



**ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ**  
**ΣΧΟΛΗ ΜΗΧΑΝΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ**  
**Τομέας Μηχανολογικών Κατασκευών & Αυτομάτου Ελέγχου**  
**Εργαστήριο Δυναμικής & Κατασκευών**

Διπλωματική εργασία

**Ματθαίος Τσίνης**

**Ταξινόμηση βλαβών περιστρεφόμενων μηχανών με εφαρμογή μεθόδων  
επεξεργασίας εικόνας και μηχανικής μάθησης**

**Επιβλέπων:** Δρ. Ιωάννης Αντωνιάδης  
Καθηγητής ΕΜΠ

Αθήνα 2020





# ΠΕΡΙΕΧΟΜΕΝΑ

<b>ΕΥΧΑΡΙΣΤΙΕΣ</b> .....	5
<b>ΠΕΡΙΛΗΨΗ</b> .....	6
<b>ABSTRACT</b> .....	7
<b>ΚΕΦΑΛΑΙΟ 1 – ΕΙΣΑΓΩΓΗ</b> .....	8
<b>ΚΕΦΑΛΑΙΟ 2 – ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ</b> .....	10
2.1 Φασματική Κύρτωση (Spectral Kurtosis).....	10
2.2 Φασματική ανάλυση ανώτερης τάξης (Bispectrum).....	12
2.3 Μέθοδος SURF.....	18
2.3.1 Εισαγωγή.....	18
2.3.2 Εντοπισμός σημείων ενδιαφέροντος.....	19
2.3.3 Αναπαράσταση σε κλιμακούμενο χώρο (space-scale).....	21
2.3.4 Χωρικός εντοπισμός σημείων ενδιαφέροντος.....	22
2.3.5 Περιγραφή των σημείων ενδιαφέροντος.....	22
2.3.6 Δημιουργία διανυσμάτων περιγραφής SURF.....	23
2.4 Ομαδοποίηση K-means.....	25
2.5 Μηχανές διανυσματικής υποστήριξης (SVM).....	31
2.5.1 Βασικά στοιχεία θεωρίας μηχανών διανυσματική υποστήριξης (SVM).....	31
2.5.2 Γραμμικές μηχανές διανυσματικής υποστήριξης.....	31
2.5.3 Ταξινόμηση Δεδομένων.....	36
<b>ΚΕΦΑΛΑΙΟ 3 – ΠΕΡΙΓΡΑΦΗ ΜΕΘΟΔΟΛΟΓΙΑΣ</b> .....	37
3.1 Επεξεργασία σημάτων και εξαγωγή bispectrum ( <i>extractBispectrum.m</i> ).....	39
3.2 Εξαγωγή Χαρακτηριστικών ( <i>trainAndPredict.m</i> ).....	41
3.2.1.1 Εξαγωγή διανυσμάτων SURF.....	41
3.2.1.2 Ομαδοποίηση των διανυσμάτων SURF με χρήση Kmeans αλγορίθμου και εξαγωγή του τελικού SURF χαρακτηριστικού.....	43
3.2.2 Εξαγωγή Χαρακτηριστικών από την κλίμακα του γκρι.....	44
3.2.3 Εξαγωγή Χαρακτηριστικών καμπυλότητας (circularity).....	46
3.3 Εκπαίδευση με Support Vector Machine και πρόβλεψη ( <i>trainAndPredict.m</i> ).....	48
<b>ΚΕΦΑΛΑΙΟ 4 – ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ- ΦΘΟΡΑ ΣΕ ΡΟΥΛΕΜΑΝ</b> .....	49
4.1 Προετοιμασία δεδομένων.....	49
4.2 Σετ 1 : Φθορά εσωτερικού δακτυλίου ρουλεμάν.....	51
4.3 Σετ 2 : Φθορά εξωτερικού δακτυλίου ρουλεμάν.....	62
<b>ΚΕΦΑΛΑΙΟ 5 – ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ- ΣΠΗΛΑΙΩΣΗ</b> .....	73
5.1 Πειραματική εγκατάσταση.....	73
5.2 Πειραματική διάταξη Πανεπιστημίου του Lancaster.....	73
5.3 Πειραματική διάταξη Εθνικού Μετσόβιου Πολυτεχνείου.....	96
<b>ΚΕΦΑΛΑΙΟ 6 – ΣΥΜΠΕΡΑΣΜΑΤΑ</b> .....	118
<b>ΠΑΡΑΡΤΗΜΑ – ΚΩΔΙΚΕΣ MATLAB</b> .....	119
<b>ΒΙΒΛΙΟΓΡΑΦΙΑ</b> .....	128

# ΕΥΧΑΡΙΣΤΙΕΣ

Η εκπόνηση της παρούσας εργασίας οφείλεται στη συνεχή υποστήριξη και καθοδήγηση του κ. Ιωάννη Αντωνιάδη και του κ. Χρήστου Γιακόπουλου. Θα ήθελα να τους ευχαριστήσω θερμά για την επιστημονική καθοδήγηση, την υπομονή και τις συμβουλευτικές τους παρεμβάσεις.

Η ολοκλήρωση αυτής της διπλωματικής θα ήταν αδύνατη χωρίς την συνεισφορά του κ. Ιωάννη Αναγνωστόπουλου, του κ. Γεώργιου Μουσμούλη και του Εργαστηρίου Υδροδυναμικών Μηχανών του ΕΜΠ (Τομέας Ρευστών), καθώς μου παραχώρησαν δεδομένα απαραίτητα για την εκπόνηση της εργασίας.

Ακόμη ένα μεγάλο ευχαριστώ στους γονείς μου, την αδελφή μου, τους φίλους και τις φίλες μου, που στάθηκαν δίπλα μου και προσέφεραν σημαντική ψυχολογική υποστήριξη κατά τη διάρκεια των σπουδών μου.

## ΠΕΡΙΛΗΨΗ

Στόχος της παρούσας μελέτης είναι διάγνωση και ταξινόμηση μηχανολογικών βλαβών με επεξεργασίας και αναγνώριση εικόνας, μέσω χρήση τεχνικών μηχανικής μάθησης. Στην εργασία αυτή θα μελετήσουμε 4 σειρές σημάτων, οι οποίες παρακολουθούν: (i) την εξέλιξη απο φυσιολογική λειτουργία μηχανής σε φθορά εσωτερικού δακτυλίου ένσφαιρου εδράνου, (ii) την εξέλιξη απο φυσιολογική λειτουργία μηχανής σε φθορά εξωτερικού δακτυλίου ένσφαιρου εδράνου, (iii) την εξέλιξη απο φυσιολογική λειτουργία αντλίας στην εμφάνιση σπηλαιώσης.

Τα βήματα που ακολουθούνται έχουν ως σκοπό την δημιουργία ενός μοντέλου, ικανού να κατατάξει την κατάσταση μιας μηχανής σε φυσιολογική ή μη φυσιολογική. Για τον σκοπό αυτό, τα σήματα που λαμβάνουμε από τους κραδασμούς τον μηχανών επεξεργάζονται και φιλτράρονται, ώστε να απομονωθεί η περιοχή που εμφανίζεται η μέγιστη φασματική κύρτωση. Στη συνέχεια αποδιαμορφώνουμε το φιλτραρισμένο σήμα και εφαρμόζοντας στατιστική φασματική ανάλυση τρίτης τάξης (μέθοδος Bispectrum), εξάγουμε τις απεικονίσεις, στις οποίες θα εφαρμόσουμε τις τεχνικές αναγνώρισης εικόνας.

Από τις προκύπτουσες εικόνες (bispectrum) εξάγουμε 3 χαρακτηριστικά: (i) χαρακτηριστικά από την μέθοδο SURF (Speeded-up Robust Features), (ii) αποχρώσεις στην κλίμακα του γκρι και (iii) καμπυλότητα (circularity) των bispectrum. Τα διανύσματα των ενδιαφέροντων σημείων, που εξάγονται από την μέθοδο SURF, ομαδοποιούνται σε κέντρα φυσιολογικής και μη φυσιολογικής λειτουργίας με την μέθοδο K-means. Για κάθε εικόνα εκπαίδευσης υπολογίζεται το άθροισμα των SURF διανυσμάτων που ανήκουν σε φυσιολογικά και μη φυσιολογικά κέντρα και προκύπτει το χαρακτηριστικό (i) ως η διαφορά αυτών. Τα χαρακτηριστικά αυτά χρησιμοποιούνται για την εκπαίδευση μοντέλου ταξινόμηση μέσω μηχανών διανυσματικής υποστήριξης (SVM).

# SUMMARY

The aim of this thesis is the diagnosis and classification of mechanical faults with image processing and recognition, through machine learning techniques. In this paper we will study 4 series of signals that follows: (i) the evolution from normal machine operation to the appearance of fault of bearing's inner race, (ii) the evolution from normal machine operation to the appearance of fault of bearing's outer race and (iii) the evolution from normal pump operation to the appearance of cavitation.

The steps that are followed has as main aim the creation of a model, capable of classifying the condition of a machine to normal or abnormal. For that purpose, the signals we get from the vibrations of the machines are processed and filtered, in order to isolate the frequency area with maximum spectral kurtosis. Subsequently we decompose the filtered signal and we apply 3<sup>rd</sup> order spectral statical analysis (Bispectrum method), extracting the images, in which we will apply the image recognition techniques

From the resulting images (bispectrum) we extract 3 features: (i) features from SURF method, (ii) gray-scale shades, (iii) circularity of bispectrum. The vectors of interesting points extracted from SURF are classified in centers of normal and abnormal operation through K-means method. For every training image, we calculate the sum of SURF vectors that belong to normal and abnormal center and after the subtraction of the 2 sums we get the feature (i). The 3 features are used to train a predictive model through support vector machines (SVM).

## Κεφάλαιο 1 – Εισαγωγή

Οι περιστρεφόμενες μηχανές αποτελούν αναπόσπαστο μέρος μιας πληθώρας συστημάτων της βιομηχανίας και η καλή κατάσταση λειτουργίας τους έχει αντίκτυπο όχι μόνο στην παραγωγή αλλά και στην ασφάλεια των εργαζομένων. Για αυτόν το λόγο, η έγκαιρη και αποτελεσματική διάγνωση βλαβών και συντήρηση έχει γίνει αντικείμενο έρευνας και μελέτης εδώ και πολλές δεκαετίες.

Μία μηχανή που έχει σχεδιαστεί και κατασκευαστεί για να εκτελεί μια συγκεκριμένη λειτουργία, αναμένεται να το κάνει όταν εγκαθίσταται σε μια εγκατάσταση για τη σχεδιαζόμενη διάρκεια ζωής της. Παρ'όλα αυτά, για λόγους που δεν μπορεί κάποιος να ελέγξει, αποτυγχάνει σε αυτό για διάφορους λόγους. Μερικοί από τους λόγους θα μπορούσαν να είναι ο ελαττωματικός σχεδιασμός του μηχανήματος, κατώτερο υλικό, κακή κατασκευή, λανθασμένη εγκατάσταση και λάθος λειτουργική διαδικασία, μεταξύ πολλών άλλων. Ωστόσο, σε ένα εργοστάσιο όπου η παραγωγή θα μπορούσε να είναι τελικά προϊόντα, η αστοχία του εγκατεστημένου μηχανήματος θα οδηγούσε σε μεγάλες οικονομικές απώλειες. Σε ακόμα σοβαρότερες περιπτώσεις, η αστοχία ενός μηχανήματος θα μπορούσε οδηγήσει στον τραυματισμό ή ακόμα και στην απώλεια ανθρώπινων ζωών και όχι μόνο.

Καθίσταται, λοιπόν, φανερή η επιτακτική ανάγκη για τον έλεγχο και την έγκαιρη διάγνωση βλάβης των μηχανών και με την ανάπτυξη της επιστήμης και της τεχνολογίας, οι μέθοδοι διάγνωσης σφαλμάτων γίνονται το επίκεντρο στον τομέα της διάγνωσης σφαλμάτων περιστρεφόμενων μηχανημάτων. Πλέον, είναι εφικτό να διαγνώσουμε μια βλάβη, όχι μόνο μετά την καταστροφή μιας μηχανής, αλλά από την αρχή της εμφάνισης της καθώς και την εξέλιξη της. Η επικρατούσα μέθοδος ελέγχου και πρόληψης βασίζεται στην μέτρηση των κραδασμών και των δονήσεων της μηχανής μέσω σημάτων που λαμβάνονται από επιταχυνσιόμετρα, καθώς κάθε μηχανολογική βλάβη, αφενός αυξάνει τα επίπεδα θορύβου της μηχανής και αφεταίρου εμφανίζεται σε συγκεκριμένες συχνότητες διεγείροντας ταυτόχρονα ιδιοσυχνότητες του συστήματος.

Οι παραδοσιακές διαγνωστικές μέθοδοι αξιοποιούν ένα μεγάλο εύρος χαρακτηριστικών των σημάτων κραδασμών προκειμένου να επιτευχθεί όσο το δυνατόν υψηλότερη ακρίβεια. Ένα μεγάλο μέρος της βιβλιογραφίας ασχολείται με την εξαγωγή, ερμηνεία και συνδυασμό τέτοιων χαρακτηριστικών τόσο στο πεδίο του χρόνου όσο και στο πεδίο της συχνότητας. Παραδείγματα αποτελούν η μέση τιμή (mean value), η τιμή κορυφής (peak value), η τυπική απόκλιση (standard deviation), η διακύμανση (variance), η διασπορά (dispersion), η μέση τετραγωνική ρίζα (Root Mean Square RMS), ο βαθμός ασυμμετρίας (skewness) και η κύρτωση (kurtosis). Η επιλογή των κατάλληλων χαρακτηριστικών εξαρτάται από την εφαρμογή και το είδος των προς έλεγχο εξαρτημάτων.

Στην παρούσα εργασία, σε αντίθεση με τις μονοδιάστατες παραδοσιακές διαγνωστικές μεθόδους, θα ακολουθήσουμε μια αυτοματοποιημένη εξαγωγή χαρακτηριστικών και διάγνωση βλαβών από χώρο δύο διαστάσεων και συγκεκριμένα εικόνων bispectrum. Η μέθοδος που θα παρουσιαστεί συνδυάζει τεχνικές επεξεργασίας σήματος, επεξεργασίας εικόνας, εξαγωγής χαρακτηριστικών και μηχανικής μάθησης, με στόχο την αναγνώριση σφαλμάτων σε ένσφαιρους τριβείς και την εμφάνιση σπηλαίωσης σε προπέλες.

Συνοπτικά τα βήματα που θα ακολουθήσουμε είναι: (1) απομόνωση συχνοτικής περιοχής του σήματος με τη μέγιστη φασματική κύρτωση και αποδιαμόρφωση, (2) μετατροπή του σήματος σε εικόνα με χρήση bispectrum, (3) εξαγωγή χαρακτηριστικών μέσω SURF, αποχρώσεων του γκρι και καμπυλότητας των bispectrum, (4) διάγνωση βλάβης μέσω μηχανής διανυσματική υποστήριξης (SVM).



Αρχικά τα σήματα που έχουμε απο τις μετρήσεις των επιταχυνσιόμετρων, επεξεργάζονται μέσω της Fast\_Kurtogram του J. Antoni (2005) για να βρεθεί η συχνοτική περιοχή του με τη μέγιστη φασματική κύρτωση. Στη συνέχεια το σήμα φιλτράρεται μέσω ενός ζωνοπερατού φίλτρου (Butterworth), κρατώντας μόνο τις συχνότητες τις παραπάνω εντοπισμένης περιοχής. Συνήθως αυτή η περιοχή εμφανίζεται σε υψηλές συχνότητες, που φτάνουν μέχρι το μισό της συχνότητας δειγματοληψίας, και αντιστοιχούν σε κάποια ή κάποιες διεγερμένες ιδιοσυχνότητες. Καταλήγουμε στο τελικό σήμα μετά απο αποδιαμόρφωση του φιλτραρισμένου σήματος, με χρήση του μετασχηματισμού Hilbert.

Προκειμένου να μπορέσει να εφαρμοστεί οποιαδήποτε μέθοδος επεξεργασίας εικόνας, θα πρέπει να μετατραπούν τα επεξεργασμένα χρονικά σήματα κραδασμών σε εικόνες. Για το σκοπό αυτό θα αξιοποιηθεί φασματική ανάλυση ανώτερης τάξης (HOS), η οποία αποτελεί τυπική μέθοδο επεξεργασίας σήματος και προσφέρει μεγάλο πλήθος διαγνωστικών πληροφοριών. Συγκεκριμένα εφαρμόζεται στατιστική φασματική ανάλυση τρίτης τάξης (bi-spectrum), η οποία μπορεί να διατηρεί πληροφορίες για τη φάση του σήματος και έχει υψηλή αντίσταση στο θόρυβο. Οι εικόνες που δημιουργούνται από αυτήν την επεξεργασία θα χρησιμοποιηθούν ως βάση για τον αλγόριθμο αναγνώρισης.

Αφού μετατραπούν τα χρονικά σήματα σε εικόνες, καλούμαστε να εξάγουμε χαρακτηριστικά απο αυτές, που τις καθιστούν μοναδικές και θα μας βοηθήσουν στη διακριτοποίηση τους. Για την εξαγωγή αντιπροσωπευτικών σημείων για κάθε εικόνα θα χρησιμοποιήσουμε κατά κύριο λόγο την μέθοδο SURF (Speeded-Up Robust Features), η οποία υπερτερεί σε σχέση με τον προκάτοχο του SIFT, τόσο σε ακρίβεια, όσο και σε ταχύτητα. Η μέθοδος SURF εντοπίζει σημεία ενδιαφέροντος (πχ αιχμές, αλλαγές στον χρωματισμό), τα οποία περιγράφει με ένα διάνυσμα 64 διαστάσεων. Το πεδίο εφαρμογής της μεθόδου SURF καλύπτει προβλήματα από οπτική παρακολούθηση (image tracking) μέχρι αναδόμηση τριών διαστάσεων. Για αυτούς τους λόγους επιλέχτηκε για να εξάγει χαρακτηριστικά σημεία από τα bispectrum. Τα αντίστοιχα διανύσματα που εξαχθήκαν ομαδοποιήθηκαν με χρήση αλγορίθμου kmeans σε κλάσεις προκειμένου να καταταχθούν σε bispectrum φυσιολογική ή μη λειτουργίας. Θα επεκταθούμε σε αυτό στο κεφάλαιο 3 – Μεθοδολογία.

Τα άλλα 2 χαρακτηριστικά που θα εξάγουμε αφορούν στις αποχρώσεις των bispectrum και στην καμπυλότητα των περιγραμμάτων τους. Δεδομένου του γεγονότος ότι η μέθοδος SURF δουλεύει σε εικόνες στην κλίμακα του γκρι, το ιστόγραμμα αποχρώσεων είναι επίσης στην κλίμακα του γκρι. Όπως θα δούμε και στο κεφάλαιο 3 τα σήματα με χαμηλή ενέργεια έχουν bispectrum χαμηλού ύψους και αντίστοιχα σήματα υψηλής ενέργειας έχουν πιο ψηλά bispectrum και αυτή η διαφοροποίηση καθίσταται ορατή απο τον διαφορετικό χρωματισμό τους. Επίσης, παρατηρήθηκε ότι τα περιγράμματα των bispectrum φυσιολογικής κατάστασης και μη φυσιολογικής κατάστασης διαφέρουν. Τη διαφοροποίηση αυτή την μετρήσαμε με την μαθηματική σχέση για την καμπυλότητα

$$circularity = \frac{4 \cdot A \cdot \pi}{P^2}, \text{ όπου } A \text{ το εμβαδό του bispectrum και } P \text{ η περίμετρος του.}$$

Τέλος, για την κατηγοριοποίηση της κατάστασης της μηχανής, κατασκευάζεται ένα μοντέλο ταξινόμησης με χρήση μηχανών διανυσματικής υποστήριξης (SVM) το οποίο σε πρώτο στάδιο εκπαιδεύεται με ένα σετ σημάτων από διάφορες καταστάσεις της μηχανής και στη συνέχεια μπορεί να χρησιμοποιηθεί για κατηγοριοποίηση νέων σημάτων.

## Κεφάλαιο 2 - Θεωρητικό υπόβαθρο

### 2.1 Φασματική Κύρτωση (Spectral Kurtosis)

Η φασματική κύρτωση ενός σήματος  $x(t)$  ορίζεται ως η κανονικοποιημένη φασματική ροπή τέταρτης τάξης:

$$K_x(f) = \frac{S_{4,x}(f)}{S_{2,x}(f)^2} - 2 \quad \text{με} \quad S_{n,x}(f) = \langle |X(t,f)|^n \rangle$$

όπου  $\langle \cdot \rangle$  είναι τελεστής χρονικού μέσου και  $X(t,f)$  αναπαριστά την μιγαδική περιβάλλουσα του σήματος  $x(t)$ . Το  $X(t,f)$  μπορεί να υπολογιστεί με χρήση short time Fourier transformation (STFT).

$$X(t,f) = \sum_{n=t}^{t+N_w-1} h(n-t)x(n)e^{-j2\pi fn}$$

όπου  $h(t)$  η ανάλυση παραθύρου μήκους  $N_w$ .

Η φασματική κύρτωση μπορεί να χρησιμοποιηθεί σαν ένα μέτρο, εξαρτομένο συχνότητας, της μη-στατικότητας ενός σήματος. Έχει δειχθεί ότι είναι ευαίσθητη στα μικρα μη-στατικά φαινόμενα που υπάρχουν σε ένα σήμα και μπορεί να υποδείξει σε ποιές συχνότητες εμφανίζονται αυτά τα μεταβατικά φαινόμενα.

Επιπλέον η SK μπορεί να χρησιμοποιηθεί στο σχεδιασμό φίλτρων εντοπισμού ενός μη στατικού σήματος  $s(t)$  από ένα στατικό θόρυβο κανονικής κατανομής  $n(t)$ . Αυτά τα φίλτρα είναι χρήσιμα για τον εντοπισμό μεταβατικών καταστάσεων που είναι θαμμένες κάτω από τον θόρυβο. Έχει δειχθεί ότι η SK του αθροίσματος  $x(t) = s(t) + n(t)$  μπορεί να συσχετιστεί με την SK του μη-στατικού μέρους  $s(t)$  ως εξής:

$$K_x(f) = \frac{K_s(f)}{[1 + \rho(f)]^2}$$

όπου  $\rho(f) = S_n(f)/S_s(f)$  είναι ο λόγος φασματικής πυκνότητας ισχύος του θορύβου  $n(t)$  και του σήματος με την βλάβη  $s(t)$ , αναπαριστώντας έναν τοπικό λόγο θόρυβος-προς-σήμα σε κάθε συχνότητα.

Η τιμή  $K_x(f)$  τείνει προς την  $K_s(f)$  στις συχνότητες για τις οποίες η τιμή του  $\rho(f)$  είναι υψηλή και θα τείνει στο μηδέν όταν το φαινόμενο της υπερκάλυψης του θορύβου είναι δυνατό. Αυτό εξηγεί την μοναδική ικανότητα της SK να εξετάζει λεπτομερώς όλο το πεδίο της συχνότητας και να βρίσκει αυτές τις ζώνες συχνότητας όπου το σήμα βλάβης μπορεί να ανιχνευθεί καλύτερα.

Η SK μπορεί να εφαρμοσθεί στην διάγνωση βλαβών με τον εξής τρόπο, ο οποίος αναφέρεται από τους (Atoni & Randall, 2004), υπολογίζοντας την SK και εξετάζοντας σε κάθε ζώνη συχνότητας για ασυνήθιστα υψηλές τιμές που μπορεί να οφείλονται στην παρουσία βλάβης.

Για την εκτίμηση της SK, προτείνεται από (Atoni & Randall, 2004) μια απλή εκτίμηση βασιζόμενη στον short-time Fourier transform (SFTP). Για να χρησιμοποιηθεί αυτή η εκτίμηση θα πρέπει να ισχύουν δύο σύνθήκες.

Σ1: η μη-στατιμότητα στο σήμα έχει αργές χρονικές εξελίξεις σε σύγκριση με το μήκος του παραθύρου του SFTP.

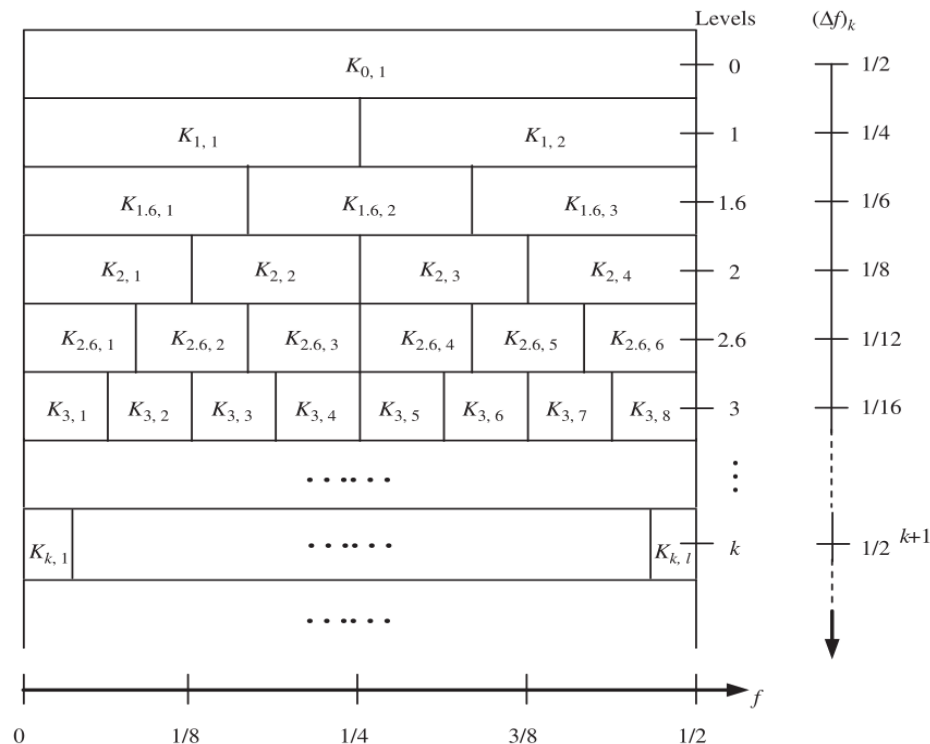
Σ2: Το μήκος συσχέτισης του σήματος είναι μικρότερο από το παράθυρο ανάλυσης του SFTP.

Παρ ότι η φασματική κύρτωση είναι ικανή να ανιχνεύσει την παρουσία βλάβης, δεν μπορεί να δώσει πληροφορίες σχετικά με την φύση της βλάβης. Θα πρέπει να εφαρμοσθούν «διαγνωστικά φίλτρα», τα οποία θα μπορέσουν να απομονώσουν το σήμα με βλάβη από τον θόρυβο που υπάρχει στο περιβάλλον.

Στην παρούσα εργασία εφαρμόζεται η έννοια του kurtogram. Η ιδέα είναι να χρησιμοποιηθεί ένα εύρωστο φίλτρο διάγνωσης με ένα επιβαλλόμενο πεδίο συχνοτήτων με δύο μόνο παραμέτρους να προσδιοριστούν. Πιο συγκεκριμένα ο σκοπός είναι τα βρεθεί η κεντρική συχνότητα  $f_c$  και το εύρος ζώνης  $B_w$  του φίλτρου το οποίο μεγιστοποιεί μερικά κριτήρια του σήματος που έχει φιλτραριστεί. Η λογική πίσω από αυτή την προσέγγιση είναι η ακόλουθη:

- Ένα φίλτρο αποκοπής ζώνης έχει πιθανότητα να επιλέξει το πεδίο συχνοτήτων στο οποίο ο δείκτης SNR είναι μέγιστος.
- Ένα φίλτρο αποκοπής ζώνης έχει πιθανότητα να επιλέξει μία πηγή παλμών ( την πιο δυνατή) ακόμα και αν υπάρχουν  $k$  άλλες πηγές στο σήμα.
- Ένα φίλτρο αποκοπής ζώνης είναι απαραίτητο για το στάδιο της προ- επεξεργασίας πριν εκτελεσθεί η αποδιαμόρφωση του σήματος.

Τέλος αξίζει να σημειωθεί ότι η υλοποίηση SK, εκτός απο την κεντρική συχνότητα και εύρος ζώνης, δίνονται να εξαγει και το αποδιαμορφωμένο σήμα αλλά και έναν διδιάστατο χάρτη (κυρτόγραμμα), που δείχνει τις τιμές της φασματικής κύρτωσης για διάφορες παραμέτρους της συχνότητας  $f$  και του εύρους  $\Delta f$ , όπως φαίνεται στο σχήμα 2.1, όπου  $K_{k,l}$  η SK του φιλτραρισμένου σήματος φίλτρου  $l$  τάξης και  $k$ -οστού επιπέδου αποσύνθεσης.



Σχήμα 1: Κυρτόγραμμα

## 2.2 Φασματική ανάλυση ανώτερης τάξης (Bispectrum)

Το πλέον διαδεδομένο διαγνωστικό εργαλείο στην επεξεργασία των δυναμικών σημάτων είναι η πυκνότητα φάσματος ισχύος PSD. Το φάσμα ισχύος ενός περιοδικού σήματος είναι η συνάρτηση συχνότητας, όπου το συνολικό εμβαδόν κάτω από την καμπύλη αυτής παρέχει τη μέση ισχύ του σήματος. Επιπλέον, το φάσμα ισχύος είναι μία πραγματική ποσότητα και ως εκ τούτου δεν παρέχει καμία πληροφορία σχετικά με τη φάση του δυναμικού σήματος.

Η συνάρτηση της πυκνότητας φάσματος ισχύος για μία διακριτή χρονική ακολουθία  $x(n)$  ορίζεται με την υποστήριξη του διακριτού μετασχηματισμού Fourier (DFT) ως εξής:

$$S_{xx} = E[ X(k)X^*(k) ] \quad (2.1)$$

όπου ο όρος  $k$  ορίζει μία διακριτή συχνοτική μεταβλητή,  $X(k)$  είναι ο μετασχηματισμός Fourier και ο αστερίσκος καθορίζει τον μιγαδικό συζυγή του όρου  $X(k)$ .

Το φάσμα ισχύος είναι δυνατόν να θεωρηθεί ως η στατιστική ροπή δεύτερης τάξης (second moment) του δυναμικού σήματος.

Τα τελευταία χρόνια, όμως, έχουν αποκτήσει περίοπτη θέση στη διαγνωστική βλαβών διαδικασίες που στηρίζονται στην επεξεργασία των ανώτερης τάξης στατιστικών χαρακτηριστικών των δυναμικών σημάτων και είναι ευρύτερα γνωστές ως στατιστικές μέθοδοι επεξεργασίας σήματος ανώτερης τάξης HOS (Higher Order Spectra, Higher Order Statistics).

Οι στατιστικές μέθοδοι επεξεργασίας σημάτων ανώτερης τάξης HOS είναι μαθηματική προέκταση των στατιστικών μεγεθών δεύτερης τάξης (second order measures), δηλαδή είναι διαδικασίες που διευρύνουν και γενικεύουν την ανάλυση των δυναμικών σημάτων με την ανάδειξη πληροφοριών που περικλείονται σε ανώτερης τάξης στατιστικές συνιστώσες του σήματος.

Επομένως, οι εν λόγω στατιστικές προσεγγίσεις βασίζονται στην αξιοποίηση των στατιστικών ροπών (moments) και συσσωρευτών (cumulants).

Το θεωρητικό αντικείμενο των στατιστικών προσεγγίσεων έχει αναπτυχθεί κάτω από ένα αυστηρό πλαίσιο, το οποίο απαιτεί μία σειρά από προϋποθέσεις που αφορούν το δυναμικό σήμα, το οποίο πρόκειται να εξετασθεί. Ένα τυχαίο σήμα  $x(n)$  μπορεί να χαρακτηριστεί με αρκετούς τρόπους, όπως το πλάτος του και η περίοδος της κυματομορφής του. Η συνάρτηση πυκνότητας πιθανότητας

PDF (probability density function) μίας χρονικής ακολουθίας εξασφαλίζει παροχή λεπτομερών πληροφοριών σχετικές με το πλάτος του σήματος. Έτσι, ένα δυναμικό σήμα είναι δυνατόν να περιγραφεί από την μορφή της καμπύλης της συνάρτησης πυκνότητας πιθανότητας PDF αυτού. Οι έμφυτες πληροφορίες της συνάρτησης πυκνότητας πιθανότητας PDF μπορούν να ποσοτικοποιηθούν με τη χρησιμοποίηση των στατιστικών ροπών και συσσωρευτών.

Η μέση τιμή (mean) ενός τυχαίου σήματος ορίζεται ως η αναμενόμενη τιμή (expected value) της τυχαίας μεταβλητής  $x(t)$ :

$$m_x(t) = E\{x(t)\} = \int_{-\infty}^{+\infty} x \cdot p_x(x, t) dx \quad (2.2)$$

όπου  $p_x(x_1; t_1) = \frac{dP_x(x_1; t_1)}{dx_1}$  είναι η συνάρτηση πυκνότητας πιθανότητας, η οποία ορίζεται ως η παράγωγος της συνάρτησης κατανομής  $P_x(x_1; t_1) = \text{prob}\{x(t_1) \leq x_1\}$ , και ο όρος  $E$  ορίζει τον τελεστή της αναμενόμενης τιμής (expectation operator). Δηλαδή, η μέση τιμή  $m_x$  εντοπίζει το κέντρο βάρους της περιοχής κάτω από την καμπύλη της πυκνότητας πιθανότητας της τυχαίας μεταβλητής.

Ακολούθως, η μεταβλητότητα (variance) της τυχαίας μεταβλητής  $x(t)$  ορίζεται από τη σχέση:

$$\sigma_x^2 = \text{Var}\{x\} = E\{(x - m_x)^2\} = \int_{-\infty}^{+\infty} (x - m_x)^2 \cdot p_x(x, t) dx \quad (2.3)$$

Η τετραγωνική ρίζα της μεταβλητότητας, δηλαδή  $\sigma_x$ , ονομάζεται τυπική απόκλιση (standard deviation) της τυχαίας μεταβλητής.

