι διαξονικά, δηλαδή μετρούν σε δύο άξονες, καθιστά εφικτός τον προσδιορισμό μετακινήσεων σε κατακόρυφη και οριζόντια διεύθυνση, άρα και την απόκλιση από την κατακόρυφο και στις δύο αυτές διευθύνσεις. Η απόδοση των μετρήσεών τους είναι αρκετά υψηλή (έως  $\pm 0.001$  mrad).
- Υπάρχει πιθανότητα εμφάνισης σφαλμάτων λόγω λανθασμένης εγκατάστασης και μη οριζοντίωσης των αισθητήρων, με αποτέλεσμα οι καταγεγραμμένες τιμές κλίσης να αποκλίνουν από την κατακόρυφο.
- Ενδέχεται να εμφανιστούν σφάλματα απόκλισης της επιφάνειας του υγρού στο εσωτερικό του αισθητήρα από την οριζόντια θέση. Το σφάλμα αυτό μπορεί να απαλειφθεί με αναγωγή των μετρήσεων.
- Δεν ενδείκνυνται για μετρήσεις φαινομένων υψηλής δυναμικής λόγω της αδράνειας του υγρού στο εσωτερικό του αισθητήρα.
- Ο παράγοντας που παρουσιάζει την μεγαλύτερη συσχέτιση με την μεταβλητή της κλίσης αποδεικνύεται πως είναι η θερμοκρασία, σύμφωνα με τον Πίνακα 5.2, όπου προκύπτει ο μεγαλύτερος συντελεστής συσχέτισης και για τις δύο διευθύνσεις κλίσης με τη θερμοκρασία.

Συμπεράσματα σχετικά με τον υπό μελέτη πυλώνα:

- Παρουσιάζεται μία κυκλικότητα στα δεδομένα κλίσης του πυλώνα κατά τη διάρκεια της ημέρας, οι οποίες συσχετίζονται και με τις θερμοκρασιακές μεταβολές και με την κυκλοφορία τις αντίστοιχες ώρες.
- Περίοδοι με αυξημένη θερμοκρασία, συγκριτικά με άλλες, παρουσιάζεται μία αύξηση στην κλίση και αυτή να τείνει προς τις αρνητικές τιμές, αποτέλεσμα που προκύπτει και από τις προβλέψεις.

Είναι πολύ σημαντικό να τονιστεί πως η απόδοση των μεθόδων τεχνητής νοημοσύνης στον τομέα της ΠΔΚ εξαρτάται άμεσα από τον όγκο των δεδομένων που συλλέγονται κατά τη διάρκεια παρακολούθησης μίας κατασκευής. Η μηχανική μάθηση αποτελεί ένα πολύ ικανό εργαλείο για την εξαγωγή πληροφοριών και την κατασκευή μοντέλων πρόβλεψης από μεγάλους όγκους δεδομένων. Ακόμη, η έντονη χρήση των μεθόδων αυτών στον κατασκευαστικό τομέα, αποκαλύπτει πως αυτές πρόκειται να χρησιμοποιούνται κατά κόρον για τις μελέτες ΠΔΚ στο μέλλον. Σε συνδυασμό με τους ασύρματους αισθητήρες που έχουν πλέον αναπτυχθεί και χρησιμοποιούνται ως συστήματα παρακολούθησης, τεχνικές μηχανικής και βαθιάς μάθησης φαίνεται να μπορούν να λειτουργήσουν αποτελεσματικά για την επίβλεψη και αξιολόγηση κατασκευών, καθώς η αξιολόγησή τους μπορεί να πραγματοποιηθεί εξ αποστάσεως

με την επεξεργασία των μετρήσεων με τις τεχνικές αυτές. Όπως έχει αναφερθεί ξανά, οι αλγόριθμοι μηχανικής μάθησης είναι ικανοί να εκπαιδεύονται ακόμη και σε αρκετά πολύπλοκα συστήματα που επηρεάζονται από πολλαπλούς παράγοντες, πραγματοποιώντας προβλέψεις αυτόνομα, χωρίς την επέμβαση εμπειρικών μοντέλων και παρέχοντας τη δυνατότητα βελτίωσης των δικών τους αποτελεσμάτων. Έτσι, με τη χρήση τέτοιων συστημάτων αισθητήρων συνδυαστικά με την επεξεργασία των δεδομένων με τεχνικές τεχνητής νοημοσύνης, μπορεί να οδηγήσει σε αρκετά αξιόπιστα και αποτελεσματικά συστήματα ΠΔΚ.

