



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

Τμήμα Μηχανικών Βιομηχανικής
Και Σχεδίασης και Παραγωγής

ΠΑΝΕΠΙΣΤΗΜΙΟ
&
ΑΙΓΑΙΟΥ

Τμήμα Ναυτιλίας και
Επιχειρηματικών Υπηρεσιών



ΔΙΔΡΥΜΑΤΙΚΟ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

«ΝΕΕΣ ΤΕΧΝΟΛΟΓΙΕΣ ΣΤΗ ΝΑΥΤΙΛΙΑ ΚΑΙ ΤΙΣ ΜΕΤΑΦΟΡΕΣ»

ΤΙΤΛΟΣ

*Προβλεπτική Συντήρηση Μηχανημάτων Με Περιστρεφόμενα Μέρη
Χρησιμοποιώντας Τα Συνελκτικά Νευρωνικά Δίκτυα*

ΤΙΤΛΟΣ ΑΓΓΛΙΚΑ

*Rotating Machinery Condition Based Maintenance Utilizing
Convolutional Neural Networks*

Όνοματεπώνυμο Σπουδαστή:

Απειρανθίτης Σταμάτιος (8066256)

Όνοματεπώνυμο Υπεύθυνου Καθηγητή:

Ζαχαρία Παρασκευή

ΔΙΑΤΡΙΒΗ

Μάρτιος 2023



ΠΑΝΕΠΙΣΤΗΜΙΟ
ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

Τμήμα Μηχανικών Βιομηχανικής
Και Σχεδίασης και Παραγωγής

ΠΑΝΕΠΙΣΤΗΜΙΟ
&
ΑΙΓΑΙΟΥ

Τμήμα Ναυτιλίας και
Επιχειρηματικών Υπηρεσιών



Μέλη Εξεταστικής Επιτροπής

Ζαχαρία Παρασκευή

Παπουτσιδάκης Μιχαήλ

Δρόσος Χρήστος

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΜΕΤΑΠΤΥΧΙΑΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος/η *.Απειρανθίτης Σταμάτιος.* του *.Γεωργίου.*, με αριθμό μητρώου *...8066256..* φοιτητής του Διδρυματικού Προγράμματος Μεταπτυχιακών Σπουδών «Νέες Τεχνολογίες στη Ναυτιλία και τις Μεταφορές» του Τμήματος Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής της Σχολής Μηχανικών Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι: «Είμαι συγγραφέας αυτής της μεταπτυχιακής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος. Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ο δηλών

Απειρανθίτης Σταμάτιος



Ημερομηνία

16 Ιουνίου 2023

Περίληψη

Σύμφωνα με το *World Economic Forum*, το **90%** του παγκόσμιου εμπορίου μεταφέρεται δια θαλάσσης με εμπορικά πλοία. Τα πλοία κάθε είδους, αποτελούνται από δεκάδες πολύπλοκα μηχανήματα, κοινός παράγοντας των οποίων είναι τα περιστρεφόμενα μέρη και οι ηλεκτρικοί κινητήρες, τα οποία λειτουργούν σε ένα σύνθετο περιβάλλον με αυξημένη θερμοκρασία και υγρασία, κραδασμούς, κόπωση, και φορτίο. Μία βλάβη ή δυσλειτουργία ενός εκ των μηχανημάτων αυτών, μπορεί να έχει σημαντικές επιπτώσεις στη λειτουργία, αλλά ακόμη και στη ασφάλεια του πλοίου και κατά συνέπεια στην ασφάλεια του πληρώματος και του περιβάλλοντος. Η ναυτιλιακή βιομηχανία ξοδεύει τεράστια ποσά στην προληπτική συντήρηση και επισκευή, ώστε να διατηρεί τα πλοία όχι μόνο αξιόπλοα, αλλά πάνω από όλα ασφαλή.

Στην παρούσα εργασία θα παρουσιάσουμε τα οικονομοτεχνικά οφέλη της **προγνωστικής συντήρησης** σε σχέση με την **προληπτική** και την **επισκευαστική συντήρηση** που ως σήμερα εφαρμόζεται στα πλοία. Θα δούμε, πως μελετώντας την **πραγματική λειτουργική κατάσταση ενός μηχανήματος** και εκμεταλλευόμενοι την σύγχρονη τεχνολογία και την **Τεχνητή Νοημοσύνη**, μπορούμε να προβλέψουμε πιθανές βλάβες, σε αρχικό ακόμα στάδιο, παρέχοντας έτσι τον απαραίτητο χρόνο για τον σωστό προγραμματισμό της απαραίτητης συντήρησης ή επισκευής.

Στην πορεία της εργασίας θα προτείνουμε και αναπτύξουμε ένα **συνελικτικό νευρωνικό δίκτυο**, το οποίο θα το τροφοδοτήσουμε με **ακατέργαστες μετρήσεις κραδασμών** που έχουν συλλεγεί από τους σφαιροτριβείς ενός κινητήρα σε εργαστηριακό περιβάλλον. Στη συνέχεια θα μελετήσουμε αν και πως το **προτεινόμενο δίκτυο** μπορεί να ανιχνεύσει τη **λειτουργική κατάσταση** των σφαιροτριβέων, αλλά και να **κατηγοριοποιήσει** τυχόν βλάβες. Τα **συνελικτικά νευρωνικά δίκτυα** αποτελούν τομέα των **τεχνητών νευρωνικών δικτύων** και της **βαθιάς μάθησης** και στις μέρες μας τυγχάνουν ιδιαίτερης προσοχής στο χώρο της αναγνώρισης εικόνων και φωνής.

Λέξεις κλειδιά: προβλεπτική συντήρηση, προγνωστική συντήρηση, τεχνητό νευρωνικό δίκτυο, συνελικτικό νευρωνικό δίκτυο, βαθιά μάθηση, κραδασμός

Abstract

According to the World Economic Forum, 90% of global trade is transferred by merchant vessels by sea. The vessels of all kinds consist of dozens of complex machineries, the common factor of which are the rotating parts and the electric motors that operate continuously in a harsh environment with excess temperature and humidity, vibration, fatigue, and load. A breakdown or malfunction of one of these machineries can significantly impact the vessel's operation and safety, and consequently, the safety of the crew and the environment. To maintain operational efficiency and seaworthiness, the shipping industry invests substantial resources in preventive maintenance and repairs. This research, aims to present the economic and technical benefits of *predictive maintenance* over to traditional *preventive maintenance* and *repair by replacement* approaches in the maritime domain. By leveraging modern technology and *Artificial Intelligence*, we can analyze real-time operating conditions of machinery, enabling early detection of potential damages and allowing for effective planning of future maintenance and repair activities.

In the course of the paper, we will propose and develop a *Convolutional Neural Network*, which it will be fed with *raw vibration* measurements had been acquired in laboratory environment from the ball bearings of a motor. Then, we will investigate whether the proposed network can accurately detect the functional state of ball bearings and categorize any possible failures present, contributing to improved maintenance practices in the shipping industry. *Convolutional Neural Networks* belong in the field of *Artificial Neural Networks* and *Deep Learning*, and nowadays, they are receiving researchers' attention in the field of image and voice recognition.

Key Words: Predictive Maintenance, Preventive Maintenance, Artificial Neuron Network, Convolutional Neuron Network, Deep Learning, Vibration.

Περιεχόμενα

1.	Εισαγωγή	- 9 -
1.1	Σκοπός της εργασίας	- 11 -
1.2	Δομή της εργασίας.....	- 12 -
2.	Τεχνητά Νευρωνικά Δίκτυα- Artificial Neural Networks	- 13 -
2.1	Εισαγωγικά Στοιχεία για τα Τεχνητά Νευρωνικά Δίκτυα	- 13 -
2.2	Χαρακτηριστικά Νευρωνικών Δικτύων.....	- 16 -
2.3	Ιστορική Αναδρομή για τα Τεχνητά Νευρωνικά Δίκτυα	- 22 -
3.	Συνελικτικά Νευρωνικά Δίκτυα	- 24 -
3.1	Εισαγωγή στα Συνελικτικά Νευρωνικά Δίκτυα	- 24 -
3.2	Σύντομη Ιστορική Αναδρομή για τα Συνελικτικά Νευρωνικά Δίκτυα.	- 27 -
3.3	Επίπεδα Συνέλιξης – Convolutional Layers.....	- 28 -
3.3.1	Τι είναι η συνέλιξη (convolution)	- 28 -
3.3.2	Η πράξη της συνέλιξης στα Συνελικτικά Νευρωνικά Δίκτυα	- 29 -
3.3.3	Stride	- 31 -
3.3.4	Padding – Zero Padding.....	- 33 -
3.3.5	Parameter Sharing	- 34 -
3.4	Συνάρτηση Ενεργοποίησης – Activation Function.....	- 36 -
3.5	Επίπεδο ομαδοποίησης - Pooling Layer	- 37 -
3.5.1	Max Pooling.....	- 38 -
3.5.2	Global Average Pooling.....	- 39 -
3.6	Fully Connected ή Dense Layer	- 41 -
3.7	Εκπαίδευση - Training	- 44 -
3.7.1	Συνάρτηση Απώλειας - Loss Function.....	- 45 -
3.7.2	Μέθοδος Ταχύτερης Καθόδου - Gradient Descent.....	- 47 -
3.7.3	Dropout Function.....	- 49 -
3.8	Συμπέρασμα για τα συνελικτικά νευρωνικά δίκτυα	- 51 -
4.	Συντήρηση – Σύστημα Διαχείρισης της Συντήρησης.....	- 52 -
4.1	Εισαγωγή στη Συντήρηση.....	- 52 -
4.2	Συντήρηση εισαγωγή και ορισμός	- 53 -
4.3	Συντήρηση - Σύντομη Ιστορική Αναδρομή.....	- 55 -

4.4	Η Αναγκαιότητα της Συντήρησης – Οι Βασικοί Στόχοι.....	- 57 -
4.5	Φιλοσοφίες Συντήρησης – προσεγγίσεις και στρατηγικές.....	- 58 -
4.5.1	Διορθωτική Συντήρηση - Corrective Maintenance.....	- 59 -
4.5.2	Προληπτική Συντήρηση - Preventive Maintenance	- 60 -
4.5.3	Προγνωστική Συντήρηση - Predictive Maintenance	- 62 -
4.5.4	Προγνωστική Συντήρηση - Condition Based Maintenance	- 64 -
4.5.4.1	Πρακτικές που εφαρμόζονται στην προγνωστική συντήρηση .	- 69 -
5.	Κραδασμός – Vibration	- 71 -
5.1	Εισαγωγή στον κραδασμό.	- 71 -
5.2	Η έννοια του κραδασμού	- 73 -
5.3	Βασικά χαρακτηριστικά κραδασμών	- 74 -
5.4	Μετατόπιση – Ταχύτητα – Επιτάχυνση και αισθητήρες μέτρησης.....	- 78 -
5.4.1	Μετατόπιση – Displacement.....	- 78 -
5.4.2	Ταχύτητα – Velocity.....	- 79 -
5.4.3	Επιτάχυνση – Acceleration.....	- 80 -
5.4.4	Η θέση των αισθητήρων για τη μέτρηση κραδασμών σε ένα μηχάνημα. - 82 -	
5.5	Πεδίο Χρόνου – Πεδίο Συχνοτήτων (Time – Frequency Domain)	- 84 -
5.5.1	Πεδίο Χρόνου – Time Domain	- 84 -
5.5.2	Πεδίο Συχνοτήτων – Frequency Domain.....	- 85 -
5.5.3	Phase Signal Analysis.....	- 87 -
5.6	Επίπεδα Κραδασμών	- 88 -
5.7	Ανίχνευση Βλαβών Μηχανημάτων με στρεφόμενα μέρη με την ανάλυση κραδασμών	- 90 -
5.7.1	Misalignment	- 91 -
5.7.2	Unbalance	- 92 -
5.7.3	Bent Shaft.....	- 93 -
5.7.4	Mechanical Looseness	- 94 -
5.7.5	Rolling Elements.....	- 95 -
5.7.6	Λοιπές βλάβες	- 97 -
6.	Predictive Maintenance and Convolutional Neural Networks.....	- 98 -
6.1	Εισαγωγή στη διαγνωστική συντήρηση με χρήση των συνελκτικών νευρωνικών δικτύων.	- 98 -

6.2	Επισκόπηση μελετών προγνωστικής συντήρησης, βασισμένη στα συνελκτικά νευρωνικά δίκτυα δίκτυα	99 -
6.3	Εφαρμογή των συνελκτικών νευρωνικών δικτύων (CNN) στην ανίχνευση και κατηγοριοποίηση βλαβών μηχανημάτων με περιστρεφόμενα μέρη.....	104 -
6.4	Βαθιά μάθηση και Προγνωστική Συντήρηση	105 -
6.4.1	Εισαγωγή, Μονοδιάστατα (1D) – Δισδιάστατα (2D) Συνελκτικά Νευρωνικά Δίκτυα (CNNs)	105 -
6.4.2	Κανονικοποίηση – Normalization	110 -
6.4.3	Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου (CNN).....	112 -
7.	Σχεδίαση και Ανάπτυξη Συνελκτικού Νευρωνικού Δικτύου Ανίχνευσης Βλαβών Σφαιροτριβέων	119 -
7.1	Εισαγωγή.....	119 -
7.2	Παρουσίαση του μοντέλου μέτρησης κραδασμών.....	120 -
7.3	Παρουσίαση Δεδομένων Εκπαίδευσης – Δοκιμής.....	121 -
7.4	Παρουσίαση του συνελκτικού νευρωνικού μοντέλου	124 -
	• Είσοδος – Input Layer.....	126 -
	• Εξαγωγή πινάκων χαρακτηριστικών (Features Extraction)	127 -
	• Κατηγοριοποίηση (classification).....	128 -
7.5	Εκπαίδευση (training) - Επιβεβαίωση (validation)	132 -
7.6	Παρουσίαση Αποτελεσμάτων	134 -
7.6.1	Δοκιμή Δικτύου με Νέα Δεδομένα.....	136 -
8.	Συμπεράσματα – Παρατηρήσεις	140 -
8.1	Σύνοψη Αποτελεσμάτων	140 -
8.2	Μελλοντικοί Στόχοι.....	142 -
9.	Παράρτημα.....	144 -
9.1	Case Western Reserve University Data Set.....	144 -
9.2	Γραφική απεικόνιση σετ δεδομένων	146 -
9.3	Scatter Plots	148 -
9.4	Πίνακας συντομεύσεων και αντιστοιχίας Ελληνικών και Αγγλικών όρων	150 -
9.5	Συγκεντρωτική λίστα εικόνων	152 -
9.6	Συγκεντρωτική λίστα πινάκων	154 -
10.	Βιβλιογραφία	154 -

1. Εισαγωγή

Η διακίνηση του παγκόσμιου εμπορίου αγαθών και καυσίμων στηρίζεται κατά κύριο λόγο στα εμπορικά πλοία. Αρκεί κάποιος να δει στο διαδίκτυο έναν χάρτη αποτύπωσης (π.χ Marine Traffic), για να συνειδητοποιήσει τον αριθμό των πλοίων που ταξιδεύουν στις θάλασσές και τους ωκεανούς του πλανήτη. Η τελευταία μελέτη που πραγματοποιήθηκε το Νοέμβριο του 2022 από τη *Statista Research Department* (<https://www.statista.com/statistics/264024/number-of-merchant-ships-worldwide-by-type/>), αποκάλυψε πως ο παγκόσμιος εμπορικός στόλος αποτελείται από 58590 πλοία όλων των τύπων και μεγέθους, όπως δεξαμενόπλοια, πλοία μεταφοράς εμπορευματοκιβωτίων, πλοία γενικού φορτίου, RoRo, πλοία μεταφοράς χημικών, και υγροποιημένου φυσικού αερίου (LNG). Συλλογιζόμενοι τις ιδιαιτερότητες της λειτουργίας αλλά και το περιβάλλον που δραστηριοποιείται, δεν θα ήταν υπερβολή ένα πλοίο να συγκριθεί με πολλά και εξειδικευμένα εργοστάσια, που το ένα εξαρτάται από το άλλο, ώστε τα παραχθεί ένα τελικό προϊόν. Το προϊόν αυτό είναι η ασφαλής μεταφορά των εμπορευμάτων από το λιμάνι φόρτωσης στο λιμάνι προορισμού εντός καθορισμένου χρονικού πλαισίου.

Τα πλοία, κάθε είδους, αποτελούνται από πολλά και περίπλοκα μηχανήματα, η συντήρηση των οποίων είναι υψίστης σημασίας, καθώς βλάβη σε ένα ή περισσότερα μπορεί να επιφέρει καθυστερήσεις στο χρόνο άφιξης στο επόμενο λιμάνι ή ακόμη χειρότερα, να θέσει σε κίνδυνο την ασφάλεια του πλοίου και του πληρώματος. Για το λόγο αυτό, ο *Διεθνής Οργανισμός Ναυσιπλοΐας (IMO)* θέσπισε το **1993** και έθεσε σε εφαρμογή το **1994** τον *Διεθνή Κώδικα Ασφαλούς Διαχείρισης (International Safety Management Code, ISM)*, ο οποίος προστέθηκε ως **κεφάλαιο 10** στη *Διεθνή Σύμβαση για την Ασφάλεια της Ζωής στην Θάλασσα (SOLAS)*. Το κεφάλαιο 10 του ISM είναι αφιερωμένο στη *συντήρηση του πλοίου* και τον *εξοπλισμό του*.

“The company should establish procedures to ensure that the ship is maintained in conformity with the provisions of the relevant rules and regulations and with any additional requirements which may be established by the company” [20]. Επομένως,

κάθε ναυτιλιακή εταιρία είναι υποχρεωμένη να έχει θεσπίσει και θέσει σε εφαρμογή συγκεκριμένο πρόγραμμα συντήρησης για τη διατήρηση της αποτελεσματικότητας, της διάρκειας και των επιδόσεων των πλοίων και των μηχανημάτων που περιέχονται σε αυτά.

Έως σήμερα εφαρμόζεται η *προγραμματιζόμενη προληπτική συντήρηση*, κατά την οποία κάθε μηχανήμα επιθεωρείται και στη συνέχεια συντηρείται σε προκαθορισμένα χρονικά διαστήματα. Αυτό σημαίνει πως όταν έρθει ο χρόνος της συντήρησης του μηχανήματος αντικαθίστανται προληπτικά κάποια από τα πιο βασικά εξαρτήματα του, ανεξάρτητα από την κατάσταση στην οποία βρίσκονται. Μπορεί δηλαδή, να είναι ακόμα πλήρως λειτουργικά, οδηγώντας με αυτό τον τρόπο σε αύξηση του συνολικού κόστους συντήρησης. Από την άλλη πλευρά, υπάρχει πιθανότητα να προκληθεί βλάβη σε κάποιο μηχανήμα πριν φτάσει το χρονικό διάστημα της προγραμματισμένης συντήρησης του και αρά θα πρέπει να εκτελεσθούν άμεσα εργασίες επισκευής. Επομένως, εντός του πλοίου, θα πρέπει να υπάρχουν συνεχώς και σε αφθονία ανταλλακτικά εξαρτήματα για όλα τα κρίσιμα μηχανήματα. Αυτό, σημαίνει αύξηση του συνολικού κόστους συντήρησης, αλλά και δέσμευση μεγάλων οικονομικών πόρων για την προμήθεια και αποθήκευση των ανταλλακτικών αυτών.

Με το πέρασμα των χρόνων και την ανάπτυξη της τεχνολογίας, νέες μέθοδοι *συντήρησης που βασίζονται στην πραγματική κατάσταση του μηχανήματος* (PDM) έχουν κάνει σταδιακά την εμφάνισή τους και με αργούς ακόμα ρυθμούς, εφαρμόζονται στο χώρο της βιομηχανίας. Για την εφαρμογή της PDM είναι αναγκαία η όσο το δυνατόν πιο συχνή συλλογή και ανάλυση των σημαντικών εκείνων παραμέτρων που υποδηλώνουν τη λειτουργική κατάσταση των μηχανημάτων. Η έλευση της 4^{ης} βιομηχανικής επανάστασης και του Internet of Things (IoT), παρέχει από τη μία τη δυνατότητα της “ευφυούς” διασύνδεσης “έξυπνων” συσκευών με απώτερο σκοπό τη πραγματοποίηση μετρήσεων και τη συλλογή παραμέτρων λειτουργίας και από την άλλη, την ανάλυση των δεδομένων αυτών με σύγχρονα εργαλεία και μεθόδους, όπως η *τεχνητή νοημοσύνη*, με απώτερο σκοπό την εξαγωγή συμπερασμάτων για την πραγματική λειτουργική κατάσταση ενός μηχανήματος.

Προς το παρόν, και όσο μπορούμε να γνωρίζουμε, ο ναυτιλιακός τομέας δεν έχει υιοθετήσει αντίστοιχες σύγχρονες τεχνικές και μεθόδους ανίχνευσης και κατηγοριοποίησης βλαβών, αν και μεγάλες εταιρίες χρηματοδοτούν την έρευνα προς τον τομέα αυτό.

1.1 Σκοπός της εργασίας

Στην παρούσα εργασία θα προσπαθήσουμε να αναλύσουμε, πως η σύγχρονη τεχνολογία και πιο συγκεκριμένα τα *συνελικτικά νευρωνικά δίκτυα* που αποτελούν τομέα της *βαθιά μάθηση* και της *τεχνητής νοημοσύνης* θα μπορούσαν να βοηθήσουν στην προγνωστική συντήρηση *μηχανημάτων με περιστρεφόμενα μέρη*. Θα δούμε εάν υπάρχει τρόπος αναλύοντας κάποια από τα βασικά χαρακτηριστικά λειτουργίας ενός μηχανήματος, να ανιχνεύσουμε την ύπαρξη μίας πιθανής βλάβης, σε όσο το δυνατόν πιο αρχικό στάδιο. Καθώς τα μηχανημάτων με περιστρεφόμενα μέρη είναι πολλά και το καθένα έχει διαφορετικά χαρακτηριστικά λειτουργίας, η εργασία θα εστιάσει στην *ανίχνευση* και *κατηγοριοποίηση βλαβών των εδράνων* και *σφαιροτριβέων* λαμβάνοντας μετρήσεις και στη συνέχεια αναλύοντας τα αποτυπώματα κραδασμών των εξαρτημάτων αυτών. Τα *έδρανα* και *σφαιροτριβείς* αποτελούν αναπόσπαστο κομμάτι κάθε μηχανήματος με περιστρεφόμενα μέρη και μάλιστα παρουσιάζουν τις συχνότερες βλάβες.

Στην πορεία της εργασίας θα αναπτύξουμε ένα *συνελικτικό νευρωνικό δίκτυο* το οποίο, αφού το *εκπαιδεύσουμε* με μετρήσεις *κραδασμού* που έχουν συλλεχθεί από τους σφαιροτριβείς ενός κινητήρα γνωστής λειτουργικής κατάστασης, στη συνέχεια θα το τροφοδοτήσουμε με νέες, άγνωστες για το δίκτυο μετρήσεις. Σκοπός μας είναι να δούμε κατά πόσο το προτεινόμενο δίκτυο θα καταφέρει να *προβλέψει*, αλλά και να *κατηγοριοποιήσει* πιθανές βλάβες των σφαιροτριβέων, σε όσο το δυνατόν πιο αρχικό στάδιο.

Μία τέτοια δυνατότητα θα είχε πολλαπλά και σημαντικά οφέλη για τη λειτουργία και την συντήρηση των εν λόγω μηχανημάτων. Ας σκεφτούμε την περίπτωση που το προτεινόμενο μοντέλο, αναλύοντας τα δεδομένα κραδασμού κατά τη λειτουργία της κύριας προωστήριας μηχανής ενός πλοίου θα μπορούσε να προβλέψει μία πιθανή βλάβη των εδράνων της. Αυτό θα έδινε το δυνατότητα στο

πλήρωμα και τη ναυτιλιακή εταιρία, από τη μία να λάβουν όλα τα απαραίτητα μέτρα για να αποτρέψουν, αν δυνατόν, τη βλάβη ή έστω να παρατείνουν τη υπολειπόμενο ζωής των εδράνων της κύριας μηχανής, αλλά να κάνουν τις απαραίτητες προετοιμασίες για την αντικατάστασή τους. Σημαντικό επίσης ρόλο έχει το γεγονός ότι οι μετρήσεις κραδασμών που θα χρησιμοποιηθούν δεν θα έχουν υποστεί καμία προεπεξεργασία ή μετασχηματισμό, το οποίο σημαίνει πως απαιτείται ένα απλούστερο δίκτυο για την ανάλυση τους και επομένως μικρότερη υπολογιστική ισχύς.

Τα *συνελκτικά νευρωνικά δίκτυα*, όπως προαναφέραμε, αποτελούν τομέα της *τεχνητών νευρωνικών δικτύων* και της *βαθιά μάθηση* και τα τελευταία χρόνια τυγχάνουν ιδιαίτερης προσοχής και ανάπτυξης στο χώρο της αναγνώρισης και κατηγοριοποίησης εικόνων και ήχου. Η εφαρμογή τους στο χώρο της βιομηχανικής πρόβλεψης και κατηγοριοποίησης βλαβών έχει κεντρίσει το ενδιαφέρον της επιστημονικής κοινότητας, η οποία, όπως θα δούμε στην πορεία της εργασίας, πραγματοποιεί ολοένα και περισσότερη έρευνα και ανάπτυξη στον τομέα αυτό.

1.2 Δομή της εργασίας

Η εργασία αποτελείται από επτά κεφάλαια και ολοκληρώνεται με τα συμπεράσματα. Στα πρώτα πέντε κεφάλαια γίνεται μία βιβλιογραφική επισκόπηση στο θεωρητικό υπόβαθρο που κρίνουμε απαραίτητο ότι χρειάζεται ο αναγνώστης για να κατανοήσει το θέμα της εργασίας. Το έβδομο κεφάλαιο αφιερώνεται στην ανάπτυξη του προτεινόμενου μοντέλου.

Πιο αναλυτικά, μετά την εισαγωγή, στο *κεφάλαιο 2* παραθέτουμε βασικές γνώσεις στα *τεχνητά νευρωνικά δίκτυα* και στο *κεφάλαιο 3* εξειδικεύουμε την σχεδίαση και ανάλυση των *συνελκτικών νευρωνικών δικτύων*. Κατόπιν, το *κεφάλαιο 4* αφιερώνεται στα ήδη της συντήρησης που υπάρχουν και εφαρμόζονται, καθώς και την εξέλιξή τους στο χώρο της βιομηχανίας και της ναυτιλίας. Αντίστοιχα στο *κεφάλαιο 5* παραθέτουμε βασικές έννοιες και θεωρία πάνω στη μέτρηση και ανάλυση των κραδασμών (*vibration measurement*). Έχοντας καλύψει την βιβλιογραφική επισκόπηση και πριν την παρουσίαση του προτεινόμενου δικτύου, στο *κεφάλαιο 6* εξειδικεύουμε την εφαρμογή των *συνελκτικών νευρωνικών δικτύων* και



πιο συγκεκριμένα των *μονοδιάστατων δικτύων*, στο χώρο της ανάλυσης σημάτων χρόνου (*time series*) και την συμβολή τους στην *προληπτική συντήρηση*. Στο *κεφάλαιο 7* αναλύουμε την σχεδίαση, ανάπτυξη, εκπαίδευση και δοκιμή του προτεινόμενου δικτύου, παραθέτοντας αναλυτικά, όλα τα αποτελέσματα αλλά και την πορεία των δοκιμών που πραγματοποιήσαμε, πριν καταλήξουμε στη τελική δομή του δικτύου. Η εργασία ολοκληρώνεται με τα επίλογο και τα συμπεράσματα που εξήχθησαν από την εργασία, αλλά και τους μελλοντικούς στόχους στο *κεφάλαιο 8*.

Ευχόμαστε καλή ανάγνωση!!!

2. Τεχνητά Νευρωνικά Δίκτυα- Artificial Neural Networks

2.1 Εισαγωγικά Στοιχεία για τα Τεχνητά Νευρωνικά Δίκτυα


Τα *τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks)* είναι συστήματα υπολογιστικής επεξεργασίας, εμπνευσμένα από τη λειτουργία αντίστοιχων βιολογικών νευρικών συστημάτων, όπως για παράδειγμα αυτό του ανθρώπινου εγκεφάλου. Η λειτουργία τους προσπαθεί να συνδυάσει τον τρόπο σκέψης του ανθρώπινου εγκεφάλου, με τον αφηρημένο μαθηματικό τρόπο σκέψης. Επομένως, στα νευρωνικά δίκτυα, πέραν των δύσκολων και περίπλοκων εργαλείων μαθηματικής ανάλυσης, θα συναντήσουμε και όρους, όπως *εκμάθηση, μνήμη, εκπαίδευση*, που μέχρι πρότινος αποδίδονταν μόνο στους ζώντες οργανισμούς.

Ένα βιολογικό νευρικό δίκτυο (όπως αυτό του ανθρώπινου οργανισμού) αποτελείται από πολλά *νευρωνικά δίκτυα*, κάθε ένα εκ των οποίων είναι υπεύθυνο για την εκτέλεση συγκεκριμένων διεργασιών, ενώ η κεντρική μονάδα επεξεργασίας και ελέγχου είναι ο *εγκέφαλος*. Κάθε *νευρωνικό δίκτυο* αποτελείται από έναν μεγάλο αριθμό μονάδων που ονομάζονται *νευρώνες* και αποτελούν την μικρότερη ανεξάρτητη μονάδα του δικτύου [4]. Υπολογίζεται πως ο ανθρώπινος εγκέφαλος περιέχει περίπου 10δισ νευρώνες τοποθετημένους σε ομάδες νευρωνικών δικτύων [10].

Κάθε νευρώνας αποτελείται από τρία κύρια τμήματα:

- Τους **δενδρίτες**, οι οποίοι λειτουργούν ως κανάλια εισόδου για τους νευρώνες
- Το κυρίως **κυτταρικό σώμα**
- Τον άξονα του κυττάρου-νευροάξονα, που συνδέει ένα νευρώνα με τους υπόλοιπους.

Ο άξονας ενός νευρώνα μεταφέρει ηλεκτρικά σήματα στους δενδρίτες γειτονικών νευρώνων μέσω του σημείου ένωσης, που ονομάζεται **νευροαξονική απόληξη ή σύναψη**. Έτσι, ένας νευρώνας λαμβάνει σήματα από έναν, ή περισσότερους γειτονικούς νευρώνες, τα επεξεργάζεται και τελικά τα τροφοδοτεί σε γειτονικούς νευρώνες μέσω της εξόδου του. Τα σήματα εισόδου του νευρώνα επιδρούν στο δυναμικό του, αυξομειώνοντάς το. Όταν αθροιστικά η τιμή του δυναμικού ξεπεράσει μία τιμή κατωφλίου, τότε ο νευρώνας διεγείρεται, παράγοντας ένα ηλεκτρικό σήμα στην έξοδο του. Κάθε νευρώνας μεταφέρει το ηλεκτρικό σήμα πάντοτε προς μία κατεύθυνση, η οποία είναι προκαθορισμένη.




Εικόνα 2-1 – Σχηματικό Διάγραμμα Ενός Τυπικού Νευρώνα – [10]

Σε πλήρη αντιστοιχία με τα βιολογικά νευρικά δίκτυα, η βασική δομή των **τεχνητών νευρωνικών δικτύων** αποτελείται από ένα πλήθος υπολογιστικών κόμβων, διασυνδεδεμένων μεταξύ τους, τους **νευρώνες**, οργανωμένους σε **στρώματα**, οι οποίοι υλοποιούν τοπικά έναν απλό υπολογισμό. Ένα βασικό **τεχνητό νευρωνικό δίκτυο**, αποτελείται από τουλάχιστον δύο **επίπεδα**, αυτό της **εισόδου** και το επίπεδο

της *εξόδου*, ενώ μπορεί να περιέχουν ένα ή και περισσότερα ενδιάμεσα, *κρυφά επίπεδα*. Ο όρος *κρυφά* έγκειται στο γεγονός ότι τα επίπεδα αυτά δεν έχουν καμία διασύνδεση με τον έξω κόσμο, παρά είναι συνδεδεμένα μόνο μεταξύ τους (*Εικόνα 2-2*). Κάθε *επίπεδο* αποτελείται από έναν αριθμό *μονάδων* ή *κόμβων* που είναι συνδεδεμένα με τέτοιο τρόπο, ώστε να έχει συνδέσμους με πολλές άλλες μονάδες του ίδιου ή και διαφορετικού κόμβου.

Τα δεδομένα φορτώνονται με τη μορφή ενός πολυδιάστατου διανύσματος στην είσοδο (x_i), διανέμονται στα *κρυφά επίπεδα*, στα οποία λαμβάνονται αποφάσεις, σταθμίζοντας πώς μία στοχαστική αλλαγή μπορεί να επηρεάσει την τελική έξοδο (y).



Εικόνα 2-2 Βασική δομή ενός Τεχνητού Νευρωνικού Δικτύου (ANN) [24]

Βασική λειτουργία των νευρώνων είναι η συλλογή των δεδομένων στην είσοδό τους προκειμένου να βελτιστοποιήσουν την έξοδό τους. Κάθε νευρώνας έχει μερικές πιθανές καταστάσεις στις οποίες μπορεί να βρεθεί και οι οποίες εξαρτώνται από τις εισόδους που δέχεται. Η έξοδός του μπορεί έχει μόνο μία πιθανή κατάσταση και είναι συνάρτηση των σημάτων εισόδου. Κατ' αντιστοιχία με τον βιολογικό, ένας τεχνητός νευρώνας αποτελείται από τρία βασικά στοιχεία:

- Τις *συνάψεις*, που αποτελούν τους συνδέσμους με τους οποίους ο νευρώνας δέχεται τα σήματα εισόδου και χαρακτηρίζονται από μία τιμή *βάρους-w*, η οποία υποδηλώνει πόσο στενά είναι συνδεδεμένοι οι νευρώνες που συνδέονται με το βάρος αυτό. Με άλλα λόγια, το βάρος, υποδηλώνει τη συνεισφορά του κάθε σήματος στη διαμόρφωση του δικτύου. Το *βάρος-w* πολλαπλασιάζεται με την τιμή

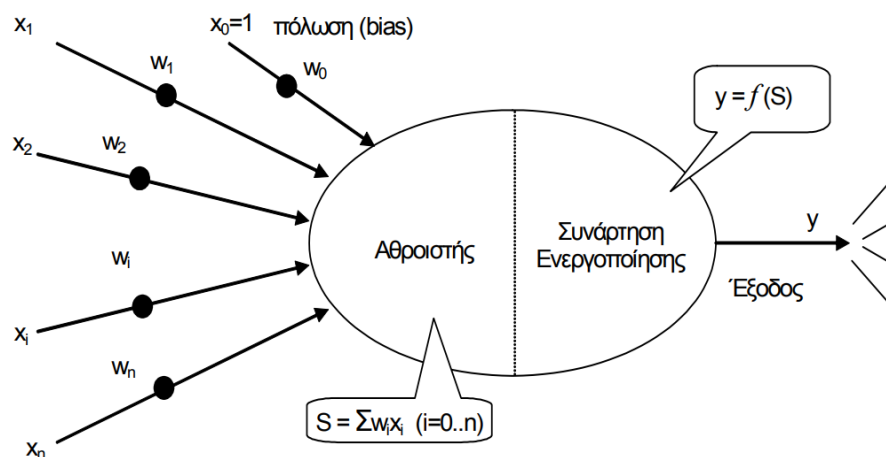
x του σήματος εισόδου που λαμβάνει ο νευρώνας μέσω της συγκεκριμένης σύναψης j . Γενικεύοντας, ένα σήμα εισόδου x της σύναψης j που είναι συνδεδεμένη με έναν νευρώνα k , πολλαπλασιάζεται με το βάρος w και τελικά ο νευρώνας λαμβάνει το σήμα εισόδου $x_j * w_{kj}$.

- Τον **αθροιστή**, ο οποίος αθροίζει όλες τις τελικές τιμές εισόδου $x_j * w_{kj}$ που λαμβάνει ο νευρώνας k , και μίας χαρακτηριστικής για κάθε νευρώνα τιμής, που ονομάζεται **τιμή κατωφλίου (bias)**, b_k .

$$S = x_1 w_{k1} + x_2 w_{k2} + \dots + x_r w_{kr} + b_k = \sum_i^r x_i w_{ki} + b_k$$

- Την **συνάρτηση μεταφοράς ή ενεργοποίησης**, η οποία παίρνει την τιμή S του αθροιστή και αποδίδει την τιμή y , που αποτελεί την έξοδο του νευρώνα. Με άλλα λόγια, η συνάρτηση μεταφοράς, $y = f(S)$, ενεργοποιεί την έξοδο του νευρώνα.

Τα παραπάνω συνοψίζονται στην **Εικόνα 2-3**.



Εικόνα 2-3 – Σχηματική αναπαράσταση νευρώνα [7]

2.2 Χαρακτηριστικά Νευρωνικών Δικτύων

Τα βασικά στοιχεία που χαρακτηρίζουν την αρχιτεκτονική κάθε **Τεχνητού Νευρωνικού Δικτύου** είναι:

- Ο αριθμός των κόμβων ανά επίπεδο

- **Η ύπαρξη και ο αριθμός των κρυφών επιπέδων**

Εάν οι νευρώνες ενός δικτύου οργανώνονται σε ένα επίπεδο, τότε το δίκτυο ονομάζεται *single-layer*, ειδικά, εάν υπάρχουν περισσότερα του ενός επίπεδα, τότε το δίκτυο ονομάζεται *multi-layer* και τα εσωτερικά επίπεδα ονομάζονται *hidden layers*, καθώς δεν έχουν καμία επικοινωνία με την είσοδο ή την έξοδο του δικτύου. Αξίζει να σημειωθεί, πως τις περισσότερες φορές το επίπεδο των εισόδων δεν προσμετράται στον συνολικό αριθμό των επιπέδων του δικτύου.

- **Ο τρόπος της σύνδεσης των μονάδων μεταξύ τους.**

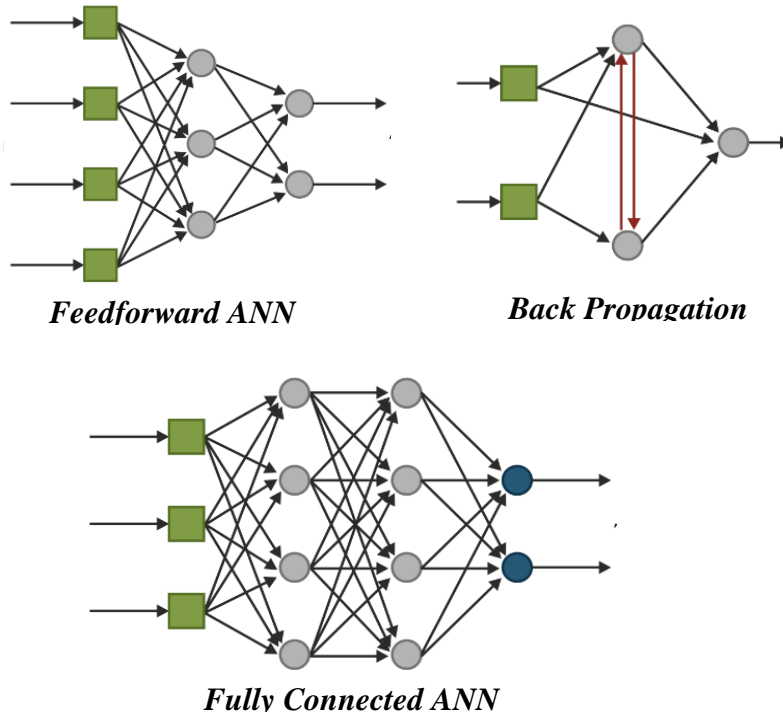
Με βάση τον τρόπο διασύνδεσης των μονάδων μεταξύ τους, τα νευρωνικά δίκτυα μπορούν να ταξινομηθούν ως ακολούθως:

- **Πρόσθιας τροφοδότησης**, όπου ο κάθε νευρώνας έχει ως είσοδό του μόνο τις εξόδους άλλων νευρώνων που βρίσκονται σε προηγούμενα επίπεδα.
- **Οπίσθιας τροφοδότησης**, όπου η έξοδος ενός νευρώνα μπορεί να αποτελέσει είσοδο ενός νευρώνα προηγούμενου επιπέδου.
- **Μερικής διασύνδεσης**, όταν ένας ή περισσότεροι νευρώνες ενός επιπέδου **ΑΕΝ** συνδέονται σε κάποια είσοδο νευρώνα του επόμενου επιπέδου.
- Και τέλος, **Πλήρους διασύνδεσης**, όταν **ΟΛΟΙ** οι νευρώνες ενός επιπέδου συνδέονται με όλες τις εισόδους των νευρώνων του επόμενου επιπέδου.

Τα παραπάνω συνοψίζονται στην **Εικόνα 2-4**.

- **Η τιμή ενεργοποίησης ή κατωφλίου**


- **Η μορφή της συνάρτησης μεταφοράς**, Είναι ένα από τα βασικότερα στοιχεία ενός *νευρωνικού δικτύου*, καθώς από αυτήν εξαρτάται η τιμή εξόδου του κάθε νευρώνα. Η μορφή τους μπορεί να είναι γραμμική ή μη και η επιλογή τους γίνεται με βάση τις ανάγκες που καλείται να επιτελέσει το κάθε δίκτυο. Παρακάτω παρατίθεται μία λίστα των σημαντικότερων συναρτήσεων μεταφοράς, χωρίς να γίνεται ιδιαίτερη ανάλυση τουλάχιστον στις γραμμικές οι οποίες χρησιμοποιούνται σπάνια.




Εικόνα 2-4 - Ταξινόμηση Τεχνητών Δικτύων ANN με βάση τον τρόπο διασύνδεσης [10]

ο Γραμμικές Συναρτήσεις Μεταφοράς

- ο Βηματική συνάρτηση ή συνάρτηση κατώφλιου
- ο Συνάρτηση προσήμου ()
- ο Συνάρτηση βηματικής μεταβολής



α) Βηματική Συνάρτηση




β) Συνάρτηση Προσήμου

ο Μη Γραμμικές Συναρτήσεις Μεταφοράς

Χρησιμοποιούνται ευρέως στα *τεχνητά νευρωνικά δίκτυα*, καθώς παρέχουν τη δυνατότητα επίλυσης *μη γραμμικών προβλημάτων*. Βασική απαίτηση για τη χρήση μη γραμμικών συναρτήσεων μεταφοράς, είναι αυτές να είναι συνεχές σε όλο το φάσμα των πραγματικών αριθμών, φραγμένες και παραγωγίσιμες σε όλο το πεδίο ορισμού τους.

ο **Σιγμοειδής συνάρτηση ενεργοποίησης.**

Αποτελεί μία εκ των βασικότερων συναρτήσεων μεταφοράς, καθώς καλύπτει όλες τις προαναφερθείσες απαιτήσεις. Είναι μέλος των "λογιστικών" συναρτήσεων και βασικό της γνώρισμα είναι η χαρακτηριστική γραφική παράσταση σχήματος "S". Η συνάρτησή της δίδεται από τον τύπο:



$$\sigma(s) = \frac{1}{1 + e^{-as}}$$


Το βασικότερο χαρακτηριστικό της σιγμοειδούς συνάρτησης είναι ότι η **έξοδος** του αντίστοιχου νευρώνα θα είναι μεταξύ **0** και **1**. Επίσης, καθώς είναι μη γραμμική, η έξοδος της θα είναι μη γραμμική συνάρτηση του αθροίσματος του γινομένου του σήματος εισόδου και των αντίστοιχων βαρών [65]

ο **Συνάρτηση υπερβολικής εφαπτομένης.**

Δίδεται από την σχέση:

$$f(x) = \alpha \tanh(\beta x)$$

Η συνάρτηση υπερβολικής εφαπτομένης έχει όλα τα ιδιαίτερα χαρακτηριστικά της σιγμοειδούς συνάρτησης (είναι μη γραμμική, συνεχής, γνησίως αύξουσα και παραγωγίσιμη σε όλο το πεδίο ορισμού της), αλλά επιπλέον έχει ως σύνολο τιμών το διάστημα $(-\alpha, \alpha)$.



ο **Συνάρτηση ανόρθωσης**

Ίσως η πιο δημοφιλής και πολυχρησιμοποιημένη συνάρτηση μεταφοράς.

Περεταίρω στοιχεία της παραθέτουμε στην [παράγραφο 3.4](#)

Συνεχίζοντας με τα βασικά χαρακτηριστικά των *τεχνητών νευρωνικών δικτύων*

- **Οι τιμές των αρχικών βαρών**
- **Ο τρόπος εκπαίδευσης που χρησιμοποιείται**

Όπως τα βιολογικά δίκτυα έχουν τη δυνατότητα να αντιδρούν στα ερεθίσματα που δέχονται από το περιβάλλον και μάλιστα, μπορούν και προσαρμόζονται στις αντίστοιχες επικρατούσες κάθε στιγμής συνθήκες, έτσι και τα τεχνητά νευρωνικά δίκτυα μπορούν να *“εκπαιδευτούν”* ώστε να αντιδρούν και να αναπροσαρμόζονται στα δεδομένα που δέχονται στην είσοδό τους. Εξάλλου ο πρωταρχικός σκοπός ενός τέτοιου δικτύου (*TNN*), δεν είναι άλλος από το να επιλύει προβλήματα που του παρουσιάζονται ή ακόμα και να εκτελεί συγκεκριμένες εργασίες, όπως η αναγνώριση εικόνων, φωνής, μοτίβων κ.λ.π. Με άλλα λόγια ένα *τεχνητό νευρωνικό δίκτυο* καλείται μέσω μίας περίπλοκης υπολογιστικής διαδικασίας που εξαρτάται από τις τιμές των βαρών, ενεργοποίησης κατωφλίου και τις συναρτήσεις μεταφοράς, να αποδώσει στην έξοδό του μία τιμή, σχετική με τα εξωτερικά ερεθίσματα που δέχεται, που δεν είναι άλλα από το διάνυσμα των τιμών εισόδου. Η παραπάνω διαδικασία ονομάζεται *εκπαίδευση* του νευρωνικού δικτύου και έχει οριστεί από τους *J.M. Mendel και R.W. McLaren* στο βιβλίο τους *“Learning and Pattern Recognition Systems: Theory and Applications” (1970)* ως:

“Η εκπαίδευση είναι μία διαδικασία κατά την οποία οι ελεύθερες παράμετροι ενός Τεχνητού Νευρωνικού Δικτύου αναπροσαρμόζονται μέσα από μία διαδικασία διέγερσης από το περιβάλλον του δικτύου. Η μορφή της εκπαίδευσης καθορίζεται από τον τρόπο με τον οποίο επιτυγχάνεται η αλλαγή των ελεύθερων παραμέτρων”.

Η διαδικασία της εκπαίδευσης ενός *τεχνητού νευρωνικού δικτύου* ακολουθεί συγκεκριμένη μεθοδολογία και κανόνες, με απώτερο σκοπό την αναπροσαρμογή των τιμών των βαρών για κάθε σύναψη των νευρώνων του δικτύου. Το σύνολο των κανόνων και της μεθοδολογίας, που ακολουθείται, καλείται *αλγόριθμος μάθησης*. Συνοπτικά, και καθώς δεν αποτελεί τον βασικό στόχο αυτής της εργασίας, ο τρόπος εκπαίδευσης ενός δικτύου με βάση τον αλγόριθμο και τη μεθοδολογία που θα ακολουθηθεί, μπορεί να ταξινομηθεί ως ακολούθως:

Με βάση τη μεθοδολογία:

- **Εκπαίδευση με επίβλεψη (Supervised Learning)**

Στη μέθοδο με επίβλεψη, το **τεχνητό νευρωνικό δίκτυο**, ακολουθώντας έναν συγκεκριμένο αλγόριθμο, εκπαιδεύεται να αποδίδει δεδομένες εισόδους σε εξόδους εκ των προτέρων γνωστές (σύνολο εκπαίδευσης). Το δίκτυο ξεκινάει τη λειτουργία του με τυχαίες τιμές βαρών (w), τις οποίες κατά τη διάρκεια της εκπαίδευσης αναπροσαρμόζει υπολογίζοντας το σφάλμα της εξόδου με βάση τη γνωστή τιμή της εισόδου. Απώτερος σκοπός είναι η ελαχιστοποίηση της διαφοράς της πραγματικής τιμής εξόδου από την ήδη γνωστή επιθυμητή τιμή.

- **Εκπαίδευση χωρίς επίβλεψη**

Στη μέθοδο χωρίς επίβλεψη, το δίκτυο τροφοδοτείται με την πληροφορία εισόδου, όχι όμως και με το επιθυμητό αποτέλεσμα. Επομένως, κατά τη διαδικασία αυτή, η διόρθωση των βαρών δεν μπορεί να γίνει υπολογίζοντας το σφάλμα εξόδου. Εδώ το δίκτυο, ακολουθώντας πάλι έναν συγκεκριμένο αλγόριθμο, εκπαιδεύεται επιβλέποντας τον ίδιο του τον εαυτό. Πιο αναλυτικά, χρησιμοποιώντας έναν μηχανισμό ανάδρασης, το δίκτυο προσπαθεί να συσχετίσει τα σήματα εισόδου με αντίστοιχες εξόδους. Χρησιμοποιείται λιγότερο συχνά από την εποπτευόμενη μάθηση, αλλά είναι ιδιαίτερος χρήσιμος τρόπος όταν τα δεδομένα απουσιάζουν από μία εφαρμογή.

- **Εκπαίδευση με ενίσχυση**

Εδώ ο αλγόριθμος εκπαιδεύεται μόνος του μέσα από την αλληλεπίδρασή του με το περιβάλλον. Τροφοδοτείται με διανύσματα εισόδου, τα οποία δημιουργούν μία χρονική ακολουθία και τελικά υπολογίζεται μία συγκεκριμένη έξοδος. Το δίκτυο είναι εφοδιασμένο με έναν **δείκτη συμπεριφοράς** ο οποίος επιδρά σαν ένα μέτρο αξιολόγησης του διανύσματος εξόδου. Με άλλα λόγια, όταν η έξοδος ανταποκρίνεται στο επιθυμητό αποτέλεσμα, με βάση την συγκεκριμένη είσοδο, το μέτρο αξιολόγησης είναι μεγάλο και μέσω μίας διαδικασίας ανατροφοδότησης, ο συντελεστής διόρθωσης των βαρών μικρός. Αντίθετα, όταν η έξοδος δεν ανταποκρίνεται



στο επιθυμητό αποτέλεσμα, το μέτρο αξιολόγησης είναι μικρό και άρα ο συντελεστής διόρθωσης των βαρών θα είναι μεγάλος. Η διαδικασία της "επιβράβευσης" ή "τιμωρίας" επαναλαμβάνεται έως ότου μεγιστοποιηθεί η "αίσθηση ικανοποίησης".

Με βάση τον αλγόριθμο της εκπαίδευσης

Όπως γίνεται αντιληπτό, όλες οι μέθοδοι εκπαίδευσης ακολουθούν συγκεκριμένη μεθοδολογία και καλά ορισμένους κανόνες, οι οποίοι καθορίζουν τον τρόπο με τον οποίο θα γίνονται οι αλλαγές των εσωτερικών παραμέτρων των δικτύων, όπως π.χ τα βάρη των συνάψεων. Οι κανόνες αυτοί ονομάζονται **αλγόριθμοι εκπαίδευσης** και μπορούν να ταξινομηθούν στις παρακάτω κατηγορίες.