Η Ν-οστή ροπή του τυχαίου σήματος  $x(t)$  ορίζεται από την ακόλουθη σχέση:

$$m_n = E\{x^n\} = \int_{-\infty}^{+\infty} x^n \cdot p_x(x, t) dx \quad (2.4)$$

Οι περισσότερο σημαντικές ροπές της τυχαίας μεταβλητής  $x(t)$  είναι οι δύο πρώτες. Έτσι, θέτοντας  $n=1$  στη σχέση 2.4, λαμβάνεται η πρώτη ροπή που είναι η μέση τιμή της τυχαίας μεταβλητής, όπως περιεγράφηκε στη σχέση 2.2, ενώ θέτοντας  $n=2$  λαμβάνεται η δεύτερη ροπή που είναι η μέση τετραγωνική τιμή (mean square value) της τυχαίας μεταβλητής:

$$m_2 = E(x^2) = \int_{-\infty}^{+\infty} x^2 \cdot p_x(x, t) dx \quad (2.5)$$

Οι κεντρικές ροπές (central moments) είναι απλά οι ροπές της διαφοράς μεταξύ μιας τυχαίας μεταβλητής και της μέσης τιμής της, και ορίζονται ως εξής:

$$E\left((x - m_x)^n\right) = \int_{-\infty}^{+\infty} (x - m_x)^n \cdot p_x(x, t) dx \quad (2.6)$$

Για  $n=1$ , η κεντρική ροπή είναι φυσικά μηδέν, ενώ για  $n=2$  η δεύτερη κεντρική ροπή είναι η μεταβλητότητα που αναφέρθηκε παραπάνω.

Η τρίτη κεντρική ροπή ( $n=3$ ) ονομάζεται λοξότητα (skewness) και αποτελεί το καλύτερο μέτρο σύνοψης της ασυμμετρίας μιας τυχαίας διαδικασίας. Στη διεθνή βιβλιογραφία συναντάται με την ακόλουθη ομαλοποιημένη σχέση:

$$skew = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - m_x)^3}{\sigma_x^3} \quad (2.7)$$

Ένα μέτρο κύρτωσης ή ένα μέτρο της αιχμηρότητας που εμφανίζει η κατανομή μιας τυχαίας μεταβλητής αποτελεί η κεντρική ροπή τέταρτης τάξης ( $n=4$ ), η οποία ονομάζεται κύρτωση (kurtosis) και εκφράζεται από την ακόλουθη ομαλοποιημένη σχέση:

$$Kurt = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - m_x)^4}{\sigma_x^4} \quad (2.8)$$

Οι στατιστικές ροπές του τυχαίου σήματος συνδέονται με τη συνάρτηση πυκνότητας πιθανότητας PDF με την υποστήριξη της συνάρτησης παραγωγής ροπών (moment generating function), η οποία ορίζεται από την ακόλουθη σχέση:

$$\Phi(s) = \int_{-\infty}^{+\infty} p_x(x_1; t_1) \cdot e^{s \cdot x} dx \quad (2.9)$$

Η ν-οστή ροπή του τυχαίου σήματος είναι δυνατόν να υπολογισθεί από την ν-οστή παράγωγο της συνάρτησης παραγωγής ροπών  $\Phi(s)$  για  $s=0$  σύμφωνα με τη σχέση:

$$m_n = \left. \frac{d^n \Phi(s)}{ds^n} \right|_{s=0} \quad (2.10)$$

Ένας άλλος σημαντικός στατιστικός μέσος όρος είναι η χαρακτηριστική συνάρτηση (characteristic function), η οποία ισούται με το λογάριθμο της συνάρτησης παραγωγής ροπών  $\Phi(s)$ .

Οι στατιστικοί συσσωρευτές (cumulants) του τυχαίου σήματος είναι δυνατόν να προκύψουν από τον υπολογισμό των n παραγώγων της χαρακτηριστικής συνάρτησης για  $s=0$ :

$$c_n = \left. \frac{d^n \ln(\Phi(s))}{ds^n} \right|_{s=0} \quad (2.11)$$

Επίσης, οι τέσσερις πρώτοι στατιστικοί συσσωρευτές είναι δυνατόν να υπολογιστούν από τις τέσσερις πρώτες ροπές χρησιμοποιώντας τις παρακάτω σχέσεις:

$$\begin{aligned} c_1 &= m_1 \\ c_2 &= m_2 - m_1^2 \\ c_3 &= m_3 - 3 \cdot m_2 \cdot m_1 + 2 \cdot m_1^3 \\ c_4 &= m_4 - 3 \cdot m_2^2 - 4 \cdot m_3 \cdot m_1 + 12 \cdot m_2 \cdot m_1^2 - 6 \cdot m_1^4 \end{aligned} \quad (2.12)$$

Όταν η μέση τιμή του τυχαίου σήματος είναι μηδέν, οι συσσωρευτές της σχέσης 5.12 είναι:

$$\begin{aligned} c_1 &= m_1 = 0 \\ c_2 &= m_2 \\ c_3 &= m_3 \end{aligned} \quad (2.13)$$

$$c_4 = m_4 - 3 \cdot m_2^2$$

Η στατιστική φασματική ανάλυση τρίτης τάξης (Bispectrum/Bilinear Analysis) ταυτίζεται με το διπλό μετασχηματισμό Fourier του συσσωρευτή τρίτης τάξης του τυχαίου σήματος. Η γραφική αναπαράσταση της άνωθεν στατιστικής προσέγγισης αποτελεί το πρώτο και το πιο απλό από τα στατιστικά φάσματα ανώτερης τάξης (Bispectrum).

Είναι δυνατόν να εφαρμοσθεί στο κυβικό τυχαίο σήμα (cubed signal) ανάλογη διαδικασία με αυτήν που ακολουθείται για τον υπολογισμό του φάσματος ισχύος:

$$\int_{-\infty}^{+\infty} x^3(t) dt = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} E_{xxx}(f_1, f_2) df_1 df_2 \quad (2.14)$$

Έτσι, το στατιστικό φάσμα τρίτης τάξης (Bispectrum) μπορεί να εκφρασθεί από την ακόλουθη σχέση:

$$E_{xxx}(f_1, f_2) = X(f_1) \cdot X(f_2) \cdot X(f_1 + f_2) \quad (2.15)$$

Συνήθως, όμως, στη διεθνή βιβλιογραφία χρησιμοποιείται ο ακόλουθος ορισμός, ο οποίος πηγάζει από το διακριτό μετασχηματισμό Fourier του τυχαίου σήματος:

$$E_{xxx}(f_1, f_2) = X(f_1) \cdot X(f_2) \cdot X(f_1 + f_2)^* \quad (2.16)$$

Όπως έχει ήδη αναφερθεί το φάσμα ισχύος (power spectrum) αναλύει και ερμηνεύει την ροπή δεύτερης τάξης (διακύμανση) του τυχαίου σήματος στο πεδίο της συχνότητας. Με ανάλογη διαδικασία το στατιστικό φάσμα τρίτης τάξης (Bispectrum) αναλύει την ροπή τρίτης τάξης ή τη λοξότητα (skewness) της συνάρτησης πυκνότητας πιθανότητας PDF του τυχαίου σήματος.

Η ροπή τρίτης τάξης είναι μια συνάρτηση που υποστηρίζεται από δύο φασματικές μεταβλητές  $f_1$  και  $f_2$ . Σε αντίθεση με το φάσμα ισχύος, που εξετάζει τα χαρακτηριστικά μεγέθη κάθε φασματικής συνιστώσας ανεξάρτητα από τις υπόλοιπες, η ροπή τρίτης τάξης εντοπίζει και ερμηνεύει τις αλληλεπιδράσεις ανάμεσα στις φασματικές συνιστώσες του τυχαίου σήματος στις συχνότητες  $f_1$ ,  $f_2$  και  $f_1 + f_2$ . Επιπλέον, είναι σημαντικό να αναφερθεί ότι η ροπή τρίτης τάξης είναι μια μιγαδική ποσότητα



που περιλαμβάνει δύο φασματικές μεταβλητές και παρέχει πληροφορίες που αφορούν τη φάση του τυχαίου σήματος.


Ένα βασικό προνόμιο της εφαρμογής της στατιστικής φασματικής ανάλυσης ανώτερης τάξης HOS στην προβλεπτική συντήρηση στρεφόμενου μηχανολογικού εξοπλισμού πηγάζει από τις έμφυτες ιδιότητες που περικλείει μία τυχαία διαδικασία κανονικής κατανομής (Gauss distribution). Μία τυχαία διαδικασία κανονικής κατανομής χαρακτηρίζεται πλήρως από τις στατιστικές ροπές πρώτης και δεύτερης τάξης (μέση τιμή και διακύμανση). Αποδεικνύεται εύκολα πως όλοι οι συσσωρευτές ανώτερης τάξης μίας τυχαίας διαδικασίας κανονικής κατανομής είναι μηδενικοί. Έτσι, ο θόρυβος, ο οποίος ακολουθεί κανονική κατανομή, εξαφανίζεται μετά την εφαρμογή συσσωρευτών τρίτης και πλέον τάξης. Η χρήση της λέξης ‘εξαφανίζεται’ ίσως είναι υπερβολική για πραγματικές διαδικασίες, αλλά αναφέρεται για να τονίσει και να δώσει έμφαση σε αυτήν τη σημαντική ιδιότητα. Αυτό που συμβαίνει μετά την εφαρμογή των συσσωρευτών ανώτερης τάξης είναι η αύξηση του λόγου σήματος – θορύβου SNR.

Στον πραγματικό κόσμο, όμως, τα περισσότερα σήματα παρουσιάζουν μη κανονική κατανομή (non-Gaussian distribution) λόγω της ύπαρξης μη γραμμικών φαινομένων. Έτσι, το τυχαίο σήμα που περικλείει επωφελείς πληροφορίες και ακολουθεί μη κανονική κατανομή αναδύεται μέσα από την κουρτίνα του θορύβου και αποκαλύπτεται μετά την εφαρμογή στατιστικών μεθόδων επεξεργασίας που βασίζονται σε συσσωρευτές ανώτερης τάξης. Αυτή η διεργασία αποτελεί το κλειδί της στατιστικής φασματικής ανάλυσης ανώτερης τάξης HOS.

Ο διακριτός μετασχηματισμός Fourier (DFT) και το φάσμα ισχύος περιέχουν περιττές πληροφορίες άνω της συχνότητας του Nyquist, η οποία ισούται με το ήμισυ της συχνότητας δειγματοληψίας  $f_s$ . Κατά παρόμοιο τρόπο, αναπτύσσονται συμμετρίες στο πεδίο  $(f_1, f_2)$  του στατιστικού φάσματος τρίτης τάξης, και για αυτό το λόγο δεν είναι απαραίτητος ο υπολογισμός της στατιστικής φασματικής ανάλυσης τρίτης τάξης  $E_{xxx}(f_1, f_2)$  για όλα τα ζεύγη συχνοτήτων  $(f_1, f_2)$ . Η περιοχή του στατιστικού φάσματος τρίτης τάξης που περιλαμβάνει τις απαραίτητες και χρήσιμες πληροφορίες ονομάζεται στοιχειώδες ή κύριο πεδίο PD (principal domain) (σχήμα 2-1) και ορίζεται από την ακόλουθη σχέση:

$$\left\{ f_1; 1:0 \leq f_1 \leq \frac{f_s}{2}, f_2 \leq f_1, 2 \cdot f_1 + 1 = f_s \right\} \quad (2.17)$$

Για την ανάλυση των στοχαστικών σημάτων, το κύριο πεδίο PD είναι απαραίτητο να διαιρεθεί σε δύο τριγωνικές περιοχές: την εσωτερική IT (inner triangle) και την εξωτερική OT (outer triangle) περιοχή (σχήμα 2-1). Όλες οι σημαντικές πληροφορίες που ευρίσκονται στις περιοχές αυτές.



Σχήμα 2-1 : Το πεδίο της στατιστικής φασματικής ανάλυσης τρίτης τάξης και οι συμμετρίες που εμφανίζονται σε αυτό.

## 2.3 Μέθοδος SURF

### 2.3.1 Εισαγωγή

Η διαδικασία εντοπισμού κοινών σημείων μεταξύ δύο εικόνων που απεικονίζουν το ίδιο τοπίο ή αντικείμενο αποτελεί μέρος πολλών εφαρμογών μηχανικής όρασης όπως ταξινόμηση εικόνων, παραμετροποίηση καμερών και αναγνώριση αντικειμένων.

Η εύρεση τέτοιων διακριτών σημείων μπορεί να χωριστεί σε τρία βασικά βήματα. Πρώτον, επιλέγονται «σημεία ενδιαφέροντος» σε συγκεκριμένα σημεία της εικόνας, όπως γωνίες, τομές και σημεία έντονων διακυμάνσεων. Η σημαντικότερη ιδιότητα ενός «εντοπιστή» σημείων ενδιαφέροντος

είναι η επαναληψιμότητα του. Η επαναληψιμότητα εκφράζει την αξιοπιστία του εντοπιστή στο να βρίσκει τα ίδια σημεία ενδιαφέροντος κάτω από διαφορετικές συνθήκες θέασης. Στη συνέχεια η γειτονιά του κάθε σημείου ενδιαφέροντος περιγράφεται από ένα διάνυσμα χαρακτηριστικών. Αυτό το «διάνυσμα περιγραφής» πρέπει να είναι ξεχωριστό και παράλληλα εύρωστο σε θόρυβο και γεωμετρικές και φωτομετρικές παραμορφώσεις. Τέλος, τα διανύσματα περιγραφής αντιστοιχίζονται μεταξύ διαφορετικών εικόνων. Η αντιστοίχιση βασίζεται στην απόσταση μεταξύ των διανυσμάτων, π.χ. απόσταση Mahalanobis ή Ευκλείδεια απόσταση. Η διάσταση του διανύσματος περιγραφής έχει άμεση επίδραση στο χρόνο υπολογισμού και διανύσματα χαμηλότερων διαστάσεων επιλέγονται για γρηγορότερη αντιστοίχιση σημείων ενδιαφέροντος. Παρ' όλα αυτά, διανύσματα λιγότερων διαστάσεων δεν έχουν την ίδια ευκρίνεια όσο τα αντίστοιχα διανύσματα περισσότερων διαστάσεων.

Η συγκεκριμένη μέθοδος αναπτύχθηκε από τους [Herbert Bay, Andreas Ess, Tinne Tuytelaars, Luc Van Gool] με στόχο να δημιουργηθεί ένας εντοπιστής και αντίστοιχο διάνυσμα περιγραφής τα οποία τα μπορούν να υπολογιστούν ταχύτερα από τις μέχρι τότε υπάρχουσες μεθόδους χωρίς να θυσιαστεί η απόδοσή. Για το λόγο αυτό έπρεπε να επιτευχθεί μία ισορροπία μεταξύ των παραπάνω απαιτήσεων, όπως απλοποίηση της μεθόδου εντοπισμού, διατηρώντας την ακρίβεια της, και μείωση των διαστάσεων του διανύσματος περιγραφής χωρίς να μειωθεί η ικανότητα περιγραφής. Η συγκεκριμένη μέθοδος ονομάζεται SURF (Speeded-Up Robust Features) και μπορεί να επιτύχει όχι μόνο υψηλότερη ταχύτητα υπολογισμού αλλά και καλύτερη επαναληψιμότητα.

### 2.3.2 Εντοπισμός σημείων ενδιαφέροντος


Για τον εντοπισμό των σημείων ενδιαφέροντος χρησιμοποιείται μία προσέγγιση του πίνακα Hessian. Το κάθε σημείο ενδιαφέροντος εντοπίζεται από το τοπικό μέγιστο του πίνακα.

Αν θεωρήσουμε ένα συγκεκριμένο σημείο  $(x,y)$  στη γραμμή  $x$  και στήλη  $y$  της εικόνας  $I$ , ο πίνακας Hessian  $H(x,\sigma)$  στο  $x$  με φίλτρο Gaussian κλίμακας  $\sigma$  ορίζεται ως:

$$H(x,\sigma) = \begin{bmatrix} L_{xx}(x,\sigma) & L_{xy}(x,\sigma) \\ L_{xy}(x,\sigma) & L_{yy}(x,\sigma) \end{bmatrix} \quad (2.18)$$

Όπου  $L_{xx}(x,\sigma)$ ,  $L_{xy}(x,\sigma)$ ,  $L_{yy}(x,\sigma)$  είναι η μερική παράγωγος δεύτερης τάξης και η δισδιάστατη σύγκλιση του σημείου  $(x,y)$  της εικόνας  $I$ , αντίστοιχα.

Η συνάρτηση Gauss μπορεί να εφαρμοστεί στη ανάλυση του χώρου κλίμακας, αλλά σε πρακτικές εφαρμογές, πρέπει να διακριτοποιηθεί και να αποκοπεί όπως φαίνεται στο σχήμα 2-2:



Σχήμα 2-1 : Προσεγγιστικές παράγωγοι 2<sup>ης</sup> τάξης με φίλτρα κουτιού.

Αυτό έχει ως αποτέλεσμα σε απώλεια επαναληψιμότητας κατά την περιστροφή της εικόνας κατά περίττα πολλαπλάσια του  $\pi/4$ . Για βελτίωση της ακρίβειας της παραγωγού Gauss δεύτερης τάξης χρησιμοποιούνται φίλτρα τύπου «κουτιού» (**box filters**). Η επεξεργασία ακέραιων εικόνων με χρήση πλαισίου σύγκλισης (**convolution template**) μετά την προσέγγιση παρέχει ξεκάθαρο πλεονέκτημα, καθώς το πλαίσιο αποτελείται από ένα απλό παραλληλόγραμμο, του οποίου ο υπολογισμός είναι ανεξάρτητος του μεγέθους. Με αυτόν τον τρόπο η αποδοτικότητα των υπολογισμών επιταχύνεται σημαντικά.

Η προσέγγιση δεν επηρεάζει αρνητικά την απόδοση του πλαισίου σύγκλισης. Το πλαίσιο σύγκλισης του **σχήματος 13** είναι προσεγγίσεις μίας συνάρτησης Gauss με  $\sigma=1.2$ , η οποία είναι η μικρότερη κλίμακα για τους χάρτες απόκρισης των διακυμάνσεων (**blobs**). Το πλαίσιο προσέγγισης και η σύγκλιση ορίζονται ως  $D_{xx}$ ,  $D_{yy}$ ,  $D_{xy}$ , και χρησιμοποιούνται αντί για τα  $L_{xx}(x,\sigma)$ ,  $L_{xy}(x,\sigma)$ ,  $L_{yy}(x,\sigma)$  για να εξαχθεί ο προσεγγιστικός πίνακας Hessian  $H$ .


$$|H| = D_{xx}(X)D_{yy}(X) - [w D_{xy}(X)]^2 \quad (2.19)$$

### 2.3.3 Αναπαράσταση σε κλιμακούμενο χώρο (scale-space)

Προκειμένου να γίνει ο εντοπισμός των σημείων ενδιαφέροντος με σχέση σμίκρυνσης-μεγέθυνσης, θα πρέπει ο εντοπιστής να έχει τη δυνατότητα να βρίσκει σημεία στην ίδια θέση αλλά σε διαφορετική κλίμακα. Ο κλιμακούμενος χώρος συνήθως αναπαρίσταται με μία πυραμίδα εικόνων. Οι εικόνες εξομαλύνονται ένα με φίλτρο Gauss και χρησιμοποιούνται για την επίτευξη υψηλότερου επιπέδου στη πυραμίδα. Αφαιρώντας όλα τα επίπεδα της πυραμίδας εξάγεται η διαφορά των Gaussians (Difference of Gaussians – DoG) όπου μπορούν να εντοπιστούν διακυμάνσεις και ακμές της εικόνας.

Σε αντίθεση με αυτή τη προσέγγιση, η μέθοδος SURF επεξεργάζεται την αρχική εικόνα με φίλτρα κουτιού διαφόρων μεγεθών. Χάρη στην εφαρμογή ακέραιων εικόνων, η ταχύτητα υπολογισμού μεταξύ φίλτρων κουτιού όλων των μεγεθών είναι ίδια.

Στην αριστερή στήλη του σχήματος 2-3 δυο πλαίσια προσέγγισης  $9 \times 9$  θεωρούνται ως το αρχικό πλαίσιο προσέγγισης (προσεγγιστικές παράγωγοι Gauss με  $\sigma=1.2$ ). Το  $S$  αναφέρεται στη κλίμακα του πλαισίου προσέγγισης, όπου  $s = \sigma = 1.2$ . Ως αρχικό επίπεδο ορίζεται η σύγκλιση μεταξύ των προσεγγιστικών πλαισίων της αρχικής κλίμακας της εικόνας. Τα επόμενα επίπεδα λαμβάνονται από τη σύγκλιση της αρχικής εικόνας και κλιμακωτά αυξανόμενου  $s$ . Προκειμένου να διατηρηθεί η ακεραιότητα και το κεντρικό pixel, τα γειτονικά πλαίσια διαφέρουν πάντα κατά περιττό αριθμό.



Σχήμα 2-2 : Φίλτρα  $D_{xy}$  για δύο διαδοχικές κλίμακες ( $9 \times 9$  και  $15 \times 15$ )

Κάθε οκτάβα αποτελείται από 4 πλαίσια. Στην πρώτη οκτάβα, τα γειτονικά πλαίσια διαφέρουν κατά 6 pixel. Στην δεύτερη οκτάβα κατά 8 pixel, στην τρίτη κατά 24 κ.λπ. Αν το μέγεθος ενός πλαισίου είναι  $N*N$ , η κλίμακα του πλαισίου είναι  $S=1.2*9/N$ . Υπολογίζοντας και καταγράφοντας την απόκριση σε κάθε σημείο, μπορούμε να αποτυπώσουμε την απόκριση σε διαφορετική κλίμακα. Με αυτόν τον τρόπο μπορεί να κατασκευαστεί ένας τρισδιάστατος κλιμακούμενος χώρος.

### 2.3.4 Χωρικός εντοπισμός σημείων ενδιαφέροντος

Αρχικά ερευνώνται ακρότατα της κλιμακούμενης εικόνας  $(x, y, \sigma)$  σύμφωνα με τον πίνακα Fast-Hessian. Τα σημεία που δεν αποτελούν μέγιστα απαλείφονται στην κυκλική γειτονιά  $3x3x3$ . Μόνο ακραία σημεία με διαφορά μεγαλύτερη ή μικρότερη του 26 συγκριτικά με την αντίστοιχη μία κλίμακας πάνω ή κάτω αντίστοιχα μπορούν να θεωρηθούν ως σημεία χαρακτηριστικών. Για τον εντοπισμό σημείων χαρακτηριστικών με ακρίβεια υπο-pixel εφαρμόζετε γραμμική παρεμβολή μεταξύ του χώρου κλίμακας και του χώρου της εικόνας. Με αυτό τον τρόπο λαμβάνεται ένα ευσταθές χαρακτηριστικό σημείο και η κλίμακά του στο σημείο εντοπισμού.

### 2.3.5 Περιγραφή των σημείων ενδιαφέροντος


Προκειμένου το διάνυσμα περιγραφής να μην επηρεάζεται από περιστροφές, πρέπει να ληφθεί ο προσανατολισμός του σημείου. Για τον σκοπό αυτό, αρχικά κατασκευάζεται μία απόκριση wavelet της οποίας το κέντρο είναι το σημείο ενδιαφέροντος και η ακτίνα της  $6s$  (όπου  $s$  είναι η κλίμακα του σημείου). Με εφαρμογή Haar wavelet μεγέθους  $4s$  στην εικόνα, μπορεί να υπολογιστεί η απόκριση κατά τον άξονες  $x$  και  $y$ .



Σχήμα 2-3 : Φίλτρα Haar wavelet

Στο σχήμα 2-4 φαίνονται απεικονίσεις των Haar wavelet. Η αριστερή εικόνα χρησιμοποιείται για την απόκριση στον άξονα x και η αριστερή για τον άξονα y. Τα μαύρα τμήματα σηματοδοτούνται με -1 και τα λευκά με +1.


Η γειτονιά της απόκρισης wavelet βρίσκεται στην κατεύθυνση των x και y αξόνων. Στη συνέχεια αντιστοιχίζονται διαφορετικά βάρη Gauss σε κάθε απόκριση. Αθροίζοντας το Haar wavelet στις κατευθύνσεις των αξόνων x και y με εύρος  $60^\circ$  δημιουργείται ένα τοπικό διάνυσμα προσανατολισμού. Μόλις έχει ολοκληρωθεί η παραπάνω διαδικασία για ολόκληρο τον κύκλο, το μεγαλύτερο διάνυσμα επιλέγεται ως ο κύριος προσανατολισμός του σημείου. Η διαδικασία απεικονίζεται στο σχήμα 2-5.




Σχήμα 2-4 : Καθορισμός κύριου προσανατολισμού του χαρακτηριστικού σημείου

### 2.3.6 Δημιουργία διανύσματος περιγραφής SURF

Για την εξαγωγή του διανύσματος περιγραφής, αρχικά δημιουργείται ένα παράθυρο με κέντρο το σημείο ενδιαφέροντος και μήκος  $20\sigma$ . Στη συνέχεια το παράθυρο χωρίζεται σε  $4 \times 4$  υπο-περιοχές (σχήμα 2-6). Από κάθε υπο-περιοχή λαμβάνονται  $5 \times 5$  σημεία δειγματοληψίας. Για κάθε ένα από αυτά τα σημεία λαμβάνονται οι αποκρίσεις wavelet κατά τους άξονες x και y και ορίζονται ως  $dx$  και  $dy$  αντίστοιχα. Σε κάθε υπο-περιοχή εφαρμόζεται ένα φίλτρο Gauss με κέντρο το σημείο ενδιαφέροντος και σχηματίζεται ένα ιδιοδιάνυσμα τεσσάρων διαστάσεων από τα αθροίσματα των  $dx$ ,  $dy$ ,  $|dx|$  και  $|dy|$  ( $\Sigma dx$ ,  $\Sigma dy$ ,  $\Sigma |dx|$ ,  $\Sigma |dy|$ ) όπως φαίνεται στο σχήμα 2-7. Για τις  $4 \times 4 = 16$  υπο-περιοχές, έχουμε συνολικά  $4 \times 16 = 64$  διαστάσεις του διανύσματος περιγραφής.



Σχήμα 2-5 : Αριστερά απεικονίζονται οι 4x4 υπο-περιοχές γύρω από το σημείο ενδιαφέροντος. Για κάθε υπο-περιοχή, οι αποκρίσεις wavelet λαμβάνονται από 5x5 δείγματα (για λόγους οπτικοποίησης, στο σχήμα έχουν ληφθεί δείγματα 2x2)



Σχήμα 2-6 : Τιμές των ιδιοδιανυσμάτων σε διάφορα ήδη απεικονίσεων



## 2.4 Ομαδοποίηση K-MEANS

Η ομαδοποίηση K-means είναι ένας από τους πιο απλούς και πιο δημοφιλείς αλγόριθμους εκμάθησης χωρίς επίβλεψη για την επίλυση του προβλήματος ομαδοποίησης. Η ομαδοποίηση K-means δημιουργεί ένα συγκεκριμένο αριθμό ασυνεχών (**disjoint**), επίπεδων (μη ιεραρχικών) συστάδων. Δηλαδή, η συνάρτηση των K-means διαχωρίζει τις παρατηρήσεις που εξάγονται από τα δεδομένα σε k αποκλειστικές συστάδες, και επιστρέφει ένα διάνυσμα δεικτών, το οποίο υποδεικνύει σε ποια από τις k συστάδες έχει ανατεθεί κάθε σετ χαρακτηριστικών.

Το M-πρόβλημα της συσταδοποίησης (**M-clustering problem**) στοχεύει στη δημιουργία διαμερισμάτων σε ένα σύνολο δεδομένων  $X = \{x_1, \dots, x_N\}$ ,  $x_n \in R^d$ , σε M ασυνεχή υποσύνολα (**disjoint**)  $C_1, \dots, C_M$ , έτσι ώστε να βελτιστοποιείτε μια συνάρτηση F, που αναφέρεται ως κριτήριο ομαδοποίησης. Η πιο ευνόητη και συχνά χρησιμοποιούμενη συνάρτηση-κριτήριο είναι το άθροισμα των τετραγώνων της ευκλείδειας απόστασης ανάμεσα σε κάθε σημείο δεδομένων  $x_i$  και το κέντρο του συμπλέγματος  $m_k$  του υποσυνόλου που περιέχει το  $x_i$ . Το κριτήριο αυτό ονομάζεται σφάλμα ομαδοποίησης και εξαρτάται από τα κέντρα  $m_1, \dots, m_M$ :

$$F(m_1, \dots, m_M) = \sum_{i=1}^M \sum_{j=1}^{M_i} \|x_{ij} - m_i\|^2 \quad (2.20)$$

όπου  $M_i$  είναι ο αριθμός των σημείων της συστάδας  $C_i$ ,  $x_{ij}$  είναι το  $j$ -th σημείο της  $i$ -th συστάδας και  $m_i$  είναι το κέντρο της  $i$ -th συστάδας το οποίο ορίζεται ως εξής:

$$m_i = \frac{1}{M_i} \sum_{j=1}^{M_i} x_{ij} \quad i=1, \dots, M \quad (2.21)$$

Ένας ψευδοκώδικας για την εφαρμογή της ομαδοποίησης K-means έχει ως εξής:

(A) ο αλγόριθμος αρχίζει με μια αρχική κατάτμηση της βάσης δεδομένων σε ασυνεχή (**disjoint**) υποσύνολα και υπολογίζονται τα κέντρα βάρους των αρχικών συστάδων,

(B), στη συνέχεια, τα δεδομένα "επανατοποθετούνται" στη συστάδα με το πλησιέστερο κέντρο βάρους σε μια προσπάθεια να μειωθεί το τετραγωνικό σφάλμα. Ένα σημείο  $x_i \in C_s$  στο βήμα της

επανατοποθέτησης μπορεί να αλλάξει συστάδα στην οποία ανήκει  $x_i \in C_t$  εάν

$$\|x_i - m_t\| \leq \|x_i - m_j\|$$

. Στη συνέχεια τα κέντρα βάρους, των συστάδων, και το τετραγωνικό σφάλμα θα πρέπει να υπολογιστούν εκ νέου.

(C) Αυτή η διαδικασία επαναλαμβάνεται μέχρι το τετραγωνικό σφάλμα να μην μπορεί να μειωθεί περαιτέρω, που σημαίνει ότι κανένα δεδομένο, δεν είναι δεν μπορεί να αλλάξει συστάδα.

Έχει αποδειχθεί ότι η απόδοση της μεθόδου συνδέεται στενά με τις χρησιμοποιούμενες μετρική απόσταση. Μπορούν να επιλεγούν μια σειρά από διαφορετικά μέτρα απόστασης, ανάλογα με το είδος των δεδομένων που θέλουμε να ομαδοποιήσουμε.

Η Ευκλείδεια απόσταση μέτρα την απόσταση σε ευθεία γραμμή μεταξύ δύο σημείων. Κάθε κέντρο βάρους είναι ο μέσος όρος των σημείων της συστάδας. Αν έχουμε δύο γονίδια  $A_i = \{x_{ik}\}$  και  $A_j = \{x_{jk}\}$ ,  $k=1, \dots, n$  και  $i, j \in \{1, \dots, n\}$ ,  $i \neq j$  η Ευκλείδεια μεταξύ τους απόσταση και διατυπώνεται ως εξής:

$$r(A_i, A_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (2.22)$$

όπου  $x_i$ ,  $x_j \in R$ , είναι τα μετρούμενα επίπεδα έκφρασης (**expression levels**). Η Ευκλείδεια απόσταση  $r$  μετρά τη διαφορά στα επιμέρους μεγέθη (**magnitudes**) του κάθε γονιδίου. Η Ευκλείδεια απόσταση λαμβάνει τη διαφορά μεταξύ των δύο γονιδίων άμεσα. Θα πρέπει επομένως να χρησιμοποιούνται μόνο για τα δεδομένα που είναι κατάλληλα κανονικοποιημένα. Η Ευκλείδεια απόσταση περιέχει πληροφορίες τόσο για την κατεύθυνση και τάξη μεγέθους του κάθε διανύσματος από το κέντρο βάρους της συστάδας. Ως εκ τούτου, τα γονίδια μπορούν να θεωρηθούν όμοια με βάση την Ευκλείδεια απόσταση αν και είναι πολύ ανόμοια ως προς το σχήμα τους και αντίστροφα.

Η συσχέτιση Pearson μετρά την ομοιότητα μεταξύ δύο προφίλ. Κάθε κέντρο βάρους είναι ο **component-wise** μέσος όρος των σημείων της συστάδας, αφού τα σημεία αυτά κεντραριστούν και κανονικοποιηθούν με μέσο όρο μηδέν και τυπική απόκλιση ίση με μονάδα. Αν έχουμε δύο σειρές

αριθμών  $A_i = \{x_{ik}\}$  και  $A_j = \{x_{jk}\}$ ,  $k=1, \dots, n$  και  $i, j \in \{1, \dots, n\}$ ,  $i \neq j$ , η συσχέτιση του Pearson του (κέντρο), ορίζεται ως εξής:

$$r(A_i, A_j) = \frac{\sum_{k=1}^n (x_{ik} - m_i)(x_{jk} - m_j)}{\sqrt{\sum_{k=1}^n (x_{ik} - m_i)^2} \sqrt{\sum_{k=1}^n (x_{jk} - m_j)^2}} \quad (2.23)$$

όπου  $m_i$  και  $m_j$  είναι ο μέσος όρος των  $x_{ik}$  and  $x_{jk}$ ,  $k=1, \dots, n$ , αντιστοίχως. Ο συντελεστής συσχέτισης Pearson είναι πάντα μεταξύ -1 και 1, με τη μονάδα να δηλώνει ότι οι δύο σειρές είναι πανομοιότυπες, το μηδέν να δηλώνει ότι είναι εντελώς ασυσχέτιστες, και -1 δηλώνει ότι είναι τελείως αντίθετες.