Με τον συνδυασμό των τεχνικών ΠΔΚ, της τεχνητής νοημοσύνης και της ασύρματης μετάδοσης και αποθήκευσης δεδομένων, μπορούν να αναπτυχθούν πολύ εξελιγμένες μορφές των υπάρχοντων συστημάτων παρακολούθησης δομικής κατάστασης των κατασκευών. Τα δεδομένα μπορούν να αποθηκεύονται και μεταφέρονται μέσω υπολογιστικών νεφών, να ελέγχονται ασύρματα και να αναλύονται με τεχνικές μηχανικής μάθησης.

Ακόμη, για την αναγνώριση δομικής κατάστασης, την εκτίμηση αξιόπιστης πρόβλεψης της πραγματικής συμπεριφοράς της κατασκευής σε μελλοντικές διεγέρσεις και την ανάπτυξη μοντέλου φθορών απαιτούνται:

- η λήψη στοχευμένων μετρήσεων, περιοδικού χαρακτήρα της δυναμικής απόκρισης της κατασκευής που θα οδηγήσουν στον υπολογισμό των πραγματικών ιδιομορφικών χαρακτηριστικών (κύριες συχνότητες, ιδιομορφές, συντελεστής απόσβεσης, κ.α.) της γέφυρας
- υπολογισμός του μοντέλου πεπερασμένων στοιχείων (FEM) της κατασκευής
- επικαιροποίηση του αριθμητικού μοντέλου βάσει των μετρητικών στοιχείων
- επανάληψη της διαδικασίας μετά από ικανό χρονικό διάστημα (έτη) και εντοπισμός πιθανών μεταβολών

Τέλος, μπορούν να εφαρμοστούν κάποιες τεχνικές ανάλυσης δεδομένων:

- Safe operating signal envelope
- Dynamic regression modeling
- Principal component analysis
- Mahlanobis distance

Οι οποίες προκειμένου να υλοποιηθούν απαιτούν:

- συνέχιση του προγράμματος καταγραφής (χωρίς διακοπή)
- διορθωτικές κινήσεις ως προς την υπάρχουσα εγκατάσταση
- υιοθέτηση υπολογιστικών εργαλείων εκτίμηση δομικής κατάστασης

## **ΒΙΒΛΙΟΓΡΑΦΙΑ**

- [1] K. Worden, C. R. Farrar, G. Manson, G. Park, 2007. The fundamental axioms of structural health monitoring, *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, Volume 463, Issue 2082
- [2] FPrimeC Solutions Inc., 2019. *Structural Health Monitoring for Bridge Structures*, Oshawa, Canada
- [3] C. Neves, 2020. *Structural Health Monitoring of Bridges: Data-based damage detection method using Machine Learning*, Doctoral Thesis in Structural Engineering and Bridges, KTH Royal Institute of Technology, Stockholm, Sweden
- [4] Β. Λεκίδης, Χ. Καρακώστας, Π. Πανέτσος, Ι. Διαμαντουλάκη, 2009. Ενόργανη παρακολούθηση δομικής κατάστασης σημαντικών έργων με σκοπό την πληρέστερη συντήρησή τους, *Τεχνικό Επιμελητήριο Ελλάδος (ΤΕΕ)*, Θεσσαλονίκη, Ελλάδα.
- [5] G.-D. Zhou, T.-H. Yi, 2013. Thermal Load in Large-Scale Bridges: A State-of-the-Art Review, *Review Article in International Journal of Distributed Sensor Networks*
- [6] Γ. Μανώλης, Π. Κολιόπουλος, Χ. Παναγιωτόπουλος, 2015. *Δυναμική των Κατασκευών*, ΣΕΑΒ
- [7] D. Coronado, K. Fischer, 2015. *CONDITION MONITORING OF WIND TURBINES: STATE OF THE ART, USER EXPERIENCE AND RECOMMENDATIONS*, Fraunhofer Institute for Wind Energy and Energy System Technology IWES Northwest, Bremerhaven, Germany
- [8] Encardio rite Group, 2019. *What is a Tilt Sensor and How it is Used in Geo-technical Fields?*, India
- [9] Leica Geosystems A.G., 2006. *Nivel200, User Manual*, Heerbrugg, Switzerland
- [10] Λ. Θαλασσινός, 2011. *Ανάλυση χρονοσειρών*, Πανεπιστήμιο Πειραιώς, Αθήνα, Ελλάδα
- [11] Κ. Γεωργούλη, 2015. *Τεχνητή Νοημοσύνη- Μια εισαγωγική προσέγγιση*, ΣΕΑΒ
- [12] H. Salehi, R. Burgueno, 2018. Emerging artificial intelligence methods in structural engineering, *Review article in Elsevier journal*
- [13] G. Lombaert, B. Moaveni, X. He, J. P. Conte, 2009. Damage identification of a seven-story reinforced concrete shear wall building using Bayesian model updating, *29<sup>th</sup> International Modal Analysis Conference (IMAC-XXVII)*, Orlando, FL, USA, February 2009, pages 9-12
- [14] J. P. Santos, C. Cremona, A. D. Orcesi, P. Silveira, 2017. Early damage detection based on pattern recognition and data fusion, *Journal of Structural Engineering*