- Εκπαίδευση με διόρθωση σφάλματος
- Εκπαίδευση κατά Hebbian
- Ανταγωνιστική εκπαίδευση
- Εκπαίδευση κατά Boltzmann
- Εκπαίδευση στηριζόμενη στη μνήμη

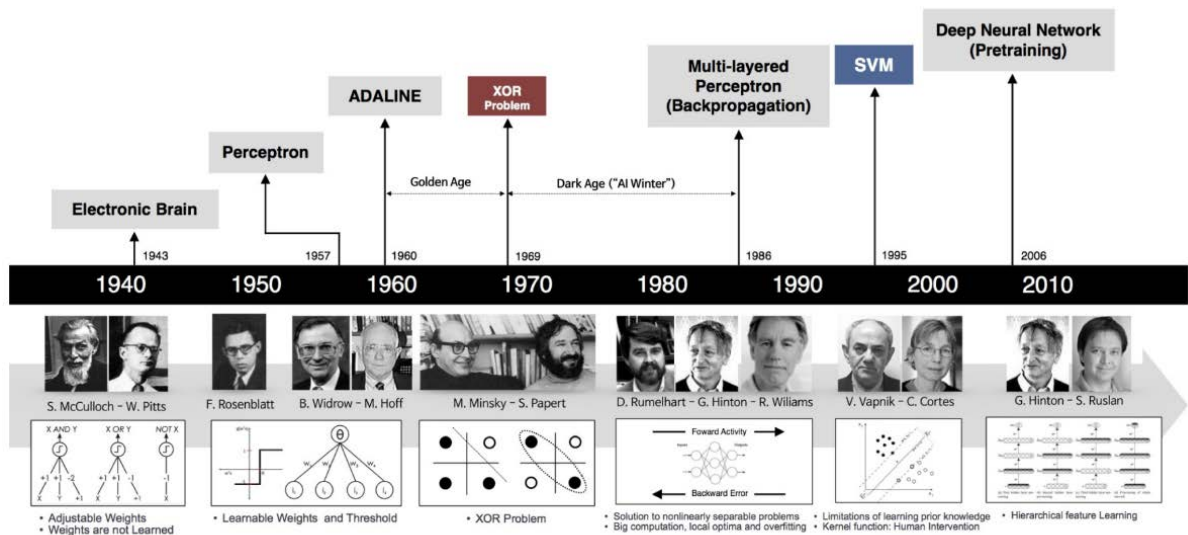
Καθώς ο σκοπός της εργασίας αυτής δεν είναι η εις βάθος ανάλυση του θεωρητικού υποβάθρου των δικτύων τεχνητής νοημοσύνης, δεν θα επεκταθούμε σε περαιτέρω ανάλυση των αλγορίθμων εκπαίδευσης.

2.3 Ιστορική Αναδρομή για τα Τεχνητά Νευρωνικά Δίκτυα

Στην **Εικόνα 2-5** συνοψίζεται η ιστορική εξέλιξη των **Τεχνητών Νευρωνικών Δικτύων**. Πατέρας τους θεωρείται ο ψυχίατρος **S.McCulloth** και ο μαθηματικός **W.Pitts**, οι οποίοι το **1943**, σε μία πρωτοπόρα εργασία για την εποχή της, παρουσίασαν την ιδέα ότι ένα νευρωνικό δίκτυο αποτελείται από ένα μεγάλο αριθμό νευρώνων διασυνδεδεμένων μεταξύ τους, το οποίο περιέγραψαν με μαθηματικούς λογικούς κανόνες. Ο αμέσως επόμενος θεμέλιος λίθος, τέθηκε από τον **Hebb το 1949**, με το βιβλίο του **"The organization of behavior"** στο οποίο εισάγει και τον αντίστοιχο κανόνα εκμάθησης. Η πρώτη όμως πρακτική εφαρμογή των **Τεχνητών Νευρωνικών Δικτύων** ήρθε το **1957**, με την σχεδίαση και υλοποίηση από τον **Frank Rosenblatt** του δικτύου **Perceptron** που είχε την ικανότητα να αναγνωρίζει πρότυπα.

Έκτοτε υπήρξαν πολλές μελέτες στο χώρο των *Τεχνητών Νευρωνικών Δικτύων* και περίοδοι που η πρόοδος ήταν στάσιμη, όπως αυτή μεταξύ του 1969 έως το 1982, όπου ο *J Hopfield* σε μία εργασία μόλις 5 σελίδων, απέδειξε πως ένα *Τεχνητών Νευρωνικών Δικτύων* μπορεί να αποτελέσει *αποθηκευτικό χώρο δεδομένων*, αλλά και πως η πληροφορία μπορεί να *επανακτηθεί*, αρκεί να του δοθούν μερικά μόνο τμήματα αυτής [19]

Οι εξελίξεις στο χώρο των *Τεχνητών Νευρωνικών Δικτύων* μετά το 1986 ήταν καταγιστικές, φτάνοντας στις μέρες μας που νέες μελέτες παρουσιάζονται καθημερινά, από σχεδόν όλα τα μεγάλα πανεπιστήμια του κόσμου, και η εφαρμογή τους είναι συνεχείς σε κάθε πτυχή της καθημερινότητας. Αρκεί κάποιος να δει τις εφαρμογές των *Τεχνητών Νευρωνικών Δικτύων* στην αεροπλοΐα, ναυτιλία, ιατρική, οικονομία, αυτοκίνηση. Ακόμα πιο εύκολα, στην λειτουργία των Η/Υ με τις εφαρμογές αναγνώρισης εικόνων και φωνής, αυτόματης μετάφρασης κειμένων, και άλλα πολλά.



Εικόνα 2-5 – Σύνοψη της Ιστορικής Εξέλιξης των Τεχνητών Νευρωνικών Δικτύων [28]

3. Συνελικτικά Νευρωνικά Δίκτυα

3.1 Εισαγωγή στα Συνελικτικά Νευρωνικά Δίκτυα

Τα *συνελικτικά νευρωνικά δίκτυα*, συνοπτικά *CNN (Convolutional Neural Networks)*, ή *ConvNets*, είναι ένας ειδικός τύπος και ταυτόχρονα ο εντυπωσιακότερος αντιπρόσωπος των δικτύων τεχνητής νοημοσύνης και ιδιαίτερα του χώρου του της *βαθιάς μάθησης*. Η χρήση των *συνελικτικών νευρωνικών δικτύων* επικρατεί τα τελευταία χρόνια στη επίλυση δύσκολων εφαρμογών αναγνώρισης μοτίβων και ταξινόμησης ή κατηγοριοποίησης δεδομένων. Οι δύο βασικότερες ομάδες εφαρμογών είναι η αντιστοίχιση μίας δισδιάστατης εικόνας (2D image) είτε σε συγκεκριμένη κατηγοριοποίηση (*classification problems*) ή, η ανάθεση της εικόνας σε μία συγκεκριμένη αναλογική τιμή (*regression based problems*) - [48].

Πιο συγκεκριμένα, μερικές από τις πολλές εφαρμογές των *συνελικτικών νευρωνικών δικτύων*, είναι η αναγνώριση εικόνων, φωνής και ήχου, η κατάταξη δεδομένων, εφαρμογές Computer Vision, αυτόματη αναγνώριση κειμένου, η μετάφραση κειμένων και φωνής, κ.α. Γενικά, τα *συνελικτικά δίκτυα* μπορούν να επεξεργαστούν δεδομένα *χρονοσειράς*, που μπορεί να προκύψουν από τη δειγματοληψία σημάτων σε μορφή μονοδιάστατου πίνακα (1D grid), ή δεδομένα εικόνας που μπορούν να αναλυθούν σε δισδιάστατους πίνακες (2D grid) από pixels. Έχουν σχεδιαστεί ώστε να μαθαίνουν αυτόματα και προσαρμοστικά, χωρικές ιεραρχίες χαρακτηριστικών, μέσω της οπίσθιας διάδοσης. Είναι μαθηματικές κατασκευές που αποτελούνται από τρία βασικά δομικά στοιχεία:

- Τα *επίπεδα συνέλιξης*
- *Pooling layers* ή *επίπεδα συγκέντρωσης*
- και *Επίπεδα πλήρους διασύνδεσης*.

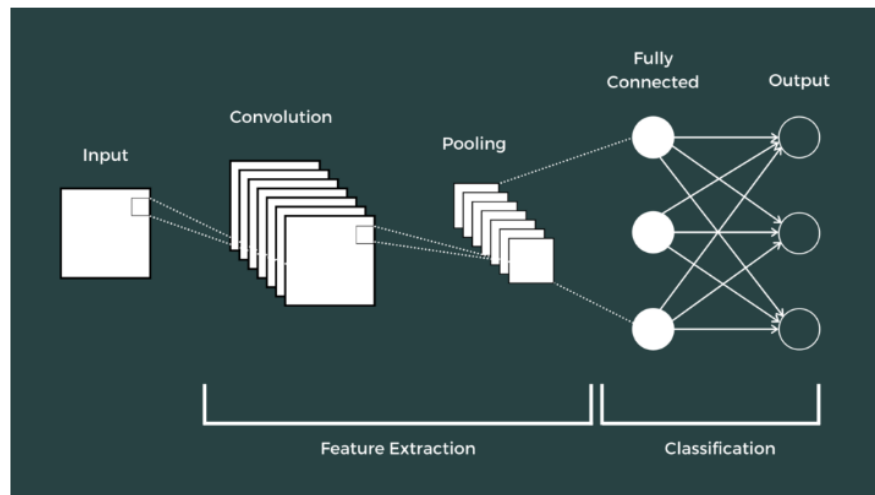
Τα δύο πρώτα, *convolutional* και *pooling layers*, παρέχουν την εξαγωγή των *χαρακτηριστικών μοτίβων* των διανυσμάτων εισόδου, ενώ το τρίτο, *fully connected layer* μπορεί να θεωρηθεί ως το επίπεδο εκείνο που, είτε ταξινομεί τα χαρακτηριστικά αυτά σε μία μοναδική έξοδο, είτε τα αντιστοιχεί σε μία μοναδική αναλογική τιμή.

Στην **Εικόνα 3-1** παρατίθενται οι διαφορετικές διεργασίες που το κάθε επίπεδο εκτελεί, καθώς και οι παράμετροι που το καθορίζουν.

Layers	Action	Parameters
Convolution layer	Apply filters to extract features Filters are composed of small kernels, learned One bias per filter Apply activation function on every value of feature map	Number of kernels Size of kernels (height and width) Activation function Stride Padding
Pooling layer	Reduce dimensionality Extract maximum or average value of a region Sliding window approach	Regularization type and value Stride Size of window
Fully connected layer	Aggregate information from final feature maps Generate final classification	Number of nodes Activation function, depending on role of layer. If aggregating info, use ReLU. If producing final classification, use Softmax

Εικόνα 3-1 – Comparison of different layers in CNN [5]


Ένα **συνελικτικό νευρωνικό δίκτυο** μπορεί να αποτελείται από πολλαπλά **convolution layers** και **pooling layers**, πάντα όμως η έξοδος αποτελείται από ένα **επίπεδο**, στο οποίο καταλήγουν μέσω της συνάρτησης ενεργοποίησης ένα ή και περισσότερα **fully connected layers**. Στην **Εικόνα 3-2** φαίνεται η τυπική αρχιτεκτονική ενός **συνελικτικού νευρωνικού δικτύου**.



Εικόνα 3-2 – Βασική αρχιτεκτονική Convnet [77]

Αντίστοιχα, στην **Εικόνα 3-3** απεικονίζεται μία αναλυτικότερη αρχιτεκτονική ενός **συνελικτικού νευρωνικού δικτύου** με δύο επίπεδα συνέλιξης. Εδώ, γίνεται ορατή μία εκ των βασικότερων διαφορών μεταξύ των **συμβατικών τεχνητών νευρωνικών**

δικτύων και των *συνελικτικών*. Ενώ στα *TNN* οι νευρώνες συνδέονται μεταξύ τους με βαθμωτές τιμές, τα *συνελικτικά* δίκτυα εκτείνονται σε δύο ή ακόμα και σε τρεις διαστάσεις (2D – 3D planes). Γι' αυτό το λόγο, όπως προαναφέρθηκε, τα σήματα εισόδου, καθώς και τα βάρη των νευρώνων αποτελούνται από πίνακες τιμών. Στην ίδια εικόνα φαίνεται πως το σήμα εισόδου είναι ένας δισδιάστατος πίνακας 24x24 pixels. Το δίκτυο επεξεργασίας αποτελείται από το *No1 convolution* και *pooling layer* τεσσάρων νευρώνων, ενώ το *No2 convolution* και *pooling layer* αποτελείται από έξι νευρώνες. Επίσης γίνεται αντιληπτό πως κατά τη εξέλιξη της διαδικασία μειώνεται σταδιακά το μέγεθος των *πινάκων χαρακτηριστικών* που εξάγονται από τις διεργασίες της *συνέλιξης* και *ομαδοποίησης*. Τέλος, η έξοδος του δεύτερου pooling layer, εισάγεται σε ένα *fully connected layer*, από το οποίο γίνεται *κατηγοριοποίηση* δύο εξόδων y_1 και y_2 .



Εικόνα 3-3 – Αρχιτεκτονική Συνελικτικού Δικτύου με δύο επίπεδα Συνέλιξης

Τα παρακάτω βήματα περιγράφουν τις διεργασίες που εκτελούνται στο δίκτυο της [Εικόνας 3-3](#) .[26]

1. Την είσοδο του δικτύου αποτελεί μία εικόνα 24x24 pixels σε αποχρώσεις του γκρι.
2. Κάθε νευρώνας του πρώτου επιπέδου συνέλιξης εκτελεί μία γραμμική πράξη *συνέλιξης* μεταξύ της εικόνας και του *φίλτρου* με σκοπό τη δημιουργία του *πίνακα χαρακτηριστικών* του νευρώνα

3. Ο *πίνακας χαρακτηριστικών* κάθε νευρώνα περνάει από μία *συνάρτηση ενεργοποίησης* για να παραχθεί ο πίνακας εξόδου των χαρακτηριστικών του νευρώνα
4. Στο *επίπεδο ομαδοποίησης*, ο *πίνακας χαρακτηριστικών* κάθε νευρώνα δημιουργείται μειώνοντας το μέγεθος του σχετικού πίνακα χαρακτηριστικών εξόδου του προηγούμενου νευρώνα του επιπέδου συνέλιξης. Στο παράδειγμα της *Εικόνα 3-3*, στο πρώτο επίπεδο pooling, δημιουργούνται πίνακες χαρακτηριστικών διαστάσεων 7 x 7.
5. Τα βήματα 3 και 4 επαναλαμβάνονται και τελικά η έξοδος του επιπέδου *ομαδοποίησης*, διαστάσεων 4x4, της δεύτερης συνέλιξης εισάγονται στο πλήρως *διασυνδεδεμένο επίπεδο*
6. Οι *μονοδιάστατες πλέον έξοδοι* του *fully connected layer* διαδίδονται προς τα εμπρός (forward propagation), ώστε τελικά να παραχθεί η *ταξινομημένη έξοδος* του δικτύου.

3.2 Σύντομη Ιστορική Αναδρομή για τα Συνελικτικά Νευρωνικά Δίκτυα.

Το 1982 οι *Fukushima and Miyake* [25] παρουσίασαν τον προκάτοχο των *συνελικτικών νευρωνικών δικτύων* που το ονόμασαν “*Neocognitron*”. Το *neocognitron* είναι ένα ιεραρχικό δίκτυο με την ικανότητα αυτό-οργάνωσης που μπορεί να αναγνωρίζει “*μοτίβα ερεθισμάτων*” (*stimulus patterns*) βασισμένο στις διαφορές της εμφάνισής τους. Με βάση τους *Serkan Kiranyaz et al (2020)*, [25] αυτό ήταν το πρώτο δίκτυο με την ικανότητα να αναγνωρίζει και κατηγοριοποιεί παρόμοια αντικείμενα σε συγκεκριμένη κατηγορία ανεξάρτητα από θέση τους ή από τυχόν μορφολογικές διαφορές, όπως ακριβώς μπορεί να κάνει και το βιολογικό οπτικό σύστημα των θηλαστικών. Η εξέλιξη του δικτύου σταμάτησε όταν κρίθηκε απαραίτητη η μεγιστοποίηση της μαθησιακής απόδοσης του δικτύου πράγμα που απαιτούσε την ανάγκη της εποπτευόμενης μάθησης με πολύ μεγάλα σετ δεδομένων και άρα την χρήση τεράστιας υπολογιστικής δύναμης, άγνωστη για την εποχή εκείνη.

Παρόλα αυτά, πατέρας των *συνελικτικών νευρωνικών δικτύων*, θεωρείται ο Γάλλος ερευνητής *Yann LeCun*. Στα τέλη της δεκαετίας του 80 πρότεινε μία



αρχιτεκτονική τεχνητού νευρωνικού δικτύου που θα έδινε στους Η/Υ την ικανότητα να αναγνωρίσουν εικόνες. Ήταν το **1994** όταν ανέπτυξε το πρώτο **συνελικτικό νευρωνικό δίκτυο** με το όνομα **LeNet**, ικανό να αναγνωρίζει χειρόγραφους γραφικούς χαρακτήρες, εφαρμόζοντας για πρώτη φορά την εκπαίδευση της **οπίσθιας διάδοσης**. Το **1998** οι **Yann LeCun, Leon Bottou, Yoshua Bengio** και **Patrick Haffner**, δημοσίευσαν την εργασία τους με τίτλο **Gradient Based Learning Applied to Document** [30]. Στην εργασία τους αυτή μεγέθους 46 σελίδων, παρουσίασαν ένα νέο συνελικτικό μοντέλο το **LeNet5**, το οποίο εκπαιδεύτηκε με την μέθοδο της **ταχύτερης καθόδου** στην αναγνώριση χειρόγραφων χαρακτήρων, χρησιμοποιώντας την βάση δεδομένων NIST [30]. Την ίδια χρονιά οι τράπεζες στην Αμερική χρησιμοποιούσαν την τεχνολογία αυτή για την ανάγνωση πάνω από το 10% των τραπεζικών επιταγών. [91]. Από τότε χρειάστηκαν περίπου είκοσι τέσσερα χρόνια, έως το **2012**, όπου σε έναν διαγωνισμό αναγνώρισης εικόνων για υπολογιστές, παρουσιάστηκε το δίκτυο **AlexNet**, το οποίο κέρδισε και τον διαγωνισμό. Έκτοτε τα **συνελικτικά νευρωνικά δίκτυα** βρίσκονται στο προσκήνιο της **βαθιάς μάθησης**. Οι ερευνητές εμφανίζουν συνεχώς νέες ιδέες με βελτιωμένα χαρακτηριστικά και αποδόσεις των δικτύων. Αρκεί να αναφέρουμε, χωρίς να επεκταθούμε καθόλου, κάποια από αυτά τα συνελικτικά δίκτυα, όπως το **Google Net (2013)**, το **VGG (2015)**, **ResNeXT(2017)** και το **EfficientNet 1303(2020)**.

3.3 Επίπεδα Συνέλιξης – Convolutional Layers

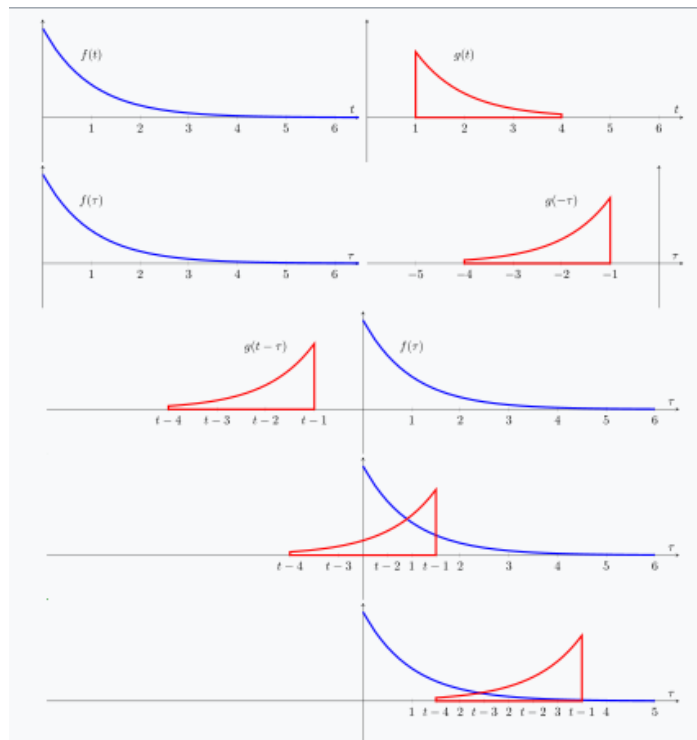
3.3.1 Τι είναι η συνέλιξη (convolution)

Στη γενική της μορφή, συνέλιξη είναι μια γραμμική πράξη δύο συναρτήσεων f και g με πραγματικές τιμές η οποία παράγει μία άλλη συνάρτηση την $f * g$, η οποία εκφράζει πως η μία συνάρτηση επιδρά στην άλλη [68]. Ορίζεται ως το ολοκλήρωμα του γινομένου των δύο συναρτήσεων, αφού η μία συνάρτηση ανακλαστεί στον άξονα y και μετατοπισθεί. Το αποτέλεσμα της συνέλιξης δεν επηρεάζεται από το ποια από τις δύο συναρτήσεις θα επιλέγει να ανακλαστεί και μετατοπισθεί πριν την πράξη της ολοκλήρωσης.

Η συνέλιξη ορίζεται από τον τύπο:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau) g(t - \tau) d\tau$$

Στη **Εικόνα 3-4**, φαίνεται παραστατικά η διαδικασία της συνέλιξης



Εικόνα 3-4 – Σχηματική παράσταση συνέλιξης δύο συναρτήσεων $f(t)$ και $g(t)$ [68]

Στα **συνελκτικά νευρωνικά δίκτυα**, ή πρώτη συνάρτηση $f(t)$ ονομάζεται **είσοδος**, ενώ η δεύτερη συνάρτηση $g(t)$ **φίλτρο**. Το αποτέλεσμα αναφέρεται ως **πίνακας χαρακτηριστικών**.

3.3.2 Η πράξη της συνέλιξης στα Συνελκτικά Νευρωνικά Δίκτυα

Όπως και το όνομα ορίζει, η συνέλιξη είναι η **γραμμική πράξη** που εκτελείται στα **συνελκτικά νευρωνικά δίκτυα**, με σκοπό την εξαγωγή των **ιδιαιτέρων χαρακτηριστικών** του σήματος εισόδου. Είναι η βασικότερη και σπουδαιότερη πράξη του συγκεκριμένου τύπου νευρωνικών δικτύων και αυτή που τα ξεχωρίζει από όλα τα υπόλοιπα.

Στην πράξη, ένα *φίλτρο*, που απαρτίζεται από έναν πίνακα αριθμών και που προκύπτει από τον αλγόριθμο εκμάθησης του δικτύου, εφαρμόζεται κατά μήκος του σήματος εισόδου, που είναι ένας άλλος πίνακας αριθμών και ονομάζεται *input tensor*. Κατά την συνέλιξη προκύπτει ένας νέος πίνακας που είναι το άθροισμα του γινομένου κάθε στοιχείου του *φίλτρου* και του *πίνακα εισόδου*, καθώς το φίλτρο *σαρώνει* τον τανυστή. Το εσωτερικό αυτό γινόμενο, είναι ένας μετασχηματισμός, που περιγράφεται από την παρακάτω συνάρτηση:

$$O_j^l = f \left(\sum_{i \in M_j} (\sigma_{ij} O_i^{l-1} \blacksquare W_{ij}^l) + b_j^l \right)$$

Στη συνάρτηση αυτή,

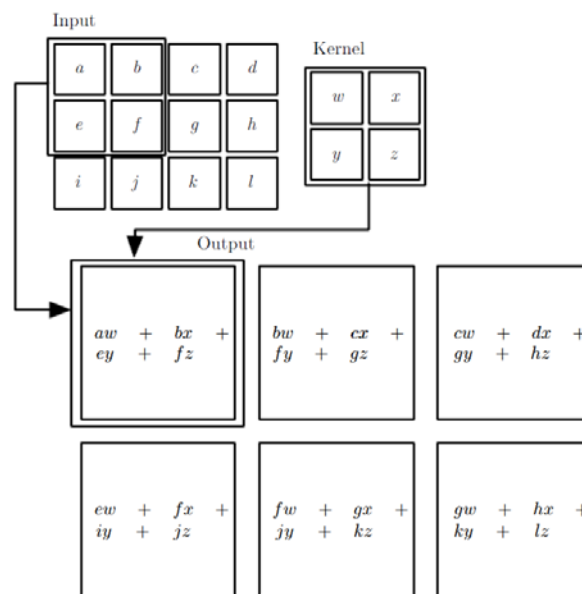
- O_i^{l-1} , είναι η έξοδος του επιπέδου της συνέλιξης $l-1$ και η είσοδος του επιπέδου l , μέσω του πίνακα χαρακτηριστικών i ,
- O_j^l , είναι ο j th πίνακας χαρακτηριστικών, του επιπέδου $l-1$
- f , η συνάρτηση μεταφοράς (RELU, sigmoid, κλπ)
- M_j , αντιπροσωπεύει τη συλλογή των πινάκων εισόδου
- W_{ij}^l , είναι η τιμή του βάρους που συνδέει το i th feature του $l-1$ επιπέδου, με το j th feature του l επιπέδου
- b_j^l είναι το αντίστοιχο bias για το επίπεδο $l-1$
- Το σύμβολο \blacksquare υποδηλώνει την πράξη της συνέλιξης.

Η διαδικασία επαναλαμβάνεται εφαρμόζοντας διαφορετικά *φίλτρα*, με σκοπό την εξαγωγή αυθαίρετου αριθμού χαρακτηριστικών του σήματος εισόδου. Δύο βασικές παράμετροι που καθορίζουν την διαδικασία της συνέλιξης είναι ο *αριθμός* και το *μέγεθος των φίλτρων*, η επιλογή των οποίων είναι αυθαίρετη και καθορίζει το μέγεθος των *πινάκων χαρακτηριστικών*. Χαρακτηριστικά μεγέθη kernel είναι 3x3, 5x5 ή ακόμα και 7x7, με επικρατέστερο το 3x3.



Παρακάτω, στην **Εικόνα 3-5** παρατίθεται η μαθηματική διαδικασία της συνέλιξης, ενώ στην **Εικόνα 3-6**, ένα παράδειγμα συνέλιξης ενός πίνακα σήματος εισόδου διαστάσεων 5×5 , εφαρμόζοντας ένα φίλτρο διαστάσεων 3×3 .

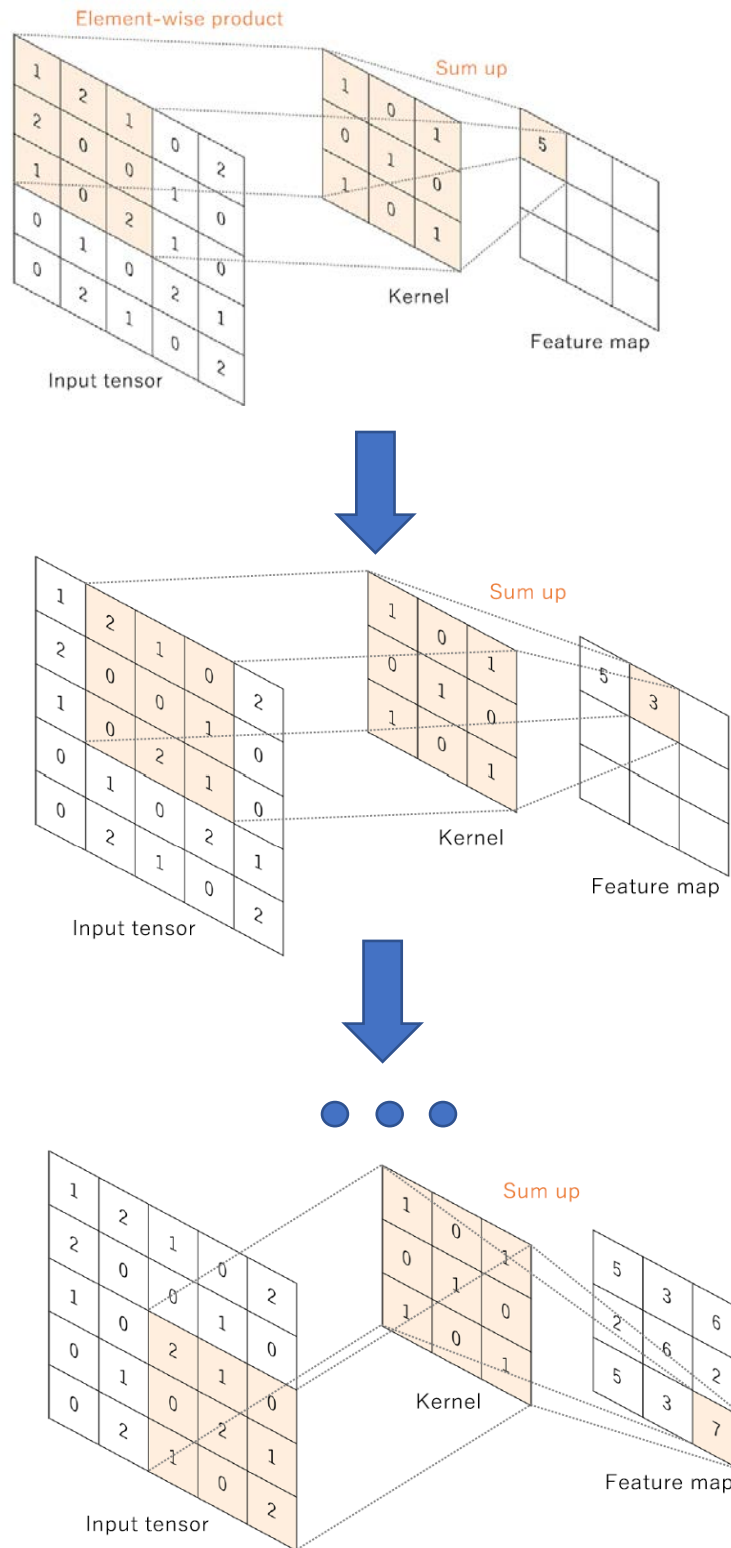
Έστω ότι ο **πίνακας εισόδου** έχει διαστάσεις (x,y) και το **φίλτρο** (m,n) , το αποτέλεσμα της συνέλιξης $(x,y) * (m,n)$, θα είναι ένας **πίνακας** διαστάσεων $(x-m+1, y-n+1)$



Εικόνα 3-5 - An example of 2-D convolution without kernel-flipping [17]

3.3.3 Stride

Ονομάζεται η **απόσταση, βήμα** μεταξύ δύο διαδοχικών θέσεων της εφαρμογής ενός **φίλτρου**. Είναι ένα από τα βασικά χαρακτηριστικά των **συνελικτικών νευρωνικών δικτύων**, καθώς επηρεάζει το μέγεθος του **πίνακα χαρακτηριστικών**.

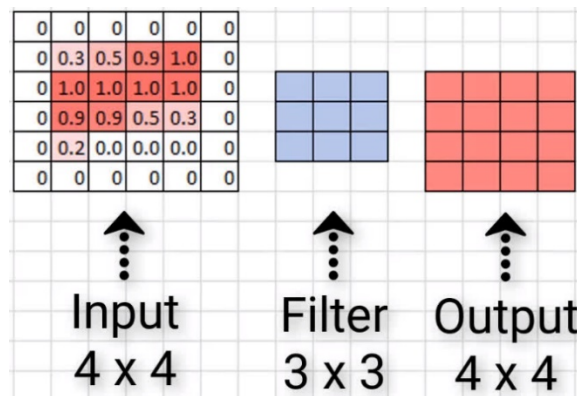


Εικόνα 3-6 – Convolution Process [38]



3.3.4 Padding – Zero Padding


Ένα ακόμη χαρακτηριστικό των *επιπέδων συνέλιξης* είναι η διαδικασία *zero-padding*, κατά την οποία στην περιφέρεια του διανύσματος εισόδου προστίθενται μηδενικά, ώστε μετά την εφαρμογή του *φίλτρου* ο *πίνακας χαρακτηριστικών* να διατηρήσει το μέγεθος του διανύσματος εισόδου. Αυτό είναι μία σημαντική διαδικασία καθώς, υπάρχει η πιθανότητα, στην εξωτερική περιφέρεια των πινάκων εισόδου να βρίσκονται σημαντικά δεδομένα/χαρακτηριστικά του σήματος, τα οποία μπορεί να χαθούν χωρίς την εφαρμογή του *padding*. Για παράδειγμα, στην *Εικόνα 3-7* το αρχικό διάνυσμα έχει μέγεθος 4x4 και το φίλτρο kernel 3x3. Χωρίς την εφαρμογή του *padding*, το διάνυσμα εξόδου θα είχε διάσταση 2x2, ενώ μετά την εφαρμογή του *padding*, το διάνυσμα εξόδου διατηρεί την αρχική του διάσταση 4x4. Η επιλογή της εφαρμογής *padding* είναι προαιρετική, καθώς, πέραν της ακρίβειας στην εξαγωγή των χαρακτηριστικών του σήματος εισόδου, αυξάνει και το μέγεθος των διανυσμάτων εξόδου κάθε *συνελκτικού επιπέδου*, το οποίο δεν είναι πάντοτε επιθυμητό.



Εικόνα 3-7 – Zero Padding [92]

Το μέγεθος του *padding* δίνεται από την σχέση: $P = \frac{f-1}{2}$, όπου f είναι το μέγεθος του φίλτρου kernel. Το αποτέλεσμα της πράξης πρέπει να είναι ακέραιος αριθμός

Στην *Εικόνα 3-8* φαίνεται το αποτέλεσμα της εφαρμογής διαφόρων *φίλτρων kernel* με και χωρίς *Padding*, σε μία εικόνα που απεικονίζει τον αριθμό 8, τονίζοντας τα ιδιαίτερα χαρακτηριστικά που προκύπτουν



Εικόνα 3-8 – Εξαγωγή χαρακτηριστικών (features extraction) μετά τη εφαρμογή kernels σε μία εικόνα [38]

3.3.5 Parameter Sharing

Ένα από τα βασικότερα χαρακτηριστικά των *συνελκτικών νευρωνικών δικτύων* είναι πως παρέχουν τη δυνατότητα αναγνώρισης συγγενικών μοτίβων σε εικόνες που τροφοδοτούνται στην είσοδό τους. Έχουν δηλαδή την δυνατότητα να ανιχνεύουν συγγενικά χαρακτηριστικά εικόνων που τροφοδοτούνται ως σήμα εισόδου, ακόμα και αν αυτά βρίσκονται σε διαφορετικά σημεία (shifted), έχουν αλλάξει κατεύθυνση (tilted) ή προσανατολισμό (orientation). Αυτό επιτυγχάνεται καθώς οι νευρώνες ενός *επιπέδου*, αν και είναι δυνατόν να μην συνδέονται με όλους τους νευρώνες του προηγούμενου επιπέδου, μέσω των *φίλτρων kernels* και των *βαρών* σχετίζονται με συγκεκριμένα τοπικά *δεκτικά πεδία* τα οποία εξαρτώνται από τη διαδικασία της *σάρωσης (sliding)* του *φίλτρου kernel* στο διάνυσμα εισόδου. Παράλληλα, οι τιμές των παραμέτρων των νευρώνων διαμοιράζονται σε όλα τα *φίλτρα kernels* που χρησιμοποιούνται στο ίδιο ή σε επόμενο *επίπεδο*.

Το χαρακτηριστικό αυτό των *συνελκτικών νευρωνικών δικτύων* και ιδιαίτερα των *επιπέδων συνέλιξης*, ονομάζεται *διαμοιρασμός κοινών παραμέτρων* ή όπως είναι γνωστό στην ορολογία *Parameter Sharing* ή *Weight Replication*.

Έστω ότι κατά τη διαδικασία της εκπαίδευσης (*training process*), ο αλγόριθμος, εφαρμόζοντας μία σειρά *φίλτρων kernels* στο *επίπεδο i* , υπολογίζει τα βέλτιστα *βάρη* και τιμές *κατωφλίου* των συζεύξεων για την εξαγωγή των *χαρακτηριστικών* του συγκεκριμένου επιπέδου. Τότε είναι πολύ πιθανόν τα ίδια χαρακτηριστικά (kernels, weights και biases) να είναι χρήσιμα και στο επόμενο επίπεδο $i+1$. Έτσι τα τοπικά χαρακτηριστικά ενός επιπέδου (*spatial characteristics*) μεταφέρονται σε όλες τις θέσεις των υπολοίπων *επιπέδων*. Αυτό έχει σαν αποτέλεσμα τη δραστική μείωση των παραμέτρων που το δίκτυο πρέπει να εξάγει κατά τη διαδικασία της εκμάθησης, αυξάνοντας την αποτελεσματικότητά του και την μείωση της απαιτούμενης υπολογιστικής ισχύος. Στην *Εικόνα 3-9* απεικονίζεται η διαφορά μεταξύ ενός δικτύου που χρησιμοποιεί *διαμοιρασμό κοινών παραμέτρων* και ενός δικτύου *πλήρους διασύνδεσης*.




Figure 9.5: Parameter sharing: Black arrows indicate the connections that use a particular parameter in two different models. (*Top*)The black arrows indicate uses of the central element of a 3-element kernel in a convolutional model. Due to parameter sharing, this single parameter is used at all input locations. (*Bottom*)The single black arrow indicates the use of the central element of the weight matrix in a fully connected model. This model has no parameter sharing so the parameter is used only once.

Εικόνα 3-9 – Επεξήγηση Parameters Sharing [17]

Για να γίνει το παραπάνω πιο κατανοητό, παραθέτουμε τις παραμέτρους που το δίκτυο πρέπει να υπολογίσει κατά την εκπαίδευση, με και χωρίς τον *διαμοιρασμό κοινών παραμέτρων*, όπως αυτό παρουσιάζεται στο άρθρο του Richmond A. (2020) “*Understanding Parameter Sharing (or weights replication) Within Convolutional Neural Networks*” [83]

Name	AlexNet First Conv Layer
Input image size	227x227x3
Number of filters	96
Filter size	11x11x3
Stride	4
Padding	0
Number of parameters without sharing	105,705,600
Number of parameters with sharing	34,944


Παρατηρούμε πως η διαφορά των προς εκπαίδευση παραμέτρων χωρίς και με *διαμοιρασμό κοινών παραμέτρων* είναι της τάξης του $1/3025$

3.4 Συνάρτηση Ενεργοποίησης – Activation Function

Αδιάσπαστο μέρος των *συνελκτικών δικτύων (CNNs)* αποτελεί η εφαρμογή της *συνάρτησης ενεργοποίησης* ή *activation function*. Αποτελεί συμπληρωματικό βήμα της συνέλιξης, με απώτερο σκοπό, αφενός την μετατροπή του *γραμμικού αποτελέσματος* σε *μη γραμμικό* και αφετέρου τον έλεγχο την διάδοση της πληροφορίας μεταξύ γειτονικών των *επιπέδων* [36]. Η ανάλυση μία εικόνας ή ακόμα και ενός χρονικού σήματος είναι κατά βάση μη γραμμική. Απώτερος σκοπός της *συνάρτησης ενεργοποίησης* είναι η βελτιστοποίηση του δικτύου κατά τη διαδικασία της εκπαίδευσης, ακόμα και αν υπάρχει θόρυβος στο σήμα εισόδου, αναδεικνύοντας τα ιδιαίτερα χαρακτηριστικά του.

Στα *συνελκτικά νευρωνικών δίκτυα* έχει επικρατήσει η χρήση της συνάρτησης ενεργοποίησης *Rectified Linear Units* ή σε συντομογραφία *ReLU*, στοιχεία της οποίας είδαμε στην [παράγραφο 2.2](#) και παραθέτουμε εν συντομία ξανά εδώ.

Η συνάρτηση της δίδεται από τον τύπο: $f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$ ή $f(x) = \max\{0, x\} = x$, όπου $x \in [0, +\infty]$, ενώ η γραφική της αναπαράσταση απεικονίζεται στην [Εικόνα 3-10](#)



(a) ReLU

Εικόνα 3-10 – Activation Function ReLU [36]

Η **συνάρτηση RELU** αποδίδει την τιμή του αθροίσματος του γινομένου των τιμών εισόδου επί το αντίστοιχο βάρος συμμετοχής, αλλά μόνο όταν η τιμή του γινομένου είναι θετική, αλλιώς, όταν δηλαδή το γινόμενο είναι αρνητικό, επιστρέφει την τιμή 0. Η επιτυχία της εφαρμογής της συνάρτησης ενεργοποίησης ReLU, έγκειται στο γεγονός ότι μέσω της διάδοσης μόνο των θετικών αποτελεσμάτων σχεδόν εξαλείφει το φαινόμενο του *gradient vanishing*.

3.5 Επίπεδο ομαδοποίησης - Pooling Layer

Όπως προαναφέρθηκε, ένα **συνελικτικό νευρωνικό δίκτυο**, αποτελείται από πολλά **επίπεδα συνέλιξης**, τα οποία προηγούνται μίας **συνάρτησης ενεργοποίησης** και ενός **επιπέδου ομαδοποίησης** ή όπως αναφέρεται στην βιβλιογραφία **Pooling Layer**. Επίσης, στις προηγούμενες παραγράφους είδαμε τις εργασίες που εκτελούν τα **επίπεδα συνέλιξης** και οι **συναρτήσεις ενεργοποίησης**. Ποια όμως η χρήση των **επιπέδων ομαδοποίησης**;

Ένα βασικό πρόβλημα των **πινάκων χαρακτηριστικών** που εξάγονται από τα επίπεδα συνέλιξης, είναι ότι οι τιμές τους εξαρτώνται άμεσα από τη χωροταξική θέση των χαρακτηριστικών στην εικόνα του σήματος εισόδου. Τα **pooling layers**


εφαρμόζοντας την μέθοδο της *υποδειγματοληψίας (down-sampling)*, καθιστούν τους *πίνακες χαρακτηριστικών* πιο ανθεκτικούς στις τοπογραφικές αλλαγές των χαρακτηριστικών. Πιο αναλυτικά, εκτελείται μία δειγματοληψία στα εξαγόμενα χαρακτηριστικά του προηγούμενου επιπέδου, δημιουργώντας έναν καινούριο πίνακα χαρακτηριστικών, πιο συμπτυκνωμένο αλλά και ταυτόχρονα πιο γενικό. Κατά την εκπαίδευση του, το δίκτυο μαθαίνει να συσχετίζει συγκεκριμένα χαρακτηριστικά σε συγκεκριμένες τοποθεσίες του διανύσματος εισόδου. Αυτό μπορεί να είναι ιδιαίτερος χρήσιμο, εάν σε ένα διάνυσμα εισόδου, μας ενδιαφέρει να βρούμε εάν υπάρχει ένα συγκεκριμένο χαρακτηριστικό και όχι το πού ακριβώς βρίσκεται ή αν έχει διαφορετικό προσανατολισμό. Για παράδειγμα, μας ενδιαφέρει να αναγνωρίσουμε εάν σε μία εικόνα υπάρχει ένας σκύλος ή μία γάτα, αλλά μας είναι αδιάφορο σε ποιο σημείο της εικόνας βρίσκονται.

Δύο εκ των πιο διαδεδομένων διαδικασιών *ομαδοποίησης*, είναι οι *max pooling* και *average pooling*.

3.5.1 Max Pooling.

Ίσως η επικρατέστερη αυτή την στιγμή διαδικασία *ομαδοποίησης* στο χώρο των *συνελκτικών δικτύων*. Ένα φίλτρο διαστάσεων $m \times n$ εφαρμόζεται στον *πίνακα χαρακτηριστικών*. Η έξοδος του φίλτρου είναι η *μέγιστη τιμή* των τιμών εισόδου που εμπεριέχονται στον πίνακα αυτό, ενώ οι υπόλοιπες τιμές απορρίπτονται. Για να γίνει πιο κατανοητό, στη [Εικόνα 3-11](#) φαίνεται παραστατικά η εφαρμογή του *max pooling*.

Εφαρμόζοντας ένα φίλτρο 2×2 στην πορτοκαλί περιοχή του πίνακα εισόδου, προκύπτουν οι τιμές $\begin{bmatrix} 8 & 3 \\ 4 & 7 \end{bmatrix}$, εκ των οποίων επιλέγεται η *μεγαλύτερη* που είναι το 8 και οι υπόλοιπες τιμές απορρίπτονται. Με την εφαρμογή μιας *μετατόπισης (stride)* 2, προκύπτει ο αμέσως επόμενος πίνακας τιμών $\begin{bmatrix} 5 & 9 \\ 2 & 4 \end{bmatrix}$, όπου εδώ η μεγαλύτερη τιμή είναι το 9 και ομοίως, οι υπόλοιπες απορρίπτονται. Η διαδικασία συνεχίζεται σε όλο τον πίνακα των τιμών εισόδου.



Εικόνα 3-11 – Εφαρμογή Max Pooling

Γίνεται αντιληπτό πως η εφαρμογή **Max Pooling** οδηγεί σε ένα πίνακα εξόδου μικρότερο από αυτόν της εισόδου κατά ένα ποσοστό ανάλογο του εφαρμοζόμενου φίλτρου. Παραδείγματος χάριν, για ένα φίλτρο 2x2 και stride 2 ο πίνακας εξόδου θα είναι ο μισός αυτού της εισόδου. Η εφαρμογή **Max Pooling** ενδέχεται να οδηγήσει σε ανεπιθύμητά αποτελέσματα και απώλεια σημαντικής πληροφορίας, όταν οι τιμές του **πίνακα χαρακτηριστικών** στον οποίο εφαρμόζεται, δεν έχουν διακριτή διαφορά, αλλά όλες έχουν παρόμοια τιμή. Ένα χαρακτηριστικό παράδειγμα φαίνεται στην [Εικόνα 3-13](#)

Η συνάρτηση του Max Pooling δίδεται από τον τύπο $f_{max}(X) = \max x_i x_j$

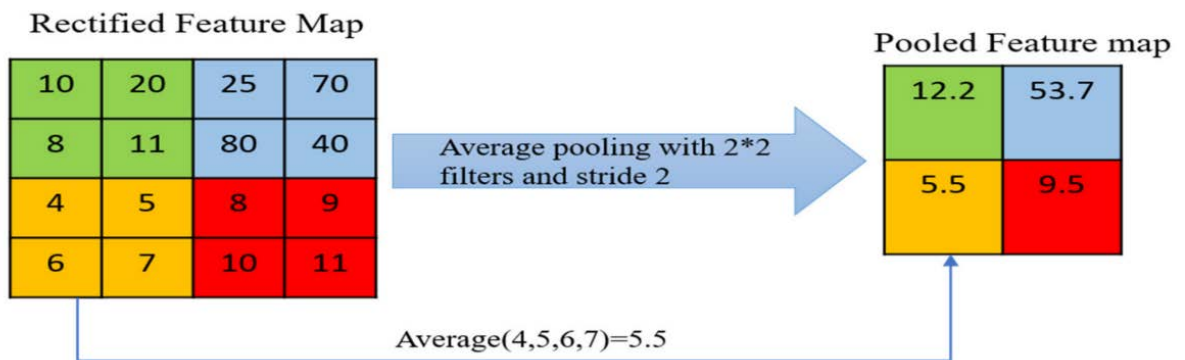
3.5.2 Global Average Pooling.

Είναι σχεδόν τόσο παλιά όσο και τα συνελκτικά δίκτυα. Εφαρμόστηκε αρχικά σε μία εφαρμογή αναγνώρισης φωνής το 1990 (*Yamaguchi et al*).

Εδώ, εφαρμόζοντας ένα φίλτρο διαστάσεων $m \times n$, ο πίνακας εισόδου διαιρείται σε υποπίνακες διαστάσεων $m \times n$, η έξοδος των οποίων είναι ο **μέσος όρος** των εμπεριχομένων τιμών. Μαθηματικά περιγράφεται από την εξίσωση

$$f_{ave}(X) = \frac{1}{N} \sum_i^N x_i x_j$$

Στην *Εικόνα 3-12*, για ευκολότερη κατανόηση, φαίνεται παραστατικά η εφαρμογή του *max pooling*. Η αποτελεσματικότητα του είναι σχετική και εξαρτάται από το εύρος των τιμών του κάθε χωρίου που εφαρμόζεται. Εάν για παράδειγμα, η συγκεκριμένη περιοχή του διανύσματος εισόδου περιέχει μία σημαντική πληροφορία και επομένως υψηλή τιμή, ενώ οι υπόλοιπες τιμές είναι χαμηλές, τότε και το αποτέλεσμα του υπολογισμού του μέσου όρου θα παραμείνει χαμηλό και τελικά η πληροφορία θα χαθεί. Αυτό θα γίνει ακόμα χειρότερο, εάν κάποιες εκ των τιμών του συγκεκριμένου χωρίου είναι 0 .




Εικόνα 3-12 Εφαρμογή Global Average Pooling [16]


Συνοψίζοντας, τα *επίπεδα ομαδοποίησης (pooling layers)* είναι μία απλή, αλλά παράλληλα πολύ σημαντική λειτουργία των *συνελκτικών νευρωνικών δικτύων*. Ουσιαστικά, συγκεντρώνουν τις βασικότερες από τις τιμές του διανύσματος εισόδου σε έναν νέο πίνακα που περιέχει μόνο τα βασικά, σημαντικά χαρακτηριστικά του. Εν αντιθέσει με τα *συνελκτικά επίπεδα*, δεν περιέχουν παραμέτρους (βάρη ή τιμές κατωφλίου), ενώ ίδια παραμένει η διάσταση του *φίλτρου kernel* και η *μετάθεσή stride* του *φίλτρου pooling* επί του διανύσματος εισόδου. Έτσι, οι βασικοί στόχοι που επιτυγχάνονται με την εφαρμογή ενός *επιπέδου ομαδοποίησης* είναι:

- η μείωση των απαιτούμενων παραμέτρων (weights και bias)
- η μείωση του απαιτούμενου χρόνου εκπαίδευσης
- και ίσως σημαντικότερο όλων, η αποτροπή του φαινομένου overfitting, που θα δούμε στην συνέχεια.

Στην *Εικόνα 3-13* φαίνεται παραστατικά η πιθανότητα απώλειας σημαντικής πληροφορίας από τον πίνακα χαρακτηριστικών, εφαρμόζοντας την υποδειγματοληψία *max* ή *avg pooling*.



(a) Illustration of max pooling drawback




(b) Illustration of average pooling drawback

Εικόνα 3-13 – Max – Avg Pooling Drawbacks [16]

3.6 Fully Connected ή Dense Layer

Αυτά είναι τα τελευταία επίπεδα πριν την έξοδο του δικτύου και είναι ο κοινός τύπος μεταξύ των υπόλοιπων νευρωνικών δικτύων και των συνελκτικών.

