



ΠΑΝΕΠΙΣΤΗΜΙΟ ΜΑΚΕΔΟΝΙΑΣ
ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ
ΤΜΗΜΑΤΟΣ ΕΦΑΡΜΟΣΜΕΝΗΣ ΠΛΗΡΟΦΟΡΙΚΗΣ

ΑΝΙΧΝΕΥΣΗ ΣΦΑΛΜΑΤΩΝ ΜΕ ΧΡΗΣΗ ΑΛΓΟΡΙΘΜΟΥ QGA-SVM

Διπλωματική Εργασία

του

Αχιλλέα Ι. Σούλη

Θεσσαλονίκη, Ιούνιος 2021

ΑΝΙΧΝΕΥΣΗ ΣΦΑΛΜΑΤΩΝ ΜΕ ΧΡΗΣΗ ΑΛΓΟΡΙΘΜΟΥ QGA-SVM

Αχιλλέας Ι. Σούλης

Πτυχίο Μαθηματικών, Πανεπιστήμιο Ιωαννίνων, 2018

Διπλωματική Εργασία

υποβαλλόμενη για τη μερική εκπλήρωση των απαιτήσεων του

ΜΕΤΑΠΤΥΧΙΑΚΟΥ ΤΙΤΛΟΥ ΣΠΟΥΔΩΝ ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ
ΠΛΗΡΟΦΟΡΙΚΗ

Επιβλέπων Καθηγητής
Γεώργιος Ευαγγελίδης

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 29/06/2021

Γεώργιος Ευαγγελίδης

Γεωργία Κολωνiάρη

Νικόλαος Σαμαράς.

Αχιλλέας Ι. Σούλης

Περίληψη

Η χρήση των μηχανημάτων που στηρίζονται στην περιστρεφόμενη μηχανολογία (rotating machinery) έχει τύχει ευρύτατης εφαρμογής σε συμπιεστές, φυγόκεντρες αντλίες, υδροστρόβιλους, αεριοστρόβιλους, αντλίες θερμότητας, τεχνητές καρδιές, εξορυκτικές και διατρητικές μηχανές κ.ά. Η έγκαιρη διάγνωση των πιθανών βλαβών που θα προκύψουν κατά την λειτουργία τους είναι ζωτικής σημασίας. Λαμβάνοντας υπόψη τα μειονεκτήματα των συμβατικών μεθόδων διάγνωσης σφαλμάτων για μηχανές και ρουλεμάν, με την παρούσα εργασία προτείνεται μια μέθοδος διάγνωσης τέτοιων σφαλμάτων που βασίζεται στην τεχνική της υποστηρικτικής μηχανής μέσω διανυσμάτων (Supporting Vector Machine, SVM) η οποία βελτιστοποιείται με τη χρήση κβαντικού γενετικού αλγορίθμου (Quantum Genetic Algorithm, QGA). Αρχικά βελτιστοποιούνται οι χαρακτηριστικοί παράμετροι της τεχνικής SVM με τον αλγόριθμο QGA. Στη συνέχεια, χρησιμοποιούνται τα δεδομένα εκπαίδευσης (training) του αλγορίθμου SVM. Το σύνολο δεδομένων δοκιμής (test) χρησιμοποιείται για το αλγόριθμο δοκιμής. Τα πειραματικά δεδομένα ελήφθησαν από δοκιμές σε ρουλεμάν που έγιναν στο Πανεπιστήμιο Case Western Reserve. Τα δεδομένα δόνησης συλλέχθηκαν χρησιμοποιώντας επιταχυνσιόμετρα. Η μέθοδος που προτείνεται βασίζεται σε γενετικούς αλγόριθμους και στην τεχνική SVM. Τα αποτελέσματα της ανάλυσης δείχνουν ότι η προτεινόμενη μέθοδος έχει ορισμένες φορές μεγαλύτερη ακρίβεια στη διάγνωση σφαλμάτων από την παραδοσιακή μέθοδο SVM, αλλά και η εύρεση του βέλτιστου αποτελέσματος επιτυγχάνεται πιο γρήγορα.

Λέξεις Κλειδιά: Διάγνωση σφαλμάτων μηχανημάτων, κβαντικός γενετικός αλγόριθμος, υποστηρικτική διανυσματική μηχανή

Abstract

The use of machines based on rotating machinery (rotating machinery) has been widely applied in compressors, centrifugal pumps, hydroturbines, gas turbines, heat pumps, artificial hearts, mining and drilling machines, etc. Early diagnosis of possible failures that will occur during their operation is therefore vital. Considering the disadvantages of conventional error diagnostic methods for machines and gears with the present work a fault diagnosis method based on the technique of Supporting Vector Machine (SVM) optimized with Quantum Genetic Algorithm (QGA) is proposed. Initially the characteristic parameters of the SVM technique are optimized. Then, the training data of the SVM model are used. The test data set is used for the test modeling. The experimental data were obtained from bearings tests performed at Case Western Reserve University. Vibration data were collected using accelerometers. The proposed method is based on genetic algorithms and the SVM technique. The results of the analysis show that the proposed method is sometimes more accurate in diagnosing errors than the traditional SVM method. Furthermore the best result can be found faster than the traditional way.

Keywords: Machinery fault diagnosis, quantum genetic algorithm, support vector machine

Ευχαριστίες

Θα ήθελα να ευχαριστήσω αρχικά τον επιβλέποντα Καθηγητή μου κ. Γεώργιο Ευαγγελίδη για την καθοδήγηση το ενδιαφέρον αλλά και την βοήθεια που μου προσέφερε σε όλη τη διάρκεια της εκπόνησης της Μεταπτυχιακής Διπλωματικής μου εργασίας. Επίσης, θα ήθελα να ευχαριστήσω όλα τα μέλη της οικογένειας μου ξεχωριστά για την υποστήριξη τους όλο αυτό το διάστημα.

Περιεχόμενα

1	Εισαγωγή.....	8
1.1	Γενικά.....	8
1.2	Προηγούμενη γνώση SVM και QGA-SVM.....	11
1.3	Συνεισφορά της παρούσας έρευνας	11
1.4	Διαμόρφωση μελέτης	12
2	Τεχνικές λήψης δεδομένων.....	13
2.1	Τεχνικές ελέγχου μετρήσεων.....	13
2.2	Λήψεις δεδομένων και συστήματα επεξεργασίας.....	16
3	Μηχανική μάθηση.....	18
3.1	Εισαγωγή.....	18
3.2	Τύποι αλγορίθμων μάθησης.....	19
3.3	Επεξηγηματικοί όροι μηχανικής εκμάθησης.....	20
3.4	Αλγόριθμοι για μηχανική εκμάθηση και κατηγοριοποίηση.....	24
3.4.1	Naive Bayes.....	24
3.4.2	Δέντρα αποφάσεων.....	26
3.4.3	Multi-Layer Perceptron.....	27
3.4.4	Η τεχνική SVM.....	28
4.	Κβαντική Μηχανική.....	37
4.1	Εισαγωγή στη κβαντική μηχανική.....	37
4.2	Κωδικοποίηση κβαντικών δεδομένων.....	38
4.2.1	Κβαντικά δεδομένα.....	38
4.2.2	Κβαντικές πύλες.....	39
4.3	Κβαντικός γενετικός αλγόριθμος QGA.....	41
5.	Πειραματική διαδικασία και λήψη δεδομένων.....	47
5.1	Λεπτομέρειες της πειραματικής διάταξης.....	47
5.2	Συλλογή δεδομένων.....	48
5.3	Δεδομένα των μετρήσεων.....	48
6.	Προτεινόμενη μεθοδολογία και αριθμητική προσομοίωση.....	50
6.1	Το πρόβλημα.....	50
6.2	Προ-επεξεργασία δεδομένων.....	51
6.3	Υπολογισμός χαρακτηριστικών των δεδομένων.....	53

6.4 Προτεινόμενη μεθοδολογία QGA-SVM.....	53
6.5 Επίλυση.....	57
7. Αποτελέσματα μοντέλων SVM και QGA-SVM.....	61
7.1 Αποτελέσματα αλγόριθμου SVM. Εφαρμογή 1 ^η	61
7.2 Αποτελέσματα αλγόριθμου QGA-SVM. Εφαρμογή 2 ^η	65
7.3 Αποτελέσματα αλγόριθμου QGA-SVM για τις εφαρμογές.....	66
8. Συγκρίσεις, σύνοψη και συμπεράσματα.....	71
8.1 Συγκρίσεις μοντέλων SVM και QGA-SVM.....	71
8.2 Ευαισθησία των συντελεστών C και σ^2	72
8.3 Σύνοψη και συμπεράσματα.....	75
8.4 Όρια και περιορισμοί της έρευνας.....	75
8.5 Μελλοντικές επεκτάσεις.....	76
9. Βιβλιογραφία-Αρθρογραφία, Διαδίκτυο.....	77
Παράρτημα I Πίνακας μετρήσεων και διαστάσεις των δυο ρουλεμάν.....	81
Παράρτημα II Δεδομένα κανονικής και προβληματικής λειτουργίας.....	83
Παράρτημα III Δεδομένα των πρώτων σειρών της σφαίρας "Ball_007_1".....	87
Παράρτημα IV Υπολογιστικός αλγόριθμος QGA-SVM.....	88

Κατάλογος Σχημάτων

Σχήμα 1.1 Βέλτιστο υπερ-επίπεδο για δυαδική ταξινόμηση από SVM.....	10
Σχήμα 2.1 Σύστημα συλλογής ψηφιακών δεδομένων.....	14
Σχήμα 3.1 Δένδρο αποφάσεων.....	26
Σχήμα 3.2 Δύο επιπέδων Perceptron.....	27
Σχήμα 3.3 Μεγιστοποίηση του περιθωρίου μεταξύ των υποστηρικτικών διανυσμάτων (support vectors).....	28
Σχήμα 3.4 Ταξινόμηση σημείων δεδομένων που ανήκουν σε ορισμένη κατηγορία από το σύνολο των δεδομένων.....	30
Σχήμα 3.5 Ορισμός υπερ-επιπέδων.....	31
Σχήμα 3.6 Μετασχηματισμός μη-γραμμικού προβλήματος και γραμμικός διαχωρισμός.....	34
Σχήμα 3.7 Χρήση της συνάρτησης πυρήνα (kernel).....	35
Σχήμα 4.1 Κλασσικό bit και qubit.....	38
Σχήμα 4.2 Διάγραμμα ροής του συμβατικού κβαντικού γενετικού αλγορίθμου.....	43
Σχήμα 4.3 Σχηματικό διάγραμμα διασταυρούμενης επικύρωσης.....	44
Σχήμα 4.4 Σχηματικό διάγραμμα κβαντικής διασταύρωσης.....	44
Σχήμα 5.1 Πειραματική διάταξη για μετρήσεις προβληματικής λειτουργίας ρουλεμάν.....	48
Σχήμα 6.1 Ρουλεμάν με τα τέσσερα κύρια μέρη αυτού.....	50
Σχήμα 6.2 Η μέθοδος διάγνωσης λαθών με την τεχνική QGA-SVM.....	55
Σχήμα 6.3 Βελτιστοποίηση των παραμέτρων της μεθόδου QGA-SVM.....	57
Σχήμα 7.1 Τμήμα κώδικα SVM με τις παραμέτρους του προβλήματος.....	61
Σχήμα 7.2 Ολική ακρίβεια.....	61
Σχήμα 7.3 Αποτελέσματα του πίνακα σύγκρισης για τα εκπαιδευτικά δεδομένα της εφαρμογής SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) ποσοστιαία τιμή των ορθώς κατηγοριοποιημένων δεδομένων (ακρίβεια).....	63
Σχήμα 7.4 Αποτελέσματα του πίνακα σύγκρισης για τα δεδομένα δοκιμής της εφαρμογής SVM. α) Σύνολο ορθά κατηγοριοποιημένων	

δεδομένων, β) ποσοστιαία τιμή των ορθώς κατηγοριοποιημένων δεδομένων (ακρίβεια).....	64
Σχήμα 7.5 Διάταξη μετρήσεων για την διάγνωση σφαλμάτων λειτουργίας ενός φυγοκεντρικού ανεμιστήρα.....	65
Σχήμα 7.6 Αποτελέσματα του πίνακα σύγχυσης για τα εκπαιδευτικά δεδομένα της εφαρμογής QGA-SVM. α) Σύνολο ορθά κατηγοριοποιη- μένων δεδομένων, β) Ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια).....	68
Σχήμα 7.7 Αποτελέσματα του πίνακα σύγχυσης για τα δεδομένα δοκιμής της εφαρμογής QGA-SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) Ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια).....	69
Σχήμα 7.8 Βελτιστοποίηση της ακρίβειας του αλγόριθμου QGA-SVM (0.9667) και αριθμός των γενεών (ανακυκλώσεων).....	70
Σχήμα 7.9 Αποτέλεσμα ακρίβειας (Best fitness=0.9667) που υπολογίσθηκε.....	70
Σχήμα 8.1 Ενδείξεις υψηλής και χαμηλής τιμής του συντελεστή C.....	73
Σχήμα 8.2 α) Ενδείξεις χαμηλής και β) υψηλής τιμής σ^2	74
Σχήμα 8.3 Εφαρμογές του κβαντικού υπολογισμού.....	76

Κατάλογος Πινάκων

Πίνακας 4.1 Προσαρμογή της γωνίας περιστροφής.....	45
Πίνακας 8.1 Διαγνωστική ακρίβεια των μεθόδων SVM και QGA-SVM για την 1 ^η Εφαρμογή.....	72
Πίνακας 8.2 Διαγνωστική ακρίβεια των μεθόδων SVM QGA-SVM για την 2 ^η Εφαρμογή.....	72
Πίνακας I.1 Πίνακας των αλλοιώσεων που εισήχθησαν στα ρουλεμάν στο Case Western Reserve των Η.Π.Α. Όλες οι τιμές σε ίντσες, 1”=2.54 cm.....	81
Πίνακας I.2 Διαστάσεις των δυο ρουλεμάν που χρησιμοποιήθηκαν για τις μετρήσεις στο Case Western Reserve των Η.Π.Α. 1”=2.54 cm.....	82
Πίνακας II.1 Δεδομένα κανονικής λειτουργίας του κινητήρα χωρίς ελαττώματα. Case Western Reserve των Η.Π.Α.....	83
Πίνακας II.2 Δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 12.0 kHz. Case Western Reserve των Η.Π.Α.....	84
Πίνακας II.3 Δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 48.0 kHz. Case Western Reserve των Η.Π.Α.....	85
Πίνακας II.4 Δεδομένα προβληματικής λειτουργίας του άκρου του ανεμιστήρα (fan end) του κινητήρα με δειγματοληψία 12.0 kHz. Case Western Reserve των Η.Π.Α.....	86
Πίνακας III.1 Τυπικά δεδομένα των πρώτων σειρών της σφαίρας "Ball_007_1" του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 48.0 kHz με τις τιμές των χαρακτηριστικών, "max", "min", "mean", "sd", "rms", "skewness", "kurtosis", "crest", "form", "fault". Case Western Reserve των Η.Π.Α.....	87
Πίνακας IV.1 Ο υπολογιστικός αλγόριθμος QGA-SVM.....	88

Συμβολισμοί

A accuracy, ακρίβεια

α με α^2 πιθανότητα εμφάνισης του $|0\rangle$

α_i συντελεστές Lagrange

$$\sum_{i=1}^1 \alpha_i y_i = 0$$

β με β^2 πιθανότητα εμφάνισης του $|1\rangle$

H1 υπερ-επίπεδο

H2 υπερ-επίπεδο

θ γωνία

$\Delta\theta$ διαφορά γωνιών

N πληθυσμός χρωμοσωμάτων

σ^2 συντελεστής SVM

$|\psi\rangle$ $\alpha |0\rangle + \beta |1\rangle$ υπέρθεση

b μετατόπιση διανύσματος

bit : 0 ή 1

C παράμετρος έλεγχου σφάλματος

$$0 \leq \alpha_i \leq C \quad i=1,2,3,\dots,l$$

C συντελεστής SVM

C1, C2, ..., C10, κατηγορίες σφαλμάτων

f συνάρτησης προσαρμοστικότητας

FN λανθασμένα σωστή μη-πρόβλεψη

FP λανθασμένα σωστή πρόβλεψη.

Kernel συνάρτηση πυρήνα

$$K(x_i, x_j) = \phi(\bar{x}_i) \cdot \phi(\bar{x}_j)$$

Lagrange εξίσωση

$$L(x, \alpha) = f(x) + \sum_{i=1}^1 \alpha_i g_i(x)$$

l μέγιστος αριθμός δεδομένων

m αριθμός των γονιδίων κάθε χρωμοσώματος

P precision, ακρίβεια

P(A) πιθανότητα του A

P(B) πιθανότητα του B

P(A | B) με συνθήκη πιθανότητα

P(B | A) με συνθήκη πιθανότητα

Q(t) πληθυσμός χρωμοσωμάτων γενιάς t

$\begin{bmatrix} q_j^t \end{bmatrix}$ χρωμόσωμα

QGA Quantum Genetic Algorithm

QGA-SVM Quantum Genetic Algorithm-Support Vector Machine

qubit στοιχειώδης μονάδα κβαντικής πληροφορίας

R recall, ανάκληση

rbf radial basis function, συνάρτηση πυρήνα

$$K(x_i, x_j) = \exp \left[- \frac{|x_i - x_j|^2}{2\sigma^2} \right]$$

s(a_i.b_i) κατεύθυνση της περιστρεφόμενης γωνίας

SVM Support Vector Machine

t γενιά QGA

TP σωστή πρόβλεψη

TN σωστή μη-πρόβλεψη

$$U(\theta_i) = \begin{pmatrix} \cos\theta_i & -\sin\theta_i \\ \sin\theta_i & \cos\theta_i \end{pmatrix} \text{ τελεστής στροφής}$$

u διάνυσμα

w διάνυσμα

x_i, i=1,2,3...l διανυσματικά δεδομένα

y_i κλάσεις {-1,+1} για κάθε διάνυσμα x_i.

1 Εισαγωγή

1.1 Γενικά

Διάγνωση βλαβών. Η χρήση των μηχανημάτων που στηρίζονται στην περιστρεφόμενη μηχανολογία (rotating machinery) έχει τύχει ευρύτατης εφαρμογής σε πολλαπλές βιομηχανικές, οικιακές και ιατρικές εφαρμογές. Παραδείγματα αυτών είναι, συμπιεστές, φυγόκεντρες αντλίες, υδροστρόβιλοι, αντλίες θερμότητας, τεχνητές καρδιές, εξορυκτικές και διατρητικές μηχανές κ.ά. Η αξιοπιστία των μηχανημάτων αυτών στηρίζεται κατά κύριο λόγο στην έγκαιρη διάγνωση των πιθανών βλαβών που θα προκύψουν κατά την λειτουργία τους. Η συστηματική καταγραφή, μετάδοση και επεξεργασία των δεδομένων μιας διαταραχής από οπουδήποτε και αν αυτή προέρχεται, είναι σημαντικός παράγοντας για την ανάλυση, βελτιστοποίηση και πρόβλεψη λειτουργίας των μηχανών/μηχανισμών. Η έξυπνη ανάλυση διαταραχών πιέσεων-σημάτων είναι υψίστης σημασίας προκειμένου να γίνεται έγκαιρα η διάγνωση πιθανών προβληματικών καταστάσεων. Είναι λοιπόν ζωτικής σημασίας η παροχή πληροφοριών για την σωστή συντήρηση αυτών των μηχανημάτων η οποία θα αποτρέψει τη λειτουργία αυτών με χαμηλή απόδοση ή με πλήρη διακοπή της λειτουργίας που θα έχουν σαν αποτέλεσμα να επιφέρουν τις ανάλογες οικονομικές επιβαρύνσεις, (Wei et al. 2019).

Κάθε είδους διαφοροποίηση από το συγκεκριμένο-προγραμματισμένο ορθό τρόπο λειτουργίας επιφέρει δυσλειτουργίες, οι οποίες μπορεί να επιφέρουν απόκλιση από τη προδιαγεγραμμένη, πρότυπη, συμπεριφορά. Αυτό έχει σαν συνέπεια τη πιθανή πρόκληση βλαβών, οι οποίες μπορεί σε εξαιρετικές περιπτώσεις να φανούν καταστροφικές. Η αποφυγή βλαβών σε οποιαδήποτε μηχανή είναι από τα πιο βασικά θέματα λειτουργίας μηχανής/μηχανισμού. Οι βλάβες αποφεύγονται,

- με συντήρηση όταν απαιτείται και
- με πρόβλεψη εκ των προτέρων.

Η υιοθέτηση της διαδικασίας της συντήρησης που εκτελείται μόνο όταν απαιτείται οδηγεί σε σημαντικά κέρδη, καθώς αποκλείει την περιοδική συντήρηση και μειώνει τον μη-προγραμματισμένο χρόνο διακοπής της. Ο άλλος τρόπος συντήρησης είναι η προγνωστική συντήρηση. Σε αυτή τη μέθοδο προβλέπεται εκ των προτέρων πότε θα γίνει η συντήρηση.

Λήψη μεγάλων δεδομένων. Η παρακολούθηση των μηχανών και μηχανισμών απαιτεί σύστημα αισθητήρων. Οι αισθητήρες είναι ένα βασικό όργανο στη βιομηχανία και στον κόσμο των μετρήσεων. Η καταγραφή δεδομένων μεγάλης κλίμακας, σχετικά με την κατάσταση λειτουργίας και την απόδοση των μηχανών, είναι ουσιαστική και σημαντική πράξη. Το σύστημα της λήψης μεγάλων δεδομένων διαταραχών σε πραγματικό χρόνο προορίζεται για την παρακολούθηση μηχανών και για την άμεση ανίχνευση αποκλίσεων από την κανονική τους λειτουργία.