- [15] Δ. Κόλλιας, 2015. Τεχνικές βαθιάς μηχανικής μάθησης και γνώσης για ανάλυση συναισθήματος στην αλληλεπίδραση ανθρώπου μηχανής, Διπλωματική Εργασία, ΣΗΜΜΥ, ΕΜΠ, Αθήνα, Ελλάδα
- [16] Γ. Μπακερτζής, 2019. Νευρωνικά δίκτυα και χρονοσειρές, Δημοσίευση
- [17] A. Neves, I. Gonzalez, J. Leander, R. Karoumi, 2017. Structural health monitoring of bridges: a model-free ANN-based approach to damage prediction, Journal of Civil Structural Health Monitoring, volume 7, pages 689-702
- [18] S. J. Taylor, B. Letham, 2018. Forecasting at scale, The American Statistician Journal, volume 72, pages 37-45
- [19] L. Sun, Z. Shang, Y. Xia, S. Bhowmick, 2020. Review of bridge structural health monitoring aided by big data and artificial intelligence: from condition assessment to damage detection, American Society of Civil Engineers, Reston, VA, USA
- [20] J. Portilla, 2020. Python for time series data analysis, Perian Data, Online Course, Udemy
- [21] Χ. Κ. Ζύγουρας, 2017. Μέθοδος παρακολούθησης δομικής ακεραιότητας κατασκευών με εφαρμογή σε μεταλλική καπνοδόχο τύπου BYPASS-STACK, Διπλωματική Εργασία, Σχολή Πολιτικών Μηχανικών, ΕΜΠ, Αθήνα, Ελλάδα
- [22] Ε. Πασχαλίδου, 2014. Αξιολόγηση ψηφιακών κλισιμέτρων ακριβείας στην μελέτη δομικής παρακολούθησης γεφυρών κατά την επιβολή ελεγχόμενης δοκιμαστικής φόρτισης, Μεταπτυχιακή Διπλωματική Εργασία, ΣΑΤΜ, Τομέας Τοπογραφίας, ΕΜΠ, Αθήνα, Ελλάδα
- [23] Σ. Παναγιωτοπούλου, 2019. Χρήση ψηφιακών κλισιμέτρων ακριβείας για την παρακολούθηση δομικής κατάστασης γέφυρας, Μεταπτυχιακή Διπλωματική Εργασία, ΣΑΤΜ, Τομέας Τοπογραφίας, ΕΜΠ, Αθήνα, Ελλάδα
- [24] Ι. Κοντούλης, 2017. Μια ανασκόπηση της βαθιάς μάθησης: θεωρία, μέθοδοι και εφαρμογές, Μεταπτυχιακή Διατριβή, Μεταπτυχιακό Πρόγραμμα Σπουδών «Πληροφορική», Πανεπιστήμιο Πειραιώς, Αθήνα, Ελλάδα
- [25] Γ. Πανταζής, 2020. Γεωδαιτικές μέθοδοι ελέγχου μετακινήσεων, Κεφάλαιο 8, Εκδόσεις Ζήτη, Αθήνα, Ελλάδα