Στα τεχνητά νευρωνικά δίκτυα ονομάζονται *κρυφά επίπεδα* και βρίσκονται μεταξύ της *εισόδου* και της *εξόδου* του δικτύου. Στα *συνελκτικά νευρωνικά δίκτυα*, βρίσκονται μετά το τελευταίο *convolutional* ή *pooling layer* και ονομάζονται **fully connected** ή **dense layer**. Το όνομά τους προκύπτει από το γεγονός ότι κάθε νευρώνας είναι συνδεδεμένος με όλους τους νευρώνες του επόμενου επιπέδου. Ουσιαστικά είναι ένα κλασικό *νευρωνικό τεχνητό δίκτυο* που προστίθεται στο τέλος του *συνελκτικού δικτύου*. Είναι το μέρος εκείνο του δικτύου που παίρνει την *μονοδιάστατη έξοδο* του τελευταίου συνελκτικού σταδίου (*flattenend output*), υπολογίζει την πιθανότητα και κατηγοριοποιεί τα δεδομένα σε συγκεκριμένες, γνωστές *ετικέτες (labels)* από το σύνολο των δεδομένων εκπαίδευσης.




Εικόνα 3-14 -Fully Connected Layer [71]

Για πραγματοποιηθεί αυτό χρησιμοποιείται μία συνάρτηση ενεργοποίησης που ονομάζεται **softmax**, ο τύπος της οποίας είναι:

$$\text{softmax}(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}$$

Στην **Εικόνα 3-16** απεικονίζεται η γραφική παράσταση της συνάρτησης **softmax**

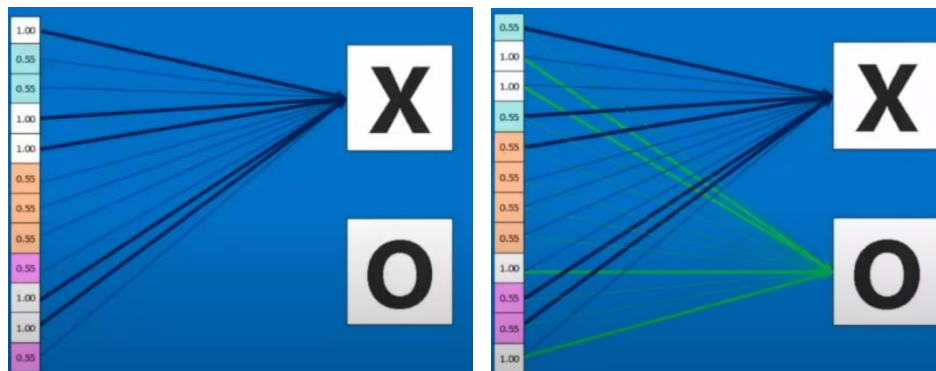


Εικόνα 3-15 – Γραφική παράσταση συνάρτησης ενεργοποίησης Softmax [47]

Ο αριθμός των πλήρως συνδεδεμένων επιπέδων εξαρτάται από το βάθος της ταξινόμησης που θέλουμε τελικά να επιτύχουμε. Για να γίνει κατανοητό πως ακριβώς λειτουργούν τα *fully connected* ή *dense layers*, παραθέτουμε ένα παράδειγμα από το site [freecodecamp.org](https://www.freecodecamp.org) και την παρουσίαση *How Deep Neural Networks Work - Full Course for Beginners* [74].

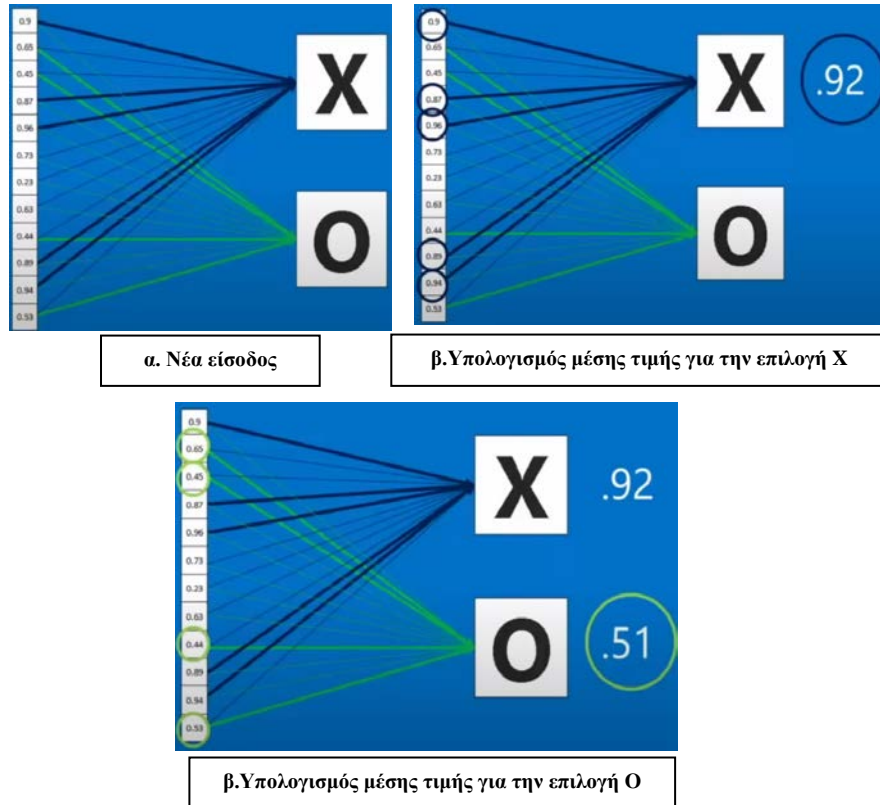
Έστω ότι ένα *συνελικτικό νευρωνικό δίκτυο (CNN)* έχει σχεδιασθεί να αναγνωρίζει εάν ένας χαρακτήρας είναι το **X** ή το **O**. Ύστερα από συνεχόμενα *επίπεδα συνέλιξης* και *ομαδοποίησης (convolutional και pooling layers)*, το δίκτυο έχει εκπαιδευτεί και έχει καταλήξει στα παρακάτω βάρη για την επιλογή των **X** και **O** (*Εικόνα 3-16*).

Παρατηρούμε ότι για κάθε ένα από τα δύο αποτελέσματα υπάρχουν διαφορετικές τιμές στο *μονοδιάστατο πίνακα (flattened)* εισόδου του *dense layer*, η αξία των οποίων είναι υψηλή, καθορίζοντας σαφώς εάν το σήμα εισόδου είναι **X** ή **O**. Όπως έχουμε προαναφέρει, οι τιμές αυτές προκύπτουν κατά τη διαδικασία της εκπαίδευσης του δικτύου με τα ήδη γνωστά δεδομένα εκπαίδευσης.



Εικόνα 3-16 – Weights for X and O classes [74]

Έστω τώρα ότι το δίκτυο λαμβάνει μία καινούρια είσοδο, που δεν γνωρίζει εάν είναι **X** ή **O**. Το δίκτυο με βάση τα υπολογισμένα βάρη για κάθε μία από τις συγκεκριμένες θέσεις (νευρώνες) θα υπολογίσει τη μέση τιμή των χαρακτηριστικών του σήματος εισόδου. Στο συγκεκριμένο παράδειγμα υπολογίστηκε ότι για **X** η τιμή είναι 0,92 και για **O**, 0,51, επομένως το δίκτυο θα κατηγοριοποιήσει τη νέα αυτή είσοδο ως **X** (*Εικόνα 3-17*)



Εικόνα 3-17 – New input classification at the dense layer [74]

3.7 Εκπαίδευση - Training

Ένα *συνελικτικό νευρωνικό δίκτυο* έχει παραμέτρους οι οποίες πρέπει να υπολογιστούν κατά τη διαδικασία της *εκπαίδευσης*, ώστε να είναι αποτελεσματικό και να μπορέσει να κατηγοριοποιήσει μία εικόνα ή μία χρονική σειρά δεδομένων (είσοδος) σε συγκεκριμένο είδος, ή ακόμα και να εκτελέσει ενέργειες *ανίχνευσης (detection)* και *παλινδρόμησης (regression)*. Οι παράμετροι που πρέπει να υπολογιστούν κατά την εκπαίδευση είναι τα *φίλτρα kernels*, τα *βάρη* και οι *τιμές κατωφλίου*. Απώτερος σκοπός της εκπαίδευσης δεν είναι άλλος από την *ελαχιστοποίηση της διαφοράς μεταξύ της εξόδου και της εισόδου του δικτύου*, εφαρμόζοντας αρχικά σήματα εισόδου των οποίων η έξοδος είναι γνωστή. Άρα, η εκπαίδευση ενός συνελικτικού νευρωνικού δικτύου, θα είναι η *εκπαίδευση με επίβλεψη*. Ο πιο συνηθής τρόπος εκπαίδευσης του εφαρμόζεται στα *συνελικτικά νευρωνικά δίκτυα*, είναι αυτός της *οπίσθιας διάδοσης*, με βασικούς πρωταγωνιστές

τη συνάρτηση απώλειας (**loss function**) και τη μέθοδο ταχύτερης καθόδου (**gradient descent**)

Με ένα δεδομένο *set φίλτρων kernels*, *βαρών* και *τιμών κατοφλίου*, το μοντέλο βρίσκει την έξοδο με βάση την είσοδο και στη συνέχεια υπολογίζει την τιμή του σφάλματος εξόδου. Κατά τη διάρκεια κάθε επανάληψης (*iteration*) του backpropagation, ο αλγόριθμος *ταχύτερης καθόδου*, υπολογίζει το μέγεθος της κλίσης (**gradient magnitude**) κάθε παραμέτρου του δικτύου (kernels, weights και bias). Στη συνέχεια, το δίκτυο αλλάζει τις τιμές των παραμέτρων αυτών και η διαδικασία επαναλαμβάνεται, έως ότου επιτευχθεί ένα συγκεκριμένο κριτήριο διακοπής της εκπαίδευσης.

Η παραπάνω διαδικασία ονομάζεται **optimization (βελτίωση)** και αναφέρεται στη *ελαχιστοποίηση* ή *μεγιστοποίησης κάποιας συνάρτησης $f(x)$* αλλάζοντας το x . Συνήθως, τα περισσότερα προβλήματα βελτιστοποίησης διατυπώνονται με όρους ελαχιστοποίησης του $f(x)$. [17]

3.7.1 Συνάρτηση Απώλειας - Loss Function

“The cost function reduces all the various good and bad aspects of a possibly complex system down to a single number, a scalar value, which allows candidate solutions to be ranked and compared” (Smithing.N (1999)-Supervised Learning in Feedforward Artificial Neural Networks)

Η *συνάρτηση απώλειας*, ή *συνάρτηση κόστους*, υπολογίζει μέσω της *οπίσθιας διάδοσης* τη συμβατότητα μεταξύ της προβλέψεων εξόδου του δικτύου και των αναμενόμενων τιμών, ετικετών του δεδομένου σετ εκπαίδευσης που έχει δοθεί στο μοντέλο του δικτύου.

Υπάρχουν πολλές συναρτήσεις που υπολογίζουν την παραπάνω διαφορά και η επιλογή τους εξαρτάται από την συγκεκριμένη εφαρμογή του *νευρωνικού δικτύου*. Οι δύο επικρατέστερες είναι:

- Η **διασταυρούμενη εντροπία (cross-entropy)** μέσω της εφαρμογής της **ταξινόμησης πολλαπλών κλάσεων (Maximum likelihood estimation MLE)** για εφαρμογές **ταξινόμησης (binary and multi-class classification)**

“One way to interpret maximum likelihood estimation is to view it as minimizing the dissimilarity between the empirical distribution defined by the training set and the model distribution, with the degree of dissimilarity between the two measured by the KL divergence.... Minimizing this KL divergence corresponds exactly to minimizing the crossentropy between the distributions.... Any loss consisting of a negative log-likelihood is a crossentropy between the empirical distribution defined by the training set and the probability distribution defined by model. For example, mean squared error is the cross-entropy between the empirical distribution and a Gaussian model”
[17]

Η σχέση που υπολογίζει τη **διασταυρούμενη εντροπία (cross-entropy)** ή **logarithmic loss** είναι:

$$H_p(\mathbf{q}) = -\frac{1}{N} \sum_{i=1}^N y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i))$$

Κάθε προβλεπόμενη πιθανότητα συγκρίνεται με την πραγματική αναμενόμενη τιμή (0 ή 1). Στη συνέχεια υπολογίζεται μια βαθμολογία που “τιμωρεί” την πιθανότητα με βάση την απόσταση από την αναμενόμενη τιμή. Η ποινή είναι λογαριθμική, προσφέροντας μικρό σκορ για μικρές διαφορές (0,1 ή 0,2) και μεγάλο σκορ για μεγάλη διαφορά (0,9 ή 1,0). Επομένως, μικρές τιμές **cross-entropy** αντιπροσωπεύουν καλύτερο μοντέλο από τις μεγαλύτερες τιμές. Ένα μοντέλο που προβλέπει τέλειες πιθανότητες (100%) έχει διασταυρούμενη εντροπία **cross-entropy** ή **logarithmic loss** 0,0.

- **Μέσο τετράγωνο σφάλμα (Mean Squared Error MSE)** για εφαρμογές **παλινδρόμησης (regression)**. Το μέσο τετράγωνο σφάλμα δίδεται από την σχέση:

$$f_{cost} = \frac{1}{N} \sum_{i=0}^N |f(W, x_i) - \widehat{y}_i|^2$$

Όπως προκύπτει από την παραπάνω συνάρτηση, η τιμή είναι πάντα θετική και αποτελείται από τη μέση τιμή των τετραγωνισμένων διαφορών μεταξύ των προβλέψεων του μοντέλου και των δεδομένων που προσπαθούμε να προσεγγίσουμε. Το τετράγωνο της διαφοράς βοηθάει, ώστε να αποφεύγονται οι παράμετροι που προκαλούν μεγάλες διαφορές στις προβλέψεις του μοντέλου.

3.7.2 Μέθοδος Ταχύτερης Καθόδου - Gradient Descent

Στα μαθηματικά ως *αλγόριθμος βελτιστοποίησης* αναφέρεται η διαδικασία της *ελαχιστοποίησης* ή *μεγιστοποίησης* μιας συνάρτησης $f(x)$ ως προς το x . Η $f(x)$, ονομάζεται *αντικειμενική συνάρτηση* (*objective function*). Η τιμή που ελαχιστοποιεί ή μεγιστοποιεί τη συνάρτηση, πολλές φορές υποδηλώνεται με έναν *αστερίσκο* (*), για παράδειγμα $x^* = \operatorname{argmin} f(x)$ [17]


Αντίστοιχα, στο χώρο της *τεχνητής νοημοσύνης*, ενώ με την *συνάρτηση απώλειας* (*loss function*) υπολογίζουμε τη διαφορά του πραγματικού από το επιθυμητό αποτέλεσμα, ο μηχανισμός που συνήθως χρησιμοποιείται, ως *αλγόριθμος βελτιστοποίησης* (*optimization algorithm*), για την ενημέρωση των παραμέτρων του δικτύου (kernels, weights, biases), είναι η μέθοδος της *ταχύτερης καθόδου* (*gradient descent*). Χρησιμοποιείται για να βρεθούν τα τοπικά ελάχιστα, ή μέγιστα μίας συνάρτησης, και την κατεύθυνση στην οποία η συνάρτηση αυτή έχει τον πιο απότομο ρυθμό αύξησης. Έτσι οι παράμετροι του δικτύου κατά την διαδικασία της εκπαίδευσης, ενημερώνονται προς την αντίθετη κατεύθυνση της κλίσης με ένα αυθαίρετο μέγεθος βήματος που καθορίζεται με βάση μια άλλη σταθερή παράμετρο που ονομάζεται *ρυθμός εκπαίδευσης* (*learning rate*). Η παραπάνω διαδικασία φαίνεται σχηματικά στην *Εικόνα 3-18*. Ο όρος *gradient*, μαθηματικά, είναι η *μερική παράγωγος* (*partial derivative*) της *απώλειας* (*loss*), σε σχέση με την προς ενημέρωση παράμετρο του συστήματος και περιγράφεται από την παρακάτω εξίσωση. [38]

$$w := w - a * \frac{\partial L}{\partial w}$$

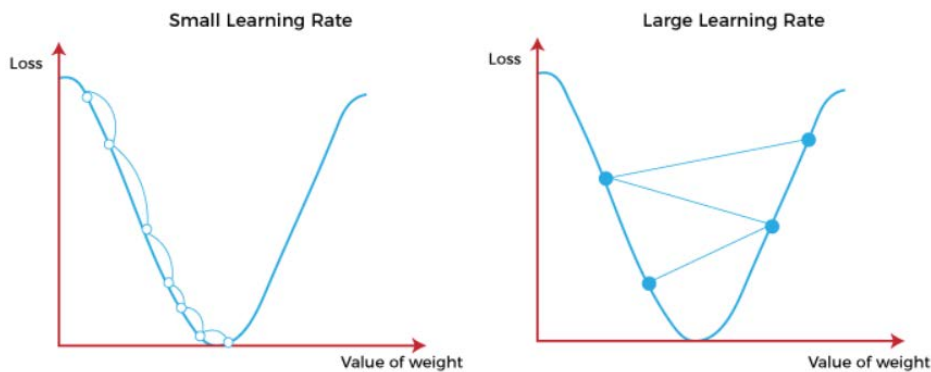
Όπου, w , είναι η παράμετρος προς εκμάθηση (**kernels, weights, biases**)

a , ο **ρυθμός εκπαίδευσης**. Είναι μία εκ των βασικότερων παραμέτρων που καθορίζονται πριν την έναρξη της εκπαίδευσης και καθορίζει το βήμα μεταβολής στις τιμές εκπαίδευσης. Συνήθως είναι μία μικρή τιμή και αναπροσαρμόζεται με βάση το αποτέλεσμα της συνάρτησης απώλειας (loss function). Επιλογή πολύ μεγάλου βαθμού εκπαίδευσης μπορεί να προκαλέσει overshooting και το δίκτυο να μην μπορεί να βρει τις ελάχιστες τιμές της συνάρτησης απώλειας. (**Εικόνα 3-19**)

L , η συνάρτηση απώλειας (**loss function**)



Εικόνα 3-18 – Gradient descent optimization method [17]



Εικόνα 3-19 – Learning Rate Values vs Loss function [72]

Λόγω περιορισμού δυνατοτήτων του υπολογιστικού συστήματος, είναι δυνατό η εφαρμογή των παραπάνω διεργασιών να εφαρμοστεί όχι σε όλο το πλήθος των *δεδομένων εκμάθησης (training dataset)*, αλλά σε ένα υποσύνολο αυτών που ονομάζεται **minibatch**. Η διαδικασία ονομάζεται **minibatch gradient descent** ή **stochastic gradient descent**. Το μέγεθος του υποσυνόλου των δεδομένων εκμάθησης (**minibatch**), αποτελεί άλλη μία παράμετρο του συστήματος.


Άλλες εκδοχές της μεθόδου gradient descent που έχουν αναπτυχθεί και χρησιμοποιούνται στα νευρωνικά δίκτυα και ιδιαίτερα στα συνελκτικά, είναι **SGD with momentum, AdaGrad, Adadelts, Adam**, η ανάλυση των οποίων είναι πέραν του ενδιαφέροντος της παρούσας εργασίας.

3.7.3 Dropout Function

Ένα από τα μεγαλύτερα προβλήματα που γενικότερα εμφανίζονται στα δίκτυα *βαθιάς μάθησης* και επομένως και τα *συνελκτικά νευρωνικά δίκτυα*, είναι όταν το μοντέλο κατά τη διαδικασία της εκπαίδευσης “ταιριάζει” απόλυτα τα δεδομένα εκπαίδευσης. Η κατάσταση αυτή του δικτύου ονομάζεται **overfitting** και έχει ως αποτέλεσμα το μοντέλο να μην μπορεί να κατηγοριοποιήσει με ακρίβεια νέα δεδομένα, τα οποία δεν αποτελούν μέρος της εκπαίδευσης του. Το φαινόμενο αυτό γίνεται ακόμα πιο έντονο όσο μεγαλύτερο και πολυπλοκότερο γίνεται το δίκτυο με περισσότερα *επίπεδα συνέλιξης* και μεγαλύτερο αριθμό *φίλτρων kernels*. Επίσης, ένας από τους βασικότερους παράγοντες που οδηγούν το δίκτυο σε **overfitting** είναι όταν το σετ δεδομένων εκπαίδευσης είναι πολύ μικρό. [6]

Για την αποφυγή αυτού του δυσάρεστου φαινομένου εφαρμόζονται διάφορες μέθοδοι, όπως η εκπαίδευση του δικτύου με μεγαλύτερο σετ δεδομένων, η εικονική αύξηση δεδομένων (data augmentation), η σωστότερη επιλογή των πινάκων χαρακτηριστικών, η μέθοδος των τεχνικών συνόλου (ensemble techniques), αλλά και η *κανονικοποίηση του δικτύου* γνωστή και ως **regularization**. Σκοπός της διαδικασίας αυτής (**regularization**) είναι η απλοποίηση του δικτύου, μειώνοντας τον αριθμό των *εξαγόμενων χαρακτηριστικών (number of features)* με έναν αυτόματο τρόπο. [49]

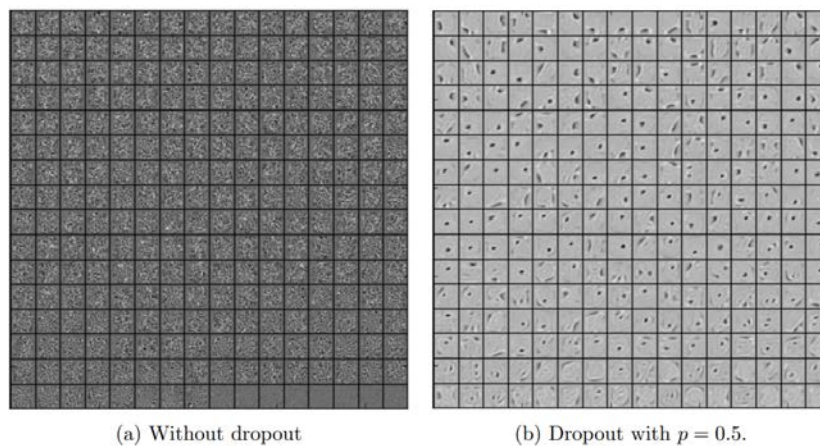
Βασικότερος εκπρόσωπος της **κανονικοποίησης** είναι η διαδικασία του **dropout function**. Το **dropout function** είναι μία πολύ απλή αλλά ταυτόχρονα πολύ αποτελεσματική διαδικασία. Κατά την διαδικασία της εκπαίδευσης, το δίκτυο επιλέγει **τυχαία** μέσω μίας **πιθανότητας p** και απενεργοποιεί μέρος των συνδέσεων μεταξύ των νευρώνων, έτσι ώστε να μην συνεισφέρουν ή μάθουν καμία πληροφορία, ωθώντας του υπόλοιπους νευρώνες (**$1-p$**) να μειώσουν το σφάλμα του overfitting (**Εικόνα 3-20**). Για να γίνει πιο κατανοητό, έστω το διάνυσμα εισόδου με τιμές **$x:\{1,3,5,8,10\}$** σε ένα επίπεδο συνέλιξης. Θέτοντας ως **dropout function probability $p=0.2$** , κατά τη διαδικασία της εκπαίδευσης το 20% των νευρώνων δεν θα συνδεθούν με τα επόμενα layers. Για παράδειγμα ότι το διάνυσμα εισόδου θα γίνει **$x':\{1,0,5,8,10\}$** ή **$x'':\{1,3,5,8,0\}$** κ.ο.κ . Σε κάθε νέα επανάληψη της διαδικασίας εκπαίδευσης, νέοι νευρώνες απενεργοποιούνται. Αυτό που ουσιαστικά επιτυγχάνεται με τη διαδικασία του **dropout function** είναι να μειώσουμε ή ακόμα και εξαφανίσουμε την προσπάθεια των νευρώνων να διορθώσουν το σφάλμα της **συνάρτησης απώλειας (loss function)** γειτονικών νευρώνων, το οποίο προκαλεί μία αλληλεξάρτηση των νευρώνων μεταξύ τους, με αποτέλεσμα το δίκτυο να μην μπορεί να γενικεύσει τα χαρακτηριστικά και τελικά να αποτυγχάνει να αναγνωρίσει και κατηγοριοποιήσει νέες, άγνωστες εισόδους.



Εικόνα 3-20 – Dropout Function [49]

Στην εικόνα **Εικόνα 3-21** απεικονίζεται τα χαρακτηριστικά που εξήχθησαν από ένα δίκτυο **autoencoder** με ένα μόνο κρυφό επίπεδο, για το set δεδομένων **MNIST** με και χωρίς την εφαρμογή του **dropout function** [49]. Είναι ξεκάθαρο πως, στην

εικόνα a τα χαρακτηριστικά δεν είναι διακριτά εν αντιθέσει με αυτά της *εικόνας b* που έχει εφαρμοσθεί *dropout function 0.5*

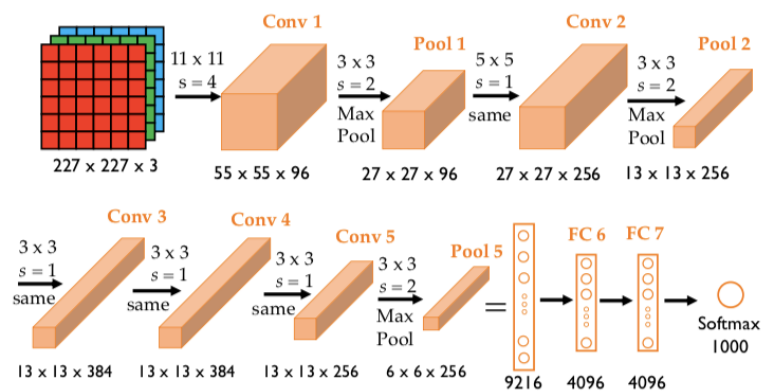


Εικόνα 3-21 - Features learned on MNIST with and without the dropout function [49]

3.8 Συμπέρασμα για τα συνελκτικά νευρωνικά δίκτυα

Τα συνελκτικά νευρωνικά δίκτυα έχουν καταφέρει τα τελευταία 50 χρόνια αξιοσημείωτα αποτελέσματα εν συγκρίσει με την ανάπτυξη των τεχνητών νευρωνικών δικτύων. Ήδη, πέραν των εφαρμογών αναγνώρισης εικόνων και φωνής, τα συνελκτικά νευρωνικά δίκτυα βρίσκουν πεδίο ανάπτυξης στο χώρο της ιατρικής, βιοτεχνολογίας, πρόβλεψη και ανάπτυξη μοντέλων καιρού, ταξινόμηση βλαβών και πρόβλεψη υπολειπόμενου χρόνου ζωής μηχανημάτων. Ένα εκ των σημαντικότερων πλεονεκτημάτων των συνελκτικών νευρωνικών δικτύων είναι ότι με κατάλληλη εφαρμογή και εκπαίδευση, μπορούν να προσαρμοστούν σε συγκεκριμένο τύπο σημάτων εισόδου. Για παράδειγμα, στην αναγνώριση εικόνων, ένα συνελκτικό νευρωνικό δίκτυο δεν χρειάζεται να εκπαιδευτεί ώστε να αναγνωρίζει όλη την εικόνα, αρκεί να αναγνωρίσει τα κυριότερα χαρακτηριστικά σημεία της και κατόπιν να εκτελέσει με ευκολία και αποτελεσματικότητα διεργασίες ταξινόμησης. Αυτό έχει σαν αποτέλεσμα τη δημιουργία μιας απλούστερης αρχιτεκτονικής δικτύου και επομένως ο υπολογισμός των παραμέτρων είναι ευκολότερος, ο χρόνος εκπαίδευσης του δικτύου μικρότερος και τελικά οι απαιτήσεις υπολογιστικής ισχύος σημαντικά μειωμένες.

Επίσης είναι αξιοσημείωτο πως γενικά μοντέλα δικτύων, όπως τα *Alexnet* (Εικόνα 3-22), *ResNet50*, *EfficientNet*, *NASNet* και άλλα, μπορούν να χρησιμοποιηθούν για εφαρμογές ταξινόμησης και πρόβλεψης, χωρίς επιπλέον εκπαίδευση και αλλαγές στην αρχιτεκτονική του δικτύου.



Εικόνα 3-22 – AlexNet Architecture [82]

4. Συντήρηση – Σύστημα Διαχείρισης της Συντήρησης

4.1 Εισαγωγή στη Συντήρηση

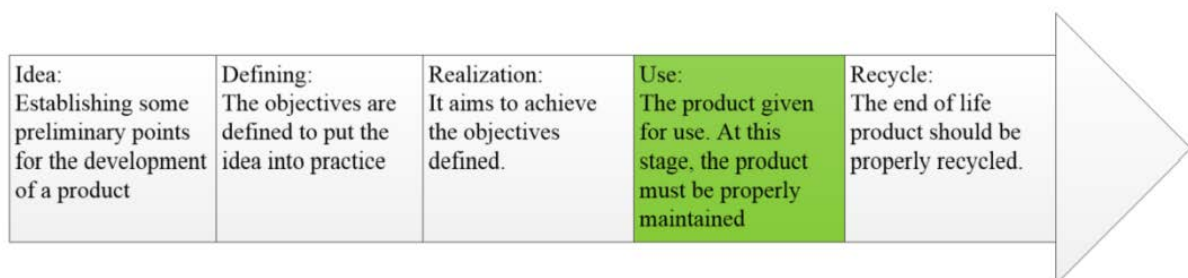
Η βιομηχανική επανάσταση από τα μέσα του 18^{ου} αιώνα έφερε ραγδαίες εξελίξεις στη βιομηχανία και καθόρισε σε έναν μεγάλο βαθμό τον τρόπο που διαμορφώθηκε η κοινωνία από τότε έως σήμερα. Η κοινωνία στις μέρες μας ακολουθεί έναν ολοένα και αυξανόμενο καταναλωτικό τρόπο ζωής. Αρκεί κάποιος να κοιτάξει γύρω του, να περιηγηθεί στο διαδίκτυο, να κάνει μία βόλτα στη αγορά και θα συνειδητοποιήσει την πληθώρα των καταναλωτικών αγαθών, αλλά και υπηρεσιών, τα οποία μάλιστα ανανεώνονται με υπερβολικά γρήγορους ρυθμούς. Αντίστοιχα, όλοι οι κλάδοι της κατασκευαστικής και εφοδιαστικής αλυσίδας, εκμεταλλευόμενοι τις νέες τεχνολογίες, ψάχνουν αδιάκοπα τρόπους, ώστε να μπορούν να ανταπεξέλθουν σε αυτή την συνεχώς αυξανόμενη ζήτηση παραγωγής, μεταφοράς και διάθεσης αγαθών και υπηρεσιών, λαμβάνοντας παράλληλα υπόψη την αυξανόμενη πολυπλοκότητα των τεχνικών συστημάτων. Γίνεται αντιληπτό πως για να είναι αποδοτική και κατά

συνέπεια παραγωγική μία κατασκευαστική αλυσίδα, θα πρέπει να λειτουργεί αποδοτικά με όσο το δυνατόν λιγότερες βλάβες και μειωμένους χρόνους ακινησίας των μηχανημάτων. Το ίδιο ισχύει και για τον τομέα των μεταφορών των αγαθών από την παραγωγή στους χώρους διανομής και κατανάλωσης και ιδιαίτερα τον χώρο της ναυτιλίας. Με βάση την τελευταία καταμέτρηση που διενεργήθηκε τον Νοέμβριο του 2022, περίπου 85000 εμπορικά πλοία ταξιδεύουν στους ωκεανούς για τη μεταφορά κάθε λογής αγαθών, καυσίμων αλλά και επιβατών. Αυτό εισάγει την έννοια της συντήρησης και στο χώρο των μεταφορών και ιδιαίτερα στη ναυτιλιακή βιομηχανία. Η συντήρηση που εκτελείται σωστά, ανεξάρτητα από τον τύπο της, έχει ως βασικό σκοπό την βελτίωση του εργασιακού περιβάλλοντος και την αύξηση της απόδοσης των μηχανημάτων.

4.2 Συντήρηση εισαγωγή και ορισμός

Ως ιδέα, η συντήρηση, ξεκινάει από τα πρώτα στάδια της σχεδίασης ενός προϊόντος και έχει ως απώτερο σκοπό την σωστή λειτουργία του καθ' όλη τη διάρκεια ζωής του. Όπως φαίνεται στην *Εικόνα 4-1*, η ζωή ενός προϊόντος περιλαμβάνει πέντε στάδια, *σύλληψη ιδέας, σχεδίαση, πραγματοποίηση, χρήση, ανακύκλωση*. Τα στάδια αυτά μπορούν να διαιρεθούν σε τρεις βασικές κατηγορίες [12]:

- *Αρχική φάση:* περιλαμβάνει την σύλληψη της ιδέας, την σχεδίαση και την πραγματοποίηση
- *Μεσαία φάση:* Χρήση
- *Τελική φάση:* Ανακύκλωση



Εικόνα 4-1 – The lifecycle of a product [12]



Από τα παραπάνω γίνεται αντιληπτό πως η μεσαία φάση, αυτή της χρήσης του προϊόντος, είναι και αυτή που πρέπει να διαρκέσει περισσότερο και επομένως το προϊόν θα πρέπει να διατηρηθεί σε κατάσταση τέτοια, ώστε η απόδοσή του να είναι η βέλτιστη καθ' όλη τη διάρκεια της ζωής του. Ως προϊόν ορίζεται οποιοδήποτε παραγόμενο αγαθό, αλλά και μηχανήμα, γραμμή παραγωγής, λογισμικό που σχετίζεται με την παραγωγική διαδικασία.

Η έννοια της συντήρησης ορίζεται από το Ευρωπαϊκό πρότυπο EN13306 ως εξής *“Ο συνδυασμός όλων των τεχνικών, διοικητικών και διαχειριστικών ενεργειών που εκτελούνται κατά τη διάρκεια του κύκλου ζωής ενός προϊόντος για την διατήρηση ή την αποκατάσταση των συνθηκών υπό τις οποίες μπορεί να εκτελεί την απαιτούμενη λειτουργία”* [13].

Γίνεται αντιληπτό πως μία σωστά οργανωμένη συντήρηση απαιτεί ένα ολοκληρωμένο σύστημα διαχείρισης της συντήρησης (**maintenance management plant**), το οποίο ορίζεται επίσης στο ίδιο πρότυπο (EN13306) ως εξής *“ Διαχείριση συντήρησης ορίζεται ως το σύνολο των δραστηριοτήτων διαχείρισης που καθορίζουν τους στόχους και τις στρατηγικές συντήρησης, τις ευθύνες και το πως αυτά θα εφαρμοστούν μέσω του σχεδιασμού, ελέγχου και βελτίωσης των ενεργειών συντήρησης”* [13].

Επομένως, για την βελτιστοποίηση της διάρκειας ζωής ενός προϊόντος, χρειάζεται ένα ολοκληρωμένο πλάνο συντήρησης του, το οποίο θα περιλαμβάνει:

- Την εποπτεία της λειτουργίας του καθ' όλη τη διάρκεια ζωής του
- Τις απαραίτητες ενέργειες για την επισκευή σε περίπτωση βλάβης
- Τη μελέτη του τρόπου συντήρησης
- Τη διαχείριση των απαραίτητων ανταλλακτικών
- Την οργάνωση και επίβλεψη των δραστηριοτήτων
- Τη διανομή ρόλων σε όλη τη φάση της εποπτείας και συντήρησης.



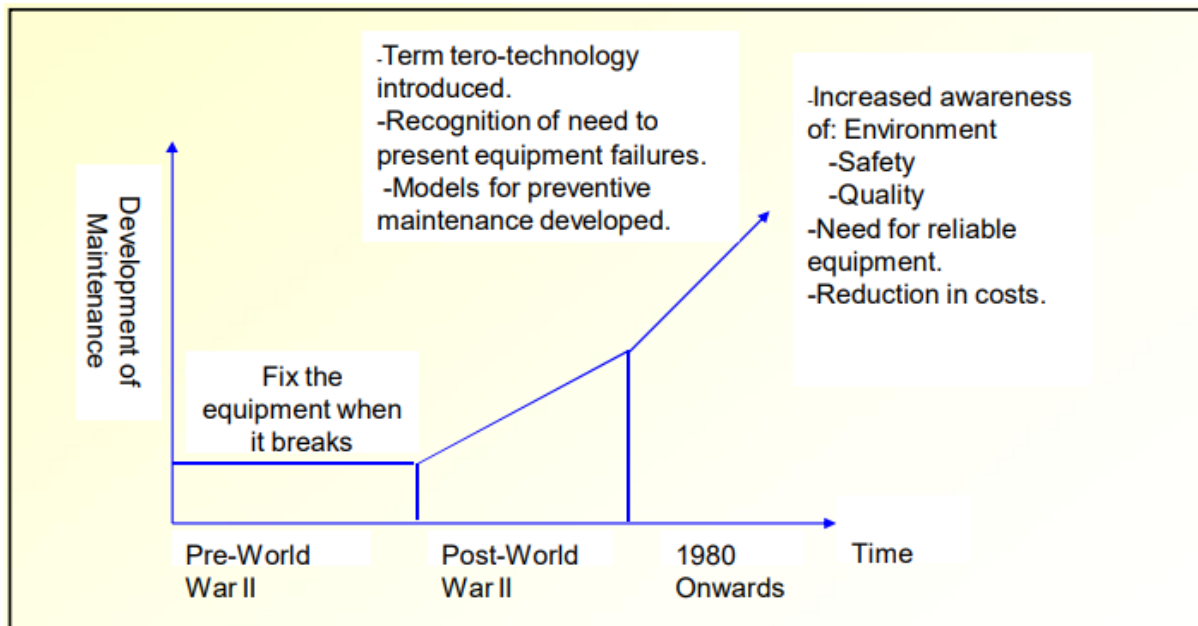
4.3 Συντήρηση - Σύντομή Ιστορική Αναδρομή

Πρώτος ο Νεύτωνας (1642-1727), όντας βαθιά θρησκευόμενος, όρισε πως ακολουθώντας το πρότυπο του δημιουργού της φύσης που την κατασκεύασε χωρίς να απαιτείται συντήρηση, έτσι και κάθε μηχανήμα/προϊόν που κατασκευάζεται δεν χρειάζεται κάποιο είδος συντήρησης [50]. Αυτό φυσικά αποδείχθηκε μη αληθές, καθώς δεν υπάρχει δημιούργημα της φύσης που με κάποιο τρόπο, στη διάρκεια της ζωής του δεν συντηρείται. Το ίδιο φυσικά ισχύει και για τα δημιουργήματα του ανθρώπου. Ο *Dr. Abed Schokry*, από το Πανεπιστήμιο της Παλαιστίνης, αναφέρει τρεις περιόδους συντήρησης, προ Δευτέρου Παγκοσμίου Πολέμου (pre-World War 2), κατά τη διάρκεια του πολέμου, και την περίοδο μετά τον Δεύτερο Παγκόσμιο Πόλεμο (post-World War 2) [44]

Μέχρι τον *2^ο Παγκόσμιο Πόλεμο (1939-1945)* η εξέλιξη της τεχνολογίας δεν παρουσίαζε αξιοσημείωτη πρόοδο. Τα μηχανήματα, όσα υπήρχαν, είχαν βασικό σχεδιασμό και απλοϊκή κατασκευή, ώστε να εκτελούν μία βασική διεργασία. Επομένως οι απαιτήσεις και η έννοια της συντήρησης ήταν σχεδόν ανύπαρκτες και τα μηχανήματα επισκευάζονταν μόνο όταν παρουσίαζαν κάποια βλάβη που τα καθιστούσε μη λειτουργικά.

Κάποια αλλαγή αρχίζει να διαφαίνεται στο τέλος του *1^ο Παγκοσμίου πολέμου (1914-1918)*, με σημαντικότερο σημείο αναφοράς την δημιουργία δύο μονάδων σχεδίασης και ανάπτυξης της αεροναυτιλίας στην Αμερική (U. S. Department of Transportation, 2012). Με την ανάπτυξη της αεροναυτιλίας η έννοια της ασφάλεια της ανθρώπινης ζωής γίνεται πιο έντονη και η συντήρηση αρχίζει να κάνει τα πρώτα της βήματα.

Κατά τη διάρκεια του *2^ο Παγκόσμιο Πόλεμο (1939-1945)*, η εξέλιξη της βιομηχανίας, σε όλους τους τομείς, ήταν ραγδαία. Οι εμπλεκόμενες στον πόλεμο χώρες προσπαθούσαν να βρουν το στρατηγικό πλεονέκτημα σε επίπεδο πολεμικού εξοπλισμού, που θα τους εξασφάλιζε τη νίκη. Παράλληλα το κόστος συντήρησης του πολέμου ήταν τεράστιο και έπρεπε να βρεθούν τρόποι βελτιστοποίησης της διάρκειας ζωής των παραγόμενων μηχανημάτων. Τότε έκανε την εμφάνισή της ή έννοια της συντήρησης του εξοπλισμού. Επιπλέον, μετά τον *2^ο Παγκόσμιο Πόλεμο* η παγκόσμια



Εικόνα 4-2 – Σύνοψη Ιστορία της Συντήρησης [44]

βιομηχανία και οικονομία ήταν καταρρακωμένες, ενώ έκδηλη ήταν και η μείωση του ανθρώπινου δυναμικού.

Παράλληλα, η αποκατάσταση των ζημιών που προκάλεσε ο πόλεμος στο πέρασμά του, αλλά και η αύξηση της ζήτησης των καταναλωτικών προϊόντων, ώθησε τις βιομηχανίες σε αύξηση της παραγωγής. Πλέον οι βλάβες των μηχανημάτων και η ακινητοποίηση της παραγωγής έχει μεγάλο και βαθμιαία, ραγδαίο οικονομικό αντίκτυπο. Η μηχανοποίηση και στη συνέχεια αυτοματοποίηση της παραγωγικής διαδικασίας ήταν μονόδρομος. Είναι το **1962**, όταν εισάγεται ο όρος **Reliability Centered Maintenance (RCM)** και το **1970** όταν η Ιαπωνία φέρνει στο προσκήνιο τον όρο **Total Productive Maintenance (TPM)** [50]

Στις μέρες μας, η φιλοσοφία της συντήρησης έχει ξεπεράσει κάθε προηγούμενο. Οι βιομηχανίες έχουν τμήματα που ασχολούνται μόνο με τη διαχείριση της συντήρησης. Βασικός στόχος είναι η μείωση του απρογραμμάτιστου χρόνου διακοπής λειτουργίας ενός μηχανήματος λόγω βλάβης, αλλά και η μείωση του προγραμματισμένου χρόνου διακοπής λειτουργίας για οποιαδήποτε συντήρηση ή βελτίωση. Παράλληλα, η βελτιστοποίηση της ασφάλειας, αλλά και το

περιβαντολογικό αποτύπωμα είναι βασικοί στόχοι, οι οποίοι προσμετρούνται στους δείκτες απόδοσης των παραγωγικών διαδικασιών (key performance indicator KPI). Βρισκόμαστε ήδη στην περίοδο της 4^{ης} βιομηχανικής επανάστασης, η οποία είναι σε πλήρη εξέλιξη.

4.4 Η Αναγκαιότητα της Συντήρησης – Οι Βασικοί Στόχοι

Η αναγκαιότητα της συντήρησης είναι άμεσα συνυφασμένη με την παραγωγή. Η σχέση των στόχων συντήρησης και παραγωγής αντικατοπτρίζονται στη διατήρηση του μηχανολογικού εξοπλισμού, αλλά και ολόκληρης της παραγωγικής διαδικασίας στην καλύτερη δυνατή κατάσταση, αποδίδοντας τα βέλτιστα των δυνατοτήτων τους, εξασφαλίζοντας παράλληλα την ασφάλεια του προσωπικού, του εξοπλισμού και της εγκατάστασης.

Ανάλογα με τον κλάδο, το κόστος συντήρησης ως ποσοστό του κόστους παραγωγής ενός προϊόντος, κυμαίνεται από 15 έως και 40% (*Dunn, 1987; Lofsten, 2000*). Το αντίστοιχο ποσοστό στο χώρο της ποντοπόρου ναυτιλίας κυμαίνεται από 10% και μπορεί να φτάσει έως 30% του συνολικού κόστους συντήρησης ενός πλοίου (OPEX) και εξαρτάται από τον τύπο του πλοίου, την ηλικία του, τον χώρο που δραστηριοποιείται, την διαθεσιμότητα των απαραίτητων ανταλλακτικών κ.α (*Ship Maintenance Cost: How can owners reduce it. www.seaplace.es 2022*), (*Moore Maritime Index 2021 - Shipping Trends Based On The Fleet Size*)

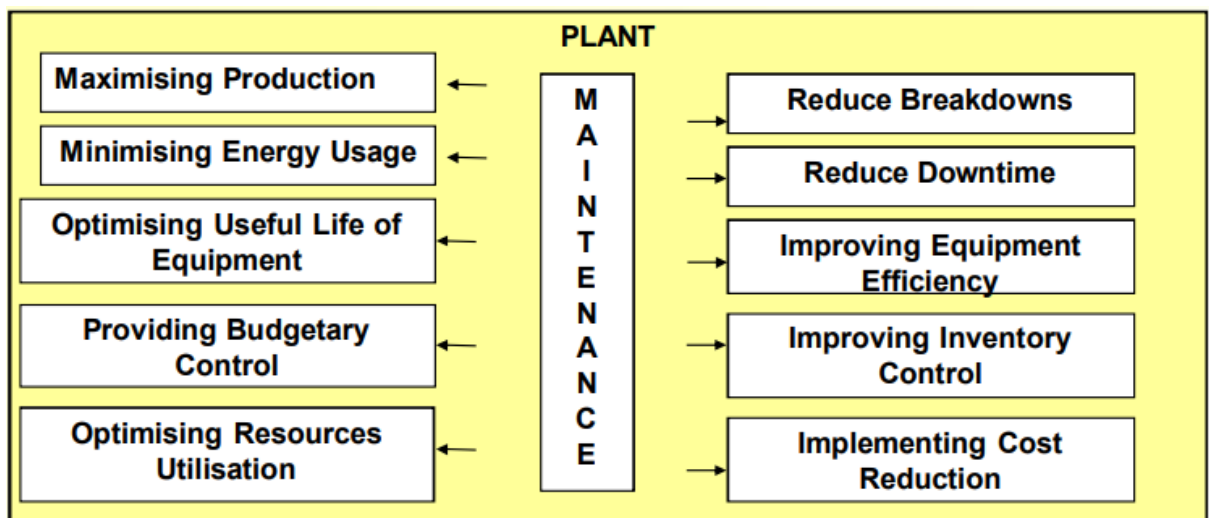
Από τα παραπάνω γίνεται αντιληπτό πως η κατάσταση λειτουργίας μίας παραγωγικής μονάδας παίζει έναν εκ των σημαντικότερων λόγων στην ευημερία της επιχείρησης. Αντίστοιχα, η σημασία της συντήρησης έχει γιγαντωθεί χάρη στο αντίκτυπο που έχει στη διατήρηση, αλλά και την βελτίωση της λειτουργίας και της απόδοσης του εξοπλισμού.

Επιγραμματικά οι στόχοι της συντήρησης πρέπει να περιλαμβάνουν τα παρακάτω:

- Μείωση των βλαβών και έκτακτων διακοπών λειτουργίας
- Μείωση του συνολικού χρόνου διακοπής λειτουργίας
- Βελτιστοποίηση παραγωγής
- Βελτιστοποίηση της χρήσης των πόρων

- Βελτιστοποίηση της διαχείρισης των ανταλλακτικών
- Αύξηση της απόδοσης των μηχανημάτων
- Μείωση της καταναλισκόμενης ενέργειας
- Βελτιστοποίηση της διάρκειας ζωής των μηχανημάτων
- Να παρέχει ένα αξιόπιστο κόστος λειτουργίας και έλεγχο του προϋπολογισμού

Τα παραπάνω συνοψίζονται στην *Εικόνα 4-3*

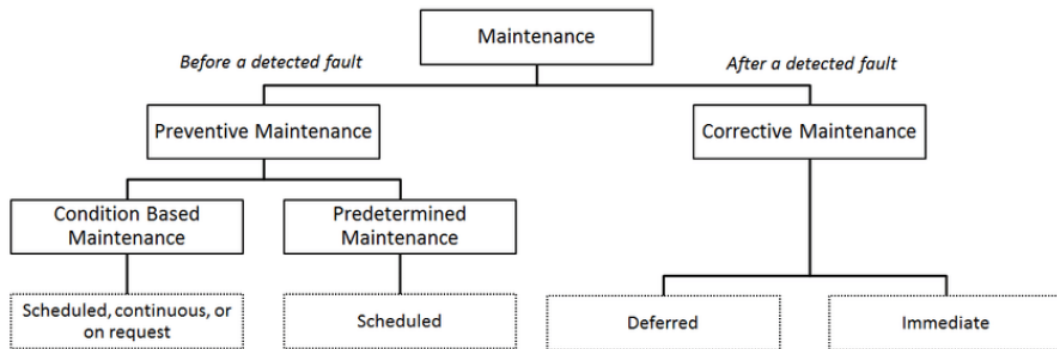


Εικόνα 4-3 – Maintenance Objectives [44]

4.5 Φιλοσοφίες Συντήρησης – προσεγγίσεις και στρατηγικές

Αν και ο απώτερος σκοπός της συντήρησης είναι ο ίδιος, η φιλοσοφία της εξαρτάται από την μορφή της βιομηχανίας ή γενικότερα του παραγωγικού χώρου που θα εφαρμοσθεί, αλλά και από τη νοοτροπία κάθε φορά των ενδιαφερομένων. Σε γενικές γραμμές και όπως αυτό καθορίζεται από το πρότυπο *EN 13306*, η συντήρηση χωρίζεται σε δύο μεγάλες κατηγορίες, την **προληπτική συντήρηση (preventive maintenance)** και την **διορθωτική συντήρηση (corrective maintenance)**. Κάθε μία από τις δύο αυτές βασικές κατηγορίες, υποδιαιρείται σε υποκατηγορίες που συνοπτικά θα παρουσιάσουμε παρακάτω, ενώ θα εστιάσουμε στην σημαντικότερη και ίσως βασικότερη στις μέρες μας, την **προγνωστική συντήρηση (predictive maintenance)** και πως αυτή έχει αναπτυχθεί και βελτιωθεί με τη χρήση της τεχνητής νοημοσύνης

και ιδιαίτερα των τεχνητών νευρωνικών δικτύων. Στην *Εικόνα 4-4* φαίνεται η περίληψη των παραπάνω.



Εικόνα 4-4 – Types of maintenance according to EN 13306 standard [13]

4.5.1 Διορθωτική Συντήρηση - Corrective Maintenance

Είναι η πρώτη μορφή συντήρησης που εφαρμόστηκε και παράλληλα η πιο απλοϊκή, αφού στηρίζεται στη λογική “λειτουργία μέχρι την αποτυχία”, ή στην διεθνή ορολογία *Run to Failure or Breakdown*. Όπως και η ονομασία παραπέμπει, η φιλοσοφία πίσω από την διορθωτική συντήρηση, είναι ότι το μηχάνημα λειτουργεί ασταμάτητα μέχρι την αποτυχία ή την εμφάνιση της βλάβης. Τότε, εφαρμόζεται η επισκευή, αντικαθιστώντας μόνο τα χαλασμένα εξαρτήματα, με σκοπό την επαναφορά του μηχανήματος ή της εγκατάστασης στην ελάχιστη δυνατή, αποδεκτή λειτουργική κατάσταση. Στο Βρετανικό Πρότυπο *3811:1993* ορίζεται ως “η συντήρηση που εκτελείται εφόσον έχει αναγνωρισθεί κάποια δυσλειτουργία και προορίζεται να θέσει τον εξοπλισμό σε κατάσταση στην οποία μπορεί να εκτελέσει μία απαιτούμενη λειτουργία”.