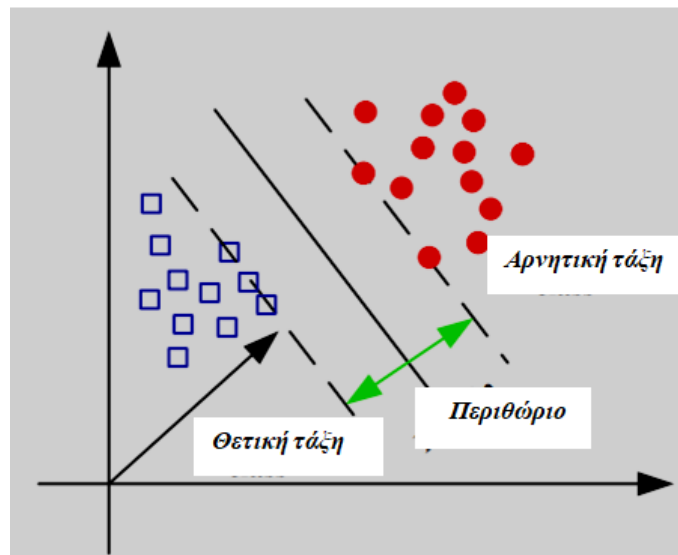
Μηχανική μάθηση. Η μηχανική μάθηση (Machine Learning) είναι υπο-πεδίο της επιστήμης των υπολογιστών (Computer Science) που αναπτύχθηκε από τη μελέτη της αναγνώρισης προτύπων και της υπολογιστικής θεωρίας μάθησης στην τεχνητή νοημοσύνη (Artificial Intelligence), (Machine Learning, 2021). Το 1959 ο Άρθουρ Σάμουελ ορίζει τη μηχανική μάθηση ως "πεδίο μελέτης που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν ρητά προγραμματιστεί", (Simon P, 2013). Η μηχανική μάθηση διερευνά τη μελέτη και την κατασκευή αλγορίθμων που μπορούν να μαθαίνουν από τα δεδομένα και να κάνουν προβλέψεις σχετικά με αυτά. Τέτοιοι αλγόριθμοι λειτουργούν κατασκευάζοντας μοντέλα από πειραματικά δεδομένα, προκειμένου να κάνουν προβλέψεις βασιζόμενες σε αυτά ή να εξάγουν αποφάσεις που εκφράζονται ως το αποτέλεσμα. Η μηχανική εκμάθηση κατηγοριοποιείται γενικά σε,

- εποπτευόμενη μάθηση και
- μη-εποπτευόμενη μάθηση.

Στην εποπτευόμενη εκμάθηση τα δεδομένα βοηθούν τον αλγόριθμο να συσχετίσει τα χαρακτηριστικά λειτουργίας. Χαρακτηριστικά παραδείγματα εποπτευόμενης μηχανικής μάθησης είναι η ταξινόμηση και η παλινδρόμηση. Στην μη-εποπτευόμενη μάθηση τα δεδομένα ευρίσκονται χωρίς ταξινόμηση και το σύστημα επιχειρεί να αποκαλύψει μοτίβα συμπεριφοράς δεδομένων.

Support Vector Machine. Οι μηχανές διανυσματικής υποστήριξης ή Support Vector Machines (SVM) είναι εποπτευόμενα μοντέλα μάθησης. Τα μοντέλα αυτά, που αναλύουν δεδομένα, χρησιμοποιούνται για την ταξινόμηση ή παλινδρόμηση, (Zhangetal., 2020). Η μέθοδος SVM είναι μια από τις πιο ευρέως χρησιμοποιούμενες αλλά και από τις πιο αποτελεσματικές τεχνικές ταξινόμησης (SVM classification, 2020).

Ο ταξινομητής SVM είναι ένας αλγόριθμος που βασίζεται στη θεωρία της στατιστικής μάθησης. Η αρχική ιδέα του SVM είναι να χρησιμοποιηθεί ένα γραμμικό διαχωριστικό υπερ-επίπεδο για να χωρισθούν τα εκπαιδευτικά δείγματα σε δύο τάξεις, Σχήμα 1.1. Γενικά, υπάρχουν δύο είδη κατάλληλων μεθόδων για την ολοκλήρωση αυτού του στόχου. Η πρώτη είναι να βρεθεί το βέλτιστο υπερ-επίπεδο που χωρίζει στα δύο τα πλησιέστερα δείγματα σε δύο περιοχές. Η δεύτερη είναι να βρεθεί το βέλτιστο υπερ-επίπεδο δημιουργώντας το περιθώριο μεταξύ δύο παράλληλων υποστηρικτικών επιπέδων. Και τα δύο μπορεί να δώσουν τη βέλτιστη απόφαση υπερ-επίπεδου και τα διανύσματα που τα υποστηρίζουν. Στις εφαρμογές, τα προβλήματα επιλύονται χρησιμοποιώντας πολλαπλές τάξεις και όχι δύο όπως αυτό φαίνεται στο Σχήμα 1.1.



Σχήμα 1.1 Βέλτιστο υπερ-επίπεδο για δυαδική ταξινόμηση από SVM

Quantum Genetic Algorithm. Ο κβαντικός γενετικός αλγόριθμος ή Quantum Genetic Algorithm (QGA) χρησιμοποιείται για την αναζήτηση των βέλτιστων παραμέτρων λειτουργίας σ^2 του πυρήνα (kernel) και του συντελεστή C με χρήση της τεχνικής SVM. Επιπλέον, με βάση τα αποτελέσματα της αναζήτησης με χρήση της QGA, η βελτιστοποιημένη τεχνική SVM χρησιμοποιήθηκε για εκπαίδευση και δοκιμή με δεδομένα των ρουλεμάν που ελήφθησαν από τις δημοσιεύσεις, (Bearing data center, 2021) του Case Western Reserve University των Η.Π.Α.

Προκειμένου να επαληθευθούν οι νέες τεχνολογίες, είτε υπολογιστικές είτε τεχνικές, είναι απαραίτητη η εκτέλεση πειραμάτων. Η επιτυχής σύγκριση υπολογισμών με μετρήσεις είναι η μόνη παραδεκτή μέθοδος έρευνας. Οι μετρήσεις που έγιναν στο

Case Western Reserve University των Η.Π.Α., (Bearing data center, 2021), αφορούν την λειτουργία ενός κινητήρα χρησιμοποιήθηκαν προκειμένου να αξιολογηθούν οι συνθήκες ελαττωματικού ρουλεμάν. Το πειραματικό πρόγραμμα έχει επεκταθεί κατά τέτοιο τρόπο ώστε να παρέχει μια βάση δεδομένων απόδοσης του κινητήρα για περαιτέρω έρευνα.

Οι μετρήσεις μπορεί να χρησιμοποιηθούν για την επαλήθευση ή και για την βελτίωση πλήθους υπολογιστικών τεχνικών που αφορούν την κατάσταση του κινητήρα. Αυτά τα δεδομένα θα χρησιμοποιηθούν στην παρούσα έρευνα.

1.2 Προηγούμενη γνώση SVM και QGA-SVM

Η υπολογιστική τεχνική SVM θεωρείται ότι είναι μια τεχνική ταξινόμησης δεδομένων και χρησιμοποιείται ευρέως σε διάφορους επιστημονικούς τομείς όπως στον τομέα της διάγνωσης των μηχανικών βλαβών (Zhu et al., 2018). Οι (Rychetsky et al., 1999), μελέτησαν έναν μηχανισμό ανίχνευσης ελαττωμάτων, που ήταν η πρώτη φορά που εφαρμόστηκε το SVM για διάγνωση βλαβών. Τα πειραματικά αποτελέσματα έδειξαν ότι η προτεινόμενη μέθοδος είναι καλύτερη από τις άλλες μεθόδους διάγνωσης σφαλμάτων. Επιπλέον, οι (Xiao et al., 2001) χρησιμοποίησαν μια μέθοδο βασισμένη στην SVM για διάγνωση σφαλμάτων σε κινητήρες και γρανάζια, και τα αποτελέσματα που προέκυψαν έδειξαν ότι η μέθοδος έχει μεγαλύτερη ακρίβεια από τη μέθοδο διάγνωσης νευρωνικών δικτύων, αλλά η μελέτη εξέτασε μόνο δύο τύπους προβλημάτων διάγνωσης σφαλμάτων. Τα πειραματικά αποτελέσματα έδειξαν ότι η προτεινόμενη μέθοδος μπορεί να βελτιστοποιήσει τις παραμέτρους σε μεγάλο εύρος, και μπορούν αποτελεσματικά να διαγνώσουν τα ελαττώματα του μετασχηματιστή.

Η βελτιστοποίηση των παραμέτρων SVM, έγινε με τον αλγόριθμο QGA, ο οποίος έχει το πλεονέκτημα της υψηλής απόδοσης και αποφυγής του τοπικού βέλτιστου, (Zhang et al., 2017). Σκοπός ήταν η αναζήτηση των καλύτερων παραμέτρων του SVM. Προηγούμενες μελέτες για την ανάπτυξη γενετικών αλγορίθμων αναφέρονται και από τους (SaiToh et al., 2014) και (Lee et al., 2011).

1.3 Συνεισφορά της παρούσας έρευνας

Η μέθοδος που προτείνεται βασίζεται σε κβαντικό γενετικό αλγόριθμο QGA και στην τεχνική της υποστηρικτικής μηχανής μέσω διανύσματος SVM. Τα αποτελέσματα της ανάλυσης θα δείξουν εάν η προτεινόμενη μέθοδος έχει μεγαλύτερη ακρίβεια και ταχύτερη εύρεση στη διάγνωση των σφαλμάτων από την παραδοσιακή μέθοδο SVM

όταν αυτή εφαρμόζεται στις βλάβες μηχανών που προέρχονται από την λειτουργία των ρουλεμάν. Η διάγνωση με τεχνική QGA-SVM μπορεί να συμβάλει σε μεγάλο βαθμό για την επίλυση σύνθετων και προβλημάτων μεγάλων δεδομένων, εφ' όσον βέβαια συνδυασθούν και με κατάλληλο υπολογιστικό εξοπλισμό (hardware).

1.4 Διαμόρφωση μελέτης

Στα πρώτα κεφάλαια δίνεται μια περιγραφή της εργασίας που πρόκειται να αναλυθεί με αναφορές στην προηγούμενη εμπειρία σε στοιχεία λήψης δεδομένων και υπολογιστικών διαδικασιών διαγνώσεων βλαβών. Αμέσως μετά αναφέρονται τα δεδομένα που χρησιμοποιήθηκαν για την εκμάθηση του προτεινόμενου γενετικού κβαντικού κώδικα. Έγιναν συγκρίσεις των υπολογισμών με παραδοσιακό κώδικα και συνάγονται τα αποτελέσματα. Η διάθρωση της εργασίας έχει ως εξής,

- Στο Κεφάλαιο 2 αναφέρονται οι τεχνικές λήψεις δεδομένων με τα αντίστοιχα συστήματα που υποβοηθούν την συλλογή αυτών.
- Το Κεφάλαιο 3 δίνει μια γενική αναφορά στις τεχνικές μηχανικής εκμάθησης.
- Το θεωρητικό υπόβαθρο της κβαντικής μηχανικής δίνεται στο Κεφάλαιο 4.
- Η πειραματική διαδικασία και η λήψη των δεδομένων για την μοντελοποίηση των υπολογιστικών αλγορίθμων δίνονται στο Κεφάλαιο 5.
- Στο Κεφάλαιο 6 περιγράφεται η προτεινόμενη μεθοδολογία και η αριθμητική προσομοίωση για το πρόβλημα που απασχολεί την παρούσα εργασία.
- Τα υπολογιστικά αποτελέσματα των μοντέλων Supporting Vector Machine (SVM) και Quantum Genetic Algorithm-SVM (QGA-SVM) δίνονται στο Κεφάλαιο 7.
- Ενώ οι συγκρίσεις και τα συμπεράσματα από την ανάλυση δίνονται στο Κεφάλαιο 8.
- Αναλυτική περιγραφή ορισμένων θεμάτων, όπως π.χ. δεδομένων, δίνεται στα Παραρτήματα.

2. Τεχνικές λήψης δεδομένων

2.1 Τεχνικές ελέγχου μετρήσεων

Υπάρχουν δυο μέθοδοι για τη διάγνωση των σφαλμάτων ορθής λειτουργίας,

- προσεγγίσεις βάσει αλγόριθμου
- προσεγγίσεις βάσει δεδομένων.

Προσεγγίσεις βάσει αλγόριθμου. Στην προσέγγιση αυτή, δημιουργείται ένας αλγόριθμος του συστήματος λειτουργίας για διάγνωση και για την πρόγνωση των σφαλμάτων. Η προσέγγιση γίνεται δύσκολη όταν υπάρχουν διακυμάνσεις στις συνθήκες λειτουργίας.

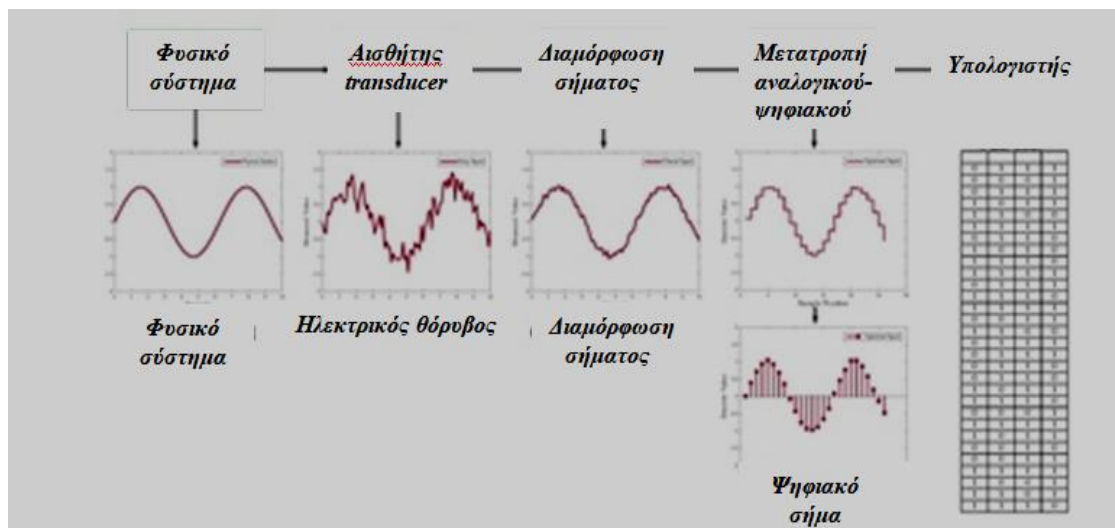
Προσεγγίσεις βάσει δεδομένων. Στην προσέγγιση αυτή χρησιμοποιούνται δεδομένα που λαμβάνονται κατά την λειτουργία όπως, δόνησης, θερμικής απεικόνισης, δεδομένα ακουστικής εκπομπής κ.ά. Τα δεδομένα του μηχανήματος χρησιμοποιούνται ως είσοδος σε αλγόριθμους που προβλέπουν την διάγνωση σφαλμάτων και την πρόγνωση.

Συλλογή δεδομένων. Μέτρηση θεωρείται η πράξη με την οποία προσδίνεται μια επιμέρους τιμή σε μια φυσική ποσότητα. Η ποσότητα αυτή γίνεται η μετρούμενη μεταβλητή. Η απόκτηση δεδομένων είναι η διαδικασία δειγματοληψίας σημάτων που μετρούν τις πραγματικές φυσικές συνθήκες του κόσμου και μετατρέπουν τα σήματα σε ψηφιακές αριθμητικές τιμές. Οι τιμές καταγράφονται και επεξεργάζονται από έναν ηλεκτρονικό υπολογιστή. Ο αισθητήρας είναι ένα στοιχείο, συνήθως ηλεκτρικό/ ηλεκτρονικό, που χρησιμοποιεί το σχετικό φυσικό φαινόμενο μέσω του οποίου αναγνωρίζεται η υπό μέτρηση φυσική ποσότητα. Οι αισθητήρες συλλέγουν και αποστέλλουν για καταγραφή και κατά συνέπεια επεξεργασία, μέσω ηλεκτρονικών υπολογιστών, τεράστιες ποσότητες δεδομένων σε πραγματικό χρόνο. Οι αισθητήρες πρέπει επίσης να έχουν υψηλή συχνότητα καταγραφής και να μπορούν να ενσωματωθούν εύκολα σε σύνθετα συστήματα παραγωγής. Σύστημα μέτρησης είναι τα χρησιμοποιούμενα μηχανήματα για την ποσοτική έκφραση της φυσικής μεταβλητής. Ένα σύστημα μέτρησης, Σχήμα 2.1, αποτελείται από,

- τον αισθητήρα,
- τον μετατροπέα (transducer),
- τον επεξεργαστή σήματος και

- την παρουσίαση των μετρήσεων.

Ο μετατροπέας (transducer) μετατρέπει την μετρήσιμη φυσική ποσότητα, που λαμβάνεται από τον αισθητήρα, σε αναγνώσιμο σήμα, το οποίο δύναται να είναι ηλεκτρικό, συνήθως σε mVolt, μηχανικό, οπτικό ή άλλο. Ο επεξεργαστής του σήματος το μετασχηματίζει και το ενισχύει στο επιθυμητό μέγεθος τάσης. Κατόπιν, χρησιμοποιούνται ηθμοί (φίλτρα) για περαιτέρω ανάλυση. Τέλος, οι μετρήσεις αφού ψηφιοποιηθούν δίνουν τα αποτελέσματα που καταγράφονται συστηματικά και παρουσιάζονται σε μια επιθυμητή μορφή όπως, γραφικές παραστάσεις, εικόνες, αρχεία δεδομένων, video, κ.ά. Παρακάτω δίνεται μια περιγραφή των τρόπων με τους οποίους μπορεί κανείς να καταγράψει τις διάφορες διαταραχές που μπορεί να αποκαλύψουν τις πιθανές βλάβες της λειτουργίας των μηχανών/μηχανισμών.



Σχήμα 2.1 Σύστημα συλλογής ψηφιακών δεδομένων

Τεχνική δόνησης. Η πιο συχνά χρησιμοποιούμενη τεχνική για την παρακολούθηση της λειτουργίας ενός μηχανήματος/μηχανισμού είναι η τεχνική της δόνησης. Η αλλαγή της μορφής του φυσιολογικού, και κατά συνθήκη κανονικού σήματος δόνησης μιας μηχανής, χωρίς όμως αλλαγή της αρχικής της λειτουργίας, μπορεί να συνεπάγεται βλάβη του μηχανήματος. Τα σήματα της δόνησης συνήθως δημιουργούνται στα κινούμενα μέρη του μηχανήματος/μηχανισμού, π.χ. φθορές στο ρουλεμάν, στα κιβώτια των ταχυτήτων, φθορές στα παλινδρομικά εξαρτήματα κ.ά. Ένα ελαττωματικό ρουλεμάν επιδρά και σε άλλα μέρη της μηχανής και το τελικό σήμα που λαμβάνεται, λόγω των κραδασμών, είναι αρκετά περίπλοκο. Το εύρος συχνοτήτων των κραδασμών είναι

μεγάλο και μπορεί να αρχίζει από το κατώτατο όριο με τιμή κάτω από 20.0 Hz, και να εκτείνεται στα όρια της ακουστικής συχνότητας του ανθρώπου που φθάνει μέχρι και τα 20.0 kHz.

Τεχνική της θερμογραφίας. Η τεχνική της θερμογραφίας μετρά την εκπομπή υπέρυθρων ακτινοβολιών ενέργειας με τη χρήση θερμο-υπέρυθρων συσκευών μέτρησης. Με τον τρόπο αυτό κατά τη διαδικασία λειτουργίας, π.χ. ενός ρουλεμάν, ανιχνεύεται η ύπαρξη ελαττωμάτων. Τα πιο κοινά όργανα που χρησιμοποιούνται για τέτοιες μετρήσεις είναι οι κάμερες θερμικής ακτινοβολίας. Η διακύμανση της θερμότητας προκαλείται από την αλλαγή που επιφέρει η προβληματική λειτουργία της μηχανής/μηχανισμού. Η προβληματική λίπανση, το παραλαμβανόμενο φορτίο και η ταχύτητα λειτουργίας επιφέρουν διακυμάνσεις της θερμοκρασιακής κατανομής.

Τεχνική ακουστικής εκπομπής. Η ακουστική εκπομπή δημιουργείται από τις τάσεις που αναπτύσσονται πάνω σε ένα υλικό. Οι τάσεις αυτές εμφανίζονται όταν αναδιανέμονται οι δυνάμεις που ασκούνται πάνω στο υλικό. Όταν, π.χ. ένα ρουλεμάν είναι ελαττωματικό, δημιουργεί κραδασμούς πάνω στην μηχανή. Οι κραδασμοί αυτοί δημιουργούν ακουστικά κύματα που μπορούν να καταγραφούν και κατόπιν να επεξεργασθούν. Σε σύγκριση με τα σήματα που προκύπτουν από δόνηση, τα σήματα που λαμβάνεται από την ακουστική εκπομπή, λόγω ελαττωματικής λειτουργίας, είναι μικρότερα και πιθανότατα επηρεάζονται από τον κυρίαρχο θόρυβο και τους κραδασμούς. Για καλύτερη σαφήνεια στην λήψη πρέπει να ελαχιστοποιηθούν οι απώλειες ενέργειας κατά μήκος της διαδρομής διάδοσης του σήματος.

Μαγνητική ροή σήματος. Όταν ένα ρουλεμάν ηλεκτρικού κινητήρα λειτουργεί σε ελαττωματική κατάσταση, η ακτινική κίνηση του άξονα του κινητήρα οδηγεί σε μια μικρή μετατόπιση του δρομέα. Αυτό έχει σαν συνέπεια την αλλαγή της πυκνότητας της μαγνητικής ροής που δημιουργείται μεταξύ του στάτη και του ρότορα. Η επαγόμενη ηλεκτρική τάση προκαλεί διακύμανση του ρεύματος του στάτη. Η τεχνική της μαγνητικής ροής σήματος στον στάτη χρησιμοποιεί μη-επεμβατικούς αισθητήρες για την παρακολούθηση της διακύμανσης του ρεύματος.

Τεχνική παρακολούθησης των λαδιών και των υπολειμμάτων. Η εφαρμογή της τεχνικής παρακολούθησης λαδιών και υπολειμμάτων μιας μηχανής, που λαμβάνονται κατά την συντήρηση ή με διαφορετικό άλλο τρόπο, είναι μια συχνά χρησιμοποιούμενη προσέγγιση και αποτελεί τμήμα της επιστήμης της Τριβολογίας για την παρακολούθηση της κατάστασης του μηχανήματος. Η κατάσταση της σωστής λειτουργίας ενός μηχανικού στοιχείου μπορεί να παρακολουθείται με την ανάλυση των ιδιοτήτων και των σωματιδίων του λιπαντικού. Η εφαρμογή αυτή είναι σχετικά απλή.