## ΔΙΑΔΙΚΤΥΟ

1. [www.wikipedia.org/](http://www.wikipedia.org/)
2. <http://www.leica-geosystems.com/>
3. <http://www.metrica.gr/>
4. <http://www.tjskl.org.cn/>
5. <https://www.bestech.com.au/>
6. [www.elektormagazine.com](http://www.elektormagazine.com)
7. <https://www.sas.com/>
8. <http://www.gps.gov/>
9. <http://www.russianspaceweb.com/>
10. <http://en.beidou.gov.cn/>
11. <http://www.idsgeoradar.com/>
12. <http://www.kalliergos.com/>
13. <https://www.aodos.gr/>
14. <https://www.vaisala.com/>

## ΠΑΡΑΡΤΗΜΑ

### Α' Μέρος: Πρόβλεψη με τη χρήση του λογισμικού *Prophet*

```
from fbprophet import Prophet
import pandas as pd
import numpy as np
import datetime
import matplotlib.pyplot as plt
%matplotlib inline

df1 = pd.read_csv('read_mat/A0data1.csv')
df1 = df1.iloc[:,2]
df1['A0data'] = 'A0data1'
df1['ds'] = df1['unixTime_sec'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df2 = pd.read_csv('read_mat/A0data2.csv')
df2['A0data'] = 'A0data2'
df2['ds'] = df2['unixTime_sec'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df3 = pd.read_csv('read_mat/A0data3.csv')
df3['A0data'] = 'A0data3'
df3['ds'] = df3['unixTime_sec'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df4 = pd.read_csv('read_mat/A0data4.csv')
df4['A0data'] = 'A0data4'
df4['ds'] = df4['unixTime_sec'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df5=pd.read_csv('read_mat/traffic_processed.csv')
df_all = (pd.concat([df1.set_index(['ds', 'A0data']),
                    df2.set_index(['ds', 'A0data']),
                    df3.set_index(['ds', 'A0data']),
                    df4.set_index(['ds', 'A0data'])],sort=True)
         .sum(level=[0],min_count=1))
```

### # Prediction of Inclination X using rest of variables as external regressors

```
cond = (df_all['inclinationX_rad_'].notna())
df_all['NA'] = np.where(cond, 1, 0)

df_all = df_all.fillna(method='ffill').fillna(method='bfill')
df_all = df_all[df_all.NA == 1]

df_all = df_all.reset_index()
df_all = df_all.drop_duplicates(subset='ds', keep="last")

df_all = df_all.rename(columns={"inclinationX_rad_": "y"})
df_all_train = df_all.loc[df_all["ds"]<"2019-06-20"]
df_all_test = df_all.loc[df_all["ds"]>="2019-06-20"]
```



```

import numpy as np

#calculate the correlation between the two arrays
np.corrcoef(df_all['y'],df_all['atmPress_mbar_'])
np.corrcoef(df_all['y'],df_all['dailyRain_mm_'])
np.corrcoef(df_all['y'],df_all['humidity_'])
np.corrcoef(df_all['y'],df_all['inclinationY_rad_'])
np.corrcoef(df_all['y'],df_all['temperature_celsius_'])

df6 = (pd.concat([df_all,
                  df5.set_index(['ds']),sort=True)
                .sum(level=[0],min_count=1))
df6.head()

cond = (df6['inclinationX_rad_'].notna())
df6['NA'] = np.where(cond, 1, 0)
df6 = df6.fillna(method='ffill').fillna(method='bfill')
df6 = df6[df6.NA == 1]
df6 = df6.rename(columns={"inclinationX_rad_": "yy"})
np.corrcoef(df6['inclinationY_rad_'],df6['y'])
np.corrcoef(df6['yy'],df6['y'])

m3=Prophet()

m3.add_regressor('atmPress_mbar_')
m3.add_regressor('dailyRain_mm_')
m3.add_regressor('humidity_')
m3.add_regressor('inclinationY_rad_')
m3.add_regressor('temperature_celsius_')

m3.fit(df_all_train)
forecast3=m3.predict(df_all_test.drop(columns='y'))
fig1=m3.plot(forecast3)
fig2 = m3.plot_components(forecast3)

RMSE3 = rmse(forecast3.yhat.values, df_all_test.y.values)
print('RMSE for Inclination X of the last 5 days is: ', RMSE3)

MAPE3 = mape(forecast3.yhat.values, df_all_test.y.values)
print('MAPE for Inclination X of the last 5 days is: ', MAPE3)

plt.figure(figsize=(10,7))
train_prediction = m3.predict(pd.DataFrame(df_all.drop(columns="y")))
fig1 = m3.plot(train_prediction)

from statsmodels.tools.eval_measures import rmse

predictions=forecast3['yhat']
rmse(predictions,df_all_test['y'])

from fbprophet.diagnostics import cross_validation,performance_metrics
from fbprophet.plot import plot_cross_validation_metric

len(df_all)/len(predictions)
#initial 3 months training period
initial=90
initial=str(initial)+'days'
#fold every 10days
period=10
period=str(period)+'days'
#forecast 10 days into the future
horizon=10
horizon=str(horizon)+'days'

df_cv = cross_validation(m3, initial='90 days', period='10 days', horizon = '10 days')
plot_cross_validation_metric(df_cv,metric='rmse');

#trend changes check

df_all.plot(x='ds',y='y') |