Η απόσταση συσχέτισης στην ομαδοποίηση θεωρεί κάθε γονίδιο ως τυχαία μεταβλητή με  $n$  παρατηρήσεις και τα μέτρα την ομοιότητα μεταξύ των δύο γονιδίων, υπολογίζοντας τη γραμμική σχέση μεταξύ των κατανομών των δύο αντίστοιχων τυχαίων μεταβλητών. Ο συντελεστής συσχέτισης μένει αναλλοίωτος με γραμμικό μετασχηματισμό των δεδομένων. Η απόσταση συσχέτισης είναι ανεξάρτητη της ενίσχυσης της έκφρασης (παραβλέπει διαφορές στην τάξη μεγέθους) και λαμβάνει υπόψη τις τάσεις της αλλαγής. Ο συντελεστής συσχέτισης Pearson μπορεί να χρησιμοποιηθεί για ολοκληρωτικά και αναλογικά κλιμακούμενα δεδομένα. Το μόνο μειονέκτημα της χρήσης συσχέτισης είναι ότι είναι λίγο πιο αργή από την Ευκλείδεια απόσταση.

Η μετρική απόσταση συνημίτονου ορίζεται ως ένα μείον το συνημίτονο της γωνίας που περιλαμβάνονται μεταξύ των σημείων. Κάθε κέντρο βάρους είναι ο μέσος όρος των σημείων της συστάδας, μετά την κανονικοποίηση των σημείων αυτών σε μοναδιαίο ευκλείδειο μήκος. Δεδομένων δύο σειρών αριθμών  $A_i$  και  $A_j$ ,  $i, j \in \{1, \dots, n\}$ ,  $i \neq j$ , η μετρική απόσταση συνημίτονου ορίζεται ως εξής:

$$r(A_i, A_j) = 1 - \frac{\sum_{k=1}^n x_{ik} x_{jk}}{\sqrt{\sum_{k=1}^n x_{ik}^2} \sqrt{\sum_{k=1}^n x_{jk}^2}} \quad (2.24)$$

όπου

$$\frac{\sum_{k=1}^n x_{ik}x_{jk}}{\sqrt{\sum_{k=1}^n x_{ik}^2} \sqrt{\sum_{k=1}^n x_{jk}^2}} \quad (2.25)$$

είναι η αποκεντρωμένη συσχέτιση Pearson, το οποίο είναι ίσο με το συνημίτονο της γωνίας των δύο n-διαστάσεων διανυσμάτων  $A_i$  και  $A_j$ . Η Εξ. (2.25) είναι η ίδια συνάρτηση με την Εξ. (2.23), εκτός από το ότι θεωρεί ότι ο μέσος όρος είναι μηδέν, ακόμη και όταν δεν είναι. Η αποκεντρωμένη απόσταση συσχέτισης Pearson μετρά την ομοιότητα του σχήματος μεταξύ δύο προφίλ, αλλά μπορεί επίσης να εντοπίζει αντίστροφες συσχετίσεις. Ειδικότερα, συνδυάζοντας K-means με την μετρική απόσταση της Εξ. (2.25) μπορεί να οδηγήσει σε μη διαισθητικά κέντρα βάρους, επειδή μπορεί ομαδοποιήσει μη σχετιζόμενα αντικείμενα.

Η απόσταση Cityblock, γνωστή και ως απόσταση Manhattan, εξετάζει τις απόλυτες διαφορές μεταξύ των συντεταγμένων ενός ζεύγους σημείων. Κάθε κέντρο βάρους είναι το **component-wise**

**median** των σημείων της συστάδας. Με δεδομένα δύο γονίδια  $A_i$  και  $A_j$ ,  $i, j \in \{1, \dots, n\}$ ,

$i \neq j$ , η απόσταση Cityblock ορίζεται ως εξής:

$$r(A_i, A_j) = \frac{1}{n} \sqrt{\sum_{k=1}^n |x_{ik} - x_{jk}|} \quad (2.26)$$

Οι λόγοι πίσω από την δημοτικότητα του αλγορίθμου K-means είναι οι εξής:

(A) Είναι απλός και χωρίς επίβλεψη εκπαιδευόμενος αλγόριθμος. Τα K-means δεν περιορίζεται σε έλεγχο υπόθεσης με βάση κάποια προηγούμενη εκπαίδευση. Διερευνά τη δομή των δεδομένων με βάση τις ομοιότητες που παρουσιάζονται σε αυτά.

(B) Ο χρόνος που απαιτείται είναι  $O(nML)$ , όπου n είναι ο αριθμός των προτύπων, M είναι ο αριθμός των συστάδων και L είναι ο αριθμός των επαναλήψεων που λαμβάνονται από τον αλγόριθμο μέχρι να συγκλίνει. Οι παράμετροι M και L καθορίζονται εκ των προτέρων. Ως εκ τούτου, η προσέγγιση K-means έχει γραμμική πολυπλοκότητα χρόνου ως προς το μέγεθος των δεδομένων.

(Γ) Η πολυπλοκότητα του χώρου είναι  $O(m+n)$ . Αποθηκεύονται μόνο τα δεδομένων και τα κέντρα βάρους. Ο αλγόριθμος απαιτεί πρόσθετο χώρο για να αποθηκεύσετε των πίνακα δεδομένων.

(Δ) Είναι ανεξάρτητος της διάταξης (**order**). Έτσι, για τις ίδιες αρχικές συνθήκες, δημιουργεί τον ίδιο διαχωρισμό των δεδομένων, ανεξάρτητα από τη σειρά με την οποία τα πρότυπα εισάγονται στον αλγόριθμο.

(Ε) Με μεγάλο αριθμό μεταβλητών, K-means μπορεί να είναι υπολογιστικά πιο γρήγορα.

(ΣΤ) Μπορεί να παράγει πιο συμπαγείς συστάδες.

(Ζ) Μπορεί να χρησιμοποιηθεί για μια ευρεία ποικιλία τύπων δεδομένων.

(Η) Είναι σε θέση να βρει καθαρή υπο-ομάδα εάν έχει οριστεί αρκετά μεγάλος αριθμός συστάδων.

(Ι) Παρόλο που δεν υπάρχει καμία εγγύηση για την επίτευξη μιας ολικού ελάχιστου, η σύγκλιση του αλγορίθμου είναι εξασφαλισμένη.

Το μεγάλο μειονέκτημα της ομαδοποίησης K-means είναι η ευαισθησία του αλγορίθμου στην επιλογή των αρχικών συνθηκών. Μια τεχνική που χρησιμοποιείται για την αντιμετώπιση του προβλήματος της επιλογής αρχικής κέντρων είναι η πολλαπλές εκτελέσεις, που απορρέουν από την υψηλή ταχύτητα εκτέλεσης του αλγορίθμου, η καθεμία με διαφορετικό σύνολο τυχαία επιλεγμένων αρχικών κέντρων, και στη συνέχεια η επιλογή των συστάδων με το ελάχιστο σφάλμα ομαδοποίησης (**clustering error**). Αυτή η στρατηγική μπορεί να μην λειτουργεί πολύ καλά, ανάλογα με το σύνολο των δεδομένων και τον αριθμό των συστάδων που έχουν ζητηθεί.

Λόγω του προβλήματος της χρήσης τυχαίων αρχικών κέντρων, το οποίο ακόμα και οι επαναλαμβανόμενες ίσως να μην υπερβούν, έχουν προταθεί άλλες τεχνικές για την αρχικοποίηση. Στη βιβλιογραφία, πολλές τεχνικές έχουν προταθεί πολλές τεχνικές για την επιλογή των καλύτερων αρχικές θέσεις των κέντρων βάρους, με σκοπό να επιτευχθεί μια υψηλής ποιότητας λύση στο τέλος της εκτέλεσης των K-Means. Ο Milligan (Milligan, 1980) εξέτασε την ισχυρή εξάρτηση των K-Means

από τους αρχικούς όρους και υπέδειξε ότι μπορούν να προκύψουν καλές τελικές δομές τελικών συστάδων με την ιεραρχική μέθοδο του Ward (Ward, 1963). Οι Likas et al. πρότειναν μια βηματική προσέγγιση για την ομαδοποίηση, που ονομάζεται **global K- Means** (Likas, Vlasis & Verbeek, 2003). Τα αρχικά κέντρα παράγονται με μια μέθοδο δέντρων. Ο αλγόριθμος είναι ντετερμινιστικός, δεν εξαρτάται από οποιαδήποτε αρχική θέση για το κέντρο της συστάδας και δεν περιέχει καμία εμπειρική παράμετρο. Οι Bradley et al. παρουσιάζουν τον αλγόριθμο βελτιστοποίησης (Bradley & Fayyad, 1998) που λειτουργεί με μικρό αριθμό επιμέρους δειγμάτων από μια συγκεκριμένη βάση δεδομένων. Τα δεδομένα σε κάθε επιμέρους δείγμα είναι ομαδοποιημένα. Στη συνέχεια, όλα τα κέντρα όλων των επιμέρους δειγμάτων ομαδοποιούνται με K-Means. Τα κέντρα του κάθε επιμέρους δείγματος που χρησιμοποιούνται ως αρχικά κέντρα. Τα τελικά κέντρα που δίνουν ελάχιστη σφάλμα ομαδοποίησης στη συνέχεια χρησιμοποιούνται ως αρχικές συνθήκες στην ομαδοποίηση με K- Means του αρχικού συνόλου δεδομένων.

Οι προαναφερόμενοι αλγόριθμοι αρχικοποίησης είναι σε θέση να οδηγήσει στον υπολογισμό καλών αρχικών κέντρων. Δεν συνιστούν απλώς μεθόδους αρχικοποίησης. Πρόκειται για μεθόδους ομαδοποίησης καθαυτές και ορισμένες από αυτές χρησιμοποιούν τον αλγόριθμο K- Means ως μέρος των αλγορίθμων τους. Ως εκ τούτου, υποφέρουν από το ίδιο πρόβλημα με την προσέγγιση των K- Means.

## 2.5 Μηχανές Διανυσματικής Υποστήριξης (SVM)

### 2.5.1 Βασικά Στοιχεία Θεωρίας Μηχανών Διανυσματικής Υποστήριξης (SVM)

Η θεωρία των Μηχανών Διανυσματικής Υποστήριξης (Support Vector Machine - SVM) παρουσιάστηκε συστηματικά από τους Vapnik και Chervonenkis προς το τέλος της δεκαετίας του '60. Ωστόσο, δεν ήταν παρά μετά τα μέσα της δεκαετίας του 1990 που οι μέθοδοι που χρησιμοποιούνται για SVMs άρχισαν να ανακάμπτουν χάρη στην μεγάλη διαθεσιμότητα της υπολογιστικής δύναμης, που οδήγησε σε πολλές πρακτικές εφαρμογές. Η βασική ιδέα της SVM [Vapnik 1995], [Cristianini and Shawe-Taylor 2000, Vapnik 1998] είναι να μετατρέπει το σήμα σε έναν χώρο χαρακτηριστικών ανώτερων διαστάσεων και να βρίσκει το βέλτιστο υπερεπίπεδο στο χώρο που μεγιστοποιεί το περιθώριο μεταξύ των τάξεων. Εν συντομία, το SVM λύνει ένα δυαδικό πρόβλημα όπου τα δεδομένα χωρίζονται από ένα υπερεπίπεδο. Το υπερεπίπεδο ορίζεται μέσω της χρήσης των Διανυσμάτων Υποστήριξης (Support Vectors), τα οποία αποτελούν ένα υποσύνολο των διαθέσιμων δεδομένων για τις δύο περιπτώσεις και καθορίζουν τα όρια μεταξύ των δύο κατηγοριών.

### 2.5.2 Γραμμικές Μηχανές Διανυσματικής Υποστήριξης

Αρχικά παρουσιάζεται η πιο απλή περίπτωση: γραμμικές μηχανές που εκπαιδεύονται με διαχωρίσιμα δεδομένα (όπως παρουσιάζεται παρακάτω, η ανάλυση της γενικής περίπτωσης των μη γραμμικών μηχανών που εκπαιδεύονται με μη διαχωρίσιμα δεδομένα καταλήγει σε ένα παρόμοιο πρόβλημα τετραγωνικού προγραμματισμού). Για τα δεδομένα εκπαίδευσης χρησιμοποιείται ο

ακόλουθος συμβολισμός  $\{x_i, y_i\}, i=1, K, l, y_i \in \{-1, 1\}, x_i \in \mathbf{R}^d$ .

Θεωρούνται υπερεπίπεδα τα οποία διαχωρίζουν τα θετικά από τα αρνητικά παραδείγματα (ένα υπερεπίπεδο διαχωρισμού). Τα σημεία  $x$  που βρίσκονται στο υπερεπίπεδο ικανοποιούν την σχέση

$w \cdot x + b = 0$ , όπου το  $w$  είναι κάθετο στο υπερεπίπεδο,  $|b|/\|w\|$  είναι η κατακόρυφη απόσταση του

υπερεπιπέδου από την αρχή των αξόνων και  $\|w\|$  είναι η Ευκλείδεια Νόρμα του  $w$ . Ορίζεται ως  $d_+$  (

$d_-$ ) ως η μικρότερη απόσταση του υπερεπιπέδου διαχωρισμού από το κοντινότερο θετικό (αρνητικό)

παράδειγμα. Επίσης ορίζεται το “περιθώριο” του υπερεπιπέδου διαχωρισμού ίσο με  $d_+ + d_-$ . Για την γραμμικά διαχωρίσιμη περίπτωση, ο αλγόριθμος διανυσμάτων υποστήριξης απλά αναζητεί το

διαχωριστικό επίπεδο με το μέγιστο περιθώριο. Το γεγονός αυτό μπορεί να διατυπωθεί ως εξής: θεωρείται ότι όλα τα δεδομένα εκπαίδευσης ικανοποιούν τους παρακάτω περιορισμούς:

$$\mathbf{x}_i \cdot \mathbf{w} + b \geq +1 \quad \text{για } y_i = +1 \quad (2.27)$$


$$\mathbf{x}_i \cdot \mathbf{w} + b \leq -1 \quad \text{για } y_i = -1 \quad (2.28)$$

Οι δύο αυτές σχέσεις μπορούν να συνδυαστούν σε ένα σύνολο ανισοτήτων:

$$y_i (\mathbf{x}_i \cdot \mathbf{w} + b) - 1 \geq 0 \quad \forall i \quad (2.29)$$

Θεωρούνται τα σημεία για τα οποία ισχύει η ισότητα στη σχέση (2.28) (ζητώντας η ύπαρξη ενός τέτοιου τέτοιου σημείου είναι ισοδύναμη με την επιλογή της κλίμακας του  $\mathbf{w}$  και του  $b$ ). Τα σημεία αυτά βρίσκονται στο υπερεπίπεδο  $H_1: \mathbf{x}_i \cdot \mathbf{w} + b = 1$  με κάθετο  $\mathbf{w}$  και κατακόρυφη απόσταση από την αρχή των αξόνων  $|1 - b| / \|\mathbf{w}\|$ . Παρόμοια, τα σημεία για τα οποία ισχύει η Σχέση (2.28) βρίσκονται στο υπερεπίπεδο  $H_2: \mathbf{x}_i \cdot \mathbf{w} + b = -1$ , με κάθετο  $\mathbf{w}$  πάλι και κατακόρυφη απόσταση από την αρχή των αξόνων  $|-1 - b| / \|\mathbf{w}\|$ . Κατά συνέπεια  $d_+ = d_- = 1 / \|\mathbf{w}\|$  και το περιθώριο είναι ίσο με  $2 / \|\mathbf{w}\|$ . Σημειώνεται ότι τα επίπεδα  $H_1$  και  $H_2$  είναι παράλληλα (έχουν την ίδια κάθετη) και ότι κανένα σημείο εκπαίδευσης δεν βρίσκεται μεταξύ τους. Κατά συνέπεια μπορεί να βρεθεί ένα ζεύγος υπερεπιπέδων που δίνει το μέγιστο περιθώριο ελαχιστοποιώντας το  $\|\mathbf{w}\|^2$ , υποκείμενο στους περιορισμούς (2.29).





**Σχήμα 2-7 :** Γραμμικά Υπερεπίπεδα Διαχωρισμού για την διαχωρίσιμη περίπτωση. Οι Μηχανές Υποστήριξης είναι κυκλωμένες.

Σημειώνεται ότι η λύση αυτού του προβλήματος βελτιστοποίησης είναι ολική. Το γεγονός αυτό αποτελεί ένα εξαιρετικό πλεονέκτημα συγκριτικά με τα MLPs ή τα RBF δίκτυα τα οποία μπορεί να έχουν πολλά τοπικά ελάχιστα και κατά συνέπεια συνήθως δεν είναι εγγυημένη η ολική βέλτιστη λύση.

Η λύση μιας τυπικής περίπτωσης δύο διαστάσεων αναμένεται να έχει την μορφή που παρουσιάζεται στο Σχήμα 2-8. Τα σημεία εκπαίδευσης για τα οποία ισχύει η ισότητα της σχέσης (2.29) (δηλαδή, εκείνα τα οποία καταλήγουν σε ένα από τα υπερεπίπεδα  $H_1$  και  $H_2$ ) και η αφαίρεση τους θα άλλαζε την λύση που βρέθηκε, ονομάζονται Διανύσματα Υποστήριξης και παρουσιάζονται στο Σχημα 2-8 με επιπλέον κύκλους.

Στη συνέχεια χρησιμοποιείται μια διατύπωση Lagrange του προβλήματος. Υπάρχουν δύο λόγοι για αυτό. Ο πρώτος λόγος είναι ότι οι περιορισμοί (2.29) θα αντικατασταθούν από περιορισμούς στους ίδιους τους πολλαπλασιαστές Lagrange, που είναι πιο εύκολα χειριζόμενοι. Ο δεύτερος λόγος είναι ότι στην αναδιατύπωση του προβλήματος, τα δεδομένα εκπαίδευσης θα εμφανίζονται μόνο (στους υπάρχοντες αλγορίθμους εκπαίδευσης και ελέγχου) στην μορφή εσωτερικών πηλίκων μεταξύ των διανυσμάτων. Η ιδιότητα αυτή είναι ζωτικής σημασίας, γιατί επιτρέπει την γενίκευση της διαδικασίας στην μη γραμμική περίπτωση.

Κατά συνέπεια, εισάγονται θετικοί πολλαπλασιαστές Lagrange  $a_i, i = 1, K, l$ , ένας για κάθε έναν από τους περιορισμούς ανισότητας (2.29). Υπενθυμίζεται ο κανόνας σύμφωνα με τον οποίο για

περιορισμούς της μορφής  $c_i \geq 0$ , οι σχέσεις περιορισμού πολλαπλασιάζονται με θετικούς πολλαπλασιαστές Lagrange και αφαιρούνται από την αντικειμενική συνάρτηση για να σχηματιστεί η Lagrangian συνάρτηση. Για περιορισμούς ισότητας, οι πολλαπλασιαστές Lagrange δεν δεσμεύονται από περιορισμούς. Η Lagrangian συνάρτηση λαμβάνει την μορφή:

$$L_P = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^J a_i y_i (\mathbf{x}_i \cdot \mathbf{w} + b) + \sum_{i=1}^J a_i \quad (2.30)$$

Η  $L_P$  ελαχιστοποιείται ως προς  $\mathbf{w}$ ,  $b$  και ταυτόχρονα απαιτείται οι παράγωγοι της  $L_P$  ως προς όλα τα  $a_i$  να εξαφανίζονται, υποβαλλόμενα όλα στους περιορισμούς  $a_i \geq 0$  (το συγκεκριμένο σύνολο περιορισμών θα ονομάζεται  $C_1$ ). Το πρόβλημα πλέον είναι ένα κυρτό πρόβλημα τετραγωνικού προγραμματισμού καθώς η αντικειμενική συνάρτηση είναι κυρτή και τα σημεία που ικανοποιούν τους περιορισμούς σχηματίζουν επίσης ένα κυρτό σύνολο (κάθε γραμμικός περιορισμός ορίζει έναν κυρτό σύνολο και ένα σύνολο  $N$  ταυτόχρονων γραμμικών περιορισμών ορίζει την τομή των  $N$  κυρτών συνόλων, το οποίο είναι επίσης ένα κυρτό σύνολο). Το γεγονός αυτό σημαίνει ότι μπορεί ισοδύναμα να επιλυθεί το ακόλουθο “διττό” (“dual”) πρόβλημα:

Μεγιστοποίηση της Lagrangian συνάρτησης  $L_P$ , υπό τους περιορισμούς ότι η παράγωγος της  $L_P$  ως προς το  $\mathbf{w}$  και το  $b$  εξαφανίζεται και υπόκειται επίσης στους περιορισμούς ότι  $a_i \geq 0$  (το ιδιαίτερο αυτό σύνολο των περιορισμών θα αναφέρεται ως  $C_2$ ). Η διττή αυτή διατύπωση του προβλήματος ονομάζεται διττό Wolfe [Fletcher 1987]. Παρουσιάζει την ιδιότητα, το μέγιστο της Lagrangian συνάρτησης  $L_P$ , υπό τους περιορισμούς  $C_2$ , εμφανίζεται στις ίδιες τιμές των  $\mathbf{w}$ ,  $b$  και  $a$ , όπου εμφανίζεται το ελάχιστο της Lagrangian συνάρτησης  $L_P$ , υπό τους περιορισμούς  $C_1$ .

Η απαίτηση, να εξαφανίζεται η παράγωγος της Lagrangian συνάρτησης  $L_P$  ως αναφορά τα  $\mathbf{w}$  και  $b$ , δίνει τις παρακάτω συνθήκες:

$$\mathbf{w} = \sum_i a_i y_i \mathbf{x}_i \quad (2.31)$$

$$\sum_i a_i y_i = 0 \quad (2.32)$$

Εφόσον οι σχέσεις αυτές είναι περιορισμοί στην διττή διατύπωση, μπορούν να αντικατασταθούν στην σχέση:

$$L_D = \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (2.33)$$

Σημειώνεται ότι έχει δοθεί διαφορετικό σύμβολο στην συνάρτηση Lagrangian (P για το αρχικό (primal), D για διττό (dual)) για να τονιστεί ότι οι δύο διατυπώσεις είναι διαφορετικές: οι  $L_P$  και  $L_D$  προέρχονται από την ίδια αντικειμενική συνάρτηση αλλά με διαφορετικούς περιορισμούς και η λύση βρίσκεται ελαχιστοποιώντας την  $L_P$  ή μεγιστοποιώντας την  $L_D$ . Σημειώνεται επίσης ότι αν το πρόβλημα διατυπωθεί με  $b=0$ , που καταλήγει να απαιτεί όλα τα υπερεπίπεδα να περιλαμβάνουν την αρχή των αξόνων, ο περιορισμός (2.32) δεν εμφανίζεται. Αυτό αποτελεί έναν ήπιο περιορισμό για χώρους υψηλών διαστάσεων, καθώς μειώνει τον αριθμό των βαθμών ελευθερίας κατά έναν.

Η εκπαίδευση των Διανυσμάτων Υποστήριξης (για την γραμμικά διαχωρίσιμη περίπτωση καταλήγει κατά συνέπεια στην μεγιστοποίηση της  $L_D$  ως προς τα  $\alpha_i$ , υπό τους περιορισμούς (2.32) και την θετικότητα των  $\alpha_i$ , ενώ η λύση δίνεται από την σχέση (2.31). Σημειώνεται ότι υπάρχει ένας πολλαπλασιαστής Lagrange  $\alpha_i$ , για κάθε σημείο εκπαίδευσης. Στην λύση, τα σημεία εκείνα για τα οποία  $\alpha_i > 0$  καλούνται Διανύσματα Υποστήριξης και βρίσκονται σε ένα από τα υπερεπίπεδα  $H_1, H_2$ . Όλα τα υπόλοιπα σημεία εκπαίδευσης έχουν  $\alpha_i = 0$  και βρίσκονται πάνω στο υπερεπίπεδο  $H_1$  ή στο  $H_2$  (έτσι ώστε να ισχύει η ισότητα (2.29) ή σε εκείνη την πλευρά του  $H_1$  ή του  $H_2$  ώστε να ισχύει η αυστηρή ανισότητα της σχέσης (2.29)). Για τις μηχανές αυτές, τα Διανύσματα Υποστήριξης είναι τα κρίσιμα στοιχεία του συνόλου εκπαίδευσης και δίνουν το όνομα στην μηχανή μάθησης γιατί αποδεικνύονται πολύ σημαντικά για την ταξινόμηση όσον αφορά την γενίκευση και τους υπολογισμούς. Τοποθετούνται κοντά στο όριο απόφασης και εάν όλα τα υπόλοιπα σημεία εκπαίδευσης αφαιρεθούν (ή μετακινηθούν χωρίς όμως να τέμνουν το  $H_1$  ή το  $H_2$ ), η επανάληψη της εκπαίδευσης θα οδηγήσει στην εύρεση του ίδιου υπερεπιπέδου διαχωρισμού. Προσφέρουν μια αραιή λύση στο πρόβλημα της ταξινόμησης ενώ ο Vapnik παρουσίασε ένα απλό και ισχυρό αποτέλεσμα που συνδέει τον αριθμό των Διανυσμάτων Υποστήριξης και την δυνατότητα γενίκευσης του ταξινομητή [Vapnik 1995]. Εάν τα δεδομένα εκπαίδευσης περιλαμβάνουν  $M$  δείγματα που διαχωρίζονται από τον υπερεπίπεδο μέγιστου περιθωρίου, το φράγμα της αναμενόμενης πιθανότητας του σφάλματος ελέγχου μπορεί να υπολογιστεί ως:

$$E[P_{error}] \leq \frac{\#SV}{M} \quad (2.34)$$

όπου #SV είναι ο αριθμός των SVs. Η σχέση αυτή δίνει έναν εύκολο τρόπο για την εκτίμηση της ικανότητας γενίκευσης του ταξινομητή με ένα φράγμα που είναι ανεξάρτητο από την διαστασιμότητα του χώρου εισόδου.

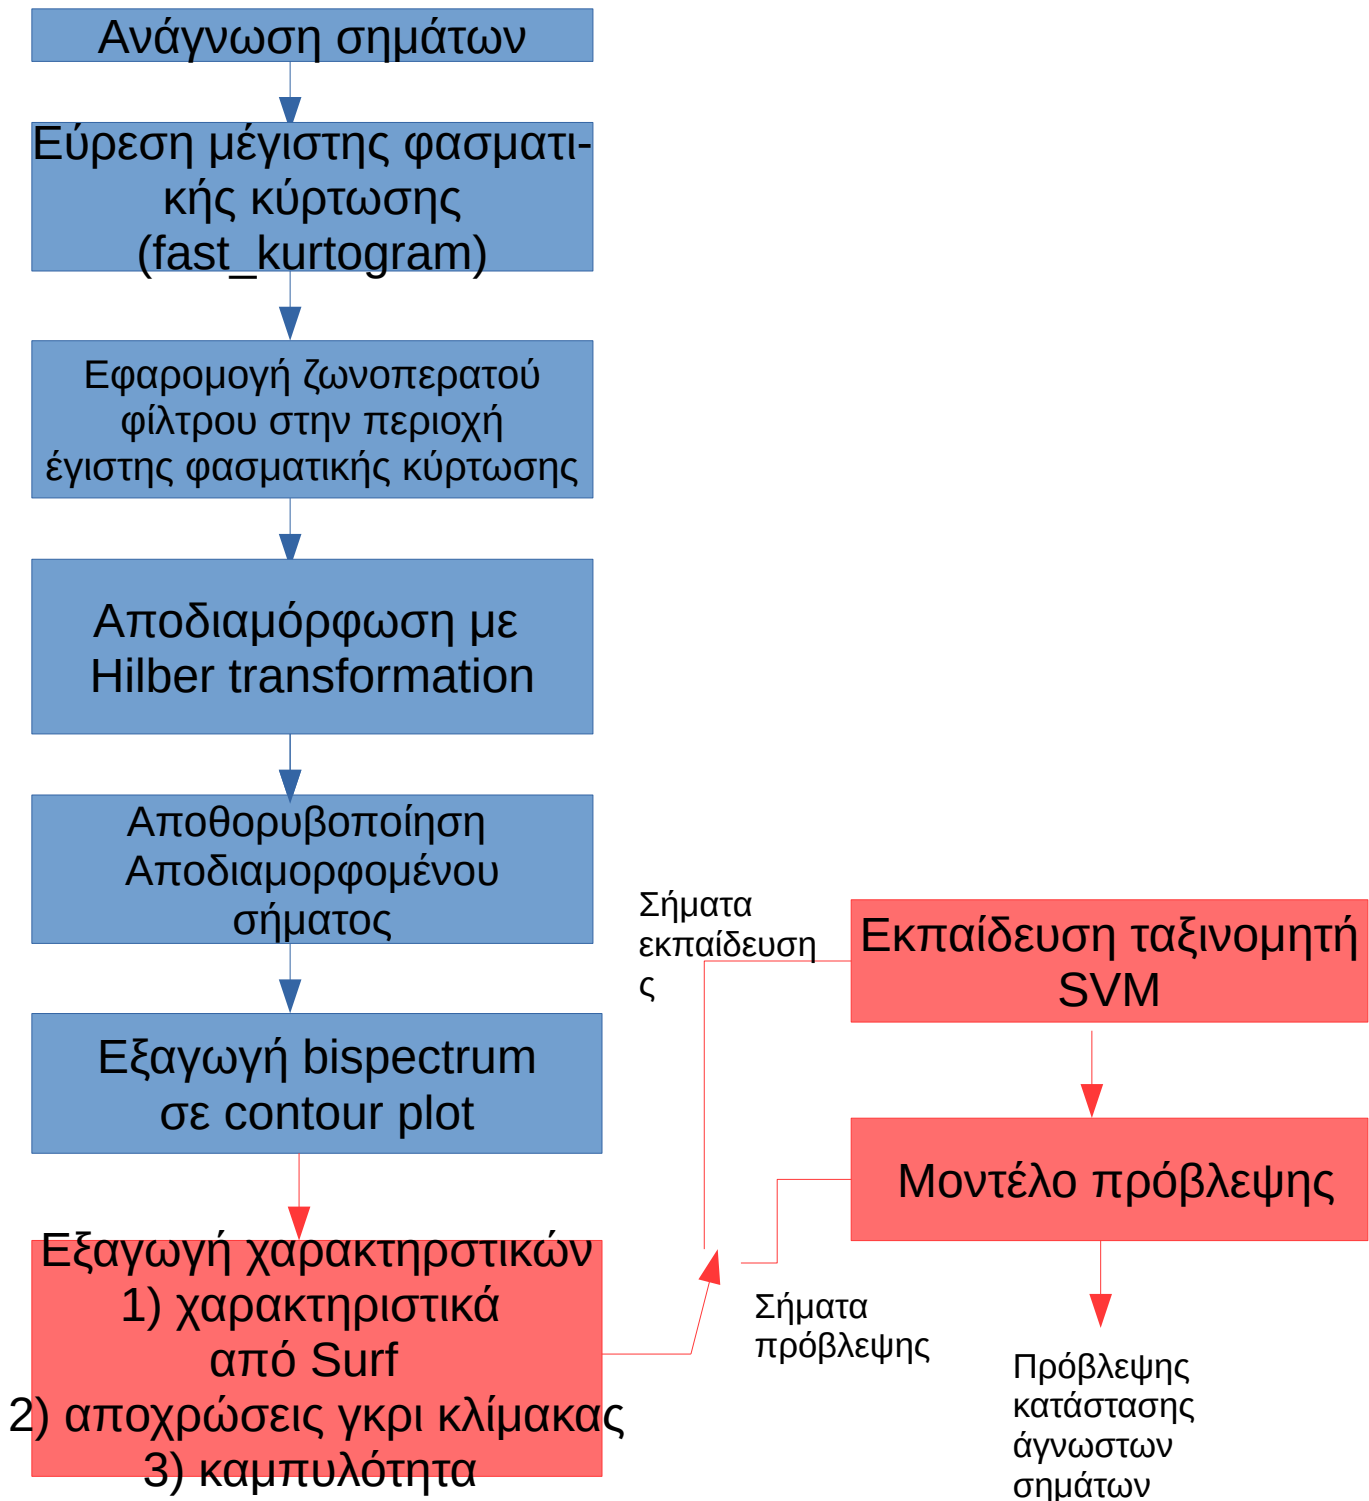
### 2.5.3 Ταξινόμηση Δεδομένων

Μετά την εκπαίδευση της Μηχανής Διανυσματικής Υποστήριξης, κάθε ελεγχόμενο στοιχείο καθορίζεται σε ποια πλευρά του ορίου απόφασης (δηλαδή του υπερεπιπέδου που βρίσκεται στην μέση απόσταση μεταξύ των H1 και H2 και παράλληλο με αυτά) βρίσκεται και ταξινομείται στην Κλάση εκείνη σύμφωνα με τον υπολογισμό της παρακάτω σχέσης:

$$f(x) = \text{sgn} \left( \sum_{i=1}^{N_s} a_i y_i x_i \cdot \mathbf{x} + b \right) \quad (2.35)$$


# ΚΕΦΑΛΑΙΟ 3 – ΠΕΡΙΓΡΑΦΗ ΜΕΘΟΔΟΛΟΓΙΑΣ

## Διάγραμμα ροής μεθοδολογίας




Μέσω του κώδικα (*extractBispectrums.m*), αρχικά εφαρμόζεται σε κάθε σήμα ο αλγόριθμος *fast\_kurtogram* για να βρεθεί η συχνοτική περιοχή που εμφανίζεται η μέγιστη κυρτότητα. Εξάγωντας την κεντρική συχνότητα  $f_c$  από αυτήν την περιοχή, αλλά και το εύρος της,  $B_w$ , εφαρμόζουμε ζωνοπερατό φίλτρο *butterworth* 4ης τάξης στο σήμα επιτρέποντας μόνο τις συχνότητες που βρίσκονται στο διάστημα  $[f_c - 0.5 \cdot B_w, f_c + 0.5 \cdot B_w]$ . Στη συνέχεια το σήμα αποδιαμορφώνεται με χρήση μετασχηματισμού Hilbert και στο αποδιαμορφωμένο χρονικό σήμα που προκύπτει εφαρμόζεται μία ήπια αποθρομβοποίηση με εφαρμογή κυματιδιακού μετασχηματισμού. Από το προκύπτον σήμα εξάγουμε το bispectrum του σε μορφή 2-D contour.