2.2 Λήψεις δεδομένων και συστήματα επεξεργασίας

Σύστημα DAQ. Ένα σύστημα απόκτησης δεδομένων είναι ένα ενιαίο σύνολο υλικού (hardware) και λογισμικού (software) που επιτρέπει να μετρήσουν ή να ελέγξουν τα χαρακτηριστικά κάποιου φυσικού φαινομένου του πραγματικού κόσμου, (Λήψη και επεξεργασία δεδομένων, 2021). Η απόκτηση δεδομένων ξεκινά με το φυσικό φαινόμενο ή τη φυσική ιδιότητα που πρέπει να μετρηθεί όπως, θερμοκρασία, ένταση φωτός, πίεση αερίου, ροή υγρού, δύναμη κ.ά. Ένα σύστημα απόκτησης για τη μέτρηση διαφορετικών ιδιοτήτων εξαρτάται από τους αισθητήρες που είναι κατάλληλοι για την ανίχνευση αυτών των ιδιοτήτων. Ένα πλήρες σύστημα απόκτησης δεδομένων αποτελείται από υλικό Data Acquisition (DAQ), τους αισθητήρες και έναν υπολογιστή που χρησιμοποιεί λογισμικό κατάλληλο για το DAQ. Το έργο της εκτέλεσης τέτοιων μετασχηματισμών από φυσικό φαινόμενο σε ηλεκτρικό σήμα γίνεται από συσκευές που ονομάζονται αισθητήρες (transducers). Τα συστήματα απόκτησης δεδομένων, όπως, DAS, DAQ ή DAU, συνήθως μετατρέπουν αναλογικές κυματομορφές σε ψηφιακές τιμές. Οι λήψεις και επεξεργασίες των δεδομένων ελέγχονται συνήθως από προγράμματα λογισμικού χρησιμοποιώντας διάφορες γλώσσες προγραμματισμού γενικής χρήσης, όπως Python, Assembly, Basic, C, C++, Fortran, Java, LabVIEW, Lisp, Pascal κ.λπ. Στην επόμενη παράγραφο του παρόντος κειμένου δίνεται μια περιγραφή του συστήματος λήψεως και επεξεργασίας δεδομένων LabVIEW. Εάν το σήμα που λαμβάνεται δεν είναι κατάλληλο για άμεση χρήση από το υλικό DAQ μπορεί η ρύθμιση να είναι απαραίτητη. Στις περισσότερες περιπτώσεις το ηλεκτρικό σήμα πρέπει να φιλτραριστεί, να διαμορφωθεί ή να ενισχυθεί.

LabVIEW. Το Laboratory Virtual Instrument Engineering Workbench (LabVIEW) είναι μια ισχυρή γλώσσα προγραμματισμού για ηλεκτρονικούς υπολογιστές, η οποία

στηρίζεται στη χρήση επιστημονικών οργάνων για τη μεταφορά των δεδομένων και στη συνέχεια την ανάλυση αυτών. Το LabVIEW ξεφεύγει από την μέχρι τώρα φύση των παραδοσιακών γλώσσων προγραμματισμού και παρουσιάζει ένα γραφικό περιβάλλον προγραμματισμού με όλα τα απαιτούμενα εργαλεία για την καταγραφή, την ανάλυση και την παρουσίαση των δεδομένων. Με τη γλώσσα του γραφικού προγραμματισμού μπορεί κανείς να προγραμματίσει ομάδα από γραφικές παραστάσεις σε στυλ “windows”. Το σύστημα ενώνει τα δεδομένα που έχουν ληφθεί, πραγματοποιεί την ανάλυση και την τελική παρουσίαση. Για τα δεδομένα που χρειάζεται να αναλυθούν, υπάρχει μια εκτεταμένη βιβλιοθήκη που περιέχει εξισώσεις για την λήψη σήματος, για μεταβαλλόμενο σήμα, για φίλτρα, για στατιστική ανάλυση, για παλινδρόμηση, για γραμμική άλγεβρα και για αριθμητική πράξη. Το LabVIEW χαρακτηρίζεται από τη φύση του ως ένα γραφικό πρόγραμμα, είναι αναμφίβολα ένα πακέτο παρουσίασης δεδομένων.

3 Μηχανική μάθηση

3.1 Εισαγωγή

Η μηχανική μάθηση ανήκει στην επιστήμη των υπολογιστών. Η αναγνώριση προτύπων και η υπολογιστική μάθηση στην τεχνητή νοημοσύνη βοήθησαν στην ανάπτυξη της επιστήμης αυτής. Στο γνωστικό αντικείμενο της ανάλυσης των δεδομένων, η μηχανική μάθηση χρησιμοποιείται για την ανάπτυξη πολύπλοκων υπολογιστικών μοντέλων και σχετικών αλγορίθμων που οδηγούν στην κατανόηση και την σωστή πρόβλεψη των προβλημάτων του πραγματικού κόσμου. Τα μοντέλα επιτρέπουν στους επιστήμονες των δεδομένων, στους μηχανικούς και στους αναλυτές συστημάτων να παίρνουν αξιόπιστες αποφάσεις. Τα αποτελέσματα, εάν οι υπολογισμοί είναι ακριβείς θα δείξουν τις συσχετίσεις μεταξύ των δεδομένων. Οι αλγόριθμοι της μηχανικής μάθησης μπορούν να μαθαίνουν από τα υπάρχοντα δεδομένα και να προβλέπουν σχετικά με αυτά. Οι αλγόριθμοι αναπτύσσουν μοντέλα, που στηρίζονται σε πειραματικά δεδομένα, προκειμένου να κάνουν προβλέψεις βασισόμενες σε αυτά. Προκειμένου να εφαρμοσθεί σε επιχειρήσεις, η μηχανική μάθηση αναφέρεται ως προγνωστική ανάλυση. Ένα υποσύνολο της μηχανικής μάθησης σχετίζεται στενά με την υπολογιστική στατιστική. Όμως, η όλη αυτή επιστήμη δεν είναι στατιστική μάθηση. Η μελέτη της μαθηματικής βελτιστοποίησης παρέχει τις μεθόδους και τις θεωρίες για την ανάπτυξη της μηχανικής μάθησης. Η εξόρυξη δεδομένων είναι ένας σχετικός τομέας μελέτης και εστιάζεται στην διερευνητική ανάλυση δεδομένων μέσω μη-εποπτευόμενης μάθησης.

Η εκμάθηση μηχανών για την ανίχνευση των σφαλμάτων στην λειτουργία των μηχανών/μηχανισμών επικεντρώνεται στην,

- ανίχνευση ανωμαλιών και
- στην ταξινόμηση των σφαλμάτων.

Ανίχνευση ανωμαλιών. Αυτή είναι η διαδικασία αναγνώρισης μετρήσεων που δεν είναι συμβατές με τα άλλα πρότυπα του συνόλου των δεδομένων. Ένα τμήμα της μηχανικής μάθησης είναι και η ανίχνευση ανωμαλιών λειτουργίας σε μηχανικά και μη-μηχανικά συστήματα. Οι μετρήσεις που λαμβάνονται από ελαττωματική λειτουργία δείχνουν ότι η κατάσταση του μηχανήματος από λειτουργική άποψη έχει διαφοροποιηθεί, π.χ. προέκυψε δηλ. πρόβλημα. Η ανίχνευση ανωμαλιών δεν απαιτεί δείγματα δεδομένων που πάρθηκαν από διαφορετικές πιθανές συνθήκες λειτουργίας, αλλά μόνο δείγματα

δεδομένων που λαμβάνονται σε κανονικές συνθήκες λειτουργίας. Ως εκ τούτου η ανίχνευση ανωμαλιών είναι σχετικά απλή ως προς την εφαρμογή. Τα χαρακτηριστικά του προβλήματος χρησιμοποιούνται από αλγόριθμους, όπως μηχανές διανυσμάτων υποστήριξης SVM, κατανομής Gauss, μοντέλα Markov και τεχνητά νευρωνικά δίκτυα.

Ανίχνευση σφάλματος. Σε αντίθεση με την ανίχνευση ανωμαλιών, υπάρχει η ανίχνευση σφάλματος. Η κύρια διαφορά είναι ότι εκτός από τα δείγματα, που λαμβάνονται κάτω από κανονικές συνθήκες λειτουργίας, υπάρχουν και δείγματα από μη-φυσιολογικές συνθήκες και χρησιμοποιούνται για την εκπαίδευση των μοντέλων μηχανικής μάθησης. Ενώ η ανίχνευση ανωμαλιών μπορεί να εντοπίσει μόνο αποκλίσεις από τις κανονικές συνθήκες, η ανίχνευση σφάλματος μπορεί να προσδιορίσει σε ποιο τμήμα της μηχανής/μηχανισμού έχει προκληθεί. Παρόλα αυτά, το μειονέκτημα για την ανίχνευση σφάλματος είναι ότι τα δεδομένα, από τις διαφορετικές συνθήκες λειτουργίας, πρέπει να είναι άμεσα διαθέσιμα. Η ανίχνευση σφαλμάτων χρησιμοποιεί λειτουργίες που υποβάλλονται σε επεξεργασία με αλγόριθμους μηχανικής μάθησης, όπως k-πλησιέστεροι ταξινομητές kNN, ταξινομητές Bayes, δέντρα αποφάσεων και ταξινομητές πολλαπλών επιπέδων perceptrons. Χρησιμοποιώντας αυτούς τους ταξινομητές, μπορεί να ανιχνευθούν με ακρίβεια διάφοροι τύποι σφαλμάτων.

3.2 Τύποι αλγορίθμων μάθησης

Οι αλγόριθμοι εκμάθησης μπορούν να ταξινομηθούν στην εποπτευόμενη μάθηση και στη μη-εποπτευόμενη μάθηση, (Machine learning classification, 2013).

Εποπτευόμενη μάθηση. Οι εποπτευόμενοι αλγόριθμοι χρησιμοποιούνται όταν είναι γνωστές οι ετικέτες των δεδομένων. Αυτοί οι αλγόριθμοι δημιουργούν ένα μαθηματικό μοντέλο που περιέχει τόσο τις εισόδους των δεδομένων όσο και τα επιθυμητά αποτελέσματα δηλ. τις εξόδους. Μερικά από τα δεδομένα χρησιμοποιούνται ως δεδομένα εκπαίδευσης (training data). Στο μαθηματικό μοντέλο, κάθε παράδειγμα εκπαίδευσης αντιπροσωπεύεται από έναν πίνακα, που μερικές φορές ονομάζεται και διανυσματικό στοιχείο. Οι εποπτευόμενοι αλγόριθμοι μάθησης, μέσω της επαναληπτικής βελτιστοποίησης, μαθαίνουν μια συνάρτηση που μπορεί να χρησιμοποιηθεί για την πρόβλεψη που σχετίζεται με νέες εισόδους. Η βέλτιστη λειτουργία θα επιτρέψει στον αλγόριθμο να καθορίσει ορθά την έξοδο για εισόδους που δεν ήταν μέρος των

εκπαιδευτικών δεδομένων. Ένας αλγόριθμος που βελτιώνει την ακρίβεια των εξόδων ή των προβλέψεων του με την πάροδο του χρόνου λέγεται ότι έμαθε να εκτελεί αυτήν την εργασία.

Η χρήση εποπτευόμενης μάθησης είναι και ένα πρόβλημα ταξινόμησης. Χρησιμοποιώντας την εκπαίδευση δεδομένων ο αλγόριθμος δημιουργεί ένα μοντέλο στο οποίο εκχωρεί τον τύπο του ελαττώματος που ανήκουν τα δεδομένα. Γενικά, τα δεδομένα προ-επεξεργάζονται και στη συνέχεια γίνεται ταξινόμηση αυτών στις περιπτώσεις σφάλματος με τη βοήθεια των ετικετών τους. Χρησιμοποιούνται διάφοροι παράμετροι όπως, η ελάχιστη Ευκλείδεια απόσταση και η γενικευμένη Ευκλείδεια απόσταση για την ταξινόμηση των δεδομένων υπολογίζοντας ότι τα δεδομένα ανήκουν σε μια συγκεκριμένη κατηγορία. Έχουν πραγματοποιηθεί πολλές υπολογιστικές μελέτες χρησιμοποιώντας μη-παραμετρικές μεθόδους ταξινόμησης λόγω της ικανότητάς τους να χειρίζονται την τυχαία φύση των δεδομένων. Για μη-παραμετρική ταξινόμηση δεδομένων χρησιμοποιούνται μέθοδοι όπως, λειτουργίες ακτινικής βάσης ή radial basis function (rbf), νευρωνικά δίκτυα, μηχανές με υποστήριξη διανυσμάτων, SVM, και Multi Layer Perceptron (MLP).

Μη-εποπτευόμενη μάθηση. Η μη-εποπτευόμενη μάθηση χρησιμοποιείται σε προβλήματα ταξινόμησης όπου οι ετικέτες των δεδομένων δεν είναι γνωστές. Ένα παράδειγμα τέτοιου προβλήματος είναι η ομαδοποίηση δεδομένων όπως συγκέντρωση αναφορών ειδήσεων που ανήκουν στην ίδια κατηγορία π.χ. αθλητισμός, επιστήμη, τέχνη κ.ά. Ο αριθμός και οι ετικέτες των κατηγοριών σε αυτήν την περίπτωση δεν καθορίζονται.

3.3 Επεξηγηματικοί όροι μηχανικής εκμάθησης

Μετρική. Είναι η μέση διαφορά μεταξύ των προβλέψεων και της σωστής τιμής για την παρατήρηση αυτή.

- Η χαμηλή διασπορά μπορεί να σημαίνει ότι κάθε πρόβλεψη είναι σωστή. Θα μπορούσε επίσης να σημαίνει ότι οι μισές από τις προβλέψεις είναι πάνω από τις πραγματικές τους τιμές και οι μισές είναι κάτω, σε ίση αναλογία, με αποτέλεσμα χαμηλή μέση διαφορά.

- Η υψηλή διασπορά, με χαμηλή διακύμανση, υποδηλώνει ότι ο αλγόριθμος μπορεί να μην είναι κατάλληλος και έχει χρησιμοποιηθεί λάθος αρχιτεκτονική για την εργασία.

Ταξινόμηση. Προβλέπεται η έξοδος και ταξινόμηση των αποτελεσμάτων

- Η δυαδική ταξινόμηση προβλέπει ένα από τα δύο πιθανά αποτελέσματα π.χ. είναι ανεπιθύμητο ή επιθυμητό.
- Η ταξινόμηση πολλαπλών τάξεων προβλέπει ένα από τα πολλαπλά πιθανά αποτελέσματα π.χ. αυτή είναι μια φωτογραφία γάτας, σκύλου, αλόγου ή ανθρώπου.

Ομαδοποίηση. Μη-εποπτευόμενη ομαδοποίηση δεδομένων σε συσσωρευμένα δεδομένα.

Πίνακας σύγκρισης. Είναι ο πίνακας που περιγράφει την απόδοση ενός αλγόριθμου ταξινόμησης ομαδοποιώντας τις προβλέψεις και θέτοντας αυτές σε 4 κατηγορίες.

- True Positive (TP): υπάρχει σωστή πρόβλεψη.
- True Negative (TN): υπάρχει σωστή μη-πρόβλεψη.
- False Positive (FP): υπάρχει λανθασμένα σωστή πρόβλεψη.
- False Negative (FN): υπάρχει λανθασμένα σωστή μη-πρόβλεψη.

Βαθιά μάθηση. Η βαθιά μάθηση (Deep Learning) είναι ένα μέρος μιας ευρύτερης οικογένειας μεθόδων μηχανικής μάθησης που βασίζεται σε τεχνητά νευρωνικά δίκτυα με εκμάθηση αναπαραγωγής. Η μάθηση μπορεί να είναι επιβλεπόμενη, ημι-εποπτευόμενη ή μη-επιβλεπόμενη. Αρχιτεκτονικές βαθιάς μάθησης, όπως βαθιά νευρωνικά δίκτυα, επαναλαμβανόμενα νευρωνικά δίκτυα έχουν εφαρμοστεί σε πεδία όπως, όραση μηχανής, αναγνώριση ομιλίας, επεξεργασία φυσικής γλώσσας, φιλτράρισμα κοινωνικών δικτύων κ.ά.

Διάσταση. Η διάσταση για τη επιστήμη της μηχανικής μάθησης και της επιστήμης της επεξεργασίας δεδομένων έχει διαφορετική ερμηνεία από ότι στις φυσικές επιστήμες. Η διάσταση στην μηχανική μάθηση σημαίνει πόσα χαρακτηριστικά υπάρχουν στο σύνολο των δεδομένων.

Χαρακτηριστικά. Σ' ένα σύνολο δεδομένων ένα χαρακτηριστικό αντιπροσωπεύει απλά ένα χαρακτηριστικό και συνδυασμό τιμών.

Ετικέτα. Σε ένα σύνολο δεδομένων, που χρησιμοποιείται για την ταξινόμηση σε διαφορετικά είδη, τα χαρακτηριστικά μπορεί να περιγράφουν επί μέρους ιδιότητες του είδους ενώ η ετικέτα θα είναι το είδος αυτό καθ' αυτό.

Μηχανική μάθηση. Στην απλή μάθηση γλωσσών, η μηχανική μάθηση είναι ένα πεδίο στο οποίο οι αλγόριθμοι που δημιουργούνται έχουν την ικανότητα να μαθαίνουν από μόνοι τους ή να προβλέπουν το μέλλον για μη-ορατά δεδομένα ή για πρακτικές εφαρμογές.

Υπερβολική τοποθέτηση. Η υπερβολική τοποθέτηση (over fitting) εμφανίζεται όταν ο αλγόριθμος μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης (training) και ενσωματώνει λεπτομέρειες και θορύβους ειδικά για το σύνολο δεδομένων. Στην περίπτωση αυτή ο αλγόριθμος αποδίδει εξαιρετικά το σύνολο των δεδομένων εκπαίδευσης αλλά αποδίδει άσχημα το σύνολο των δοκιμών (test) ή αποδίδει άσχημα σε αντίστοιχα δεδομένα του πραγματικού κόσμου.

Υποτονική τοποθέτηση. Η υποτονική τοποθέτηση (under fitting) εμφανίζεται όταν ο αλγόριθμος υπερ-γενικεύει και δεν ενσωματώνει σχετικές παραλλαγές στα δεδομένα που θα δώσουν στον αλγόριθμο περισσότερη προγνωστική ισχύ. Στην περίπτωση αυτή ένας τέτοιος αλγόριθμος αποδίδει άσχημα το σύνολο των δεδομένων εκπαίδευσης αλλά άσχημα και το σύνολο των δοκιμών.

Παράμετροι. Οι παράμετροι είναι ιδιότητες των εκπαιδευτικών δεδομένων που μαθαίνονται με την εκπαίδευση ενός αλγόριθμου μηχανικής μάθησης ή ενός ταξινομητή. Προσαρμόζονται χρησιμοποιώντας αλγόριθμους βελτιστοποίησης και είναι μοναδικοί σε κάθε πείραμα. Παραδείγματα παραμέτρων μπορεί να είναι,

- βάρη σε ένα τεχνητό νευρωνικό δίκτυο,
- διανύσματα υποστήριξης σε μια μηχανή φορέα υποστήριξης,
- συντελεστές σε γραμμική ή λογιστική παλινδρόμηση κ.ά..

Ακρίβεια (Accuracy). Η ακρίβεια A αναφέρεται στο πόσο κοντά είναι μια μέτρηση στην πραγματική ή την αποδεκτή τιμή,

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$

Ακρίβεια (Precision). Η ακρίβεια P αναφέρεται στο πόσο κοντά μεταξύ τους είναι οι μετρήσεις του ίδιου αντικειμένου. Στο πλαίσιο της δυαδικής ταξινόμησης, Ναι/Όχι, η ακρίβεια μετρά την απόδοση του αλγόριθμου στην ταξινόμηση θετικών παρατηρήσεων, “Ναι”. Με άλλα λόγια, όταν προβλέπεται θετική τιμή, πόσο συχνά είναι σωστή η πρόβλεψη,

$$P = \frac{TP}{TP + FP}$$

Ανάκληση (Recall). Στο πλαίσιο της δυαδικής ταξινόμησης, Ναι/Όχι, η ανάκληση R μετρά πόσο “ευαίσθητη” είναι η ταξινόμηση στον εντοπισμό θετικών παρουσιών. Με άλλα λόγια, για όλες τις αληθινές παρατηρήσεις στο δείγμα, να εξακριβωθεί πόσες αντιλήφθηκε ο αλγόριθμος,

$$R = \frac{TP}{TP + FN}$$

Ανάκληση σχετικά με την ακρίβεια. Ας υποθεθεί ότι αναλύονται ανιχνεύσεις εγκεφάλου και γίνεται προσπάθεια να προβλεφθεί εάν υπάρχει συγκεκριμένη ασθένεια True ή όχι False.

- Η ακρίβεια είναι το επί τοις εκατό % των αληθινών προβλέψεων που ήταν πραγματικά σωστές. Αν υποθεθεί ότι μια εικόνα είναι αληθινή από 100 εικόνες και αυτή η εικόνα είναι η πραγματικά αληθινή, τότε η ακρίβειά της είναι 100.0 %. Ωστόσο, τα αποτελέσματά δεν είναι χρήσιμα, επειδή χάθηκαν π.χ. 10 προβλέψεις. Η προσπάθεια ήταν εξαιρετικά ακριβής, χρειάζεται όμως και άλλη προσπάθεια για σωστή ανάλυση.

- Η ανάκληση παρέχει έναν τρόπο να δει κανείς πόσο καλός είναι ο αλγόριθμος. Ας υποθεθεί ότι υπάρχουν 100 εικόνες, 10 με ασθένεια και προβλέφθηκε σωστά ότι μόνο ένας είχε ασθένεια. Η ακρίβεια είναι 100.0 %, αλλά η ευαισθησία είναι 10.0 %. Η τέλεια ευαισθησία απαιτεί να προβλεφθούν και οι 10 με ασθένεια.

Κατάτμηση (segmentation). Είναι η διαδικασία διαχωρισμού ενός συνόλου δεδομένων σε πολλά διαφορετικά σύνολα. Αυτός ο διαχωρισμός γίνεται έτσι ώστε τα μέλη του ίδιου τμήματος να είναι παρόμοια μεταξύ τους και διαφορετικά από τα μέλη άλλων τμημάτων.

Δοκιμή (test) δεδομένων. Ένα σύνολο παρατηρήσεων που χρησιμοποιήθηκαν στο τέλος της εκπαίδευσης και της επικύρωσης του αλγόριθμου για την αξιολόγηση της προγνωστικής ισχύος του αλγόριθμου. Πόσο ισχυρός είναι δηλαδή ο αλγόριθμος για να επαληθευθούν δεδομένα του πραγματικού χώρου.