```

```

from fbprophet.plot import add_changepoints_to_plot
fig = m3.plot(forecast3)
a = add_changepoints_to_plot(fig.gca(), m3, forecast3)

fig2 = m3.plot_components(forecast3)

m=Prophet(seasonality_mode='multiplicative')
m.fit(df_all_train)
forecast1=m.predict(df_all_test.drop(columns='y'))

fig5=m.plot(forecast1)

fig5 = m.plot_components(forecast1)

from fbprophet.plot import add_changepoints_to_plot
fig = m.plot(forecast1)
a = add_changepoints_to_plot(fig.gca(), m, forecast1)

def plot_results(time_series, Time, train_prediction, test_prediction, y_test, mode, description):
    """
    Plots the original time series and it prediction
    """
    if mode == 'prophet':
        ts = time_series["y"].values
        train_pr = train_prediction["yhat"].values
        test_pr = test_prediction["yhat"].values

    elif mode == 'pyramid':
        train_pr = train_prediction
        test_pr = test_prediction
        ts = time_series

    else:
        print("Check mode")
        return None

    plt.figure(figsize=(20,14))

    from scipy.stats import kde

    # create data
    x = Time
    y = ts

    # Evaluate a gaussian kde on a regular grid of nbins x nbins over data extents
    nbins=500
    k = kde.gaussian_kde([x,y])
    xi, yi = np.mgrid[x.min():x.max():nbins*1j, y.min():y.max():nbins*1j] |
    zi = k(np.vstack([xi.flatten(), yi.flatten()]))

```

```

# Change color palette
plt.pcolormesh(xi, yi, zi.reshape(xi.shape), shading='bicubic', cmap=plt.cm.Set2)

# plt.plot(Time, ts, 'o', color='gray', label = "true")

plt.plot(Time[start_point: end_point], np.concatenate([train_pr, test_pr]),
         label = "predictions, \n MAPE = {0}, MAE = {1}".format(
             np.round(mean_absolute_percentage_error(test_pr, y_test), 6),
             np.round(mean_absolute_error(test_pr, y_test), 6)))

plt.axvline(x=middle_point, label = "train-test-split", color = 'r')

plt.xlabel("timestep", size = 20)
plt.ylabel("Inclination", size = 20)
plt.title("{}".format(description), size = 20)
# plt.ylim(-0.0006, 0)

plt.grid()

plt.legend(fontsize = 15)

plt.show()
pass

# metrics
from sklearn.metrics import mean_absolute_error

def mean_absolute_percentage_error(y_true, y_pred):
    return np.mean(np.abs((y_true - y_pred) / y_true))

mode = 'prophet'
start_point = 0
middle_point = 146530
end_point = 159740

Time = df_all.index.values
data_train = df_all_train.iloc[: middle_point].copy()
data_test = df_all_test

y_test = df_all_test["y"].copy()
test_prediction = m3.predict(data_test)
train_prediction = m3.predict(pd.DataFrame(data_train.drop(columns="y")))

description = "Prophet, predicting Inclination X with external regressors"
plot_results(df_all, Time, train_prediction, test_prediction, y_test, mode, description)

mean_absolute_error(test_prediction["yhat"].values, y_test)