Παρακάτω παρουσιάζεται η επίδραση της διαδικασίας στα σήματα τόσο στα πεδίο του χρόνου, όσο και στο πεδίο της συχνότητας και το αντίστοιχο bispectrum που προκύπτει στο τέλος αυτής. Ενδεικτικά παρουσιάζεται ένα σήμα σε λειτουργία υπό σπηλαιώση (fail) αντλίας:




Σχήμα 3-1α : Αρχικό σήμα (πεδίο χρόνου)




Σχήμα 3-1β : Αρχικό σήμα (πεδίο συχνότητας-fft)




Σχήμα 3-2α : Φιλτραρισμένο σήμα με *Butterworth* στην περιοχή μέγιστης κύρτωσης (πεδίο χρόνου)




Σχήμα 3-2β : Φιλτραρισμένο σήμα με *Butterworth* στην περιοχή μέγιστης κύρτωσης (πεδίο συχνότητας)




Σχήμα 3-3α : Αποδιαμόρφωση του φιλτραρισμένου σήματος-αναλυτικό σήμα (πεδίο χρόνου)



Σχήμα 3-3β : Αποδιαμόρφωση του φιλτραρισμένου σήματος-αναλυτικό σήμα (πεδίο συχνότητας)




Σχήμα 3-4α : αποθουροποίηση αποδιαμορφωμένου σήματος (πεδίο χρόνου)



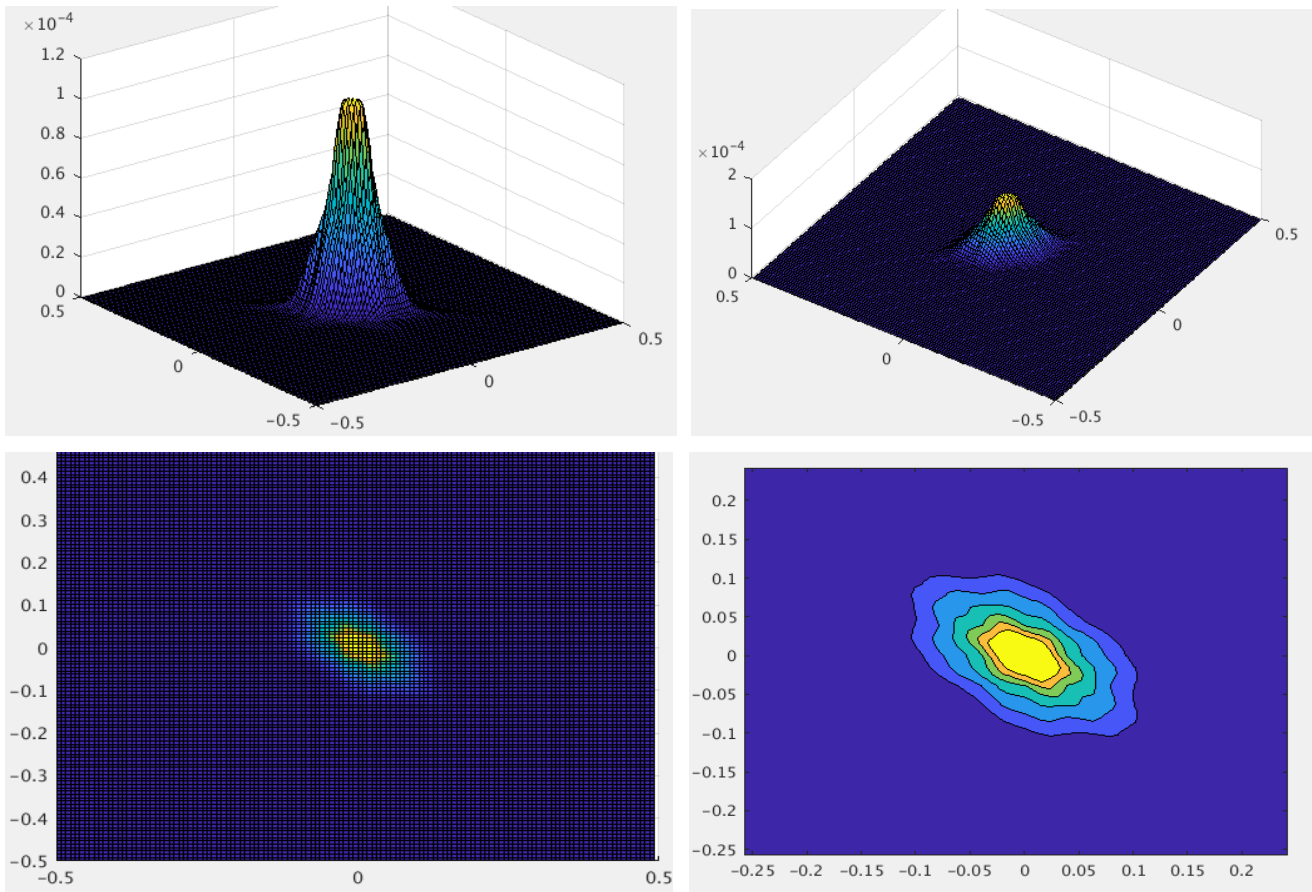
Σχήμα 3-4β : αποθουροποίηση σήματος (πεδίο συχνότητας)

Η παραπάνω διαδικασία υλοποιείται με τον κώδικα `extractBispectrums.m` (Παράρτημα Α) και με τη βοήθεια της συνάρτησης `bispec.m` εξάγονται τελικά τα bispectrum με κανονικοποιημένες συχνότητες (-0.5 , 0.5) σε μορφή `contour` όπως φαίνεται στο σχήμα 3-5.



Σχήμα 3-5 : contour από bispectrum σήματος με σπηλαίωση

Το περίγραμμα του σχήματος 3-5 προκύπτει από την προβολή του bispectrum στο οριζόντιο επίπεδο , με κάθε χρώμα να σηματοδοτεί το ύψος της εκάστοτε περιοχής, 6 στο σύνολο. Παρακάτω φαίνεται η συσχέτιση της τρισδιάστατης καμπύλης με το διδιάστατο contour.



Σχήμα 3-6 : Προβολή του 3-D bispectrum σε 2-D contour plot



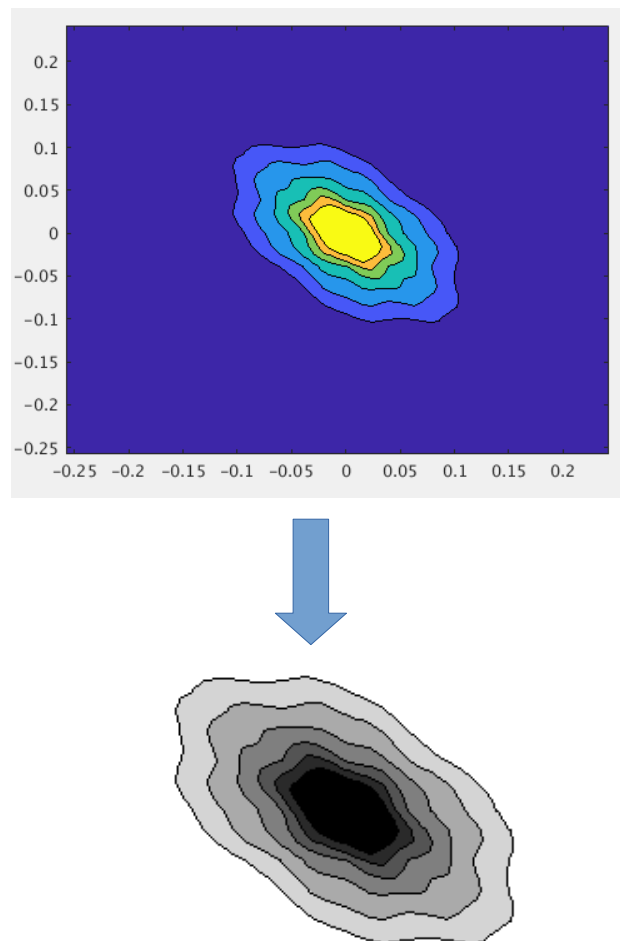
## 3.2 Εξαγωγή χαρακτηριστικών (*trainAndPredict.m*)

Από τα bispectrum που προκύπτουν από κάθε σειρά σημάτων, αφού επιλέξουμε τυχαία κάποια από αυτά για train (65%) και κάποια για test (35%), θα εξάγουμε χαρακτηριστικά (features) με τα οποία θα τροφοδοτήσουμε το Support Vector Machine, με σκοπό την πρόβλεψη και κατάταξη ενός σήματος σε φυσιολογική λειτουργία ή εσφαλμένη λειτουργία. Πριν την εξαγωγή των χαρακτηριστικών, τα bispectrum μετατρέπονται σε εικόνες στην κλίμακα του γκρι (gray scale). Συνολικά για κάθε εικόνα θα εξαχθούν χαρακτηριστικά από τις ακόλουθες διαδικασίες :

- Διανύσματα SURF
- Αποχρώσεις του γκρι
- Καμπυλότητα των bispectrum

### 3.2.1.1 Εξαγωγή διανυσμάτων SURF

Πριν εξάγουμε τα χαρακτηριστικά SURF, το bispectrum μετατρέπεται σε gray scale εικόνα και αφαιρείται η βαθμονόμηση των αξόνων, ώστε να αποφευχθεί η σύγχυση του αλγορίθμου σε εύρεση σημείων που δεν σχετίζονται με το bispectrum αυτό κάθε αυτό. Η μετατροπή φαίνεται στο Σχ. 3-7.



Σχήμα 3-6 : μετατροπή του “πολύχρωμου” bispectrum σε gray scale image χωρίς άξονες

Το επόμενο βήμα είναι η εύρεση σημείων SURF, δηλαδή “ενδιαφέροντων” σημείων βάσει της θεωρίας του SURF. Αυτό πραγματοποιείται με την συνάρτηση *detectSURFFeatures* της Matlab. Οι ρυθμίσεις που εισάγονται στην συνάρτηση είναι οι default , δηλαδή:

- **MetricThreshold = 1000**


Το metric threshold καθορίζει στον αλγόριθμο ένα όριο κάτω από το οποίο δεν ψάχνει για ενδιαφέροντες περιοχές (χωρικές άμορφες μάζες-blobs) . Συνεπώς όσο μικρότερο είναι, τόσο περισσότερα blobs-SURF features θα μας επιστρέψει.

- **NumOctaves = 3**

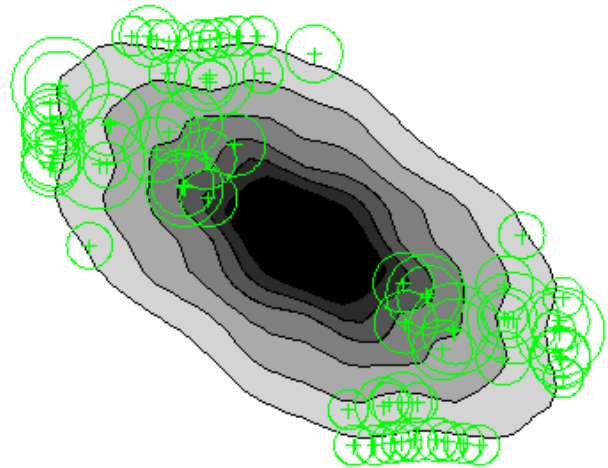
Οι οκτάβες αποτελούν ένα μέτρο για την εύρεση μικρών ή μεγάλων περιοχών. Όσο μικρότερος είναι ο αριθμός τόσο μικρότερες περιοχές βρίσκονται. Ενδεικτικά για κλειδί 1 τα φίλτρα-”παράθυρα” ψαξίματος ξεκινάνε από 9-by-9 και για 3 ξεκινάνε από 27-by-27.

- **NumScaleLevels = 4**

Αυξάνοντας το Scale Level των οκτάβων, αυξάνεται και ο αριθμός των περιοχών που εντοπίζονται. Η προεπιλεγμένη τιμή κρίνεται κατάλληλη.



Σχήμα 3-7α : εντοπισμός SURF points με metric threshold : 100



Σχήμα 3-7β : εντοπισμός SURF points με metric threshold : 1000

Όπως παρατηρούμε στα σχήματα 3-7α και 3-7β, τα SURF points που επιστρέφονται με μικρό threshold είναι πολύ περισσότερα. Παρα όλα αυτά δεν βελτιώνεται η απόδοση της πρόβλεψης του αλγορίθμου, παρα μόνο τον επιβαρύνει και τον κάνει πιο αργό.

Στη συνέχεια πρέπει για κάθε SURF point που έχει εντοπιστεί να εξαχθεί το αντίστοιχο διάνυσμα περιγραφής. Αυτό πραγματοποιείται με την βοήθεια της συνάρτησης *extractFeatures* της Matlab. Συνπώς, περνάμε από μια περιοχή (SURF point) με 5 χαρακτηριστικά (Scale, Sign of Laplace, Orientation, Location, Metric) σε 1 χαρακτηριστικό διάνυσμα διάστασης 64. Δεδομένου ότι δεν έχουμε μεταβολή στον προσανατολισμό των bispectrum καταλήγουμε στις εξής παραμέτρους για την *extractFeatures*:

- **Method : SURF**
- **FeatureSize : 64**
- **Upright : true**

### 3.2.1.2 Ομαδοποίηση των διανυσμάτων SURF με χρήση Kmeans αλγορίθμου και εξαγωγή του τελικού SURF χαρακτηριστικού

Από τα διανύσματα SURF όλων των bispectrum normal κατάστασης και abnormal κατάστασης από τα ιστορικά δεδομένα, βρίσκουμε 50 κέντρα για την κάθε μια, συνολικά 100. Αυτό πραγματοποιείται με την βοήθεια της συνάρτησης *kmeans* της Matlab.

Στη συνέχεια κάθε διάνυσμα SURF παίρνει ένα δείκτη, 0 για ακαθόριστο - 1 για normal - 2 για abnormal. Αυτό υλοποιείται ως εξής :

- Υπολογίζεται η ευκλείδεια απόσταση του διανύσματος από τα 100 κέντρα.
- Βρίσκονται τα 2 πιο κοντινά κέντρα του διανύσματος
- Αν και τα 2 κέντρα ανήκουν στην ίδια κατηγορία τότε το διάνυσμα παίρνει την τιμή 1 αν τα κέντρα είναι normal ή 2 αν τα κέντρα είναι abnormal
- Αν τα 2 κέντρα ανήκουν σε διαφορετική κατηγορία, τότε το διάνυσμα λαμβάνει χαρακτηρισμό μόνο αν η απόσταση του από το πιο κοντινό κέντρο είναι το πολύ 75% της απόστασης του αμέσως επόμενου κοντινού κέντρου. Διαφορετικά θεωρείται ακαθόριστο και λαμβάνει την τιμή 0


Συνεπώς για κάθε bispectrum προκύπτει ένα διάνυσμα διάστασης ίσου με το πλήθος των SURF points που έχουν εντοπιστεί σε αυτό, το οποίο αντιστοιχίζει κάθε SURF διάνυσμα σε ακαθόριστο ή normal ή abnormal δίνοντας τιμή 0 ή 1 ή 2. Στη συνέχεια υπολογίζουμε το άθροισμα των normal και το άθροισμα των abnormal. Τέλος υπολογίζεται η διαφορά των δυο αθροισμάτων:

$$[\sum (SURFvector=1)] - [\sum (SURFvector=2)]$$


Το νούμερο που προκύπτει αποτελεί το πρώτο χαρακτηριστικό (SURF feature) που θα τροφοδοτήσουμε τις μηχανές διανυσματικής υποστήριξης (SVM). Για τα normal σήματα η διαφορά προκύπτει θετική ενώ για τα abnormal προκύπτει αρνητική.

### 3.2.2 Εξαγωγή Χαρακτηριστικών από την κλίμακα του γκρι

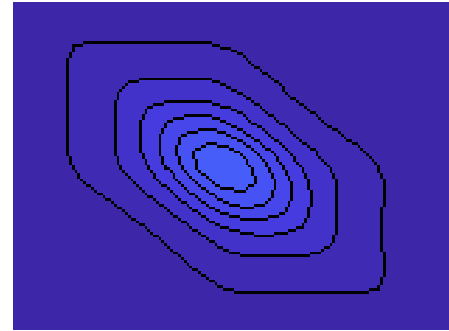
Για κάθε σειρά σημάτων ο χρωματισμός των contour έχει βαθμονομηθεί λαμβάνοντας υπόψιν την ενέργεια όλων των σημάτων και όχι κάθε σήματος ξεχωριστά. Κατά αυτόν τον τρόπο τα bispectrum των σημάτων με χαμηλή ενέργεια εμφανίζουν αποχρώσεις κοντά στο σκούρο μπλε, ενώ τα bispectrum των σημάτων με υψηλότερη ενέργεια εμφανίζουν πιο ανοιχτές αποχρώσεις. Αυτό γίνεται περισσότερο κατανοητό στα σχήματα 8 και 9, όπου βλέπουμε την απεικόνιση 3 σημάτων σε normal λειτουργία και 3 σημάτων σε abnormal λειτουργία, και πιο συγκεκριμένα με φθορά σε εξωτερικό δακτύλιο ρουλεμάν.




Σχήμα 3-8α : bispectrum από σήμα normal λειτουργίας ενέργειας 0.0010



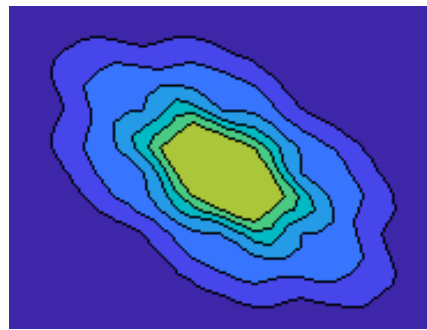
Σχήμα 3-8β : bispectrum από σήμα normal λειτουργίας ενέργειας 0.0200




Σχήμα 3-8γ : bispectrum από σήμα normal λειτουργίας ενέργειας 0.0070



Σχήμα 3-9α : bispectrum από σήμα abnormal λειτουργίας ενέργειας 0.0360



Σχήμα 3-9β : bispectrum από σήμα abnormal λειτουργίας ενέργειας 0.0418




Σχήμα 3-9γ : bispectrum από σήμα abnormal λειτουργίας ενέργειας 0.1585


Καθίσταται φανερό ότι ο χρωματισμός και πιο συγκεκριμένα οι διαφορετικές αποχρώσεις που εμφανίζουν τα bispectrum, αποτελούν στοιχείο διαφοροποίησης των εικόνων, πράγμα που εκμεταλλευόμαστε σε συνδιασμό με τα SURF χαρακτηριστικά για πιο ακριβή πρόβλεψη των σημάτων.

Όπως έχει ήδη προαναφερθεί πριν εξαχθούν χαρακτηριστικά από τις εικόνες πρώτα μετατρέπονται στην κλίμακα του γκρι. Έτσι οι εικόνες περιγράφονται με διδιάστατο πίνακα του οποίου η τιμή κάθε στοιχείου περιγράφει το χρώμα του αντίστοιχου pixel με έναν ακέραιο αριθμό στο διάστημα 0-255 (0 : μαύρο – 255 : άσπρο). Άρα στα τροποποιημένα contour περιοχές με χαμηλότερη ενέργεια εμφανίζονται άσπρες και περιοχές με την υψηλότερη ενέργεια εμφανίζονται μαύρες. Οι μηχανικές βλάβες έχουν την τάση να ανεβάζουν τα επίπεδα του θορύβου και τις ενέργειες, οπότε τα bispectrum των αντίστοιχων σημάτων εμφανίζουν σκούρες αποχρώσεις του γκρι. Με τη βοήθεια της συνάρτησης *imhist* της Matlab εξάγεται το ιστόγραμμα με τις αποχρώσεις του γκρι κάθε εικόνας. Το χαρακτηριστικό (feature) που χρησιμοποιούμε είναι το άθροισμα των σκουροχρωμών pixel της εικόνας και πιο συγκεκριμένα το πλήθος των pixel που έχουν τιμή από 1 [ ] μέχρι το γκρι που αντιστοιχεί σε στον αριθμό 150 [ ]


Όπότε τα bispectrum των σχημάτων χ-8 και χ-9 με τα αντίστοιχο πλήθος σκουρόχρωμων περιοχών φαίνονται παρακάτω :




Σχήμα 3-10α : Άθροισμα σκουρόχρωμων pixel : 1133 (πρακτικά μόνο το περίγραμμα)




Σχήμα 3-10β : Άθροισμα σκουρόχρωμων pixel : 1308



Σχήμα 3-10γ : Άθροισμα σκουρόχρωμων pixel : 1228



Σχήμα 3-11α : Άθροισμα σκουρόχρωμων pixel : 3658



Σχήμα 3-11β : Άθροισμα σκουρόχρωμων pixel : 8548




Σχήμα 3-11γ : Άθροισμα σκουρόχρωμων pixel : 28856

Το πλήθος των σκουρόχρωμων pixel, που αντιστοιχούν σε bispectrum με υψηλή ενέργεια, αποτελούν το δεύτερο χαρακτηριστικό που θα τροφοδοτήσουμε τον ταξινομητή (SVM).

### 3.2.3 Εξαγωγή Χαρακτηριστικών καμπυλότητας (circularity)


Το τελευταίο χαρακτηριστικό που εξάγουμε από τα bispectrum είναι η μορφή του στους πρόποδες του. Αυτό επιτυγχάνεται με τη χρήση της μαθηματικής σχέσης  $circularity = \frac{4 \cdot A \cdot \pi}{P^2}$ , όπου A το εμβαδό του contour και P η περίμετρος του. Για τέλειο κύκλο η σχέση δίνει circularity = 1. Για την διευκόλυνση αυτού του σκοπού εφαρμόζεται η ακόλουθη επεξεργασία εικόνας:

- Αφαίρεση των αποχρώσεων του σχήματος, κρατώντας μόνο τα περιγράμματα :



Σχήμα 3-12 : αποχρωματισμός του bispectrum


- Χρήση μάσκας ώστε να μονοχρωματιστεί όλη η επιφάνεια του bispectrum



Σχήμα 3-13 : μονοχρωματισμός του bispectrum

Από το πλήθος των μαύρων pixel βρίσκουμε το εμβαδό A του bispectrum


- Εξαγωγή περιγράμματος του bispectrum



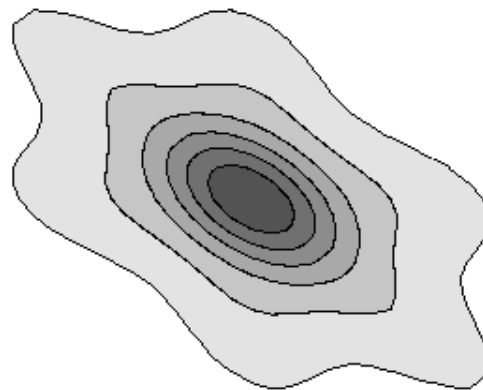
Σχήμα 3-14: Εξαγωγή περιγράμματος

Με την χρήση της συνάρτησης `bwperim` της Matlab εξάγουμε την περίμετρο του bispectrum μετρώντας τα άσπρα pixel. Επειδή η γραμμή δεν είναι συνεχής, λόγω pixel, η περίμετρος  $P$  πολλαπλασιάζεται με έναν συντελεστή 1.07 .

Στο σχήμα 15 φαίνονται ενδεικτικά οι καμπυλότητες ενός normal bispectrum και ενός bispectrum που αντιστοιχεί σε λειτουργία με σπηλαίωση :



Σχήμα 3-15α : *normal bispectrum* -  
*circularity = 0.968*



Σχήμα 3-15β : *abnormal bispectrum* -  
*circularity = 0.7730*

Η καμπυλότητα αποτελεί το τρίτο χαρακτηριστικό (feature) για κάθε εικόνα που θα τροφοδοτήσουμε τον ταξινομητή SVM.

### 3.3 Εκπαίδευση με Support Vector Machine και πρόβλεψη (*trainAndPredict.m*)

Αφού εξαχθούν τα 3 χαρακτηριστικά για κάθε bispectrum γνωστής κατάστασης (train) , SURF feature, gray scale feature και circularity feature, κανονικοποιούνται μεταξύ τους στην κλίμακα του SURF feature. Στη συνέχεια τροφοδοτούμε τα 3 κανονικοποιημένα features στο Support Vector Machine , χρησιμοποιώντας τον κώδικα από το libsvm, svmtrain, υλοποιημένο από τον Chih-Jen Lin. Ο πυρήνας του SVM είναι γραμμικός , οπότε για 3 features το όριο απόφασης θα είναι ένα επίπεδο.

Στη συνέχεια διαβάζονται τα bispectrum άγνωστης κατάστασης (test) και εξάγονται τα 3 χαρακτηριστικά όπως περιγράφεται στην εξαγωγή χαρακτηριστικών παραπάνω. Με τον κώδικα svmpredict του libsvm πραγματοποιείται πρόβλεψη και κατάταξη του bispectrum σε φυσιολογική ή μη φυσιολογική λειτουργία.


Τόσο η εξαγωγή χαρακτηριστικών όσο και η εκπαίδευση του ταξινομητή υλοποιούνται μέσω του κώδικα (*trainAndPredict*).



## ΚΕΦΑΛΑΙΟ 4 - ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ- ΦΘΟΡΑ ΣΕ ΡΟΥΛΕΜΑΝ

### 4.1 Προετοιμασία δεδομένων

Τέσσερα έδρανα είναι τοποθετημένα κατά μήκος του άξονα. Η ταχύτητα περιστροφής παραμένει σταθερή στις 2000RPM. Ακτινικό φορτίο 6000 lb ασκείται στον άξονα και τα έδρανα μέσω ενός μηχανισμού ελατηρίου. Σε κάθε έδρανο εγκαθίστανται δύο επιταχυνσιόμετρα υψηλής ευαισθησίας τύπου PCB 353B33 (ένα οριζόντιο κατά τον άξονα X και ένα κατακόρυφο κατά τον άξονα Y, καταλήγοντας σε οκτώ επιταχυνσιόμετρα συνολικά). Το σχήμα Y-1 παρουσιάζει την πειραματική διάταξη και τα σημεία τοποθέτησης των αισθητήρων. Όλες οι βλάβες εμφανίστηκαν μετά τον προβλεπόμενο κύκλο ζωής των εδράνων, ο οποίος ήταν ένα εκατομμύριο περιστροφές.



Σχήμα 4-1 : Πειραματική διάταξη

Τα δεδομένα είναι οργανωμένα ως εξής:

Κάθε αρχείο δεδομένων αποτελείται από 8 στήλες. Κάθε στήλη αντιστοιχεί στο σήμα ενός επιταχυνσιόμετρου όπως φαίνεται παρακάτω.

Στήλη	1	2	3	4	5	6	7	8
Έδρανο	1	1	2	2	3	3	4	4
Επιταχυνσιόμετρο	X	Y	X	Y	X	Y	X	Y

Το όνομα του κάθε αρχείου καθορίζει πότε συλλέχθηκαν τα δεδομένα. Σήματα διάρκειας 1 δευτερολέπτου συλλέχθηκαν κάθε 20 λεπτά για το πρώτο σετ δεδομένων και κάθε 10 λεπτά για το δεύτερο σετ. Κάθε γραμμή στα αρχεία δεδομένων αποτελεί ένα χρονικό σημείο της μέτρησης. Ο ρυθμός δειγματοληψίας ήταν 20 kHz.

#### Σετ 1:

**Διάρκεια μετρήσεων:** 19/12/2003 11:16:18 – 30/12/2003 23:55:42

**Δειγματοληψία:** 20 kHz

**Περιγραφή:** Δεδομένα κραδασμών συλλέχθηκαν κάθε 20 λεπτά από κάρτα NI DAQ 6062E. Στο τέλος της δοκιμής παρατηρήθηκε μία ρωγμή κοντά στο έδρανο 3. Τα τελευταία αρχεία εμφανίζουν αισθητή αλλαγή στο σήμα του εδράνου 3.

#### Σετ 2:

**Διάρκεια μετρήσεων:** 12/02/2004 10:32:39 – 19/02/2004 06:22:39

**Δειγματοληψία:** 20 kHz


**Περιγραφή:** Δεδομένα κραδασμών συλλέχθηκαν κάθε 20 λεπτά από κάρτα NI DAQ 6062E. Στο τέλος της δοκιμής παρατηρήθηκε σφάλμα στο έδρανο 1.

## 4.2 Σετ 1 : Φθορά εσωτερικού δακτυλίου ρουλεμάν


Από το πρώτο σετ χρησιμοποιήθηκαν 40 σήματα για εκπαίδευση και πρόβλεψη. Από τα 40 σήματα, τα 24 αποτελούν σήματα φυσιολογικής λειτουργίας και τα υπόλοιπα 16 σήματα που αντιστοιχούν σε φθορά του εσωτερικού δακτυλίου του ρουλεμάν 3 (δεδομένα απο τη στήλη 5 των μετρήσεων)

### Βήμα 1: Επεξεργασία σημάτων και εξαγωγή bispectrum (*extractBispectrums.m*)

Επεξεργάζοντας τα σήματα παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση σε πιο ψηλές συχνότητες, γύρω από την περιοχή των 8000 Hz όπως φαίνεται στο σχήμα 4-2:




Σχήμα 4-2α




Σχήμα 4-2β

Σχήμα 4-2 α) Μέγιστη φασματική κύρτωση 9791 Hz, β) Μέγιστη φασματική κύρτωση 7291 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 4-3 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα normal σήματα μετα την αποδιαμόρφωση.




Σχήμα 4-3α



Σχήμα 4-3β



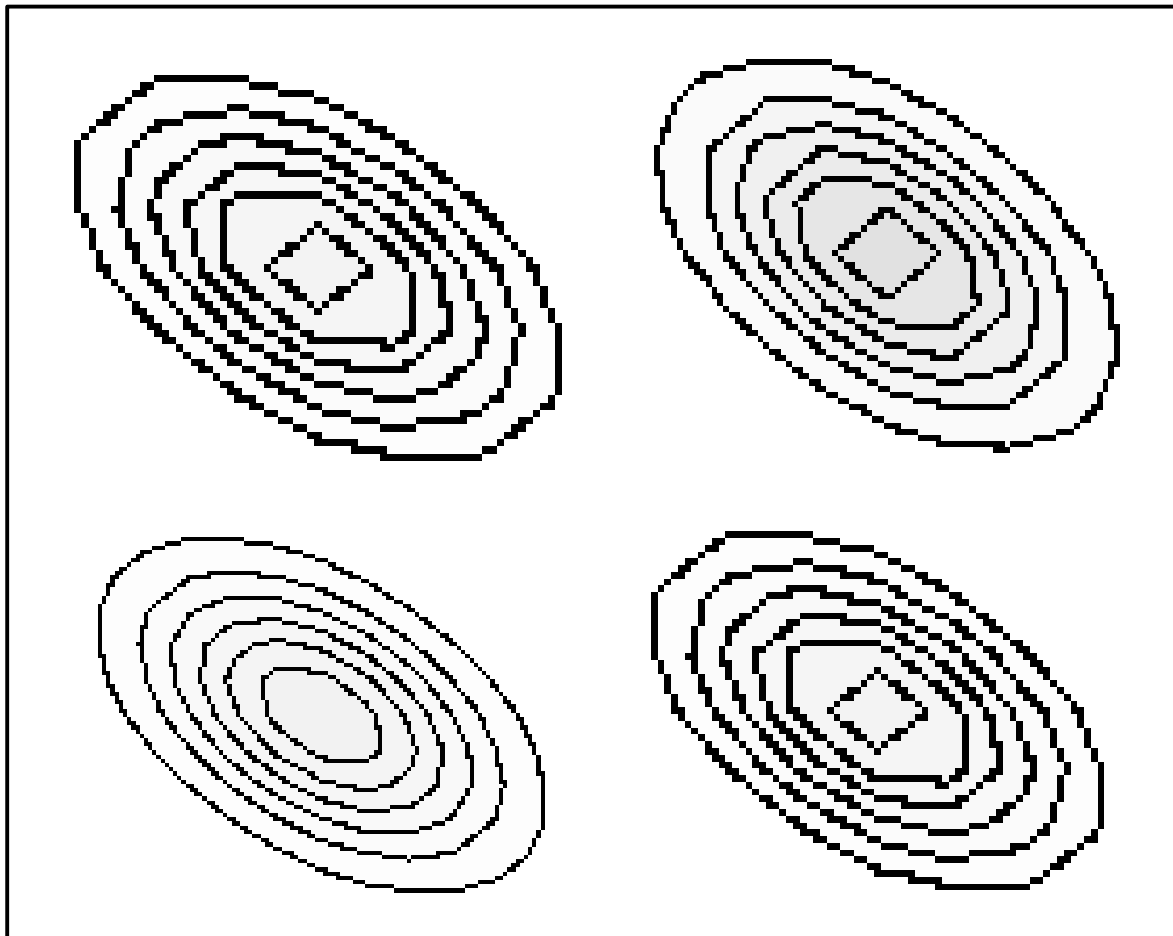
Σχήμα 4-3γ



Σχήμα 4-3δ

Σχήμα 4-3: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων φυσιολογικής λειτουργίας

Στο σχήμα 4-4 φαίνονται ενδεικτικά 4 bispectrum εξαγόμενα από τα normal σήματα (φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 4-4: Bispectrum φυσιολογικής λειτουργίας

Όπως φαίνεται στο σχήμα 4-4 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :


1. οβαλοειδές σχήμα
2. Πολύ ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.