Χωρίζεται σε δύο υποκατηγορίες, **differed** και **immediate**. **Differed**, είναι οι ενέργειες που εφαρμόζονται όταν έχουν εντοπιστεί μη κρίσιμες βλάβες που δεν επηρεάζουν τη γενική λειτουργία και συνεπώς μπορούν να πραγματοποιηθούν και σε μεταγενέστερο χρόνο. **Immediate**, είναι οι ενέργειες που πρέπει να πραγματοποιηθούν άμεσα μόλις εντοπισθεί κάποιο λειτουργικό πρόβλημα ή κενό ασφαλείας ώστε να αποκατασταθεί η λειτουργία του μηχανήματος ή της γραμμής παραγωγής.

Η μέθοδος αυτή είναι εφαρμόσιμη, χωρίς δυσάρεστες συνέπειες, όταν το μηχανήμα που έχει παρουσιάσει βλάβη δεν επηρεάζει την παραγωγή, ή η ζήτηση υπερیشχύει κατά πολύ της παραγωγής ή το περιθώριο κέρδους είναι τόσο μεγάλο, που το κόστος επισκευής είναι αμελητέο.

4.5.2 Προληπτική Συντήρηση - Preventive Maintenance


Η προληπτική συντήρηση εμφανίστηκε παράλληλα με την 2^η βιομηχανική επανάσταση στα τέλη του 1800. Η εξέλιξη της βιομηχανίας αρχίζει να αναπτύσσεται και τα μηχανήματα γίνονται ολοένα πιο περίπλοκα και απαιτητικά. Οι βλάβες κοστίζουν σε χρόνο και χρήμα και οι πρώτες αναφορές στην προληπτική συντήρηση κάνουν την εμφάνισή τους. Είναι ο *Henry Ford* που στο πρώτο του εγχειρίδιο το 1919 προτείνει την προληπτική συντήρηση. *“Frequently inspect the running gear. See that no unnecessary play exists in either front or rear wheels and that all bolts and nuts are tight. Make a practice of taking care of every repair or adjustment as soon as its necessity is discovered. This attention requires but little time and may avoid delay or possible accident on the road.”* [57]. Με το πέρασμα των χρόνων, η προληπτική συντήρηση κερδίζει ολοένα και περισσότερο έδαφος, με κορύφωση τον Β΄ Παγκόσμιο Πόλεμο (1939-1945).

Το πρότυπο *EN 13360* ορίζει πως η προληπτική συντήρηση εκτελείται σε προκαθορισμένα χρονικά διαστήματα ή άλλες μονάδες μέτρησης της χρήσης, χωρίς πρότερη γνώση της κατάστασης του μηχανήματος, με μοναδικό σκοπό τη μείωση της αποτυχίας ή την υποβάθμιση της λειτουργικής κατάστασης ενός συστήματος, εξαρτήματος ή μηχανήματος [13].

Ένας από τους βασικούς στόχους της προληπτικής συντήρησης είναι να μειώσει το ποσοστό, αλλά και τη συχνότητα των βλαβών [40]. Στην πράξη, η προληπτική συντήρηση εφαρμόζεται είτε βασιζόμενη στην πρακτική εμπειρία είτε σε προκαθορισμένα χρονικά διαστήματα, βασισμένα σε ημερολογιακές ημέρες ή στις πραγματικές ώρες λειτουργίας του μηχανήματος και οι οποίες ορίζονται από τον κατασκευαστή. Η συντήρηση βασιζόμενη στην εμπειρία, δεν ακολουθεί συγκεκριμένα πρωτόκολλα επιθεώρησης. Το τεχνικό τμήμα, στηριζόμενο στην

εμπειρία του και στη γνώση από άλλες παλαιότερες βλάβες ή λάθη, αποφασίζει το χρόνο που το κάθε μηχάνημα πρέπει να επιθεωρηθεί και αν χρειαστεί να επισκευασθεί.

Η συντήρηση βασισμένη στο χρόνο, στηρίζεται σε κινδύνους ή διαγράμματα που απεικονίζουν τις *τάσεις αστοχίας*, γνωστά ως **bathtub curves** (Εικόνα 4-5)



Εικόνα 4-5 – Typical Bathtub Curve[40]

Ο **Ebeling** στο βιβλίο του **Reliability and maintainability engineering (1997)** [40], αναφέρει πως τα διαγράμματα των ποσοστών αποτυχίας ενός μηχανήματος ακολουθούν τρεις φάσεις: **burn in – useful life – wear out**. Στην αρχή της λειτουργίας του ένα μηχάνημα αντιμετωπίζει βλάβες οι οποίες βαίνουν μειούμενες (burn in). Ακολούθως, οι βλάβες σταθεροποιούνται σε ένα μικρό ποσοστό εμφάνισης (useful life) και όσο πλησιάζει προς το τέλος της ζωής του (wear out), ο ρυθμός εμφάνισης των βλαβών αυξάνεται ξανά [40].

Το βασικό πλεονέκτημα της **προληπτικής συντήρησης** είναι πως, με μικρές εξαιρέσεις, η συντήρηση, αντικατάσταση φθαρμένων εξαρτημάτων και η αξιολόγηση της κατάστασης ενός μηχανήματος, πραγματοποιείται πριν την εμφάνιση λειτουργικών προβλημάτων. Αυτό με τη σειρά του οδηγεί σε μείωση του συνολικού κόστους συντήρησης, πρώτον γιατί μειώνονται οι βλάβες και δεύτερον με τον σωστό προγραμματισμό, η συντήρηση πραγματοποιείται σε χρονικά διαστήματα που η διακοπή της λειτουργίας των μηχανημάτων θα έχει το μικρότερο δυνατό αντίκτυπο

στην παραγωγή. Επίσης γίνεται ευκολότερη η παρακολούθηση των ανταλλακτικών, και η παραγγελία τους στο σωστό χρόνο.

Από την άλλη, η *προληπτική συντήρηση* μπορεί να έχει και αρνητικές επιπτώσεις τόσο στην παραγωγική διαδικασία όσο και στην άσκοπη σπατάλη πόρων.

Πιο συγκεκριμένα:

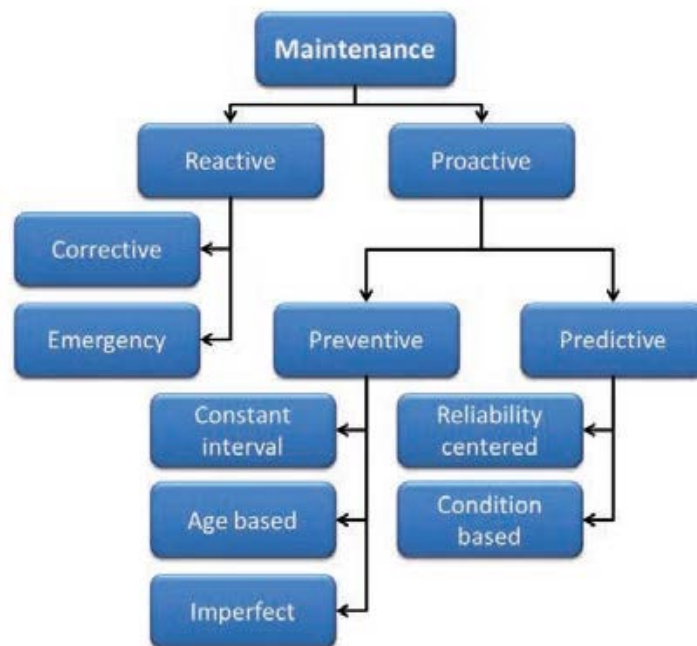
- Με την εφαρμογή συντήρησης με μόνο κριτήριο τον χρόνο, είναι δυνατόν οι εργασίες να εκτελούνται πολύ νωρίς ή πολύ αργά.
- Η αντικατάσταση εξαρτημάτων να πραγματοποιείται, ενώ ο υπολειπόμενος χρόνος ζωής τους είναι ακόμα αρκετός.
- Απαιτείται να υπάρχει μόνιμα επαρκές προσωπικό κατάλληλα εκπαιδευμένο για την εκτέλεση των συγκεκριμένων εργασιών συντήρησης.
- Υπάρχει η πιθανότητα να προκληθούν βλάβες σε εξοπλισμό, ο οποίος λειτουργούσε χωρίς πρόβλημα, διότι οι τεχνικοί που θα εκτελέσουν την προκαθορισμένη συντήρηση δεν θα έχουν την απαραίτητη τεχνογνωσία ή εμπειρία.
- Απαιτείται να υπάρχει τμήμα οργάνωσης και παρακολούθησης του προγράμματος προληπτικής συντήρησης, το οποίο θα είναι επιφορτισμένο με τα ακόλουθα:
 - Σωστό προγραμματισμό εργασιών
 - Σωστή εφαρμογή των εργασιών συντήρησης
 - Σωστή αξιολόγηση της σπουδαιότητας του κάθε μηχανήματος στην παραγωγική διαδικασία.
 - Παρακολούθηση και διαχείριση της αποθήκης ανταλλακτικών
 - Εκπαίδευση του τεχνικού προσωπικού\

4.5.3 Προγνωστική Συντήρηση - Predictive Maintenance

Με την πάροδο των χρόνων και προσπαθώντας οι ενδιαφερόμενοι να συγκεράσουν τα πλεονεκτήματα των αρχικών μεθόδων (corrective και proactive), νέες έννοιες εισήχθησαν στον καμβά της συντήρησης (*Εικόνα 4-6*).

Παρατηρούμε ότι η μεθοδολογία συντήρησης διακρίνεται πλέον σε **Αντιδραστική (Reactive)** και **Προληπτική (Proactive)**, με την πρώτη να μην παρουσιάζει διαφορές ως προς την αρχική της θεώρηση. Η **προληπτική** όμως **συντήρηση** χωρίζεται πλέον σε δύο υποκατηγορίες, τις **Preventive (PM)** και **Predictive maintenance (PDM)**. Και ενώ οι έννοιες **Proactive** και **Preventive** είναι συγγενικές, η **προγνωστική συντήρηση** είναι κάτι εντελώς νέο. Χωρίζεται σε **Reliability** και **Condition Based**.

Βάσει ορισμού [13], *“η προγνωστική συντήρηση εφαρμόζεται ακολουθώντας τα αποτελέσματα μίας πρόγνωσης που βασίζεται σε επαναλαμβανόμενη ανάλυση γνωστών χαρακτηριστικών και την αξιολόγηση σημαντικών παραμέτρων της υποβάθμισης του εξαρτήματος”*



Εικόνα 4-6 – Maintenance Philosophies [29]

Όταν αναφερόμαστε στην **προγνωστική συντήρηση**, εννοούμε την στρατηγική εκείνη όπου στηρίζεται στην παρατήρηση κάποιων, αν όχι όλων, εκ των μηχανικών παραμέτρων ή στοιχείων λειτουργίας του μηχανήματος. Οι παράμετροι αυτοί συγκρίνονται με τις προκαθορισμένες από τον κατασκευαστή καμπύλες

λειτουργίας και λαμβάνοντας υπ' όψη τις συνθήκες και το περιβάλλον εργασίας αξιολογείται η κατάσταση του μηχανήματος.

Το κύριο πλεονέκτημα αυτής της μεθόδου είναι ότι τις περισσότερες φορές, η παρακολούθηση γίνεται σε πραγματικό χρόνο ή σε τακτά χρονικά διαστήματα, παρέχοντας έτσι τη δυνατότητα η ανίχνευση της βλάβης να γίνεται σε πρωταρχικά στάδια, πριν ακόμα εξελιχθεί, καθιστώντας το μηχάνημα μη λειτουργικό. Επίσης η μέθοδος αυτή αυξάνει την ευκολία με την οποία ανιχνεύεται η θέση κάθε βλάβης. Ως αποτέλεσμα, παρέχεται η δυνατότητα να προγραμματισθεί, πότε είναι βολικό για την παραγωγή να σταματήσει το συγκεκριμένο μηχάνημα για να εκτελεσθούν οι εργασίες συντήρησης ή επισκευής. Παράλληλα η παρακολούθηση και οργάνωση της αποθήκης ανταλλακτικών είναι πιο εύκολη και εύελικτη. Ένα σωστά οργανωμένο πρόγραμμα **προγνωστικής συντήρησης**, μπορεί να σημαίνει εξοικονόμηση 8% έως 12% στον ετήσιο προϋπολογισμό μίας εταιρίας, ενώ, σύμφωνα με μελέτες του **Υπουργείου Ενέργειας της Αμερικής, (US Department of energy, 2010)** η προληπτική συντήρηση, ανάλογα με τις συνθήκες, τον εξοπλισμό και τα υλικά που χρησιμοποιούνται, μπορεί να επιφέρει εξοικονόμηση 30 ή ακόμα και 40%. Με βάση τον **David Ženíšek και την εργασία του Historical Overview of Maintenance Management Strategies (2019)[57]** η **προγνωστική συντήρηση** μπορεί να επιφέρει τα παρακάτω αποτελέσματα.

- Return on investment: 10 times
- Reduction of maintenance costs: 25% to 30%
- Troubleshooting: 70% to 75%
- Reduction of downtime: 35% to 45%
- Increased production: 20% to 25%

4.5.4 Προγνωστική Συντήρηση - Condition Based Maintenance

Πρώτος ένας διακεκριμένος βιολόγος, ο **C.H. Waddington το 1943**, υπηρετώντας την Αγγλική Πολεμική Αεροπορία λόγω του πολέμου, μελετώντας τα αρχεία συντήρησης των αεροσκαφών της RAF, κατέληξε στο συμπέρασμα πως μετά από κάθε προγραμματισμένη συντήρηση (PM) αυξάνονταν οι βλάβες στα αεροσκάφη.

Ο ίδιος και η ομάδα του πρότεινε ένα εξελιγμένο πρόγραμμα επισκευών, βασισμένο σε πραγματικά στοιχεία της λειτουργίας των κινητήρων των αεροσκαφών, αλλά και της κατάστασης του ίδιου του αεροσκάφους. [9],[34]

Χρειάστηκαν περίπου πέντε δεκαετίες ώστε η *προγνωστική συντήρηση* να εξελιχθεί και να αναπτυχθεί. Στις μέρες μας, με την έλευση της 4^{ης} *βιομηχανικής επανάστασης (Industry 4.0)*, αλλά και του *Industrial Internet of Things (IIoT)*, η *προγνωστική συντήρηση* έχει εξελιχθεί ραγδαία, οδηγώντας στην *συντήρηση με βάση την κατάσταση του μηχανήματος (Condition Based Maintenance)*. Σε αυτό βοήθησε η ανάπτυξη των τεχνολογιών και των υπηρεσιών, η κατασκευή νέων, πιο έξυπνων συστημάτων και αισθητήρων.

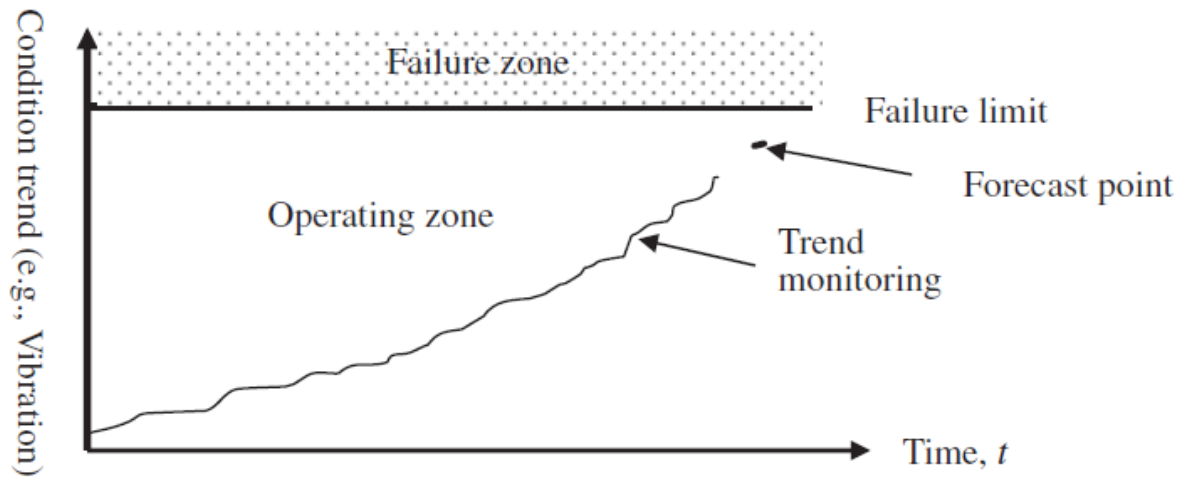
Η συντήρηση βασιζόμενη στην *πραγματική κατάσταση του μηχανήματος*, ακολουθεί μία επιστημονική προσέγγιση, η οποία περιλαμβάνει συγκεκριμένες διαδικασίες και αρχές που εμπλέκουν διάφορες τεχνικές ανάλυσης, όπως *στατιστική, μαθηματικά, προγραμματισμό, τεχνητή νοημοσύνη* κ.α [14]. Στην πράξη, η κατάσταση του μηχανήματος παρακολουθείται σε πραγματικό χρόνο ή σε προκαθορισμένα χρονικά διαστήματα, μετρώντας λειτουργικές παραμέτρους όπως τα *επίπεδα κραδασμών, θερμοκρασία λειτουργίας, ρεύμα λειτουργίας, επίπεδα θορύβου, ανάλυση ποιότητας ελαίου λίπανσης* κ.α. Επομένως, η πραγματική κατάσταση του εξοπλισμού μπορεί να αξιολογείται συνεχώς και σε πραγματικό χρόνο και άρα κάθε συντήρηση ή επισκευή να πραγματοποιείται μόνο όταν πραγματικά χρειάζεται. Οι *Bloch & Geitner*, στο βιβλίο τους *Machinery failure analysis and troubleshooting (1983)*, αναφέρουν ότι 99% πριν την εμφάνιση της αστοχίας ενός εξοπλισμού, συγκεκριμένα σημάδια, συνθήκες ή ενδείξεις κάνουν την εμφάνισή τους. Ένα άλλο πλεονέκτημα της *προγνωστική συντήρηση* είναι ότι μπορεί να εφαρμοσθεί όσο το μηχάνημα είναι σε λειτουργία και εφόσον στηρίζεται σε ανάλυση δεδομένων, είναι δυνατόν αυτά να αναλυθούν και σε κατάσταση ηρεμίας, όταν δηλαδή το μηχάνημα δεν λειτουργεί.

Η εφαρμογή της *προγνωστικής συντήρησης* μπορεί να διαιρεθεί σε δύο κατηγορίες, *διάγνωση (detection)*, κατά την οποία τα δεδομένα αναλύονται με απώτερο σκοπό την αναγνώριση της ύπαρξης κάποιας βλάβης ή πιθανά την



μελλοντική ύπαρξη σφάλματος και *πρόγνωση (predication)*, κατά την οποία τα δεδομένα αναλύονται με σκοπό την πρόβλεψη/εκτίμηση του πότε μπορεί να παρουσιασθεί μία βλάβη και άρα, να υπολογισθεί το **υπολειπόμενο ζωής** του μηχανήματος (**Useful Remaining Life - URL**). Επομένως, πρωταρχικός σκοπός της **διάγνωσης** πρέπει να είναι η ανίχνευση των προειδοποιητικών εκείνων σημείων που θα μπορούσαν να σηματοδοτήσουν μία πιθανά άρχουσα βλάβη. Αυτό βέβαια δεν σημαίνει πως το μηχάνημα θα πρέπει να ακινητοποιηθεί και να επισκευασθεί άμεσα, καθώς πρόκειται για ενδείξεις και πιθανότατα μπορεί ακόμα να χρησιμοποιηθεί για συγκεκριμένο χρονικό διάστημα. Το ποιο είναι αυτό το διάστημα, πριν η επισκευή του μηχανήματος κριθεί αναγκαία, έρχεται να το προβλέψει και να το υπολογίσει με τον καλύτερο δυνατό τρόπο η **πρόγνωση**. Γίνεται αντιληπτό πως η σωστή εφαρμογή της **προγνωστικής συντήρησης** μπορεί να μας παρέχει προειδοποίηση για μία πιθανή βλάβη, αλλά και εκτίμηση/πρόβλεψη του υπολειπόμενου διαθέσιμου χρόνου ζωής και ως εκ τούτου, ένα μηχάνημα είναι δυνατόν να λειτουργήσει πλήρως και οι απαραίτητες εργασίες συντήρησης να πραγματοποιηθούν λίγο πριν παρουσιασθεί η βλάβη.

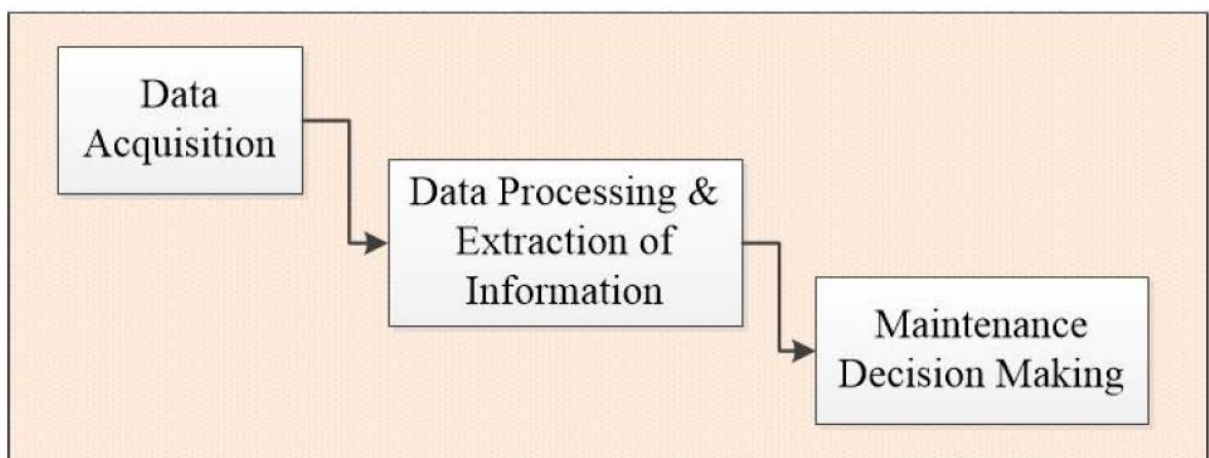
Στην *Εικόνα 4-7* συνοψίζονται όλα τα παραπάνω με την εφαρμογή της **προγνωστικής συντήρησης** σε ένα μηχάνημα. Διακρίνουμε την εξέλιξη της ανάλυσης των δεδομένων (στο παράδειγμα μέτρηση κραδασμών - vibration) καθώς και την μελλοντική πρόβλεψη του μοντέλου. Όσο η πρόβλεψη βρίσκεται στην ζώνη λειτουργίας το υπολειπόμενο διάρκειας ζωής (URL) υπολογίζεται και παρέχεται. Όσο το σημείο πρόβλεψης πλησιάζει το όριο βλάβης, το υπολειπόμενο διάρκειας ζωής URL μειώνεται και παράλληλα το μοντέλο παρέχει συγκεκριμένη διάγνωση της επερχόμενης βλάβης.



Εικόνα 4-7 - The Principle of Condition Based Maintenance[40]

Για την εφαρμογή της **προγνωστικής συντήρησης** βασισμένη στην **πραγματική κατάσταση** του μηχανήματος, απαιτούνται τρία στάδια ενεργειών σύμφωνα με τους **Davor Kolar et al (2020) [27]**

- Συλλογή δεδομένων – Data Acquisition
- Επεξεργασία των δεδομένων και εξαγωγή των απαραίτητων πληροφοριών - Data Processing & Extraction of Information
- Λήψη αποφάσεων για την συντήρηση που θα εφαρμοσθεί – Maintenance Decision Making



Εικόνα 4-8 – Condition Based Maintenance process [27]

Για το πρώτο σκέλος, αυτό δηλαδή της συλλογής δεδομένων, υπάρχουν πολλές μελέτες και εφαρμογές που αναλύουν εις βάθος, τόσο το θεωρητικό πλαίσιο της λήψης των σημάτων όσο και το πρακτικό, αυτό δηλαδή των αισθητήρων που χρησιμοποιούνται για τον σκοπό αυτό. Παράλληλα η βελτιστοποίηση των αισθητήρων μέτρησης είναι μία συνεχόμενη προσπάθεια από μέρους των κατασκευαστών.

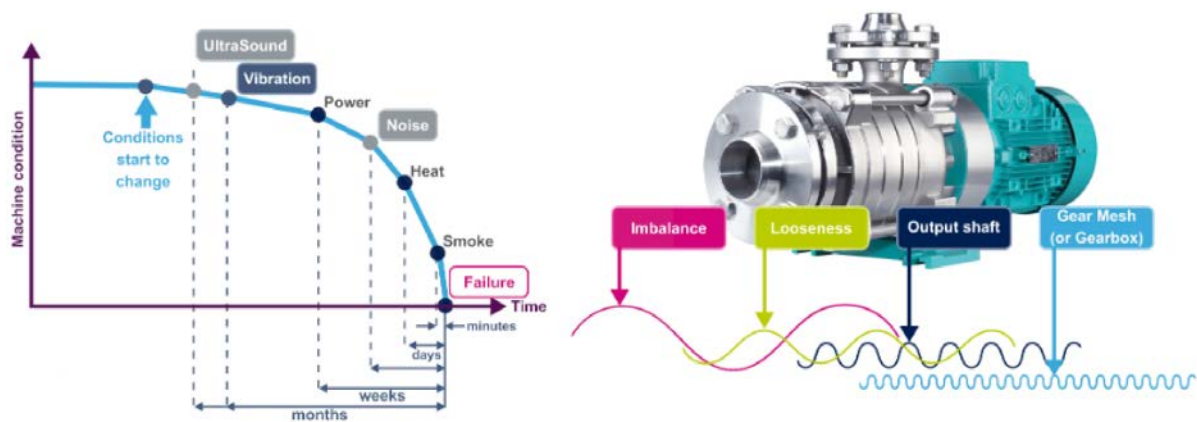
Τα επόμενα δύο στάδια, αυτά δηλαδή της ανάλυσης των δεδομένων και της λήψης αποφάσεων, βρίσκονται επί του παρόντος σε πλήρη ανάπτυξη και μελέτη. Πολλές έρευνες έχουν πραγματοποιηθεί και συνεχίζουν να πραγματοποιούνται καθημερινά, για την επεξεργασία και ανάλυση των δεδομένων, με τις περισσότερες να εστιάζουν στην παραδοσιακή μαθηματική ανάλυση και επεξεργασία. Τα τελευταία χρόνια με την ανάπτυξη της **τεχνητής νοημοσύνης**, οι ερευνητές έχουν στραφεί σε νέους τρόπους ανάλυσης των μετρήσεων σε μία συνεχόμενη προσπάθεια αυτοματοποίησης και βελτίωσης της διαδικασίας προληπτικής συντήρησης. Δύο είναι οι βασικότερες προσεγγίσεις αυτή την στιγμή που χαίρουν της προσοχής των επιστημόνων, τα **φυσικά μοντέλα (physical models)** και τα **ιστορικά δεδομένα (historical data)**.

Τα **φυσικά μοντέλα** στηρίζονται και απαιτούν την ύπαρξη ενός **δίδυμου συστήματος (digital twin)** με αυτό που πρόκειται να αναλύσουν, ικανό να προσομοιάζει την λειτουργία του πραγματικού συστήματος. Το πλεονέκτημα αυτού του τρόπου ανάλυσης είναι ότι η επεξεργασία των σημάτων και η εφαρμογή των προτεινόμενων επεμβάσεων πραγματοποιείται στο δίδυμο σύστημα και επομένως το πραγματικό συνεχίζει ανεπηρέαστο τη λειτουργία του. Το αρνητικό είναι ότι απαιτείται πολύς εξοπλισμός και συστήματα με μεγάλη υπολογιστική ισχύ.

Ο δεύτερος τρόπος προσέγγισης είναι αυτός της συλλογής και επεξεργασίας των **ιστορικών στοιχείων** και της ανάπτυξης των μοντέλων δεδομένων (data driven models). Κυριότερος εκπρόσωπος είναι τα μοντέλα της **μηχανικής μάθησης**, των **τεχνητών νευρωνικών δικτύων**, αλλά και της **βαθιάς μάθησης**. Στο [κεφάλαιο 6](#) θα αναλύσουμε πως η **βαθιά μάθηση** και πιο συγκεκριμένα τα **συνελκτικά νευρωνικά**

δίκτυα εφαρμόζονται στην *προγνωστική συντήρηση* μέσω της ανίχνευσης και κατηγοριοποίησης βλαβών.

Στην *Εικόνα 4-9* φαίνεται το διάγραμμα υποβάθμισης της λειτουργίας ενός κινητήρα και η σταδιακή εμφάνιση των αντίστοιχων σημάτων, όπως την περιγράφουν οι *Tomarchio, G et al* στο άρθρο τους "*Jumping into Industry 4.0 with Predictive Maintenance Solutions*" [51]



Εικόνα 4-9 Καμπύλη Υποβάθμιση Ηλεκτρικού κινητήρα [51]

4.5.4.1 Πρακτικές που εφαρμόζονται στην προγνωστική συντήρηση

- **Sound or acoustic monitoring.** Βασίζεται στη καταγραφή και ανάλυση σε πραγματικό χρόνο των ήχων που παράγει ένα μηχάνημα. Σε σύγκριση με την ανάλυση κραδασμών, στην ανάλυση ήχου και θορύβου, ειδικά μικρόφωνα είναι εγκατεστημένα σε διάφορα σημεία του μηχανήματος ώστε να "ακούν" τους ήχους που παράγει. Οι παραγόμενοι ήχοι είναι άμεσα συνδεδεμένοι με την πραγματική κατάσταση λειτουργίας. Φθορά στους σφαιροτριβείς, ή αρχικά στάδια φθοράς του ρότορα ενός κινητήρα, φαινόμενα ελλιπούς λίπανσης ή σπηλαιώσης σε υδραυλικές αντλίες έχουν άμεσο αντίκτυπο στις συχνότητες του ήχου που παράγει ένα μηχάνημα.
- **Oil-analysis or lubricant monitoring.** Μία άλλη, πολύ βασική εφαρμοζόμενη, πρακτική για την εφαρμογή της συντήρησης βασισμένη στην πραγματική



κατάσταση του μηχανήματος, είναι η περιοδική ανάλυση των λιπαντικών ελαίων. Δείγματα του λιπαντικού ελαίου αναλύονται εργαστηριακά για την ανίχνευση των συστατικών τους και την πρόσμιξη ξένων ουσιών. Το αποτέλεσμα των αναλύσεων παρέχει δύο σημαντικά δεδομένα:

- Την ικανότητα του ελαίου να συνεχίσει να παρέχει επαρκή λίπανση
- Την διάγνωση φθαρμένων μερών του μηχανήματος ανάλογα με τις ξένες προσμίξεις που θα βρεθούν στην ανάλυση του (contamination). Για παράδειγμα η εύρεση μεταλλικών ρινισμάτων μπορεί να σημαίνει φθορά σε μεταλλικά μέρη ή αυξημένες τριβές. Εύρεση νερού μπορεί να σημαίνει ελλιπή στεγανοποίηση σε κάποιο κύκλωμα ψύξης κ.α.

Το αρνητικό αυτής της εφαρμογής είναι ότι η ανάλυση του ελαίου δεν μπορεί να πραγματοποιηθεί σε πραγματικό χρόνο, αλλά χρειάζεται εργαστηριακή ανάλυση που συνεπάγεται αυξημένο κόστος αλλά και χρόνο επεξεργασίας.

- **Άλλες CM τεχνικές**, μπορεί να περιλαμβάνουν μετρήσεις σημαντικών παραμέτρων λειτουργίας, όπως η θερμοκρασία, το ηλεκτρικό ρεύμα, η αντίσταση τυλιγμάτων, αλλά και πιο εξειδικευμένες μετρήσεις, όπως η πίεση συμπίεσεως και πίεση καύσης σε μηχανές εσωτερικής καύσης, φασματογραφική ανάλυση της ροής υγρών, μέτρηση αγωγιμότητας σε μονάδες επεξεργασίας νερού, μέτρηση των ολικών οξειδωτικών (total residual oxidant) σε μονάδες επεξεργασίας θαλασσίου έρματος κ.α. Αλλαγή σε μία ή σε συνδυασμό των παραπάνω μετρήσεων μπορεί να υποδηλώνει δυσλειτουργία ή φθορά του σχετικού μηχανήματος.
- **Vibration monitoring**. Είναι, ίσως, η πιο διαδεδομένη μέθοδος για τα μηχανήματα με περιστρεφόμενα μέρη όπως ηλεκτρικοί κινητήρες, μειωτήρες, αντλίες, αλλά και μηχανές εσωτερικής καύσης. Στηρίζεται στην ανάλυση των παραγόμενων κραδασμών, είτε με εγκατάσταση μόνιμων αισθητήρων σε συγκεκριμένα σημεία του μηχανήματος, είτε με περιοδικές μετρήσεις που λαμβάνονται από φορητά όργανα. Το παραγόμενο αποτύπωμα των κραδασμών και η ανάλυσή τους στο πεδίο του χρόνου (time domain) ή των συχνοτήτων (frequency domain – spectrum analysis), παρέχει μία ακριβή εικόνα για την κατάσταση του υπό εξέταση μηχανήματος. Βλάβες όπως φθορά των εδράνων ή

των σφαιροτριβέων, εσφαλμένη ευθυγράμμιση (misalignment) , χαλαρή-λάθος στήριξη (looseness), φθορά στα πηνία και τα γρανάζια ενός μειωτή κίνησης, αλλά ακόμα και φθορά στον ρότορα και τον στάτη ενός κινητήρα, μπορούν να ανιχνευθούν σε αρχικά ακόμα στάδια. Οι εφαρμογές της τεχνητής νοημοσύνης και ιδιαίτερα του deep learning και των νευρωνικών δικτύων στον τομέα αυτό, έχουν κάνει αξιοθαύμαστη πρόοδο, παρέχοντας αξιόπιστα αποτελέσματα.

5. Κραδασμός – Vibration

5.1 Εισαγωγή στον κραδασμό.

Μέχρι τώρα είδαμε την σημαντικότητα της συντήρησης των μηχανημάτων με στρεφόμενα μέρη, καθώς και την αρνητική επίδραση που δυνητικά μπορεί να προκαλέσει η διακοπή της λειτουργίας τους λόγω βλάβης. Επίσης, αναλύσαμε τους διάφορους τύπους συντήρησης και εστίασαμε στην *προγνωστική συντήρηση* βασισμένη στην *πραγματική κατάσταση του μηχανήματος (Condition Based Maintenance)*. Για την ανάλυση της κατάστασης ενός μηχανήματος αναφέραμε πως μπορεί να πραγματοποιηθεί συλλέγοντας πληροφορίες και μελετώντας διάφορα σήματα. Από αυτά τις περισσότερες και ακριβέστερες πληροφορίες παρέχει η μελέτη των κραδασμών.

Κάθε μηχανήμα που περιστρέφεται παράγει *κραδασμούς* ως συνάρτηση της δυναμικής του μηχανήματος, όπως για παράδειγμα η ευθυγράμμιση και το balance των περιστρεφόμενων μερών, αλλά και συνάρτηση των εγγενών χαρακτηριστικών του. Το φάσμα των συχνοτήτων των κραδασμών ενός μηχανήματος, *απαρτίζεται* από πολλές συνιστώσες, εκ των οποίων κάποιες παράγονται από την λειτουργία του ίδιου του μηχανήματος και τα περιοδικά χαρακτηριστικά του (ταχύτητα περιστροφής, συχνότητα ηλεκτρικής παροχής, κ.α), ενώ άλλες προέρχονται από γειτονικά μηχανήματα και τον θόρυβο που αυτά παράγουν ή τον συντονισμό μεταξύ τους μέσω της βάσης έδρασης, ή άλλων εξαρτημάτων με τα οποία μπορεί να συνδέονται. Για παράδειγμα, η ύπαρξη στρεφόμενων μερών (σφαίρες ολίσθησης) μέσα στους σφαιροτριβείς, προκαλούν κραδασμούς, που είναι έμφυτοι στο σύστημα. Η θέση των στρεφόμενων μερών αλλάζει συνέχεια καθώς ο σφαιροτριβέας βρίσκεται σε

περιστροφή. Η παραγωγή των κραδασμών εξαρτάται άμεσα από το φορτίο που δέχεται ο σφαιροτριβέας, την ταχύτητα περιστροφής, τόσο του ίδιου όσο και των σφαιρών ολίσθησης, αλλά και από τις γεωμετρικές, κατασκευαστικές ατέλειες της εξωτερικής και εσωτερικής επιφάνειας του σφαιροτριβέα. Ένα άλλο παράδειγμα αποτελούν οι συνιστώσες συχνοτήτων που αποτυπώνονται στον άξονα περιστροφής μίας μηχανής εσωτερικής καύσης και οφείλονται στον αριθμό των καύσεων που πραγματοποιούνται ανά περιστροφή στους κυλίνδρους της μηχανής.

Στα μηχανήματα με περιστρεφόμενα μέρη, όπως ηλεκτρικοί κινητήρες, ανεμογεννήτριες, ατμοστρόβιλοι και αεριοστρόβιλοι, μηχανές εσωτερικής καύσης και μειωτήρες κίνησης, μπορούν να παρουσιασθούν βλάβες στα κουζινέτα έδρασης (bearings), στους σφαιροτριβείς (ball bearings), τα γρανάζια μετάδοσης κίνησης (gears), αλλά και στα μηχανικά μέρη των ηλεκτρικών κινητήρων, όπως ο ρότορας των επαγωγικών κινητήρων κλωβού.

Μέσω της ανάλυσης του φάσματος των κραδασμών είναι δυνατή η αναγνώριση συγκεκριμένων συχνοτήτων και μέσω αυτών των συχνοτήτων η ανίχνευση πιθανών βλαβών όπως, misalignment, imbalance, βλάβη σε γρανάζι μετάδοσης κίνησης, προβληματικός σφαιροτριβέας κ.α. Η ανίχνευση των πιθανών βλαβών πραγματοποιείται από μία συνδυασμένη ανάλυση του φάσματος των συχνοτήτων και του πλάτους της κάθε συχνότητας. Το πλάτος υποδηλώνει και την ένταση του κραδασμού, ενώ η συχνότητα τον ρυθμό ταλάντωσης.


Η ανάλυση των κραδασμών είναι μία αυτόνομη επιστήμη και απαιτεί πολύ καλή γνώση της φυσικής και των μαθηματικών. Επίσης, χρειάζεται ιδιαίτερη γνώση για το είδος των κραδασμών, τις πηγές που μπορεί να τους παράγουν, το πλάτος πάνω από το οποίο μπορούν να προκαλέσουν κάποια βλάβη, το αποτέλεσμα που μπορεί να προκαλέσουν, τα αδύναμα σημεία των μηχανημάτων στα οποία εμφανίζονται κ.α

Παρακάτω γίνεται μία περιγραφή της ανάλυσης των κραδασμών, καθώς και μία παρουσίαση των βλαβών που μπορεί να παρουσιάσουν τα μηχανήματα με στρεφόμενα μέρη και πως αυτές αποτυπώνονται στο φάσμα των συχνοτήτων. Καθώς το αντικείμενο της παρούσας εργασίας δεν είναι αυτό καθ' αυτό οι κραδασμοί, η

ανάλυση θα είναι περιγραφική, ενώ δεν θα προβούμε σε εις βάθος μαθηματική ανάλυση.

5.2 Η έννοια του κραδασμού

Παρακάτω παρατίθεται μία συνοπτική ανάλυση της έννοιας της ταλάντωσης, ώστε στη συνέχεια ο αναγνώστης να μπορεί να κατανοήσει κάποιες έννοιες και όρους. Στο *Εικόνα 5-1* φαίνεται ένα σύστημα που αποτελείται από ένα ελατήριο και μία μάζα στερεωμένη στη μία του άκρη. Πιο αναλυτικά, ένα ελατήριο με συντελεστή ακαμψίας (stiffness) k , είναι στερεωμένο στο ένα του άκρο σε άκαμπτη βάση. Στην άλλη άκρη του ελατηρίου είναι στερεωμένο σώμα μάζας M . Το σώμα αυτό από την άλλη του πλευρά είναι συνδεδεμένο με ένα έμβολο, το οποίο μπορεί και κινείται μέσα σε ένα δοχείο γεμάτο με λάδι που παίζει τον ρόλο του αποσβεστήρα (damping).



Εικόνα 5-1 – Mass – Spring system [43]

Εάν εφαρμοσθεί μία δύναμη F στην μάζα M , την οποία μετακινήσει προς την κατεύθυνση του βέλους, τότε, το ελατήριο θα τεντωθεί, ενώ το λάδι μέσα στο δοχείο θα συμπιεστεί από το έμβολο. Γίνεται κατανοητό, πως για να κινηθεί η μάζα M , η δύναμη F πρέπει να υπερνικήσει την αδράνεια της μάζας M , την ακαμψία του ελατηρίου k και την αντίσταση που το λάδι εφαρμόζει στο έμβολο.

Κάθε μηχανήμα έχει τρεις θεμελιώδεις ιδιότητες, ο συνδυασμός των οποίων καθορίζει την συμπεριφορά του σε μία ασκούμενη δύναμη F . Οι ιδιότητες αυτές είναι:

- **Μάζα (Mass):** Έχει άμεση επίδραση στην αδράνεια του συστήματος, στην ιδιότητά του δηλαδή, να αντιστέκεται σε κάθε μεταβολή της κινητικής του κατάστασης παραμένοντας στην αρχική θέση ισορροπίας του.

- **Ακαμψία (Stiffness):** Είναι το μέτρο της αντίστασης ενός σώματος στην παραμόρφωση που τείνει να επιβάλει η εφαρμογή μία εξωτερικής δύναμης. Μετριέται σε N/m
- **Απόσβεση (Damping):** Η αντίδραση ενός συστήματος στην μεταβολή της κινητικής του κατάστασης, προσπαθώντας να μειώσει την ταχύτητα της κίνησής του. Μετριέται σε N/(m/s)

Έστω για παράδειγμα, ότι ένα μηχανήμα ταλαντώνεται λόγω της επιβολής μίας εξωτερικής δύναμης. Η μάζα του μηχανήματος σε συνδυασμό με την ακαμψία του και την απόσβεση, θα προσπαθήσουν να αντισταθούν στην επιβαλλόμενη δύναμη. Όταν το μέτρο της δύναμης είναι μεγαλύτερο από το αλγεβρικό άθροισμα των τριών αυτών συνιστωσών, τότε το μηχανήμα θα μπει σε ταλάντωση το μετρό της οποίας θα είναι η διαφορά της εφαρμοζόμενης δύναμης με το άθροισμα των συνιστωσών. Θεωρητικά, αν η μάζα M αφήνονταν από τη θέση στην οποία έφθασε μετά την άσκηση της δύναμης F , θα επέστρεφε στην αρχική της θέση ισορροπίας και θα συνέχιζε συμπιέζοντας αυτή τη φορά το ελατήριο έως ότου η ακαμψία του σταματούσε την κίνηση. Η μάζα τότε θα κινούνταν ξανά προς την αντίθετη κατεύθυνση κ.ο.κ. Η κίνηση αυτή θα μπορούσε να συνεχιστεί, εάν δεν υπήρχαν οι τριβές και το σύστημα απόσβεσης του εμβόλου. Η περιοδική αυτή κίνηση ονομάζεται **κραδασμός (vibration)**

5.3 Βασικά χαρακτηριστικά κραδασμών

Τα βασικά χαρακτηριστικά που περιγράφουν έναν κραδασμό είναι τα ακόλουθα:

- **Κύκλος (cycle)**, Ονομάζεται η κίνηση από ένα σημείο ισορροπίας προς το ένα άκρο, την επιστροφή προς το σημείο ισορροπίας, την κίνηση προς το άλλο άκρο και τελικά την επιστροφή προς το σημείο ισορροπίας.
- **Συχνότητα (frequency)**, είναι ο αριθμός των επαναλήψεων (cycles) στην μονάδα του χρόνου. $f = \frac{\text{cycles}}{\text{second}}$ (**cps**) και μονάδα μέτρησης είναι το ένα **Hertz (Hz)**



- **Μετατόπιση (displacement)** ορίζεται ως η μέγιστη τιμή που θα λάβει η μετατόπιση (x) της μάζας M , από το σημείο ισορροπίας ($x=0$). Έχει μονάδα μέτρησης το **micron (1/1000mm)**. Είναι περιοδικό φαινόμενο και δίδεται από την σχέση:

$$\text{displacement} = X_0 \cdot \sin \omega t$$

- **Ταχύτητα (Velocity)** Είναι η ταχύτητα με την οποία κινείται η μάζα M από το ένα άκρο ως το άλλο, περνώντας από το σημείο ισορροπίας. Η ταχύτητα δεν είναι σταθερή, μειώνεται έως ότου μηδενισθεί στα δύο άκρα και έχει τη μέγιστη τιμή της στο σημείο ισορροπίας. Προκύπτει από την διαφορίση της μετατόπισης και έχει μονάδα μέτρησης το **mm/sec**. Είναι περιοδικό φαινόμενο και δίδεται από την σχέση:

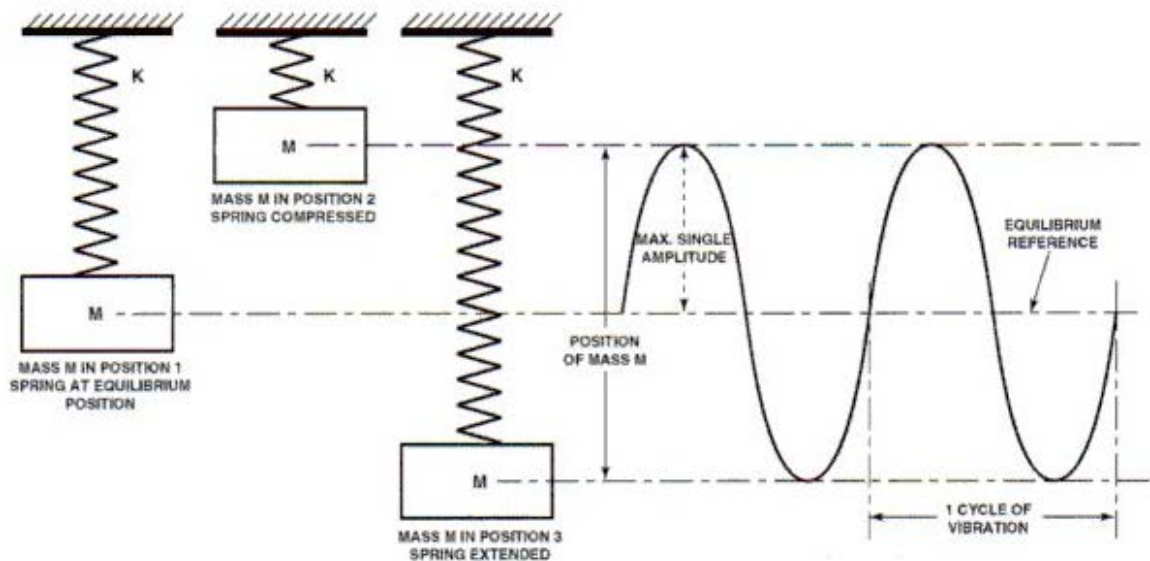
$$\text{velocity} = \frac{dx}{dt} = X_0 \cdot \omega \cdot \cos \omega t$$

Ο **Διεθνής Οργανισμό Προτύπων (ISO)** έχει ορίσει ότι η ταχύτητα ενός κραδασμού πρέπει να υπολογίζεται με βάση την μέση τιμή του τετραγώνου (**RMS**). Η rms τιμή της ταχύτητας δίνει την ενέργεια που έχει ένα σήμα κραδασμού, ενώ η απόλυτη τιμή πλάτους (peak), σχετίζεται με την ένταση της δόνησης. [43]

- **Επιτάχυνση (acceleration)**, παρόμοια με την ταχύτητα ορίζεται η επιτάχυνση, η οποία είναι ο ρυθμός με τον οποίο μεταβάλλεται η ταχύτητα του κραδασμού. Προκύπτει από την διαφορίση της ταχύτητας και έχει μονάδα μέτρησης το **g (9.80665 m/sec²)**. Δίδεται από την σχέση:

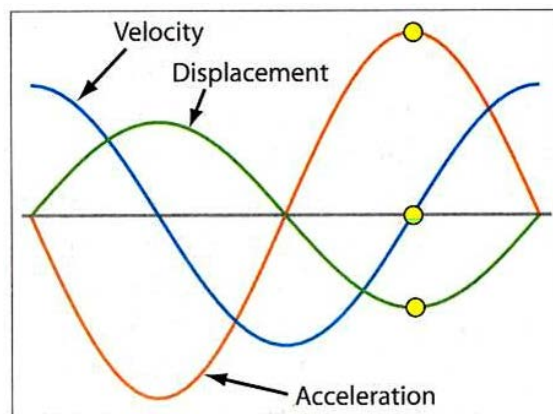
$$\text{acceleration} = \frac{dv}{dt} = -X_0 \cdot \omega^2 \cdot \sin \omega t$$

- **Πλάτος (amplitude)**, ορίζεται ως η μέγιστη τιμή που θα λάβει η μετατόπιση, η ταχύτητα ή η επιτάχυνση.




Εικόνα 5-2 Vibration Theory [70]

Στην *Εικόνα 5-3*, φαίνεται η αποτύπωση της μετατόπισης, ταχύτητας και επιτάχυνσης ενός σήματος κραδασμού.




Εικόνα 5-3 – Displacement vs Velocity vs Acceleration [89]

- **Φάση (phase)** Έστω δύο περιοδικά σήματα A και B τα οποία έχουν το ίδιο πλάτος X_0 και την ίδια συχνότητα f , το B όμως καθυστερεί κατά $T/2$ ως προς το σήμα A. Λέμε τότε ότι τα δύο σήματα έχουν **διαφορά φάσης (phase shift)** $T/2$ ή 180° . (*Εικόνα 5-4*)



Εικόνα 5-4 – Phase Shift

- **Αρμονικές (harmonics)**, αρμονική ονομάζεται κάθε συχνότητα που είναι πολλαπλάσιο μίας άλλης. Έστω για παράδειγμα μία ταλάντωση με συχνότητα f . Οι ταλαντώσεις με συχνότητα $2f$, $3f$, $4f$ κ.λπ. θεωρούνται αρμονικές της κύριας θεμελιώδους συχνότητας f . Στην [Εικόνα 5-5](#) απεικονίζεται ένα σήμα περιοδικό συχνότητας f , καθώς και η 3^η και 5^η αρμονική του. Επίσης στην ίδια εικόνα φαίνεται η "πρόσθεση" των αρμονικών αυτών σε ένα σήμα το οποίο, όσο οι προστιθέμενες αρμονικές αυξάνουν, τείνει να γίνει ένας τετραγωνικός παλμός. Η συχνότητα της 1^{ης} αρμονικής ονομάζεται **βασική ή fundamental**



Εικόνα 5-5 – Fundamental Frequency & Harmonics


5.4 Μετατόπιση – Ταχύτητα – Επιτάχυνση και αισθητήρες μέτρησης.