```

## # Prediction of Inclination Y using rest of variables as external regressors

```

df_all = (pd.concat([df1.set_index(['ds', 'A0data']),
                    df2.set_index(['ds', 'A0data']),
                    df3.set_index(['ds', 'A0data']),
                    df4.set_index(['ds', 'A0data'])], sort=True)
         .sum(level=[0], min_count=1))
cond = (df_all['inclinationY_rad_'].notna())
df_all['NA'] = np.where(cond, 1, 0)
df_all = df_all.fillna(method='ffill').fillna(method='bfill')
df_all = df_all[df_all.NA == 1]
df_all = df_all.reset_index()
df_all = df_all.drop_duplicates(subset='ds', keep="last")

df_all = df_all.rename(columns={"inclinationY_rad_": "y"})

# from scipy.stats import boxcox
# # Apply Box-Cox Transform to value column and assign to new column y
# df_all['y'], lam = boxcox(df_all['y'])

df_all_train = df_all.loc[df_all["ds"] < "2019-06-20"]
df_all_test = df_all.loc[df_all["ds"] >= "2019-06-20"]

df_all_train = df_all_train.reset_index(drop=True)
df_all_test = df_all_test.reset_index(drop=True)

```

```

m4 = Prophet(growth="linear",
             seasonality_mode="multiplicative",
             changepoint_prior_scale=100,
             seasonality_prior_scale=100,
             daily_seasonality=False,
             weekly_seasonality=False,
             yearly_seasonality=False,
             ).add_seasonality(
             name='monthly',
             period=30.5,
             fourier_order=10
             ).add_seasonality(
             name='daily',
             period=1,
             fourier_order=10
             ).add_seasonality(
             name='weekly',
             period=7,
             fourier_order=10)
m4.add_regressor('atmPress_mbar_')
m4.add_regressor('dailyRain_mm_')
m4.add_regressor('humidity_')
m4.add_regressor('inclinationX_rad_')
m4.add_regressor('temperature_celsius_')

m4.fit(df_all_train)

forecast4=m4.predict(df_all_test.drop(columns='y'))
fig1=m4.plot(forecast4)
fig5 = m4.plot_components(forecast4)

RMSE4 = rmse(forecast4.yhat.values, df_all_test.y.values)
print('RMSE for Inclination Y of the last 5 days is: ', RMSE4)

MAPE4 = mape(forecast4.yhat.values, df_all_test.y.values)
print('MAPE for Inclination Y of the last 5 days is: ', MAPE4)

plt.figure(figsize=(20,14))
train_prediction = m4.predict(pd.DataFrame(df_all.drop(columns="y")))
fig1 = m4.plot(train_prediction)

mode = 'prophet'
start_point = 0
middle_point = 146530
end_point = 159740

Time = df_all.index.values
data_train = df_all_train.iloc[: middle_point].copy()
data_test = df_all_test

y_test = df_all_test["y"].copy()
test_prediction = m4.predict(data_test)
train_prediction = m4.predict(pd.DataFrame(data_train.drop(columns="y")))

description = "Prophet-Custom, predicting Inclination Y with external regressors"
plot_results(df_all, Time, train_prediction, test_prediction, y_test, mode, description)

mean_absolute_error(test_prediction["yhat"].values, y_test)

```

```

from statsmodels.tools.eval_measures import rmse
predictions1=forecast3['yhat']
rmse(predictions,df_all_test['y'])
df_all_test.mean()

from fbprophet.diagnostics import cross_validation,performance_metrics
from fbprophet.plot import plot_cross_validation_metric
len(df_all)/len(predictions)
df_cv = cross_validation(m4, initial='90 days', period='10 days', horizon = '10 days')
plot_cross_validation_metric(df_cv,metric='mae');
df_all.plot(x='ds',y='y')

from fbprophet.plot import add_changepoints_to_plot
fig = m4.plot(forecast3)
a = add_changepoints_to_plot(fig.gca(), m4, forecast3)
fig = m4.plot_components(forecast3)

m22=Prophet(seasonality_mode='multiplicative')
m22.fit(df_all_train)
forecast4=m22.predict(df_all_test.drop(columns='y'))
fig6=m22.plot(forecast4)
fig7 = m22.plot_components(forecast4)

from fbprophet.plot import add_changepoints_to_plot
fig = m22.plot(forecast4)
a = add_changepoints_to_plot(fig.gca(), m22, forecast4)