Εκπαίδευση (training) δεδομένων. Ένα σύνολο παρατηρήσεων που χρησιμοποιούνται για τη δημιουργία μοντέλων μηχανικής μάθησης.

Διακύμανση. Πόσο κοντά είναι οι προβλέψεις για μια συγκεκριμένη παρατήρηση σε σχέση μεταξύ τους.

- Η χαμηλή διακύμανση δηλώνει ότι ο αλγόριθμος είναι εσωτερικά συνεπής, με τις προβλέψεις, μετά από κάθε επανάληψη, να διαφέρουν λίγο μεταξύ τους.
- Η υψηλή διακύμανση, με χαμηλή μεροληψία, υποδηλώνει ότι ο αλγόριθμος μπορεί να δίνει υπερβολική τοποθέτηση και να διαβάξει τον θόρυβο που υπάρχει σε κάθε δεδομένα εκπαίδευσης.

3.4 Αλγόριθμοι για μηχανική εκμάθηση και κατηγοριοποίηση

3.4.1 Naive Bayes

Οι ταξινομητές Naive Bayes βασίζονται στην εφαρμογή του θεωρήματος του Bayes και είναι μια κατηγορία ταξινομητών. Στη ταξινόμηση αυτή υπάρχουν ισχυρές παραδοχές ανεξαρτησίας μεταξύ των χαρακτηριστικών του προβλήματος. Ο αλγόριθμος Naive Bayes, σε συνδυασμό με την εκτίμηση του πυρήνα (kernel), μπορεί να επιτύχει υψηλά επίπεδα ακρίβειας,, (McCallum, 2019), και είναι εξαιρετικά επεκτάσιμος. Οι αλγόριθμοι απαιτούν έναν αριθμό γραμμικών παραμέτρων σε ένα πρόβλημα μάθησης. Η

εκπαίδευση για την εύρεση της μέγιστης πιθανότητας μπορεί να γίνει με την αξιολόγηση μιας έκφρασης και δεν απαιτεί ακριβή επαναληπτική προσέγγιση όπως γίνεται αυτό σε πολλούς άλλους ταξινομητές. Η εκπαίδευση απαιτεί ανάλογο χρόνο. Ο αλγόριθμος είναι ένας από τους απλούστερους αλγόριθμους για μάθηση. Σε πολλές περιπτώσεις είναι ενδιαφέρον να αναφερθεί ότι μπορεί να ξεπεράσει τους περισσότερους από τους εξελιγμένους αλγόριθμους μάθησης, (Gosavi, 2014). Ο ταξινομητής χρησιμοποιεί την εκτίμηση της μέγιστης πιθανότητας για την ταξινόμηση νέων δειγμάτων που βασίζεται στο θεώρημα του Bayes,

$$P(A/B) = \frac{P(B/A)P(A)}{P(B)}$$

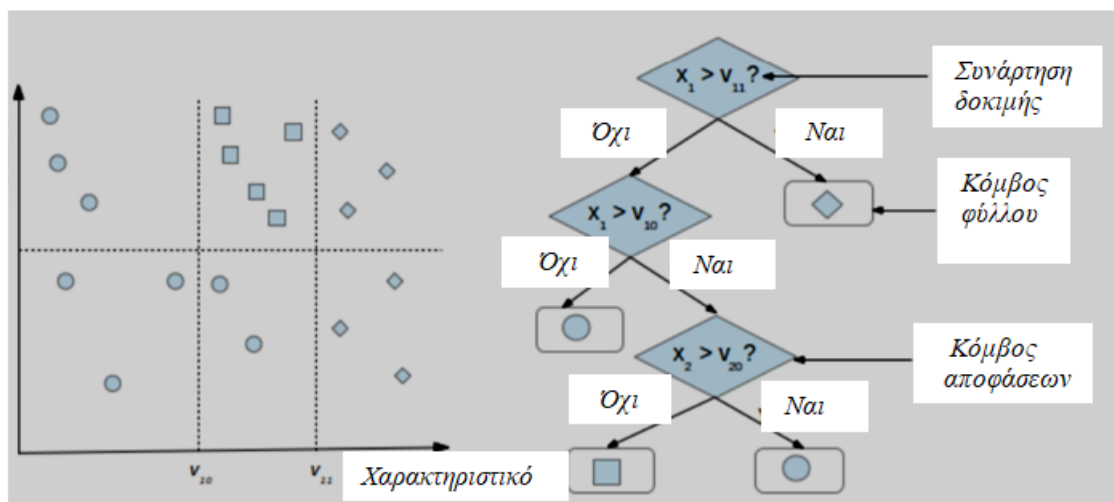
όπου, $P(A)$ και $P(B)$ είναι οι πιθανότητες των A και B , και $P(A|B)$ και $P(B|A)$ είναι οι πιθανότητες A με συνθήκη B , και οι πιθανότητες B με συνθήκη A , αντίστοιχα. Κατά τη διάρκεια της εκπαίδευσης του ταξινομητή η πιθανότητα εύρεσης ενός παραδείγματος για κάθε κατηγορία υπολογίζεται και αποθηκεύεται ως η προηγούμενη πιθανότητα για αυτήν την κατηγορία. Επίσης, υπολογίζεται η πιθανότητα για περιπτώσεις συμβάντος x δεδομένης της κατηγορίας C_i . Η πιθανότητα $P(C_i|x)$ αναφέρεται ως προς την προηγούμενη πιθανότητα. Μια τάξη C_i επιλέγεται εάν,

$$P(C_i/x) = \max_k [P(C_k/x)]_k$$

δηλ. η τάξη με την μεγαλύτερη πιθανότητα. Ένα σαφές πλεονέκτημα της χρήσης των Naive Bayes είναι ότι ο αλγόριθμος είναι γρήγορος να εκπαιδεύσει και να ταξινομήσει το δεδομένα. Αυτό γίνεται διότι για να υπολογίσει τις πιθανότητες και να τις αποθηκεύσει σε έναν πίνακα σαρώνει τη βάση των δεδομένων έτσι ώστε να τη χρησιμοποιήσει για ταξινομήσει σε μελλοντικά παραδείγματα. Επίσης, ο αλγόριθμος είναι εγγενώς πιο ανθεκτικός σε σχέση με χαρακτηριστικά που είναι άσχετα μεταξύ τους. Ο πληθυσμός του δείγματος πρέπει να είναι πραγματικά αντιπροσωπευτικός των πραγματικών δεδομένων. Επίσης, σημαντικό μειονέκτημα είναι ότι ο ταξινομητής θεωρεί ότι τα χαρακτηριστικά είναι ανεξάρτητα μεταξύ τους. Ωστόσο, σε πολλές περιπτώσεις ο ταξινομητής αποδίδει αρκετά καλά ακόμη και σε περιπτώσεις όπου τα χαρακτηριστικά εξαρτώνται το ένα από το άλλο.

3.4.2 Δέντρα αποφάσεων

Τα δέντρα απόφασης είναι ιεραρχικά μοντέλα, όπου κάθε βήμα είναι μια συνάρτηση δοκιμής μη-καθορισμένης τιμής ενός χαρακτηριστικού έναντι μιας καθορισμένης τιμής, (Gosavi, 2014). Τα ιεραρχικά βήματα καλούνται κόμβοι αποφάσεων. Μια δοκιμή υλοποιείται με τη μορφή συνάρτησης με διακριτά αποτελέσματα που αναφέρονται ως κλάδοι. Στους κόμβους αυτούς εφαρμόζονται δοκιμές αναδρομικά σε ένα χαρακτηριστικό ή ένα σύνολο χαρακτηριστικών του παραδείγματος των δεδομένων, έως ότου φτάσει στο τέλος του δέντρου και ενεργοποιήσει το κόμβο των φύλλων ο οποίος αντιπροσωπεύει την έξοδο. Ένα απλό δέντρο αποφάσεων απεικονίζεται στο Σχήμα 3.1.




Σχήμα 3.1 Δένδρο αποφάσεων

Οι αλγόριθμοι εκμάθησης δέντρων αποφάσεων χρησιμοποιούνται για τη λήψη αποφάσεων. Οι ID3, C4.5 είναι μερικά μόνο παραδείγματα αυτών των αλγορίθμων. Στην περίπτωση των δέντρων αποφάσεων, η εκπαίδευση γίνεται με το να επιλέγονται χαρακτηριστικά που παρέχουν τις περισσότερες πληροφορίες σχετικά με το σύνολο κατάρτισης. Στη συνέχεια κατασκευάζεται το δέντρο από πάνω προς τα κάτω. Άλλοι προηγμένοι αλγόριθμοι, όπως ο Ripper [C+95], βασίζονται στην ίδια προσέγγιση και μετά χρησιμοποιούν κλάδεμα για τη μείωση του ελαττώματος της εκπαίδευσης. Τα δέντρα αποφάσεων χρησιμοποιούν μια προσέγγιση “λευκού κουτιού”, όπου η εσωτερική λήψη αποφάσεων και η δομή του δέντρου είναι ορατές στον χρήστη. Αυτό διευκολύνει την απεικόνιση και την ερμηνεία των δέντρων απόφασης, (Kotsianti, 2013). Τα δέντρα αποφάσεων εκτελούν επίσης έλεγχο χαρακτηριστικών με σκοπό να τοποθετήσουν τα

λιγότερο ενημερωτικά χαρακτηριστικά κοντά σε κόμβους φύλλων. Ένα μειονέκτημα των δέντρων απόφασης είναι ότι μπορούν να δημιουργήσουν πολύπλοκα δέντρα που δεν γενικεύουν καλά τα δεδομένα, δηλ. την υπερ-τοποθέτηση των δεδομένων.

3.4.3 Multi-Layer Perceptron

Ο Multi-Layer Perceptron (MLP) είναι ένας μοντέλο τεχνητού νευρωνικού δικτύου, (Gosavi, 2014). Σε αυτό τον αλγόριθμο, κάθε χαρακτηριστικό και έξοδος παρουσιάζονται ως κόμβοι, και οι κόμβοι χαρακτηριστικών σε κάθε επίπεδο συνδέονται με το ανώτερο επίπεδο χρησιμοποιώντας βάρη ή συνάψεις. Το Σχήμα 3.2 είναι ένα παράδειγμα ενός σχετικά απλού, δύο στρωμάτων perceptron.



Σχήμα 3.2 Δύο επιπέδων Perceptron

Οι εισοδοι x_1, x_2, \dots, x_k είναι τα χαρακτηριστικά και $x_0 = +1$ είναι ένα στοιχείο που χρησιμοποιείται για να κάνει τον αλγόριθμο πιο γενικό επιτρέποντας στο χρήστη να τελειοποιήσει την έξοδο μετατοπίζοντας τη λειτουργία εξόδου. Ενώ, a , b είναι οι πίνακες των βαρών στις συνάψεις στο $x_0 = +1$ με το κρυφό στρώμα h_0 , και το κρυφό στρώμα με την έξοδο y , αντίστοιχα. Η έξοδος του perceptron στο Σχήμα 3.2 μπορεί να αναπαρασταθεί μαθηματικά ως,


$$y = \sum_{j=0}^n b_j \left(\sum_{i=1}^k (a_{ij} x_i + a_o) \right)$$

Κατά τη διάρκεια της εκπαίδευσης ενός perceptron, ο αλγόριθμος εκπαίδευσης θα προσπαθήσει να βρει το κατάλληλο αποτέλεσμα συνδέοντας τα βάρη. Μπορούν να κατασκευαστούν πολλαπλά στρώματα perceptrons με την εφαρμογή κρυφών στρωμάτων

κόμβων μεταξύ χαρακτηριστικών και εξόδου. Με αυτό τον τρόπο μπορεί να εφαρμοστούν μη-γραμμικές συναρτήσεις εξόδου. Ο βαθμός μη-γραμμικότητας εξαρτάται από τον αριθμό των κρυφών επιπέδων. Ο αλγόριθμος Back propagation [RHW85] είναι ένας από τους αλγόριθμους που χρησιμοποιούνται συνήθως για την εκπαίδευση MLP.

3.4.4 Η τεχνική SVM

Η τεχνική SVM. Η κατανόηση της υπολογιστικής τεχνικής Support Vector Machine (SVM) μπορεί να γίνει αντιληπτή με παράδειγμα όπως δείχνεται στο Σχήμα 3.3. Στη τεχνική αυτή, η γραμμή που χρησιμοποιείται για το διαχωρισμό των κλάσεων αναφέρεται ως υπερ-επίπεδο, (Idiot's guide to SVM, MIT, 2020).



Σχήμα 3.3 Μεγιστοποίηση του περιθωρίου μεταξύ των υποστηρικτικών διανυσμάτων (support vectors)

Τα σημεία των δεδομένων που βρίσκονται πλησιέστερα στο υπερ-επίπεδο ονομάζονται Support Vectors ή υποστηρικτικά διανύσματα και χρησιμοποιούνται για τη σχεδίαση της οριακής γραμμής ή επιπέδου προκειμένου για 3D ανάλυση. Χαρακτηριστικά της τεχνικής SVM είναι,

- Τα διανύσματα υποστήριξης είναι τα σημεία δεδομένων που βρίσκονται πιο κοντά στην επιφάνεια διαχωρισμού ή υπερ-επίπεδου.

- Είναι τα σημεία δεδομένων που είναι πιο δύσκολο να ταξινομηθούν.
- Έχουν άμεσο αντίκτυπο στη βέλτιστη θέση της επιφάνειας διαχωρισμού.
- Τα υποστηρικτικά διανύσματα είναι τα κρίσιμα στοιχεία του εκπαιδευτικού χώρου.
- Η τεχνική SVM βρίσκει τη βέλτιστη λύση. Είναι ένα πρόβλημα βελτιστοποίησης και μπορεί να λυθεί με ανάλογες τεχνικές, όπως η τεχνική Lagrange.
- Η τεχνική SVM μεγιστοποιεί το περιθώριο μεταξύ των υποστηρικτικών διανυσμάτων, Σχήμα 3.3.
- Η συνάρτηση καθορίζεται από ένα μικρό αριθμό εκπαιδευτικών δεδομένων.
- Όταν γίνεται η ταξινόμηση μέσω της τεχνικής SVM, τα δεδομένα μπορεί να είναι γραμμικά ή μη-γραμμικά.
- Υπάρχουν διαφορετικοί πυρήνες (kernels) που μπορούν να οριστούν σε έναν ταξινομητή SVM.
- Για ένα μη-γραμμικό σύνολο δεδομένων μπορεί να υπάρχουν πυρήνες όπως, radial basis function (rbf), πολυώνυμου κ.ά.


Από το Σχήμα 3.4 είναι προφανές ότι είναι δύσκολο να σχεδιασθεί μια γραμμική SVM στον 2D χώρο, (Gurucharan, 2020). Χαρτογραφούνται λοιπόν τα δεδομένα σε μια υψηλότερη διάσταση με μετασχηματισμό, π.χ. $z=x^2+y^2$ στο 3D χώρο, και σχεδιάζεται το υπερ-επίπεδο. Μετά αυτό το επίπεδο μεταφέρεται στο αρχικό που εδώ φαίνεται να είναι ένας κύκλος. Με αυτόν τον τρόπο, ο υπολογιστικός αλγόριθμος SVM μπορεί να χρησιμοποιηθεί για την ταξινόμηση μιας σειράς δεδομένων και να υποδειχθεί σε ποια κατηγορία ανήκει από το σύνολο δεδομένων.

Δεδομένα. Ας υποθεθεί ότι υπάρχει ένας αριθμός δεδομένων που ελήφθησαν από παρατηρήσεις, (Jiang et al. 2005). Τα δεδομένα αυτά είναι σε ζεύγη. Κάθε ζεύγος αποτελείται από,

- διανυσματικά δεδομένα $x_i, i=1,2,3\dots I$ και
- μια κλάση y_i που ανήκει στο $\{-1,+1\}$ για κάθε διάνυσμα x_i .

Τα x_i ανήκουν στην κλάση I εάν $y_i = +1$ και τα x_i ανήκουν στη κλάση II, εάν $y_i = -1$. Αυτά τα ζεύγη αποτελούν τα εκπαιδευτικά (training) δεδομένα. Για γραμμικά διαχωρίσιμα δεδομένα, μπορούν να προσδιορισθούν με ένα υπερ-επίπεδο $H(x)$ που τα

διαχωρίζει. Εάν η είσοδος x_i ανήκει σε θετική κλάση τότε για το διαχωρισμό υπερ-επίπεδο ισχύει $H(x) \geq 0$, και εάν το x_i ανήκει σε αρνητική κλάση τότε $H(x) < 0$.



Σχήμα 3.4 Ταξινόμηση σημείων δεδομένων που ανήκουν σε ορισμένη κατηγορία από το σύνολο των δεδομένων

Είσοδος. Τα δεδομένα εισόδου αποτελούνται από δείγματα εκπαιδευτικών ζευγών. Το δείγμα εισόδου αποτελείται από τα δεδομένα x_1, x_2, \dots, x_i και τα αποτελέσματα εξόδου είναι y_i . Συνήθως, μπορεί να υπάρχουν πολλά δεδομένα εισαγωγής x_i .

Εξόδος. Τα δεδομένα εξόδου αποτελούνται από ένα σύνολο w_i , όπου αντιστοιχεί ένα για κάθε ένα χαρακτηριστικό x_i , του οποίου ο γραμμικός συνδυασμός προβλέπει την τιμή του y . Υπάρχει ένα πλεονέκτημα, εδώ χρησιμοποιείται η βελτιστοποίηση της μεγιστοποίησης του περιθωρίου, όπως φαίνεται στο Σχήμα 3.3. Σκοπός είναι η μείωση του αριθμού των w_i , που είναι μη-μηδενικά, σε μικρό αριθμό που αντιστοιχούν στα σημαντικά χαρακτηριστικά για τον καθορισμό της διαχωριστικής γραμμής (υπερ-επίπεδο). Αυτά τα μη-μηδενικά w_i αντιστοιχούν στο διανύσματα υποστήριξης, επειδή διαμορφώνουν το διαχωριστικό υπερ-επίπεδο.


Υπερ-επίπεδα. Τα υπερ-επίπεδα ορίζονται, Σχήμα 3.5 ως,

$$H_1 = \bar{w} \cdot \bar{x}_i + b = \sum_{i=1}^l w_i x_i + b \geq +1 \quad y_i = +1$$

$$H_2 = \bar{w} \cdot \bar{x}_i + b = \sum_{i=1}^l w_i x_i + b \leq -1 \quad y_i = -1$$

d^+ είναι η πιο μικρή απόσταση από το πλησιέστερο σημείο ενώ,

d^- είναι η πιο μικρή απόσταση από το πλησιέστερο αρνητικό σημείο.



Σχήμα 3.5 Ορισμός υπερ-επιπέδων

Η απόσταση ενός σημείου (x_0, y_0) από την γραμμή $Ax+By+c=0$ είναι,

$$\frac{Ax_0 + By_0 + c}{\sqrt{A^2 + B^2}}$$

άρα, στην περίπτωση του επιπέδου γίνεται,

$$\frac{|\bar{w} \cdot \bar{x}_i + b|}{|\bar{w}|} = \frac{1}{|\bar{w}|}$$

και η απόσταση μεταξύ των επιπέδων H_1 και H_2 είναι, $\frac{2}{|\bar{w}|}$ οπότε πρέπει να ελαχιστοποιηθεί ο παρονομαστής για να μεγιστοποιηθεί η απόσταση μεταξύ των δυο επιπέδων. Με την συνθήκη ότι δεν υπάρχουν σημεία μεταξύ των H_1 και H_2 θα είναι,

Άρα, $y_i (\bar{w} \cdot \bar{x}_i) \geq 1$ στο πρόβλημα η συνάρτηση είναι,

$$f(x): \frac{1}{2} |\bar{w}|^2$$

και η συνθήκη που πρέπει να ικανοποιηθεί είναι,

$$g(x): [\bar{w} \bullet \bar{x}_i - b] - 1 = 0$$

Lagrange. Η Lagrange στην γενική περίπτωση είναι,

$$L(x, \alpha) = f(x) + \sum_{i=1}^l \alpha_i g_i(x)$$

όπου α_i είναι οι περιοριστικές συνθήκες Lagrange, με τον δείκτη i να μεταβάλλεται από $1, 2, 3, \dots, l$, όσος είναι δηλ. ο αριθμός των δεδομένων και l ο αριθμός των α . Κάθε ζεύγος δεδομένων αντιστοιχεί σε α_i . Εκείνα τα ζεύγη για τα οποία $\alpha_i \geq 0$ είναι τα υποστηρικτικά διανύσματα για τα οποία ισχύει η ελαχιστοποίηση του $\frac{1}{2}|\bar{w}|^2$. Όλα τα άλλα εκπαιδευτικά ζεύγη των δεδομένων που δίνουν $\alpha_i = 0$ αφαιρούνται από τα εκπαιδευτικά δεδομένα χωρίς να προκαλούν κανένα πρόβλημα στην επίλυση. Με παραγωγή θα προκύψουν $l+m$ εξισώσεις και κάθε μια τίθεται ίση με μηδέν. Οι l εξισώσεις με παραγωγή δίνουν τις συνθήκες των κλίσεων και οι m εξισώσεις με παραγωγή ως προς α_i δίνουν τις περιοριστικές συνθήκες των g_i . Σύμφωνα με τις $f(x)$ και $g(x)$ είναι,

$$\min L = \frac{1}{2}|\bar{w}|^2 - \sum_i \alpha_i [y_i(\bar{w} \bullet x_i + b) - 1] \text{ σε συνάρτηση } \bar{w} \text{ και } b \text{ με } \alpha_i > 0$$

ή
$$\min L = \frac{1}{2}|\bar{w}|^2 - \sum_i \alpha_i y_i (\bar{w} \bullet x_i + b) + \sum_i \alpha_i \text{ σε συνάρτηση } \bar{w} \text{ και } b \text{ με } \alpha_i > 0$$

Στην τεχνική SVM, με παραγωγή ως προς \bar{w} και b και θέτοντας ίσον με μηδέν, προκύπτει ότι,

$$\bar{w} = \sum_{i=1}^{m,l} \alpha_i y_i \bar{x}_i \qquad \sum_{i=1}^m \alpha_i y_i = 0$$

Lagrange Dual. Στο Lagrange Dual πρόβλημα, αντί για ελαχιστοποίηση με \bar{w} και b με συνθήκες για τα α , μπορεί κανείς να μεγιστοποιήσει για τα α με την προϋπόθεση ότι υπακούουν την ανωτέρω συνθήκη οπότε, η Lagrange Dual παίρνει την μορφή ως,

$$\max L_D(\alpha_i) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\bar{x}_i \bullet \bar{x}_j)$$

με συνθήκες,

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad i=1,2,3\dots l$$

όπου C είναι μια σταθερά (συντελεστής). Στην ανωτέρω εξίσωση δεν υπάρχει εξάρτηση από \bar{w} και b . Υπάρχει μόνο το εσωτερικό γινόμενο των διανυσμάτων. Εάν ληφθούν οι παράγωγοι ως προς α και τεθούν ίσοι με μηδέν λαμβάνεται η ακόλουθη εξίσωση ως προς α_i ,

$$\sum_{i=1}^l \alpha_i y_i = 0$$

Με γνωστά τα α_i , βρίσκονται και τα \bar{w} ,

$$\bar{w} = \sum_{i=1}^l \alpha_i y_i \bar{x}_i$$

Μετά την εκπαίδευση και την εύρεση των \bar{w} , δοθέντος αγνώστου σημείου \bar{u} που μετρήθηκε στα χαρακτηριστικά x_i , μπορεί κανείς να το κατηγοριοποιήσει κοιτάζοντας το πρόσημο της συνάρτησης $f(x)$,


$$f(x) = \bar{w} \bullet \bar{u} + b = \left(\sum_{i=1}^l \alpha_i y_i \bar{x}_i \bullet \bar{u} \right) + b$$

Το x ανήκει στην τάξη I εάν το πρόσημο της ανωτέρω συνάρτησης $f(x)$ είναι θετικό και το x ανήκει στην τάξη II εάν το πρόσημο της ανωτέρω συνάρτησης είναι αρνητικό, όπου

α_i και b είναι οι παράμετροι που καθορίζουν το υπερ-επίπεδο με βέλτιστη κατηγοριοποίηση.