Πιο συγκεκριμένα οι αποχρώσεις που εμφανίζονται στα bispectrum φυσιολογικής λειτουργίας είναι στην περιοχή (205 – 255), με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια).

Αντίστοιχα παρατηρείται ότι τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία (φθορά στον εσωτερικό δακτύλιο ρουλεμάν) εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση σε πιο χαμηλές συχνότητες, γύρω από την περιοχή των 5000 Hz όπως φαίνεται στο σχήμα 4-5:




Σχήμα 4-5α




Σχήμα 4-5β

Σχήμα 4-5 α) Μέγιστη φασματική κύρτωση στα 3750 Hz, β) Μέγιστη φασματική κύρτωση στα 5937.5 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση, αποθρομβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 4-6 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα normal σήματα μετα την αποδιαμόρφωση.




Σχήμα 4-6α



Σχήμα 4-6β




Σχήμα 4-6γ



Σχήμα 4-6δ

Σχήμα 4-6: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας

Στο σχήμα 4-7 φαίνονται ενδεικτικά 4 bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



Σχήμα 4-7: Bispectrum μη φυσιολογικής λειτουργίας

Όπως φαίνεται στο σχήμα 4-7 τα bispectrum φυσιολογικής λειτουργίας έχουν τα εξής χαρακτηριστικά :

- Πλειοψηφικά αποτελούν γενικευμένα πολύγωνα είτε σε μορφή εξαπλευρου, είτε σε μορφή “αστεριού” με 6 κορυφές.
- Εμφανίζουν σκούρες αποχρώσεις του γκρι που φτάνουν ως το μαύρο, γεγονός που υποδηλώνει υψηλή ενέργεια

Παρατηρείται ότι ακόμα και τα οβαλοειδή bispectrum μη φυσιολογικής κατάστασης που μοιάζουν με τα αντίστοιχα φυσιολογικής κατάστασης, διαφοροποιούνται ως προς το ύψος ( μεγαλύτερα ποσά ενέργειας) και αυτό φαίνεται στον πιο έντονο χρωματισμό τους.



## **Βήμα 2:** Διαχωρισμός εικόνων σε ομάδες εκπαίδευσης και δοκιμών (*trainAndPredict.m*)

Πριν αρχίσουμε την εκπαίδευση του ταξινομητή χωρίζουμε τα σήματα σε ομάδες εκπαίδευσης (*train* – ιστορικά δεδομένα εκπαίδευσης) και ομάδες δοκιμών (*test* – δεδομένα ελέγχου). Τα σήματα εκπαίδευση αποτελούν το 65% των σημάτων. Μετά τον διαχωρισμό καταλήγουμε σε:

- 16 bispectrum φυσιολογικής λειτουργίας για εκπαίδευση και 8 για έλεγχο (24 σύνολο)
- 9 bispectrum μη φυσιολογικής λειτουργίας για εκπαίδευση και 5 για έλεγχο (16 σύνολο)

Σημειώνεται ότι καθορίζεται με τυχαίο τρόπο ποια σήματα θα είναι εκπαίδευσης και ποια δοκιμής.

## **Βήμα 3:** Εξαγωγή SURF χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Στο επόμενο βήμα εξάγονται τα SURF features όπως περιγράφονται στην μεθοδολογία στο κεφάλαιο X.

Πρώτα βρίσκονται όλα τα SURF διανύσματα που περιγράφουν τα bispectrum. Για όλα τα bispectrum φυσιολογικής κατάστασης εξάγονται συνολικά 690 με 750 διανύσματα περιγραφής, ενώ για τα bispectrum μη φυσιολογικής κατάστασης εξάγονται συνολικά 800 με 1200 διανύσματα περιγραφής. Αυτό είναι λογικό διότι, αν και λιγότερα τα abnormal bispectrum, είναι πιο σύνθετα και έχουν περισσότερα σημεία ενδιαφέροντος.

Στη συνέχεια επιλέγεται ο αριθμός των κέντρων-κλάσσεων, που θα καταταχθούν τα normal SURF διανύσματα και τα abnormal SURF διανύσματα. Όπως θα δούμε στο βήμα 6 (αξιολόγηση αλγορίθμου ταξινόμησης) επιλέγουμε 50 κέντρα για κάθε κατηγορία (100 συνολικά). Αφού βρεθούν τα κέντρα, κατατάσσουμε τα SURF διανύσματα κάθε bispectrum σε normal κέντρο ή abnormal κέντρο και υπολογίζεται τελικά το SURF feature κάθε bispectrum ως:

$$[\sum (SURFvector = normal)] - [\sum (SURFvector = abnormal)]$$

## **Βήμα 4:** Εξαγωγή Gray Scale χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Όπως φαίνεται και στο σχήμα 4-4 τα bispectrum φυσιολογικής κατάστασης έχουν χαμηλή ενέργεια και αντίστοιχα απουσία σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα normal bispectrum είναι περίπου 800.

Αντίστοιχα όπως φαίνεται στο σχήμα 4-7 τα bispectrum μη φυσιολογικής κατάστασης έχουν υψηλή ενέργεια και αντίστοιχα εμφάνιση σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα abnormal bispectrum με βλάβη στον εσωτερικό δακτύλιο ρουλεμάν είναι περίπου 3500.

## **Βήμα 5:** Εξαγωγή χαρακτηριστικού καμπυλότητας (*trainAndPredict.m*)

Κατά την εξαγωγή της καμπυλότητας, αναμένουμε για τα φυσιολογικά bispectrum τιμές circularity πιο κοντά στην μονάδα, σε σχέση με τα bispectrum μη φυσιολογικής λειτουργίας. Πράγματι η σχέση  $circularity = \frac{4 \cdot A \cdot \pi}{P^2}$  δίνει για τα normal bispectrum κατά μέσο όρο 0.96 και για τα

abnormal δίνει τιμές γύρω στο 0.83. Αυτό συμβαίνει γιατί τα οβαλοειδή bispectrum που προκύπτουν για τα σήματα φυσιολογικής κατάστασης είναι πιο “κυκλικά”, από τα αντίστοιχα εξάπλευρα και αστεροειδή bispectrum των σημάτων μη φυσιολογικής κατάστασης.


#### **Βήμα 6:** Αξιολόγηση αλγορίθμου ταξινόμησης (*trainAndPredict.m*)

Αφού εξαχθούν τα 3 χαρακτηριστικά (features) για κάθε bispectrum, τροφοδοτούνται στη μηχανή διανυσματικής υποστήριξης (SVM) και πραγματοποιείται η εκπαίδευση με την συνάρτηση *svmtrain* της βιβλιοθήκης *libsvm*. Στη συνάρτηση *svmtrain* ορίζουμε γραμμικό πυρήνα ('-t 0'). Στη συνέχεια εξάγουμε τα χαρακτηριστικά από τα bispectrum που ανήκουν στην ομάδα δοκιμών και με τη βοήθεια της συναρτησης *svmpredict*, πραγματοποιείται πρόβλεψη, κατατάσσοντας τα σε normal ή abnormal. Τέλος πραγματοποιείται έλεγχος της απόδοσης του μοντέλου υπολογίζοντας την απόλυτη και την μέση ακρίβεια. Προς αποφυγή εξαγωγής λανθασμένων συμπερασμάτων, ο κώδικας *trainAndPredict.m* ‘έτρεξε’ 100 φορές, διαλέγοντας με τυχαίο τρόπο κάθε φορά, διαφορετικά bispectrum για την ομάδα εκπαίδευσης και την ομάδα δοκιμών.

Μετά από 100 διαφορετικές εκπαιδεύσεις η απόλυτη ακρίβεια προέκυψε ίση με 94.46% . Η απόλυτη ακρίβεια προκύπτει από την σχέση:

$$totalAccuracy = \frac{totalCorrectPredictions}{totalTrainSample}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος 4-8 από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 76.92% 3 φορές, 84.6% 9 φορές, 92.3% 45 φορές και 100% 43 φορές.




Σχήμα 4-8: απόλυτη ακρίβεια του SVM

Αντίστοιχα μετά από 100 εκπαιδεύσεις η μέση ακρίβεια προέκυψε ίση με 94.23% . Η μέση ακρίβεια προκύπτει από την σχέση:


$$meanAccuracy = \frac{\frac{totalNORMcorrect}{totalNORMtrain} + \frac{totalFAILcorrect}{totalFAILtrain}}{2}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος 4-7 από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 77.5% 3 φορές, 83.75% 3 φορές, 87.5% 5 φορές, 90% 27 φορές, 93.75% 19 φορές και 100% 43 φορές.




Σχήμα 4-9: Ιστόγραμμα μέσης ακρίβειας SVM


Στο σχήμα 4-10 ακολουθεί οπτικοποίηση της πρόβλεψης του μοντέλου. Με κόκκινους κύκλους συμβολίζουμε τα abnormal bispectrum ομάδας εκπαίδευσης και με μπλε κύκλους τα normal bispectrum ομάδας εκπαίδευσης. Με κόκκινο X συμβολίζουμε τα abnormal bispectrum ομάδας δοκιμών και με μπλε αστέρι τα normal bispectrum ομάδας δοκιμών. Το μπλε επίπεδο είναι το όριο απόφασης που προκύπτει από την εκπαίδευση του SVM



Σχήμα 4-10α



Σχήμα 4-10β



Σχήμα 4-10γ

Σχήμα 4-10 α) μέση ακρίβεια 100%, β) μέση ακρίβεια 93.75%, γ) μέση ακρίβεια 87.5%

Στο Σχήμα 4-10α η μέση ακρίβεια είναι 100% (13/13) και κάθε παρατήρηση έχει ταξινομηθεί σωστά. Στο σχήμα 4-10β η μέση ακρίβεια είναι 93.75% (12/13) και όπως παρατηρείται, ένα bispectrum μη φυσιολογικής κατάστασης έχει ταξινομηθεί σαν normal. Στο σχήμα 4-10γ η μέση ακρίβεια είναι 87.5% (11/13) και όπως φαίνεται ένα normal bispectrum έχει καταταχθεί σαν abnormal (σήμα 17) και αντίστοιχα ένα abnormal bispectrum σαν normal (σήμα 38).

Αξίζει να σημειωθεί ότι οι παραπάνω ακρίβειες δεν επηρεάζονται ιδιαίτερα από την επιλογή των κλάσεων στις οποίες κατατάσσονται τα SURF διανύσματα μέσω του Kmeans. Για κλάσεις από 50 ως 300, τόσο η απόλυτη όσο και η μέση ακρίβεια πρόβλεψης προκύπτουν στο 94%  $\pm$  0.5%, με τον χρόνο εκτέλεση του κώδικα *trainAndPredict.m* να αυξάνεται από 3.9 sec (50 κλάσεις) σε 4.5 sec (300 κλάσεις). Επιλέγουμε 50 κλάσεις, ώστε ο κώδικας να είναι εύρωστος σε περίπτωση περιορισμένου αριθμού σημάτων και κατ' επέκταση περιορισμένου αριθμού διανυσμάτων SURF.


Από την παραπάνω ανάλυση προκύπτει ότι ακόμα και με λίγες εικόνες (40 bispectrum συνολικά, ενώ προτείνεται 1000 εικόνες ανά κλάση), μπορούν να προβλεφθούν σωστά πάνω από 9 από τα 10 σήματα. Αυτό συμβαίνει διότι τα bispectrum είναι αρκετά διακριτά μεταξύ normal (φυσιολογικής λειτουργίας) και abnormal (μη φυσιολογικής λειτουργίας). Στις ελάχιστες περιπτώσεις που πέφτει η απόδοση του κώδικα, μπορούμε να αποδώσουμε ευθύνη σε 2 παράγοντες: α) Στην τυχαία επιλογή των σημάτων ελέγχου, κατά την οποία επιλέχθηκαν τα normal και abnormal σήματα που μοιάζουν μεταξύ τους (βλέπε σχήμα 4-7 οβαλοειδές bispectrum μη φυσιολογικής κατάστασης), β) στην τυχαία αρχικοποίηση των κέντρων SURF, διότι κατά την εκτέλεση του kmeans, μπορούν να προκύψουν τελικά κέντρα, normal και abnormal, που είναι πολύ κοντά μεταξύ τους, με συνέπεια η πλειοψηφία των SURF διανυσμάτων ορισμένων bispectrum να μην μπορούν να καταταχθούν και η εικόνα να γίνεται οριακά misclassify, όπως φαίνεται χαρακτηριστικά στο σχήμα 4-10γ.

### 4.3 Σετ 2 : Φθορά εξωτερικού δακτυλίου ρουλεμάν


Από το δεύτερο σετ χρησιμοποιήθηκαν 40 σήματα για εκπαίδευση και πρόβλεψη. Από τα 40 σήματα, τα 30 αποτελούν σήματα φυσιολογικής λειτουργίας και τα υπόλοιπα 10 σήματα αντιστοιχούν σε φθορά του εξωτερικού δακτυλίου του ρουλεμάν 1 (δεδομένα απο τη στήλη 1 των μετρήσεων).

**Βήμα 1:** Επεξεργασία σημάτων και εξαγωγή bispectrum (*extractBispectrums.m*)

Επεξεργάζοντας τα σήματα παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση κατά μέσο όρο στα 3800 Hz όπως φαίνεται στο σχήμα 4-9:




Σχήμα 4-11α




Σχήμα 4-11β

Σχήμα 4-11 α) Μέγιστη φασματική κύρτωση 5156 Hz, β) μέγιστη φασματική κύρτωση 5833 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 4-10 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα normal σήματα μετά την αποδιαμόρφωση.




Σχήμα 4-12α



Σχήμα 4-12β




Σχήμα 4-12γ



Σχήμα 4-12δ

Σχήμα 4-12: Συχνολογικό φάσμα αποδιαμορφωμένων σημάτων φυσιολογικής λειτουργίας

Στο σχήμα 4-13 φαίνονται ενδεικτικά 4 bispectrum εξαγόμενα από τα normal σήματα (φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



Σχήμα 4-13: Bispectrum φυσιολογικής λειτουργίας


Όπως φαίνεται στο σχήμα 4-13 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :

- Εξάπλευρο περίγραμμα και σε ορισμένες περιπτώσεις οβαλοειδές σχήμα
- Ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.


Πιο συγκεκριμένα οι αποχρώσεις που εμφανίζονται στα bispectrum φυσιολογικής λειτουργίας είναι στην περιοχή (205 – 255), με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια).



Τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση γύρω από την περιοχή των 5000 Hz όπως φαίνεται στο σχήμα 4-14:




Σχήμα 4-14α




Σχήμα 4-14β

Σχήμα 4-14 α) Μέγιστη φασματική κύρτωση στα 5000 Hz, β) Μέγιστη φασματική κύρτωση στα 5833


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 4-14 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα normal σήματα μετα την αποδιαμόρφωση.




Σχήμα 4-15α



Σχήμα 4-15β




Σχήμα 4-15γ



Σχήμα 4-15δ

Σχήμα 4-15: Συχνολογικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας

Στο σχήμα 4-16 φαίνονται ενδεικτικά 4 bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



Σχήμα 4-16: Bispectrum μη φυσιολογικής λειτουργίας

Όπως φαίνεται στο σχήμα 4-16 τα bispectrum φυσιολογικής λειτουργίας έχουν τα εξής χαρακτηριστικά :

- Πλειοψηφικά αποτελούν πολύγωνα σε σχήμα “νιφάδας”
- Εμφανίζουν σκούρες αποχρώσεις του γκρι που φτάνουν ως το μαύρο, γεγονός που υποδηλώνει υψηλή ενέργεια

Παρατηρείται ότι όπως και στο Σει 1, τα σήματα που αντιστοιχούν σε μη φυσιολογική λειτουργία εμφανίζουν πιο ψηλά bispectrum, που φαίνεται στις πιο έντονες αποχρώσεις τους. Αυτό είναι αναμενόμενο, διότι οι μηχανολογικές βλάβες αυξάνουν τα επίπεδα του θορύβου και κατα συνέπεια την ενέργεια των σημάτων.

## **Βήμα 2:** Διαχωρισμός εικόνων σε ομάδες εκπαίδευσης και δοκιμών (*trainAndPredict.m*)

Πριν αρχίσουμε την εκπαίδευση του ταξινομητή χωρίζουμε τα σήματα σε ομάδες εκπαίδευσης (*train* – ιστορικά δεδομένα εκπαίδευσης) και ομάδες δοκιμών (*test* – δεδομένα ελέγχου). Τα σήματα εκπαίδευση αποτελούν το 65% των σημάτων. Μετά τον διαχωρισμό καταλήγουμε σε:

- 13 bispectrum φυσιολογικής λειτουργίας για εκπαίδευση και 7 για έλεγχο (20 σύνολο)
- 13 bispectrum μη φυσιολογικής λειτουργίας για εκπαίδευση και 7 για έλεγχο (20 σύνολο)

Σημειώνεται ότι καθορίζεται με τυχαίο τρόπο ποια σήματα θα είναι εκπαίδευσης και ποια δοκιμής.

## **Βήμα 3:** Εξαγωγή SURF χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Στο επόμενο βήμα εξάγονται τα SURF features όπως περιγράφονται στην μεθοδολογία στο κεφάλαιο X.

Πρώτα βρίσκονται όλα τα SURF διανύσματα που περιγράφουν τα bispectrum. Για όλα τα bispectrum φυσιολογικής κατάστασης εξάγονται συνολικά 700 με 900 διανύσματα περιγραφής, ενώ για τα bispectrum μη φυσιολογικής κατάστασης εξάγονται συνολικά 1000 με 1200 διανύσματα περιγραφής. Αυτό αποδίδεται στην πιο σύνθετη μορφή των abnormal bispectrums.

Στη συνέχεια επιλέγεται ο αριθμός των κέντρων-κλάσσεων, που θα καταταχθούν τα normal SURF διανύσματα και τα abnormal SURF διανύσματα. Όπως και στην περίπτωση του Σει 1 επιλέγουμε 50 κέντρα για κάθε κατηγορία (100 συνολικά). Αφού βρεθούν τα κέντρα, κατατάσσουμε τα SURF διανύσματα κάθε bispectrum σε normal κέντρο ή abnormal κέντρο και υπολογίζεται τελικά το SURF feature κάθε bispectrum ως:

$$[\sum (SURFvector = normal)] - [\sum (SURFvector = abnormal)]$$

## **Βήμα 4:** Εξαγωγή Gray Scale χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Όπως φαίνεται και στο σχήμα 4-16 τα bispectrum φυσιολογικής κατάστασης έχουν χαμηλή ενέργεια και αντίστοιχα απουσία σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα normal bispectrum είναι περίπου 1.300.

Αντίστοιχα όπως φαίνεται στο σχήμα 4-16 τα bispectrum μη φυσιολογικής κατάστασης έχουν υψηλή ενέργεια και αντίστοιχα εμφάνιση σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα abnormal bispectrum με βλάβη στον εξωτερικό δακτύλιο ρουλεμάν είναι περίπου 14.000.

## **Βήμα 5:** Εξαγωγή χαρακτηριστικού καμπυλότητας (*trainAndPredict.m*)

Κατα την εξαγωγή της καμπυλότητας, δεν αναμένουμε πολύ μεγάλες αποκλίσεις στην τιμή της καμπυλότητας για τα φυσιολογικά και τα μη φυσιολογικά bispectrum. Πράγματι η σχέση

$circularity = \frac{4 \cdot A \cdot \pi}{P^2}$  δίνει για τα normal bispectrum κατά μέσο όρο 0.90 και για τα abnormal δίνει τιμές γύρω στο 0.88.


### Βήμα 6: Αξιολόγηση αλγορίθμου ταξινόμησης (trainAndPredict.m)

Αφού εξαχθούν τα 3 χαρακτηριστικά (features) για κάθε bispectrum, τροφοδοτούνται στη μηχανή διανυσματικής υποστήριξης (SVM) και πραγματοποιείται η εκπαίδευση με την συνάρτηση svmtrain της βιβλιοθήκης libsvm. Στη συνάρτηση svmtrain ορίζουμε γραμμικό πυρήνα ('-t 0'). Στη συνέχεια εξαγάμε τα χαρακτηριστικά από τα bispectrum που ανήκουν στην ομάδα δοκιμών και με τη βοήθεια της συναρτησης svmpredict, πραγματοποιείται πρόβλεψη, κατατάσσοντας τα σε normal ή abnormal. Τέλος πραγματοποιείται έλεγχος της απόδοσης του μοντέλου υπολογίζοντας την απόλυτη και την μέση ακρίβεια. Προς αποφυγή εξαγωγής λανθασμένων συμπερασμάτων, ο κώδικας trainAndPredict.m 'έτρεξε' 100 φορές, διαλέγοντας με τυχαίο τρόπο κάθε φορά, διαφορετικά bispectrum για την ομάδα εκπαίδευσης και την ομάδα δοκιμών.

Μετά από 100 διαφορετικές εκπαιδεύσεις η απόλυτη ακρίβεια προέκυψε ίση με 93.71% . Η απόλυτη ακρίβεια προκύπτει από την σχέση:

$$totalAccuracy = \frac{totalCorrectPredictions}{totalTrainSample}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος 4-16 από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 78.57% 4 φορές, 85.71% 18 φορές, 92.86% 40 φορές και 100% 38 φορές.




Σχήμα 4-17: Ιστόγραμμα απόλυτης ακρίβειας SVM

Αντίστοιχα μετά από 100 εκπαιδεύσεις η μέση ακρίβεια προέκυψε ίση με 93.71% . Η μέση ακρίβεια προκύπτει από την σχέση:

$$meanAccuracy = \frac{\frac{totalNORMcorrect}{totalNORMtrain} + \frac{totalFAILcorrect}{totalFAILtrain}}{2}$$


Πιο συγκεκριμένα από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 78.57% 4 φορές, 85.71% 18 φορές, 92.86% 40 φορές και 100% 38 φορές.

Όπως ήταν αναμενόμενο τα νούμερα της απόλυτης και της μέσης ακρίβειας ταυτίζονται, διότι οι ομάδες ελέγχου για τα bispectrum φυσιολογικής και μη φυσιολογικής λειτουργίας έχουν το ίδιο μέγεθος. Στο σχήμα 17 παρουσιάζεται το ιστόγραμμα μέσης ακρίβειας για λόγους πληρότητας.




Σχήμα 18: ιστόγραμμα μέσης ακρίβειας SVM


Στο σχήμα 4-19 ακολουθεί οπτικοποίηση της πρόβλεψης του μοντέλου. Με κόκκινους κύκλους συμβολίζουμε τα abnormal bispectrum ομάδας εκπαίδευσης και με μπλε κύκλους τα normal bispectrum ομάδας εκπαίδευσης. Με κόκκινο X συμβολίζουμε τα abnormal bispectrum ομάδας δοκιμών και με μπλε αστέρι τα normal bispectrum ομάδας δοκιμών.



Σχήμα 4-19α



Σχήμα 4-19β



Σχήμα 4-19γ

Σχήμα 4-19 α) Μέση ακρίβεια 100%, β) Μέση ακρίβεια 92.86%, γ) Μέση ακρίβεια 85.71%

Στο Σχήμα 4-19α η μέση ακρίβεια είναι 100% (14/14) και κάθε παρατήρηση έχει ταξινομηθεί σωστά. Στο σχήμα 4-19β η μέση ακρίβεια είναι 92.86% (13/14) και όπως παρατηρείται, ένα bispectrum μη φυσιολογικής κατάστασης έχει ταξινομηθεί σαν normal. Στο σχήμα 4-19γ η μέση ακρίβεια είναι 87.5% (12/14) και όπως φαίνεται δύο abnormal bispectrum έχουν καταταχθεί σαν normal.

Αξίζει να σημειωθεί ότι οι παραπάνω ακρίβειες δεν επηρεάζονται ιδιαίτερα από την επιλογή των κλάσεων στις οποίες κατατάσσονται τα SURF διανύσματα μέσω του Kmeans. Για κλάσεις από 50 ως 300, τόσο η απόλυτη όσο και η μέση ακρίβεια πρόβλεψης προκύπτουν στο 93.5%  $\pm$  0.5%, με τον χρόνο εκτέλεση του κώδικα *trainAndPredict.m* να αυξάνεται από 5.9 sec (50 κλάσεις) σε 6.5 sec (300 κλάσεις). Επιλέγουμε 50 κλάσεις, ώστε ο κώδικας να είναι εύρωστος σε περίπτωση περιορισμένου αριθμού σημάτων και κατ' επέκταση περιορισμένου αριθμού διανυσμάτων SURF.

Από την παραπάνω ανάλυση προκύπτει ότι ακόμα και με λίγες εικόνες (40 bispectrum συνολικά, ενώ προτείνεται 1000 εικόνες ανά κλάση), μπορούν να προβλεφθούν σωστά πάνω από 9 από τα 10 σήματα. Αυτό συμβαίνει διότι τα bispectrum είναι αρκετά διακριτά μεταξύ normal (φυσιολογικής λειτουργίας) και abnormal (μη φυσιολογικής λειτουργίας). Επίσης παρατηρούμε ότι η ανικανότητα να διακριθούν τα bispectrum λόγω καμπυλότητας (για τα normal bispectrum έχουμε κατά μέσο όρο circularity=0.90 και για τα abnormal circularity=0.88) δεν επηρεάζει την απόδοση του αλγορίθμου, δεδομένου του γεγονότος ότι τα άλλα 2 χαρακτηριστικά, τόσο τα SURF features, όσο και τα Gray Scale features, είναι ικανά να διαφοροποιήσουν τις 2 ομάδες.



## ΚΕΦΑΛΑΙΟ 5- Πειραματικά αποτελέσματα – Σπηλαιώση

### 5.1 Πειραματική εγκατάσταση

Δύο πειραματικές εγκαταστάσεις φυγοκεντρικών αντλιών συναρμολογήθηκαν με σκοπό την μελέτη του εντοπισμού της σπηλαιώσης. Η μία εγκαταστάθηκε στο Τμήμα Μηχανικής του Πανεπιστημίου του Lancaster και η άλλη στο Εργαστήριο Υδροδυναμικών Μηχανών του Εθνικού Μετσόβιου Πολυτεχνείου. Το ανοικτό κάρτερ με τη διαδικασία της πεταλούδας (βαλβίδας) στραγγαλισμού που ακολουθήθηκε για την παραγωγή καμπυλών σπηλαιώσης και στις δύο εξέδρες δοκιμής παρέχονται από το ISO 9906:2012. Κατά τη διαδικασία αυτή, η στατική πίεση αναρρόφησης της ροής μειωνόταν σταδιακά, κλείοντας την βαλβίδα στραγγαλισμού. Με αυτόν τον τρόπο οι απώλειες αναρρόφησης αυξανόταν, η τιμή της NPSH μειωνόταν, ωστόσο η ροή μειώθηκε. Ως αποτέλεσμα, η βαλβίδα κατάθλιψης προσαρμοζόταν κατάλληλα για να ρυθμιστεί η ροή στην αρχική της τιμή.

Μετά από 30 δευτερόλεπτα από τη ρύθμιση των βαλβίδων, η ροή σταθεροποιείται και οι συνθήκες θεωρούνται σταθερή κατάσταση. Σε αυτό το σημείο αποκλείεται το διαφορετικό σύνολο δεδομένων από τις υδραυλικές μετρήσεις για 2 λεπτά και μετά από αυτό, ακολουθεί η νέα ρύθμιση της βαλβίδας αναρρόφησης. Ταυτόχρονα κατά τη διάρκεια αυτού του χρονικού διαστήματος, τα σήματα δόνησης μετρήθηκαν για 30 δευτερόλεπτα. Η συνολική τιμή δόνησης παρέμεινε σε αποδεκτά επίπεδα και δεν επηρέασε τα αποτελέσματα. Πιο συγκεκριμένα, η ταχύτητα RMS στην περιοχή από 10 έως 1000 Hz είναι χαμηλότερη από  $3,2 \text{ mms}^{-1}$  για όλα τα σημεία λειτουργίας.


Και στις δύο ρυθμίσεις, οι υδραυλικές μετρήσεις περιελάμβαναν την απόκτηση στατικής πίεσης αναρρόφησης και κατάθλιψης, ροής, θερμοκρασίας νερού και ταχύτητας περιστροφής, ενώ για τη μέτρηση των κραδασμών χρησιμοποιήθηκαν 2 πιεζοηλεκτρικά επιταχυνσιόμετρα. Η ταχύτητα περιστροφής και η θερμοκρασία του ρευστού διατηρούνται σταθερά κατά την εξαγωγή των καμπυλών σ-Ψ. Κατά τη διάρκεια της περιόδου των 2 λεπτών, η απεικόνιση της περιοχής σπηλαιώσης μέσω της κάμερας παρέμεινε αμετάβλητη. Ως αποτέλεσμα, θεωρήσαμε ότι το φαινόμενο εμφάνισε σταθερή κατάσταση (steady state) χαρακτηριστικών της καλυμμένης περιοχής του, παρόλο που παρουσιάζει μικροσκοπικά παροδικά χαρακτηριστικά.

### 5.2 Πειραματική διάταξη Πανεπιστημίου του Lancaster

Η δοκιμαστική εξέδρα στο Πανεπιστήμιο του Λάνκαστερ φαίνεται στο Σχήμα 5-1 και οι θέσεις της αντλίας, των βαλβίδων, των αισθητήρων και του στροβοσκοπίου είναι σημειωμένες. Ο αγκώνας (σωλήνας) πριν από την είσοδο της αντλίας εισάγει επιπλέον απώλειες και διαταράσσει την αξονική συμμετρία της ροής. Αυτό οδήγησε σε ένα πεδίο μη αξονοσυμμετρικής ροής στην περιστρεφόμενη πτερωτή, όπου εμφανίστηκε σπηλαιώση για πρώτη φορά στην αριστερή του πλευρά. Για το λόγο αυτό, η περιοχή φωτογραφήθηκε από την αριστερή πλευρά της πτερωτής. Η κάμερα που χρησιμοποιήθηκε είναι τύπου DSLR με αριθμό εγγεγραμμένων εικονοστοιχείων  $4752 \times 3168$ , αισθητήρα εικόνας CMOS και μέγιστη ταχύτητα κλείστρου 0,25 msec. Επιπλέον, οι συνολικές σχετικές αβεβαιότητες όλων των υδραυλικών μετρούμενων και υπολογισμένων ποσοτήτων δίδονται στον Πίνακα 5-1.

Μετρούμενες Μεταβλητές					Υπολογισμένες μεταβλητές					
X	Q	P <sub>st Suct</sub>	P <sub>st Dis</sub>	T	ω	Φ	Ψ	σ	H <sub>tot</sub>	NPSH
+fx%	0.6	0.3	0.3	1	0.1	0.6	0.6	0.8	0.6	0.6

Πίνακας 1: Συνολικές σχετικές αβεβαιότητες όλων των υδραυλικών μετρούμενων και υπολογισμένων ποσοτήτων



Σχήμα 5-1: Εργαστηριακή εγκατάσταση i) αντλία, ii) μετρητής πίεσης αναρρόφησης, iii) μετρητής πίεσης κατάθλιψης, iv) μετρητής ροής, v) βαλβίδα κατάθλιψης, vi) βαλβίδα αναρρόφησης, vii) δεξαμενή νερού, viii) στροβοσκόπιο, ix) φωτογραφούμενη περιοχή, x) B01\_1 επιταχυνσιόμετρο, xi) A01 επιταχυνσιόμετρο

Η ημι-ανοιχτή πτερωτή που δοκιμάστηκε στο Πανεπιστήμιο του Λάνκαστερ και που θα μελετήσουμε έχει δώδεκα ακτινικές λεπίδες. Η πτερωτή φαίνεται στο Σχήμα 5-2 και τα γεωμετρικά χαρακτηριστικά της δίδονται στον Πίνακα 2.




Σχήμα 5-2: Πτερωτή (Lancaster)

Αριθμός λεπίδων	Αριθμός διαχωριστικών λεπίδων	$b_1$ [mm]	$b_2$ [mm]	$s_2$ [mm]	$R_1$ [mm]	$R_2$ [mm]	$\omega$ [rpm]	$T$ [°C]
12	0	7.53	3.25	2.10	33	82.5	1800	23

Πίνακας 2: Γεωμετρικά χαρακτηριστικά πτερωτής (Lancaster)

Δύο πιεζοηλεκτρικά χρησιμοποιήθηκαν επιταχυνσιόμετρα για τη μέτρηση της μηχανικής δόνησης στην αντλία. Η διάταξη της αντλίας δεν είχε ρουλεμάν και κατά συνέπεια όλα τα φορτία της μηχανής μεταφέρθηκαν στα ρουλεμάν του κινητήρα. υτός ήταν ο λόγος για την τοποθέτηση και των δύο αισθητήρων στο περίβλημα της μηχανής, όπως παρουσιάζεται στο Σχήμα 5-3. Ο αισθητήρας B01\_1 τοποθετήθηκε πιο κοντά στο τοίχωμα της πτερωτής, δίπλα στην περιοχή ροής δύο φάσεων, και ο αισθητήρας A01 στο τοίχωμα του πτερυγίου. Το αναλογικό σήμα και των δύο επιταχυνσιόμετρων πέρασε από ένα αναλογικό φίλτρο χαμηλής διέλευσης πριν από την ψηφιοποίησή του σε μια συσκευή MCC USB-1608G DAQ. Η συχνότητα δειγματοληψίας,  $f_s$ , η συχνότητα αποκοπής του φίλτρου χαμηλής διέλευσης,  $f_{cutoff}$ , ο χρόνος απόκτησης,  $t_{acq}$  και το εύρος συχνοτήτων που μπορεί να μετρήσει κάθε αισθητήρας δίδονται στον Πίνακα 3.