```

## Β' Μέρος: Πρόβλεψη με τη χρήση νευρωνικών δικτύων LSTM

```
from __future__ import absolute_import, division, print_function, unicode_literals

import copy
import time
from termcolor import colored
import os
import tensorflow as tf

import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
from numpy import array
from math import sqrt

from sklearn.covariance import EllipticEnvelope
from statsmodels.tsa.stattools import adfuller
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split

from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM

import datetime

#Read individual mat files
df1 = pd.read_csv('read_mat/A0data1.csv')
df1 = df1.iloc[:,2]
df1['A0data'] = 'A0data1'
df1['ds'] = df1['unixTime_sec_'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df2 = pd.read_csv('read_mat/A0data2.csv')
df2['A0data'] = 'A0data2'
df2['ds'] = df2['unixTime_sec_'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df3 = pd.read_csv('read_mat/A0data3.csv')
df3['A0data'] = 'A0data3'
df3['ds'] = df3['unixTime_sec_'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

df4 = pd.read_csv('read_mat/A0data4.csv')
df4['A0data'] = 'A0data4'
df4['ds'] = df4['unixTime_sec_'].map(lambda timestamp: \
                                   datetime.datetime.utcfromtimestamp(timestamp).\
                                   strftime("%Y-%m-%d %H:%M:%S"))

# Concatenate to a single df based on timestamp, many NaNs due to different timestamps
df_all = (pd.concat([df1.set_index(['ds', 'A0data']),
                    df2.set_index(['ds', 'A0data']),
                    df3.set_index(['ds', 'A0data']),
                    df4.set_index(['ds', 'A0data'])], sort=True)
          .sum(level=[0],min_count=1))

df_all

# Keep only the rows with non NaN values of the target variable (inclinationY_rad) and
# fill the other columns with backwards filling
cond = (df_all['inclinationY_rad_'].notna())
df_all['NA'] = np.where(cond, 1, 0)

df_all = df_all.fillna(method='ffill').fillna(method='bfill')

df_all = df_all[df_all.NA == 1]

df_all = df_all.reset_index()
df_all = df_all.drop_duplicates(subset='ds', keep="last")

df_all
```

```

df_all = df_all.drop(columns=['NA', 'unixTime_sec_'])

df_all.describe()
df_all['ds'] = pd.to_datetime(df_all['ds'])
# LSTM needs a standard frequency for observations, the above dataset has varying timestamps.
# Create a 1min frequency dataframe
df_all = df_all.set_index('ds')

df_all = df_all.asfreq(freq='1Min', method='bfill')

df_all_values = df_all.values

# scale values

scaler = MinMaxScaler().fit(df_all_values)
Normalized_df_all = scaler.transform(df_all_values)

# convert history into inputs and outputs

def to_supervised(train, n_input, n_out):
    # flatten data
    X, y = list(), list()
    in_start = 0
    # step over the entire history one time step at a time
    for _ in range(len(train)):
        # define the end of the input sequence
        in_end = in_start + n_input
        out_end = in_end + n_out
        # ensure we have enough data for this instance
        if out_end <= len(train):
            X.append(train[in_start:in_end, :])
            # ATTENTION! The column number we want to predict goes here:
            y.append(train[in_end:out_end, 4])
            # move along one time step
            in_start += 1
    return array(X), array(y)

n_input = 120
n_out = 10
data_x, data_y = to_supervised(Normalized_df_all, n_input, n_out)
# define model

def build_model(X_train, Y_train, n_input):
    # define parameters
    verbose, epochs, batch_size = 2, 100, 256
    n_timesteps, n_features, n_outputs = X_train.shape[1], X_train.shape[2], Y_train.shape[1]
    # define model
    model = Sequential()
    model.add(LSTM(240, activation = 'relu', input_shape = (n_timesteps, n_features)))
    model.add(Dense(100, activation = 'relu'))
    model.add(Dense(n_outputs))
    model.compile(loss = tf.keras.losses.MeanSquaredError(), optimizer = 'adam',
                  metrics = [RRSE, 'mse', 'mae', 'mape'])
    # fit network
    model.fit(X_train, Y_train, epochs = epochs, batch_size = batch_size, verbose = verbose)
    return model

# model metric

def RRSE(y_true, y_pred):
    score = tf.sqrt(tf.reduce_sum(tf.square(y_true - y_pred)) / tf.reduce_sum(tf.square(y_true - tf.reduce_mean(y_true))))
    return score