Μη-γραμμικά προβλήματα, $K(x_i, x_j)$. Για μη-γραμμικά προβλήματα μπορεί να γίνει μετασχηματισμός π.χ. $\phi(x) \rightarrow [x^2, x]$ και λαμβάνεται γραμμικός διαχωρισμός, Σχήμα 3.6. Μετά τον μετασχηματισμό με την συνάρτηση ϕ αντί για το εσωτερικό γινόμενο $(\bar{x}_i \bullet \bar{x}_j)$ υπολογίζεται η συνάρτηση,

$$K(x_i, x_j) = (\phi(\bar{x}_i) \bullet \phi(\bar{x}_j))$$



Σχήμα 3.6 Μετασχηματισμός μη-γραμμικού προβλήματος και γραμμικός διαχωρισμός

Οπότε, αντί να υπολογισθεί για βελτιστοποίηση η συνάρτηση,

$$\max L_D(\alpha_i) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\bar{x}_i \bullet \bar{x}_j)$$

βελτιστοποιείται η,

$$\max L_D(\alpha_i) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j (\phi(\bar{x}_i) \bullet \phi(\bar{x}_j))$$

ή

$$\max L_D(\alpha_i) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j)$$


με συνθήκες,

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad i=1,2,3\dots l$$

Η επιλογή της συνάρτησης $K(x_i, x_j) = \phi(\bar{x}_i) \bullet \phi(\bar{x}_j)$ είναι σημαντικός παράγοντας για την επίλυση του προβλήματος. Παράδειγμα εφαρμογής στην παρούσα εργασία είναι η συνάρτηση radial basis function (rbf),

$$K(x_i, x_j) = \exp\left[-\frac{|x_i - x_j|^2}{2\sigma^2}\right]$$

Η χρήση της συνάρτησης πυρήνα (kernel) δείχνεται στο Σχήμα 3.7, όπου x_i είναι τα δεδομένα εκπαίδευσης εισόδου, $K(x_i, x_j)$ είναι ο πυρήνας kernel, τα y_i , εδώ πρόκειται για τα Y , είναι τα αποτελέσματα εκπαίδευσης και b οι συνθήκες bias.



Σχήμα 3.7 Χρήση της συνάρτησης πυρήνα (kernel)

Το μέγεθος σ^2 στον παρονομαστή της εκθετικής συνάρτησης $K(x_i, x_j)$ καθορίζεται εκ των προτέρων και αποτελεί την ουσιαστική παράμετρο της συνάρτησης kernel. Αλλαγές στις τιμές του σ^2 και του συντελεστή C στην συνθήκη,

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad i=1,2,3\dots l$$

επιφέρουν διαφοροποιήσεις στην συνάρτηση μετασχηματισμού $K(x_i, x_j)$ και στην κατανομή των χαρακτηριστικών στον χώρο και στηρίζονται σε εμπειρική γνώση. Στον αλγόριθμο SVM, διαφορετικές συναρτήσεις για την έκφραση του πυρήνα (kernel) και οι παράμετροι αυτής της συνάρτησης έχουν μεγάλο αντίκτυπο στον υπολογισμό των αποτελεσμάτων, (Zhang et al., 2017).

Για να βρεθεί το καλύτερο αποτέλεσμα πρόβλεψης του SVM, είναι σημαντικό να επιλεγεί η κατάλληλη παράμετρος σ^2 και ο συντελεστής C. Έτσι, είναι δύσκολο να διασφαλιστεί ότι το αποτέλεσμα της πρόβλεψης είναι το καλύτερο. Η σωστή επιλογή των σ^2 και του συντελεστή C μπορεί να γίνει με διάφορους υπολογισμούς. Στην παρούσα ανάλυση θα γίνει με κβαντικό γενετικό αλγόριθμο. Επομένως, εφαρμόζεται ο αλγόριθμος QGA που είναι ένα είδος ευρετικού αλγορίθμου αναζήτησης των βέλτιστων παραμέτρων του πυρήνα ώστε να επιτευχθεί το καλύτερο αποτέλεσμα πρόβλεψης για τον αλγόριθμο SVM.

4. Κβαντική Μηχανική

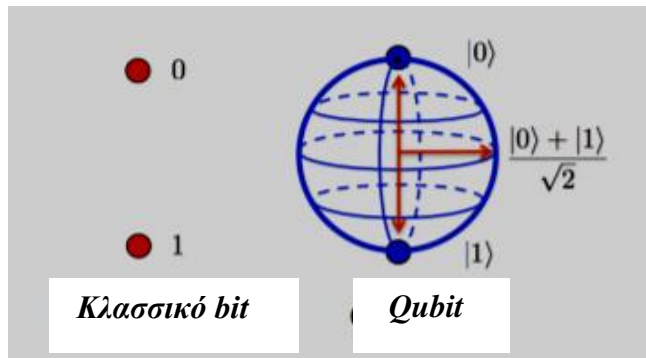
4.1 Εισαγωγή στη κβαντική μηχανική

Τα τελευταία χρόνια, οι αλγόριθμοι μηχανικής μάθησης, λόγω της αυξημένης υπολογιστικής ισχύος και της διαθεσιμότητας τεράστιων ποσοτήτων όγκου δεδομένων, έχουν τύχει εφαρμογής σε γνωστικά αντικείμενα από την υπολογιστική όραση έως τα πολύπλοκα παιχνίδια. Ωστόσο, αυτή η υπολογιστική τεχνική αρχίζει να αντιμετωπίζει αυξανόμενες προκλήσεις. Οι μονάδες επεξεργασίας γραφικών και μονάδες επεξεργασίας μπορούν να βελτιώσουν σημαντικά την απόδοση χωρίς όμως να μπορούν να προσφέρουν μια σημαντική λύση στο πρόβλημα.

Ο κβαντικός υπολογισμός βασίζεται στους νόμους της κβαντικής μηχανικής. Αξιοποιώντας προσεκτικά τις κβαντικές ιδιότητες, όπως η υπέρθεση (superposition) ή η διεμπλοκή (entanglement), οι κβαντικοί υπολογισμοί μπορούν να λύσουν αποτελεσματικά προβλήματα που είναι δύσκολα να λυθούν με κλασικούς υπολογισμούς. Με τον τρόπο αυτό οι υπολογισμοί αποκτούν αυξημένη ισχύ και παρέχουν νέους τρόπους για την επίλυση προβλημάτων φυσικών επιστημών της μηχανικής και των πολυπλοκοτήτων αυτών. Ο συνδυασμός της μηχανικής μάθησης και του κβαντικού υπολογισμού είναι γνωστός σαν κβαντική μηχανική μάθηση. Η κβαντική μάθηση χρησιμοποιείται σε διάφορους ερευνητικούς τομείς. Ο κβαντικός υπολογισμός συνδέεται με τη χρήση κβαντικών εννοιών, οι οποίες δεν είναι υπάρχουν στους κλασικούς υπολογισμούς. Μερικές από αυτές τις έννοιες που ενυπάρχουν, (Combarro, 2020), έχουν ως,

Qubit.

- Ένα κλασικό bit μπορεί να έχει δύο διαφορετικές τιμές 0 ή 1. Έχει πάντα διακεκριμένη τιμή.
- Ένα qubit μπορεί να δεχτεί απεριόριστα διαφορετικές τιμές. Είναι συνεχής μια συνάρτηση.
- Τα qubits υπάρχουν σε χώρο διανύσματος Hilbert. Για ένα qubit, ο χώρος έχει σαν βάσεις δύο στοιχεία που δηλώνονται με $|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$, $|1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$



Σχήμα 4.1 Κλασσικό bit και qubit

Αντίστοιχα, δύο qubits μπορούν να αναπαρασταθούν σε έναν τετρα-διάστατο γραμμικό διανυσματικό χώρο που περιγράφεται από τις ακόλουθες βάσεις,

$$|00\rangle = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, |01\rangle = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}, |10\rangle = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}, |11\rangle = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}$$

με

$$|\psi\rangle = a_{00} |00\rangle + a_{01} |01\rangle + a_{10} |10\rangle + a_{11} |11\rangle$$

και

$$\sum_{x,y=0}^1 |a_{x,y}|^2 = 1$$

Μέτρηση qubit. Ο τρόπος για να γίνει γνωστή η τιμή ενός qubit είναι να γίνει μια μέτρηση. Ωστόσο, το αποτέλεσμα της μέτρησης είναι τυχαίο και όταν γίνει η μέτρηση λαμβάνεται μόνο ένα (κλασσικό) κομμάτι πληροφορίας, δηλ. 0 ή 1. Εάν μετρηθεί η κατάσταση, $|\psi\rangle = \alpha |0\rangle + \beta |1\rangle$, τότε μπορεί να ληφθεί η κατάσταση 0 με πιθανότητα $|\alpha|^2$ και η κατάσταση 1 με πιθανότητα $|\beta|^2$. Επιπλέον, η νέα κατάσταση μετά τη μέτρηση θα είναι 0 ή 1 ανάλογα με το αποτέλεσμα που έχει ληφθεί (κατάρρευση κυματομορφής).

4.2 Κωδικοποίηση κβαντικών δεδομένων

4.2.1 Κβαντικά δεδομένα

Κβαντικά δεδομένα. Το qubit είναι το βασικό δομικό στοιχείο των κβαντικών υπολογιστών. Ένα qubit μπορεί να αντιπροσωπεύει 2 bits, δηλαδή 1 ή 0. Τα 2 qubits

αντιπροσωπεύουν 4 bits. Έτσι, τα n qubits αντιπροσωπεύουν 2^n bits. Η μηχανική μάθηση απαιτεί τεράστιο όγκο δεδομένων. Εάν τα αποθηκευμένα δεδομένα είναι σε κβαντικό χώρο, τότε μπορεί να αποθηκευθούν πολλά σε πολύ λιγότερο χώρο από ότι θα απαιτούνταν εάν ήταν σε κλασική μορφή. Με τον τρόπο αυτό μπορεί να εξοικονομηθεί τεράστιος υπολογιστικός χώρος και στη μνήμη του υπολογιστή αλλά και στον χρόνο εκτέλεσης των προγραμμάτων. Η πρόσβαση στα μεγάλα δεδομένα, μέσω των κβαντικών υπολογισμών, θα είναι πιο γρήγορη. Η ενσωμάτωση κβαντικής βάσης συσχετίζει κάθε είσοδο με μια υπολογιστική βάση ενός συστήματος qubit. Επομένως, τα κλασικά δεδομένα πρέπει να έχουν τη μορφή δυαδικών συμβολοσειρών για να χρησιμοποιηθούν. Ως εκ τούτου, ένα κομμάτι κλασικών πληροφοριών αντιπροσωπεύεται από ένα κβαντικό υποσύστημα.

4.2.2 Κβαντικές πύλες

Στην κβαντική υπολογιστική και συγκεκριμένα στον αλγόριθμο υπολογισμού κβαντικού κυκλώματος, μια κβαντική λογική πύλη ή απλά κβαντική πύλη είναι ένα βασικό κβαντικό κύκλωμα που λειτουργεί σε ένα μικρό αριθμό qubits, (Combarro, 2020). Τα δομικά στοιχεία των κβαντικών κυκλωμάτων είναι όπως οι κλασικές πύλες λογικής για συμβατικά ψηφιακά κυκλώματα. Σε αντίθεση με πολλές κλασικές λογικές πύλες, οι κβαντικές λογικές πύλες είναι αναστρέψιμες. Στην περίπτωση των κβαντικών κυκλωμάτων οι λειτουργίες που μπορούν να πραγματοποιηθούν δίδονται από πίνακες.

Πύλες ενός-qubit. Όταν υπάρχει μόνο ένα qubit, $|\psi\rangle = \alpha |0\rangle + \beta |1\rangle$, συνήθως, αντιπροσωπεύεται ως διάνυσμα στήλης, $\begin{pmatrix} \alpha \\ \beta \end{pmatrix}$. Στη συνέχεια, μια πύλη ενός qubit μπορεί να ταυτοποιηθεί με έναν μοναδιαίο πίνακα (Barenco et al., 1995),

$$U = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \quad \text{που ικανοποιεί την εξίσωση,}$$

$$U = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \begin{pmatrix} \bar{a} & \bar{b} \\ \bar{c} & \bar{d} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

όπου $\bar{a}, \bar{b}, \bar{c}, \bar{d}$ είναι οι συζυγείς μιγαδικών αριθμών a, b, c, d .

Ενέργεια πύλης ενός qubit: Η εξίσωση $|\psi\rangle = x|0\rangle + y|1\rangle$ μετασχηματίζεται σε,

$$U = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} ax+by \\ cx+dy \end{pmatrix} \quad \text{δηλ. στην εξίσωση,}$$

$$|\psi\rangle = (ax+by)|0\rangle + (cx+dy)|1\rangle \quad \text{Ισχύει ότι,}$$

$$|(ax+by)|^2 + |(cx+dy)|^2 = 1$$

Η πύλη X ή NOT. Η πύλη X ορίζεται από τον μοναδιαίο πίνακα, $\begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$. Η δράση της σε όρους κβαντικού κυκλώματος είναι,

$$|0\rangle \text{ ---[X]--- } |1\rangle$$

$$|1\rangle \text{ ---[X]--- } |0\rangle$$

δηλ. λειτουργεί ως η κλασική πύλη με NOT. Σε ένα γενικευμένο qubit, η δράση της είναι,

$$\alpha|0\rangle + \beta|1\rangle \text{ ---[X]--- } \beta|0\rangle + \alpha|1\rangle$$

Η πύλη Z. Η πύλη Z ορίζεται από τον μοναδιαίο πίνακα, $\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$.

Η δράση της, σε όρους κβαντικού κυκλώματος, είναι,

$$|0\rangle \text{ ---[Z]--- } |0\rangle$$

$$|1\rangle \text{ ---[Z]--- } -|1\rangle$$

Η πύλη H ή Hadamard. Αυτή ορίζεται ως, $\frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$. Η δράση της, σε όρους κβαντικού κυκλώματος, είναι,

$$|0\rangle \text{---[H]---} \frac{|0\rangle + |1\rangle}{\sqrt{2}}$$

$$|1\rangle \text{---[H]---} \frac{|0\rangle - |1\rangle}{\sqrt{2}}$$

Συνήθως τίθεται,

$$|+\rangle = \frac{|0\rangle + |1\rangle}{\sqrt{2}}$$

$$|-\rangle = \frac{|0\rangle - |1\rangle}{\sqrt{2}}$$

Inner product. Το εσωτερικό γινόμενο δυο καταστάσεων $|\psi_1\rangle = \alpha_1 |0\rangle + \beta_1 |1\rangle$ και $|\psi_2\rangle = \alpha_2 |0\rangle + \beta_2 |1\rangle$ δίνεται από την εξίσωση,

$$\langle \psi_1 | \psi_2 \rangle = (\bar{\alpha}_1 \bar{\beta}_1) \begin{pmatrix} \alpha_2 \\ \beta_2 \end{pmatrix} = \bar{\alpha}_1 \alpha_2 + \bar{\beta}_1 \beta_2$$

4.3 Κβαντικός γενετικός αλγόριθμος QGA

Σε σχέση με τον κλασσικό γενετικό αλγόριθμο, ο κβαντικός γενετικός αλγόριθμος, Quantum Genetic Algorithm (QGA) είναι μια διαδικασία βελτιστοποίησης των υπολογισμών. Ο τρόπος κωδικοποίησής του είναι περίπλοκος και κάθε γενιά της μπορεί να καλύψει μια ευρύτερη περιοχή. Ο QGA συνδυάζει ορισμένα χαρακτηριστικά και του κβαντικού υπολογισμού αλλά και του γενετικού αλγόριθμου του οποίου τα άτομα επιλέγονται με φυσική επιλογή. Τα γενετικά εκλεπτυσμένα είδη προσαρμόζονται καλύτερα στο περιβάλλον του κβαντικού γενετικού αλγορίθμου και παράγονται με τη λειτουργία κβαντικών περιστρεφόμενων πυλών με στόχο την εύρεση του καλύτερου ατόμου (είδους) της συγκεκριμένης γενιάς. Τα κύρια χαρακτηριστικά του QGA έχουν ως εξής,

- Ο QGA περιέχει την έννοια της αυτο-μάθησης.
- Ο αντικειμενικός σκοπός του QGA δεν είναι οι παράμετροι, αλλά τα χρωμοσώματα που κωδικοποιούνται σύμφωνα με τις μεταβλητές παραμέτρους.
- Το QGA αναζητά ταυτόχρονα μια ομάδα σημείων και όχι ένα σημείο στο χώρο λύσης.

- Στο QGA, δεν απαιτείται η γνώση του χώρου αναζήτησης ή άλλων βοηθητικών πληροφοριών. Χρησιμοποιείται μόνο η λειτουργία της φυσικής κατάστασης για την αξιολόγηση των ατόμων.

Χρωμοσώματα και γονίδια. Ο πληθυσμός N χρωμοσωμάτων $Q(t)$ μπορεί να εκφρασθεί, (Wang et al., 2013) ως,

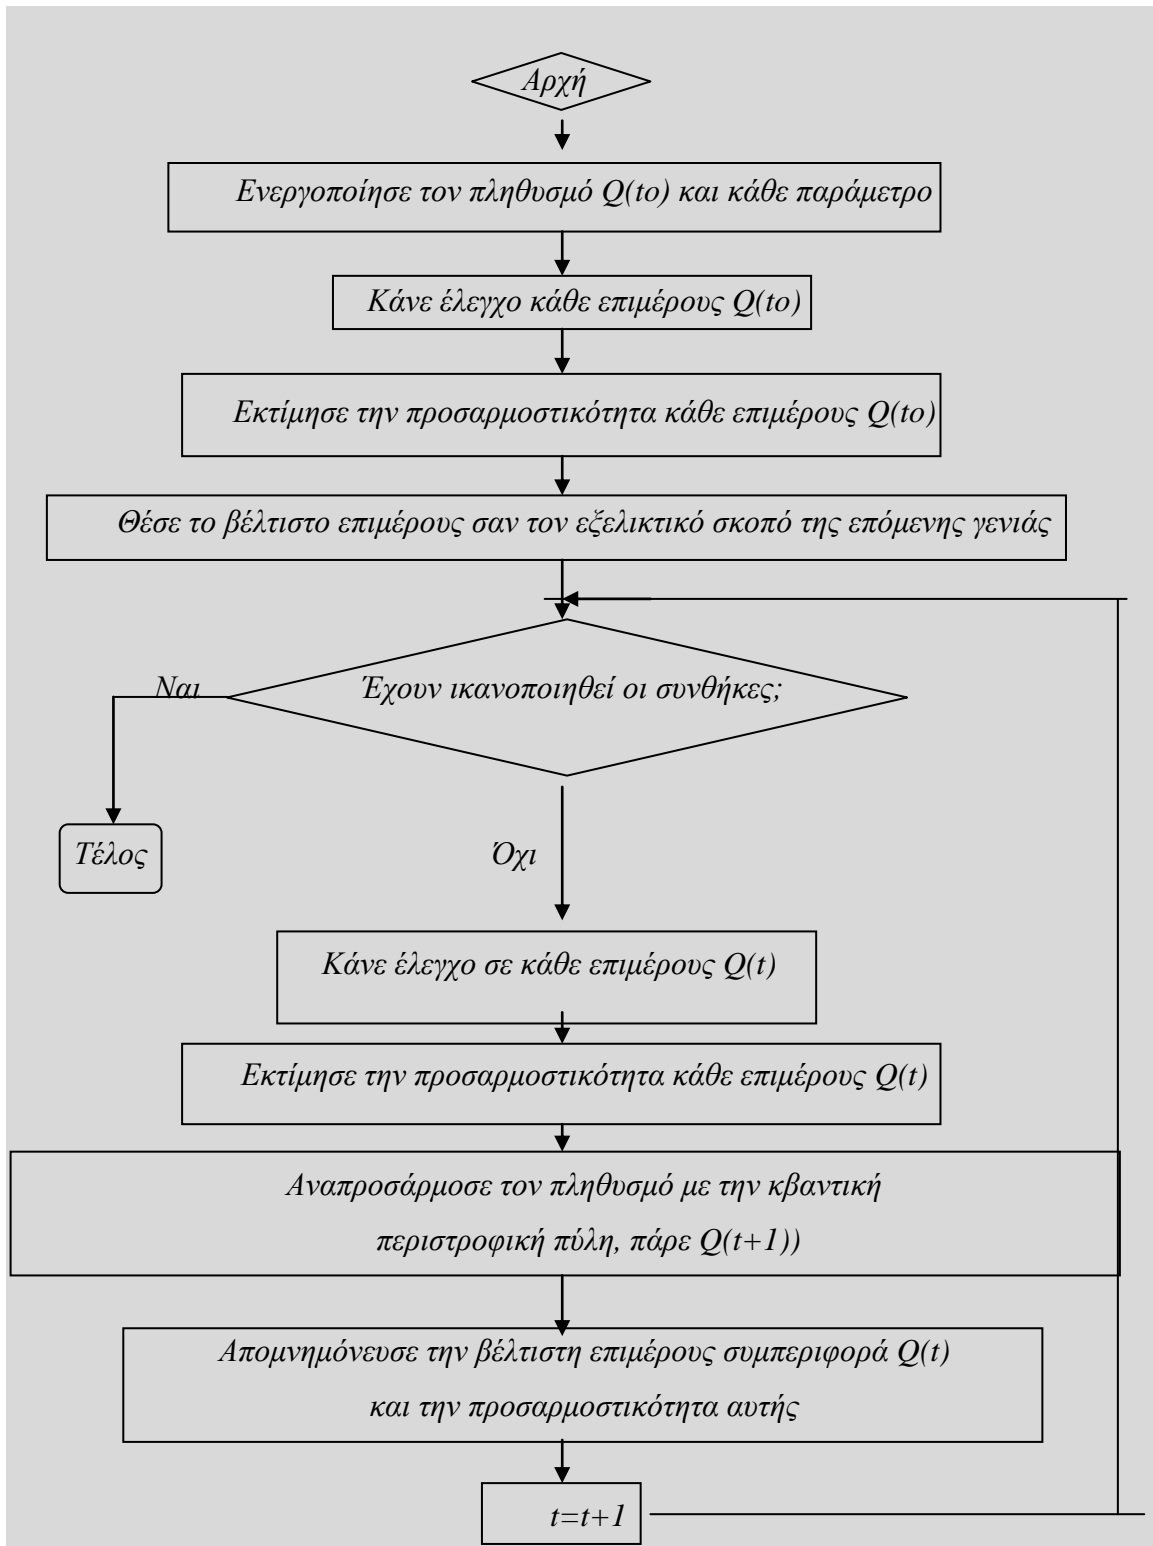
$$Q(t) = [q_1^t, q_2^t, q_3^t \dots q_N^t]$$

Ένα τυχαίο χρωμόσωμα $[q_j^t]$ αντιπροσωπεύει το j^{th} μεμονωμένο χρωμόσωμα της t^{th} γενιάς,


$$[q_j^t] = q_j = \begin{bmatrix} a_1 & a_2 & a_3 \dots a_m \\ \beta_1 & \beta_2 & \beta_3 \dots \beta_m \end{bmatrix}$$

Το m αντιπροσωπεύει τον αριθμό των γονιδίων στο χρωμόσωμα. Το διάγραμμα ροής του συμβατικού κβαντικού γενετικού αλγορίθμου QGA δείχνεται στο Σχήμα 4.2.