Σχήμα 5-3: Θέσεις επιταχυνσιόμετρων

Sensor	$f_s$ [KHz]	$f_{cutoff}$ [KHz]	$t_{acq}$ [sec]	$[f_{min}-f_{max}]$ [Hz]
B01_1	20	10	30	0.2-15000
A01	20	5	30	0.2-15000

Πίνακας 3: Τεχνικά χαρακτηριστικά αισθητήρων στο πανεπιστήμιο του Lancaster

Τέλος, οι μηχανικές συχνότητες του συστήματος αντλίας-κινητήρα δίδονται στον Πίνακα 4. Αυτές σχετίζονται με τη συχνότητα περιστροφής, τη συχνότητα διέλευσης λεπίδας blade passing frequency, τα δύο ρουλεμάν (6207 & 6203) και τον κινητήρα.

RF	BPF	TPBF	MF	BPI	BPO	FT	BS
30	360	-	50	163/131	107/79	12/11	69/57


Πίνακας 4: Συχνότητες από το σύστημα αντλία-κινητήρα από την εγκατάσταση στο πανεπιστήμιο του Lancaster

## Επεξεργασία μετρήσεων και εκπαίδευση SVM (εγκατάσταση Lancaster)

Από την εγκατάσταση στο πανεπιστήμιο του Lancaster θα επεξεργαστούμε 2 σειρές μετρήσεων για 2 διαφορετικές παροχές  $Q_1=4.1\text{m}^3/\text{hr}$  και  $Q_2=6.8\text{m}^3/\text{hr}$ . Από την παροχή έχουμε 9 μετρήσεις και από την δεύτερη 8.

### Βήμα 1: Επεξεργασία σημάτων και εξαγωγή bispectrum (*extractBispectrums.m*)


Από τις 9 μετρήσεις που αντιστοιχούν στην παροχή  $Q_1=4.1\text{m}^3/\text{hr}$ , τα 5 σήματα αντιστοιχούν σε φυσιολογική λειτουργία και τα 4 αντιστοιχούν σε λειτουργία με σπηλαίωση. Από τις 8 μετρήσεις που αντιστοιχούν στην παροχή  $Q_1=6.8\text{m}^3/\text{hr}$ , τα 3 σήματα αντιστοιχούν σε φυσιολογική λειτουργία και τα 5 αντιστοιχούν σε λειτουργία με σπηλαίωση. Κάθε σήμα αντιστοιχεί σε ένα διαφορετικό σημείο λειτουργίας (Operating Point), όπως φαίνεται στο σχήμα 5-4:




Σχήμα 5-4: Χαρακτηριστικές καμπύλες  $\sigma$ - $\Psi$  σπηλαίωσης για διαφορετικές τιμές  $\Phi$

Όπως φαίνεται στο σχήμα 5-4, πτώση στην τιμή  $\sigma$  συντελεί και μείωση στην τιμή  $\Psi$ . Τα σημειωμένα σημεία λειτουργίας αντιστοιχούν στην *έναργξη* της σπηλαίωσης, όπου παρατηρούνται οι πρώτες φυσαλίδες. Για τιμές  $\sigma$  μικρότερες της  $\sigma$  (έναργξης) έχουμε σπηλαίωση.

Ελεξεργάζοντας τα σήματα για την παροχή  $Q1=4.1m^3/hr$  παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση κατά μέσο όρο στα 9000 Hz όπως φαίνεται στο σχήμα 5-5:




Σχήμα 5-5α




Σχήμα 5-5β

Σχήμα 5-5 α) Μέγιστη φασματική κύρτωση 8958 Hz, β) Μέγιστη φασματική κύρτωση 9062 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-6 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα postal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-6α




Σχήμα 5-6β



Σχήμα 5-6γ




Σχήμα 5-6δ




Σχήμα 5-6ε

Σχήμα 6: Συχνολογικό φάσμα αποδιαμορφωμένων σημάτων φυσιολογικής λειτουργίας, α) OP1, β) OP2, γ) OP3, δ) OP4, ε) OP5


Στο σχήμα 5-7 φαίνονται τα bispectrum εξαγόμενα από τα normal σήματα (φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 5-7α




Σχήμα 5-7β



Σχήμα 5-7γ



Σχήμα 5-7δ



Σχήμα 5-7ε


Σχήμα 5-7 α) bispectrum OP1, β) bispectrum OP2, γ) bispectrum OP3, δ) bispectrum OP4, ε) bispectrum OP5

Όπως φαίνεται στο σχήμα 5-7 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :


- Οβαλοειδές σχήμα
- Πολύ ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.

Πιο συγκεκριμένα η αποχρώση που εμφανίζεται στα bispectrum φυσιολογικής λειτουργίας είναι μόνο το 255, με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια).

Αντίστοιχα παρατηρείται ότι τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία (σπηλαίωση) εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση γύρω από την περιοχή των 8500 Hz όπως φαίνεται στο σχήμα 5-8:



Σχήμα 5-8α




Σχήμα 5-8β


Σχήμα 5-8 α) Μέγιστη φασματική κύρτωση 8333 Hz, β) Μέγιστη φασματική κύρτωση 8750 Hz




Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση, αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα Z-9 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα abnormal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-9α



Σχήμα 5-9β



Σχήμα 5-9γ




Σχήμα 5-9δ


Σχήμα 9: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων φυσιολογικής λειτουργίας, α) OP6, β) OP7, γ) OP8, δ) OP9

Στο σχήμα 5-9 φαίνεται ήδη ότι από την αρχή της σπηλαίωσης κάνει εμφανίζεται η Blade Pass Frequency (BPF = 360 Hz). Όσο δυναμώνει το φαινόμενο, ενισχύεται η BPF και εμφανίζονται και αρμονικές τις καθώς και οι  $\pm$  Fshaft εκατέρωθεν τους.


Στο σχήμα 5-10 φαίνονται τα bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 5-10α



Σχήμα 5-10β



Σχήμα 5-10γ



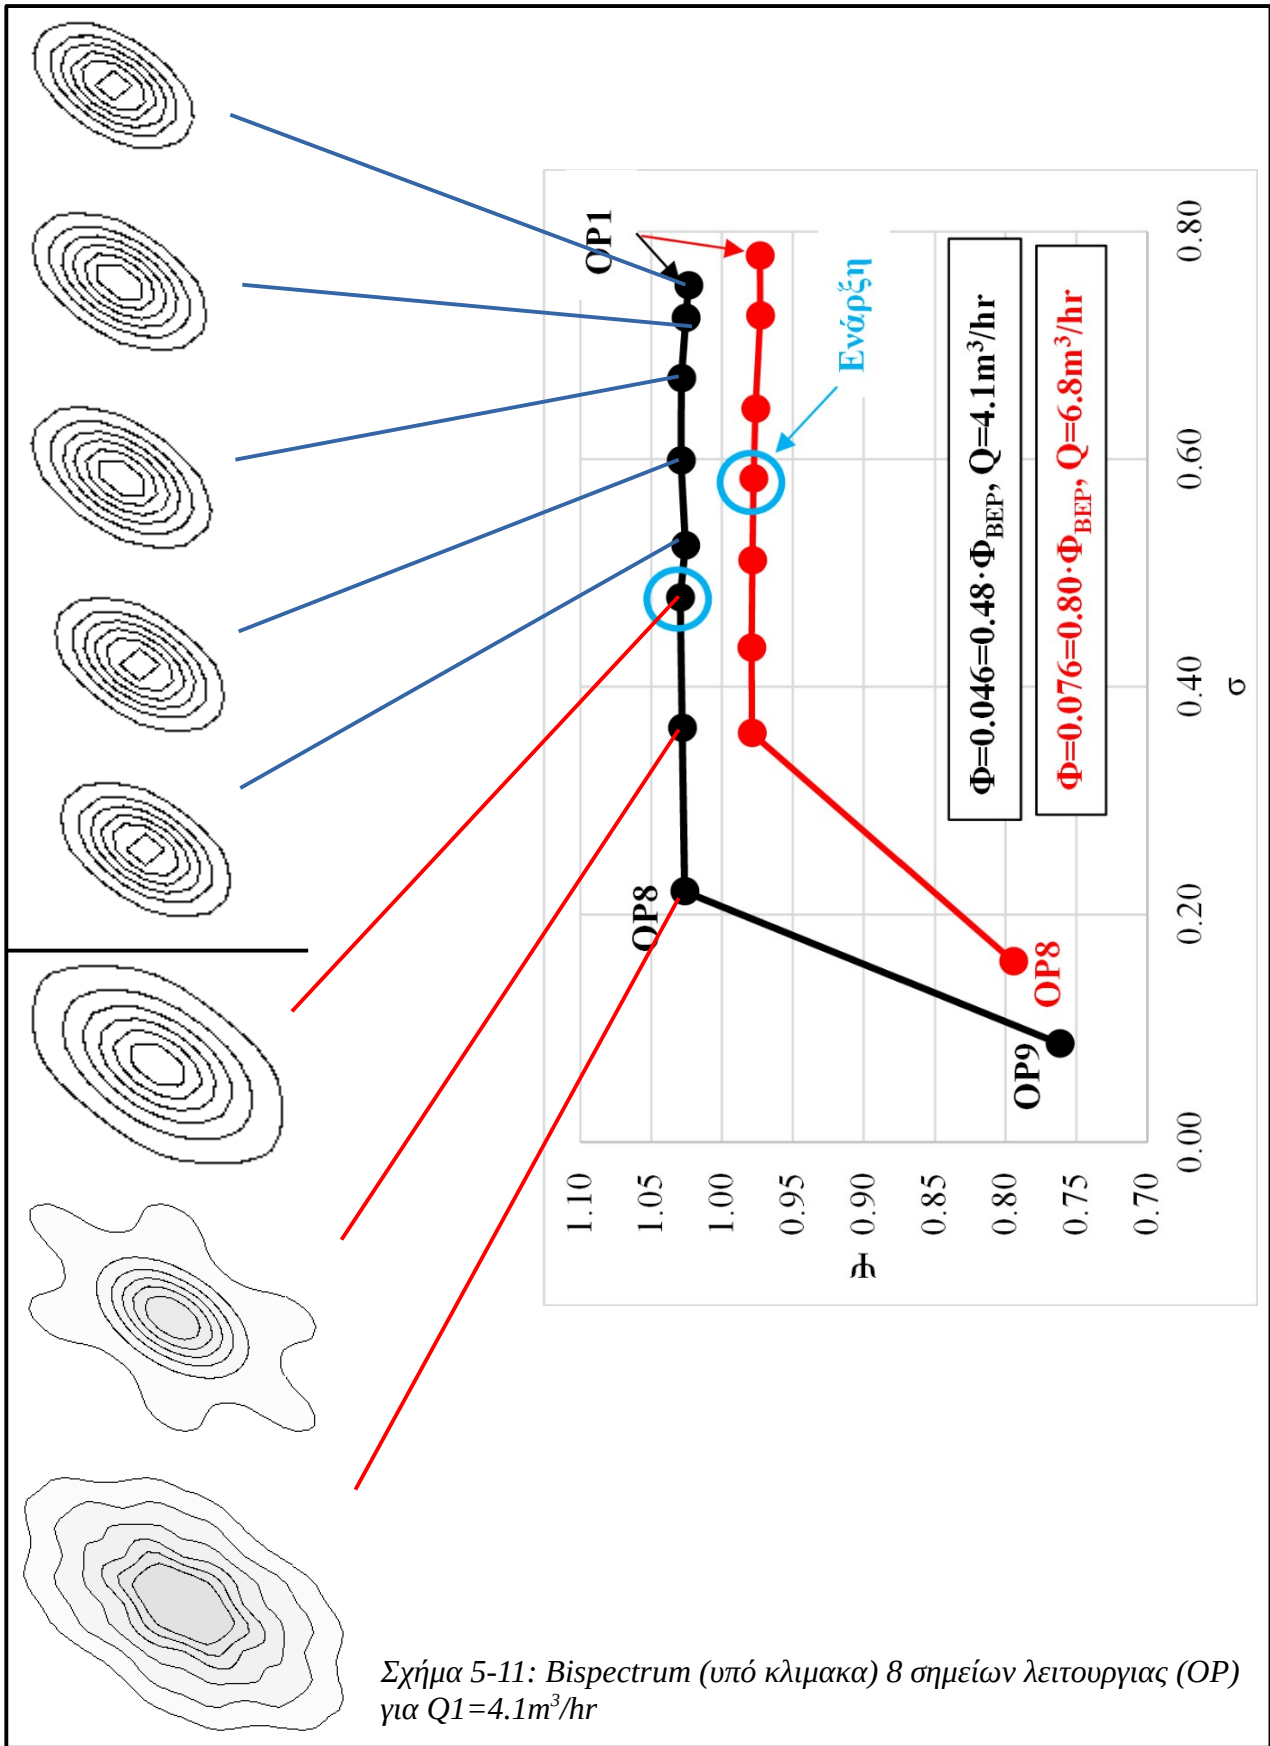
Σχήμα 5-10δ

Σχήμα 5-10: Bispectrum μη φυσιολογικής κατάστασης, α) OP6, β) OP7, γ) OP8, δ) OP9


Όπως φαίνεται στο σχήμα 5-10 τα bispectrum μη φυσιολογικής λειτουργίας έχουν τα εξής χαρακτηριστικά :

- Ξεκινάνε από γωνιώδη οβαλοειδή μορφή, μετά αποκτούν μορφή στρογγυλεμένου εξαγωνικού αστέρα και καταλήγουν σε πολυγωνικά σχήματα.
- Εμφανίζουν πιο σκούρες αποχρώσεις του γκρι, συγκριτικά με τα normal bispectrum, που φτάνουν ως το μαύρο, γεγονός που υποδηλώνει υψηλή ενέργεια.


Στο σχήμα 5-11 που ακολουθεί φαίνονται συνοπτικά 8 από τα σημεία λειτουργίας και τα αντίστοιχα bispectrum υπο κλίμακα, για παροχή  $Q1=4.1\text{m}^3/\text{hr}$



Ελεξεργάζοντας τα σήματα για την παροχή  $Q1=6.8m^3/hr$  παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση κατά μέσο όρο στα 8600 Hz όπως φαίνεται στο σχήμα 5-12:




Σχήμα 5-12α




Σχήμα 5-12β

Σχήμα 5-12 α) Μέγιστη φασματική κύρτωση 8593 Hz, β) Μέγιστη φασματική κύρτωση 8593 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθρομβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-13 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα normal σήματα μετα την αποδιαμόρφωση.



Σχήμα 5-13α




Σχήμα 5-13β



Σχήμα 5-13γ

Σχήμα 5-13: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας

Στο σχήμα 5-14 φαίνονται τα bispectrum εξαγόμενα από τα normal σήματα ( φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



Σχήμα 5-14α



Σχήμα 5-14β



Σχήμα 5-14γ


Σχήμα 5-14: Bispectrum φυσιολογικής κατάστασης, α) OP1, β) OP2, γ) OP3

Όπως φαίνεται στο σχήμα 5-14 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :


- Οβαλοειδές σχήμα
- Πολύ ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.

Πιο συγκεκριμένα η αποχρώση που εμφανίζεται στα bispectrum φυσιολογικής λειτουργίας είναι μόνο το 255, με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια). Η ομοιότητα με τα Bispectrum φυσιολογικής κατάστασης παροχής  $Q1=4.1\text{m}^3/\text{hr}$  είναι φανερή (βλ. Σχήμα 5-7).

Αντίστοιχα παρατηρείται ότι τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία (σπηλαίωση) εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση γύρω από την περιοχή των 9000 Hz όπως φαίνεται στο σχήμα 5-15:




Σχήμα 5-15α




Σχήμα 5-15β

Σχήμα 15 α) Μέγιστη φασματική κύρτωση 9375 Hz, β) Μέγιστη φασματική κύρτωση 8750 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-16 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα abnormal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-16α




Σχήμα 5-16β



Σχήμα 5-16γ



Σχήμα 5-16δ





Σχήμα 5-16ε

Σχήμα 5-16: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας, α) OP4, β) OP5, γ) OP6, δ) OP7, ε) OP8



Στο σχήμα 5-17 φαίνονται τα bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



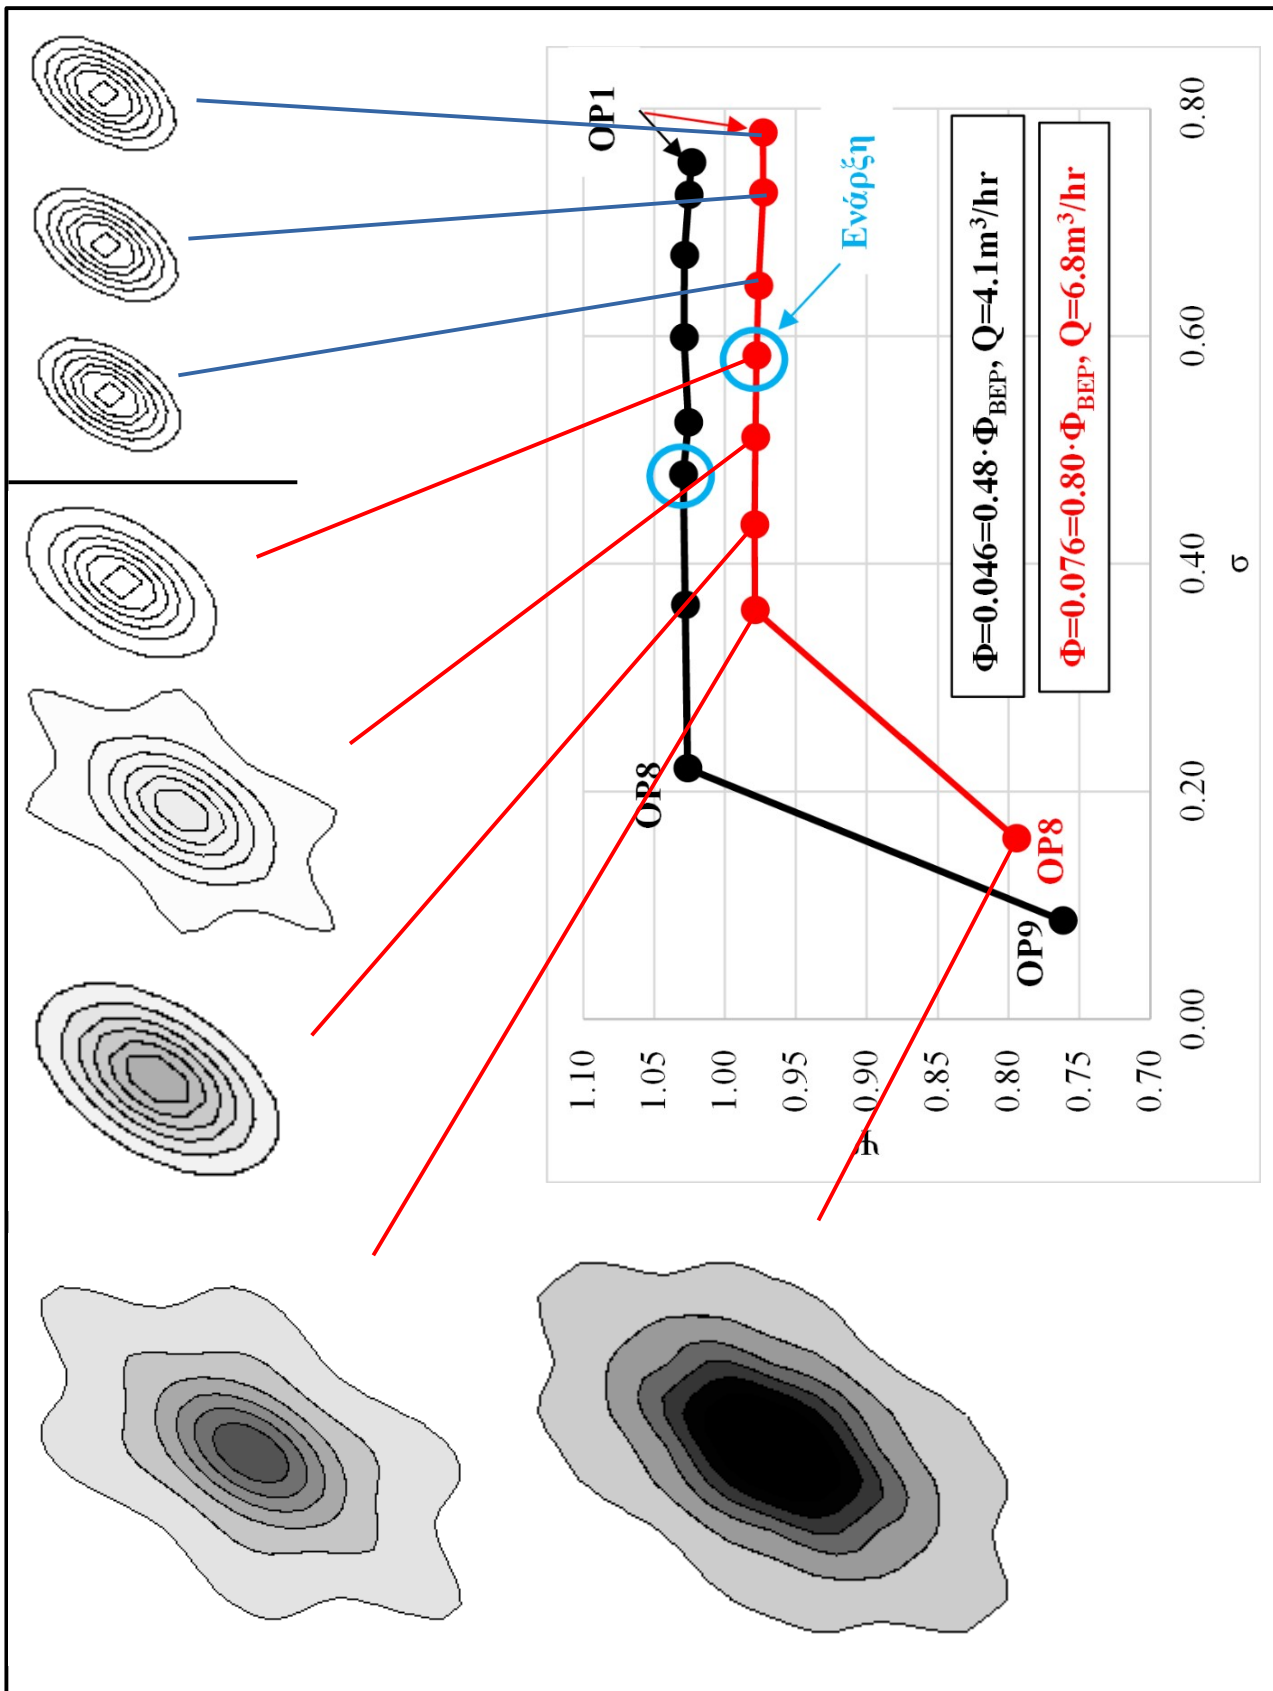
Σχήμα 5-17: Bispectrum μη φυσιολογικής κατάστασης, α) OP4, β) OP4, γ) OP6, δ) OP7, ε) OP8

Όπως φαίνεται στο σχήμα 5-17 τα bispectrum μη φυσιολογικής λειτουργίας έχουν τα εξής χαρακτηριστικά :

- Ξεκινάνε από γωνιώδη οβαλοειδή μορφή, μετά αποκτούν μορφή εξαγωνικού αστέρα και καταλήγουν σε πολυγωνικά σχήματα.
- Εμφανίζουν πιο σκούρες αποχρώσεις του γκρι, συγκριτικά με τα normal bispectrum, που φτάνουν ως το μαύρο, γεγονός που υποδηλώνει υψηλή ενέργεια.

Παρατηρείται ότι το bispectrum του σημείου λειτουργίας 6, ενώ σχηματικά μοιάζει με τα bispectrum φυσιολογικής λειτουργίας, διαφέρει από αυτά ως προς το πλάτος αλλά και ως προς το ύψος (ενέργεια), όπως φαίνεται στον χρωματισμό του.

Στο σχήμα 5-18 που ακολουθεί φαίνονται συνοπτικά τα σημεία λειτουργίας και τα αντίστοιχα bispectrum υπο κλίμακα για παροχή  $Q_2=6.8m^3/hr$ .



Σχήμα 5-18: Bispectrum (υπό κλιμακα) σημείων λειτουργίας (OP) για  $Q_2 = 6.8 \text{ m}^3/\text{hr}$

## **Βήμα 2:** Διαχωρισμός εικόνων σε ομάδες εκπαίδευσης και δοκιμών (*trainAndPredict.m*)

Η εκπαίδευση θα γίνει ταυτόχρονα και στις 2 σειρές μετρήσεων, με σκοπό την πρόβλεψη κατάστασης ανεξαρτήτου παροχής. Πριν αρχίσουμε την εκπαίδευση του ταξινομητή χωρίζουμε τα σήματα σε ομάδες εκπαίδευσης (*train* – ιστορικά δεδομένα εκπαίδευσης) και ομάδες δοκιμών (*test* – δεδομένα ελέγχου). Τα σήματα εκπαίδευσης αποτελούν το 65% των σημάτων. Μετά τον διαχωρισμό καταλήγουμε σε:

- 6 bispectrum φυσιολογικής λειτουργίας για εκπαίδευση και 2 για έλεγχο (8 σύνολο)
- 6 bispectrum μη φυσιολογικής λειτουργίας για εκπαίδευση και 3 για έλεγχο (9 σύνολο)

Σημειώνεται ότι καθορίζεται με τυχαίο τρόπο ποια σήματα θα είναι εκπαίδευσης και ποια δοκιμής.

## **Βήμα 3:** Εξαγωγή SURF χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Στο επόμενο βήμα εξάγονται τα SURF features όπως περιγράφονται στην μεθοδολογία στο κεφάλαιο X.

Πρώτα βρίσκονται όλα τα SURF διανύσματα που περιγράφουν τα bispectrum. Για όλα τα bispectrum φυσιολογικής κατάστασης εξάγονται συνολικά 240 με 270 διανύσματα περιγραφής, ενώ για τα bispectrum μη φυσιολογικής κατάστασης εξάγονται συνολικά 250 με 600 διανύσματα περιγραφής. Αυτό αποδίδεται στην πιο σύνθετη μορφή των abnormal bispectrums.

Στη συνέχεια επιλέγεται ο αριθμός των κέντρων-κλάσσεων, που θα καταταχθούν τα normal SURF διανύσματα και τα abnormal SURF διανύσματα. Όπως και στην περίπτωση του Σετ 1 και του Σετ 2 των σημάτων για τα ρουλεμάν, επιλέγουμε 50 κέντρα για κάθε κατηγορία (100 συνολικά). Αφού βρεθούν τα κέντρα, κατατάσσουμε τα SURF διανύσματα κάθε bispectrum σε normal κέντρο ή abnormal κέντρο και υπολογίζεται τελικά το SURF feature κάθε bispectrum ως:

$$[\sum (SURFvector = normal)] - [\sum (SURFvector = abnormal)]$$

## **Βήμα 4:** Εξαγωγή Gray Scale χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Όπως φαίνεται και στα σχήματα 5-7 και 5-14, τα bispectrum φυσιολογικής κατάστασης έχουν χαμηλή ενέργεια και αντίστοιχα απουσία σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα normal bispectrum είναι περίπου 800.

Αντίστοιχα όπως φαίνεται στα σχήματα 5-10 και 5-17, τα bispectrum μη φυσιολογικής κατάστασης έχουν υψηλή ενέργεια και αντίστοιχα εμφάνιση σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα abnormal bispectrum με σπηλαίωση είναι περίπου 3500.

## **Βήμα 5:** Εξαγωγή χαρακτηριστικού καμπυλότητας (*trainAndPredict.m*)

Κατά την εξαγωγή της καμπυλότητας, αναμένουμε για τα φυσιολογικά bispectrum τιμές circularity πιο κοντά στην μονάδα, σε σχέση με τα bispectrum μη φυσιολογικής λειτουργίας. Πράγματι η σχέση  $circularity = \frac{4 \cdot A \cdot \pi}{P^2}$  δίνει για τα normal bispectrum κατά μέσο όρο 0.95 και για τα

abnormal δίνει τιμές γύρω στο 0.83. Αυτό συμβαίνει γιατί τα οβαλοειδή bispectrum που προκύπτουν για τα σήματα φυσιολογικής κατάστασης είναι πιο “κυκλικά”, από τα αντίστοιχα πολυγωνικά και αστεροειδή bispectrum των σημάτων μη φυσιολογικής κατάστασης.


### **Βήμα 6:** Αξιολόγηση αλγορίθμου ταξινόμησης (*trainAndPredict.m*)

Αφού εξαχθούν τα 3 χαρακτηριστικά (features) για κάθε bispectrum, τροφοδοτούνται στη μηχανή διανυσματικής υποστήριξης (SVM) και πραγματοποιείται η εκπαίδευση με την συνάρτηση *svmtrain* της βιβλιοθήκης *libsvm*. Στη συνάρτηση *svmtrain* ορίζουμε γραμμικό πυρήνα ('-t 0'). Στη συνέχεια εξάγουμε τα χαρακτηριστικά από τα bispectrum που ανήκουν στην ομάδα δοκιμών και με τη βοήθεια της συναρτησης *svmpredict*, πραγματοποιείται πρόβλεψη, κατατάσσοντας τα σε *normal* ή *abnormal*. Τέλος πραγματοποιείται έλεγχος της απόδοσης του μοντέλου υπολογίζοντας την απόλυτη και την μέση ακρίβεια. Προς αποφυγή εξαγωγής λανθασμένων συμπερασμάτων, ο κώδικας *trainAndPredict.m* ‘έτρεξε’ 300 φορές, διαλέγοντας με τυχαίο τρόπο κάθε φορά, διαφορετικά bispectrum για την ομάδα εκπαίδευσης και την ομάδα δοκιμών.

Μετά από 300 διαφορετικές εκπαιδεύσεις η απόλυτη ακρίβεια προέκυψε ίση με 95.73% . Η απόλυτη ακρίβεια προκύπτει από την σχέση:

$$totalAccuracy = \frac{totalCorrectPredictions}{totalTrainSample}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος Z-19 από τις 300 επαναλήψεις, το μοντέλο είχε ακρίβεια 80% 64 φορές, και 100% 234 φορές.




Σχήμα Z-19: Ιστόγραμμα απόλυτης ακρίβειας SVM

Αντίστοιχα μετά από 300 εκπαιδεύσεις η μέση ακρίβεια προέκυψε ίση με 96.28% . Η μέση ακρίβεια προκύπτει από την σχέση:


$$meanAccuracy = \frac{\frac{totalNORMcorrect}{totalNORMtrain} + \frac{totalFAILcorrect}{totalFAILtrain}}{2}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος 5-20 από τις 300 επαναλήψεις, το μοντέλο είχε ακρίβεια 75% 6 φορές, 83.3% 58 φορές και 100% 234 φορές.




Σχήμα Z-20: Ιστόγραμμα μέσης ακρίβειας SVM


Στο σχήμα 5-21 ακολουθεί οπτικοποίηση της πρόβλεψης του μοντέλου. Με κόκκινους κύκλους συμβολίζουμε τα abnormal bispectrum ομάδας εκπαίδευσης και με μπλε κύκλους τα normal bispectrum ομάδας εκπαίδευσης. Με κόκκινο X συμβολίζουμε τα abnormal bispectrum ομάδας δοκιμών και με μπλε αστέρι τα normal bispectrum ομάδας δοκιμών. Το μπλε επίπεδο είναι το όριο απόφασης που προκύπτει από την εκπαίδευση του SVM.



Σχήμα 5-21α



Σχήμα 5-21β



Σχήμα 5-21γ

Στο Σχήμα 5-21α η μέση ακρίβεια είναι 100% (5/5) και κάθε παρατήρηση έχει ταξινομηθεί σωστά . Στο σχήμα 5-21β η μέση ακρίβεια είναι 83.3% (4/5) και όπως παρατηρείται, ένα bispectrum μη φυσιολογικής κατάστασης έχει ταξινομηθεί σαν normal. Στο σχήμα 5-21γ η μέση ακρίβεια είναι 100% (5/5).

Ένα σημαντικό συμπέρασμα που προκύπτει από τα σχήματα 5-21α και 5-21β είναι ότι η πρόβλεψη εξαρτάται σημαντικά από την επιλογή των bispectrum που κατατάσσονται στην ομάδα εκπαίδευσης. Έτσι η μηχανή διανυσματική υποστήριξης (SVM), κάποιες φορές κατατάσσει το σήμα 13 σαν abnormal (σωστή πρόβλεψη) και κάποιες φορές σαν normal (λάθος πρόβλεψη). Αξίζει να σημειωθεί ότι το σήμα 13 αντιστοιχεί στο σημείο λειτουργίας 4 για την παροχή  $Q_2=6.8\text{m}^3/\text{hr}$ , στο σημείο δηλαδή που οριακά έχει ξεκινήσει να εμφανίζεται η σπηλαίωση, και το bispectrum αυτού μοιάζει αρκετά με τα bispectrum των σημάτων φυσιολογικής λειτουργίας (βλ. Σχήματα 14, 17α , 18). Ενδέχεται, επίσης, αυτό να οφείλεται στην τυχαία αρχικοποίηση των κέντρων SURF, διότι κατά την εκτέλεση του kmeans, μπορούν να προκύψουν τελικά κέντρα, normal και abnormal, που είναι πολύ κοντά μεταξύ τους, με συνέπεια η πλειοψηφία των SURF διανυσμάτων ορισμένων bispectrum να μην μπορούν να καταταχθούν και η εικόνα να γίνεται οριακά misclassify.

Από την παραπάνω ανάλυση προκύπτει ότι ακόμα και με λίγες εικόνες (17 bispectrum συνολικά, ενώ προτείνεται 1000 εικόνες ανά κλάση), μπορούν να προβλεφθούν σωστά πάνω από 9 από τα 10 σήματα. Αυτό συμβαίνει διότι τα bispectrum είναι αρκετά διακριτά μεταξύ normal (φυσιολογικής λειτουργίας) και abnormal (μη φυσιολογικής λειτουργίας). Παρ' όλα αυτά, ένα μεγαλύτερο δείγμα σημάτων και κατ' επέκταση bispectrum, θα καθιστούσε τη μηχανή διανυσματικής υποστήριξης πιο εύρωστη και θα είχε μεγαλύτερη συνέπεια ως προς την πρόβλεψη αμφίβολων εικόνων-bispectrum, όπως αυτό που αντιστοιχεί στο σήμα 13 (OP4,  $Q_2=6.8\text{m}^3/\text{hr}$ ).