```

```

# evaluate one or more weekly forecasts against expected values

def evaluate_forecasts(actual, predicted):
    scores = []
    # calculate an RSE score for each day
    for i in range(actual.shape[1]):
        # calculate rse
        rse = np.sum(np.square(actual[:, i] - predicted[:, i])) / np.sum(np.square(actual[:, i] - np.mean(actual[:, i])))
        # calculate rrse
        rrse = sqrt(rse)
        # store
        scores.append(rrse)
    # calculate overall RRSE
    score = sqrt(np.sum(np.square(actual - predicted)) / np.sum(np.square(actual - np.mean(actual))))
    return score, scores

# summarize scores

def summarize_scores(name, score, scores):
    s_scores = ', '.join(['%.1f' % s for s in scores])
    print('%s: [%.3f] %s' % (name, score, s_scores))

# split train and test data
X_train, X_test, Y_train, Y_test = train_test_split(data_x, data_y,
                                                    test_size = 0.20,
                                                    random_state = 0, shuffle = True)

# train model
model = build_model(X_train, Y_train, n_input)

# get predictions
Y_hat = model.predict(X_test, verbose = 0)

# # inverse standardization for test data
# X_test_inversed = scaler.inverse_transform(X_test)

# compute rrse (per step and total) and save
score, scores = evaluate_forecasts(Y_test, Y_hat)

# split train and test data
X_train, X_test, Y_train, Y_test = train_test_split(data_x, data_y,
                                                    test_size = 0.20,
                                                    random_state = 0, shuffle = True)

score, scores = evaluate_forecasts(Y_test, Y_hat)
summarize_scores(name='sum', score=score, scores=scores)

# make a forecast
def forecast(model, history, n_input):
    # flatten data
    data = array(history)
    data = data.reshape((data.shape[0]*data.shape[1], data.shape[2]))
    # retrieve last observations for input data
    input_x = data[-n_input:, :]
    # reshape into [1, n_input, n]
    input_x = input_x.reshape((1, input_x.shape[0], input_x.shape[1]))
    # forecast the next week
    yhat = model.predict(input_x, verbose=0)
    # we only want the vector forecast
    yhat = yhat[0]
    return yhat

y_hat_last_scaled = forecast(model, history=data_x[-120:,:,:], n_input=120)
y_true_last_scaled= data_y[-1:].flatten()

```



```

pred_scaler = MinMaxScaler()
pred_scaler.min_, pred_scaler.scale_ = scaler.min_[4], scaler.scale_[4]

y_true_last_scaled = y_true_last_scaled.reshape(1,-1)
y_hat_last_scaled = y_hat_last_scaled.reshape(1,-1)

y_true_last = pred_scaler.inverse_transform(y_true_last_scaled)
y_hat_last = pred_scaler.inverse_transform(y_hat_last_scaled)

y_hat_last = y_hat_last.flatten()
y_true_last = y_true_last.flatten()

import numpy as np
import matplotlib.pyplot as plt
plt.figure(figsize=(15, 14))

x1 = np.linspace(1, 10, num=10)
x2 = np.linspace(1, 10, num=10)
plt.plot(x1, y_hat_last, label='predictions')
plt.plot(x2, y_true_last, label='actuals')
plt.ylim(-0.0005, -0.0004)
#plt.ylim(-0.001064, 0.000329)
plt.xlim(1,10)
plt.xlabel("10 next observations")
plt.ylabel("Inclination of Y axis (rad)")
plt.legend()
plt.show()

```