Διασταυρούμενη επικύρωση. Η αξιολόγηση των αποτελεσμάτων μιας στατιστικής ανάλυσης γίνεται και με ένα είδος επικύρωσης έτσι ώστε να μπορεί να αποφεύγεται το πρόβλημα της υπερφόρτωσης, (Zhang et al., 2017). Τα βασικά βήματα της διασταυρούμενης επικύρωσης είναι η τμηματοποίηση του δείγματος των δεδομένων σε πολλά υποσύνολα, πραγματοποιώντας την ανάλυση σε ένα υποσύνολο που ονομάζεται εκπαίδευση και επικυρώνοντας την ανάλυση για το υποσύνολο που ονομάζεται δοκιμή. Το σχηματικό διάγραμμα της διασταυρούμενης επικύρωσης εμφανίζεται στο Σχήμα 4.3.




Σχήμα 4.2 Διάγραμμα ροής του συμβατικού κβαντικού γενετικού αλγορίθμου



Σχήμα 4.3 Σχηματικό διάγραμμα διασταυρούμενης επικύρωσης

Κβαντική διασταυρούμενη μεταβολή. Γίνεται διασταύρωση και ανταλλαγή των αντίστοιχων γονιδίων, σημειώνοντας με το G_k , οποιοδήποτε δύο χρωμοσώματων $[q_j^{t_0}]$ και $[q_{j+n}^{t_0}]$, όπου n τυχαίος αριθμός γονιδίου, προκειμένου να σχηματιστούν δύο παρόμοια χρωμοσώματα. Ο σκοπός της κβαντικής διασταύρωσης είναι η ανταλλαγή πληροφοριών μεταξύ δύο πιθανών λύσεων. Το σχηματικό διάγραμμα της κβαντικής διασταύρωσης δείχνεται στο Σχήμα 4.4. Αλλάζοντας ένα ή περισσότερα γονίδια οποιοδήποτε χρωμοσώματος $[q_j^{t_0}]$, π.χ. G_k με G'_k , μπορεί να σχηματιστεί νέο χρωμόσωμα $[q_j^{t_0+1}]$, ώστε να διασφαλιστεί η ποικιλομορφία των χρωμοσωμάτων. Αυτή η διαδικασία ονομάζεται κβαντική διασταυρούμενη μεταβολή, που είναι ένας καλός τρόπος για να αλλαχθεί η τρέχουσα κατεύθυνση της εξέλιξης και να αποφευχθεί το τοπικό βέλτιστο.



Σχήμα 4.4 Σχηματικό διάγραμμα κβαντικής διασταύρωσης

Περιστρεφόμενες πύλες. Οι κβαντικές περιστρεφόμενες πύλες, (Wang et al., 2013), μπορούν να καθοριστούν ως,

$$\begin{bmatrix} a'_i \\ \beta'_i \end{bmatrix} = U(\theta_i) \begin{bmatrix} a_i \\ \beta_i \end{bmatrix}$$

όπου

$$U(\theta_i) = \begin{pmatrix} \cos \theta_i & -\sin \theta_i \\ \sin \theta_i & \cos \theta_i \end{pmatrix}$$

και $\begin{bmatrix} a_i \\ \beta_i \end{bmatrix}, \begin{bmatrix} a'_i \\ \beta'_i \end{bmatrix}$ οι πιθανότητες του i^{th} qubit, πριν και μετά τον υπολογισμό των κβαντικών περιστρεφόμενων πυλών αντίστοιχα, ενώ θ_i είναι η περιστρεφόμενη γωνία, Παράγραφος 3.4.4. Η τιμή και το πρόσημο της γωνίας περιστροφής καθορίζονται από τη στρατηγική η οποία σαν ένα παράδειγμα φαίνεται στον Πίνακα 4.1.

Πίνακας 4.1 Προσαρμογή της γωνίας περιστροφής

x_i	best_i	$f(x) > f(\text{best})$	$\Delta\theta_i$	$s(\alpha_i, \beta_i)$			
				$\alpha_i\beta_i > 0$	$\alpha_i\beta_i < 0$	$\alpha_i = 0$	$\beta_i = 0$
0	0	FALSE	0	0	0	0	0
0	0	TRUE	0	0	0	0	0
0	1	FALSE	$\Delta\theta_i$	+1	-1	0	± 1
0	1	TRUE	$\Delta\theta_i$	-1	+1	± 1	0
1	0	FALSE	$\Delta\theta_i$	-1	+1	± 1	0
1	0	TRUE	$\Delta\theta_i$	+1	-1	0	± 1
1	1	FALSE	0	0	0	0	0
1	1	TRUE	0	0	0	0	0

x_i είναι το i^{th} τμήμα των δεδομένων, best_i είναι το i^{th} τμήμα του βέλτιστου των δεδομένων, $f(x)$ είναι η συνάρτηση προσαρμογής,

$$f(x) = \text{sgn} \left[\sum_{i=1}^l \alpha_i y_i K(x_i, x_j) + b \right]$$

όπου a_i και b_i είναι οι παράμετροι που καθορίζουν τα βέλτιστα υπερ-επίπεδα και $K(x_i, x_j)$ ο πυρήνας (kernel), Παράγραφος 3.4.3, $s(a_i, b_i)$ είναι η κατεύθυνση της περιστρεφόμενης γωνίας με 0 ή +1 ή -1, $\Delta(\theta)$ είναι η τιμή της περιστρεφόμενης γωνίας και καθορίζεται από συγκεκριμένη στρατηγική προσαρμογής στο συμβατικό κβαντικό γενετικό αλγόριθμο. Η στρατηγική προσαρμογής γίνεται συγκρίνοντας την καταλληλότερη τιμή της τρέχουσας $f(x)$ του επιμέρους $[q_j^t]$ με την καταλληλότητα του τρέχοντος βέλτιστου $f(\text{best})$, εάν $f(x) > f(\text{best})$ τότε προσαρμόζονται τα αντίστοιχα qubits $[q_j^t]$, κάνοντας τη πιθανότητα να κατευθυνθεί προς την κατεύθυνση που είναι ευνοϊκή για την εμφάνιση του x_i . Αντίθετα, εάν $f(x) < f(\text{best})$, τότε ρυθμίζονται τα αντίστοιχα qubits, κάνοντας την πιθανότητα (a_i, b_i) να εξελιχθεί προς την κατεύθυνση που είναι ευνοϊκή για την εμφάνιση του καλύτερου. Η πιθανότητα του $\begin{pmatrix} \alpha \\ \beta \end{pmatrix}$ αναπαριστά ένα χρωμόσωμα κβαντικού bit και ο πληθυσμός των χρωμοσωμάτων είναι ,

$$Q(t) = [q_1^t, q_2^t, q_3^t, \dots, q_N^t],$$

όπου N δηλώνει το μέγεθος των χρωμοσωμάτων,

$$q_j = \begin{bmatrix} a_1 & a_2 & a_3 & \dots & a_m \\ b_1 & b_2 & b_3 & \dots & b_m \end{bmatrix}$$

με m τον αριθμό των γονιδίων κάθε χρωμοσώματος. Στον αρχικό πληθυσμό N η πιθανότητα των επιμέρους $\begin{pmatrix} \alpha_i \\ \beta_i \end{pmatrix}$ είναι, $\begin{pmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{pmatrix}$. Με τις ανακυκλώσεις η αρχική πιθανότητα μετατρέπεται σε $\begin{pmatrix} \alpha'_i \\ \beta'_i \end{pmatrix}$ μετά την περιστροφή κατά $\Delta\theta_i$.

5. Πειραματική διαδικασία και λήψη δεδομένων

5.1 Λεπτομέρειες της πειραματικής διάταξης


Στο κεφάλαιο αυτό περιγράφεται η συλλογή των δεδομένων από τα πειράματα που διεξήχθησαν στις Η.Π.Α. Τμήμα των δεδομένων αυτών χρησιμοποιήθηκε στην παρούσα ερευνητική εργασία για να εξακριβωθεί η ακρίβεια της υπολογιστικής κβαντικής μεθόδου QGA-SVM σε σύγκριση με την τεχνική SVM.

Τα πειράματα διεξήχθησαν χρησιμοποιώντας έναν κινητήρα Reliance Electric 2.0 hp και τα δεδομένα επιτάχυνσης ελήφθησαν από την ελαττωματική λειτουργία που ρουλεμάν του κινητήρα σε διάφορες θέσεις, Σχήμα 5.1, (Bearing data center, 2021). Τα ρουλεμάν στήριξης υποστηρίζουν τον άξονα του κινητήρα. Ο κινητήρας δοκιμάστηκε σε πραγματικές συνθήκες λειτουργίας.

Στα ρουλεμάν του κινητήρα εισήχθησαν επίτηδες αλλοιώσεις πριν την λειτουργία του για λήψη δεδομένων. Τα δεδομένα δόνησης καταγράφηκαν για φορτία κινητήρα ισχύος έως 3.0 hp και με ταχύτητες κινητήρα έως 1720 στροφές το λεπτό. Πιο αναλυτικά, οι σημειακές αλλοιώσεις εισήχθησαν στα ρουλεμάν χρησιμοποιώντας μια μηχανική ηλεκτροφόρτιση. Οι σημειακές αλλοιώσεις είχαν διάμετρο, 0.007 ίντσες, 0.014 ίντσες, 0.021 ίντσες, 0.028 ίντσες και 0.040 ίντσες και έγιναν σε βάθος 0.011 ίντσες σε κάθε μια των περιπτώσεων, Πίνακας I.1. Οι αλλοιώσεις αυτές χαράχθηκαν ξεχωριστά σε τρία μέρη του ρουλεμάν, Σχήμα 6.1,

- στην εσωτερική κούρσα του ρουλεμάν,
- στο περίβλημα (σφαίρες) και
- στην εξωτερική πλευρά του ρουλεμάν.

Οι τεχνικές προδιαγραφές των ρουλεμάν, τύπου SKF, και τα μοντέλα που χρησιμοποιήθηκαν 6205-2RS JEM SKF και 6203-2RS JEM SKF δίνονται στον Πίνακα I.2. Οι αλλοιώσεις πραγματοποιήθηκαν στις θέσεις, 3 η ώρα, στις 6 η ώρα και στις 12 η ώρα τόσο στο ρουλεμάν του ανεμιστήρα (fan end) που ήταν του τύπου 6203-2RS JEM SKF όσο και στο ρουλεμάν του οδηγού κίνησης (drive end) του τύπου 6205-2RS JEM SKF.



Σχήμα 5.1 Πειραματική διάταξη για μετρήσεις λειτουργίας ρουλεμάν με αλλοιώσεις

5.2 Συλλογή δεδομένων

Τα δεδομένα δόνησης συλλέχθηκαν χρησιμοποιώντας επιταχυνσιόμετρα, τα οποία προσαρτήθηκαν στο περίβλημα του κινητήρα που στηρίζονταν με μαγνητικές βάσεις, (Bearing data center, 2021). Τα επιταχυνσιόμετρα τοποθετήθηκαν στη θέση των 12 ωρών των δεικτών του ωρολογίου τόσο στο άκρο της κίνησης (drive end) του κινητήρα όσο και στο άκρο του ανεμιστήρα (fan end) του περιβλήματος του κινητήρα. Κατά τη διάρκεια ορισμένων πειραμάτων, ένα επιταχυνσιόμετρο προσαρτήθηκε και στην πλάκα βάσης στήριξης του κινητήρα. Τα σήματα της δόνησης, από την λειτουργία του κινητήρα, συλλέχθηκαν χρησιμοποιώντας μια συσκευή καταγραφής των δεδομένων που αποτελούνταν από 16 κανάλια. Με την σειρά τους τα δεδομένα υποβλήθηκαν σε επεξεργασία με την χρήση του λογισμικού Matlab. Όλα τα αρχεία δεδομένων είναι σε μορφή .mat. Τα ψηφιακά δεδομένα συλλέχθηκαν στο άκρο της κίνησης με ρυθμό λήψης δειγμάτων 12.0 kHz και 48.0 kHz. Η συλλογή κράτησε 100.0 δευτερόλεπτα. Τα δεδομένα της περιστροφικής ταχύτητας και της ιπποδύναμης συλλέχθηκαν χρησιμοποιώντας δυναμόμετρο και καταγράφηκαν με το χέρι.

5.3 Δεδομένα των μετρήσεων

Κάθε αρχείο σε μορφή .mat περιέχει δεδομένα τόσο για το άκρο κίνησης (drive end) του κινητήρα όσο και για το άκρο του ανεμιστήρα (fan end) του περιβλήματος του

κινητήρα, (Bearing data center, 2021). Στα δεδομένα υπάρχει και η περιστροφική ταχύτητα του κινητήρα.

Στον Πίνακα II.1 δείχνεται το αρχείο των δεδομένων σε κανονική λειτουργία, χωρίς δηλ. αλλοιώσεις στα ρουλεμάν. Για παράδειγμα, Normal_1 είναι το αρχείο που πάρθηκε με ισχύ κινητήρα 1.0 hp και περιστροφική ταχύτητα 1772 στροφές το λεπτό.

Τα αρχεία στον Πίνακα II.2 περιέχουν τα δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 12.0 kHz. Για παράδειγμα το [IR007@6.01](#) είναι το αρχείο των δεδομένων με αλλοίωση 0.007 ίντσες, με ισχύ 1.0 hp, σε 1772 στροφές το λεπτό και αντιστοιχεί στα δεδομένα της εσωτερικής κούρσας (inner race) στη θέση 6 ώρα, ενώ το αρχείο B007_1 αντιστοιχεί στα δεδομένα της σφαίρας (ball) και τα αρχεία [OR007@6.1](#), [OR007@3.1](#) και [OR007@12.1](#) αντιστοιχούν στις μετρήσεις των αλλοιώσεων που χαράχθηκαν στις θέσεις, 6 ώρα, 3 ώρα και 12.0 ώρα, αντίστοιχα.

Τα αρχεία στον Πίνακα II.3 περιέχουν τα δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα αλλά η συχνότητα λήψης των δεδομένων ήταν ίση με 48.0 kHz με αντίστοιχη επεξήγηση.

Τέλος, τα αρχεία στον Πίνακα II.4 περιέχουν τα δεδομένα προβληματικής λειτουργίας του άκρου του ανεμιστήρα (fan end) του κινητήρα με δειγματοληψία 12.0 kHz.


6. Προτεινόμενη μεθοδολογία και αριθμητική προσομοίωση

6.1 Το πρόβλημα

Ένα ρουλεμάν έχει τέσσερα κύρια μέρη, Σχήμα 6.1,

- την εσωτερική κούρσα,
- την εξωτερική κούρσα
- το κυλιόμενο στοιχείο (σφαίρα) και
- το περίβλημα των σφαιρών

Ελαττωματική λειτουργία μπορεί να προκύψει σε οποιοδήποτε από αυτά τα στοιχεία.



Σχήμα 6.1 Ρουλεμάν με τα τέσσερα κύρια μέρη αυτού

Σε αυτήν τη μελέτη, θα ληφθούν υπόψη δεδομένα που αποκτήθηκαν με συχνότητα δειγματοληψίας 48.0 kHz και 1772 στροφές το λεπτό, με ιπποδύναμη 1.0 hp. Τα αρχεία βρίσκονται, Πίνακας II.3, με την ονομασία,

- [IR007_1, B007_1, OR007@6_1](#), (εσωτερική κούρσα),
- [IR014_1, B014_1, OR014@6_1](#) (κυλιόμενο στοιχείο, σφαίρα),
- [IR021_1, B021_1, OR021@6_1](#) (εξωτερική κούρσα).

Επίσης, το αρχείο [Normal_1](#) δίνει την λειτουργία των ρουλεμάν χωρίς αλλοιώσεις, Πίνακας II.1.

Οι αλλοιώσεις έχουν διαφορετικά βάθη με διαμέτρους, 0.007 ίντσες, 0.014 ίντσες και 0.021 ίντσες. Για το εξωτερικό φορτίο του 1.0 hr μελετήθηκαν οι εξής 10 περιπτώσεις,

- C1: Ελαττωματική σφαίρα με 0.007 ίντσες.
- C2: Ελαττωματική σφαίρα με 0.014 ίντσες.
- C3: Ελαττωματική σφαίρα με 0.021 ίντσες.
- C4: Ελάττωμα εσωτερικής κούρσας με 0.007 ίντσες.
- C5: Ελάττωμα εσωτερικής κούρσας με 0.014 ίντσες.
- C6: Ελάττωμα εσωτερικής κούρσας με 0.021 ίντσες.
- C7: Κανονικό ρουλεμάν.
- C8: Ελάττωμα εξωτερικής κούρσας με 0.007 ίντσες και δεδομένα που συλλέγονται από τη θέση, 6 ώρα.
- C9: Ελάττωμα εξωτερικής κούρσας με 0.014 ίντσες και δεδομένα που συλλέγονται από τη θέση, 6 ώρα.
- C10: Ελάττωμα εξωτερικής κούρσας με 0.021 ίντσες και δεδομένα που συλλέγονται από τη θέση, 6 ώρα.

6.2 Προ-επεξεργασία δεδομένων

Για τους υπολογισμούς μπορεί να ληφθεί είτε το πλήρες σήμα των δεδομένων είτε τμήματα αυτού. Τα αρχικά δεδομένα χωρίζονται σε τμήματα μήκους 1024 ή 2048 χωρίς αλληλο-επικάλυψη μεταξύ τους. Αρχικά, υπολογίζεται ο μέγιστος αριθμός τμημάτων μήκους 1024 που μπορεί να εξαχθεί από κάθε αρχείο. Εδώ αναφέρεται το αρχείο IR014_1, ως ένα αρχείο που είναι υποσύνολο δεδομένων, από τα συνολικά δεδομένα που ελήφθησαν, Πίνακας IV, και αναφέρεται για το άκρο κίνησης (drive end). Τα αρχεία μπορούν να ληφθούν από τον ιστότοπο, (Bearing data center drive end fault, 2021), που με τη σειρά τους αποθηκεύτηκαν στον φάκελο `home/biswajit/data/cwru`.

```
files=glob.glob("/home/biswajit/data/cwru/*")
```

```
files=np.sort(files)
```

Αριθμός τμημάτων (segments) για κάθε αρχείο

```
for file in files: # Φάκελος μετρήσεων όλων των δεδομένων (IR,OR,BALL,12k,48k,1hp,  
2hp,3hp,0.007inch,0.0014inch,0.0021inch)
```

```
data=loadmat(file)
```

```
if file[-7:-4]=="175":# IR014_1 data
```

```
key="X217_DE_time"
```

```
else:
```

```
key="X"+file[-7:-4]+"_DE_time"
```

```
drive_end_data=data[key]
```

```
num_segments=np.floor(len(drive_end_data)/1024)
```

```
print(num_segments)
```

```
475.0 474.0 475.0 474.0 477.0 473.0 475.0 473.0 477.0 472.0
```

Έτσι, εξάγονται τουλάχιστον 470 τμήματα από κάθε αρχείο. Στα επεξεργασμένα δεδομένα και χωρίς κανένα ιδιαίτερο λόγο συλλέγονται 460 τμήματα από κάθε αρχείο. Μετά την εξαγωγή, τα δεδομένα θα έχουν μέγεθος $4600 \times 1024 \approx 4.700.000$. Παρακάτω, δημιουργείται ένας επεξεργασμένος πίνακας δεδομένων.

```
segmented_data=np.repeat(np.nan,4600*1024).reshape(4600,1024)
```

```
num=0
```

```
for file in files:
```

```
data=loadmat(file)
```

```
if file[-7:-4]=="175":
```

```
key="X217_DE_time"
```

```
else:
```

```
key="X"+file[-7:-4]+"_DE_time"
```

```
drive_end_data=data[key]
```

```
for i in range(460):# We collect 460 segments from each file
```

```
segmented_data[num,:]=drive_end_data[i*1024:(i+1)*1024,0]
```

```
num=num+1
```

6.3 Υπολογισμός χαρακτηριστικών των δεδομένων

Για τον υπολογισμό του πίνακα των χαρακτηριστικών θα επιμερισθούν πρώτα τα συνολικά δεδομένα σε τμήματα μήκους 2048. Οι τιμές των μετρήσεων που λαμβάνονται από τα σήματα υπολογίζονται με ορισμένες χαρακτηριστικές ιδιότητες όπως, μέγιστη τιμή, ελάχιστη τιμή, η τιμή της μέσης τετραγωνικής ρίζας κ.λπ. Για κάθε σειρά δεδομένων μετρήσεως x_i , $i=1,2,3\dots n$, όπου n ο αριθμός των δεδομένων, υπολογίζονται,

- μέγιστη τιμή,
- ελάχιστη τιμή,
- μέση τιμή,
- μέση τετραγωνική τιμή ρίζας,
- τυπική απόκλιση,
- $\text{ασυμμετρία} = \frac{\sum_{i=1}^N (x_i - \mu)^3}{N} / (\text{τυπική απόκλιση})^3$
- $\text{κόρτωση} = \frac{\sum_{i=1}^N (x_i - \mu)^4}{N} / (\text{τυπική απόκλιση})^4$ 3
- κορύφωση και
- μορφή.