Από τα παραπάνω γίνεται αντιληπτό πως ένα σήμα κραδασμού μπορεί να μετρηθεί είτε με την *μετατόπιση (displacement)*, είτε με την *ταχύτητα (velocity)* είτε με την *επιτάχυνση (acceleration)*, η τιμή των οποίων καθορίζει την σοβαρότητα του κραδασμού και συνήθως αναφέρονται ως *πλάτος κραδασμού (vibration amplitude)*. Η τιμή αυτή είναι και η πρώτη που λαμβάνουμε υπόψιν κατά την μελέτη της κατάστασης ενός μηχανήματος. Αν και τα τρία αυτά μεγέθη (displacement, velocity, acceleration) σχετίζονται μαθηματικά μεταξύ τους, η τιμή του καθενός καθορίζει κάποιο διαφορετικό χαρακτηριστικό του κραδασμού.

5.4.1 Μετατόπιση – Displacement

Μετριέται σε *micron (1/1000 mm)* ή *mils* και είναι η μετατόπιση ενός αντικειμένου, για παράδειγμα ενός άξονα, από ένα σημείο αναφοράς. Μετριέται με αισθητήρες μετατόπισης, γνωστοί ως *displacement probe ή eddy probe*, οι οποίοι είναι τοποθετημένοι στο σταθερό μέρος του μηχανήματος. Μετράνε την σχετική απόσταση δύο επιφανειών και δεν έρχονται σε επαφή με την προς μέτρηση επιφάνεια. Συνήθως χρησιμοποιούνται για την μέτρηση των κραδασμών αξόνων που εδράζονται σε σφαιροτριβείς με σφηνοειδή λίπανση (fluid film bearings). Οι αισθητήρες αυτοί έχουν μικρή απόκριση και συνήθως μετρούν σήματα συχνότητας <10Hz.

Βασικότερο μειονέκτημα των αισθητήρων αυτών είναι ότι, εφόσον βρίσκονται τοποθετημένοι στη βάση του μηχανήματος, μπορούν να μετρούν μόνο την σχετική κίνηση του άξονα ως προς την βάση. Εάν για παράδειγμα το μηχανήμα κινείται μαζί τον άξονα, τότε η σχετική μετατόπιση είναι μηδέν και ο αισθητήρας δεν μπορεί να την μετρήσει. Οι αισθητήρες αυτοί χρησιμοποιούνται και για την μέτρηση της *γωνιακής φάσης* του άξονα (*shaft phase*), την γωνίας δηλαδή που προκύπτει από ένα γνωστό σημείο του άξονα και την μέτρησης του κραδασμού.




Εικόνα 5-6 – Displacement – Eddy Sensor

5.4.2 Ταχύτητα – Velocity

Οι αισθητήρες *ταχύτητας* μετρούν τον ρυθμό με τον οποίο μετατοπίζεται το μηχανήμα. Μονάδα μέτρησης είναι το *mm/sec* ή *in/sec*. Είναι ο πιο διαδεδομένος αισθητήρας μέτρησης κραδασμών και ιστορικά ο πρώτος που χρησιμοποιήθηκε για τον σκοπό αυτό. Τοποθετείται κοντά στην επιφάνεια της οποίας τον κραδασμό θέλουμε να μετρήσουμε (για παράδειγμα σφαιροτριβείς) και είναι πού σημαντικό η επιφάνεια επαφής να είναι καθαρή από ξένα σώματα αλλά και μεγαλύτερη από την επιφάνεια του αισθητήρα. Οι αισθητήρες αυτοί παρουσιάζουν ευαισθησία μέτρησης 20-30mV/mm/s. Ένα βασικό τους πλεονέκτημα είναι ότι η ευαισθησία παραμένει σταθερή για ένα μεγάλο εύρος συχνοτήτων που κυμαίνεται από 10Hz έως 1KHz. Αυτό είναι και το εύρος λειτουργίας τους μέσα στο οποίο η απόκρισή τους παραμένει γραμμική.

Στην *Εικόνα 5-7* δεξιά απεικονίζεται ο σωστός τρόπος τοποθέτησης των αισθητήρων στο σώμα του μηχανήματος, ενώ στην δεξιά εικόνα φαίνεται η πραγματική μορφή ενός τέτοιου αισθητήρα. Το βασικότερο μειονέκτημα των αισθητήρων μέτρησης ταχύτητας, είναι ότι είναι ευαίσθητοι όταν εκτίθενται σε μαγνητικά πεδία, ενώ περιλαμβάνουν και κινούμενα μέρη που τους κάνουν ποιο ευαίσθητους στην απώλεια ακρίβειας. Τέλος έχουν σχετικά μικρό εύρος απόκρισης συχνότητας.

Τέλος, από τους αισθητήρες ταχύτητας είναι εφικτό να υπολογισθεί η μετατόπιση της ταλάντωσης.




Εικόνα 5-7 – Velocity Sensor – Mounting – Sensor layout

5.4.3 Επιτάχυνση – Acceleration

Επιτάχυνση είναι ο ρυθμός με τον οποίο μεταβάλλεται η ταχύτητα. Ως μονάδα μέτρησης χρησιμοποιείται η **επιτάχυνση της βαρύτητας** g , η οποία ισούται με 9.80665 m/sec^2 . Η μέτρηση της επιτάχυνσης πραγματοποιείται με τους αισθητήρες επιτάχυνσης ή accelerometers. Η κατασκευή τους αποτελείται συνήθως από έναν ή περισσότερους πιεζοηλεκτρικούς κρυστάλλους και μία μάζα. Καθώς ο αισθητήρας δονείται ανάλογα με τον μετρούμενο κραδασμό, η μάζα ασκεί μία μεταβαλλόμενη δύναμη στον κρύσταλλο, ο οποίος με τη σειρά του, παράγει ένα ηλεκτρικό σήμα ανάλογο της επιτάχυνσης με την οποία συμπίεζεται. Όπως και οι αισθητήρες ταχύτητας, τοποθετούνται κοντά στην επιφάνεια της οποίας τον κραδασμό θέλουμε να μετρήσουμε (για παράδειγμα σφαιροτριβείς) και είναι πού σημαντικό η επιφάνεια επαφής να είναι καθαρή από ξένα σώματα αλλά και μεγαλύτερη από την επιφάνεια του αισθητήρα. Είναι πολύ σημαντικό οι αισθητήρες κραδασμών να βρίσκονται σε άμεση επαφή με την προς μέτρηση επιφάνεια. Επίσης ανάλογα με τον τρόπο έδρασης, επηρεάζεται και το εύρος συχνοτήτων που ο αισθητήρας μπορεί να μετρήσει. Η ευαισθησία τους είναι συνήθως 100 mV/g και μπορούν να μετρήσουν κραδασμούς σε ένα πολύ μεγάλο φάσμα συχνοτήτων από 2Hz έως και 10kHz .

Καθώς το κόστος κατασκευής τους έχει μειωθεί σημαντικά, είναι πλέον ο πιο συνηθισμένος τρόπος μέτρησης κραδασμών, καθώς μπορεί να λειτουργήσει σε μεγαλύτερο εύρος συχνοτήτων εν συγκρίσει με τους άλλους δύο. Επιπλέον, από την επιτάχυνση μπορεί να υπολογισθεί η ταχύτητα και άρα και η μετατόπιση. Οι


αισθητήρες επιτάχυνσης δεν χρήζουν περιοδικής διακρίβωσης. Στην *Εικόνα 5-8* φαίνεται σχηματικά η κατασκευή ενός αισθητήρα επιτάχυνσης.



Εικόνα 5-8 – Acceleration Sensor Construction

(<https://www.te.com/usa-en/whitepapers/sensors/predictive-maintenance-with-vibration-sensors.html>)

Τέλος, στην *Εικόνα 5-9* συνοψίζεται η σχέση των τριών αισθητηρίων, *displacement*, *velocity* και *acceleration* σε σχέση με το φάσμα συχνοτήτων που μπορούν να λειτουργήσουν, αλλά και του αναμενόμενου πλάτους του σήματος εξόδου.




Εικόνα 5-9 – Relationship between displacement, velocity and acceleration at constant velocity [15]

5.4.4 Η θέση των αισθητήρων για τη μέτρηση κραδασμών σε ένα μηχάνημα.

Η θέση των αισθητήρων στο μηχάνημα που θα ληφθούν οι μετρήσεις κραδασμών έχει πού μεγάλη σημασία για την ακρίβεια των μετρήσεων. Οι μετρήσεις θα πρέπει να λαμβάνονται σε τρεις άξονες και όταν χρησιμοποιούνται όργανα μέτρησης χειρός, οι αισθητήρες θα πρέπει να τοποθετούνται στο ίδιο σημείο κάθε φορά και όσο πιο κοντά στο προς μέτρηση σημείο.

Στην *Εικόνα 5-10* απεικονίζονται τα επίπεδα και η θέση των αισθητήρων κραδασμών σε έναν κινητήρα, ενώ ακολουθεί σύντομη περιγραφή.



Εικόνα 5-10 – Vibration Collection Points (<https://www.fluidlife.com/blog-sensor-placement-tips>)

Χωροταξικά κάθε μηχάνημα με περιστρεφόμενα μέρη χωρίζεται σε δύο κατηγορίες

- **Drive End (DE)** – Η πλευρά στην οποία οδηγείται η κίνηση. Π.Χ στους κινητήρες είναι η πλευρά που βρίσκεται ο άξονας κίνησης, στις Μ.Ε.Κ η πλευρά που βρίσκεται ο σφόνδυλος, στις αντλίες η πλευρά που συνδέεται ο άξονας κίνησης
- **Non Drive End (NDE)** – Η αντίθετη πλευρά από αυτή του DE

Επίσης, διακρίνουμε τρεις ακόμα κατηγορίες, δύο εκ των οποίων ορίζονται **ακτινικά (radial)** ως προς τον άξονα κίνησης και μία που ορίζεται στην ίδια διεύθυνση με τον άξονα και ονομάζεται **αξονική (axial)**

Οι *ακτινικές (radial)* θέσεις είναι:

- **Horizontal (H).** Στα μηχανήματα που είναι τοποθετημένα παράλληλα ως προς το οριζόντιο επίπεδο, ως Horizontal ορίζεται το επίπεδο που είναι 90° κάθετο ως προς την βάση έδρασης του μηχανήματος. Σε αυτά που είναι τοποθετημένα κάθετα, ο άξονας δηλαδή της κίνησης είναι κάθετος ως προς το οριζόντιο επίπεδο, τότε ως Horizontal ορίζουμε το επίπεδο που δημιουργεί 90° με την διεύθυνση της οριζόντιας κίνησης, για παράδειγμα, σε μία αντλία το επίπεδο που είναι κάθετο ως προς την ροή του υγρού.

Οι μετρήσεις του οριζόντιου επιπέδου είναι εκείνες που δίνουν τις περισσότερες μετρήσεις κραδασμών, καθώς όλα τα μηχανήματα παρουσιάζουν μεγαλύτερο βαθμό ευελιξίας σε αυτό το επίπεδο. Για το λόγο αυτό, αν και οι κραδασμοί που προκύπτουν από ανομοιομορφία φορτίου κατά την περιστροφή (imbalance) εμφανίζονται και στα δύο σημεία της ακτινικής θέσης (**V και H**), το πλάτος της **οριζόντιας(H)** συνιστώσας είναι πάντα πολύ μεγαλύτερο από αυτό της **κατακόρυφης (V)**

- **Vertical (V).** Στα μηχανήματα που είναι τοποθετημένα παράλληλα ως προς το οριζόντιο επίπεδο, ως Vertical ορίζεται το επίπεδο που είναι κάθετο ως προς την βάση έδρασης του μηχανήματος. Σε αυτά που είναι τοποθετημένα κάθετα, ο άξονας δηλαδή της κίνησης είναι κάθετος ως προς το οριζόντιο επίπεδο, τότε ως Vertical ορίζουμε το επίπεδο που έχει την ίδια διεύθυνση με αυτή της οριζόντιας κίνησης, για παράδειγμα, σε μία αντλία το επίπεδο που είναι παράλληλο ως προς την ροή του υγρού. Συνήθως το κάθετο επίπεδο δεν δίνει σημαντικές μετρήσεις κραδασμού.
- Ως **αξονική θέση (axial)** ορίζεται αυτή που είναι παράλληλη με την άξονα του μηχανήματος, βρίσκεται δηλαδή στο διάμηκες επίπεδο. **Axial vibration** αναμένουμε να μετρήσουμε μόνο σε περιπτώσεις κακής ευθυγράμμισης (misalignment) ή κάμψης του άξονα (bent shaft). Σε γενικές γραμμές οι μετρήσεις κραδασμών στο διάμηκες επίπεδο είναι μικρές, καθώς οι περισσότερες δυνάμεις στα μηχανήματα με περιστρεφόμενα μέρη παρουσιάζονται κάθετα στον άξονα κίνησης.




5.5 Πεδίο Χρόνου – Πεδίο Συχνοτήτων (Time – Frequency Domain)

5.5.1 Πεδίο Χρόνου – Time Domain

Οι μετρήσεις που συλλέγονται από τους αισθητήρες κραδασμών (*displacement, velocity, acceleration*) εμφανίζονται ως επί το πλείστον ως μία *κυματομορφή* στο *πεδίο του χρόνου*. Η απεικόνιση στο πεδίο του χρόνου ονομάζεται *time domain plot* (Εικόνα 5-11)


Το μεγάλο πλεονέκτημα των κυματομορφών στο πεδίο του χρόνου, είναι ότι καταγράφουν την κατάσταση του μηχανήματος σε πραγματικό χρόνο. Μάλιστα μία κυματομορφή στο πεδίο του χρόνου καταγράφει τον “*συνολικό κραδασμό*”, (*overall vibration*), που δεν είναι τίποτε άλλο από την συνολική ενέργεια των κραδασμών ενός μηχανήματος με περιστρεφόμενα μέρη, που μετρούνται σε μία καθορισμένη περιοχή συχνοτήτων, και η σύγκριση των οποίων με τις αντίστοιχες μετρήσεις της υγιούς κατάστασης, παρέχει το μέτρο της φθοράς του μηχανήματος.

Η ανάλυση τους είναι πιο δύσκολη από τις υπόλοιπες μεθόδους (spectra, phase κλπ), σε κάθε περίπτωση όμως μπορεί να παρέχει ενδείξεις για την κατάσταση του μηχανήματος, και σε κάποιες περιπτώσεις δεδομένα μη διαθέσιμα ή αναγνωρίσιμα στις υπόλοιπες μεθόδους. Η πιο συνήθης χρήση της κυματομορφής στο πεδίο του χρόνου είναι η σύγκρισή της με προηγούμενες μετρήσεις με σκοπό την γρήγορη αξιολόγηση της κατάστασης του μηχανήματος. Επίσης, μπορεί να χρησιμοποιηθεί για σύγκριση με κυματομορφές που έχουν συλλεγεί από παρόμοια μηχανήματα.



Εικόνα 5-11 – Time Waveform example [46]

Στην πράξη, οι κυματομορφές που συλλέγονται από τους αισθητήρες κραδασμών είναι αρκετά πολύπλοκες και αποτελούν το άθροισμα πολλών συνιστωσών. Στην *Εικόνα 5-12* απεικονίζεται μία κυματομορφή που συλλέχθηκε από το NDE ενός ανεμιστήρα βοηθητικού λέβητα [46]. Παρατηρούμε ότι πέραν της βασικής συχνότητας εμφανίζονται και αρμονικές, των οποίων το αρνητικό πλάτος είναι μεγαλύτερο από ότι το θετικό. Επιπλέον εμφανίζονται επτά αρνητικές κορυφές σε διάστημα 400ms. Από το διάγραμμα αυτό και γνωρίζοντας πως ο συγκεκριμένος ανεμιστήρας έχει επτά πτερύγια μπορούμε να βρούμε την ταχύτητα περιστροφής του, που είναι 1050 rpm.



Εικόνα 5-12 – Time Domain plot from the NDE Auxiliary Boiler Fan [46]


Για να επιτευχθεί μία αξιόλογη κυματομορφή στο πεδίο του χρόνου, θα πρέπει το παράθυρο μέτρησης να περιλαμβάνει τουλάχιστον 5-10 κύκλους λειτουργίας του μηχανήματος.

5.5.2 Πεδίο Συχνοτήτων – Frequency Domain

Όπως προαναφέραμε το πεδίο του χρόνου παρέχει πληροφορίες όπως αυτές συλλέγονται από το *ακατέργαστο σήμα (raw signal)* των αισθητήρων, οι οποίες

πληροφορίες είναι τις περισσότερες φορές όχι εύκολα αναγνωρίσιμες ή στην καλύτερη περίπτωση δυσνόητες.

Ο πιο διαδεδομένη μέθοδος ανάλυσης των μετρήσεων κραδασμών, είναι αυτή της ανάλυσης του *πεδίου των συχνοτήτων (frequency domain)*. Για να επιτευχθεί αυτό εφαρμόζεται ο *μετασχηματισμός Fast Fourier (FFT)* στο αναλογικό σήμα του πεδίου του χρόνου. Σε μη μαθηματικούς όρους, το αναλογικό σήμα αναλύεται σε συνιστώσες συχνοτήτων με συγκεκριμένο πλάτος. Στην *Εικόνα 5-13* φαίνεται παραστατικά η μετατροπή ενός σήματος από το *πεδίο του χρόνου* στο *πεδίο των συχνοτήτων*

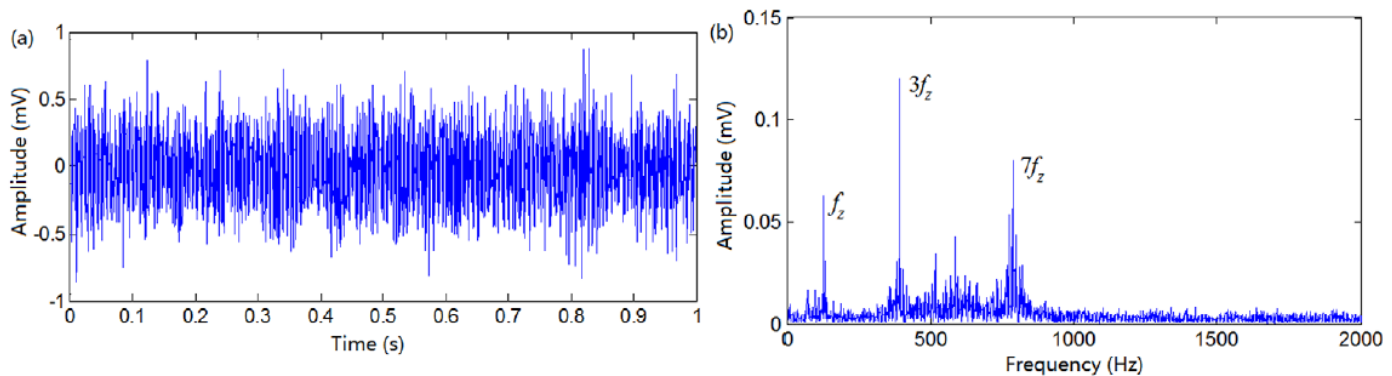


Εικόνα 5-13 Time to Frequency Domain (<https://www.ifm.com/de/en/shared/technologies/real-time-maintenance/technology/frequency-domain>)

Το πεδίο των συχνοτήτων παρέχει την δυνατότητα να αναλυθεί ένα περίπλοκο αναλογικό σήμα και να προσδιορισθούν με ακρίβεια και μεγαλύτερη ευκολία, οι συχνότητες εκείνες των οποίων το πλάτος είναι διεγερμένο. Καθώς, όπως θα δούμε σε επόμενη παράγραφο, κάθε βλάβη παρουσιάζει συγκεκριμένα συμπτώματα σε καθορισμένες συχνότητες, είναι εύκολο να ανιχνευθούν και να απομονωθούν οι συχνότητες αυτές και τελικά να ανιχνευθούν οι πηγές που προκαλούν βλάβη στο μηχάνημα. Στην *Εικόνα 5-14* απεικονίζεται το σήμα κραδασμού από ένα σύστημα μετάδοσης κίνησης με γρανάζια (μειωτήρας). Αριστερά φαίνεται το *ακατέργαστο σήμα* στο *πεδίο του χρόνου*, ενώ δεξιά ο *FFT μετασχηματισμός* στο *πεδίο των*



συχνότητων. Ευκολά μπορούμε να δούμε, πως από στο πεδίο του χρόνου δεν μπορούμε να εξάγουμε κάποιο συμπέρασμα για την λειτουργία του μειωτήρα. Αντίθετα στο πεδίο των συχνότητων παρατηρούμε την βασική συχνότητα f_z και δύο αρμονικές, $3f_z$ και $7f_z$, των οποίων μάλιστα πλάτος είναι πού μεγαλύτερο από αυτό της βασικής, υποδεικνύοντας την πηγή κάποιου κραδασμού.



Εικόνα 5-14 – Time – Frequency Domain Vibration Signal Plot [11]

Καθώς ο *μετασχηματισμός Fourier* είναι μία μαθηματική ανάλυση ενός αναλογικού περιοδικού σήματος που αποδομεί το αρχικό σήμα στις επιμέρους *ημιτονοειδής* και *συνημιτονοειδής συνιστώσες* του, πολύ σημαντικό ρόλο παίζει ο *ρυθμός δειγματοληψίας* του αρχικού ακατέργαστου σήματος. Το θεώρημα *Nyquist* ορίζει πως η συχνότητα δειγματοληψίας ενός σήματος πρέπει να είναι τουλάχιστον διπλάσια από την μέγιστη συχνότητα που μας ενδιαφέρει να αναλύσουμε [43]

5.5.3 Phase Signal Analysis

Η ανάλυση των φάσεων, *Phase Signal Analysis* είναι περισσότερο μία επιπλέον μέτρηση και όχι τόσο μία ακόμα μέθοδος ανάλυσης. Μετράει τη γωνιακή διαφορά μεταξύ ενός γνωστού σημείου στον περιστρεφόμενο άξονα του μηχανήματος και του σήματος κραδασμού. Αυτή η σχέση παρέχει πολύτιμες πληροφορίες για τα επίπεδα πλάτους κραδασμών, την τροχιά του άξονα και τη θέση του άξονα. Χρησιμοποιείται συνήθως σε συνδυασμό με την ανάλυση στο πεδίο των συχνότητων, ιδιαίτερα όταν η πηγή του κραδασμού δεν είναι εμφανής ή όταν χρειάζεται να γίνει αποσαφήνιση της. Οι περιπτώσεις που η ανάλυσης φάσης μπορεί να βοηθήσει στην

ανάλυση των κραδασμών είναι, looseness, misalignment, soft-foot, bent-shafts and rotors, cocked bearings, resonance, και imbalance

5.6 Επίπεδα Κραδασμών

Όπως έχουμε ήδη προαναφέρει, το πλάτος του κραδασμού, είτε μετρημένο σε *displacement* είτε σε *velocity*, είτε σε *acceleration*, μας δίνει το *μέτρο της έντασης* του και επομένως την σοβαρότητα μίας επικείμενης βλάβης σε ένα μηχάνημα. Μία εύλογη ερώτηση που αυτομάτως γεννιέται, είναι πιο είναι το μέγιστο αποδεκτό πλάτος κραδασμού που ένα μηχάνημα μπορεί να λειτουργήσει, χωρίς να προκληθούν βλάβες σε αυτό; Η απάντηση σε αυτό είναι, πως δεν υπάρχουν και δεν μπορούν να ορισθούν απόλυτες τιμές κραδασμών πάνω από τις οποίες ένα μηχάνημα θα παρουσιάσει βλάβη. Αυτό είναι ένας συνδυασμός παραγόντων και σίγουρα δεν εξαρτάται από μία απόλυτη τιμή κραδασμού ή ανοχής (tolerance). Από την άλλη πλευρά, είναι απαραίτητη η ύπαρξη τιμών αναφοράς πάνω στις οποίες θα στηρίζεται η ανάλυση της κατάστασης ενός μηχανήματος.

Για το λόγο αυτό, το **1974** δημιουργήθηκε το πρότυπο **ISO 2372** το οποίο τροποποιήθηκε το **1995** και μετονομάστηκε σε **ISO10816**. Το πρότυπο αυτό παρέχει καθοδήγηση για την αξιολόγηση των κραδασμών που μετρούνται στο σταθερό μέρος μηχανημάτων με περιστρεφόμενα μέρη και λειτουργούν σε εύρος συχνοτήτων από **10** έως **200Hz**, ήτοι **600** έως **12000 cpm**. Το πρότυπο ορίζει τέσσερις κατηγορίες μηχανημάτων που περιλαμβάνουν κινητήρες ισχύος έως **300KW** και αντλίες με απευθείας σύζευξης, γεννήτριες παραγωγής ηλεκτρικής ενέργειας, αεριοστρόβιλους και ατμοστρόβιλους, στροβιλοσυμπιεστές, ανεμιστήρες, και μηχανές εσωτερικής καύσης. Η μετάδοση της κίνησης μπορεί να είναι με εύκαμπτους ή και άκαμπτους συνδέσμους, μειωτήρες με γρανάζια, ιμάντες κίνησης κα. Ο περιστρεφόμενος άξονας μπορεί να είναι τοποθετημένος κατακόρυφα, οριζόντια ή κεκλιμένος υπό οποιαδήποτε γωνία.

Στην [Εικόνα 5-15](#) φαίνεται ο πίνακας κραδασμών βάση του προτύπου **ISO10816(2372)**. Αντίστοιχα πρότυπα έχουν ορίσει το American Petroleum Institute (API610, 611 to 617) και το American Gear Manufacturer Association (AGMA). Τέλος η εταιρία **IRD Mechanalysis Limited** έχει συντάξει και εκδώσει το διάγραμμα


της *Εικόνα 5-16* στο οποίο έχουν συμπεριληφθεί καμπύλες επιτάχυνσης και ταχύτητας σε σχέση με την ταχύτητα περιστροφής.

Αυτό που είναι σημαντικό να γίνει κατανοητό είναι ότι τα πρότυπα και οι πίνακες με τα όρια κραδασμών παρέχουν απλώς μία καθοδήγηση. Ο απώτερος σκοπός της ανάλυσης κραδασμών είναι η έγκαιρη διάγνωση μίας *άρχουσας βλάβης* σε ένα μηχάνημα με περιστρεφόμενα μέρη και όχι ποια είναι η ανοχή του σε κραδασμούς, πριν αυτό βγει εκτός λειτουργία λόγω βλάβης. Γι' αυτό ο βέλτιστος τρόπος παρακολούθησης των κραδασμών είναι ο συχνός έλεγχος και η σύγκριση των μετρήσεων με αυτές των προηγούμενων λήψεων.

VIBRATION SEVERITY PER ISO 10816					
Machine		Class I small machines	Class II medium machines	Class III large rigid foundation	Class IV large soft foundation
in/s	mm/s				
Vibration Velocity Vrms	0.01	0.28			
	0.02	0.45			
	0.03	0.71		good	
	0.04	1.12			
	0.07	1.80			
	0.11	2.80		satisfactory	
	0.18	4.50			
	0.28	7.10		unsatisfactory	
	0.44	11.2			
	0.70	18.0			
	0.71	28.0		unacceptable	
1.10	45.0				

Εικόνα 5-15 – Vibration Limits ISO10816(2372)

(<https://www.intech2000.com/downloads/web/54/54.1/Applying%20Examiner.pdf>)



Εικόνα 5-16 – Acc- Vel vs Freq [22]

5.7 Ανίχνευση Βλαβών Μηχανημάτων με στρεφόμενα μέρη με την ανάλυση κραδασμών

Έως τώρα είδαμε τα βασικά μεγέθη που χαρακτηρίζουν το σήμα ενός κραδασμού, τους αισθητήρες με τους οποίους μπορούμε να μετρήσουμε έναν κραδασμό, τις τρεις βασικότερες μεθόδους ανάλυσης και τα επιτρεπτά όρια λειτουργίας όπως αυτά ορίζονται από το πρότυπο **ISO2372**.

Στην παράγραφο αυτή θα περιγράψουμε πολύ περιληπτικά τις βλάβες που προκαλούν κραδασμούς στα μηχανήματα με περιστρεφόμενα μέρη. Για κάθε βλάβη παραθέτουμε και μία εικόνα με τα συμπτώματα που εμφανίζονται στο *φάσμα των συχνοτήτων*. Οι εικόνες έχουν παρθεί από τα εγχειρίδια της **SKF, Vibration Diagnostic Guide - (2000) [46]** και **Spectrum Analysis - The key features of analysing spectra [31]**




5.7.1 Misalignment


Μαζί με το unbalance, είναι οι σημαντικότερες και πιο συχνές αιτίες που προκαλούν κραδασμούς και έχουν άμεσο, καταστροφικό τις περισσότερες φορές, αντίκτυπο στα έδρανα των μηχανημάτων με περιστρεφόμενα μέρη.

Η *εσφαλμένη ευθυγράμμιση (misalignment)* εμφανίζεται όταν οι άξονες (shafts), ή οι σύνδεσμοι (couplings) και τα έδρανα (bearings) δεν είναι σωστά ευθυγραμμισμένα κατά μήκος των αξόνων συμμετρίας τους. Δύο είναι οι βασικοί τύποι:

- **Angular misalignment**, γωνιακή λανθασμένη ευθυγράμμιση που εμφανίζεται όταν δύο άξονες ενώνονται με έναν σύνδεσμο (μόνιμο ή εύκαμπτο) με τρόπο που προκαλεί τάσης κάμψης σε έναν ή και στους δύο άξονες (*Εικόνα 5-17αριστερά*). Εμφανίζει *axial vibration* στην $1x$ και συχνά στην $2x$ συχνότητα, και διαφορά φάσης (*phase shift*) 180° κατά μήκος του συνδέσμου
- **Parallel misalignment**, εμφανίζεται όταν οι κεντρικές γραμμές των δύο αξόνων είναι ναί μεν παράλληλες, αλλά μετατοπισμένες κατά το κατακόρυφο επίπεδο (*Εικόνα 5-17 δεξιά*). Εμφανίζει *radial vibration* με πολύ ψηλές τιμές στην $2x$ συχνότητα που πολλές φορές μπορεί να φθάσει και το 200% της $1x$. Επίσης εμφανίζεται διαφορά φάσης (*phase shift*) 180° κατά μήκος του συνδέσμου και 0° ή 180° όταν ο αισθητήρας μετατοπισθεί από το οριζόντιο στο κατακόρυφο επίπεδο ($V \Leftrightarrow H$ plane).



Εικόνα 5-17 -Angular Misalignment (left) – Parallel Misalignment (right) [46]



Εικόνα 5-18 – Misalignment Spectra Analysis [46]


5.7.2 Unbalance

Σύμφωνα με τον *Διεθνή Οργανισμό Τυποποίησης (ISO)*, ως **unbalance** ορίζεται ως η κατάσταση που εμφανίζεται σε έναν ρότορα όταν δονήσεις, δυνάμεις ή κίνηση μεταδίδεται στα έδρανά του ως αποτέλεσμα φυγόκεντρων δυνάμεων. Στην πράξη **unbalance** εμφανίζεται όταν ο άξονας αδράνειας (*Principle Inertia Axis*) δεν συμπίπτει με την γεωμετρική αξονική γραμμή (*Geometric Centerline*). Εμφανίζεται με τρεις τύπους:


- **Static** – όπου μόνο μία δύναμη εφαρμόζεται στον ρότορα, και η **PIA** είναι παράλληλη με την **GCL** (Εικόνα 5-19 αριστερά). Εμφανίζεται με πολύ αυξημένη τιμή της βασικής συχνότητας **1x** κατά το ακτινικό επίπεδο, χωρίς αρμονικές. Παρουσιάζει **διαφορά φάσης 90o** όταν ο αισθητήρας μετατοπισθεί από το οριζόντιο στο κατακόρυφο επίπεδο (**V-H plane**).
- **Couple** – Όταν δύο δυνάμεις με διαφορά 180° εφαρμόζονται στον άξονα. Σε αυτή τη μορφή ο άξονας στην κατάσταση ισορροπίας μοιάζει με ισορροπημένος. Αντίθετα όταν περιστρέφεται, ασκούνται στα δύο άκρα του αντίθετες δυνάμεις που προκαλούν ταλάντωση με διαφορά φάσης 180°. Εδώ η **PIA** διασταυρώνεται με την **GCL**. (Εικόνα 5-19 δεξιά). Ομοίως, εμφανίζεται με πολύ αυξημένη τιμή της βασικής συχνότητας **1x** κατά το ακτινικό επίπεδο,

χωρίς αρμονικές. Παρουσιάζει *διαφορά φάσης 90°* όταν ο αισθητήρας μετατοπισθεί από το οριζόντιο στο κατακόρυφο επίπεδο (*V-H plane*), και *180°* όταν ο αισθητήρας μετατοπισθεί από το *DE* στο *NDE*.

- *Dynamic* - Περιλαμβάνει και τις δύο προηγούμενες μορφές και είναι αυτή που συνήθως απαντάται στην πράξη. Εδώ η *PIA* δεν ακουμπάει πουθενά ούτε συμπέφτει με την *GCL*



Εικόνα 5-19- Static Unbalance (left) – Couple Unbalance (right) [46]



Εικόνα 5-20- Unbalance Spectra Analysis [46]


5.7.3 Bent Shaft

Εμφανίζεται με τα ίδια ακριβώς συμπτώματα της εσφαλμένης ευθυγράμμισης (misalignment). Αναμένονται υψηλές τιμές στην **1x** και **2x** συχνότητες και μάλιστα ανάλογα με το ποια είναι υψηλότερη υποδηλώνει εάν ο άξονας είναι στραβός κοντά στις άκρες (**2x**) ή στο κέντρο (**1x**). Υψηλές τιμές πλάτους εμφανίζονται τόσο στο


ακτινικό (radial) όσο και στο *αξονικό (axial)* επίπεδο, στο οποίο εμφανίζεται και διαφορά φάσης 180° κατά μήκος του άξονα.

5.7.4 Mechanical Looseness

Εμφανίζεται με τρεις διαφορετικές μορφές, *internal assembly looseness*, *machine to base plate* και *structure looseness*. Και στις τρεις μορφές υπάρχει ακατάλληλη συναρμογή, εφαρμογή ή σύνδεση των εξαρτημάτων του ίδιου του μηχανήματος (*internal assembly*), μεταξύ του μηχανήματος και της βάσης του (*base plate*) και μεταξύ της ευρύτερης κατασκευής και της βάσης του μηχανήματος (*structure*) (Εικόνα 5-21). Εμφανίζεται με μία μακρά σειρά αρμονικών της βασικής συχνότητας $1x$ ή ακόμη και της $1/2x$ συχνότητας, με ακανόνιστα και υψηλά πλάτη.



Εικόνα 5-21 – Looseness (<http://vlabs.iitkgp.ac.in/rmfs/exp5/index.html>)




Εικόνα 5-22 – Looseness Spectra Analysis [31]



5.7.5 Rolling Elements

Τις περισσότερες φορές, με εξαίρεση τις κατασκευαστικές αστοχίες, οι βλάβες των κουζινέτων και σφαιροτριβέων δεν είναι η αιτία ενός προβλήματος, αλλά το αποτέλεσμα. Για το λόγο αυτό κάθε φορά που εμφανίζεται ένα πρόβλημα σε έναν σφαιροτριβέα, θα πρέπει να ελέγχεται εξονυχιστικά το μηχάνημα και για κάποιο από τα προβλήματα που προαναφέρθηκαν. Οι βασικοί λόγοι που οδηγούν έναν σφαιροτριβέα ή κουζινέτο σε βλάβη είναι η ελλειπής λίπανση, λανθασμένος τύπος λίπανσης, αυξημένο φορτίο, εσφαλμένη τοποθέτηση και η ολοκλήρωση του κύκλου ζωής. Λόγω της κατασκευής των κουζινέτων και ιδιαίτερα των σφαιροτριβέων, οι βλάβες τους εμφανίζονται σε πιο υψηλότερες συχνότητες από αυτή της λειτουργίας του μηχανήματος και με πολύ χαμηλότερα πλάτη. Ένας σφαιροτριβέας (ball bearing) *Εικόνα 5-23* αποτελείται από πολλά κινούμενα μέρη όπως τα *inner* και *outer races* μέσα στα οποία περιστρέφονται οι σφαίρες ολίσθησης (*balls*), ο αποστάτης των σφαιρών (*separator*) κ.α. Βλάβη σε ένα από αυτά τα εξαρτήματα θα προκαλέσει κραδασμούς η συχνότητα των οποίων εξαρτάται από στην σχετική ταχύτητα περιστροφής του συγκεκριμένου εξαρτήματος.



Εικόνα 5-23 – Ball Bearing Parts – (<https://www.iqsdirectory.com/articles/ball-bearing.html>)

Για να γίνει λοιπόν ο προσδιορισμός, εάν ο μετρούμενος κραδασμός προέρχεται από τον σφαιροτριβέα και ενδεχόμενα από ποιο εξάρτημα του σφαιροτριβέα, είναι απαραίτητος ο υπολογισμός των παρακάτω συχνοτήτων που



σχετίζονται με την ταχύτητα περιστροφής του μηχανήματος και τα κατασκευαστικά χαρακτηριστικά του σφαιροτριβέα.

Οι συχνότητες αυτές είναι:

- F_{ord} – Frequency Outer Race Defect
- F_{ird} – Frequency Inner Race Defect
- F_{db} – Frequency Ball Defect
- F_c – Frequency Cage


Ή

- **$BPFO$** – Ball Pass Frequency Outer Race
- **$BPFI$** – Ball Pass Frequency Inner Race
- **BSF** – Ball Spin Frequency
- **FTF** – Fundamental Train Frequency

Στα συστήματα μέτρησης και παρακολούθησης κραδασμών οι παραπάνω έννοιες είναι συνήθως εναλλάξιμες ως ακολούθως:

- $F_{ord} = BPFO$
- $F_{ird} = BPFI$
- $F_{db} = BSF$
- $F_c = FTF$

Υψηλή τιμή πλάτους σε μία εκ των παραπάνω συχνοτήτων συνήθως σημαίνει βλάβη ή άρχουσα βλάβη στο αντίστοιχο εξάρτημα του σφαιροτριβέα. Στην [Εικόνα 5-24](#) φαίνεται το διάγραμμα συχνοτήτων ενός σφαιροτριβέα με αυξημένες τιμές στις συχνότητες BPFI. Η ανάλυση των κραδασμών των σφαιροτριβέων χρήζει περεταίρω μελέτης καθώς υπάρχουν τεχνικές, όπως για παράδειγμα το *enveloping* για την ανίχνευση συχνοτήτων που δεν εμφανίζονται στο spectrum ή που τα πλάτη τους είναι πολύ μικρά. Καθώς αυτό δεν αποτελεί βασικό στοιχείο της παρούσας εργασίας δεν θα επεκταθούμε παραπέρα.



Εικόνα 5-24 – Ball Bearing Inner Ring (BPFI) Spectrum Analysis [31]

5.7.6 Λοιπές βλάβες

Χρησιμοποιώντας την ανάλυση κραδασμών είναι εφικτό, πέραν των βλαβών που ήδη αναφέραμε, να ανιχνεύσουμε και μία σειρά άλλων βλαβών τις οποίες αναφέρουμε παρακάτω σε τίτλους χωρίς να επεκταθούμε καθόλου. Εάν ο αναγνώστης ενδιαφέρεται μπορεί να ανατρέξει στην βιβλιογραφία για περισσότερες πληροφορίες και μελέτη.

Με την ανάλυση των κραδασμών επιπλέον είναι δυνατόν να ανιχνεύσουμε [43]:

- **Belt defects**
- **Reductions gears**
 - Gear mesh
 - Gear tooth
 - Gear Load
- **Electric motor defects**
 - Βραχυκύκλωμα ή διακοπή στα τυλίγματα του στάτη και του ρότορα
 - Broken rotor bars
 - Unequal air gaps
 - Unbalance phases
- **Hydraulic defects**
 - Cavitation
 - Turbulance
 - Starvation

- *Defect impellers*

6. Predictive Maintenance and Convolutional Neural Networks

6.1 Εισαγωγή στη διαγνωστική συντήρηση με χρήση των συνελκτικών νευρωνικών δικτύων.

Η παρούσα εργασία πραγματεύεται την *πρόβλεψη* και *διάγνωση βλαβών* σε *μηχανήματα με στρεφόμενα μέρη* και ιδιαίτερα σε *κινητήρες* συλλέγοντας και αναλύοντας δεδομένα από *αισθητήρες κραδασμού*. Στα προηγούμενα κεφάλαια αναλύσαμε τις διάφορες μεθόδους συντήρησης που εφαρμόζονται στη βιομηχανία και τη ναυτιλία, το θεωρητικό πλαίσιο της μέτρησης και ανάλυσης κραδασμών και των τεχνητών νευρωνικών δικτύων και ιδιαίτερα των **συνελκτικών νευρωνικών δικτύων**.

Στο κεφάλαιο αυτό θα αναλύσουμε πως η *βαθιά μάθηση* και ιδιαίτερα τα **συνελκτικά νευρωνικά δίκτυα** εφαρμόζονται στην *προγνωστική συντήρηση* βασισμένη **στην πραγματική κατάσταση** ενός κινητήρα . Αυτή τη στιγμή, τα μοντέλα *προγνωστικής συντήρησης* βασισμένα στην *τεχνητή νοημοσύνη* είναι η πιο ραγδαία αναπτυσσόμενη μέθοδος διάγνωσης βλαβών. Χρησιμοποιούν την σύγχρονη ανάλυση δεδομένων πραγματικού χρόνου σε μία ολιστική επισκόπηση διασυνδεδεμένων τεχνολογιών, σε αντίθεση με τις παραδοσιακές μεθόδους συντήρησης που βασικός τους στόχος είναι η διόρθωση βλαβών αφού έχουν συμβεί ή στην καλύτερη των περιπτώσεων, η επιφανειακή ανάλυση συμπτωμάτων βασισμένη σε εμπειρικές γνώσεις. Μέχρι σήμερα, σε μία πληθώρα μελετών, έχουν δοκιμασθεί διάφορα μοντέλα *βαθιάς μάθησης* για την κατηγοριοποίηση και πρόβλεψη της διάρκειας ζωής των κινητήρων. Μερικά από αυτά είναι τα, *support vector machine (SVM)*, *deep belief network (DBN)*, *deep Boltzmann machines (DBMs)*, *wavelet packet transformation (WPT)*, *deep autoencoder*, και *convolutional neural networks*.

6.2 Επισκόπηση μελετών προγνωστικής συντήρησης, βασισμένη στα συνελκτικά νευρωνικά δίκτυα

Παρακάτω παρατίθεται μία επισκόπηση μελετών στην *προληπτική συντήρηση βασισμένη στην πραγματική κατάσταση* του μηχανήματος, και ιδιαίτερα στην ανίχνευση βλαβών μηχανημάτων με στρεπτά μέρη χρησιμοποιώντας τα *συνελκτικά νευρωνικά δίκτυα*. Από την σχετική μελέτη της βιβλιογραφίας προκύπτει, πως υπάρχει πολύ μεγάλο ενδιαφέρον για το συγκεκριμένο αντικείμενο, καθώς τα αποτελέσματα είναι ενθαρρυντικά, και καλύπτουν όλο το φάσμα των βιομηχανικών εφαρμογών και βλαβών.

Οι **Roberto M. Souza et al (2019) [47]** προτείνουν την εφαρμογή των *συνελκτικών νευρωνικών δικτύων* για την ανάπτυξη ενός μοντέλου *προγνωστικής συντήρησης* που θα ανιχνεύει και κατηγοριοποιεί βλάβες σε μηχανήματα με στρεπτά μέρη και θα ενημερώνει πότε θα πρέπει να παρθούν μέτρα συντήρησης. Για την εκπαίδευση και δοκιμή του μοντέλου, χρησιμοποιήθηκαν οι μετρήσεις των βάσεων δεδομένων, *MaFaulDa* και *Case Western Reserve University (CWRU)*. Επίσης το προτεινόμενο μοντέλο ρυθμίστηκε ώστε να χρησιμοποιήσει τις μετρήσεις από έναν μόνο αισθητήρα μέτρησης κραδασμών, αυτόν που ήταν τοποθετημένος στο drive end του κινητήρα. Στην εργασία τους χρησιμοποίησαν δύο διαφορετικές μεθόδους κατηγοριοποίησης βλάβης. Η μία ήταν η ανίχνευση ή όχι κάποιας βλάβης σε διαφορετικά επίπεδα σοβαρότητας και η άλλη, η ομαδοποίηση όλων των βλαβών ανάλογα με την κλάση τους (misalignment, imbalance, κλπ). Τα αποτελέσματα έδειξαν πως το προτεινόμενο μοντέλο *PdM-CNN* έχει ακρίβεια **99,58** και **97,3%** αντίστοιχα.

Οι **Han, Yang, and Yin (2007) [18]** προτείνουν έναν συνδυασμό *γενετικών αλγορίθμων (GA)* και *νευρωνικών δικτύων (NN)* για την διάγνωση βλαβών σε επαγωγικούς κινητήρες, βασισμένα στην ανάλυση κραδασμών. Για την εκπαίδευση και δοκιμή του προτεινόμενου δικτύου χρησιμοποίησαν τέσσερις κινητήρες πλοίων σε μία αυτοσχέδια εργαστηριακή πλατφόρμα δοκιμών. Τα αποτελέσματα έδειξαν πως το προτεινόμενο δίκτυο κατάφερε να διαγνώσει με επιτυχία τις βλάβες και είναι πολλά υποσχόμενο για εφαρμογές σε πραγματικό χρόνο.

Οι **ZhiQiang Chen et al (2015) [61]** παρουσιάζουν την εφαρμογή ενός *συνελικτικού νευρωνικού δικτύου* στην αναγνώριση και κατηγοριοποίηση βλαβών σε μειωτήρες κίνησης. Η εκπαίδευση και δοκιμή του δικτύου πραγματοποιήθηκε με μετρήσεις που λήφθηκαν από ένα μειωτήρα σε πέντε διαφορετικές συχνότητες λειτουργίας σε κάθε μία εκ των οποίων εφαρμόστηκαν τέσσερα διαφορετικά προφίλ φορτίου. Το προτεινόμενο μοντέλο έδειξε *ποσοστό ταξινόμησης* από **89,46** έως **98,35%**.

Οι **Olivier Janssens et al (2016) [23]** ανάπτυξαν ένα *συνελικτικό μοντέλο* εξαγωγής χαρακτηριστικών για την αυτοματοποιημένη ανίχνευση διάφορων βλαβών σε μηχανήματα με περιστρεφόμενα μέρη, χρησιμοποιώντας μετρήσεις κραδασμών. Οι μετρήσεις πραγματοποιήθηκαν σε δύο διαφορετικά πειράματα. Το πρώτο αφορούσε την ανίχνευση *balancing* ή όχι του κινητήρα και η άλλη την ανίχνευση και κατηγοριοποίηση τεσσάρων διαφορετικών βλαβών. Για λόγους σύγκρισης, τα ίδια δεδομένα τα ανέλυσαν με κλασικές μεθόδους εντοπισμού σφαλμάτων χρησιμοποιώντας *engineering features* όπως *kurtosis*, *root mean square* και *crest factor*. Το *set* δεδομένων αποτελείται από μετρήσεις που συλλέχθηκαν για οκτώ διαφορετικές καταστάσεις λειτουργίας σε πέντε διαφορετικούς σφαιροτριβείς και μία ώρα λειτουργίας. Η έρευνα έδειξε ότι η εφαρμογή του *προτεινόμενου συνελικτικού μοντέλου* στην ανίχνευση *balancing* είχε επιτυχία **100%**, όπως και η εφαρμογή των κλασικών μεθόδων. Όσον αφορά την ανίχνευση και ταξινόμηση των τεσσάρων διαφορετικών βλαβών, το *συνελικτικό μοντέλο* έδειξε επιτυχία από **93,6** έως **94,5%**, εν αντιθέσει με τις κλασικές μαθηματικές μεθόδους που η επιτυχία τους κυμάνθηκε στην καλύτερη περίπτωση από **86,7** έως **89,8%**.

Οι **Bayu Adhi Tama et al - (2022) [5]**, παραθέτουν τα πλεονεκτήματα και μειονεκτήματα της εφαρμογής της *βαθιάς μάθησης* στην *προγνωστική συντήρηση* μηχανών με περιστρεφόμενα μέρη. Μέσα από μία εις βάθος ανάλυση 59 ερευνών πάνω στο αντικείμενο, μελέτησαν μία σειρά *νευρωνικών δικτύων βαθιάς μάθησης* όπως τα, *CNN – DBN – RNN – GNN (generative NN) και GNN (Graphic NN)*. Η επιλογή των ερευνών που μελέτησαν έγινε με συγκεκριμένα κριτήρια. Τα αποτελέσματα της μελέτης τους για την ακρίβεια των προβλέψεων κάθε ενός εκ των

παραπάνω δικτύων μπορούν να αναζητηθούν στο αντίστοιχο paper [5]. Όσον αφορά τα *συνελικτικά νευρωνικά δίκτυα*, κατέληξαν, πως αυτή τη στιγμή, αποτελούν το 39% των αντίστοιχων μελετών στην *προγνωστική συντήρηση* και παρουσιάζουν ποσοστά επιτυχίας από 88,27% έως και 100% ανάλογα με την εφαρμογή το επιλεγμένο set δεδομένων, αλλά και τη αρχιτεκτονική του δικτύου.

Οι Zang.W et al (2017) [58], παρατήρησαν πως τα προτεινόμενα μοντέλα *βαθιάς μάθησης*, αλλά και τα *συνελικτικά νευρωνικά δίκτυα*, πολλές φορές αποτυγχάνουν να ανιχνεύσουν βλάβες όταν τα σήματα που λαμβάνουν έχουν θόρυβο, ή το φορτίο του μηχανήματος έχει μεταβληθεί από αυτό με το οποίο πραγματοποιήθηκε η εκπαίδευση του δικτύου. Στην μελέτη τους προτείνουν ένα τροποποιημένο *συνελικτικό δίκτυο* που το ονομάζουν *Convolution Neural Networks with Training Interference (TICNN)*. Το προτεινόμενο δίκτυο βασίζεται σε ένα κλασικό συνελικτικό μοντέλο με δύο παρεμβολές κατά τη διάρκεια της εκπαίδευσης του, με σκοπό την ενίσχυση της ικανότητάς του κατά του θορύβου, αλλά και την βελτίωση της προσαρμογής του στην αλλαγή των φορτίων. Για την ανάλυση, εκπαίδευση και δοκιμή του μοντέλου τους χρησιμοποίησαν τη βάση δεδομένων *Case Western Reserve University (CWRU)*. Τα αποτελέσματα έδειξαν μία σημαντική βελτίωση του μοντέλου χωρίς να είναι απαραίτητη η εφαρμογή προεπεξεργασίας απόρριψης του θορύβου ή την ανάγκη εκπαίδευσης του μοντέλου με περισσότερα δεδομένα.