### 5.3 Πειραματική διάταξη Εθνικού Μετσόβιου Πολυτεχνείου

Η πειραματική διάταξη στο ΕΜΠ φαίνεται στο σχήμα 5-22α μαζί με την αντλία, τις βαλβίδες, τους αισθητήρες για τις μετρήσεις υδραυλικών μεγεθών και τους αισθητήρες για τις μετρήσεις των κραδασμών. Η μηχανή που εγκαταστάθηκε στο ΕΜΠ ήταν μια αντλία του εμπορίου, η οποία αρχικά είχε κέλυφος πτερωτής και περίβλημα από μεταλλικό αδιαφανές υλικό. Ως αποτέλεσμα, δεν ήταν δυνατό να επιβεβαιωθεί η ύπαρξη ατμοποιημένων φυσαλίδων μέσα στην αντλία. Για να ξεπεραστεί αυτό το πρόβλημα τοποθετήθηκε ένα παράθυρο Plexiglas στο περίβλημα της μηχανής όπως παρουσιάζεται στο Σχήμα 5-22β, ενώ σχεδιάστηκε και μια νέα πτερωτή πέντε λεπίδων με κέλυφος από Plexiglas που παρουσιάζεται στο Σχήμα 5-22γ. Τα γεωμετρικά χαρακτηριστικά της προπέλας φαίνονται στον πίνακα 5.




Σχήμα 5-22α

Σχήμα 5-22 α) Εργαστηριακή εγκατάσταση i) αντλία, ii) μετρητής πίεσης αναρρόφησης, iii) μετρητής πίεσης κατάθλιψης, iv) μετρητής ροής, v) βαλβίδα κατάθλιψης, vi) βαλβίδα αναρρόφησης, β) πτερωτή με κέλυφος Plexiglass, γ) παράθυρο Plexiglass στο κέλυφος της αντλίας και οι θέσεις των επιταχυνσιόμετρων, i) B01\_2 και ii) B01\_1



Σχήμα 5-22β



Σχήμα 5-22γ



Αριθμός λεπίδων	$b_1$ [mm]	$b_2$ [mm]	$s_2$ [mm]	$R_1$ [mm]	$R_2$ [mm]	$\omega$ [rpm]	$T$ [°C]
5	7.3	5	5.5	25.8	88.5	2900	21.9

Πίνακας 5: Γεωμετρικά χαρακτηριστικά πτερωτής (EMΠ)

Ένας περιορισμός που εμφανίστηκε κατά τη διάρκεια της κατασκευής ήταν η αδυναμία επέκτασης του παράθυρου Plexiglas του περιβλήματος μέχρι το σημείο, όπου το μπροστινό άκρο (leading edge - LE) της περιστρεφόμενης λεπίδας να είναι ορατή. Ως αποτέλεσμα, σε αυτήν την κατασκευή δεν είναι δυνατό να απεικονιστεί η έναρξη του φαινομένου, αλλά μόνο η παρουσία του όταν η περιοχή σπηλαίωσης επεκταθεί στο μεσαίο τμήμα (midspan) της λεπίδας. Τόσο το μπροστινό άκρο (leading edge - LE) όσο και η μεσαία περιοχή (midspan) φαίνονται στο Σχήμα 5-22β. Ωστόσο, η τρέχουσα εγκατάσταση ικανοποίησε τον σκοπό του πειράματος, που ήταν να επιβεβαιώσει την παρουσία σπηλαίωσης σε σημεία λειτουργίας (OP) με χαμηλή τιμή  $\sigma$  και η σύγκριση των σήματων των δονήσεων με εκείνα στα OP χωρίς σχηματισμό διφασικής ροής. Η κάμερα που χρησιμοποιείται είναι TSI Powerview Plus TM 4MP με φακό Nikon 50mm και φωτογραφία της ροής υπό συνθήκες μη σπηλαίωσης από το εσωτερικό της πτερωτής φαίνεται στο Σχήμα 5-23. Οι συνολικές σχετικές αβεβαιότητες όλων των υδραυλικών ποσοτήτων που μετρήθηκαν και υπολογίστηκαν δίδονται στον Πίνακα 6.

Μετρούμενες Μεταβλητές					Υπολογισμένες μεταβλητές					
$X$	$Q$	$P_{st\ Suct}$	$P_{st\ Dis}$	$T$	$\omega$	$\Phi$	$\Psi$	$\sigma$	$H_{tot}$	$NPSH$
+fx%	1.4	0.25	0.14	0.22	0.05	1.4	0.6	0.67	0.6	0.3

Πίνακας 6: Συνολικές σχετικές αβεβαιότητες όλων των υδραυλικών μετρούμενων και υπολογισμένων ποσοτήτων

Δυο πιεζοηλεκτρικά επιταχυνσιόμετρα χρησιμοποιήθηκαν για την μέτρηση των μηχανολογικών δονήσεων στην αντλία. Οι αισθητήρες τοποθετήθηκαν στο περίβλημα (B01\_2) και στο ρουλεμάν (B01\_1) της αντλία, στις θέσεις που παρουσιάζονται στο Σχήμα 5-22γ. Το αναλογικό σήμα και των δύο επιταχυνσιόμετρων ψηφιοποιείται από μια συσκευή NI USB-9233 DAQ που ενσωματώνει ένα φίλτρο διέλευσης συχνότητας χαμηλής, που η συχνότητα αποκοπής ορίζεται αυτόματα ως η μισή τιμή της συχνότητας δειγματοληψίας. Τα χαρακτηριστικά των επιταχυνσιόμετρων φαίνονται στον Πίνακα 7.



Σχήμα 5-23: Σημείο λειτουργίας χωρίς σπηλαίωση

Sensor	$f_s$ [KHz]	$f_{cutoff}$ [KHz]	$t_{acq}$ [sec]	$[f_{min}-f_{max}]$ [Hz]
B01_1	25	12.5	30	0.2-15000
A01	25	12.5	30	0.2-15000

Πίνακας 7: Τεχνικά χαρακτηριστικά αισθητήρων στην εγκατάσταση του EMΠ

Τέλος, οι μηχανικές συχνότητες που σχετίζονται με τη συχνότητα περιστροφής, τη συχνότητα διέλευσης λεπίδων (BPF), τον κινητήρα και τα ρουλεμάν που βρίσκονται στον άξονα της αντλίας (6206) και στον άξονα του κινητήρα (6308) φαίνονται στον Πίνακα 8.

RF	BPF	TPBF	MF	BPI	BPO	FT	BS
48.3	242	-	50	263/238	172/149	24/19	117/99

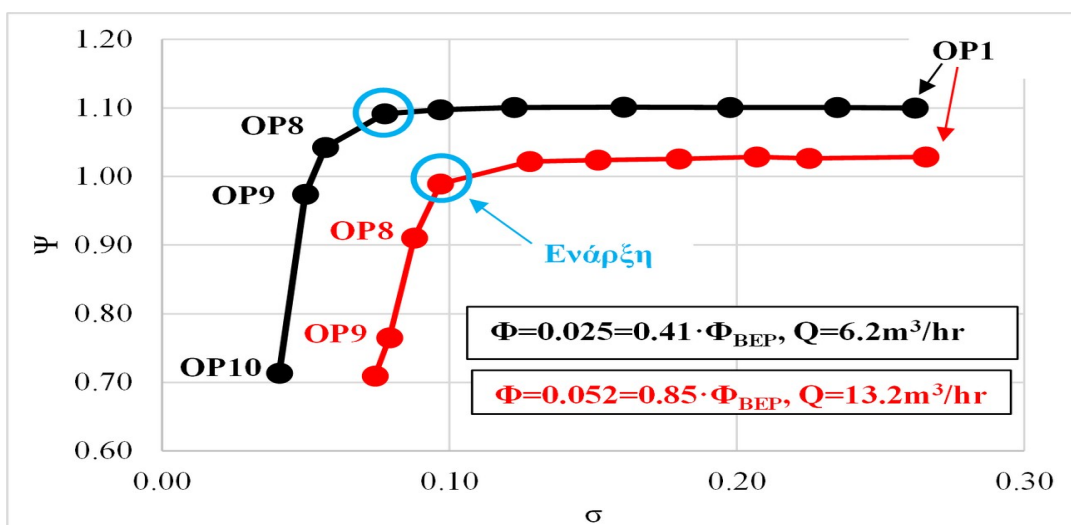
Πίνακας 8: Συχνότητες από το σύστημα αντλία-κινητήρα από την εγκατάσταση στο Εθνικό Μετσόβιο Πολυτεχνείο

### Επεξεργασία μετρήσεων και εκπαίδευση SVM (εγκατάσταση ΕΜΠ)

Από την εγκατάσταση στο πανεπιστήμιο του ΕΜΠ θα επεξεργαστούμε 2 σειρές μετρήσεων για 2 διαφορετικές παροχές  $Q_1=6.2\text{m}^3/\text{hr}$  και  $Q_2=13.2\text{m}^3/\text{hr}$ . Από την παροχή έχουμε 9 μετρήσεις και από την δεύτερη 8.

#### Βήμα 1: Επεξεργασία σημάτων και εξαγωγή bispectrum (*extractBispectrums.m*)


Από τις 10 μετρήσεις που αντιστοιχούν στην παροχή  $Q_1=6.2\text{m}^3/\text{hr}$ , τα 6 σήματα αντιστοιχούν σε φυσιολογική λειτουργία και τα 4 αντιστοιχούν σε λειτουργία με σπηλαίωση. Από τις 10 μετρήσεις που αντιστοιχούν στην παροχή  $Q_1=13.2\text{m}^3/\text{hr}$ , τα 6 σήματα αντιστοιχούν σε φυσιολογική λειτουργία και τα 4 αντιστοιχούν σε λειτουργία με σπηλαίωση. Κάθε σήμα αντιστοιχεί σε ένα διαφορετικό σημείο λειτουργίας (Operating Point), όπως φαίνεται στο σχήμα 5-24:




Σχήμα 5-24: Χαρακτηριστικές καμπύλες  $\sigma$ - $\Psi$  σπηλαίωσης για διαφορετικές τιμές  $\Phi$

Όπως φαίνεται στο σχήμα 5-24, πτώση στην τιμή  $\sigma$  συντελεί και μείωση στην τιμή  $\Psi$ . Τα σημειωμένα σημεία λειτουργίας αντιστοιχούν στην *έναρξη* της σπηλαίωσης, όπου παρατηρούνται οι πρώτες φυσαλίδες. Για τιμές  $\sigma$  μικρότερες της  $\sigma$ (έναρξης) έχουμε σπηλαίωση.

Ελεξεργάζοντας τα σήματα για την παροχή  $Q1=6.2m^3/hr$  παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση κατά μέσο όρο μεταξύ 6000 – 7000 Hz όπως φαίνεται στο σχήμα 5-25:




Σχήμα 5-25α




Σχήμα 5-25β

Σχήμα 5-25 α) Μέγιστη φασματική κύρτωση 7031 Hz, β) Μέγιστη φασματική κύρτωση 6041 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-26 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα postal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-26α




Σχήμα 5-26β




Σχήμα 5-26γ



Σχήμα 5-26δ




Σχήμα 5-26ε




Σχήμα 5-26στ

Σχήμα 5-26: Συχνοτικό φάσμα αποδιαμορφωμένων σημάτων φυσιολογικής λειτουργίας, α) OP1, β) OP2, γ) OP3, δ) OP4, ε) OP5, στ) OP6


Στο σχήμα 5-27 φαίνονται τα bispectrum εξαγόμενα από τα normal σήματα (φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 5-27α




Σχήμα 5-27β




Σχήμα 5-27γ



Σχήμα 5-27δ



Σχήμα 5-27ε



Σχήμα 5-27στ


Σχήμα 5-27 α) bispectrum OP1, β) bispectrum OP2, γ) bispectrum OP3, δ) bispectrum OP4, ε) bispectrum OP5, στ) bispectrum OP6

Όπως φαίνεται στο σχήμα 5-27 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :


- Οβαλοειδές σχήμα, εκτός από το αστεροειδές bispectrum του OP1
- Ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.

Πιο συγκεκριμένα οι αποχρώσεις που εμφανίζονται στα bispectrum φυσιολογικής λειτουργίας είναι στο εύρος 208-255, με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια).

Αντίστοιχα παρατηρείται ότι τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία (σπηλαίωση) εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση γύρω από την περιοχή των 8000 Hz όπως φαίνεται στο σχήμα 5-28:




Σχήμα 5-28α




Σχήμα 5-28β

Σχήμα 5-28 α) Μέγιστη φασματική κύρτωση 7812 Hz, β) Μέγιστη φασματική κύρτωση 8203 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση, αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα Z-29 φαίνονται ενδεικτικά τα φάσματα των συχνοτήτων που προκύπτουν στα abnormal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-29α



Σχήμα 5-29β




Σχήμα 5-29γ




Σχήμα 5-29δ

Σχήμα 9: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας, α) OP7, β) OP8, γ) OP9, δ) OP10


Στο σχήμα 5-30 φαίνονται τα bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.



Σχήμα 5-30α



Σχήμα 5-30β



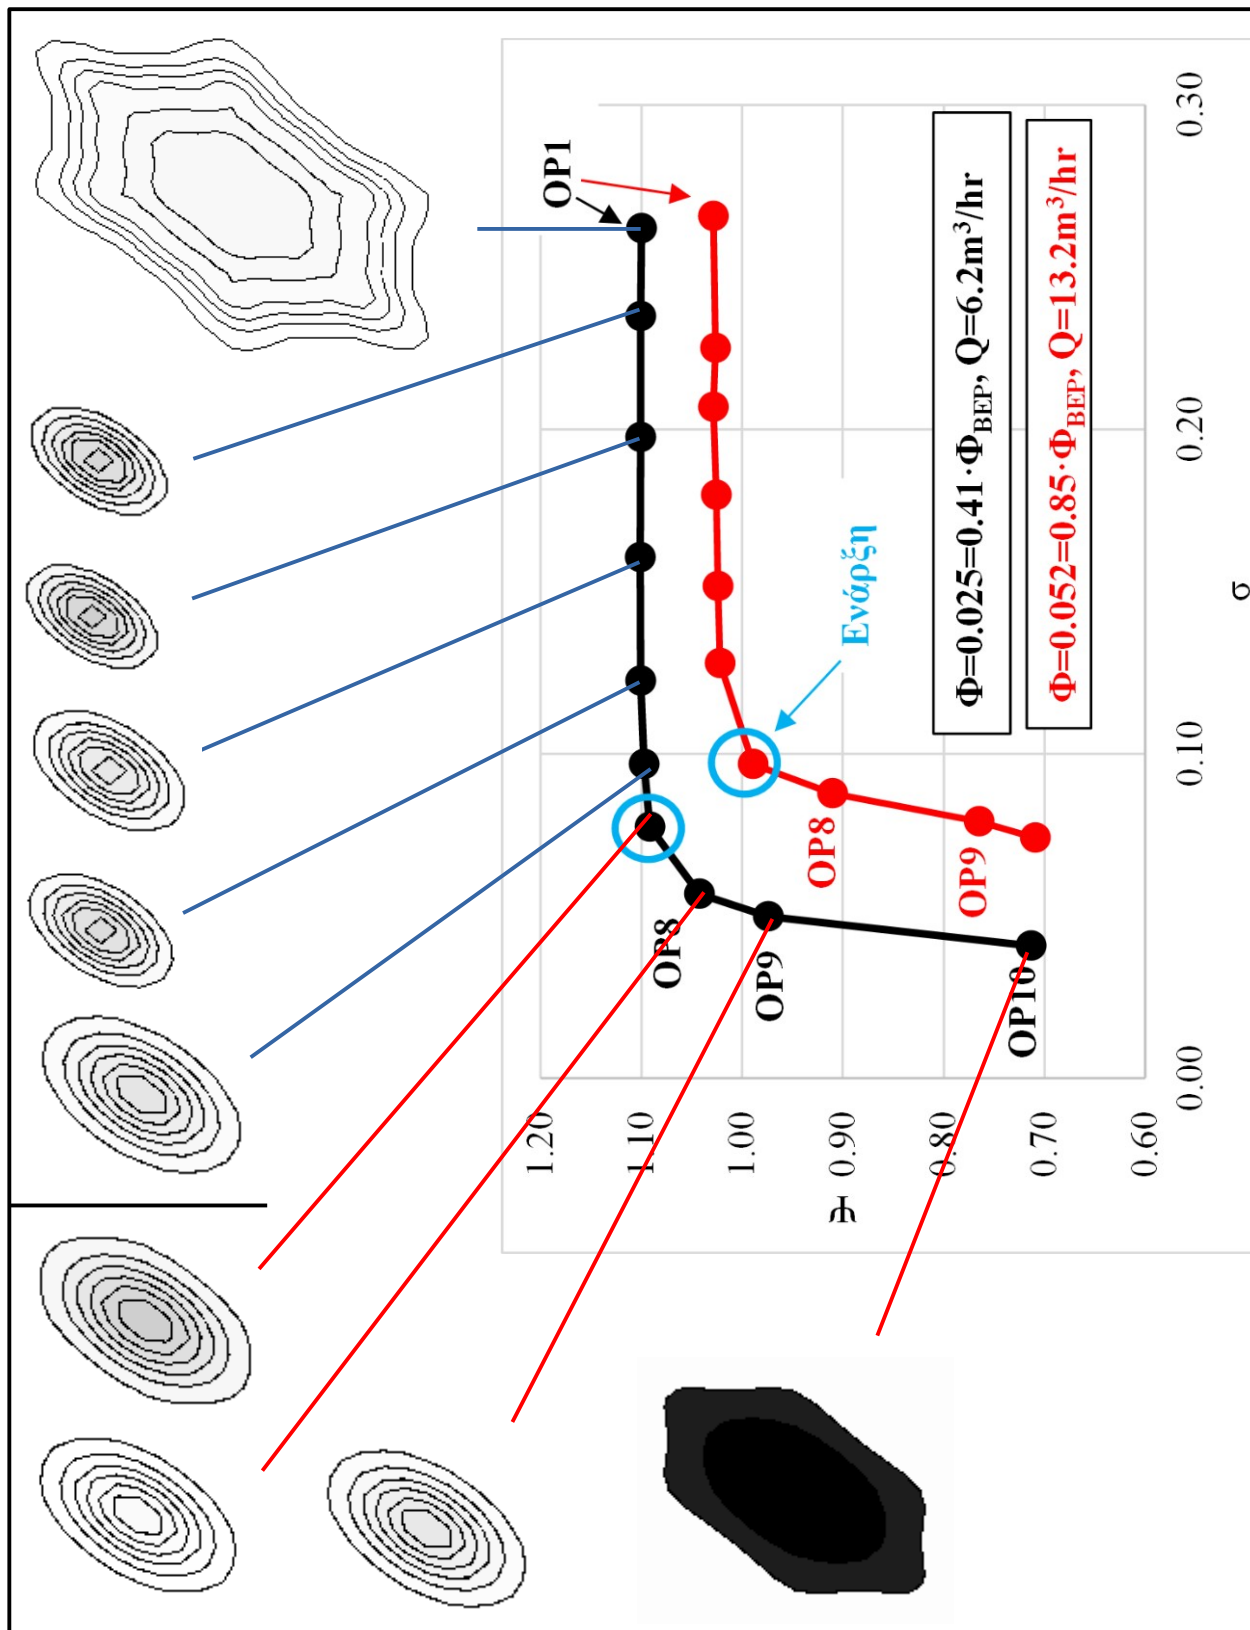
Όπως φαίνεται στο σχήμα 5-30 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :

- Οβαλοειδές σχήμα, εκτός από το εξάπλευρο bispectrum του OP10
- Ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.

Πιο συγκεκριμένα οι αποχρώσεις που εμφανίζονται στα bispectrum φυσιολογικής λειτουργίας είναι στο εύρος 200-255, με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια). Σκούρες αποχρώσεις, και κατα συνέπεια υψηλή ενέργεια, εμφανίζονται μόνο στο τελευταίο σημείο λειτουργίας, όπουη σπηλαίωση είναι πλέον σε προχωρημένο στάδιο.


Στο σχήμα 5-31 που ακολουθεί φαίνονται τα σημεία λειτουργίας και τα αντίστοιχα bispectrum υπο κλίμακα, για παροχή  $Q1=6.2\text{m}^3/\text{hr}$ . Η ομοιότητα των bispectrum φυσιολογική και μη φυσιολογικής κατάστασης μας προϊδεάζουν και αδυναμία του αλγορίθμου σωστής κατάταξης των σημάτων.






Σχήμα 5-31: Bispectrum (υπό κλιμακα) σημείων λειτουργίας (OP) για  $Q_1=6.2\text{m}^3/\text{hr}$

Ελεξεργάζοντας τα σήματα για την παροχή  $Q1=13.2m^3/hr$  παρατηρείται ότι αυτά που αντιστοιχούν σε φυσιολογική λειτουργία εμφανίζουν μέγιστη φασματική κύρτωση κατά μέσο όρο στα 1000 Hz όπως φαίνεται στο σχήμα 5-32:




Σχήμα 5-32α




Σχήμα 5-32β

Σχήμα 5-32 α) Μέγιστη φασματική κύρτωση 1041 Hz, β) Μέγιστη φασματική κύρτωση 1041 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-33 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα *normal* σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-33α




Σχήμα 5-33β




Σχήμα 5-33ε



Σχήμα 5-33δ




Σχήμα 5-33ε




Σχήμα 5-33στ

Σχήμα 5-33: Συχνωτικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας


Στο σχήμα 5-34 φαίνονται τα bispectrum εξαγόμενα από τα normal σήματα ( φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 5-34α




Σχήμα 5-34β




Σχήμα 5-34γ



Σχήμα 5-34δ



Σχήμα 5-34ε



Σχήμα 5-34στ

Σχήμα 5-34: Bispectrum φυσιολογικής κατάστασης, α) OP1, β) OP2, γ) OP3, δ) OP4, ε) OP5, στ) OP6


Όπως φαίνεται στο σχήμα 5-34 τα bispectrum φυσιολογικής λειτουργίας έχουν 2 κύρια χαρακτηριστικά :

- Πολύ ανοιχτές αποχρώσεις του γκρι στα επιμερισμένα επίπεδα, που υποδηλώνουν χαμηλή ενέργεια.
- Αστεροειδές περίγραμμα με μια κορυφή στη μέση και 6 κορυφές γύρω από το κέντρο


Πιο συγκεκριμένα οι αποχρώσεις που εμφανίζονται στα bispectrum φυσιολογικής λειτουργίας είναι στο εύρος 250-255, με την απόχρωση 0 να αντιστοιχεί στο μαύρο (υψηλή ενέργεια) και την απόχρωση 255 να αντιστοιχεί στο λευκό (χαμηλή ενέργεια).

Ιδιαίτερη περίπτωση αποτελεί το σημείο λειτουργίας 6 (OP6, Σχήμα 5-43στ). Το OP6 εμφανίζει χαρακτηριστικά Bispectrum τόσο φυσιολογικής λειτουργίας όσο και μη φυσιολογικής λειτουργίας (βλέπε και σχήμα 5-37: Bispectrum μη φυσιολογικής κατάστασης). Αυτό αποδίδεται στο γεγονός ότι το σημείο λειτουργίας 6 βρίσκεται οριακά πριν την εμφάνιση του φαινομένου της σπηλαίωσης.

Αντίστοιχα παρατηρείται ότι τα σήματα που αντιστοιχούν σε μη-φυσιολογική λειτουργία (σπηλαίωση) εμφανίζουν κατά μέσο όρο μέγιστη φασματική κύρτωση γύρω από την περιοχή των 9500 Hz όπως φαίνεται στο σχήμα 5-35:




Σχήμα 5-35α




Σχήμα 5-35β

Σχήμα 5-35 α) Μέγιστη φασματική κύρτωση 9375 Hz, β) Μέγιστη φασματική κύρτωση 10416 Hz


Αφού εφαρμοστεί η επεξεργασία που περιγράφεται στο κεφάλαιο X, δηλαδή εφαρμογή ζωνοπερατού φίλτρου στην περιοχή μέγιστης φασματικής κύρτωσης, αποδιαμόρφωση και αποθορυβοποίηση, εξάγουμε τα bispectrum. Στο σχήμα 5-36 φαίνονται τα φάσματα των συχνοτήτων που προκύπτουν στα abnormal σήματα μετα την αποδιαμόρφωση.




Σχήμα 5-36α



Σχήμα 5-36β




Σχήμα 5-36γ




Σχήμα 5-36δ

Σχήμα 5-36: Συχνотικό φάσμα αποδιαμορφωμένων σημάτων μη φυσιολογικής λειτουργίας, α) OP7, β) OP8, γ) OP9, δ) OP10


Στο σχήμα 5-37 φαίνονται τα bispectrum εξαγόμενα από τα abnormal σήματα (μη φυσιολογική λειτουργία) μετά την αποδιαμόρφωση.




Σχήμα 5-37α



Σχήμα 5-37β



Σχήμα 5-37γ



Σχήμα 5-37δ

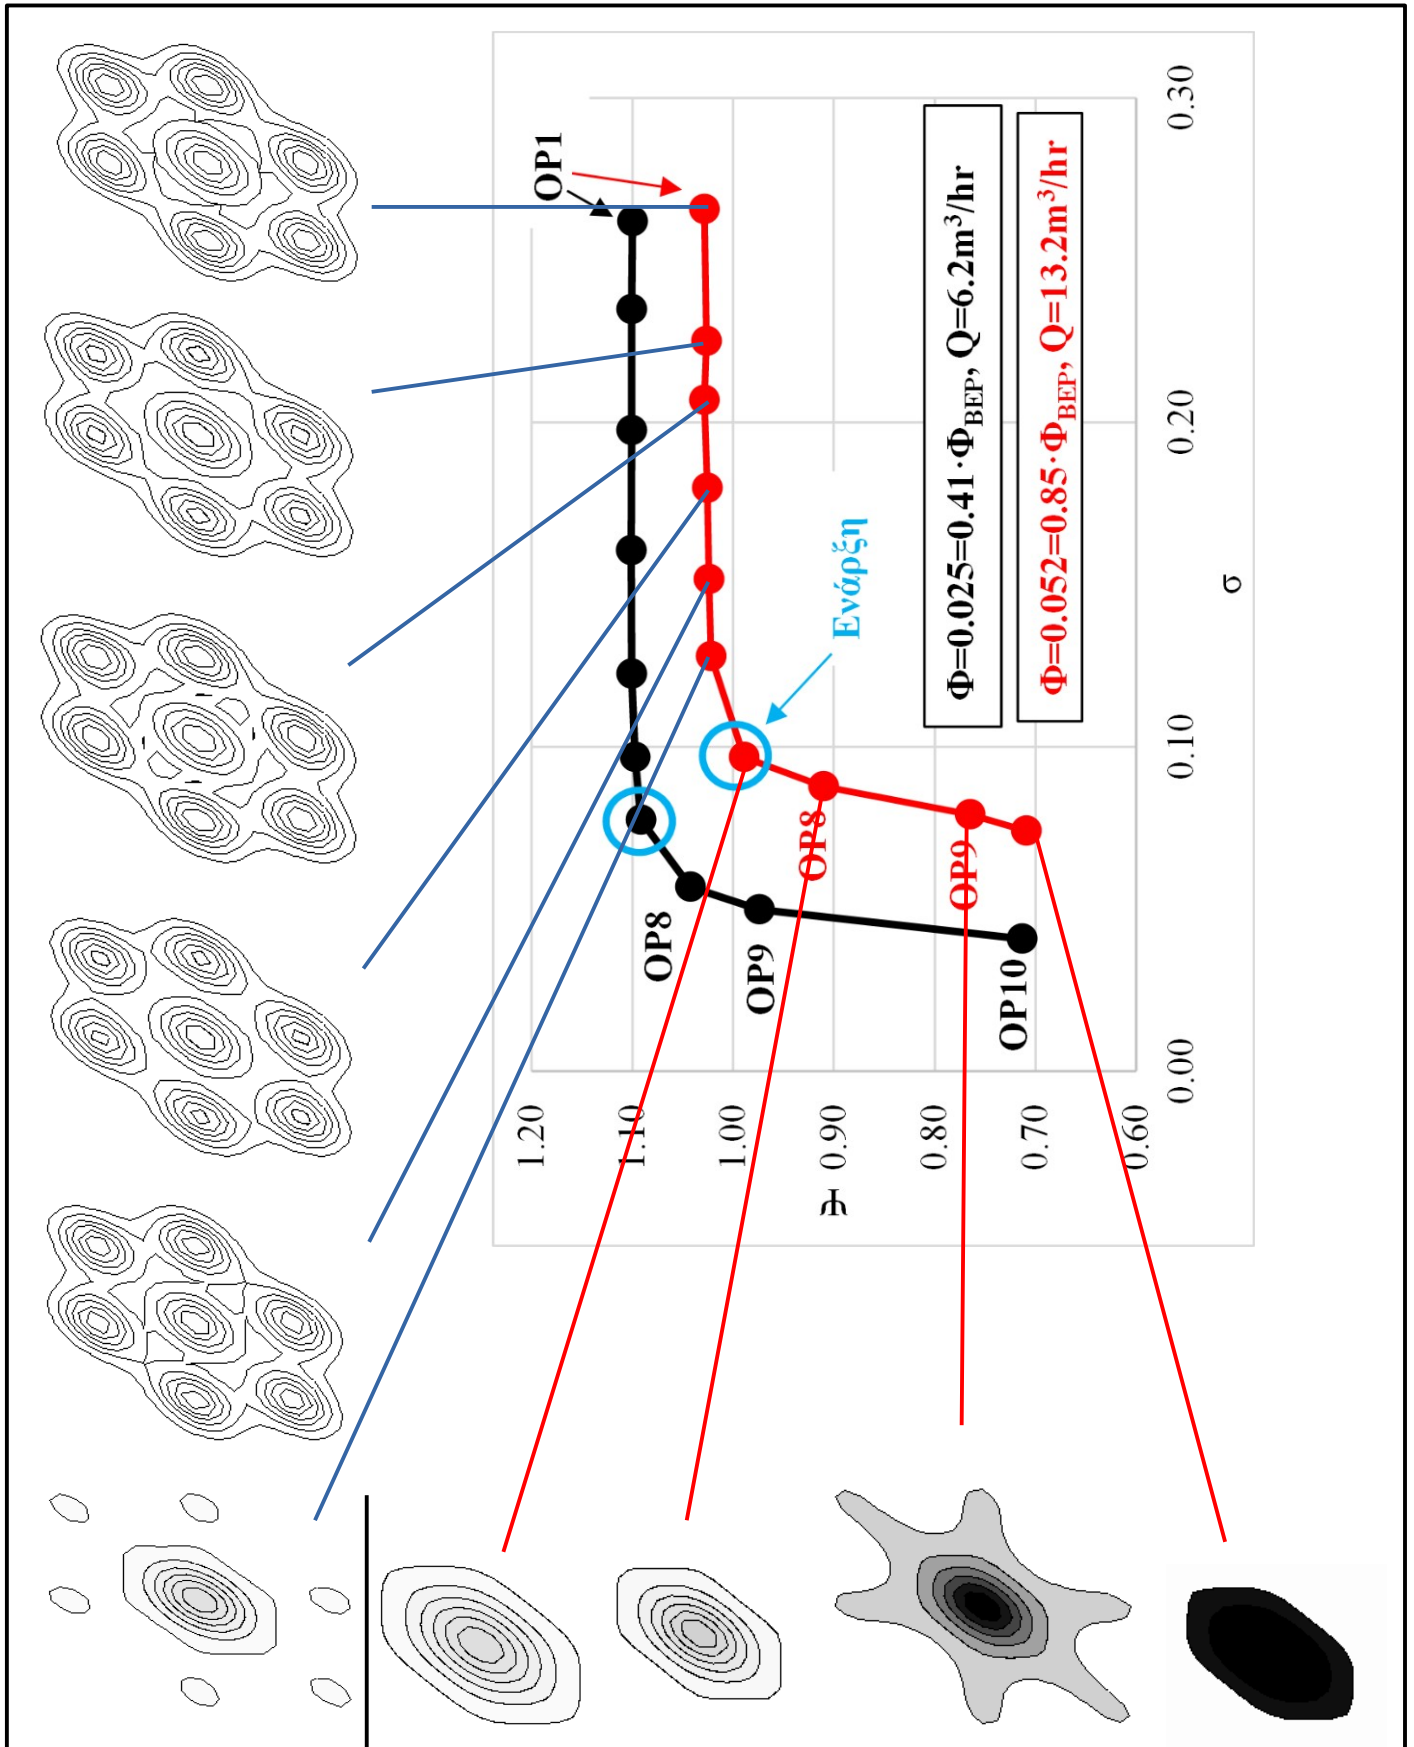
Σχήμα 5-37: Bispectrum μη φυσιολογικής κατάστασης, α) OP7, β) OP8, γ) OP9, δ) OP10

Όπως φαίνεται στο σχήμα 5-37 τα bispectrum μη φυσιολογικής λειτουργίας έχουν τα εξής χαρακτηριστικά :

- Έχουν εξάπλευρο περίγραμμα, με εξαίρεση το bispectrum του OP9, το οποίο είναι αστεροειδές που υποθάλπτει ένα εξάπλευρο.
- Εμφανίζουν πιο σκούρες αποχρώσεις του γκρι, συγκριτικά με τα normal bispectrum, που φτάνουν ως το μαύρο, γεγονός που υποδηλώνει υψηλή ενέργεια.

Παρατηρείται ότι τα bispectrum μη φυσιολογικής λειτουργίας, σε αντίθεση με τα bispectrum που προκύπτουν από τα σήματα για την παροχή  $Q_1=6.2\text{m}^3/\text{hr}$ , διαφέρουν σημαντικά από τα αντίστοιχα φυσιολογικής λειτουργίας.