Ο πίνακας των χαρακτηριστικών είναι έτοιμος για περαιτέρω ανάλυση.

6.4 Προτεινόμενη μεθοδολογία QGA-SVM

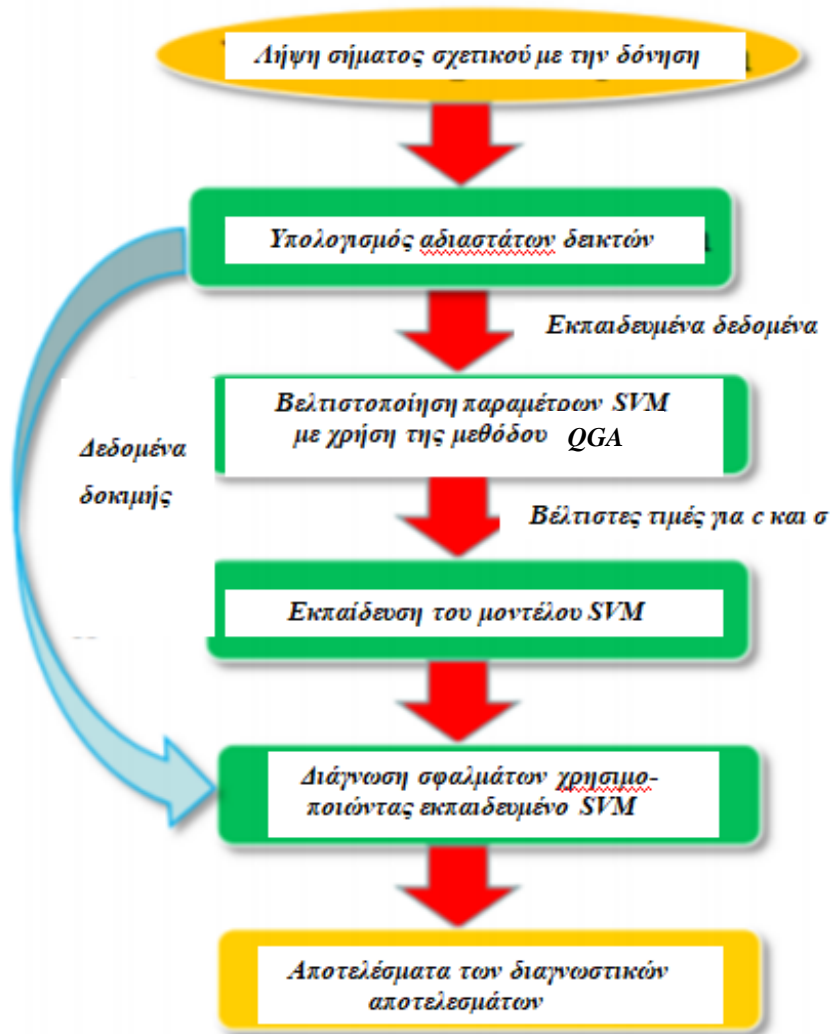
Η υπολογιστική τεχνική SVM θα χρησιμοποιηθεί για να γίνει η διάγνωση των σφαλμάτων των δεδομένων του προβλήματος. Τα πρωταρχικά δεδομένα, για κάθε τύπο αλλοίωσης, συλλέγονται και χωρίζονται σε μικρότερα μέρη. Στην υπολογιστική διαδικασία της παρούσας ανάλυσης λαμβάνονται δεδομένα με μήκος 2048 σημεία από κάθε ένα τύπο αλλοίωσης δεδομένων. Τα αρχικά δεδομένα για κάθε τύπο αλλοίωσης ήταν 4800000. Στη συνέχεια, για κάθε τμήμα υπολογίζονται τα χαρακτηριστικά των δεδομένων κάθε τύπου αλλοίωσης και συναρμολογούνται σε έναν πίνακα χαρακτηριστικών. Υπάρχουν 230 τμήματα δεδομένων για κάθε αλλοίωση δεδομένων και 9 μεγέθη χαρακτηριστικών για κάθε αλλοίωση. Τα χαρακτηριστικά των δεδομένων αυτών υπολογίζονται συναρτήσει του χρόνου, Παράγραφος 6.3. Στον πίνακα των

χαρακτηριστικών προστέθηκε ακόμη μία στήλη, είναι η στήλη C7 Παράγραφος 6.1, που περιέχει τον τύπο του σφάλματος. Υπάρχουν συνολικά 2300 (=230x10) σειρές δεδομένων.

Πριν από την εφαρμογή SVM, τα δεδομένα διαχωρίζονται πρώτα σε ένα εκπαιδευτικό (training) σύνολο και μετά σε ένα σύνολο δοκιμών (test). Οι 155 σειρές, από τις 230, λαμβάνονται ως το σύνολο της εκπαίδευσης. Το υπόλοιπο σύνολο αποτελεί τις δοκιμές και περιέχει 75 σειρές δεδομένων. Ο διαχωρισμός γίνεται για κάθε τύπο σφάλματος C1,C2,...C10, Παράγραφος 6.1. Η υπολογιστική τεχνική SVM εφαρμόζεται πρώτα σε δεδομένα εκπαίδευσης και οι καλύτερες τιμές παραμέτρων επιλέγονται για περαιτέρω εφαρμογή. Οι βέλτιστοι αυτοί παράμετροι εφαρμόζονται στη συνέχεια για να δοκιμάσουν τα δεδομένα του συνόλου και να προβλέψουν το τελικό αποτέλεσμα της ταξινόμησης.

Η διάγνωση των λαθών, (Zhu et.al., 2018), με εκμάθηση μέσω της χρήσης της μεθόδου QGA-SVM, δείχνεται στο διάγραμμα ροής, Σχήμα 6.2. Τα βήματα που ακολουθούνται στην υπολογιστική διαδικασία έχουν ως εξής,

- Λήψη σημάτων σχετικών με τις δονήσεις.
- Υπολογισμός αδιάστατων δεικτών.
- Βελτιστοποίηση των παραμέτρων SVM με χρήση της μεθόδου GQA.
- Εκπαίδευση (training) του αλγόριθμου SVM.
- Διάγνωση σφαλμάτων χρησιμοποιώντας εκπαιδευμένο SVM.
- Αποτελέσματα διάγνωσης.



Σχήμα 6.2 Η μέθοδος διάγνωσης λαθών με την τεχνική QGA-SVM

Πιο αναλυτικά τα βήματα έχουν ως εξής,

Λήψη σημάτων σχετικών με τις δονήσεις. Καταγράφηκαν όλα τα δεδομένα των μετρήσεων από το ηλεκτρονικό σύστημα καταγραφής.

Υπολογισμός αδιάστατων συντελεστών. Οι αδιάστατοι συντελεστές των υπολογισμών γίνονται με σχετικά εύκολο τρόπο. Οι συντελεστές αναφέρονται στην Παράγραφο 6.3.

Βελτιστοποίηση των παραμέτρων SVM με χρήση QGA. Η ορθή, αποτελεσματική και η βέλτιστη χρήση της τεχνικής SVM απαιτεί την βελτιστοποίηση των παραμέτρων C και σ^2 , Παράγραφος 3.4.4, χρησιμοποιώντας τον κβαντικό γενετικό αλγόριθμο QGA,

Παράρτημα IV. Το Σχήμα 6.3 δίνει αναλυτικά το διάγραμμα ροής των υπολογισμών QGA και η επεξήγηση δίνεται αμέσως παρακάτω,

- **Τίθεται ο πληθυσμός των παραμέτρων N . Αρχικός πληθυσμός χρωμοσωμάτων $Q(t)$.** Ενεργοποίηση του πληθυσμού των κβαντικών χρωμοσωμάτων $Q(t) = [q_1^t, q_2^t, q_{13}^t, \dots, q_N^t]$, όπου N είναι το μέγεθος του πληθυσμού, $[q_j^t]$ το μεμονωμένο χρωμόσωμα και ο άνω δείκτης t αναφέρεται στην γενιά του πληθυσμού.
- **Μέτρηση.** Μέτρηση όλων των επιμέρους χρωμοσωμάτων στον πληθυσμό.
- **Υπολογισμός SVM.** Υπολογισμός της ακρίβειας με SVM όλων των επιμέρους χρωμοσωμάτων στον πληθυσμό.
- **Καταγραφή.** Καταγραφή της καλύτερης ακρίβειας όλων των επιμέρους χρωμοσωμάτων στον πληθυσμό.
- **Έλεγχος.** Εάν πληρούται η συνθήκη, ο υπολογισμός του αλγορίθμου τερματίζεται και καταγράφονται οι τιμές των C και σ^2 . Διαφορετικά, ο υπολογισμός συνεχίζεται.
- **Προσάρμοσε της γωνία περιστροφής.** Εάν δεν πληρούνται οι προϋποθέσεις γίνεται προσαρμογή της περιστροφής της κβαντικής πύλης με τον τύπο,

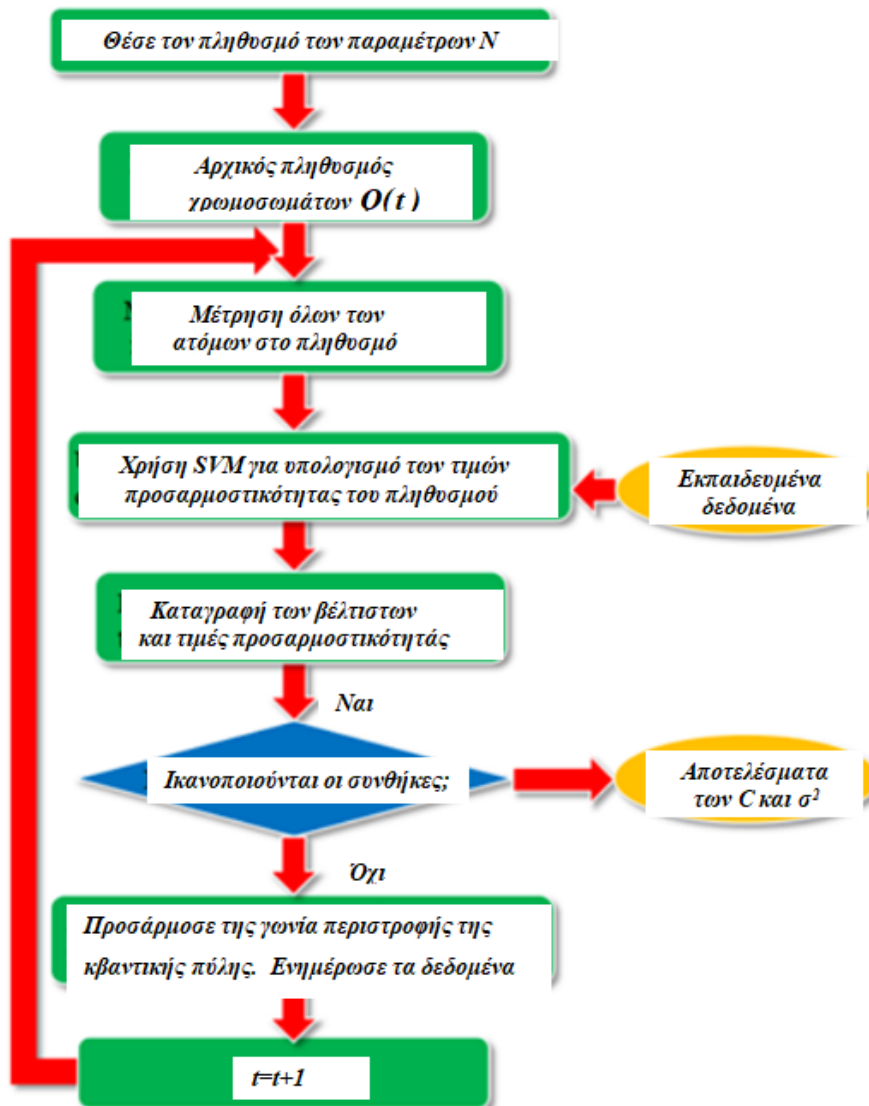
$$R_{\Delta}(\theta) \begin{bmatrix} a_i \\ \beta_i \end{bmatrix} = \begin{bmatrix} \cos(\Delta\theta_i) - \sin(\Delta\theta_i) \\ \sin(\Delta\theta_i) \cos(\Delta\theta_i) \end{bmatrix} \begin{bmatrix} a_i \\ \beta_i \end{bmatrix}$$

- **Υπολογισμός από την αρχή.** Ενημέρωση των χρωμοσωμάτων και υπολογισμός από την αρχή.

Εκπαίδευση SVM. Οι βελτιστοποιημένες τιμές C και σ^2 (πολλές φορές το $1/(2\sigma^2)$ αναφέρεται και ως γ ή gamma) τίθενται στις παραμετρικές τιμές της μεθόδου SVM και τα δοκιμαστικά (test) δεδομένα εκπαίδευσης χρησιμοποιούνται για εκπαίδευση με SVM.

Διάγνωση λαθών με χρήση εκπαιδευμένη μορφή SVM. Τα δεδομένα ελέγχου των (test) χρησιμοποιούνται ως είσοδος στη εκπαιδευμένη μορφή SVM για να διαγνωστούν τα λάθη.

Αποτελέσματα. Μετά τα ανωτέρω τα αποτελέσματα της έρευνας, με μορφή διάγνωσης λαθών, αναφέρονται στο Κεφάλαιο 7.



Σχήμα 6.3 Βελτιστοποίηση των παραμέτρων της μεθόδου QGA-SVM

6.5 Επίλυση

Παρακάτω δίνονται αναλυτικά τα βήματα που ακολουθούνται για την επίλυση του προβλήματος με ταυτόχρονη επεξήγηση των επιμέρους τμημάτων του αλγόριθμου, ο οποίος υλοποιήθηκε με τη γλώσσα προγραμματισμού Python (Spyder 3.7). Ο αλγόριθμος επίλυσης SVM με χρήση QGA έχει διαιρεθεί σε δεκατέσσερα (14) βήματα για κατανόηση και βρίσκεται στον Πίνακα IV.1 του Παραρτήματος με τίτλο Υπολογιστικός αλγόριθμος QGA-SVM.

Βήμα 1. Εισαγωγή βιβλιοθηκών

Το πρώτο βήμα περιλαμβάνει την εισαγωγή βιβλιοθηκών. Οι βιβλιοθήκες αυτές βρίσκονται στην αρχή του αλγόριθμου, Παράρτημα IV Libraries.

Βήμα 2. Εισαγωγή του συνόλου δεδομένων

Σε αυτό το βήμα, θα εισαχθεί το σύνολο χρονικών δεδομένων (timed domain) που ελήφθησαν με 48.0 kHz με ιπποδύναμη 1.0 hp από το αποθετήριο github που είναι αποθηκευμένο στο αρχείο ως, [feature_time_48k_2048_load_1.csv](#), Παράρτημα IV, Process Data.

Βήμα 3. Διαχωρισμός του συνόλου δεδομένων στο δεδομένα εκπαίδευσης και δεδομένα δοκιμών

Υπάρχουν 2300 σειρές σε αυτό το σύνολο δεδομένων. Τα δεδομένα του προβλήματος θα χωρισθούν σε δεδομένα εκπαίδευσης και δεδομένα δοκιμών. Σε αυτό το `test_size = 0.32` δηλώνει ότι το 32.0 % των δεδομένων, που είναι 750, θα χρησιμοποιηθούν ως δοκιμές και το υπόλοιπο 68.0 % των δεδομένων, που είναι 1550, θα χρησιμοποιηθούν για εκπαίδευση, Παράρτημα IV, Process Data.

Βήμα 4. Κλιμάκωση δεδομένων

Αυτό το βήμα, δηλ της κλιμάκωσης χαρακτηριστικών, είναι ένα επιπλέον βήμα που μπορεί να αυξήσει την ταχύτητα του προγράμματος καθώς μειώνονται οι τιμές των x_i σε μικρότερο εύρος. Κλιμακώνονται τόσο τα `train_data` (εκπαιδευτικά δεδομένα) όσο και τα `test_data` (δεδομένα δοκιμών) σε ένα μικρότερο εύρος, Παράρτημα IV, Process Data.

Βήμα 5. Αρχικοποίηση παραμέτρων του γενετικού κώδικα

Σ' αυτό το στάδιο αρχικοποιούνται οι απαραίτητες παράμετροι για τον γενετικό κώδικα, Παράρτημα IV, 2.1 Initialize class parameters.

Βήμα 6. Αρχικοποίηση του πληθυσμού

Αρχικοποίηση πληθυσμού με τη χρήση γωνιών για όλες τις τιμές κάθε χρωμοσώματος, Παράρτημα IV, 2.2 Quantum formalization of population.

Βήμα 7. Μετατροπή της αρχικοποιημένης ακολουθίας κβαντικών γωνιών σε μια λίστα κβαντικών συντελεστών του πληθυσμού

Στο στάδιο αυτό αποθηκεύονται ζεύγη συντελεστών για όλες τις τιμές κάθε χρωμοσώματος. Παράρτημα IV, 2.2 Quantum formalization of population.

Βήμα 8. Υπολογισμός της τιμής της συνάρτησης προσαρμοστικότητας

Αποθηκεύονται σε δυαδική μορφή όλες οι τιμές για κάθε χρωμόσωμα. Λαμβάνεται μια λίστα τιμών της συνάρτησης “fitness function”. Στους τρέχοντες υπολογισμούς, η υπολογιστική διαδικασία που χρησιμοποιείται ως “fitness function” είναι η SVM. Παράρτημα IV, 2.3 Calculating the fitness function value.

Βήμα 9. Εκπαίδευση του αλγόριθμου SVM

Μόλις το σύνολο των δεδομένων εκπαίδευσης είναι έτοιμο, εισαγάγετε η ταξινόμηση SVM και προσαρμόζεται το σύνολο των δεδομένων εκπαίδευσης στον αλγόριθμο. Η τεχνική SVC συνδέεται με την συνάρτηση “round basis function” ή “rbf”. Η συνάρτηση `rbf_svm.fit()` χρησιμοποιείται στη συνέχεια για την εκπαίδευση του αλγόριθμου Παράρτημα IV, 2.3 Calculating the fitness function value .

Βήμα 10. Βέλτιστη τιμή συνάρτησης προσαρμοστικότητας και των παραμέτρων

Υπολογίζεται η βέλτιστη τιμή λειτουργίας της φυσικής κατάστασης και η αντίστοιχη παράμετρος δυαδικής αναπαράστασης, Παράρτημα IV, 3. Find the optimal fitness function value and the corresponding parameter binary representation.

Βήμα 11. Διασταύρωση κβαντικών γωνιών μετά από παρεμβολές

Σε αυτό το βήμα θα υπολογιστεί μια βασική λειτουργία των γενετικών αλγορίθμων αποκαλούμενη ως “διασταύρωση”. Στους γενετικούς αλγόριθμους και στους εξελικτικούς υπολογισμούς, η “διασταύρωση”, που επίσης ονομάζεται ανασυνδυασμός, είναι ένας γενετικός χειριστής που χρησιμοποιείται για να συνδυάσει τις γενετικές πληροφορίες δύο γονέων με σκοπό να δημιουργήσει νέους απογόνους. Είναι ένας τρόπος

για να δημιουργηθούν στοχαστικά νέες λύσεις από έναν υπάρχοντα πληθυσμό. Παράρτημα IV, 2.4 Full interference cross.

Βήμα 12 Δημιουργία λίστας κβαντικών γωνιών για κάθε πληθυσμό με βάση τη γωνία περιστροφής κάθε qubit.

Στο συγκεκριμένο βήμα θα χρησιμοποιηθεί μια άλλη βασική λειτουργία των γενετικών αλγορίθμων γνωστή ως μετάλλαξη (mutation). Στην μετάλλαξη χρησιμοποιείται ένας γενετικός χειριστής για τη διατήρηση της ποικιλομορφίας από τη μία γενιά ενός πληθυσμού χρωμοσωμάτων στην επόμενη. Είναι ανάλογο με τη βιολογική μετάλλαξη. Η μετάλλαξη μεταβάλλει μία ή περισσότερες γονιδιακές τιμές σε ένα χρωμόσωμα από την αρχική του κατάσταση. Στη μετάλλαξη, η λύση μπορεί να αλλάξει εντελώς από την προηγούμενη λύση. Ως εκ τούτου, ο γενετικός αλγόριθμος μπορεί να βρει μια καλύτερη λύση, Παράρτημα IV, 4. Generate a new list of quantum angles for each population based on the rotation angle of each qubit.

Βήμα 13. Αποτελέσματα με γραφική παρουσίαση

Σε αυτό το τελευταίο βήμα, απεικονίζονται τα αποτελέσματα του αλγόριθμου SVM. Επίσης, σχεδιάζεται ο πίνακας σύγχυσης (confusion matrix). Ο πίνακας σύγχυσης είναι χρησιμοποιείται για να δείξει τον αριθμό των σωστών και λανθασμένων προβλέψεων σε ένα πρόβλημα ταξινόμησης, Παράρτημα IV, 2.5 Draw a graph of the results.

Βήμα 14. Ακρίβεια και παράμετροι

Σε αυτό το βήμα, υπολογίζεται η υψηλότερη ακρίβεια που επιτεύχθηκε και οι αντίστοιχοι παράμετροι του αλγόριθμου εκπαίδευσης. Παράρτημα IV, 2.6 Main function.