Οι Abdeljaber.O et al (2018) [1] παρουσίασαν ένα *μονοδιάστατο συνελικτικό δίκτυο* για την ανίχνευση, κατηγοριοποίηση και αξιολόγηση της σοβαρότητας της βλάβης σφαιροτριβέων. Το προτεινόμενο δίκτυο εκπαιδεύτηκε και στη συνέχεια δοκιμάστηκε σε σενάρια κατά τα οποία υπήρχαν ταυτόχρονα πολλαπλές βλάβες στους σφαιροτριβείς. Με τον τρόπο αυτό οι συγγραφείς απέδειξαν την ακρίβεια και εγκυρότητα που μπορεί να δείξουν απλά, *μονοδιάστατα συνελικτικά δίκτυα*, χωρίς την απαίτηση μεγάλης υπολογιστικής δύναμης και εκτεταμένων set δεδομένων για την εκπαίδευσή τους. Επιπλέον, το προτεινόμενο δίκτυο παρουσίασε κατά τις δοκιμές αξιόλογη στιβαρότητα έναντι του θορύβου στις μετρήσεις από τους αισθητήρες κραδασμών.

Οι **Serkan Kiranyaz et al (2015) [25]** παραθέτουν στη μελέτη τους την εφαρμογή των *ID συνελικτικών δικτύων*, σε μία πληθώρα εφαρμογών στο χώρο της μηχανικής, της βιοϊατρικής.

Οι **Zhang Wei et al (2017)[58]** παρουσίασαν ένα *δισδιάστατο συνελικτικό μοντέλο* για την αναγνώριση βλαβών σε σφαιροτριβείς. Για την μελέτη τους χρησιμοποίησαν τα δεδομένα του *Case Western Reserve University Bearing Data Center (CWRU)*. Αρχικά μετασχημάτισαν την μονοδιάστατη χρονοσειρά των ακατέργαστων μετρήσεων κραδασμών, κάθε ένα εκ των οποίων αποτελείται από 2400 data points, σε δισδιάστατες εικόνες μεγέθους 60x40. Το *συνελικτικό μοντέλο* που προτείναν, αποτελείται από δύο convolution και δύο pooling layers, ενώ για την κατηγοριοποίηση έχουν χρησιμοποιήσει δύο fully connected layers που, χρησιμοποιώντας τη συνάρτηση softmax, καταλήγουν σε δέκα νευρώνες στο πεδίο εξόδου. Το μοντέλο εκπαιδεύτηκε και δοκιμάστηκε με δύο data sets. Το set A, αποτελείται από 30000 training και 7500 testing data, 10 ανάμικτων καταστάσεων των σφαιροτριβέων, κάτω από τρία διαφορετικά φορτία. Για την τελική αξιολόγηση του δικτύου, χρησιμοποιήθηκε ένα δεύτερο set δεδομένων (B), αποτελούμενο από 1500 training και 7500 testing data. Τα αποτελέσματα της έρευνας δείχνουν που το προτεινόμενο μοντέλο κατάφερε να κατηγοριοποιήσει σωστά το **99,7%** των περιπτώσεων του *data set A*, ενώ το ποσοστό *μειώθηκε* περίπου **1,8%** όταν χρησιμοποιήθηκε το *set δεδομένων B*. Αυτό, με βάση τους συγγραφείς, υποδηλώνει την ανάγκη του δικτύου να εκπαιδεύεται σε μεγάλα set δεδομένων.

Επιπλέον, οι **Xiaojie G. etal (2016) [55]**, προτείνουν ένα νέο *συνελικτικό νευρωνικό δίκτυο*, το οποίο εκπαιδεύτηκε στην ανίχνευση βλαβών σφαιροτριβέων με την εφαρμογή ενός βελτιωμένου αλγόριθμου *ιεραρχικού ρυθμού μάθησης (adaptive deep CNN)*.

Οι **Kolar. D etal – 2020 [27]**, προτείνουν ένα *multi-channel συνελικτικό δίκτυο* που συλλέγει δεδομένα κραδασμών από τρεις επιταχυνσιόμετρα τοποθετημένα στους τρεις άξονες (X,Y και Z). Οι ερευνητές δοκίμασαν διάφορους συνδυασμούς παραμέτρων σε ένα σετ δεδομένων 12000 σημείων που συλλέχθηκαν κατά την προσομοίωση τεσσάρων διαφορετικών καταστάσεων και μεταβλητού φορτίου. Για

την εκπαίδευση του δικτύου χρησιμοποίησαν το 70% των δεδομένων και το 30% για την δοκιμή του. Τα αποτελέσματα έδειξαν επιτυχή ταξινόμηση από **99.64** έως **100%** με μέση τιμή **99.85%**.

Οι **Zhibin.Z etal (2020) [60]**, στην μελέτη τους “*Deep learning algorithms for rotating machinery intelligent diagnosis*” πραγματοποίησαν μία ολοκληρωμένη αξιολόγηση τεσσάρων μοντέλων βαθιάς μάθησης, περιλαμβανομένων των *multi-layer perception (MLP)*, *auto-encoder (AE)*, *convolutional neural network (CNN)* και *recurrent neural network (RNN)*. Για την αξιολόγηση χρησιμοποίησαν εννέα δημοσιευμένα set δεδομένων με μετρήσεις κραδασμών σφαιροτριβέων, τα οποία αξιολόγησαν ως προς την ικανότητά τους να εξάγουν αξιόλογα συμπεράσματα με βάση τα δεδομένα που περιλαμβάνουν. Επίσης, στην μελέτη τους εφάρμοσαν διαφορετικά ήδη του σήματος εισόδου, (time domain, frequency domain), μεθόδους normalization, αλλά και μεθόδους αύξησης των δεδομένων (data augmentation), όπου έκριναν ότι είναι απαραίτητο. Μία πρώτη παρατήρηση των συγγραφέων είναι ότι επί του παρόντος οι μέθοδοι αύξησης των δεδομένων (data augmentation) δεν έχουν ερευνηθεί και αναπτυχθεί όσο θα ήταν αναμενόμενο.

Τέλος, οι **Shangjun.M etal, (2019) [45]**, μελέτησαν την πρόβλεψη σφαλμάτων χρησιμοποιώντας ένα *μονοδιάστατο συνελκτικό δίκτυο*, αποτελούμενο από μόλις δύο επίπεδα. Το σήμα εισόδου επεξεργάστηκαν εφαρμόζοντας τον μετασχηματισμό *Wavelet Packet Transform*, ώστε να τροφοδοτήσουν το δίκτυο με περισσότερα δεδομένα από το πεδίο των συχνοτήτων (*frequency domain*). Για την επικύρωση της αποτελεσματικότητας του προτεινόμενου δικτύου, οι συγγραφείς χρησιμοποίησαν τα δεδομένα του *Case Western Reserve University (CWRU)*, τα οποία επεξεργάστηκαν προσθέτοντας White Gaussian θόρυβο σε ποσοστό από 10 έως και 100%. Τα αποτελέσματα έδειξαν πως το προτεινόμενο δίκτυο παρουσιάζει σημαντικά καλύτερη απόκριση στον θόρυβο (5-58%) εν συγκρίσει με τα ήδη υπάρχοντα μοντέλα ταξινόμησης, βελτιωμένη μάθηση έως και 44%, ενώ έχει και σημαντικά μικρότερες απαιτήσεις υπολογιστικής ισχύος που φθάνουν το 88,5%.

6.3 Εφαρμογή των συνελκτικών νευρωνικών δικτύων (CNN) στην ανίχνευση και κατηγοριοποίηση βλαβών μηχανημάτων με περιστρεφόμενα μέρη

Η *ανάλυση κραδασμών* είναι η πιο καθιερωμένη τεχνική για την παρακολούθηση της κατάστασης ενός μηχανήματος με περιστρεφόμενα μέρη, καθώς τα μοτίβα των κραδασμών και ιδιαίτερα στο *πεδίο των συχνοτήτων (spectra)* διαφέρουν ανάλογα με την κατάσταση του μηχανήματος και την ύπαρξη ή μη βλάβης. Επιπλέον είναι μία μη επεμβατική μέθοδος μέτρησης και παρακολούθησης, που σημαίνει πως μπορεί να εφαρμοσθεί καθώς το μηχάνημα είναι σε πλήρη λειτουργία. Τα ακατέργαστα δεδομένα που συλλέγονται από τους αισθητήρες βρίσκονται στο πεδίο το χρόνου και αποτελούνται από μετρήσεις χρονικά μεταβαλλόμενων σημάτων, όπως η *μετατόπιση (displacement)*, η *ταχύτητα (velocity)* και η *επιτάχυνση (acceleration)*. Η κλασσική μέθοδος ανάλυσης των ακατέργαστων δεδομένων, που εφαρμόζεται ακόμα σήμερα, στηρίζεται είτε στην οπτική ανάλυση, είτε στην εφαρμογή στατιστικών μοντέλων και μαθηματική ανάλυση των επίκτητων μετρήσεων.

Στην οπτική ανάλυση, πραγματοποιείται σύγκριση των μετρήσεων, με προηγούμενες μετρήσεις που λήφθηκαν όσο το συγκεκριμένο μηχάνημα λειτουργούσε χωρίς πρόβλημα. Ωστόσο, αυτό ο τρόπος ανάλυσης θεωρείται αναξιόπιστος για διάφορους λόγους. Για την ανάλυση με την εφαρμογή στατιστικών μοντέλων, τα δεδομένα λειτουργίας συλλέγονται και στη συνέχεια υπολογίζονται συγκεκριμένα χαρακτηριστικά των κυματομορφών που μπορεί να υποδηλώσουν μία βλάβη, συνήθως σε προχωρημένο στάδιο. Για παράδειγμα, συγκεκριμένα στατιστικά μοντέλα όπως η *θεωρία των μέτρων της κύρτωσης (kurtosis)* ή ο *συντελεστής κορυφής (crest factor)*, μπορούν ανιχνεύσουν βλάβη σε ένα σφαιροτριβέα, ενώ με την ανάλυση του *τετραγώνου μέσης τιμής (root-mean square)* της κυματομορφής του χρόνου μπορεί να ανιχνευθεί η μη επαρκής λίπανση των σφαιρών ολίσθησης του σφαιροτριβέα [23].

Ο συνηθέστερος τρόπος για την παρακολούθηση της κατάστασης των μηχανημάτων, είναι ο μετασχηματισμός των *ακατέργαστων δεδομένων* από το *πεδίο*

του χρόνου στο πεδίο των συχνοτήτων, εφαρμόζοντας *μετασχηματισμό Fourier*. Τα διαγράμματα στο πεδίο των συχνοτήτων παρέχουν μία "υπογραφή" της κατάστασης του μηχανήματος και η ανάλυσή τους παρέχει τη δυνατότητα ανίχνευσης και αναγνώρισης βλαβών με μεγαλύτερη αξιοπιστία. Το μεγάλο πλεονέκτημα της ανάλυσης στο πεδίο των συχνοτήτων, είναι ότι η συχνότητα δεν μεταβάλλεται με τον χρόνο, παραμένει σταθερή. Αυτό που μεταβάλλεται σε συνάρτηση με την κατάσταση του μηχανήματος, είναι το πλάτος του παραγόμενου σήματος και οι αρμονικές του συχνότητες. Από την άλλη, η ανίχνευση των συχνοτήτων που υποδεικνύουν εσφαλμένη λειτουργία είναι μία δύσκολη διεργασία, καθώς τις περισσότερες φορές, είτε βρίσκονται πολύ ψηλά, είτε πολύ χαμηλά στο φάσμα και συνήθως είναι "κρυμμένες" στις βασικές ή αρμονικές συχνότητες λειτουργίας του μηχανήματος, είτε έχουν πολύ υψηλή τιμή και εύκολα μπορούν να θεωρηθούν ως θόρυβος και άρα να αγνοηθούν.

Από τα τελευταία, γίνεται κατανοητό πως η μελέτη και ανάλυση των *κραδασμών*, τόσο στο *πεδίο του χρόνου*, όσο και στο *πεδίο των συχνοτήτων*, συνεπάγεται πολύ καλή γνώση της επιστήμης των μαθηματικών και της μηχανολογίας, και άρα πολύ καταρτισμένους μηχανικούς και τεχνικούς με μεγάλη τεχνογνωσία στο συγκεκριμένο αντικείμενο.

6.4 Βαθιά μάθηση και Προγνωστική Συντήρηση

6.4.1 Εισαγωγή, Μονοδιάστατα (1D) – Δισδιάστατα (2D) Συνελικτικά Νευρωνικά Δίκτυα (CNNs)

Η ανάπτυξη και εφαρμογή των μοντέλων της *βαθιάς μάθησης* μετά το 2010 σηματοδότησε μία σημαντική ανακάλυψη στα πρότυπα της μάθησης, τα οποία ως πρότινος κυριαρχούνταν από τις τεχνικές της *μηχανικής*. Οι τεχνικές της *μηχανικής μάθησης* έχουν χρησιμοποιηθεί ευρέως ως τώρα στην κατηγοριοποίηση βλαβών των επαγωγικών κινητήρων. Στηρίζονται στην εξαγωγή χαρακτηριστικών ευαίσθητων στην παρουσία βλαβών και στη συνέχεια στην εκπαίδευση μοντέλων ταξινόμησης ικανά να ανιχνεύσουν μία βλάβη και, ίσως, ταξινομήσουν σε συγκεκριμένο τύπο. Παρόλα αυτά, η εφαρμογή τους παρουσιάζει μία σημαντική δυσκολία στην επιλογή

των κατάλληλων στατιστικών μοντέλων, η οποία περιορίζει σημαντικά την απόδοση των *ταξινομητών (classifiers)*, καθώς στηρίζονται στην χειροκίνητη εξαγωγή των χαρακτηριστικών από τα σήματα εισόδου. Η επιτυχία της εφαρμογής τους στηρίζεται στο αν τα εξαγόμενα χαρακτηριστικά περιλαμβάνουν ικανά διακριτά στοιχεία που περιγράφουν την κατάσταση ορθής ή εσφαλμένης λειτουργίας του μηχανήματος.

Με την εφαρμογή της **βαθιάς μάθησης**, γίνεται προσπάθεια το μοντέλο να εκπαιδευτεί ώστε να αναγνωρίζει διακριτά στοιχεία της λειτουργίας του μηχανήματος απ' ευθείας από το σήμα εισόδου, χωρίς να απαιτείται καμία επεξεργασία ή ανάλυσή του. Στη **βαθιά μάθηση**, το σήμα εισόδου X μετασχηματίζεται, χρησιμοποιώντας μία συνάρτηση T_ϕ , όπου το ϕ αποτελείται από πολλές παραμέτρους του μετασχηματισμού και οι οποίες "εκπαιδεύονται". Ο μετασχηματισμός παρέχει μία νέα παρουσίαση του αρχικού σήματος εισόδου $T_\phi(x)$, η οποία χρησιμοποιείται για την ταξινόμηση F_ϕ και τελικά την παραγωγή της εξόδου Y . [5]. Δύο είναι τα βασικότερα προβλήματα που εμφανίζονται στα μοντέλα **βαθιάς μάθησης**. Τα λεγόμενα *shallow NNs*, με μικρό αριθμό **κρυφών επιπέδων** δεν είναι ικανά να επιλύσουν δύσκολα προβλήματα και απαιτείται η προσθήκη περισσότερων **κρυφών επιπέδων** για να βελτιωθεί η απόδοσή τους. Αντίστοιχα τα μοντέλα με πολλά **κρυφά επίπεδα (deep NNs)** απαιτούν μεγάλα σετ δεδομένων για να εκπαιδευτούν. Αυτό, εγκυμονεί τον κίνδυνο εμφάνισης φαινομένων **overfitting ή gradient vanishing**. Τα **συνελκτικά νευρωνικά δίκτυα**, που στην παρούσα εργασία ασχολούμαστε, έρχονται να δώσουν λύσεις και στα δύο προηγούμενα προβλήματα, κάνοντας την εφαρμογή της **βαθιάς μάθησης** πιο αποδοτική και εύχρηστη σε μία πληθώρα εφαρμογών.

Εν αντιθέσει, τα μοντέλα της **μηχανικής μάθησης**, που συνήθως εκτελούν προεπεξεργασία στα σήματα εισόδου και στη συνέχεια με χειροκίνητες μεθόδους προκύπτουν οι πίνακες χαρακτηριστικών οι οποίοι είναι σταθεροί, τα **συνελκτικά νευρωνικά δίκτυα** παρουσιάζουν ένα μεγάλο συγκριτικό πλεονέκτημα στο πεδίο της **προβλεπτικής συντήρησης** και ανίχνευσης βλαβών, στο ότι συνδυάζουν την **εξαγωγή των χαρακτηριστικών (feature characteristics)** και την **ταξινόμηση (classification)** σε ένα και μόνο μοντέλο απ' ευθείας από το ακατέργαστο σήμα εισόδου. Για το λόγω αυτό ονομάζονται δίκτυα "**end to end**", που σημαίνει πως σε

ένα μόνο δίκτυο περιλαμβάνεται όλη η διαδικασία *εξαγωγής των χαρακτηριστικών*, επεξεργασίας και μείωσης του όγκου των χαρακτηριστικών αυτών (dimension reduction), αλλά και της *ταξινόμησης και κατηγοριοποίησης*. Επομένως, η προσέγγιση αυτή δεν απαιτεί σχεδόν καμία τεχνογνωσία στο συγκεκριμένο αντικείμενο ή πρότερη γνώση του προβλήματος. Επιπλέον, η εφαρμογή των μοντέλων αυτών μπορεί να πραγματοποιηθεί όσο το μηχάνημα είναι σε λειτουργία και άρα η αξιολόγηση της κατάστασης του μηχανήματος γίνεται σε πραγματικό χρόνο.


Η εφαρμογή των *συνελκτικών νευρωνικών δικτύων* εστιάζεται σε δύο βασικούς τομείς, την *ανίχνευση της βλάβης (fault detection)* σε όσο το δυνατόν πιο αρχικό στάδιο, και την *κατάταξη της βλάβης (fault classification)* σε συγκεκριμένο τύπο. Για την ανίχνευση της βλάβης δεν απαιτείται να συλλεχθούν δεδομένα από διάφορες καταστάσεις λειτουργίας, αρκεί το δίκτυο να εκπαιδευθεί με τα δεδομένα της ορθής λειτουργίας. Κάθε εκτροπή από την ομαλή λειτουργία συνεπάγεται αλλαγή του μοτίβου των δεδομένων και άρα πιθανή βλάβη. Για την κατηγοριοποίηση όμως των βλαβών, το δίκτυο θα πρέπει να εκπαιδευτεί πέραν των δεδομένων ορθής λειτουργίας και με δεδομένα που θα υποδηλώνουν την ή τις συγκεκριμένες βλάβες. Μετά την ολοκλήρωση της εκπαίδευσης η ακριβής κατηγοριοποίηση όπως, βλάβες στα inner και outer race ways των σφαιροτριβέων, misalignment, looseness, ελλειπής λίπανση κ.α, είναι εφικτή.

Όπως αναφέρθηκε εκτενώς στο *κεφάλαιο 3*, τα *νευρωνικά συνελκτικά δίκτυα* είναι ένα είδος **Feed-Forward, Multi-Layer τεχνητών νευρωνικών δικτύων**, με ευρεία εφαρμογή στην αναγνώριση και ταξινόμηση εικόνων, αλλά και στην εξεύρεση συγκεκριμένων μοτίβων (όπως για παράδειγμα η ανθρώπινη συμπεριφορά και τα συναισθήματα) μέσα από την ανάλυση δεδομένων φωνής. Καθώς στην αναγνώριση εικόνων τα **φίλτρα kernels** κινούνται σε δύο διαστάσεις στους πίνακες δεδομένων, τα συνελκτικά δίκτυα αναφέρονται ως **δισδιάστατα (2D CNNs)**. Βασικό χαρακτηριστικό των *συνελκτικών δικτύων* είναι η δυνατότητά τους να απομονώνουν, μέσα από μία εικόνα οποιοδήποτε μεγέθους, ή από ένα σήμα οποιασδήποτε διάρκειας, συγκεκριμένα χαρακτηριστικά. Για παράδειγμα, η υπόδειξη μίας βλάβης σε ένα ακατέργαστο σήμα κραδασμού θα μπορούσε να διαφύγει από

οποιοδήποτε έμπειρο αναλυτή, καθώς μοιάζει πολύ με έναν λευκό Γκαουσιανό θόρυβο (White Gaussian Noise). Όταν όμως το σήμα αυτό αποδομηθεί σε πολλές μικρότερες ζώνες, ένα **συνελκτικό δίκτυο** μπορεί να εκπαιδευτεί ώστε να ανιχνεύσει και στη συνέχεια απομονώσει το συγκεκριμένο μοτίβο μέσα στο ακατέργαστο αρχικό αποτύπωμα κραδασμού και τελικά να ανιχνεύσει και να κατηγοριοποιήσει τη βλάβη.


Έως το 2015, για την επεξεργασία και ανάλυση **χρονικά μεταβαλλόμενων σημάτων ή χρονοσειρών**, με την εφαρμογή των **συνελκτικών νευρωνικών δικτύων** ήταν πρώτα απαραίτητη η μετατροπή τους σε δισδιάστατα σήματα. Δυο είναι οι πιο ευρέως χρησιμοποιούμενες μέθοδοι.

- Ο μετασχηματισμός του σήματος κραδασμού σε ένα πίνακα matrix διαστάσεων $m \times n$, το λεγόμενο “vibration image” (*Εικόνα 6-1*) [59]



Εικόνα 6-1 – The Vibration Image composed by a m - n vibration signal matrix [59]

- Η μέτρηση δύο ανεξάρτητων σημάτων κραδασμού στα οποία εφαρμόζεται ο **μετασχηματισμός Fourier** και στη συνέχεια συνενώνονται σε ένα πίνακα matrix διαστάσεων $m \times n$. (*Εικόνα 6-2*) [23]



Εικόνα 6-2 – Dual Fourier Transformed Concatenated Vibration Signals [23]

Και οι δύο προηγούμενοι μέθοδοι απαιτούν, από τη μία, μεγάλη υπολογιστική ισχύ για την εκτέλεση του δικτύου, ιδιαίτερα σε συνθήκες πραγματικού χρόνου, και από την άλλη, δεδομένα πολύ μεγάλων διαστάσεων για την σωστή και ολοκληρωμένη εκπαίδευση του.


Το 2015 οι **Kiranyaz et al** πρότειναν το πρώτο συμπαγές και προσαρμοζόμενο **μονοδιάστατο συνελκτικό δίκτυο (1D CNN)** για την απ' ευθείας επεξεργασία σημάτων ενός καρδιογράφου [26]. Στην επεξεργασία **σημάτων χρονοσειράς (time series)**, η είσοδος, τις περισσότερες φορές, είναι ένα **μονοδιάστατο διάνυσμα (1D)** και ως εκ τούτου τα αντίστοιχα **φίλτρα kernels** κινούνται σε μία διάσταση. Κατά συνέπεια και τα αντίστοιχα **συνελκτικά δίκτυα** ονομάζονται **1D CNNs**. Βασική διαφορά των **1D** από τα **2D CNNs** είναι ότι στα μεν **1D**, τα **φίλτρα kernels**, αλλά και οι **χάρτες χαρακτηριστικών** αντιπροσωπεύονται από **μονοδιάστατες ψηφιοσειρές (arrays)**, ενώ στα **2D** αντιπροσωπεύονται από **δισδιάστατους πίνακες (matrices)**.

Στο χώρο της ανίχνευσης βλαβών με ανάλυση σημάτων κραδασμών, οι ερευνητές έχουν χρησιμοποιήσει διάφορους τύπους σήματος ως είσοδο του δικτύου με σκοπό την ενίσχυση της απόδοσης του. Οι βασικότεροι εκπρόσωποι σημάτων είναι

- **Time domain.** Το σήμα χρησιμοποιείται απ'ευθείας από τον αισθητήρα μέτρησης χωρίς καμία προεπεξεργασία (raw signal)
- **Frequency domain.** Στο ακατέργαστο σήμα εφαρμόζεται ο μετασχηματισμός Fourier (FFT) ώστε κάθε δείγμα να μετασχηματισθεί από το πεδίο του χρόνου (time domain) στο πεδίο των συχνοτήτων (frequency domain).
- **Time Frequency Domain.** Εδώ, στο ακατέργαστο σήμα εφαρμόζεται ο μετασχηματισμός short time Fourier (STFT), ενώ συνήθως χρησιμοποιείται το παράθυρο Hanning.
- **Wavelet domain input.** Στο ακατέργαστο σήμα εισόδου εφαρμόζεται ο μετασχηματισμός **Wavelet**. Εφαρμόζεται συνήθως σε σήματα που η απεικόνισή τους στο πεδίο των συχνοτήτων δεν είναι σταθερή. Είναι παρομοίως με τον μετασχηματισμό **short time Fourier**, με βασική διαφορά ότι το παράθυρο ανάλυσης στον **Wavelet** είναι μεταβαλλόμενο σε σύγκριση με τον **short time Fourier** που είναι σταθερό [86]. Η ανάλυση αυτή απαιτεί πολύ

χρόνο προεπεξεργασίας και χρειάζεται ιδιαίτερη μελέτη στο μήκος του παραθύρου ανάλυσης.

Στην *Εικόνα 6-3* απεικονίζεται η σχηματική διαφορά της ανάλυσης ενός υπερβολικού σήματος (hyperbolic signal) με τις δύο τελευταίες μεθόδους, STFT και WT



Analyzing a hyperbolic chirp signal (left) with two components that vary over time in MATLAB. The short-time Fourier transform (center) does not clearly distinguish the instantaneous frequencies, but the continuous wavelet transform (right) accurately captures them. See the MATLAB code.

Εικόνα 6-3 – STFT – CWT transformation

6.4.2 Κανονικοποίηση – Normalization

Μία ακόμα σημαντική διαδικασία που εφαρμόζεται στο σήμα εισόδου πριν το πρώτο κρυφό επίπεδο συνέλιξης είναι η *κανονικοποίηση* ή αλλιώς *normalization*. Η *κανονικοποίηση* είναι μία κοινή διαδικασία που χρησιμοποιείται ευρέως στην επεξεργασία δεδομένων και στα δίκτυα *τεχνητής νοημοσύνης*. Ουσιαστικά το σήμα εισόδου μετασχηματίζεται, ώστε να έχει *μέση τιμή μηδέν* και *μετατόπιση ίση με ένα (1)* ή *από μείον ένα (-1) έως ένα (1)*. Αυτό είναι ιδιαίτερα χρήσιμο όταν το εύρος τιμών των σημάτων εισόδου δεν είναι το ίδιο. Η διαδικασία της *κανονικοποίησης* μεταξύ των άλλων βοηθάει στην ταχύτερη εκπαίδευση το δικτύου και ιδιαίτερα του πρώτου *κρυφού επιπέδου*. Τρεις είναι οι βασικές μέθοδοι *κανονικοποίησης*:

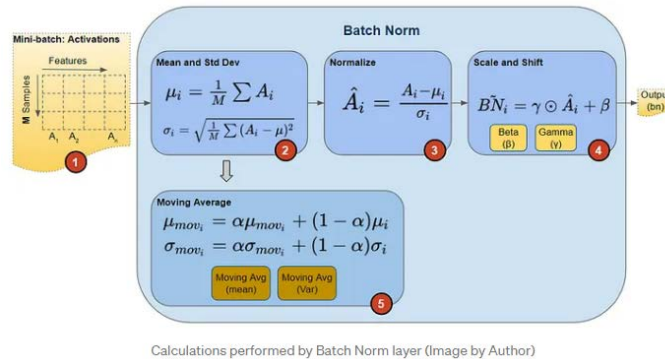
- **Min-Max Norm.** Είναι ο πιο διαδεδομένος τύπος. Η τιμή του σήματος μετασχηματίζεται σε εύρος τιμών 0-1. Ο τύπος μετασχηματισμού δίδεται από την σχέση: $x_n = \frac{x_i - x_{min}}{x_{max} - x_{min}}$, όπου x_n είναι η *κανονικοποιημένη τιμή*, x_i η τιμή του σήματος πριν τον μετασχηματισμό και x_{max} , x_{min} η μέγιστη και ελάχιστη αντίστοιχα τιμή του σήματος εισόδου.

- **[-1...1] Norm.** Η τιμή του σήματος εισόδου μετασχηματίζεται από -1 έως 1 εφαρμόζοντας την ακόλουθη εξίσωση: $x_n = -1 + 2 * \frac{x_i - x_{min}}{x_{max} - x_{min}}$
- **Z-score Normalization.** Χρησιμοποιείται πιο σπάνια και δίδεται από την σχέση: $x_n = \frac{x_i - x_{mean}}{x_{std}}$, όπου x_{mean} είναι η μέση τιμή των τιμών εισόδου και x_{std} η απόκλιση από την τιμή εισόδου. Εδώ το σήμα εισόδου παίρνει την τιμή μηδέν όταν ισούται με την μέση τιμή, αρνητική τιμή όταν είναι < από x_{mean} και θετική τιμή όταν είναι > από x_{mean} .


Η διαδικασία της **κανονικοποίησης**, μπορεί να εφαρμοστεί και μεταξύ της εξόδου ενός επιπέδου και της εισόδου του επόμενου και τότε ονομάζεται **Batch Normalization**. Αυτό που επιτυγχάνει είναι την μετατροπή όλων των τιμών των πινάκων των χαρακτηριστικών που προκύπτουν κατά τη συνέλιξη στο ίδιο εύρος (για παράδειγμα 0-1) και την ίδια μέση τιμή. Επίσης, μειώνει το φαινόμενο του **Internal covariate shifting**, που δεν είναι τίποτε άλλο από την προσπάθεια των κρυφών επιπέδων να προσαρμόσουν τις παραμέτρους τους σε κάθε αλλαγή του σήματος εισόδου. Το φαινόμενο αυτό εντείνεται όσο περισσότερα **επίπεδα** έχει το δίκτυο, με άλλα λόγια όσο πιο **βαθύ** είναι (**deep network**). Το **Batch Normalization** εφαρμόζεται για την επιτάχυνση της διαδικασίας εκπαίδευσης και την χρήση υψηλότερων **ρυθμών εκμάθησης**. Συναντάται αμέσως μετά τη διαδικασία της **συνέλιξης** και πριν την εφαρμογή της **συνάρτησης ενεργοποίησης** [63].

Η εφαρμογή του **Batch Normalization**, προσθέτει στο δίκτυο ένα ακόμα **επίπεδο** και δύο ακόμα παραμέτρους που πρέπει να υπολογισθούν για κάθε νέο **batch norm layer**. Οι παράμετροι αυτοί είναι οι β και γ , για την μετατόπιση και μετατροπή της κλίμακας των τιμών του διανύσματος εξόδου του προηγούμενου επιπέδου.

Στην **Εικόνα 6-4** φαίνονται οι υπολογισμοί που εκτελούνται κατά την εφαρμογή του **Batch Normalization** με σε ένα **τεχνητό νευρωνικό δίκτυο**, ενώ στην **Εικόνα 6-5** η παραστατική απεικόνισή του [64].



Εικόνα 6-4 – Batch normalization calculations [64]




Εικόνα 6-5 - Batch Normalization Lay out [64]

6.4.3 Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου (CNN)

Στην πρόβλεψη και κατηγοριοποίηση βλαβών βασισμένη σε μετρήσεις κραδασμών, χρησιμοποιούνται πλέον, κυρίως **μονοδιάστατα συνελκτικά νευρωνικά δίκτυα (1D CNN)** για την ανάλυση των δεδομένων και την εξαγωγή και κατηγοριοποίηση των μοτίβων λειτουργίας. Στην [Εικόνα 6-6](#) φαίνεται μία χαρακτηριστική αρχιτεκτονική ενός **συνελκτικού νευρωνικού δικτύου**. Αποτελείται από έναν αριθμό συνδεδεμένων σε μορφή καταρράκτη (cascade) **επίπεδων συνέλιξης**, ενώ ακολουθούν **επίπεδα ομαδοποίησης** και όσο πλησιάζουμε προς την έξοδο, **επίπεδα πλήρους διασύνδεσης**. Η είσοδος του αποτελείται από ένα αναλογικό σήμα, για παράδειγμα το σήμα ενός αισθητήρα επιτάχυνσης για την μέτρηση κραδασμών. Στο επίπεδο συνέλιξης πραγματοποιείται η γραμμική πράξη του εσωτερικού γινόμενο δύο πινάκων, ο ένας πίνακας αποτελείται από τις αναπροσαρμοζόμενες μεταβλητές, τα **φίλτρα kernels** και ο άλλος από τον πίνακα με τις τιμές εισόδου του κάθε επιπέδου. Η διαδικασία της συνέλιξης αναλύεται στην [παράγραφο 3.3.2](#)



Κατά τη διάρκεια της *συνέλιξης* χρησιμοποιούνται τα ίδια *βάρη* για την εξαγωγή όλων των *πινάκων χαρακτηριστικών* κάθε *επιπέδου* (*parameter sharing παράγραφος 3.3.5*). Αυτό μειώνει σημαντικά τις παραμέτρους του δικτύου και επομένως απλοποιεί τη διαδικασία της εκπαίδευσής του. Η έξοδος του *επιπέδου* της *συνέλιξης* είναι ένας *τανυστής*, που αποτελείται από *πολλαπλούς πίνακες* (*matrices*) που ονομάζονται *χάρτες χαρακτηριστικών* (*feature maps*). Οι νέοι αυτοί πίνακες εισάγονται ως είσοδος σε νέα πεδία συνέλιξης όπου εφαρμόζεται *υποδειγματοληψία* μέσω της *ομαδοποίησης* με την εφαρμογή νέων *φίλτρων kernels*, μικρότερων πάντα διαστάσεων από αυτά που χρησιμοποιούνται για την συνέλιξη. Οι κυριότεροι μέθοδοι *ομαδοποίησης* είναι οι *MaxPooling*, *GlobalAvgPooling* και *GlobalMaxPooling*, όπως αναφέρθηκαν στην *παράγραφο 3.5*. Τα *φίλτρα kernels* αναπροσαρμόζονται με τη μέθοδο της *οπίσθιας διάδοσης*. Σε κάθε *επίπεδο συνέλιξης* εφαρμόζεται μία *συνάρτηση ενεργοποίησης*, με μοναδικό σκοπό τη μετατροπή των γραμμικών πινάκων δεδομένων σε μη γραμμικούς. Κατά κύριο λόγο, στα *συνελικτικά νευρωνικά δίκτυα* εφαρμόζεται η συνάρτηση *RELU*, η οποία ακυρώνει όλες τις αρνητικές τιμές, επιτρέποντας να ενεργοποιηθούν μόνο οι θετικές.



Εικόνα 6-6- Αρχιτεκτονική Μονοδιάστατου Συνελικτικού Δικτύου (1D CNN) [25]

Στο τέλος του δικτύου οι *πίνακες των χαρακτηριστικών* μετατρέπονται σε *μονοδιάστατα διανύσματα δεδομένων (1D feature vectors)* και εισάγονται στα *επίπεδα πλήρους σύνδεσης*, όπου εφαρμόζονται *συναρτήσεις ταξινόμησης (classification functions)* με σκοπό την *κατηγοριοποίηση* της εισόδου σε συγκεκριμένη έξοδο. Τα επίπεδα αυτά είναι παρόμοια με τα αντίστοιχα των *συμβατικών τεχνικών νευρωνικών δικτύων*. Έστω ότι το δίκτυο μπορεί να *κατηγοριοποιήσει N classes*. Τότε το διάνυσμα εξόδου θα έχει διάσταση N και κάθε στοιχείο του διανύσματος θα μπορεί να πάρει την τιμή 0 ή 1. Επιπλέον μόνο ένα διάνυσμα μπορεί να έχει την τιμή 1, αυτό με την μεγαλύτερη *πιθανότητα διασποράς*. Για παράδειγμα, σε ένα πρόβλημα με 3 πιθανές καταστάσεις (μη βλάβη, βλάβη στο inner race ring, βλάβη στο outer race ring), αυτές θα εμφανίζονταν ως:

Μη βλάβη	Βλάβη στο inner race ring	Βλάβη στο outer race ring
1	0	0
0	1	0
0	0	1

Ο συνηθέστερος τρόπος ταξινόμησης είναι ο *hot encoder*, ο οποίος συνήθως χρησιμοποιείται για *συνάρτηση ενεργοποίησης* την *softmax*. Με την εφαρμογή της, υπολογίζεται η πιθανότητα διασποράς μίας πιθανής τιμής μέσα σε ένα πιθανό σύνολο τιμών και τελικά η έξοδος παίρνει την τιμή με την μεγαλύτερη πιθανότητα. Το μεγαλύτερο πλεονέκτημα της συνάρτησης ενεργοποίησης *softmax* ([παράγραφος 3.6](#)) είναι ότι το εύρος τιμών είναι από μηδέν ως ένα και το άθροισμα όλων των πιθανοτήτων είναι 1. Ο αριθμός των συνδυασμών των *επιπέδων συνέλιξης, συνάρτησης ενεργοποίησης και ομαδοποίησης*, εξαρτάται από την εφαρμογή. Οι παράμετροι που χαρακτηρίζουν ένα *μονοδιάστατο συνελκτικό δίκτυο* είναι:

1. Αριθμός των *συνελκτικών (CNN)* και *MLP (Multi-Layer Perceptron) επιπέδων*. Στην [Εικόνα 6-6](#) για παράδειγμα, υπάρχουν 3 CNN layers και 2 MLP
2. Το μέγεθος του *φίλτρου συνέλιξης (Kernel)*, για κάθε επίπεδο συνέλιξης.

3. Ο συντελεστής *ομαδοποίησης (pooling size)* για κάθε ένα από τα επίπεδα συνέλιξης
4. Η επιλογή του τρόπου *ομαδοποίησης (pooling)*, καθώς και των *συναρτήσεων ενεργοποίησης (activation function)*
5. Η επιλογή του αριθμού των πλήρως *συνδεδεμένων επιπέδων (fully connected layers)*, καθώς και των *συναρτήσεων ταξινόμησης (activation function)* για την έξοδο του δικτύου.
6. Ο αριθμός των νευρώνων της εξόδου που θα είναι ίσος με τον *αριθμό των κλάσεων ταξινόμησης*.

Η εκπαίδευση του *συνελκτικού νευρωνικού δικτύου* πραγματοποιείται μία φορά. Όπως έχουμε ήδη προαναφέρει, τα *συνελκτικά νευρωνικά δίκτυα* εκπαιδεύονται με την *εποπτευόμενη μέθοδο*, που σημαίνει ότι τροφοδοτούνται με *σετ δεδομένων* των οποίων η κατάσταση, το αποτέλεσμα δηλαδή, είναι εκ των προτέρων γνωστό. Είναι μία από τις πιο σημαντικές διεργασίες για την απόδοση και αποτελεσματικότητα του δικτύου. Η επιλογή των δεδομένων πρέπει να γίνει με τέτοιο τρόπο ώστε το δίκτυο να αποκτήσει την απαραίτητη γνώση και ικανότητα να εξάγει τα απαραίτητα *χαρακτηριστικά στοιχεία* από το στο σήμα εισόδου (**features extraction**), τα οποία θα το οδηγήσουν να *ταξινομήσει* κατάλληλα (**classification**) το σήμα εισόδου σε μία από τις διαθέσιμες *κατηγορίες (classes)* στην έξοδο του δικτύου.

Απότερος σκοπός της εκπαίδευσης του δικτύου, δεν είναι άλλος από την εύρεση των *κατάλληλων τιμών των παραμέτρων (optimization)* που θα οδηγήσουν στην ελαχιστοποίηση της διαφοράς μεταξύ της εξόδου και της εισόδου του δικτύου. Ο πιο διαδεδομένος τρόπος υπολογισμού των παραμέτρων είναι η *οπίσθια διάδοση*, όπου μέσω της *συνάρτησης απώλειας (Loss Function)*, υπολογίζεται η *ασυμβατότητα* μεταξύ της γνωστής εξόδου του μοντέλου για ένα συγκεκριμένο σήμα εισόδου και του αποτελέσματος που το ίδιο το δίκτυο έχει καταλήξει. Στη συνέχεια, χρησιμοποιείται η μέθοδος της *ταχύτερης καθόδου (gradient descent)* για την βελτιστοποίηση του δικτύου.

Με βάση τον *Kolar.D etal (2020) [27]*, ένας πλήρης κύκλος αναπροσαρμογής των παραμέτρων κατά τη διαδικασία εκπαίδευσης, αποτελείται από τα παρακάτω τρία στάδια:

1. Feed forward pass
2. Back propagation pass
3. Gradient Application

Για την σωστή και αποτελεσματική εκπαίδευση του δικτύου, τρεις είναι οι βασικές παράμετροι που πρέπει να προσδιορισθούν σωστά: **Xiaojie Guo (2016) [55]**

- Ο **ρυθμός εκπαίδευσης (learning rate)**. Μία εκ των σημαντικότερων παραμέτρων, καθώς υψηλός ρυθμός εκπαίδευσης μπορεί να αποτρέψει την βελτιστοποίηση της απόδοσης του δικτύου. Αντίθετα, ένας χαμηλός ρυθμός εκπαίδευσης μπορεί να οδηγήσει και τελικά να εγκλωβίσει το μοντέλο σε ένα τοπικό ελάχιστο. Μέχρι σήμερα δεν υπάρχει σαφής τρόπος υπολογισμού του βέλτιστου ρυθμού εκπαίδευσης. Στη βιβλιογραφία ο ρυθμός εκπαίδευσης επιλέγεται ύστερα από πολλαπλές δοκιμές ή εξαρτάται από την εμπειρία του κάθε ερευνητή.
- **Batch size**, που ορίζεται το μέγεθος του αριθμού των δεδομένων που τροφοδοτούνται στο δίκτυο κατά τη διαδικασία της εκπαίδευσης. Καθώς ο αριθμός των δεδομένων εκπαίδευσης είναι πολύ μεγάλος, αν αυτά, τροφοδοτηθούν ταυτόχρονα στο δίκτυο, τότε ο χρόνος εκπαίδευσης θα είναι τεράστιος και παράλληλα θα χρειαστεί μεγάλη υπολογιστική ισχύς για την επεξεργασία των δεδομένων. Έτσι, το set των δεδομένων εκπαίδευσης χωρίζεται σε μικρότερα τμήματα συγκεκριμένου μήκους (batch size), τα οποία τροφοδοτούν το δίκτυο σταδιακά.
- Τρίτη και τελευταία σημαντική παράμετρος είναι ο αριθμός των **φίλτρων συνέλιξης (number of kernels)** για κάθε επίπεδο. Ο αριθμός των **kernels** στην ουσία καθορίζει τον αριθμό των **χαρακτηριστικών** που το μοντέλο καλείται να αναγνωρίσει στο σήμα εισόδου. Μεγαλύτερος αριθμός **kernels** συνεπάγεται μεγαλύτερη ικανότητα εξαγωγής χαρακτηριστικών, στην πράξη όμως αυτό

σημαίνει και πολυπλοκότερο μοντέλο με περισσότερες παραμέτρους που πρέπει να υπολογιστούν και τελικά απαίτηση για μεγαλύτερη υπολογιστική ισχύ.

Η έρευνα έχει δείξει πως η τιμή των παραπάνω παραμέτρων, καθώς και ο συνδυασμός αυτών, έχει μεγάλη επίδραση στην απόδοση του δικτύου. Επομένως, το δίκτυο, θα πρέπει να δοκιμάζεται με διαφορετικούς συνδυασμούς ώστε να βρεθεί ο βέλτιστος εκείνος που θα οδηγήσει το μοντέλο στην καλύτερη δυνατή απόδοση.

Ολοκληρώνοντας την παράγραφο αυτή, παραθέτουμε τον τρόπο προετοιμασίας των δεδομένων εκπαίδευσης ενός *μονοδιάστατου συνελκτικού δικτύου* ανίχνευσης και κατηγοριοποίησης βλαβών σε σφαιροτριβείς, όπως το παρουσιάζουν στην αντίστοιχη εργασία τους οι **Abdeljaber.O etal [1]**. Σκοπός της περιγραφής αυτής είναι να κατανοήσει ο αναγνώστης τη δομή των δεδομένων που χρειάζεται να περιέχει ένα *σετ εκπαίδευσης* ώστε μετά την εφαρμογή του κατά την διαδικασία της εκπαίδευσης σε ένα *συνελκτικό νευρωνικό δίκτυο*, αυτό να είναι αποτελεσματικό κατηγοριοποιώντας όσο το δυνατόν πιο σωστά κάθε σήμα εισόδου με το οποίο τροφοδοτείται.

Για να εκπαιδεύσουν το δίκτυο τους, οι **Abdeljaber.O etal [1]** δημιούργησαν τρία σετ δεδομένων.

- Το πρώτο (**C1**) ανταποκρίνεται σε σήματα κραδασμών που δεν περιλαμβάνουν κάποια βλάβη. Το δεύτερο (**C2**) περιλαμβάνει σήματα κραδασμών από σφαιροτριβείς με σοβαρή βλάβη στον εσωτερικό δακτύλιο (inner race) των σφαιροτριβέων και το τρίτο σετ δεδομένων (**C3**) περιλαμβάνει σήματα κραδασμών από σφαιροτριβείς με σοβαρή βλάβη στον εξωτερικό δακτύλιο (Outer race).
- Στη συνέχεια τα δεδομένα αυτά χωρίζονται σε έναν προκαθορισμένο αριθμό data frames χωρίς να υπάρχει επικάλυψη μεταξύ τους.

$$C_1 = [C_{1,1}, C_{1,2}, C_{1,3}, \dots, C_{1,N_1}]$$

$$C_2 = [C_{2,1}, C_{2,2}, C_{2,3}, \dots, C_{2,N_2}]$$

$$C_3 = [C_{3,1}, C_{3,2}, C_{3,3}, \dots, C_{3,N_3}], \text{ όπου } N_{1,2,3} \text{ υποδηλώνουν τον αριθμό των}$$

frames σε κάθε ένα εκ των data set $C_{1,2,3}$ αντίστοιχα

- Κατόπιν τα data frames στα C_1, C_2, C_3 ομαδοποιούνται σε τέσσερις νέες κατηγορίες, κάθε μία εκ των οποίων περιλαμβάνει δεδομένα μη εσφαλμένων σφαιροτριβέων, αλλά

και δεδομένα σφαιροτριβέων με βλάβη, αλλά όχι αυτή που θέλουμε το δίκτυο να ανιχνεύσει. Πιο αναλυτικά, τα δεδομένα ομαδοποιούνται ως ακολούθως:

$$U_i = [C_{1,1}, C_{1,2}, \dots, C_{1,N1}, C_{3,1}, C_{3,2}, \dots, C_{3,N3}]$$

$$D_i = [C_{2,1}, C_{2,2}, \dots, C_{2,N2}]$$

$$U_o = [C_{1,1}, C_{1,2}, \dots, C_{1,N1}, C_{2,1}, C_{2,2}, \dots, C_{2,N2}]$$

$$D_o = [C_{3,1}, C_{3,2}, \dots, C_{3,N3}], \text{ όπου, το } U_i \text{ περιλαμβάνει δεδομένα όπου το}$$

inner ring δεν έχει βλάβη. Αντίστοιχα το U_o , δεδομένα όπου το outer δεν έχει βλάβη.

Αναλογικά, το set δεδομένων D_i , περιλαμβάνει μετρήσεις από σφαιροτριβείς με

εσφαλμένο το inner ring και το D_o , μετρήσεις από σφαιροτριβείς με εσφαλμένο το

outer ring.

- Τέλος τα δεδομένα μετασχηματίζονται σε τιμές με εύρος $-1 \dots 1$ (normalization) και στη συνέχεια ανακατεύονται τυχαία ώστε το κάθε νέο set να περιέχει όλες τις κατηγορίες και επομένως η εκπαίδευση να είναι πιο αποτελεσματική.

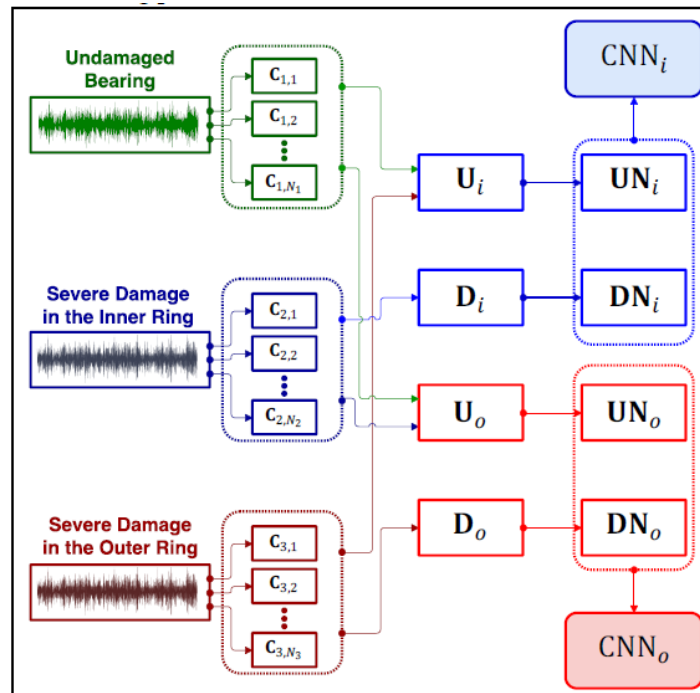
$$UN_i = [UN_{i,1}, UN_{i,2}, UN_{i,N1+N3}]$$

$$DN_i = [DN_{i,1}, DN_{i,2}, DN_{i,N2}]$$

$$UN_o = [UN_{i,1}, UN_{i,2}, UN_{i,N1+N2}]$$

$$DN_o = [DN_{i,1}, DN_{i,2}, DN_{i,N3}]$$

Από τα παραπάνω, τα δεδομένα UN_i και DN_i θα χρησιμοποιηθούν για την εκπαίδευση ενός ταξινομητή που θα ανιχνεύει βλάβες στον εσωτερικό δακτύλιο του σφαιροτριβέα και αντίστοιχα τα UN_o και DN_o θα χρησιμοποιηθούν για την εκπαίδευση ενός ταξινομητή που θα ανιχνεύει βλάβες στον εξωτερικό δακτύλιο. Με την σωστή εκπαίδευση ο κάθε ένας ταξινομητής θα αγνοεί τις βλάβες του άλλου. Στην [Εικόνα 6](#)- φαίνεται παραστατικά η παραπάνω διαδικασία.



Εικόνα 6-7 – Training DataSet of 1D Convolutional Network [1]

7. Σχεδίαση και Ανάπτυξη Συνελικτικού Νευρωνικού Δικτύου Ανίχνευσης Βλαβών Σφαιροτριβέων

7.1 Εισαγωγή


Στα προηγούμενα κεφάλαια κάναμε μία βιβλιογραφική επισκόπηση και είδαμε το θεωρητικό υπόβαθρό που καλύπτει την *διαγνωστική συντήρηση (condition based maintenance)* και την ανίχνευση βλαβών μηχανημάτων με περιστρεφόμενα μέρη. Επίσης είδαμε την επίδραση που έχει η *βαθιά μάθηση* και πιο συγκεκριμένα τα *συνελικτικά νευρωνικά δίκτυα* στην εξέλιξη και αυτοματοποίηση της *διαγνωστικής συντήρησης*.