Στο σχήμα 5-38 που ακολουθεί φαίνονται συνοπτικά τα σημεία λειτουργίας και τα αντίστοιχα bispectrum υπο κλίμακα για παροχή  $Q_2=13.2\text{m}^3/\text{hr}$





## **Βήμα 2:** Διαχωρισμός εικόνων σε ομάδες εκπαίδευσης και δοκιμών (*trainAndPredict.m*)

Η εκπαίδευση θα γίνει ταυτόχρονα και στις 2 σειρές μετρήσεων, με σκοπό την πρόβλεψη κατάστασης ανεξαρτήτου παροχής. Πριν αρχίσουμε την εκπαίδευση του ταξινομητή χωρίζουμε τα σήματα σε ομάδες εκπαίδευσης (*train* – ιστορικά δεδομένα εκπαίδευσης) και ομάδες δοκιμών (*test* – δεδομένα ελέγχου). Τα σήματα εκπαίδευσης αποτελούν το 65% των σημάτων. Μετά τον διαχωρισμό καταλήγουμε σε:

- 8 bispectrum φυσιολογικής λειτουργίας για εκπαίδευση και 4 για έλεγχο (12 σύνολο)
- 6 bispectrum μη φυσιολογικής λειτουργίας για εκπαίδευση και 2 για έλεγχο (8 σύνολο)

Σημειώνεται ότι καθορίζεται με τυχαίο τρόπο ποια σήματα θα είναι εκπαίδευσης και ποια δοκιμής.

## **Βήμα 3:** Εξαγωγή SURF χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Στο επόμενο βήμα εξάγονται τα SURF features όπως περιγράφονται στην μεθοδολογία στο κεφάλαιο X.

Πρώτα βρίσκονται όλα τα SURF διανύσματα που περιγράφουν τα bispectrum. Για όλα τα bispectrum φυσιολογικής κατάστασης εξάγονται συνολικά 1000 με 1500 διανύσματα περιγραφής, ενώ για τα bispectrum μη φυσιολογικής κατάστασης εξάγονται συνολικά 300 με 350 διανύσματα περιγραφής. Αυτό αποδίδεται στην σύνθετη μορφή των normal bispectrums για την παροχή  $Q2=13.2m^3/hr$ .

Στη συνέχεια επιλέγεται ο αριθμός των κέντρων-κλάσεων, που θα καταταχθούν τα normal SURF διανύσματα και τα abnormal SURF διανύσματα. Όπως και στην περίπτωση του Σετ 1 και του Σετ 2 των σημάτων για τα ρουλεμάν, επιλέγουμε 50 κέντρα για κάθε κατηγορία (100 συνολικά). Αφού βρεθούν τα κέντρα, κατατάσσουμε τα SURF διανύσματα κάθε bispectrum σε normal κέντρο ή abnormal κέντρο και υπολογίζεται τελικά το SURF feature κάθε bispectrum ως:

$$[\sum (SURFvector = normal)] - [\sum (SURFvector = abnormal)]$$

## **Βήμα 4:** Εξαγωγή Gray Scale χαρακτηριστικών (*features*) (*trainAndPredict.m*)

Όπως φαίνεται και στα σχήματα 5-27 και 5-34, τα bispectrum φυσιολογικής κατάστασης έχουν χαμηλή ενέργεια (απουσία σκούρων αποχρώσεων του γκρι) αλλά έντονα μάρια περιγράμματα. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα normal bispectrum είναι περίπου 2300.

Αντίστοιχα όπως φαίνεται στα σχήματα 5-10 και 5-17, τα bispectrum μη φυσιολογικής κατάστασης έχουν υψηλή ενέργεια και αντίστοιχα εμφάνιση σκούρων αποχρώσεων του γκρι. Κατά μέσο όρο ο αριθμός των σκουρόχρωμων pixel στα abnormal bispectrum με σπηλαίωση είναι περίπου 3800.

## **Βήμα 5:** Εξαγωγή χαρακτηριστικού καμπυλότητας (*trainAndPredict.m*)

Κατά την εξαγωγή της καμπυλότητας, αναμένουμε για τα μη φυσιολογικά bispectrum τιμές circularity πιο κοντά στην μονάδα, σε σχέση με τα bispectrum φυσιολογικής λειτουργίας. Πράγματι η

σχέση  $circularity = \frac{4 \cdot A \cdot \pi}{P^2}$  δίνει για τα normal bispectrum κατά μέσο όρο 0.83 και για τα abnormal δίνει τιμές γύρω στο 0.89.

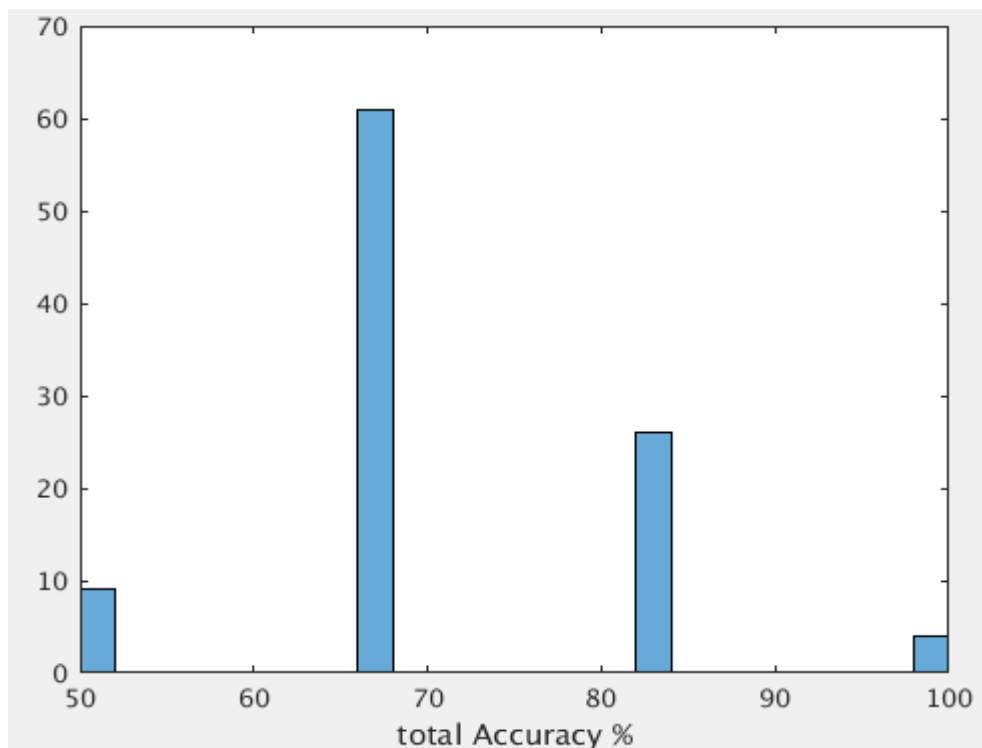
### **Βήμα 6:** Αξιολόγηση αλγορίθμου ταξινόμησης (*trainAndPredict.m*)

Αφού εξαχθούν τα 3 χαρακτηριστικά (features) για κάθε bispectrum, τροφοδοτούνται στη μηχανή διανυσματικής υποστήριξης (SVM) και πραγματοποιείται η εκπαίδευση με την συνάρτηση *svmtrain* της βιβλιοθήκης *libsvm*. Στη συνάρτηση *svmtrain* ορίζουμε γραμμικό πυρήνα ('-t 0'). Στη συνέχεια εξάγουμε τα χαρακτηριστικά από τα bispectrum που ανήκουν στην ομάδα δοκιμών και με τη βοήθεια της συναρτησης *svmpredict*, πραγματοποιείται πρόβλεψη, κατατάσσοντας τα σε normal ή abnormal. Τέλος πραγματοποιείται έλεγχος της απόδοσης του μοντέλου υπολογίζοντας την απόλυτη και την μέση ακρίβεια. Προς αποφυγή εξαγωγής λανθασμένων συμπερασμάτων, ο κώδικας *trainAndPredict.m* 'έτρεξε' 100 φορές, διαλέγοντας με τυχαίο τρόπο κάθε φορά, διαφορετικά bispectrum για την ομάδα εκπαίδευσης και την ομάδα δοκιμών.

Μετά από 300 διαφορετικές εκπαιδεύσεις η απόλυτη ακρίβεια προέκυψε ίση με 70.83% . Η απόλυτη ακρίβεια προκύπτει από την σχέση:

$$totalAccuracy = \frac{totalCorrectPredictions}{totalTrainSample}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος Z-39 από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 50% 9 φορές, 66.67% 61 φορές, 83.3% 26 φορές και 100% 4 φορές.




Σχήμα Z-39: Ιστόγραμμα απόλυτης ακρίβειας SVM

Αντίστοιχα μετά από 100 εκπαιδεύσεις η μέση ακρίβεια προέκυψε ίση με 66.5% . Η μέση ακρίβεια προκύπτει από την σχέση:


$$meanAccuracy = \frac{\frac{totalNORMcorrect}{totalNORMtrain} + \frac{totalFAILcorrect}{totalFAILtrain}}{2}$$

Πιο συγκεκριμένα όπως φαίνεται και στο ιστόγραμμα του σχήματος 5-40 από τις 100 επαναλήψεις, το μοντέλο είχε ακρίβεια 50% 14 φορές, 62.5% 52 φορές, 75% 26 φορές, 87.5% 4 φορές και 100% 4 φορές.




Σχήμα Z-40: Ιστόγραμμα μέσης ακρίβειας SVM

Στο σχήμα 5-41 ακολουθεί οπτικοποίηση της πρόβλεψης του μοντέλου. Με κόκκινους κύκλους συμβολίζουμε τα abnormal bispectrum ομάδας εκπαίδευσης και με μπλε κύκλους τα normal bispectrum ομάδας εκπαίδευσης. Με κόκκινο X συμβολίζουμε τα abnormal bispectrum ομάδας δοκιμών και με μπλε αστέρι τα normal bispectrum ομάδας δοκιμών. Το μπλε επίπεδο είναι το όριο απόφασης που προκύπτει από την εκπαίδευση του SVM.



Σχήμα 5-41α



Σχήμα 5-21β

Στο Σχήμα 5-41α η ακρίβεια είναι 66.7% (4/6) και 2 bispectrum έχουν ταξινομηθεί λάθος. Στο σχήμα 5-21β η ακρίβεια είναι 83.3% (5/6) και ένα bispectrum φυσιολογικής κατάστασης έχει ταξινομηθεί σαν abnormal.

Είναι προφανές ότι ο αλγόριθμος δεν έχει την ίδια απόδοση, όπως στις υπόλοιπες 3 περιπτώσεις (βλάβη σε εσωτερικό δακτύλιο ρουλεμάν, βλάβη σε εξωτερικό δακτύλιο ρουλεμάν και σπηλαίωση – εγκατάσταση Lancaster). Η χαμηλή απόδοση οφείλεται σε 2 κύριους λόγους:

- Τα bispectrum των δύο σειρών σημάτων ( $Q1=6.2\text{m}^3/\text{hr}$  και  $Q2=13.2\text{m}^3/\text{hr}$ ) της φυσιολογικής λειτουργίας είναι ανόμοια μεταξύ τους. Το ίδιο ισχύει και για τα bispectrum μη φυσιολογικής λειτουργίας (βλ. Σχήμα 5-31 και Σχήμα 5-38).
- Τα bispectrum φυσιολογικής και μη φυσιολογικής λειτουργίας για την παροχή  $Q1=6.2\text{m}^3/\text{hr}$  είναι πολύ όμοια μεταξύ τους (βλ. Σχήμα 5-31).

## ΚΕΦΑΛΑΙΟ 6 - ΣΥΜΠΕΡΑΣΜΑΤΑ

Από την ανάλυση που προηγήθηκε, καθίσταται σαφές ότι η αναγνώριση εικόνα με τεχνικές μηχανικής μάθησης είναι μια πολλά υποσχόμενη μέθοδος στη διάγνωση βλαβών. Προς αυτήν την κατεύθυνση, ουσιώδης σημασίας κρίθηκε η χρήση φασματικής ανάλυσης των χρονικών σημάτων για την εύρεση της μέγιστης φασματικής κύρτωσης, η οποία καταδεικνύει συχνοτικές παριοχές στις οποίες δεν θα εστιάζαμε την προσοχή μας απλά με παρατήρηση. Στην περίπτωση μηχανολογική βλάβης, η περιβάουσα που προκύπτει από την αποδιαμόρφωση του φιλτραρισμένου σήματος στην παραπάνω περιοχή εμφανίζει συχνότητες που σχετίζονται με την εκάστοτε βλάβη. Το προκύπτων σήμα επεξεργάζεται με μεθόδους στατιστικής ανάλυσης ανώτερης τάξης, από όπου προκύπτουν οι εικόνες (bispectrum) που θα κληθούμε να επεξεργαστούμε.

Εξάγοντας 3 βασικά χαρακτηριστικά: (i) χαρακτηριστικά από SURF, (ii) χαρακτηριστικά από τις αποχρώσεις στην κλίμακα του γκρι και (iii) χαρακτηριστικά καμπυλότητας των bispectrum, τροφοδοτούμε μια μηχανή διανυσματική υποστήριξης (SVM). Τα διανύσματα SURF ταξινομούνται σε κλάσεις με χρήση K-means και παρατηρήθηκε ότι αυξάνοντας τον αριθμό των κλάσεων, από 30 μέχρι 300, δεν αυξάνεται η ακρίβεια, παρά μόνο καθυστερείται η εκτέλεση του κώδικα. Από την εκπαίδευση του SVM προκύπτει ένα μοντέλο, ικανό να προβλέψει αν ένα bispectrum, που προκύπτει από σήμα μετρήσεων κραδασμών, αντιστοιχεί σε φυσιολογική ή μη φυσιολογική λειτουργία μηχανής.

Όπως προέκυψε από την ανάλυση στην πειραματική διαδικασία, η ικανότητα πρόβλεψη, στην πλειοψηφία των περιπτώσεων, προέκυψε πολύ αξιόπιστη με ποσοστό επιτυχής πρόβλεψης πάνω από 9 στις 10 μετρήσεις. Πιο συγκεκριμένα, στη σειρά μετρήσεων που καταλήγουν σε φθορά στον εσωτερικό δακτύλιο ρουλεμάν, η απόλυτη ακρίβεια είναι 94.46%. Στη σειρά μετρήσεων που καταλήγουν σε φθορά στον εξωτερικό δακτύλιο ρουλεμάν, η απόλυτη ακρίβεια είναι 93.71%. Στη σειρά μετρήσεων από την εγκατάσταση του πανεπιστημίου Lancaster, που καταλήγουν σε σπηλαίωση, η απόλυτη ακρίβεια προέκυψε 95.73%. Στη σειρά μετρήσεων από την εγκατάσταση του ΕΜΠ, που καταλήγουν σε σπηλαίωση, οι εικόνες που προκύπτουν από τα σήματα, αφενός δεν ήταν διαρκείς μεταξύ φυσιολογική και μη φυσιολογικής κατάστασης και αφεαίρου ήταν ανόμοιες για την ίδια κατάσταση διαφορετικής παροχής, με συνέπεια την πτώση της απόλυτης ακρίβειας σε 70.83%.

Η σημαντικότητα της μεθόδου που αναλύσαμε, καθίσταται φανερή και από την ικανότητα της να κάνει σωστή πρόβλεψη ακόμα και με μικρό αριθμό δεδομένων προς εκπαίδευσης. Για τις σειρές σημάτων με βλάβη στα ρουλεμάν χρησιμοποιήθηκαν 40 σήματα και για τις σειρές σημάτων με σπηλαίωση 17-20 σήματα συνολικά.

Προκειμένου να ελεγχθεί σε ακόμα μεγαλύτερο βαθμό η αξιοπιστία της μεθόδου θα χρειαστεί να γίνουν δοκιμές με μεγαλύτερες ομάδες δεδομένων καθώς και δοκιμές σε σήματα από διαφορετικές μηχανές και διαφορετικά ήδη σφαλμάτων / καταστάσεις λειτουργίας.

## ΠΑΡΑΡΤΗΜΑ Α – ΚΩΔΙΚΕΣ MATLAB

### A1 - Κώδικας επεξεργασίας χρονικού σήματος και εξαγωγής bispectrum (*extractBispectrum.m*)

```
clc;clear all;
tic
s=0;
nlevel=5;
fs=25000;
opt1=1;
opt2=1;
deik=1;
for signal= 1:1:40

x=load(sprintf('S1/%i.txt',signal)); % load signals from folder S1
x=x(:,1); %S2->1 S1->5

L=length(x);

[c,Level_w,LNw_stft,I,fi] = Fast_Kurtogram1(x,nlevel,fs,opt1,opt2);

Bw=(fs*2^-(Level_w(I)+1));
f_c=(fs*fi);

FL1=f_c-Bw/2;
FH1=f_c+Bw/2;
order1=2;
W1=2*FL1/fs;
W2=2*FH1/fs;

if (W1<=0 & W2 >= 1-10^(-3))
    ab(deik)=0;
    deik=deik+1;
    [b1,a1]=butter(2*order1, [0.01], 'high');
elseif W1<=0
    ab(deik)=1;
    deik=deik+1;
    [b1,a1]=butter(2*order1, W2 , 'low');
elseif W2 >= 1-10^(-3)
    ab(deik)=2;
    deik=deik+1;
    [b1,a1]=butter(2*order1, W1 , 'high');
else
    ab(deik)=3;
    deik=deik+1;
    [b1,a1]=butter(order1, [W1 W2]);
end

z1=filter(b1,a1,x);

midli=hilbert(z1);
```

```

z1=abs(midli);

lev = 2;
wname = 'sym8';
z1=wden(z1,'sqrtwolog','h','mln',lev,wname);

L=length(z1);
ek=40;
[bisonas,axx]=bispeci(z1,ek,L,20,'biased',2^7,0);

absobisonas=abs(bisonas);
figo=figure('visible','off');
% contourf(axx,axx,absobisonas,6), % olo
contourf(axx(128/4:128*3/4),axx(128/4:128*3/4),absobisonas((128/4:128*3/4),(128/4:128*3/4)),6), % kouti sth mesh

axis off
colormap(flipud(gray(256)));
caxis([0 0.05]); %S21 8*10^(-4)] %S22 1*10^(-5) %bpfi 0.2 %bpfo 0.05 %S41 0.01 %S42 0.05
saveas(figo,sprintf('bsee42/%i',signal),'png');
end
toc

```

## A2 - Κώδικας εξαγωγής χαρακτηριστικών, εκπαίδευσης ταξινομητή SVM και πρόβλεψης

```

clear all; clc;

addpath('libsvm-3.24/matlab');
tic
endCond=1
akrivieies=zeros(endCond,1);
for indexOfAccur=1:endCond
clearvars -except akrivieies indexOfAccur
testVol=0.65;
team1=12; % amount of data that belongs to 1st group (normal)
team2=8; % amount of data that belongs to 2nd group (abnormal)

cls=50; % classes of kmeans

%%%%% SURF parameters %%%%%%
thres=1000;
octaves=3;
lvls=4;
srs=64;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

ntper=ceil(testVol*team1); %normal train percentage
ftper=ceil(testVol*team2); %fail train percentage

for j=1:ntper

```



```

    y(j)=0;
end
for j=(ntper+1):(ntper+ftper)
    y(j)=1;
end
y=y';
for i=1:(team1-ntper)
    yi(i)=0;
end
for i=(team1-ntper+1):(team1-ntper+team2-ftper)
    yi(i)=1;
end
yi=yi';
XtestInd=[];
XtestInd=randperm(team1,team1-ntper);
XtestInd((team1-ntper+1):(team1-ntper+team2-ftper))=randperm(team2,team2-ftper)+team1;
XtestInd=sort(XtestInd);

XN=[];
ac=zeros(1,2);
q=zeros(length(XtestInd),1);
% bwkey='tophat';
%%%%%%%%%%
fpntF=[];
fpntN(1)=0;
deik=2;

for j=1:team1
if (sum(XtestInd==j)== 1 );
    continue
end

eik=imread(sprintf('bsee42/%i.png',j));

eikg=rgb2gray(eik);
regs=detectSURFFeatures(eikg,'MetricThreshold',thres,'NumOctaves',octaves,'NumScaleLevels',lvls);
[feats,validpts]=extractFeatures(eikg,regs,'SURFSize',srs,'Upright',true);

feats3=feats(1:fix(size(feats,1)/1),:);
fpntN(deik)=size(feats3,1)+fpntN(deik-1);
deik=deik+1;
XN=cat(1,XN,feats3);

xrwmata=imhist(eikg);

eikg(eikg>0)=255;
eikg=imcomplement(eikg);
[row,col] = find(eikg);
k = boundary(row,col);
Mask = poly2mask(col(k),row(k),size(eikg,1),size(eikg,2));
eikg=imcomplement(Mask);
xrw=imhist(eikg);
I = bwperim(eikg);
a=I(2:end-1,2:end-1);
boring(1)=xrw(1);

```

```

boring(2)=sum(a(:)==1)*1.07;
boring(3)=(4*boring(1)*pi)/(boring(2)^2);
fito=boring(3);

hogmtrxN(deik-2,1:2)=[sum(xrwmata(1:150)) fito];
end

fpntF=[];
fpntF(1)=0;
deik=2;
XF=[];
for j=team1+1:team1+team2
if (sum(XtestInd==j)== 1);
    continue
end

eik=imread(sprintf('bsee42/%i.png',j));
eikg=rgb2gray(eik);

regs=detectSURFFeatures(eikg,'MetricThreshold',thres,'NumOctaves',octaves,'NumScaleLevels',lvls);

[feats,validpts]=extractFeatures(eikg,regs,'SURFSize',srs,'Upright',true);

feats3=feats(1:fix(size(feats,1)/1),:);

fpntF(deik)=size(feats3,1)+fpntF(deik-1);
deik=deik+1;
XF=cat(1,XF,feats3);

xrwmata=imhist(eikg);
black=xrwmata(1);
grey=xrwmata(43);
gratio=(black-grey);
lgrey=xrwmata(213);
gratio2=(black-lgrey);
gratio3=grey/lgrey;

eikg(eikg>0)=255;
eikg=imcomplement(eikg);
[row,col] = find(eikg);
k = boundary(row,col);
Mask = poly2mask(col(k),row(k),size(eikg,1),size(eikg,2));
eikg=imcomplement(Mask);
xrw=imhist(eikg);
I = bwperim(eikg);
a=I(2:end-1,2:end-1);
boring(1)=xrw(1);
boring(2)=sum(a(:)==1)*1.07;
boring(3)=(4*boring(1)*pi)/(boring(2)^2);
fito=boring(3);

hogmtrxF(deik-2,1:2)=[sum(xrwmata(1:150)) fito];
end

```

```
%%%%%%%%%% \ %%%%%%%%%%  
%%%%%%%%%% \ %%%%%%%%%%
```

```
[klF, kentraF]=kmeans(double(XF),cls);  
[klN, kentraN]=kmeans(double(XN),cls);  
kentra=cat(1,kentraN,kentraF);
```

```
Xtest=[];  
deik=1;  
pnt=1;  
kentra=single(kentra);  
%%%%%%%%%%  
%%%%%%%%%%
```

```
for j=1:(length(fpntN)-1)
```

```
Xtest=XN((fpntN(j)+1):fpntN(j+1),:);
```

```
clas=zeros(size(Xtest,1),1);  
inter=zeros(2*cls,1);  
for i=1:size(Xtest,1)  
d=zeros(2*cls,1);
```

```
    d=(pdist2(Xtest(i,:),kentra));  
    ds=sort(d);  
    a=find(d==ds(1));  
    b=find(d==ds(2));
```

```
    if a<=cls & b<=cls  
        clas(i)=1;  
        inter(a)=1+inter(a);  
    elseif a>cls & b> cls  
        clas(i)=2;  
        inter(a)=1+inter(a);  
    elseif a<=cls & b> cls  
        if ds(1)/ds(2)<0.75  
            clas(i)=1;  
            inter(a)=1+inter(a);  
        end
```

```
    elseif a>cls & b<=cls  
        if ds(1)/ds(2)<0.75  
            clas(i)=2;  
            inter(a)=1+inter(a);  
        end  
    end
```

```
end  
featureOfSURF=sum(clas==1)-sum(clas==2);  
tnorm(deik,1:1+size(hogmtrxN,2))=[1*featureOfSURF hogmtrxN(deik,1:size(hogmtrxN,2))];  
deik=deik+1;  
end
```

```
deik=1;  
clasf=zeros(2*cls,1); % 1=N , 2=F  
for j=1:(length(fpntF)-1)
```

```
Xtest=XF((fpntF(j)+1):fpntF(j+1),:);
```

```
inter=zeros(2*cls,1);  
clas=zeros(size(Xtest,1),1);
```

```
for i=1:size(Xtest,1)  
    d=zeros(2*cls,1);  
    d=(pdist2(Xtest(i,:),kentra))';  
    ds=sort(d);  
    a=find(d==ds(1));  
    b=find(d==ds(2));
```

```
    if a<=cls & b<=cls  
        clas(i)=1;  
        inter(a)=1+inter(a);  
    elseif a>cls & b> cls  
        clas(i)=2;  
        inter(a)=1+inter(a);  
    elseif a<=cls & b> cls  
        if ds(1)/ds(2)<0.75  
            clas(i)=1;  
            inter(a)=1+inter(a);  
        end  
    elseif a>cls & b<=cls  
        if ds(1)/ds(2)<0.75  
            clas(i)=2;  
            inter(a)=1+inter(a);  
        end  
    end  
end
```

```
featureOfSURF=sum(clas==1)-sum(clas==2);  
tfail(deik,1:1+size(hogmtrxN,2))=[1*featureOfSURF hogmtrxF(deik,1:size(hogmtrxN,2))];  
deik=deik+1;  
end
```

```
%%%%%%%%%%  
%%%%%%%%%%  
%%%%%%%%%%  
%%%%%%%%%%
```

```
tnorm2=tnorm;  
hogmtrx=cat(1,hogmtrxN,hogmtrxF);
```

```
flag=0;  
if abs(max(tnorm(:,1)))>abs(min(tfail(:,1)))  
    tnorm2(:,1)=tnorm(:,1)/abs((max(tnorm(:,1))/min(tfail(:,1))));  
    flag=1;  
else  
    tfail2(:,1)=tfail(:,1)/abs((min(tfail(:,1))/max(tnorm(:,1))));  
end  
kanonahog=max(tnorm2(:,1));
```

```
hogmtrx2=hogmtrx./max(hogmtrx)*kanonahog;  
tnorm2(:,2:size(hogmtrx2,2)+1)=hogmtrx2(1:length(hogmtrxN),:);  
tfail2(:,2:size(hogmtrx2,2)+1)=hogmtrx2(length(hogmtrxN)+1:end,:);
```

```

for ki=1:size(tnorm2,1)
    if tnorm2(ki,1)<=0
        tnorm2(ki,1)=5;
    end
end
for ki=1:size(tfail2,1)
    if tfail2(ki,1)>=0
        tfail2(ki,1)=-5;
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

X=cat(1,tnorm2,tfail2);
model_linear = svmtrain(y, X, '-t 0');

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

deik=1;
for j=XtestInd
    eik=imread(sprintf('bsee42/%i.png',j));
    eikg=rgb2gray(eik);

    regs=detectSURFFeatures(eikg,'MetricThreshold',thres,'NumOctaves',octaves,'NumScaleLevels',lvls);

    [feats,validpts]=extractFeatures(eikg,regs,'SURFSize',srs,'Upright',true);

    feats3=feats;
    Xtest=feats3;

inter=zeros(2*cls,1);
clas=zeros(size(Xtest,1),1);
for i=1:size(Xtest,1)
    d=zeros(2*cls,1);
    d=(pdist2(Xtest(i,:),kentra));
    ds=sort(d);
    a=find(d==ds(1));
    b=find(d==ds(2));

    if a<=cls & b<=cls
        clas(i)=1;
        inter(a)=1+inter(a);
    elseif a>cls & b> cls
        clas(i)=2;
        inter(a)=1+inter(a);
    elseif a<=cls & b> cls
        if ds(1)/ds(2)<0.75
            clas(i)=1;
            inter(a)=1+inter(a);
        end
    elseif a>cls & b<=cls
        if ds(1)/ds(2)<0.75

```

```

        clas(i)=2;
        inter(a)=1+inter(a);
    end
end
end

eikg(eikg>0)=255;
eikg=imcomplement(eikg);
[row,col] = find(eikg);
k = boundary(row,col);
Mask = poly2mask(col(k),row(k),size(eikg,1),size(eikg,2));
eikg=imcomplement(Mask);
xrw=imhist(eikg);
I = bwperim(eikg);
a=I(2:end-1,2:end-1);
boring(1)=xrw(1);
boring(2)=sum(a(:)==1)*1.07;
boring(3)=(4*boring(1)*pi)/(boring(2)^2);
fito=boring(3);

grayAndCirc=[sum(xrwmata(1:150)) fito]./max(hogmtrx).*max(hogmtrx2);
featOfSURF=(sum(clas==1)-sum(clas==2));
if featOfSURF<0
if flag==1
    featOfSURF=(sum(clas==1)-sum(clas==2))/abs((max(tnorm(:,1))/min(tfail(:,1))));
else
    featOfSURF=(sum(clas==1)-sum(clas==2))/abs((min(tfail(:,1))/max(tnorm(:,1))));
end
end
pointbreak=[featOfSURF grayAndCirc];

testy(deik,1:size(tnorm,2))=pointbreak;
deik=deik+1;
Xtest=[];

end

[predict_label_L, accuracy_L, dec_values_L] = svmpredict(yi, testy, model_linear);
normpre=sum(predict_label_L(1:(team1-ntper))==0)/(team1-ntper);
failpre= sum(predict_label_L((team1-ntper+1):(team1-ntper+team2-ftper))==1)/(team2-ftper);

%%%%%%%%%%%%% ENABLE FOR GRAPH %%%%%%%%%%%%%%
%%%%%%%%%%%%%
% figure(1)
% scatter3(tnorm2(:,1),tnorm2(:,2),tnorm2(:,3),'b');
% hold on;
% scatter3(tfail2(:,1),tfail2(:,2),tfail2(:,3),'r');
% hold on;
%
% dx = 0.1; dy = 0.1; dz = 0.1;
% scatter3(testy(1:team1-ntper,1),testy(1:team1-ntper,2),testy(1:team1-ntper,3),200,'b','p');
% for skat=1:team1-ntper
% normind(skat)=(XtestInd(skat));
% end
% normind=num2str(normind');

```

```

% text(testy(1:team1-ntper,1)+dx, testy(1:team1-ntper,2)+dy,testy(1:team1-ntper,3)+dz, normind);
%
% scatter3(testy((team1-ntper+1):(team1-ntper+team2-ftper),1),testy((team1-ntper+1):(team1-ntper+team2-
ftper),2),testy((team1-ntper+1):(team1-ntper+team2-ftper),3),200,'r','x');
% for skat=(team1-ntper+1):(team1-ntper+team2-ftper)
% failind(skate-(team1-ntper+1)+1)=(XtestInd(skate));
% end
% failind=num2str(failind');
% text(testy((team1-ntper+1):(team1-ntper+team2-ftper),1)+dx, testy((team1-ntper+1):(team1-ntper+team2-
ftper),2)+dy,testy((team1-ntper+1):(team1-ntper+team2-ftper),3)+dz,failind);
%
% w=model_linear.SVs'*model_linear.sv_coef;
% b=-model_linear.rho;
%
% xgrid=[0:300];
% ygrid=[0:300]; % FOR 3D
% [X, Y]=meshgrid(xgrid, ygrid);
% Z=(-b-w(1)*X-w(2)*Y)/w(3);
% hSurface=surf(X, Y, Z);
% alpha 0.2
% set(hSurface,'FaceColor',[0 0 1], ...
% 'FaceAlpha',0.5,'FaceLighting','gouraud','EdgeColor','none');
% zlim([0 100]);
%
% hold off
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
akrivieies(indexOfAccur,1:2)=[accuracy_L(1) 0.5*(normpre+failpre)]; % total and mean accuracy
pause();
end

toc

```

## **ΒΙΒΛΙΟΓΡΑΦΙΑ**

- [1] Chen Lu, Yang Wang, Minvydas Ragulskis and Yujie Cheng, “Fault Diagnosis for Rotating Machinery: A Method based on Image Processing” (2016)
- [2] Herbert Bay, Andreas Ess, Tinne Tuytelaars and Luc Van Gool, “Speeded-Up Robust Features” (2008)
- [3] Edouard Oyallon and Julien Rabin, “An Analysis of the SURF Method” (2015)
- [4] Alessandro Rivola, “Applications of Higher Order Spectra to the Machine Condition Monitoring” (2000)
- [5] Lingli Jiang, Yilun Liu, Xuejun Li and Siwen Tang, “Using bispectral distribution as a feature for rotating machinery fault diagnosis” (2011)
- [6] Miguel E. Iglesias-Martinez, Jose Alfonso Antonino-Daviu, Pedro Fernandez de Cordoba and J. Alberto Conejero, “Rotor Fault Detection in Induction Motors Based on Time-Frequency Analysis Using the Bispectrum and the Autocovariance of Stray Flux Signals” (2019)
- [7] Paul S. Bradley and Usama M. Fayaad, “Refining Initial Points for K-Means Clustering” (1998)
- [8] Aristidis Likas, Nikos Vlassis and Jakob J. Verbeek, “The global K-Means clustering algorithm” (2003)
- [9] Yaguo Lei, Jing Lin, Zhengjia He, Yanyang Z, “Application of an improved kurtogram method for fault diagnosis of rolling element bearings” (2011)
- [10] F. Combet, L. Gelman, “Optimal filtering of gear signals for early damage detection based on the spectral kurtosis” (2008)
- [11] Nello Cristianini and John Shawe-Taylor, “An Introduction to Support Vector Machines and Other Kernel-based Learning Methods” (2000)