Στο κεφάλαιο αυτό, θα παρουσιάσουμε ένα μονοδιάστατο νευρωνικό συνελικτικό δίκτυο και θα δούμε την απόκρισή του στη διάγνωση βλαβών σφαιροτριβέων. Για την εκπαίδευση και δοκιμή του δικτύου χρησιμοποιήσαμε το σετ δεδομένων που παρέχεται από το *Case Western Reserve University (CWRU) Bearing Data Center*. Το συγκεκριμένο σετ δεδομένων έχει χρησιμοποιηθεί ευρέως από πολλούς μελετητές και συγγραφείς για τη μελέτη και διάγνωση βλαβών

σφαιροτριβέων, τόσο με παραδοσιακές μεθόδους ανάλυσης σημάτων κραδασμών, όσο και με τη χρήση μοντέλων μηχανικής και βαθιάς μάθησης.

7.2 Παρουσίαση του μοντέλου μέτρησης κραδασμών.

Η βασική δομή του εργαστηριακού μοντέλου που χρησιμοποιήθηκε από το *CWRU* για τη λήψη των μετρήσεων των κραδασμών, φαίνεται στην *Εικόνα 7-1* [52]



Εικόνα 7-1 – *CWRU* - Bearing Data Center – Test Rig [52]

Αποτελείται από έναν κινητήρα 2 ίππων (2hp), έναν αισθητήρα μέτρησης ροπής (torque transducer), και ένα δυναμόμετρο για την προσομοίωση του φορτίου. Οι *σφαιροτριβείς (ball bearings)*, με τους οποίους εκτελέστηκαν οι δοκιμές και οι μετρήσεις, υποστηρίζουν τον άξονα του κινητήρα, τόσο από την πλευρά του φορτίου (*DE*), όσο και από την πλευρά του ανεμιστήρα του κινητήρα (*NDE*)

Βλάβες διαστάσεων από *0.18* έως *0.71mm (7 - 40 mils)* παρήχθησαν στις σφαίρες (*balls*), αλλά και στους εσωτερικούς και εξωτερικούς δρόμους ολίσθησης (*inner & outer raceways*) των *σφαιροτριβέων (ball bearings)* χρησιμοποιώντας ηλεκτρομαγνητική εκκένωση. Οι σφαιροτριβείς που χρησιμοποιήθηκαν είναι οι *6205-2RS JEM deep groove* για το *DE* και *6203-2RS JEM deep groove* για το *NDE* της

εταιρίας *SKF* (περισσότερες τεχνικές λεπτομέρειες για τους σφαιροτριβείς ο αναγνώστης μπορεί να βρει στην ιστοσελίδα του *CWRU*) [87].

Οι μετρήσεις κραδασμών πραγματοποιήθηκαν με *αισθητήρες επιτάχυνσης (accelerometers)*, που τοποθετήθηκαν κάθετα (*vertical – radial plan*) τόσο στο *DE* όσο και στο *NDE* του κινητήρα. Η δειγματοληψία των μετρήσεων έγινε στα *12 και 48 Khz*. Συνολικά παρήχθησαν *161 αρχεία δεδομένων matlab*, ομαδοποιημένα σε τέσσερις κατηγορίες *48Khz No fault, 48Khz DE faults, 12Khz DE* και *NDE faults*. Στον *Πίνακα 9-1* [87] παρουσιάζεται η σύνοψη των σετ δεδομένων.

Αξίζει να σημειώσουμε πως για το συγκεκριμένο σετ δεδομένων η έννοια του “φορτίου” είναι χωρίς ουσιαστικό νόημα στη μέτρηση των κραδασμών, καθώς προέρχεται από έναν ηλεκτρομαγνητικό μηχανισμό και όχι πραγματικό φορτίο, όπως για παράδειγμα ένας μειωτήρας ή ένας ανεμιστήρας, ώστε η ροπή που παράγεται από τον κινητήρα να μετατρέπεται σε ακτινικό φορτίο (*radial load*) στους σφαιροτριβείς. Εδώ, η επιβολή του φορτίου επιδρά κυρίως στην ταχύτητα του κινητήρα, η οποία μειώνεται σχεδόν κατά 4% στην περίπτωση μέγιστου φορτίου [52]. Επίσης, στον *Πίνακα 9-1*, ο αναγνώστης μπορεί να παρατηρήσει πως για τις βλάβες στον εξωτερικό δρόμο ολίσθησης (*outer raceway*), υπάρχουν τρεις μετρήσεις με σήμανση *@3, @6* και *@12*. Αυτό δηλώνει την σχετική θέση της μέτρησης ως προς τη θέση του σφαιροτριβέα. Οι μετρήσεις εξωτερικό δρόμο ολίσθησης (*outer raceway*) πραγματοποιήθηκαν σε τρεις διευθύνσεις καθώς το πιθανό σημείο βλάβης είναι σταθερό (δεν περιστρέφεται μαζί με τον σφαιροτριβέα) και επομένως έχει άμεσο αντίκτυπο στην απόκριση κραδασμών του συστήματος κινητήρα – σφαιροτριβέων.

7.3 Παρουσίαση Δεδομένων Εκπαίδευσης – Δοκιμής

Όπως είδαμε στην προηγούμενη παράγραφο, τα δεδομένα μέτρησης κραδασμών που διατίθενται από το *CWRU* αποτελούνται από 161 αρχεία, κάθε ένα εκ των οποίων περιέχει από 65 έως 450 χιλιάδες καταγραφές, οι οποίες περιγράφουν μία συγκεκριμένη κατάσταση του σφαιροτριβέα. Κάθε αρχείο αποτελείται από τρεις στήλες. Μέτρηση κραδασμών στο *DE* του κινητήρα, μέτρηση κραδασμών στο *NDE* του κινητήρα και στροφές.

Για την *εκπαίδευση (training)* και *επιβεβαίωση (validation)* του δικτύου χρησιμοποιήσαμε τα δεδομένα που προκύπτουν από τη δειγματοληψία των **48Khz** και μόνο τις μετρήσεις που αφορούν το *drive end (DE)* του κινητήρα. Για να γενικεύσουμε την *εκπαίδευση (training)* του δικτύου, αλλά και για να το *δοκιμάσουμε (test)* με νέα, “φρέσκα” δεδομένα, φτιάξαμε ένα σετ δεδομένων, το οποίο συμπεριλαμβάνει τις μετρήσεις για *φορτία 0* και *1 Hp*, και για όλες τις βλάβες (*inner-race, outer-race 3Hr, 6Hr και 12Hr, BA, normal*), μεγέθους **7, 14** και **21mils**. Προέκυψε ένα αρχείο μορφής **.csv** το οποίο περιέχει 4,544,767 μετρήσεις, 2 στηλών. Η πρώτη στήλη περιέχει την μέτρηση κραδασμού που προκύπτει από τον αισθητήρα επιτάχυνσης και η δεύτερη στήλη την αντίστοιχη βλάβη που η μέτρηση υποδηλώνει. Στον **Πίνακα 7-1** έχουμε συνοψίσει τα περιεχόμενα του νέου σετ δεδομένων *εκπαίδευσης (training)* και *επαλήθευσης (validation)*.

Επίσης, εδώ, είναι σημαντικό να αναφέρουμε πως οι αρχικοί πίνακες δεδομένων χωρίστηκαν στη μέση. Έτσι από κάθε πίνακα δεδομένων το 50% χρησιμοποιήθηκε για την εκπαίδευση και επαλήθευση του δικτύου, ενώ το υπόλοιπο 50% χρησιμοποιήθηκε αργότερα για τη δοκιμή του. Έτσι, το δίκτυο κατά τη διαδικασία της δοκιμής τροφοδοτήθηκε με εντελώς νέα, άγνωστα δεδομένα.

Κατά τη διαδικασία της *εκπαίδευσης (training)* και *επιβεβαίωσης (validation)*, τα δεδομένα χωρίστηκαν σε **70/30**. Δηλαδή, το 70% χρησιμοποιήθηκε για την *εκπαίδευση (training)* του δικτύου και το 30% για την *επαλήθευσή του (validation)*.


Πίνακας 7-1 Σετ δεδομένων 48Khz – 0 και 1Hp – All Faults

Όνομα Αρχείου: Training_Evaluation_Data_Set			Τύπος Αρχείο: csv Μέγεθος: 122.778Mb
Μέγεθος	Βλάβη	Φορτίο (Hp)	Αριθμός Μετρήσεων
7	BA	0	122369
7	IR	0	121970
7	OR1	0	121770

7	OR2	0	62300
7	OR3	0	64980
7	BA	1	243690
7	IR	1	243110
7	OR1	1	243400
7	OR2	1	242500
7	OR3	1	241000
14	BA	0	124570
14	IR	0	31891
14	OR1	0	122570
14	BA	1	243110
14	OR1	1	242200
21	BA	0	121970
21	IR	0	122171
21	OR1	0	123150
21	OR2	0	64300
21	OR3	0	62280
21	BA	1	243000
21	IR	1	242500
21	OR1	1	244500
21	OR2	1	244300
21	OR3	1	243100
	Normal	0	120120
	Normal	1	241949

Στην **Εικόνα 7-2** φαίνεται η γραφική απεικόνιση των ακατέργαστων δεδομένων κραδασμών, για λειτουργία σφαιροτριβέα **χωρίς βλάβη και φορτίο**, καθώς και το **αποτύπωμα** ενός σφαιροτριβέα με βλάβη **14mils** στον **εσωτερικό διάδρομο (inner raceway)** για φορτίο **0Hp**. Από την απεικόνιση αυτή γίνεται άμεσα αντιληπτή η διαφορά του αποτυπώματος κραδασμού ως προς το πλάτος, αλλά και τη μορφή του σήματος επιτάχυνσης, σε περίπτωση ορθής και εσφαλμένης λειτουργίας. Αυτά ακριβώς τα ιδιαίτερα χαρακτηριστικά (features) θα προσπαθήσει να διακρίνει το

μοντέλο ώστε να μπορεί να προβλέψει την λειτουργική κατάσταση ενός σφαιροτριβέα.



Εικόνα 7-2 - Γραφική Απεικόνιση Σετ Δεδομένων 0N και 14-0-IR

Περισσότερα διαγράμματα για το σετ δεδομένων που χρησιμοποιήσαμε παραθέτουμε στο [παράρτημα 9.2](#)

Στην [Εικόνα 7-3](#) απεικονίζεται η διασπορά (scatter plot) των μετρήσεων ως προς το μέγιστο πλάτος και το σύνολο των δεδομένων. Εύκολα παρατηρούμε πως οι μετρήσεις που προκύπτουν από τη λειτουργία των σφαιροτριβέων χωρίς βλάβη (N) έχουν το μικρότερο πλάτος, ενώ αυτές που περιγράφουν βλάβη στον εξωτερικό διάδρομο (OR), το μεγαλύτερο πλάτος μέτρησης. Τέλος στην [Εικόνα 7-4](#), φαίνεται ένα διάγραμμα τύπου πίτας (pie chart) με την διασπορά των δεδομένων, ανά κατηγορία βλάβης. Στην εικόνα αυτή φαίνεται, πως οι μετρήσεις που αφορούν φορτίο 1 Hp είναι σχεδόν διπλάσιες σε αριθμό αυτών που πάρθηκαν για μηδενικό φορτίο.

7.4 Παρουσίαση του συνελκτικού νευρωνικού μοντέλου

Στο [κεφάλαιο 3](#) κάναμε μία αρκετά αναλυτική περιγραφή των *συνελκτικών νευρωνικών δικτύων*, ενώ στο [κεφάλαιο 6](#) εξειδικεύσαμε την εφαρμογή τους στον τομέα της *προγνωστικής συντήρησης* και περιγράψαμε την αρχιτεκτονική των *μονοδιάστατων συνελκτικών δικτύων (1D-CNN)*.

Στην ενότητα αυτή θα παρουσιάσουμε την αρχιτεκτονική του δικτύου με το οποίο πραγματοποιήσαμε τις δοκιμές ανίχνευσης βλαβών σφαιροτριβέων, χρησιμοποιώντας το σετ δεδομένων που περιγράψαμε στην προηγούμενη παράγραφο. Ο υπολογιστής που χρησιμοποιήθηκε για τη δημιουργία, εκπαίδευση και δοκιμή του δικτύου διαθέτει επεξεργαστή *intel i7-11gen* στα *2,8Ghz*, με μνήμη *DDR3 -32 GB* στα *3200Mhz*. Το δίκτυο προγραμματίστηκε σε γλώσσα *Python* σε περιβάλλον *Anaconda/Jupyter* και χρησιμοποιήθηκαν οι βιβλιοθήκες *Tensor Flow* και *Pytorch*.

Το δίκτυο αυτό, από αριστερά προς τα δεξιά μπορεί να χωριστεί σε τρία μέρη. *Είσοδος (Input)*, *εξαγωγή πινάκων χαρακτηριστικών (Features Extraction)* και *κατηγοριοποίηση (classification)*.

- **Είσοδος – Input Layer**


Η είσοδος του δικτύου αποτελείται από ένα *επίπεδο*, το οποίο τροφοδοτείται με το *ακατέργαστο σήμα χρονοσειράς* της μέτρησης *κραδασμού*. Όπως είδαμε στην *παράγραφο 7.3*, τα αρχεία με τα οποία τροφοδοτούμε το δίκτυο αποτελούνται από ένα τεράστιο όγκο δεδομένων, η άμεση τροφοδότηση των οποίων θα απαιτούσε για την εκπαίδευση του δικτύου μεγάλη υπολογιστική ισχύ, ενώ το δίκτυο θα γινόταν αργό και αναποτελεσματικό. Για το λόγο αυτό, χρησιμοποιώντας τη μέθοδο του *windowing* χωρίσαμε τα δεδομένα σε μικρότερα τμήματα (*segmenting*). Κατόπιν τα νέα, μικρότερα σετ δεδομένων τροφοδοτούνται στην είσοδο του πρώτου συνελκτικού επιπέδου. Πώς όμως πραγματοποιείται η *τμηματοποίηση (segmenting)* του σήματος εισόδου; Για την περιγραφή της διαδικασίας αυτής θα εισάγουμε δύο νέους όρους, το *μέγεθος παραθύρου (window length)* και την *ολίσθηση (stride)*.

Έστω το σήμα *κραδασμού (acceleration)* που αντιστοιχεί σε βλάβη του εξωτερικού διαδρόμου (*outer-race*) μεγέθους *7Mils*. Όπως προκύπτει από τον *Πίνακα 7-2* το σήμα αυτό αποτελείται από *62300 μετρήσεις*.

Έστω επίσης, ότι από το σήμα αυτό ξεχωρίζουμε ένα μικρότερο σετ μετρήσεων το μήκος του οποίου καθορίζεται από το επιλεγμένο μήκος παραθύρου (*window length*). Κατόπιν το παράθυρο αυτό “*ολισθαίνει*” προς τα δεξιά κατά *μήκος x*, τόσο ώστε το νέο “*mini*” σετ δεδομένων να περιέχει και ένα μέρος του προηγούμενου σετ. Το *μήκος* της *ολίσθησης* ονομάζεται *stride*. Η διαδικασία επαναλαμβάνεται για όλη τη *χρονοσειρά*. Έτσι, προκύπτουν νέα μικρότερα, αλλά περισσότερα σετ δεδομένων (*batches*) τα οποία το δίκτυο είναι ευκολότερο να διαχειριστεί.

Ιδιαίτερη προσοχή πρέπει δοθεί στο *μήκος του παραθύρου*, αλλά και της *ολίσθησης*. Ένα μεγάλο *μήκος παραθύρου* μπορεί να περιέχει *άχρηστη* πληροφορία, κάνοντας το δίκτυο αργό και αναποτελεσματικό. Αντίστοιχα, ένα πολύ μικρό *μήκος παραθύρου* μπορεί να μην εμπεριέχει χρήσιμη, αρκετή πληροφορία για την ορθή

εξαγωγή του *πίνακα χαρακτηριστικών (feature maps)* και επομένως να οδηγήσει σε ένα δίκτυο μη αποτελεσματικό χωρίς ικανότητα να διαχωρίζει τα σήματα εισόδου.



Εικόνα 7-5 – Διαδικασία Τμηματοποίησης (segmentation) Σήματος Εισόδου

Το ίδιο ισχύει για το *μήκος ολίσθησης*, το οποίο πρέπει να είναι μικρότερο από το *μήκος παραθύρου* ώστε να υπάρχει επικάλυψη των δύο διαδοχικών παραθύρων, αλλά όχι τόσο μικρό, ώστε δύο διαδοχικά παράθυρα να περιέχουν την ίδια πληροφορία. Δυστυχώς, δεν υπάρχει κάποιος χρυσός κανόνας που να ορίζει το ιδανικό *μήκος παραθύρου* και *ολίσθησης*. Για την εύρεση των βέλτιστων τιμών, πραγματοποιήσαμε δοκιμές, εφαρμόζοντας διάφορα *μήκη παραθύρου* και *ολίσθησης*, παρατηρώντας κάθε φορά την αποτελεσματικότητα του δικτύου μετά την ολοκλήρωση της εκπαίδευσης του. Τελικά, καταλήξαμε πως το δίκτυο παρουσιάζει την βέλτιστη απόδοση για μήκος παραθύρου (*window length*) 500 και ολίσθησης (*stride*) 450.

- **Εξαγωγή πινάκων χαρακτηριστικών (Features Extraction)**

Αποτελεί το βασικότερο μέρος του *συνελκτικού νευρωνικού δικτύου*, καθώς εδώ πραγματοποιείται η διαδικασία της *συνέλιξης* και *ομαδοποίησης* με σκοπό της εξαγωγή των *πινάκων χαρακτηριστικών*. Η τελική δομή του δικτύου προέκυψε μετά

από αρκετές δοκιμές και συνδυασμούς και μελετώντας τις σχετικές έρευνες. (παράγραφος 6.2).

Η αρχιτεκτονική του δικτύου, όπως φαίνεται στην *Εικόνα 7-8*, είναι αρκετά απλή και αποτελείται από μόλις τρία επίπεδα.

Το πρώτο *συνελικτικό επίπεδο (conv1d)*, στο οποίο εισέρχεται το τμηματοποιημένο (*segmented*) σήμα εισόδου, διαστάσεων 500×1 . Πεντακόσια είναι το μέγεθος του παραθύρου (*window size*) που επιλέξαμε κατά την προ επεξεργασία και ένα, καθώς το δίκτυο είναι μονοδιάστατο (*1D*). Στο πρώτο επίπεδο έχουμε επιλέξει (αυθαίρετα μετά από δοκιμές), την εφαρμογή *128 φίλτρων-kernels* διαστάσεων 100×1 . Η έξοδος του πρώτου επιπέδου αποτελείται από *401 νευρώνες*

Το δεύτερο *συνελικτικό επίπεδο (conv1d_1)*, στο οποίο εισέρχεται η έξοδος του πρώτου 401×128 . Τετρακόσια ένα, οι νευρώνες του πρώτου επιπέδου με βάθος 128 μετά την εφαρμογή της συνέλιξης και την εξαγωγή των πινάκων χαρακτηριστικών. Στο δεύτερο επίπεδο επιλέξαμε *64 φίλτρα-kernels*, διαστάσεων 50×1 . Η έξοδος του δεύτερου επιπέδου αποτελείται από *352 νευρώνες*. Και στα δύο *επίπεδα συνέλιξης* εφαρμόζεται ως *συνάρτηση ενεργοποίησης* η “*relu*”

Το τρίτο και τελευταίο επίπεδο της *εξαγωγής χαρακτηριστικών* είναι, όπως είναι αναμενόμενο, αυτό της *ομαδοποίησης*. Η είσοδος του είναι η έξοδος του *2^ο συνελικτικού επιπέδου*, διαστάσεων 352×64 . Τριακόσιοι πενήντα δύο είναι οι νευρώνες του δεύτερου επιπέδου με βάθος 64 μετά την εφαρμογή της συνέλιξης και την εξαγωγή των πινάκων χαρακτηριστικών. Η επιλογή των *φίλτρων ομαδοποίησης* (επίσης αυθαίρετη) είναι *τέσσερα*, επομένως η έξοδος του επιπέδου αυτού είναι ένα αρκετά μικρότερο διάνυσμα διαστάσεων 88×64 , το οποίο θα εισαχθεί στο επόμενο επίπεδο *flatten*.

- **Κατηγοριοποίηση (classification)**

Η *κατηγοριοποίηση (classification)* αποτελείται από τρία επίπεδα και είναι ουσιαστικά η έξοδος του δικτύου. Πρώτο επίπεδο, η *γραμμικοποίηση* ή *flatten*. Η έξοδος του *επιπέδου ομαδοποίησης* διαστάσεων 88×64 , μετατρέπεται σε ένα *μονοδιάστατο διάνυσμα* διαστάσεων $88 \times 64 = 5632$. Ακολουθεί ένα πλήρως *διασυνδεδεμένο επίπεδο (dense layer)* διακοσίων νευρώνων, στο οποίο ξεκινάει η

διαδικασία της κατηγοριοποίησης. Η επιλογή των νευρώνων είναι αυθαίρετη και προέκυψε μετά από δοκιμές. Τέλος η έξοδος του πρώτου *dense layer* γίνεται είσοδος του δεύτερου και τελευταίου *επιπέδου πλήρους διασύνδεσης (dense_19)*, στο οποίο πραγματοποιείται και η τελική κατάταξη του σήματος εισόδου σε μία εκ των είκοσι επτά κατηγοριών βλάβης. Επομένως, το μέγεθος του επιπέδου αυτού είναι όσες και οι κατηγορίες βλάβης, δηλαδή είκοσι επτά. Το πρώτο *dense layer (dense)*, χρησιμοποιεί ως *συνάρτηση ενεργοποίησης* την “*relu*”, ενώ το δεύτερο, όπως έχει ήδη αναφερθεί και στην θεωρία ([παράγραφος 3.6](#)) την *softmax*. Για την ταξινόμηση του αποτελέσματος χρησιμοποιούμε τον *hot encoder*.

Στην [Εικόνα 7-6](#) φαίνεται η σύνοψη του δικτύου και στην εικόνα [Εικόνα 7-7](#) η δομή του, όπως προκύπτουν από την βιβλιοθήκη *tensor flow* της *Python*. Και στις δύο αυτές απεικονίσεις φαίνονται αναλυτικά οι παράμετροι και η διάσταση κάθε επιπέδου, ενώ στη σύνοψη του δικτύου αναφέρονται οι συνολικές παράμετροι που θα πρέπει να υπολογισθούν κατά τη διάρκεια της *εκπαίδευσης (training)* και είναι **1,554,619**

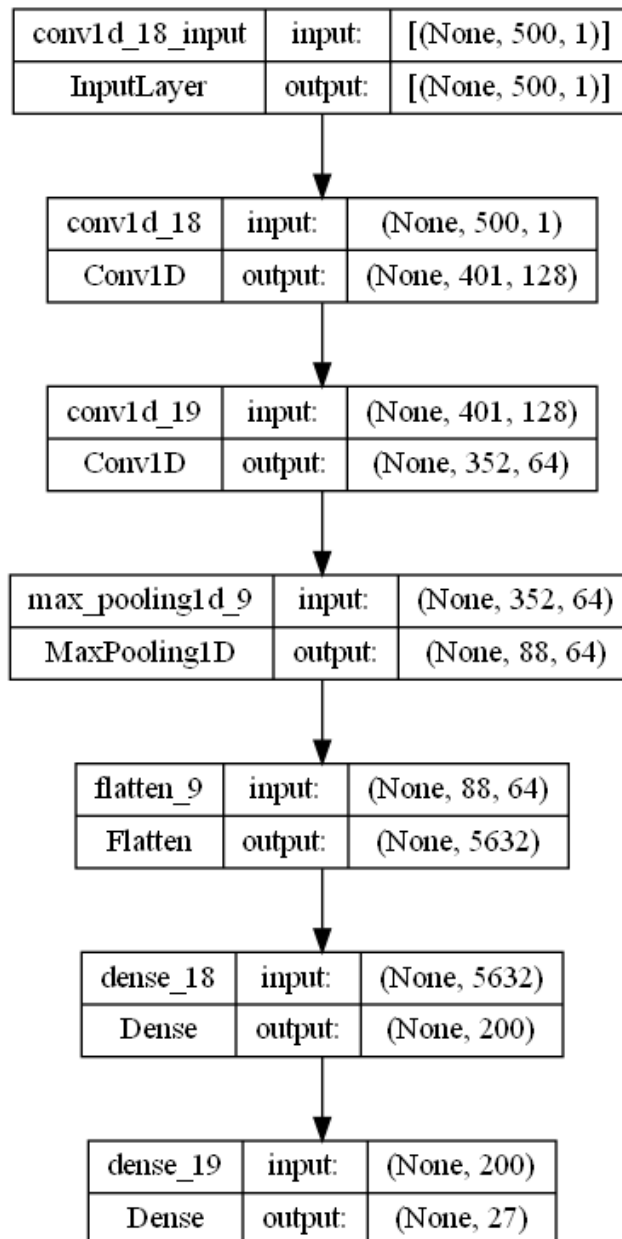
```
Model: "sequential_9"
-----
Layer (type)                Output Shape                Param #
-----
conv1d_18 (Conv1D)          (None, 401, 128)           12928
conv1d_19 (Conv1D)          (None, 352, 64)            409664
max_pooling1d_9 (MaxPooling (None, 88, 64)            0
1D)
flatten_9 (Flatten)         (None, 5632)                0
dense_18 (Dense)            (None, 200)                 1126600
dense_19 (Dense)           (None, 27)                   5427
-----
Total params: 1,554,619
Trainable params: 1,554,619
Non-trainable params: 0
```

Εικόνα 7-6 – Σύνοψη Συνελικτικού Νευρωνικού δικτύου

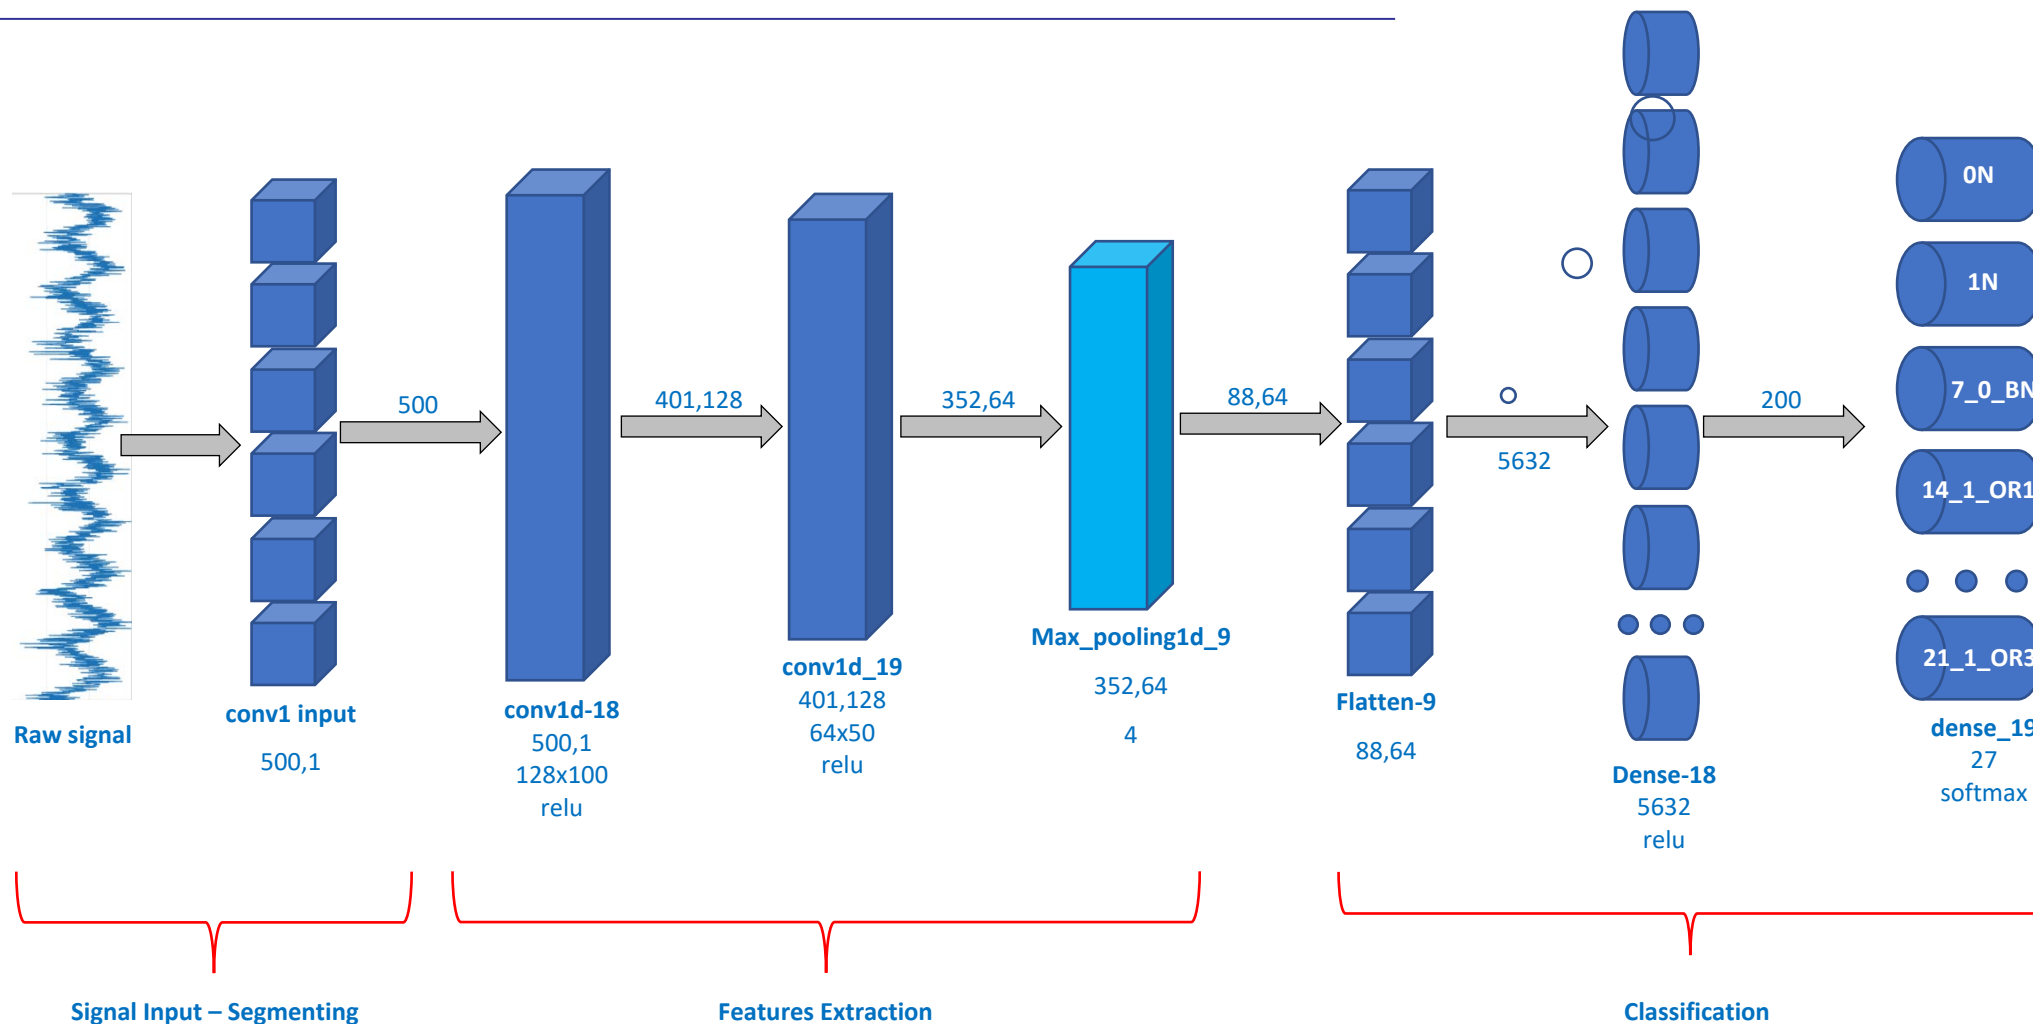

Παρατηρούμε, πως στο δίκτυο δεν χρησιμοποιήσαμε καθόλου επίπεδο κανονικοποίησης (*batch normalization layer*). Κατά τη διάρκεια της μελέτης και

δοκιμής του δικτύου είδαμε πως η προσθήκη ενός *επιπέδου κανονικοποίησης* δεν βελτίωσε την απόδοση του συγκεκριμένου μοντέλου. Αντιθέτως, οι παράμετροι προς εκπαίδευση ήταν περισσότεροι και ο χρόνος εκπαίδευσης αρκετά μεγαλύτερος.

Τέλος, στο *παράρτημα 9.3* παραθέτουμε τα *διαγράμματα διασποράς (scatter plots)* των επιπέδων *flatten* και *dense*, με σκοπό ο αναγνώστης να παρατηρήσει πως επιδρά σταδιακά η διαδικασία της *συνέλιξης* στο σήμα εισόδου



Εικόνα 7-7 – Δομή Συνελκτικού Νευρωνικού δικτύου




Εικόνα 7-8 – Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου

7.5 Εκπαίδευση (training) - Επιβεβαίωση (validation)

Για την *εκπαίδευση και επιβεβαίωση (training & evaluation)* του δικτύου το σετ δεδομένων χωρίστηκε σε 70/30. Δηλαδή **70%** των δεδομένων χρησιμοποιήθηκαν για την *εκπαίδευση* του δικτύου και **30%** για την *επιβεβαίωσή* του. Το μέγεθος της κάθε *παρτίδας* δεδομένων (*batch size*) καθώς και ο αριθμός των *επαναλήψεων (epochs)* προέκυψε μετά από δοκιμές. Τελικά καταλήξαμε πως το δίκτυο παρουσίασε την καλύτερη απόκριση για το συγκεκριμένο σετ δεδομένων όταν εκπαιδεύτηκε με *batch size 300* και *epochs 20*. Όπως αναφέραμε και στην [παράγραφο 7.4](#) ο υπολογιστής που χρησιμοποιήθηκε κατά την εκπαίδευση και δοκιμή του δικτύου είναι ένα συμβατικό Laptop με επεξεργαστή *intel i7 11^{ης} γενιάς*, χωρίς *GPU*. Ο χρόνος που χρειάστηκε το δίκτυο για να ολοκληρώσει τον υπολογισμό και την εκπαίδευση των **1,554,619 παραμέτρων** ήταν **13 λεπτά** και **53 δευτερόλεπτα**, ενώ η τελική ακρίβεια του (*accuracy*) φθάνει το **99.62%** κατά την *εκπαίδευση* και το **93,52%** κατά την *επιβεβαίωση*. Αξίζει να σημειωθεί, πως την αμέσως καλύτερη απόκριση είχε ένα δίκτυο με **5,228,411 παραμέτρους**, το οποίο χρειάστηκε 85 λεπτά και 7 δευτερόλεπτα για να εκπαιδευθεί, ενώ η τελική ακρίβεια του (*accuracy*) ήταν **93.82%** κατά την *εκπαίδευση* και το **89,26%** κατά την *επιβεβαίωση*. Στην [Εικόνα 7-9](#) φαίνονται αναλυτικά τα αποτελέσματα κάθε epoch κατά την διάρκεια της εκπαίδευσης του δικτύου, ενώ στην [Εικόνα 7-10](#) το αντίστοιχο γράφημα για την σετ εκπαίδευσης και επαλήθευσης.

```
Epoch 1/20
24/24 [=====] - 32s 1s/step - loss: 2.7129 - accuracy: 0.1744 - val_loss: 2.2570 - val_accuracy: 0.3157
Epoch 2/20
24/24 [=====] - 36s 1s/step - loss: 1.8781 - accuracy: 0.4033 - val_loss: 1.5318 - val_accuracy: 0.5392
Epoch 3/20
24/24 [=====] - 38s 2s/step - loss: 1.1082 - accuracy: 0.6664 - val_loss: 0.8049 - val_accuracy: 0.7263
Epoch 4/20
24/24 [=====] - 38s 2s/step - loss: 0.5797 - accuracy: 0.8183 - val_loss: 0.6281 - val_accuracy: 0.8043
Epoch 5/20
24/24 [=====] - 47s 2s/step - loss: 0.4406 - accuracy: 0.8501 - val_loss: 0.4276 - val_accuracy: 0.8555
Epoch 6/20
24/24 [=====] - 42s 2s/step - loss: 0.2788 - accuracy: 0.8995 - val_loss: 0.3097 - val_accuracy: 0.8869
Epoch 7/20
24/24 [=====] - 42s 2s/step - loss: 0.1934 - accuracy: 0.9360 - val_loss: 0.2891 - val_accuracy: 0.8988
Epoch 8/20
24/24 [=====] - 42s 2s/step - loss: 0.2184 - accuracy: 0.9296 - val_loss: 0.3952 - val_accuracy: 0.8602
Epoch 9/20
24/24 [=====] - 44s 2s/step - loss: 0.2039 - accuracy: 0.9290 - val_loss: 0.2341 - val_accuracy: 0.9144
Epoch 10/20
24/24 [=====] - 45s 2s/step - loss: 0.1419 - accuracy: 0.9538 - val_loss: 0.3140 - val_accuracy: 0.8955
Epoch 11/20
24/24 [=====] - 42s 2s/step - loss: 0.1154 - accuracy: 0.9615 - val_loss: 0.2062 - val_accuracy: 0.9250
Epoch 12/20
24/24 [=====] - 42s 2s/step - loss: 0.0846 - accuracy: 0.9722 - val_loss: 0.2252 - val_accuracy: 0.9253
Epoch 13/20
24/24 [=====] - 43s 2s/step - loss: 0.0616 - accuracy: 0.9810 - val_loss: 0.2025 - val_accuracy: 0.9289
Epoch 14/20
24/24 [=====] - 43s 2s/step - loss: 0.0694 - accuracy: 0.9779 - val_loss: 0.2445 - val_accuracy: 0.9170
Epoch 15/20
24/24 [=====] - 41s 2s/step - loss: 0.0875 - accuracy: 0.9694 - val_loss: 0.2773 - val_accuracy: 0.9187
Epoch 16/20
24/24 [=====] - 40s 2s/step - loss: 0.0840 - accuracy: 0.9719 - val_loss: 0.2587 - val_accuracy: 0.9160
Epoch 17/20
24/24 [=====] - 44s 2s/step - loss: 0.0586 - accuracy: 0.9795 - val_loss: 0.2461 - val_accuracy: 0.9283
Epoch 18/20
24/24 [=====] - 41s 2s/step - loss: 0.0467 - accuracy: 0.9851 - val_loss: 0.1934 - val_accuracy: 0.9369
Epoch 19/20
24/24 [=====] - 46s 2s/step - loss: 0.0236 - accuracy: 0.9943 - val_loss: 0.2365 - val_accuracy: 0.9263
Epoch 20/20
24/24 [=====] - 45s 2s/step - loss: 0.0195 - accuracy: 0.9962 - val_loss: 0.2167 - val_accuracy: 0.9352
```

Εικόνα 7-9 - Training – Validation Process



Εικόνα 7-10 – Training – Validation Accuracy Plot

7.6 Παρουσίαση Αποτελεσμάτων

Όπως προαναφέραμε στις προηγούμενες παραγράφους του κεφαλαίου 7, οι επιλογή του δικτύου αλλά και των παραμέτρων του κάθε επιπέδου πραγματοποιήθηκε μετά από δοκιμές και πειραματισμούς. Στον [Πίνακα 7-3](#) παραθέτουμε μία σύνοψη των σημαντικότερων δοκιμών, καθώς και των αποτελεσμάτων τους.

Όπως προκύπτει από την εκπαίδευση του δικτύου, η ακρίβεια του (*accuracy*) φθάνει το **99.62%** κατά την *εκπαίδευση* και το **93,52%** κατά την *επιβεβαίωση*. Στην [Εικόνα 7-12](#) φαίνεται ένας συνδυαστικός πίνακας αποτελεσμάτων (*confusion matrix*). Ο πίνακας αυτός έχει και στις δύο διαστάσεις του τις είκοσι επτά (27) πιθανές κατηγορίες βλαβών. Πιο συγκεκριμένα, στον *άξονα x* είναι η *πρόβλεψη* κάθε κατηγορίας, ενώ στον *άξονα y* το *ήδη γνωστό* αποτέλεσμα όπως αυτό έχει προκύψει από τον *Hot Encoder* για κάθε μέτρηση του set δεδομένων. Ο συνδυασμός μίας γραμμής με μία στήλη υποδηλώνει την ακρίβεια του δικτύου για τα συγκεκριμένα δεδομένα. Για παράδειγμα για την κατηγορία *0N* και *1N*, για τα δεδομένα δηλαδή όπου οι σφαιροτριβείς δεν παρουσιάζουν βλάβη η αποτελεσματικότητα του δικτύου είναι **100** και **99 %** αντίστοιχα. Από τον ίδιο πίνακα παρατηρούμε πως το δίκτυο

παρουσιάζει τα χαμηλότερα ποσοστά στην ταξινόμηση της ίδιας κατηγορίας βλαβών σε διαφορετικό φορτίο **0** και **1 Hp**, αλλά και στην ταξινόμηση των κατηγοριών **OR1**, **2** και **3**, που όμως, όπως εξηγήσαμε στην **παράγραφο 7.3** ουσιαστικά αποτελούν την ίδια βλάβη στον εξωτερικό διάδρομο (*outer race*) του σφαιροτριβέα, απλά σε διαφορετική σχετική θέση ως προς τη ζώνη φόρτωσης. Ακόμη παρατηρούμε μία σχετική δυσκολία σε ότι αφορά την διαφοροποίηση της ίδιας βλάβης σε διαφορετικό μέγεθος (**7, 14 και 21 mils**). Επομένως, το δίκτυο φαίνεται πως παρουσιάζει μία πολύ καλή απόκριση στην κατηγοριοποίηση των δεδομένων, αλλά και ικανοποιητική ικανότητα να διαχωρίζει πολύ μικρές διαφοροποιήσεις που προκύπτουν από το διαφορετικό φορτίο του κινητήρα ή την αναγνώριση της ίδιας, ουσιαστικά, βλάβης, αλλά διαφορετικού μεγέθους ή σχετικής θέσης. Αυτό που είναι ουσιαστικό πολύ ενδιαφέρον είναι η ικανότητα του δικτύου να αναγνωρίσει **την ομαλή** από την **μη ομαλή λειτουργία** και αυτό, όπως είδαμε, πλησιάζει σχεδόν το **100 %** .


Πίνακας 7-1 – Αποτελέσματα Δοκιμών Μοντέλου με διαφορετικές ρυθμίσεις

Window Size/Stride	Conv1 Kernels / Size	Conv2 Kernels /Size	Dense Size	Batch Size Epochs	Accuracy Test/Validation	Παρατηρήσεις
1000/950	128/100	64/100	200	300/10	58,78% / 57.23%	Μικρή ακρίβεια αποτελεσμάτων.
1000/950	128/100	64/100	200	300/20	87,12% / 73,38%	Μικρή ακρίβεια αποτελεσμάτων. Overfitting
1000/800	256/100	128/100	200	300/10	72,95% / 66.02%	Μικρή ακρίβεια αποτελεσμάτων. Overfitting
1000/800	256/100	128/100	200	300/20	95,48% / 78.74%	Μικρή ακρίβεια αποτελεσμάτων. Πολύ μεγάλος χρόνος training Overfitting

500/450	128/100	64/50	200	300/20	99,62%/93,52%	Πολύ καλή ακρίβεια αποτελεσμάτων. Απλό δίκτυο.
500/450	256/100	128/100	200	300/20	93.82%/ 89.26%	Καλή ακρίβεια. Μεγάλος χρόνος training
250/230	128/100	64/50	200	300/20	92,26%/87,20%	Καλή ακρίβεια. Απλό δίκτυο
250/230	256/100	128/100	200	300/20	93,41%/87,84%	Καλή ακρίβεια. Απλό δίκτυο

7.6.1 Δοκιμή Δικτύου με Νέα Δεδομένα

Όπως αναφέραμε στην [παράγραφο 7.3](#) από τα αρχικά σετ δεδομένων του *CWRU (Case Western Reserve University Bearing Data Center)*, φορτίου 0 και 1 Hr, όλων των ειδών βλαβών και δειγματοληψίας 48Khz, χρησιμοποιήσαμε το **50%** για την *εκπαίδευση (training)* και *επαλήθευση (evaluation)* του δικτύου, ενώ το υπόλοιπο **50%** των *δεδομένων* το κρατήσαμε για την τελική δοκιμή του δικτύου. Πιο συγκεκριμένα, για να αξιολογήσουμε το δίκτυο, ακολουθώντας παρόμοια διαδικασία με αυτή που εφαρμόσαμε κατά την εκπαίδευση του, τροφοδοτήσαμε το δίκτυο με νέες, “άγνωστες” μετρήσεις από τα αρχικά σετ δεδομένων κραδασμού από σφαιροτριβείς με συγκεκριμένη βλάβη ή μη. Οι μετρήσεις αυτές τμηματοποιήθηκαν (*segmentation*) χρησιμοποιώντας το ίδιο *μέγεθος παραθύρου (window size)* και την ίδια *ολίσθηση (stride)*. Όπως μπορούμε να παρατηρήσουμε στον [Πίνακα 7-2](#), για να δούμε την απόκριση του δικτύου, σε κάθε δοκιμή, χρησιμοποιήσαμε διαφορετικό αριθμό δεδομένων, μετρήσεων και σίγουρα πολύ μικρότερο από αυτό με τον οποίο εκπαιδεύτηκε το δίκτυο. Παρατηρούμε, πως τα δεδομένα που χρησιμοποιήσαμε είναι από ελάχιστο 2000 έως μέγιστο 15000 μετρήσεις, ενώ το δίκτυο εκπαιδεύτηκε με 4,544,767 μετρήσεις. Ακολουθώντας την αντίστροφη διαδικασία, αυτή δηλαδή του *inverse encoder*, συγκρίναμε την πρόγνωση του δικτύου με την πραγματική κατάσταση του σφαιροτριβέα. Τα αποτελέσματα παρατίθενται στον [Πίνακα 7-2](#)



Εικόνα 7-11 – Confusion Matrix Κατηγοριοποίησης Βλαβών Σφαιροτριβέων

Πίνακας 7-2 – Αποτελέσματα Δοκιμών Δικτύου με νέα, άγνωστα δεδομένα

	Data Set	Μέγεθος	Data Segments	Αποτέλεσμα	
1	7_0_OR1	2999	6	83,3%	1/1 [=====] - 0s 25ms/step [19 19 19 24 19 19] ['7_0_OR1' '7_0_OR1' '7_0_OR1' '7_1_OR1' '7_0_OR1' '7_0_OR1']
2	7_0_IR	5001	11	100%	1/1 [=====] - 0s 37ms/step [18 18 18 18 18 18 18 18 18] ['7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR' '7_0_IR']
3	7_0_OR2	15000	21	100%	2/2 [=====] - 0s 6ms/step [20 20] ['7_0_OR2' '7_0_OR2']
5	14_0_IR	15000	33	84,8%	2/2 [=====] - 0s 16ms/step [17 2 2 17 2 2 2 2 17 2 2 2 2 2 2 2 2 2 2 17 2 2 2 2 2 2 2 2 2 2] ['14_0_IR' '14_0_IR' '14_0_IR' '7_0_IR' '14_0_IR']
6	14_0_BN	1999	4	25%	<pre>1 y_pred1=cnn_model.predict(X1) 2 y_pred1=y_pred1.argmax(axis=1) 3 y_pred2=encoder.inverse_transform(y_pred1) 4 print(y_pred1) 5 print(y_pred2) 6 7</pre> <p>1/1 [=====] - 0s 19ms/step [1 17 17 17] ['14_0_BN' '7_0_BN' '7_0_BN' '7_0_BN']</p>
7	21_0_IR	2500	5	20%	<pre>1 y_pred1=cnn_model.predict(X1) 2 y_pred1=y_pred1.argmax(axis=1) 3 y_pred2=encoder.inverse_transform(y_pred1) 4 print(y_pred1) 5 print(y_pred2) 6 7</pre> <p>1/1 [=====] - 0s 26ms/step [12 12 12 7 12] ['21_1_IR' '21_1_IR' '21_1_IR' '21_0_IR' '21_1_IR']</p>
8	21_0_IR	15000	33	78.8%	<pre>1 y_pred1=cnn_model.predict(X1) 2 y_pred1=y_pred1.argmax(axis=1) 3 y_pred2=encoder.inverse_transform(y_pred1) 4 print(y_pred1) 5 print(y_pred2) 6 7</pre> <p>2/2 [=====] - 0s 14ms/step [7 7 12 12 7 7 7 12 7 7 7 7 7 7 7 7 7 7 7 12 7 7 7 7 7 7 7 7 7 7] ['21_0_IR' '21_0_IR' '21_0_IR' '21_1_IR' '21_1_IR' '21_1_IR' '21_0_IR']</p>
9	ON	2000	4	100%	<pre>1 y_pred1=cnn_model.predict(X1) 2 y_pred1=y_pred1.argmax(axis=1) 3 y_pred2=encoder.inverse_transform(y_pred1) 4 print(y_pred1) 5 print(y_pred2) 6 7</pre> <p>1/1 [=====] - 0s 26ms/step [0 0 0 0] ['0N' '0N' '0N' '0N']</p>



- Όπως προαναφέραμε τα δεδομένα που χρησιμοποιήσαμε για να δοκιμάσουμε το μοντέλο είναι από 2000 έως 15000 μετρήσεις, τα οποία αντιστοιχούν σε σήμα 44 έως 330msec σε δειγματοληψία 45Khz. Γίνεται αντιληπτό πως η μέτρηση αυτή είναι υπερβολικά μικρή και στην πράξη χρησιμοποιούνται μετρήσεις αρκετών δευτερολέπτων. Αυτός είναι ακόμα ένας παράγοντας επιτυχίας της απόκρισης του δικτύου.

8. Συμπεράσματα – Παρατηρήσεις

8.1 Σύνοψη Αποτελεσμάτων

Η παρούσα εργασία πραγματοποιήθηκε την *προβλεπτική συντήρηση μηχανημάτων με περιστρεφόμενα μέρη*. Στην πορεία της εργασίας αναλύσαμε την αναγκαιότητα της σωστής λειτουργίας ενός μηχανήματος για την ασφαλή πλεύση και διαχείριση ενός πλοίου, καθώς και τις επιπτώσεις που μία βλάβη μπορεί να επιφέρει τόσο στην απόδοσή του και τελικά στα κέρδη της πλοιοκτήτριας εταιρίας, όσο και στην ασφάλεια των εργαζομένων και την προστασία του φυσικού περιβάλλοντος. Η επιλογή του τρόπου συντήρησης, (διορθωτική, προβλεπτική, προγνωστική κ.τ.λ) εξαρτάται από πολλούς παράγοντες (*κεφάλαιο 4*), απώτερος όμως σκοπός είναι η μείωση των βλαβών και του χρόνου διακοπής λειτουργίας, η βελτιστοποίηση της απόδοσης των μηχανημάτων και τελικά η μείωση του κόστους συντήρησης. Εδώ, έρχεται να συμβάλει η σύγχρονη τεχνολογία και πιο συγκεκριμένα η *βαθιά μάθηση* και τα *συνελικτικά νευρωνικά δίκτυα*, παρέχοντας χρήσιμα εργαλεία για την πρόβλεψη μία βλάβης σε αρχικό ακόμα στάδιο.

Στο *κεφάλαιο 7*, παρουσιάσαμε ένα μοντέλο *συνελικτικού νευρωνικού δικτύου*, το οποίο τροφοδοτήθηκε με μετρήσεις κραδασμού που συλλέχθηκαν από *αισθητήρες επιτάχυνσης* τοποθετημένους στο *DE* και *NDE* ενός κινητήρα 2Hp σε συνθήκες εργαστηρίου.

- Μετά από αρκετές δοκιμές καταλήξαμε πως η βέλτιστη δομή του δικτύου είναι αρκετά απλή και αποτελείται από μόλις *επτά επίπεδα*, ενώ η παραμετροποίηση του δικτύου έχει *128* και *64 φίλτρα kernels* στο *πρώτο* και

δεύτερο επίπεδο συνέλιξης και 200 νευρώνες στο *επίπεδο πλήρους διασύνδεσης*, πριν την τελική *κατηγοριοποίηση*.

- Οι συνολικές *παράμετροι* τις οποίες το δίκτυο πρέπει να *υπολογίσει* και *εκπαιδεύσει* είναι μόλις **1,554,619**.
- Το δίκτυο ολοκλήρωσε την *εκπαίδευση* του σε σχεδόν **14 λεπτά**. Η εκπαίδευση του δικτύου πραγματοποιήθηκε σε **20 epochs** με *batch size* **300**
- Η απόκριση του δικτύου στο σετ *δεδομένων εκπαίδευσης* και *επαλήθευσης* είναι **99,62%** και **93,52%** αντίστοιχα. Τα ποσοστά αυτά είναι πολύ υψηλά, ιδιαίτερα αν κάποιος αναλογισθεί ότι η ικανότητα του δικτύου να ανιχνεύσει επιτυχώς την *βλάβη* από τη μη *βλάβη* είναι **100%**.
- Όταν το δίκτυο τροφοδοτήθηκε με νέα, εντελώς άγνωστα δεδομένα, η απόκρισή του στην κατηγοριοποίηση βλαβών ήταν από **20%** έως **100%**. Εδώ, αξίζει να σημειωθεί πως το σετ δεδομένων με τα οποία το δίκτυο εκπαιδεύτηκε και στην συνέχεια δοκιμάστηκε, περιέχει μετρήσεις για φορτίο **0** και **1Hp**, καθώς και ίδιες βλάβες διαφορετικού μεγέθους (**7,14,21 mils**). Μελετώντας τις κυματομορφές των δεδομένων κάθε τύπου βλάβης, **παράγραφος 9.2**, εύκολα μπορεί να παρατηρήσουμε τις ομοιότητες μεταξύ των σημάτων που προκύπτουν από τα φορτία 0 και 1Hp, αλλά και μεταξύ των όμοιων βλαβών, διαφορετικού μεγέθους. Επίσης, μελετώντας τα αποτελέσματα του δικτύου στις περιπτώσεις που η απόκρισή του είναι χαμηλή, όπως για παράδειγμα στα δεδομένα **14_0_BN** και **21_0_IR**, θα δούμε πως το δίκτυο *δεν ανιχνεύει λάθος είδος βλάβης* αλλά διαφορετικό φορτίο 0 με 1 Hp ή διαφορετικό μέγεθος βλάβης 7,14 και 21 mils. Εάν λοιπόν ομαδοποιήσουμε τις βλάβες μόνο ως προς τον τύπο, **BN, IR, OR** και **N**, και όχι ως προς το μέγεθος ή το φορτίου που εφαρμόζεται στον άξονα του κινητήρα, τότε μπορούμε να θεωρήσουμε πως η απόκριση του δικτύου είναι σταθερά πάνω από **90%**.

Από τα παραπάνω συμπεραίνουμε, πως η εφαρμογή της *προγνωστικής συντήρησης* έχει πολλά προτερήματα εν συγκρίσει με την *προληπτική* ή ακόμα περισσότερο με την *διορθωτική συντήρηση*. Όταν μάλιστα εφαρμόζεται σε

συνδυασμό με την *τεχνητή νοημοσύνη*, τότε μπορούν να ανιχνευθούν βλάβες σε πρώιμο ακόμα στάδιο, πριν προκαλέσουν ζημιά στο υπό παρακολούθηση μηχανήμα.

Το δίκτυο που προτείναμε και αναλύσαμε σε αυτή την εργασία κατάφερε να *κατηγοριοποιήσει* τη *βλάβη* από τη *μη βλάβη* σε σφαιροτριβείς κινητήρα σε ποσοστό σχεδόν *100%*. Από την μελέτη της σχετικής βιβλιογραφίας προκύπτει πως το ενδιαφέρον των μελετητών πάνω στο συγκεκριμένο αντικείμενο είναι πολύ μεγάλο. Σε εβδομαδιαία βάση δημοσιοποιούνται νέες μελέτες που παρουσιάζουν μοντέλα *μηχανικής* ή *βαθιάς μάθησης* στον τομέα της *προγνωστικής συντήρησης* τα περισσότερα εκ των οποίων δοκιμάζονται σε εργαστηριακό περιβάλλον. Η προγνωστική συντήρηση στο χώρο της ναυτιλίας, αλλά και της βιομηχανίας κάνει τα πρώτα της «παιδικά» βήματα. Αναμένεται όμως πως στο μέλλον θα αποτελέσει την βασική μέθοδο συντήρησης των μηχανημάτων.

8.2 ΜΕΛΛΟΝΤΙΚΟΙ ΣΤΟΧΟΙ

Καθώς η εκπαίδευση και δοκιμή του δικτύου πραγματοποιήθηκε με δεδομένα που συλλέχθηκαν σε *εργαστηριακό περιβάλλον* (data set *CWRU*), σκοπός του συγγραφέα είναι να συνεχίσει την έρευνα, και σε μεταγενέστερο χρόνο να δοκιμασθεί το προτεινόμενο δίκτυο σε πραγματικά δεδομένα κραδασμών που θα συλλεχθούν από μηχανήματα τοποθετημένα σε *πλοία μεταφοράς υγροποιημένου φυσικού αερίου*. Η διαδικασία αυτή θα είναι ιδιαίτερα χρονοβόρα αλλά ταυτόχρονα και ενδιαφέρουσα. *Χρονοβόρα*, γιατί υπάρχει πληθώρα δεδομένων όσο τα μηχανήματα λειτουργούν ομαλά, αλλά πολύ λίγα έως μηδενικά όταν παρουσιάζεται βλάβη. Και αυτό, γιατί αναλογιζόμενοι την κρισιμότητα της σωστής λειτουργίας των μηχανημάτων για την ασφαλή λειτουργία ενός πλοίου, τις περισσότερες φορές εφαρμόζεται η *προληπτική συντήρηση* που σκοπό έχει να αποτρέψει ή έστω να μειώσει τις πιθανότητες να φθάσει κάποιο μηχανήμα σε κατάσταση βλάβης. *Ενδιαφέρουσα*, γιατί σε ένα πλοίο υπάρχουν πολλά και *διαφορετικά μηχανήματα με περιστρεφόμενα μέρη*, τα αποτύπωμα κραδασμών των οποίων είναι ποικίλα. Επομένως το δίκτυο θα πρέπει να αναπροσαρμοσθεί κατάλληλα, ώστε να μπορεί να ανιχνεύσει με επιτυχία την κατάσταση των μηχανημάτων αυτών. Το ενδιαφέρον εστιάζεται σε μηχανήματα μεγάλης ιπποδύναμης (>1000KW), όπως οι *συμπιεστές ατμών φορτίου* και οι

συμπιεστές επανα-υγροποίησης, η σωστή λειτουργία των οποίων είναι καθοριστικής σημασίας για τα πλοία αυτά και η επισκευή τους δύσκολη και δαπανηρή. Στα μηχανήματα αυτά υπάρχουν μόνιμα εγκατεστημένοι αισθητήρες μέτρησης επιτάχυνσης στο DE και NDE και οι μετρήσεις συλλέγονται σε πραγματικό χρόνο. Δύο ακόμα παράγοντες που θα πρέπει να ελεγχθούν είναι, αν και πως οι στροφές της κύριας μηχανής επηρεάζουν το αποτύπωμα των κραδασμών των μηχανημάτων, αλλά και αν ο συνολικός κραδασμός της μεταλλικής κατασκευής του πλοίου μεταφέρεται και αποτυπώνεται στις μετρήσεις κραδασμών των επιμέρους μηχανημάτων.

Τέλος, κατά τη διάρκεια της βιβλιογραφικής επισκόπησης έγινε αντιληπτό πως πολύ λίγες μελέτες έχουν ασχοληθεί με την ανάπτυξη μοντέλων *μηχανικής ή βαθιάς μάθησης* για τον υπολογισμό του *υπολειπόμενου χρόνου διάρκειας ζωής (RUL)*. Επομένως, σκοπός και θέληση του συγγραφέα είναι να γίνει προσπάθεια ώστε το προτεινόμενο δίκτυο να επεκταθεί, και πέραν της δυνατότητας *ανίχνευσης και πρόβλεψης βλαβών*, να υπολογίζει και τον *υπολειπόμενο χρόνο διάρκειας ζωής* του συγκεκριμένου μηχανήματος. Έτσι, το δίκτυο θα συντελέσει στην εφαρμογή της *προγνωστικής συντήρησης βασισμένη στην πραγματική κατάσταση των υπό εξέταση μηχανημάτων*, αποφεύγοντας την υποβάθμιση τους, εξοικονομώντας χρόνο, χρήματα, αλλά και μειώνοντας πιθανά ατυχήματα.

9. Παραρτήμα

9.1 Case Western Reserve University Data Set

Πίνακας 9-1- CWRU Bearing Fault Data Set Details[87]

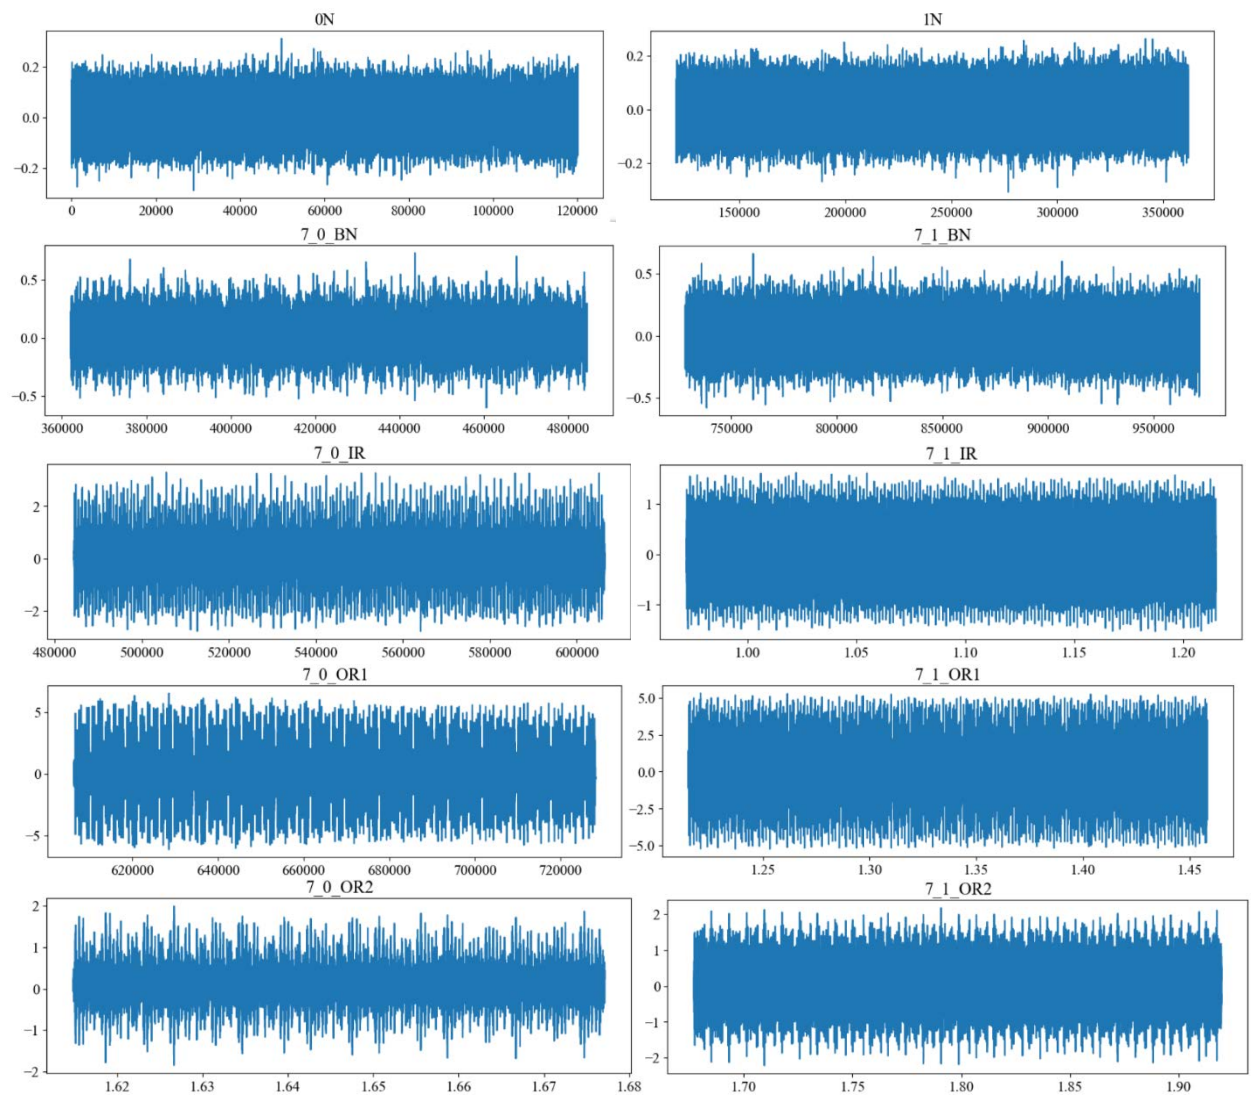
12k drive end bearing fault data							
			Type of Fault (data set number)				
Fault Width In (mm)	Motor Load (HP)	Apr. Shaft Speed	IR	Ball	Or @6	Or @3	Or @12
0,007(0,18)	0	1797	105	118	130	144	156
	1	1772	106	119	131	145	158
	2	1750	107	120	132	146	159
	3	1730	108	121	133	147	160
0,014(0,36)	0	1797	169	185	197	-	-
	1	1772	170	186	198	-	-
	2	1750	171	187	199	-	-
	3	1730	172	188	200	-	-
0,021(0,53)	0	1797	209	222	234	246	258
	1	1772	210	223	235	247	259
	2	1750	211	224	236	248	260
	3	1730	212	225	237	249	261
0,028(0,71)	0	1797	3001	3005	-	-	-
	1	1772	3002	3006	-	-	-
	2	1750	3003	3007	-	-	-
	3	1730	3004	3008	-	-	-
48k drive end bearing fault data							
			Type of Fault (data set number)				
Fault Width In (mm)	Motor Load (HP)	Apr. Shaft Speed	IR	Ball	Or @6	Or @3	Or @12
0,007(0,18)	0	1797	109	122	135	148	161
	1	1772	110	123	136	149	162
	2	1750	111	124	137	150	163
	3	1730	112	125	138	151	164

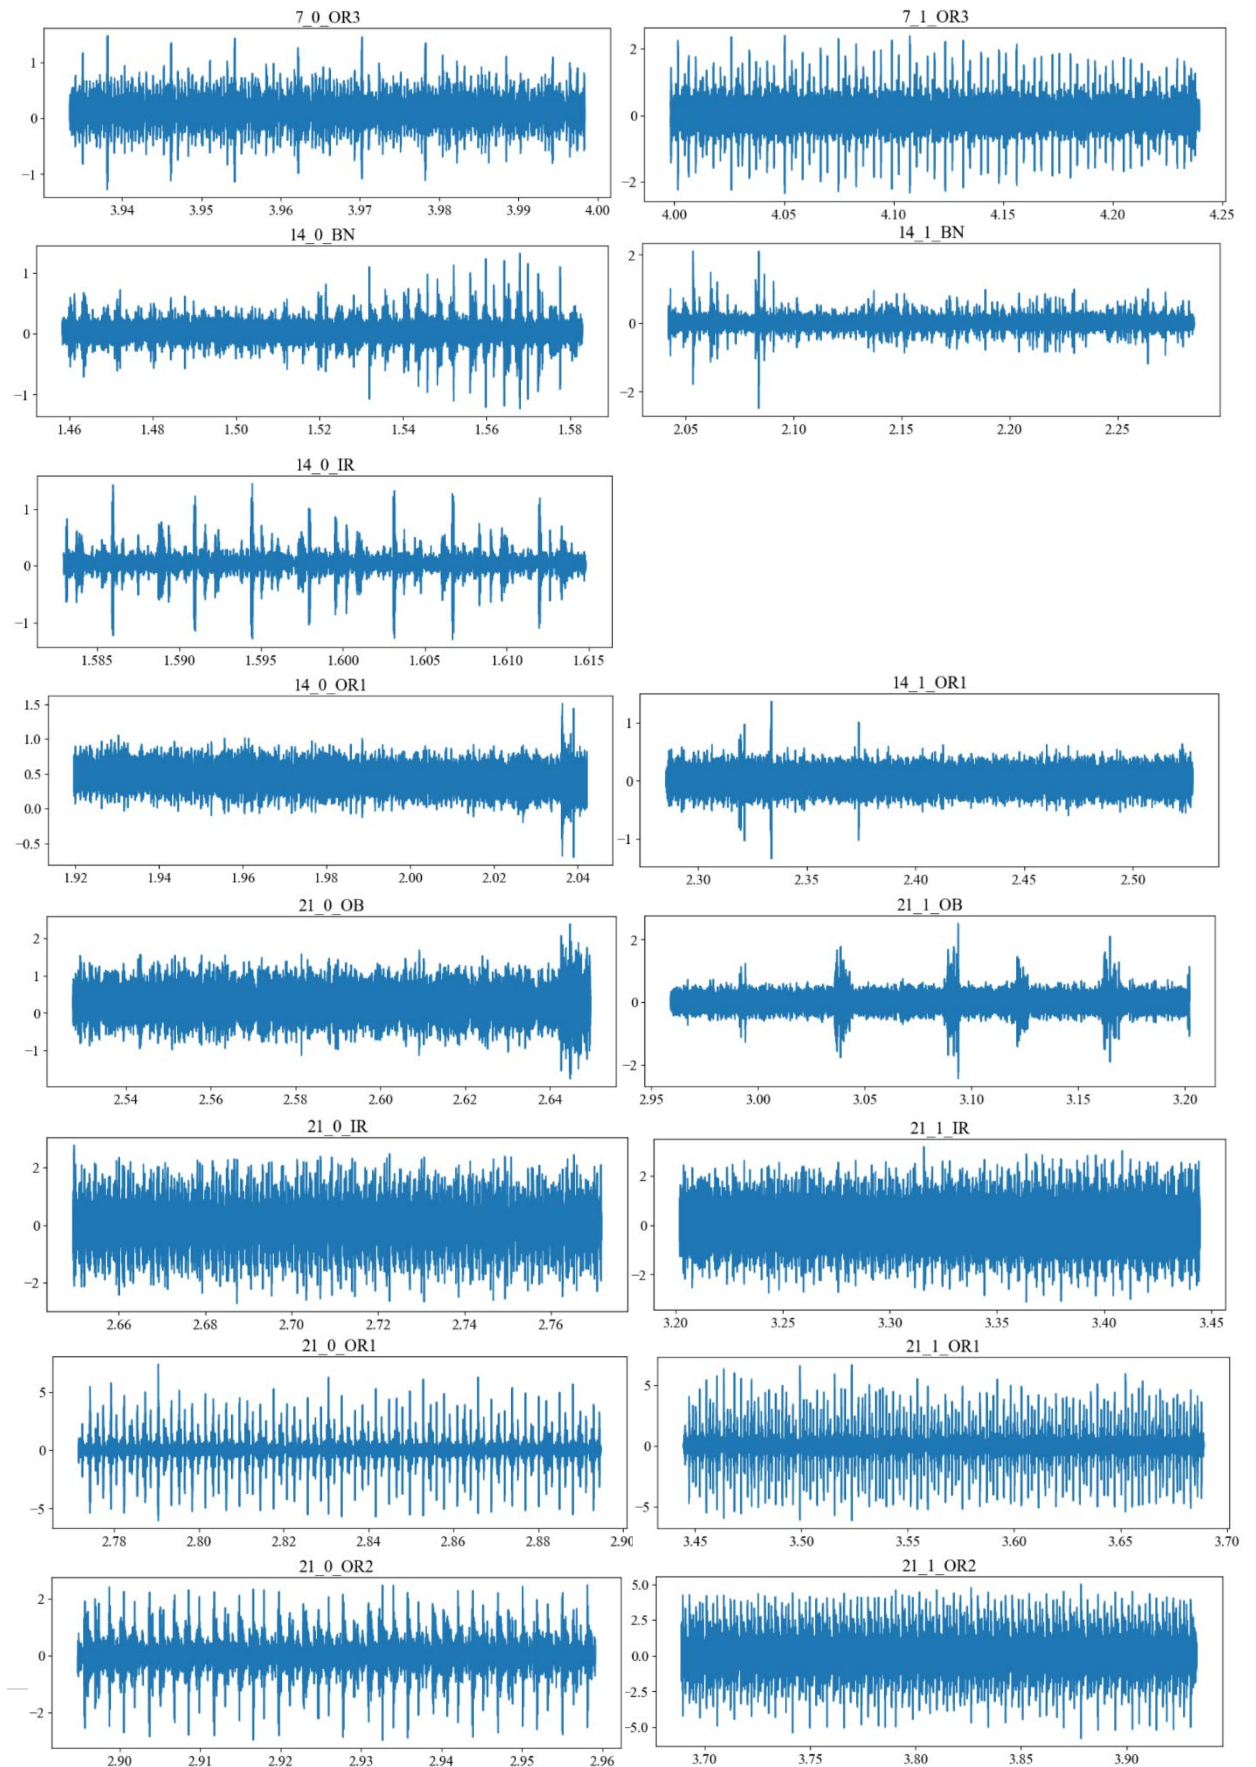
0,014(0,36)	0	1797	174	189	201	-	-
	1	1772	175	190	202	-	-
	2	1750	176	191	203	-	-
	3	1730	177	192	204	-	-
0,021(0,53)	0	1797	213	226	238	250	262
	1	1772	214	227	239	251	263
	2	1750	215	228	240	252	264
	3	1730	217	229	241	253	265
12k non drive end (fan) bearing fault data							
			Type of Fault (data set number)				
Fault Width In (mm)	Motor Load (HP)	Apr. Shaft Speed	IR	Ball	Or @6	Or @3	Or @12
0,007(0,18)	0	1797	278	282	294	298	302
	1	1772	279	283	295	299	305
	2	1750	280	284	296	300	306
	3	1730	281	285	297	301	307
0,014(0,36)	0	1797	274	286	313	310	-
	1	1772	275	287	-	309	-
	2	1750	276	288	-	311	-
	3	1730	277	289	-	312	-
0,021(0,53)	0	1797	270	290	315	-	-
	1	1772	271	291	-	316	-
	2	1750	272	292	-	317	-
	3	1730	273	293	-	318	-
48k normal baseline data							
	Motor Load (HP)	Apr. Shaft Speed	Normal dataset				
	0	1797	97				
	1	1772	98				
	2	1750	99				
	3	1730	100				




9.2 Γραφική απεικόνιση σειτ δεδομένων

Στην εικόνα *Εικόνα 9-1* απεικονίζονται οι γραφικές παραστάσεις του σειτ δεδομένων, ανά κατηγορία βλάβης. Παρατηρούμε, πως ανά κατηγορία βλάβης, το αποτύπωμα του γραφήματος της μέτρησης κραδασμού με αισθητήρα επιτάχυνσης (accelerometer) είναι διαφορετικό. Επίσης γίνεται αντιληπτό πως, πέραν από το είδος της βλάβης, το πλάτος, αλλά και η μορφή του γραφήματος εξαρτάται και από το φορτίο του κινητήρα και φυσικά και το μέγεθος της βλάβης.









Εικόνα 9-1 - Γραφική Απεικόνιση Σειτ Δεδομένων

9.3 Scatter Plots


Στις παρακάτω εικόνες βλέπουμε *διαγράμματα διασποράς (scatter plots)* των δεδομένων ανά κατηγορία βλάβης. Τα διαγράμματα αυτά μας βοηθούν να κατανοήσουμε την εξέλιξη της διακριτότητας μετά τα *επίπεδα συνέλιξης*, και την εξαγωγή των *πινακόν χαρακτηριστικών*. Στην είσοδο του *flatten layer (Εικόνα 9-4)*, παρατηρούμε μία σχετική ομαδοποίηση των χαρακτηριστικών, η οποία γίνεται πιο διακριτή στην είσοδο του *dense layer 18 (Εικόνα 9-3)*, και τελικά η κατηγοριοποίηση των διαφορετικών κατηγοριών βλαβών γίνεται διακριτή στην είσοδο του τελευταίου *dense layer 19 (Εικόνα 9-2)*. Από την εικόνα *Εικόνα 9-2* γίνεται αντιληπτό αυτό που αναφέρθηκε και στην *παράγραφο 7.6*, το ότι δηλαδή ο διαχωρισμός μη βλάβης και βλάβης είναι ευδιάκριτος και πως υπάρχουν μικρές, περιορισμένες περιοχές που καλύπτονται από παραπάνω από ένα τύπο βλάβης.



Εικόνα 9-2 - Scatter Plot Input Layer Dense 19



Εικόνα 9-3 - Scatter Plot Input Layer Dense 18



Εικόνα 9-4 - Scatter Plot Input Layer Flatten 9

9.4 Πίνακας συντομεύσεων και αντιστοιχίας Ελληνικών και Αγγλικών όρων

Στον [Πίνακα 9-2](#), παραθέτουμε την αντιστοιχία των Ελληνικών και Αγγλικών όρων που θα χρησιμοποιήσουμε στην εργασία, καθώς και τις αντίστοιχες συντομεύσεις που ο αναγνώστης μπορεί να αντιμετωπίσει στην αντίστοιχη βιβλιογραφία.

Πίνακας 9-2 – Συντομεύσεις και αντιστοιχία Ελληνικών και Αγγλικών όρων

Ελληνική Ορολογία	Ελληνική Συντόμηση	Αγγλική Ορολογία	Αγγλική Συντόμηση
Βαθιά Μάθηση	BM	Deep Learning	DL
Βαθμωτή τιμή		Scalar Value	
Βάρος		Weight	
Γραμμικός		Linear	
Δεδομένα εκπαίδευσης		Training Date Set	
Δεδομένα επαλήθευσης		Evaluation Date Set	
Δεκτικό πεδίο		Receptive field	
Διαδίκτυο των πραγμάτων		Internet of Things	IoT
Διαμοιρασμό κοινών παραμέτρων		Parameters sharing	
Διασταυρούμενη εντροπία		Cross-entropy	

Δίκτυα Οπίσθιας τροφοδότησης		Backpropagation network	
Δίκτυα μερικής διασύνδεσης		Partially connected network	
Διορθωτική συντήρηση		Corrective maintenance	CM
Εκπαίδευση		Training	
Εκπαίδευση με επίβλεψη		Supervised learning	SL
Εκπαίδευση με επίβλεψη		Unsupervised learning	UL
Εκπαίδευση με ενίσχυση		Reinforcement learning	RL
Επανάληψη		Iteration	
Επίπεδο		Layer	
Επίπεδο Πλήρους Διασύνδεσης		Dense Layer or Fully Connected Layer	
Επίπεδο συγκέντρωσης		Pooling Layer	
Κανονικοποίηση		Regularization	
Κατηγοριοποίηση		Classification	
Κρυφό επίπεδο		Hidden layer	
Μέθοδο της ταχύτερης καθόδου		Gradient descent	GD
Μέσο τετράγωνο σφάλμα		Mean Squared Error	MSE
Μηχανική Μάθηση		Machine Learning	ML
Μηχανήματα με περιστρεφόμενα μέρη		Rotating Machinery	RM
Νευρώνας		Neuron	
Παράμετροι		Parameters	
Πίνακας χαρακτηριστικών		Features Map	FM
Προγνωστική Συντήρηση		Predictive Maintenance	PDM
Προληπτική Συντήρηση		Proactive Maintenance	PRM
Δίκτυο πρόσθια τροφοδότηση		Feedforward network	FN
Ρυθμός εκπαίδευσης		Learning rate	LR
Σιγμοειδής συνάρτηση		Sigmoid function	
Συμπιεστές ατμών φορτίου		Low – High Duty Compressors	LD-HD
Συμπιεστές επανα-υγροποίησης		Reliquification Compressors	
Συνάρτηση ανόρθωσης		Rectified linear unit	LRU
Συνάρτηση απώλειας		Loss function	
Συνάρτηση βηματικής μεταβολής		Hard limiter function	
Συνάρτηση κατωφλίου		Threshold function	
συνάρτησης μεταφοράς		Transfer function	
Συνάρτηση προσήμου		Sign function	
Συνάρτηση υπερβολικής εφαπτομένης		Hyperbolic tangent function	Tanh
Συνέλιξη		Convolution	
Συνελκτικά Νευρωνικά Δίκτυα		Convolutional Neural Networks	CNN
Τανυστής		Tensor	
Ταξινομήσης πολλαπλών κλάσεων		Maximum likelihood estimation	MLE
Τεχνητό Νευρωνικό Δίκτυο	TND	Artificial Neural Network	ANN
Τεχνητή Νοημοσύνη	TN	Artificial Inteligence	AI
Τιμή ενεργοποίησης ή τιμή κατωφλίου		Bias	
Υγροποιημένο Φυσικό Αέριο	ΥΦΑ	Liquified Natural Gas	LNG
Υπολειπόμενος χρόνος διάρκειας ζωής		Remaining Useful Life	RUL

Χαρακτηριστικά		Features	
Χρονοσειρά		Time Series	
Χωρικές ιεραρχίες		Spatial hierarchies	
		Case Western Reserve University	CWRU

9.5 Συγκεντρωτική λίστα εικόνων

Εικόνα 2-1 – Σχηματικό Διάγραμμα Ενός Τυπικού Νευρώνα – [10]	14 -
Εικόνα 2-2 Βασική δομή ενός Τεχνητού Νευρωνικού Δικτύου (ANN) [24].....	15 -
Εικόνα 2-3 – Σχηματική αναπαράσταση νευρώνα [7]	16 -
Εικόνα 2-4 - Ταξινόμηση Τεχνητών Δικτύων ANN με βάση τον τρόπο διασύνδεσης [10].....	18 -
Εικόνα 2-5 – Σύνοψη της Ιστορικής Εξέλιξης των Τεχνητών Νευρωνικών Δικτύων [28].....	23 -
Εικόνα 3-1 – Comparison of different layers in CNN [5]	25 -
Εικόνα 3-2 – Βασική αρχιτεκτονική Convnet [77]	25 -
Εικόνα 3-3 – Αρχιτεκτονική Συνελκτικού Δικτύου με δύο επίπεδα Συνέλιξης...-	26 -
Εικόνα 3-4 – Σχηματική παράσταση συνέλιξης δύο συναρτήσεων $f(t)$ και $g(t)$ [68] ..	29 -
Εικόνα 3-5 - An example of 2-D convolution without kernel-flipping [17]	31 -
Εικόνα 3-6 – Convolution Process [38].....	32 -
Εικόνα 3-7 – Zero Padding [92]	33 -
Εικόνα 3-8 – Εξαγωγή χαρακτηριστικών (features extraction) μετά τη εφαρμογή kernels σε μία εικόνα [38]	34 -
Εικόνα 3-9 – Επεξήγηση Parameters Sharing [17].....	35 -
Εικόνα 3-10 – Activation Function ReLU [36]	37 -
Εικόνα 3-11 – Εφαρμογή Max Pooling	39 -
Εικόνα 3-12 Εφαρμογή Global Average Pooling [16]	40 -
Εικόνα 3-13 – Max – Avg Pooling Drawbacks [16]	41 -
Εικόνα 3-14 -Fully Connected Layer [71].....	42 -
Εικόνα 3-15 – Γραφική παράσταση συνάρτησης ενεργοποίησης Softmax [47]...-	42 -
Εικόνα 3-16 – Weights for X and O classes [74]	43 -
Εικόνα 3-17 – New input classification at the dense layer [74]	44 -
Εικόνα 3-18 – Gradient descent optimization method [17].....	48 -
Εικόνα 3-19 – Learning Rate Values vs Loss function [72].....	48 -
Εικόνα 3-20 – Dropout Function [49]	50 -
Εικόνα 3-21 - Features learned on MNIST with and without the dropout function [49]	51 -
Εικόνα 3-22 – AlexNet Architecture [82]	52 -
Εικόνα 4-1 – The lifecycle of a product [12].....	53 -
Εικόνα 4-2 – Σύντομη Ιστορία της Συντήρησης [44].....	56 -
Εικόνα 4-3 – Maintenance Objectives [44]	58 -
Εικόνα 4-4 – Types of maintenance according to EN 13306 standard [13].....	59 -
Εικόνα 4-5 – Typical Bathtub Curve[40]	61 -



Εικόνα 4-6 – Maintenance Philosophies [29].....	63 -
Εικόνα 4-7 - The Principle of Control Based Maintenance[40].....	67 -
Εικόνα 4-8 – Condition Based Maintenance process [27].....	67 -
Εικόνα 4-9 Καμπύλη Υποβάθμιση Ηλεκτρικού κινητήρα [51]	69 -
Εικόνα 5-1 – Mass – Spring system [43].....	73 -
Εικόνα 5-2 Vibration Theory [70].....	76 -
Εικόνα 5-3 – Displacement vs Velocity vs Acceleration [89].....	76 -
Εικόνα 5-4 – Phase Shift.....	77 -
Εικόνα 5-5 – Fundamental Frequency & Harmonics	77 -
Εικόνα 5-6 – Displacement – Eddy Sensor	79 -
Εικόνα 5-7 – Velocity Sensor – Mounting – Sensor layout	80 -
Εικόνα 5-8 – Acceleration Sensor Construction.....	81 -
Εικόνα 5-9 – Relationship between displacement, velocity and acceleration at constant velocity [15].....	81 -
Εικόνα 5-10 – Vibration Collection Points (https://www.fluidlife.com/blog-sensor-placement-tips).....	82 -
Εικόνα 5-11 – Time Waveform example [46].....	84 -
Εικόνα 5-12 – Time Domain plot from the NDE Auxiliary Boiler Fan [46]	85 -
Εικόνα 5-13 Time to Frequency Domain (https://www.ifm.com/de/en/shared/technologies/real-time-maintenance/technology/frequency-domain).....	86 -
Εικόνα 5-14 – Time – Frequency Domain Vibration Signal Plot [11].....	87 -
Εικόνα 5-15 – Vibration Limits ISO10816(2372).....	89 -
Εικόνα 5-16 – Acc- Vel vs Freq [22].....	90 -
Εικόνα 5-17 -Angular Misalignment (left) – Parallel Misalignment (right) [46]..	91 -
Εικόνα 5-18 – Misalignment Spectra Analysis [46].....	92 -
Εικόνα 5-19- Static Unbalance (left) – Couple Unbalance (right) [46].....	93 -
Εικόνα 5-20- Unbalance Spectra Analysis [46].....	93 -
<u>Εικόνα 5-21 – Looseness (http://vlabs.iitkgp.ac.in/rmfs/exp5/index.html).....</u>	<u>94 -</u>
Εικόνα 5-22 – Looseness Spectra Analysis [31]	94 -
Εικόνα 5-23 – Ball Bearing Parts – (https://www.iqsdirectory.com/articles/ball-bearing.html).....	95 -
Εικόνα 5-24 – Ball Bearing Inner Ring (BPFI) Spectrum Analysis [31]	97 -
Εικόνα 6-1 – The Vibration Image composed by a m-n vibration signal matrix [59]..	108 -
Εικόνα 6-2 – Dual Fourier Transformed Concatenated Vibration Signals [23]..	108 -
Εικόνα 6-3 – STFT – CWT transformation.....	110 -
Εικόνα 6-4 – Batch normalization calculations [64]	112 -
Εικόνα 6-5 - Batch Normalization Lay out [64].....	112 -
Εικόνα 6-6- Αρχιτεκτονική Μονοδιάστατου Συνελκτικού Δικτύου (1D CNN) [25] .-	113 -
Εικόνα 6-7 – Training DataSet of 1D Convolutional Network [1]	119 -
Εικόνα 7-1 – CWRU - Bearing Data Center – Test Rig [52]	120 -
Εικόνα 7-2 - Γραφική Απεικόνιση Σειρ Δεδομένων 0N και 14-0-IR	124 -
Εικόνα 7-3 Scatter Plot – Data Amplitude, Fault Data.....	125 -

Εικόνα 7-4 – Pie Chart – Data – Fault Type.....	125 -
Εικόνα 7-5 – Διαδικασία Τμηματοποίησης (segmentation) Σήματος Εισόδου...	127 -
Εικόνα 7-6 – Σύνοψη Συνελκτικού Νευρωνικού δικτύου.....	129 -
Εικόνα 7-7 – Δομή Συνελκτικού Νευρωνικού δικτύου.....	130 -
Εικόνα 7-8 – Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου	131 -
Εικόνα 7-9 - Training – Validation Process	133 -
Εικόνα 7-11 – Training – Validation Accuracy Plot	134 -
Εικόνα 7-12 – Confusion Matrix Κατηγοριοποίησης Βλαβών Σφαιροτριβέων..	137 -
Εικόνα 9-1 - Γραφική Απεικόνιση Σετ Δεδομένων.....	148 -
Εικόνα 9-2 - Scatter Plot Input Layer Dense 19	149 -
Εικόνα 9-3 - Scatter Plot Input Layer Dense 18	149 -
Εικόνα 9-4 - Scatter Plot Input Layer Flatten 9.....	150 -

9.6 Συγκεντρωτική λίστα πινάκων

Πίνακας 7-1 – Αποτελέσματα Δοκιμών Μοντέλου με διαφορετικές ρυθμίσεις .-	135 -
Πίνακας 7-2 – Αποτελέσματα Δοκιμών Δικτύου με νέα, άγνωστα δεδομένα	138 -
Πίνακας 9-1- CWRU Bearing Fault Data Set Details[87].....	144 -
Πίνακας 9-2 – Συνομοτεύσεις και αντιστοιχία Ελληνικών και Αγγλικών όρων...	150 -

10. Βιβλιογραφία

[1]Abdeljaber.O etal (2018) - Fault Detection and Severity Identification of Ball Bearings by Online Condition Monitoring

[2] Agoston.K (2015) – Fault Detection of the Electric Motors Based on Vibration Analysis

[3]Αρετός.Ε (2020) - Διπλωματική Εργασία «Τεχνητά νευρωνικά δίκτυα και εφαρμογές αυτών στην εκπαίδευση»– Ελληνικό Ανοικτό Πανεπιστήμιο

[4]Αργυράκης.Π (2001) - Νευρωνικά Δίκτυα και Εφαρμογές - Ελληνικό Ανοικτό Πανεπιστήμιο

[5]Bayu.T etal (2022) - Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals

[6]Bingzhe.W etal (2017) - Reducing Overfitting in Deep Convolutional Neural Networks Using Redundancy Regularizer

[7]Βλαχάβας.Ι, Κεφαλάς.Π, Βασιλειάδης.Ν, Κόκκορας.Φ, Σακελλαρίου.Η Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Nets) Β' Έκδοση

[8]British Standard Glossary of Maintenance management terms in terotechnology (1984)

[9]Bush.M (2008) - The Waddington Effect

[10]Γεωργούλη.Κ (2015) - Τεχνητή Νοημοσύνη – Εκδόσεις Κάλλιπος

[11]Chao.Z etal (2016) - An optimized ensemble local mean decomposition method for fault detection of mechanical components

[12]Coanda.P etal (2020) - A state of the art of predictive maintenance techniques

[13]EN 13306:2010, (2010) Maintenance Terminology. European Standard. CEN (European Committee for Standardization), Brussels

[14]Gackowiec.P (2019) - General overview of maintenance strategies – concepts and approaches

[15]GEA – Vibration Analysis Services presentation

[16]Gholamalinezhad.H (2009) - Pooling Methods in Deep Neural Networks, a Review

[17]Goodfellow.I etal (2015) - Deep Learning - MIT Press book

[18]Han.T etal (2007) - Feature-based fault diagnosis system of induction motors using vibration signal. Journal of Quality in Maintenance Engineering

[19]Hopfield.J (1982) - Neural Networks and Physical Systems with Emergent Collective Computational Abilities

[20]International Safety Management Code (ISM) – IMO – London 2010

[21]International Standard ISO2372 (1974) – Mechanical Vibration of Machines with operating speeds from 10 to 200 rev/sec

[22]IRD Mechanalysis Limited (2013) - IRD811Vibration Spike Energy Detector Operation & Maintenance Manual

[23]Janssens.O etal (2016) – Convolutional Neural Network Based Fault Detection for Rotating Machinery

- [24]Keiron.O, Nash.R (2015) - An Introduction to Convolutional Neural Networks
- [25]Kiranyaz.S etal (2020) - 1D convolutional neural networks and applications: A survey
- [26]Kiranyaz.S etal (2015) - Convolutional Neural Networks for Patient Specific ECG Classification
- [27]Kolar.D etal (2020) Fault Diagnosis of Rotary Machines Using Deep Convolutional Neural Network with Wide Three Axis Vibration Signal Input
- [28]Κόλλιας.Σ, Σταμου.Γ (2022) - Νευρωνικά Δίκτυα και Ευφυή Υπολογιστικά Συστήματα — Ε.Μ.Π - ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΚΑΙ ΜΑΘΗΣΗΣ
- [29]Konrad.E etal (2017) - Proactive maintenance as success factor for use-oriented Product-Service Systems
- [30]LeCun.Y etal (1998) - GradientBased Learning Applied to Document Recognition
- [31]Mais.J - SKF - Spectrum Analysis - The key features of analyzing spectra
- [32]Μπάτσιος.Ι (2021) - Διπλωματική Εργασία «Μηχανική και ενισχυτική μάθηση μέσω του αλγορίθμου Q-learning»,– Πανεπιστήμιο Θεσσαλίας
- [33]Μπιλάλης.Σ (2017) - Συντήρηση μηχανολογικού εξοπλισμού στη βιομηχανία παραγωγής πλαστικών προϊόντων για τρόφιμα – Πτυχιακή Εργασία - Τεχνολογικο Εκπαιδευτικο Ιδρυμα Δυτικής Ελλάδας
- [34]Νήρας.Γ (2021) - Εξελιγμένες τεχνικές συντήρησης στην εποχή της Βιομηχανίας 4.0 - Διπλωματική Εργασία – Ελληνικό Ανοικτό Πανεπιστήμιο (2021)
- [35]Pham. H etal – 2018 - Efficient Neural Architecture Search via Parameter Sharing
- [36]Qiu.S etal (2018) - Flexible Rectified Linear Units for Improving Convolutional Neural Networks
- [37]Randall.R (2011) – Vibration-based Condition Monitoring
- [38]Rikiya.Y etal (2018) - Convolutional neural networks an overview and application in radiology

[39]Ροδόπουλος.Κ (2016) - Μέθοδοι διάγνωσης βλαβών μηχανολογικού εξοπλισμού από δυναμικές μετρήσεις σε μεταβαλλόμενες συνθήκες λειτουργίας – Διδακτορική Διατριβή - Εθνικό Μετσόβιο Πολυτεχνείο

[40]Rosmaini.A etal (2012) -An overview of time-based and condition-based maintenance in industrial application

[41]Ruder.S (2017) - An overview of gradient descent optimization algorithms

[42]Samer.H etal – (2015) - Using Convolutional Neural Networks for Image Recognition

[43]Scheffer.C, Girdhar.P – Machinery Vibration Analysis & Predictive Maintenance (2004)

[44]Schokry.A (2011) - Introduction to Maintenance Second - Islamic University of Gaza

[45]Shangjun.M etal (2019) - A Lighted Deep Convolutional Neural Network Based Fault Diagnosis of Rotating Machinery (2019)

[46]SKF Reliability Systems (2000)- Vibration Diagnostic Guide

[47]Souza.R etal (2019) - Deep learning for diagnosis and classification of faults in industrial rotating machinery

[48]Srinivasamurthy.R (2018) - Understanding 1D Convolutional Neural Networks Using Multiclass Time-Varying Signals

[49]Srivastava.N etal (2014) - Dropout: A Simple Way to Prevent Neural Networks from Overfitting

[50]Tawanda.M (2015) - Machinery Maintenance Yesterday, Today and Tomorrow in the Manufacturing Sector

[51]Tomarchio.G etal (2018) - Jumping into Industry 4.0 with Predictive Maintenance Solutions

[52]Wade.S etal (2015) – Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study

[53]Waeyenbergh.G etal (2022) - Maintenance concept development: A case study

[54]Χατζηλάου.Ι, Κουπατσιάρης.Δ Π.Ν (2008) - Γ.Ι Εισαγωγή στα Νευρωνικά Δίκτυα - Σχολή Ναυτικών Δοκίμων

[55]Xiaojie.G etal (2016) - Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis

[56]Yongbo.L etal (2018) - Rotating machinery fault diagnosis based on convolutional neural network and infrared thermal imaging

[57]Ženišek.D (2019) - Historical Overview of Maintenance Management Strategies: Development from Breakdown Maintenance to Predictive Maintenance in Accordance with Four Industrial Revolutions

[58]Zhang.W etal (2017) - A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load

[59]Zhang.W etal (2017) - Bearings Fault Diagnosis Based on Convolutional Neural Networks with 2- D Representation of Vibration Signals as Input

[60]Zhibin.Z etal (2020) - Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study

[61]ZhiQiang.C etal (2015) - Gearbox Fault Identification and Classification with Convolutional Neural Networks

Πηγές από το διαδίκτυο

[62]Andersson.M - Maintenance Manual - MaintMaster Systems AB – <https://mainmaster.com>

[63]Batch Normalization in Convolutional Neural Networks
<https://www.baeldung.com/cs/batch-normalization-cnn>

[64]Batch Norm Explained Visually — How it works, and why neural networks need it <https://towardsdatascience.com/batch-norm-explained-visually-how-it-works-and-why-neural-networks-need-it-b18919692739>

[65]Brownlee.J (2023) - A Gentle Introduction To Sigmoid Function
<https://machinelearningmastery.com/a-gentle-introduction-to-sigmoid-function/>

[66] Convolutional Neural Networks (CNN) – Super Data science -
<https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-1-convolution-operation>

[67]Convolutional Neural Networks - <https://www.ibm.com/topics/convolutional-neural-networks>

[68]Convolution <https://en.wikipedia.org/wiki/Convolution>

[69]Deep learning basics — input normalization <https://medium.com/analytics-vidhya/deep-learning-basics-input-normalization-670735d3a832>

[70]Engineering Shock & Vibration Definitions
<https://hutchinsonai.com/engineering-capabilities/>

[71]Fully Connected Layers in Convolutional Neural Networks
<https://indiantechwarrior.com/fully-connected-layers-in-convolutional-neural-networks/>

[72]Gradient Descent in Machine Learning
<https://www.javatpoint.com/gradient-descent-in-machine-learning>

[73]How convolutional neural networks work, in depth - Brandon Rohrer
https://www.youtube.com/watch?v=JB8T_zN7ZC0&t=646s

[74]How Deep Neural Networks Work - Full Course for Beginners
<https://www.youtube.com/watch?v=dPWYUELwIdM&t=11638s>

[75]How is Vibration Measured
https://reliabilityweb.com/articles/entry/how_is_vibration_measured

[76]Introduction to Convolution Neural Network
<https://www.geeksforgeeks.org/introduction-convolution-neural-network/>

[77]Introduction to Convolutional Neural Networks
<https://www.theclickreader.com/introduction-to-convolutional-neural-networks/>

[78]Loss and Loss Functions for Training Deep Learning Neural Networks - Jason Brownlee PhD
<https://machinelearningmastery.com/loss-and-loss-functions-for-training-deep-learning-neural-networks/>

[79]Log Loss Function explanation - Alex Dyakonov
<https://dasha.ai/en-us/blog/log-loss-function>

[80]MIT 6.S191 (2020): Convolutional Neural Networks -2022- Alexander Amini
<https://www.youtube.com/watch?v=uapdILWYTzE&t=2046s>

[81]Ράπτης,Σ (2021) - Τι είναι η μηχανική μάθηση (machine learning); – Μέρος Α: “Εισαγωγή” <https://2science.gr/machine-learning-1/>

[82]Reynolds.A (2012) Large-scale image recognition: AlexNet
<https://anhreynolds.com/blogs/alexnet.html>

[83]Richmond.A (2020) - Understanding Parameter Sharing (or weights replication) Within Convolutional Neural Networks.
<https://towardsdatascience.com/understanding-parameter-sharing-or-weights-replication-within-convolutional-neural-networks-cc26db7b645a>

[84]Sagar.S(2017) - Activation Functions in Neural Networks
<https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>

[85]Sumit.S (2018) - A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

[86]Wavelet Transforms in MATLAB
<https://www.mathworks.com/discovery/wavelet-transforms.html>

[87]Bearing Data Center - Seeded Fault Test Data
<https://engineering.case.edu/bearingdatacenter>

[88]What is overfitting - <https://www.ibm.com/in-en/topics/overfitting>

[89]Vibration Analysis - <http://freevibrationanalysis.blogspot.com/>

[90]Vibration Sensor Technology in Predictive Maintenance Applications
<https://www.te.com/usa-en/whitepapers/sensors/predictive-maintenance-with-vibration-sensors.html>

[91]Yann LeCun: An Early AI Prophet <https://www.historyofdatascience.com/yann-lecun/>

[92]Zero Padding In Convolutional Neural Networks Explained
https://deeplizard.com/learn/video/qSTv_m-KFk0

Sites Για την εκμάθηση Προγραμματισμού Συνελκτικού Νευρωνικού Δικτύου (Convolutional Neural Network) Με Python

[93]Training a Model from Scratch
<https://www.mathworks.com/solutions/deep-learning/examples/training-a-model-from-scratch.html>

[94] Create Simple Image Classification Network
<https://www.mathworks.com/help/deeplearning/gs/create-simple-deep-learning-classification-network.html>

[95] Training an Artificial Neural Network with Matlab – Machine Learning for Engineers -
<https://www.youtube.com/watch?v=xOzh6PMk21I&list=PLUrb9ObKDCj-zuzSYKpFONf3JE4W7NHLE&index=14>

[96] Bearing-fault-diagnosis - <https://github.com/topics/bearing-fault-diagnosis>

[97] Intelligent Machines – Mohan Kumar Dash
<https://www.youtube.com/@Mohankumardash/playlists>

[98] TensorFlow 2.0 Complete Course - Python Neural Networks for Beginners Tutorial - <https://www.youtube.com/watch?v=tPYj3fFJGjk>

[99] How to Implement a CNN for Music Genre Classification
<https://www.youtube.com/watch?v=dOG-HxpbMSw&list=PL-wATfeyAMNrtbkCNsLcpoAyBBRJZVInf&index=17>

[100] SOLVING OVERFITTING in neural networks
<https://www.youtube.com/watch?v=Gf5DO6br0ts>

[101] Using TensorBoard in Notebooks
https://www.tensorflow.org/tensorboard/tensorboard_in_notebooks