7. Αποτελέσματα μοντέλων SVM και QGA-SVM

7.1 Αποτελέσματα αλγόριθμου SVM. Εφαρμογή 1^η

Τα αποτελέσματα της χρήσης του αλγόριθμου SVM υπολογίσθηκαν με τις τιμές των μεταβλητών που φαίνονται στο Σχήμα 7.1. Το σχήμα αυτό δείχνει τον τρόπο κατηγοριοποίησης του προβλήματος με χρήση του ταξινομητή SVM (tuned_svm_clf).

Αρχικά, το σύνολο των δεδομένων χωρίζεται σε δεδομένα train και test. Στη παρούσα εργασία τα δεδομένα του test_size είναι 750 και γίνεται τυχαία ανάμειξη των δεδομένων, πριν το διαχωρισμό σε train/test, με τιμή random_state=1234. Ο αριθμός της διασταυρούμενης επικύρωσης (cv) τέθηκε ίσος με 10. Όσον αφορά τις παραμέτρους, για την εύρεση του καλύτερου διαχωριστικού υπερ-επίπεδου και συνεπώς της καλύτερης κατηγοριοποίησης των δεδομένων (υψηλότερη δυνατή ακρίβεια), επιλέγεται το συγκεκριμένο εύρος τιμών των “C=[1, 10, 50, 100, 300, 500]” και “gamma=[0.01, 0.05, 0.1, 0.5, 1, 5]”.

```
10
11 data_time = pd.read_csv("svm_data.txt")
12
13 data_time['fault'] = pd.Categorical(data_time['fault'])
14
15 ▼ train_data, test_data = train_test_split(data_time, test_size = 750, stratify = data_time['fault'],
16                                           random_state = 1234)
17 test_data['fault'].value_counts()
18
19
20 scaler = StandardScaler()
21 train_data_scaled = scaler.fit_transform(train_data.iloc[:, :-1])
22 test_data_scaled = (test_data.iloc[:, :-1].values - scaler.mean_) / np.sqrt(scaler.var_)
23 ▼ parameters = {"C": [1, 10, 50, 100, 300, 500],
24                'gamma': [0.01, 0.05, 0.1, 0.5, 1, 5],
25                'kernel': ["rbf"]}
26 tuned_svm_clf = GridSearchCV(SVC(), parameters, n_jobs = -1, cv= 10)
```

Σχήμα 7.1 Τμήμα κώδικα SVM με τις παραμέτρους του προβλήματος

Για τις τιμές C=50, gamma=0.05 και με χρήση του πυρήνα rbf τα αποτελέσματα κατηγοριοποιήθηκαν ορθώς με 96.53 % ακρίβεια επί του συνόλου των δεδομένων. Σχήμα 7.2.

```
{'C': 50, 'gamma': 0.05, 'kernel': 'rbf'}
overall_test_accuracy, 0.9653333333333334
```

Σχήμα 7.2 Ολική ακρίβεια

Το σύνολο δεδομένων αποτελείται από 2300 γραμμές το οποίο χωρίζεται σε 750 γραμμές δεδομένων για δοκιμή και 1550 γραμμές για εκπαίδευση. Στο παρακάτω Σχήμα 7.3α δείχνονται τα δεδομένα εκπαίδευσης που κατηγοριοποιήθηκαν ορθώς ή μη ανά κατηγορία C1, C2, C3...,C10. Ενώ στο Σχήμα 7.3β δείχνεται η ποσοστιαία τιμή των εκπαιδευτικών δεδομένων.

Μέθοδος SVM, Δεδομένα εκπαίδευσης

C1	143	1	0	0	0	0	0	0	11	0
C2	1	146	3	0	0	0	1	0	4	0
C3	3	0	140	0	0	5	0	0	6	1
C4	0	0	0	155	0	0	0	0	0	0
C5	0	0	0	0	155	0	0	0	0	0
C6	0	0	0	0	0	155	0	0	0	0
C7	0	0	0	0	0	0	155	0	0	0
C8	0	0	0	0	0	0	0	155	0	0
C9	3	5	4	0	0	0	0	0	143	0
C10	0	0	0	1	0	0	0	0	0	154
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10

α)

C1	0.92	0.0065	0	0	0	0	0	0	0.071	0
C2	0.0065	0.94	0.019	0	0	0	0.0065	0	0.026	0
C3	0.019	0	0.9	0	0	0.032	0	0	0.039	0.0065
C4	0	0	0	1	0	0	0	0	0	0
C5	0	0	0	0	1	0	0	0	0	0
C6	0	0	0	0	0	1	0	0	0	0
C7	0	0	0	0	0	0	1	0	0	0
C8	0	0	0	0	0	0	0	1	0	0
C9	0.019	0.032	0.026	0	0	0	0	0	0.92	0
C10	0	0	0	0.0065	0	0	0	0	0	0.99
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10

β)

Σχήμα 7.3 Αποτελέσματα του πίνακα σύγκρισης για τα εκπαιδευτικά δεδομένα της εφαρμογής SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια)

Μέθοδος SVM, Δεδομένα δοκιμής

α	74	0	0	0	0	0	0	0	1	0
β	1	66	0	0	0	0	2	0	5	1
γ	0	0	68	0	0	0	0	0	7	0
δ	0	0	0	75	0	0	0	0	0	0
ε	0	0	0	0	75	0	0	0	0	0
ς	0	0	0	0	0	75	0	0	0	0
ζ	0	0	0	0	0	0	75	0	0	0
η	0	0	0	0	0	0	0	75	0	0
θ	3	3	2	0	0	0	0	0	67	0
ι	0	0	0	1	0	0	0	0	0	74
κ	α	β	γ	δ	ε	ς	ζ	η	θ	ι

α)

α	0.99	0	0	0	0	0	0	0	0.013	0
β	0.013	0.91	0	0	0	0	0	0	0.067	0.013
γ	0	0	0.89	0	0	0	0	0.013	0.093	0
δ	0	0	0	1	0	0	0	0	0	0
ε	0	0	0	0	1	0	0	0	0	0
ς	0	0	0	0	0	1	0	0	0	0
ζ	0	0	0	0	0	0	1	0	0	0
η	0	0	0	0	0	0	0	1	0	0
θ	0.04	0.04	0.027	0	0	0	0	0	0.89	0
ι	0	0	0	0.013	0	0	0	0	0	0.99
κ	α	β	γ	δ	ε	ς	ζ	η	θ	ι

β)

Σχήμα 7.4 Αποτελέσματα του πίνακα σύγκρισης για τα δεδομένα δοκιμής της εφαρμογής SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια)

7.2 Αποτελέσματα αλγορίθμου QGA-SVM. Εφαρμογή 2^η

Στα πλαίσια της αποτελεσματικότητας του αλγορίθμου QGA-SVM, χρησιμοποιήθηκε ακόμη μια παρόμοια περίπτωση κατηγοριοποίησης δεδομένων. Η δεύτερη σειρά πειραμάτων πραγματοποιήθηκε στο βασικό εργαστήριο για τη διάγνωση σφαλμάτων λειτουργίας ενός φυγοκεντρικού ανεμιστήρα πετροχημικού εξοπλισμού, στην επαρχία Γκουανγκντόνγκ της Κίνας, (Zhu et al., 2018), Σχήμα 7.5.



Σχήμα 7.5 Διάταξη μετρήσεων για την διάγνωση σφαλμάτων λειτουργίας ενός φυγοκεντρικού ανεμιστήρα

Η πειραματική διάταξη αποτελείται κυρίως από ηλεκτρικό κινητήρα, έδρανο, άξονα, ανεμιστήρας, λειτουργία πλατφόρμας διακόπτης και ούτω καθεξής. Χρησιμοποιήθηκαν όλα τα είδη άξονα, γρανάζια, ρουλεμάν και ούτω καθεξής για την προσομοίωση ποικίλων τύπων βλαβών. Στο πείραμα, συλλέχθηκαν, το σήμα κατά την κανονική κατάσταση λειτουργίας και διάφορα είδη κατάστασης σφαλμάτων που χρησιμοποιούν δόνησεις, (Zhu et al., 2018). Από τα αποτελέσματα χρησιμοποιήθηκαν 1024 σημεία που απετέλεσαν το σύνολο δειγμάτων.

Σε αυτή τη μελέτη, συλλέχθηκαν μετρήσεις για δόνηση συμπεριλαμβανομένου του κανονικού ρουλεμάν, κυλιόμενη μπάλα (σφαίρα), ρουλεμάν που φέρει εξωτερική ρωγμή και εσωτερική ρωγμή. Επιπλέον, συλλέχθηκαν 160 ομάδες δειγμάτων, 40 ομάδες ανά κατάσταση. Στη συνέχεια, υπολογίστηκαν αδιάστατοι δείκτες (δείκτης κυματομορφής, δείκτης αιχμής, δείκτης παλμών και δείκτης περιθωρίου και δείκτης κύρτωσης) για κάθε ομάδα σημάτων δόνησης. Επιπλέον, 120 ομάδες δειγμάτων δεδομένων, με 30 ομάδες ανά κατάσταση, χρησιμοποιούνται ως δεδομένα εκπαίδευσης και οι υπόλοιπες 40 ομάδες για δείγμα.

Προκειμένου να επαληθευτεί η αποτελεσματικότητα της προτεινόμενης μεθόδου, έγινε διάγνωση σφαλμάτων χρησιμοποιώντας τις μεθόδους SVM και της προτεινόμενης QGA-SVM. Στο πείραμα, η συνάρτηση rbf χρησιμοποιήθηκε ως η λειτουργία πυρήνα του SVM. Έγινε βελτιστοποίηση των παραμέτρων του QGA-SVM και οι παράμετροι του γενετικού αλγορίθμου ορίστηκαν ως εξής: το μέγεθος του πληθυσμού (population_size) ήταν 20, ο αριθμός των γενεών ή ανακυκλώσεων (iter_num) ήταν 200, η παράμετρος C ήταν στο εύρος [0, 100], το εύρος της παραμέτρου gamma ήταν [0, 1000], ο αριθμός επικυρώσεων (cross validation) ήταν 5 και, τέλος, η πιθανότητα πλάτους γωνίας περιστροφής του κβαντικού γενετικού αλγορίθμου ήταν 0.009π. Τα αποτελέσματα του αλγόριθμου QGA-SVM δίνουν διαγνωστική ακρίβεια 0.925.

7.3 Αποτελέσματα αλγόριθμου QGA-SVM για τις εφαρμογές

Ο υπολογιστικός αλγόριθμος QGA-SVM, με την τεχνική rbf που χρησιμοποιήθηκε, στην παρούσα εργασία αναφέρεται στο Πίνακα IV.1. Όπως και στη περίπτωση του αλγόριθμου SVM το σύνολο των δεδομένων χωρίζεται σε train και test size. Με 750 δεδομένα να είναι το μέγεθος του συνόλου δοκιμής και τυχαία ανάμειξη των δεδομένων, πριν το διαχωρισμό σε train/test, με τιμή random_state=1234. Οι παράμετροι που χρησιμοποιήθηκαν δείχνονται παρακάτω,

- population_size=20
- chromosome_num=2
- chromosome_length=17
- max_value=15
- min_value=0.01
- iter_num=500
- deta=0.1 * np.pi

Το μέγεθος του πληθυσμού (population_size) είναι 20, ο αριθμός των χρωμοσωμάτων (chromosome_num) είναι 2, το μήκος των χρωμοσωμάτων (chromosome_length) είναι 17, η μέγιστη τιμή γωνίας (max_value) είναι 15.0, η ελάχιστη τιμή γωνίας (min_value) είναι 0.01, ο αριθμός των γενεών ή ανακυκλώσεων (iter_num) είναι 500 και η περιστροφική τιμή της γωνία είναι 0.1π.

Τα αποτελέσματα της μεθόδου QGA-SVM εμφανίζονται στα Σχήματα 7.6 και 7.7. Πιο αναλυτικά, στο Σχήμα 7.6α δείχνονται τα δεδομένα εκπαίδευσης που κατηγοριοποιήθηκαν ορθώς ή μη ανά κατηγορία C1, C2, C3...,C10. Ενώ στο Σχήμα 7.6β δείχνεται η ποσοστιαία τιμή των εκπαιδευτικών δεδομένων. Στο Σχήμα 7.7α δείχνονται τα δεδομένα της δοκιμής που κατηγοριοποιήθηκαν ορθώς ή μη ανά κατηγορία C1, C2, C3...C10 και στο Σχήμα 7.7β δείχνεται η ποσοστιαία τιμή των δεδομένων της δοκιμής.

Στο Σχήμα 7.8 δείχνεται το αποτέλεσμα της ακρίβειας για κάθε επανάληψη και ο αριθμός των γενεών (ανακυκλώσεων). Μετά από 77 ανακυκλώσεις η ακρίβεια είναι 0.9653 και στις 420 ανακυκλώσεις 0.9667. Στο Σχήμα 7.9 δείχνονται τα αποτελέσματα του υψηλότερου ποσοστού ακρίβειας που βρέθηκε (0.9667) μετά από 500 ανακυκλώσεις που είναι και το ανώτατο όριο αυτής της εφαρμογής. Οι επόμενοι αριθμοί, 0.878, 0.848...0.8666 του ίδιου σχήματος δίνουν τις τιμές της ακρίβειας που χρησιμοποιήθηκαν στην τελευταία αυτή ανακύκλωση. Στην ανακύκλωση αυτή υπολογίζονται και οι τιμές των παραμέτρων της συνάρτησης πυρήνα (kernel) όπου η $C = 13.513$ και του $\gamma = 0.383$.

Μέθοδος QGA-SVM, Δεδομένα εκπαίδευσης

a)

C1	143	1	0	0	0	0	0	0	11	0
C2	1	146	3	0	0	0	1	0	4	0
C3	3	0	140	0	0	5	0	0	6	1
C4	0	0	0	155	0	0	0	0	0	0
C5	0	0	0	0	155	0	0	0	0	0
C6	0	0	0	0	0	155	0	0	0	0
C7	0	0	0	0	0	0	155	0	0	0
C8	0	0	0	0	0	0	0	155	0	0
C9	3	5	4	0	0	0	0	0	143	0
C10	0	0	0	1	0	0	0	0	0	154
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10

b)

C1	0.92	0.0065	0	0	0	0	0	0	0.071	0
C2	0.0065	0.94	0.019	0	0	0	0.0065	0	0.026	0
C3	0.019	0	0.9	0	0	0.032	0	0	0.039	0.0065
C4	0	0	0	1	0	0	0	0	0	0
C5	0	0	0	0	1	0	0	0	0	0
C6	0	0	0	0	0	1	0	0	0	0
C7	0	0	0	0	0	0	1	0	0	0
C8	0	0	0	0	0	0	0	1	0	0
C9	0.019	0.032	0.026	0	0	0	0	0	0.92	0
C10	0	0	0	0.0065	0	0	0	0	0	0.99
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10

Σχήμα 7.6 Αποτελέσματα του πίνακα σύγκρισης για τα εκπαιδευτικά δεδομένα της εφαρμογής QGA-SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια)

C1	74	0	0	0	0	0	0	0	1	0
C2	1	68	0	0	0	0	0	0	5	1
C3	0	0	68	0	0	0	0	0	7	0
C4	0	0	0	75	0	0	0	0	0	0
C5	0	0	0	0	75	0	0	0	0	0
C6	0	0	0	0	0	75	0	0	0	0
C7	0	0	0	0	0	0	75	0	0	0
C8	0	0	0	0	0	0	0	75	0	0
C9	3	3	1	0	0	0	0	0	68	0
C10	0	0	0	1	0	0	0	0	0	74
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10

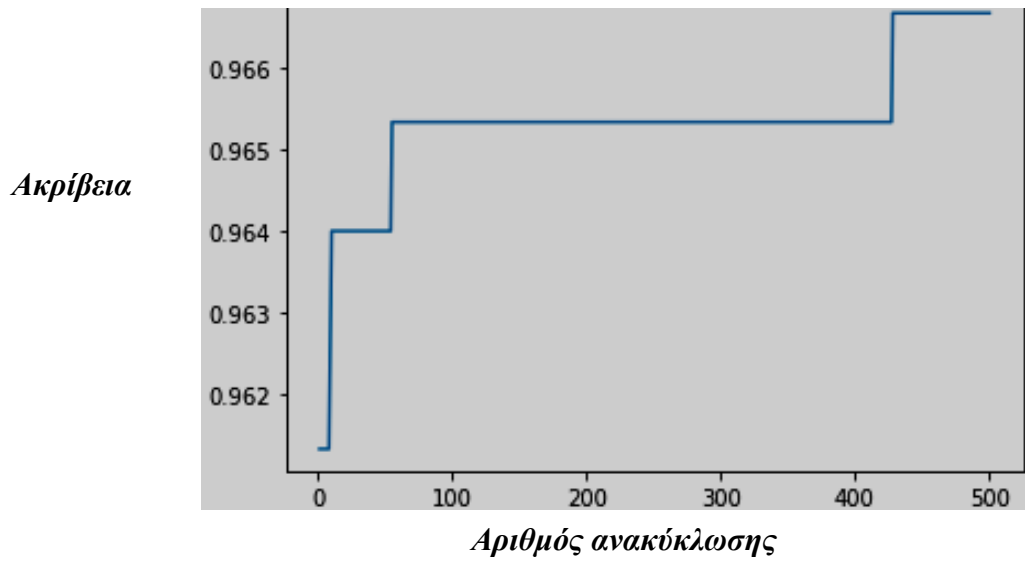
α)

C1	0.99	0	0	0	0	0	0	0	0.013	0
C2	0.013	0.91	0	0	0	0	0	0	0.067	0.013
C3	0	0	0.91	0	0	0	0	0	0.093	0
C4	0	0	0	1	0	0	0	0	0	0
C5	0	0	0	0	1	0	0	0	0	0
C6	0	0	0	0	0	1	0	0	0	0
C7	0	0	0	0	0	0	1	0	0	0
C8	0	0	0	0	0	0	0	1	0	0
C9	0.04	0.04	0.027	0	0	0	0	0	0.89	0
C10	0	0	0	0.013	0	0	0	0	0	0.99
	C1	C2	0.013	C4	C5	C6	C7	C8	C9	C10

β)

Σχήμα 7.7 Αποτελέσματα του πίνακα σύγκρισης για τα δεδομένα δοκιμής της εφαρμογής QGA-SVM. α) Σύνολο ορθά κατηγοριοποιημένων δεδομένων, β) ποσοστιαία τιμή των ορθά κατηγοριοποιημένων δεδομένων (ακρίβεια)

QGA-SVM rbf



Σχήμα 7.8 Βελτιστοποίηση της ακρίβειας του αλγόριθμου QGA-SVM (0.9667) και αριθμός των γενεών (ανακυκλώσεων)

```
iteration is : 500 ;Best parameters: [13.51314552307129, 0.3829430389404297] ;Best fitness 0.966666666666667
0.878666666666667
0.848
0.866666666666667
0.824
0.830666666666667
0.944
0.862666666666667
0.936
0.853333333333334
0.944
0.846666666666667
0.950666666666667
0.932
0.913333333333333
0.869333333333333
0.890666666666667
0.850666666666667
0.821333333333334
```

Σχήμα 7.9 Αποτέλεσμα ακρίβειας (Best fitness=0.9667) που υπολογίσθηκε

8. Συγκρίσεις, σύνοψη και συμπεράσματα

8.1 Συγκρίσεις μοντέλων SVM και QGA-SVM

Εφαρμογή 1^η. Από το προηγούμενο κεφάλαιο αντιλαμβάνεται κανείς ότι το ποσοστό ακρίβειας του QGA-SVM είναι μεγαλύτερο από αυτό των ερευνητών του Case Reserve University, κάτω από τις ίδιες συνθήκες υπολογισμού. Να αναφερθεί, επίσης, ότι την τιμή $\text{best fitness}=0.9653$ ο αλγόριθμος QGA-SVM την υπολόγισε μετά από 77 ανακυκλώσεις, Σχήμα 7.8. Γίνεται αποδεκτό το γεγονός ότι η μέθοδος QGA-SVM του κλασσικού γενετικού αλγόριθμου, ως μέσο βελτιστοποίησης των αποτελεσμάτων, είναι αποδοτικότερη από αυτήν του αλγόριθμου SVM. Η κβαντική του εκδοχή του SVM επέφερε σαφώς καλύτερα αποτελέσματα της SVM, ως προς το βέλτιστο αποτέλεσμα, μετά από 430 ανακυκλώσεις. Προηγούμενες εκτελέσεις του κβαντικού αλγορίθμου με διαφορετικές τιμές εκτέλεσης αυτού όπως π.χ. πλήθος πληθυσμού, αριθμός χρωμοσωμάτων, έφεραν το ίδιο αποτέλεσμα, δηλ. $\text{best fitness}=0.9653$ με τον συμβατικό αλγόριθμο μετά από 77 ανακυκλώσεις.

Η ουσιώδης όμως διαφορά του κβαντικού QGA-SVM με τον κλασσικό γενετικό αλγόριθμο SVM είναι στο ότι η τιμή των παραμέτρων των δυο αλγορίθμων βρίσκεται με διαφορετικό τρόπο ο ένας από τον άλλο. Στην τεχνική SVM καθορίζεται ένα αριθμός τιμών για τις παραμέτρους C και gamma βάσει των οποίων δίνεται η λύση της βελτιστοποίησης μετά από πολλές δοκιμές προκειμένου να βρεθούν οι παράμετροι. Η όλη βέβαια διαδικασία είναι αρκετά χρονοβόρα. Αυτό όμως δεν συμβαίνει με τον αλγόριθμο QGA-SVM. Εδώ οι τιμές των παραμέτρων του πυρήνα υπολογίζονται αυτόματα και βελτιστοποιούνται ταυτόχρονα μέσω του κβαντικού γενετικού αλγορίθμου.

Η εύρεση καλύτερου ατόμου της γενιάς μέσω των περιστρεφόμενων πυλών αλλά και η βελτιστοποίηση των παραμέτρων C και gamma είναι μεγάλης σημασίας μιας που είναι καθοριστικοί συντελεστές για τη βέλτιστη εύρεση του υπερ-επίπεδου του SVM, ώστε να γίνει καλύτερη κατηγοριοποίηση. Ο Πίνακας 8.1 δείχνει την διαγνωστική ακρίβεια των μεθόδων SVM, QGA-SVM για την 1^η Εφαρμογή.

Μέθοδος	Αριθμός δεδομένων δοκιμής	Αριθμός σωστά διαγνωσμένων λαθών	Διαγνωστική ακρίβεια
SVM	2300	2220	0.9653
QGA-SVM	2300	2223	0.9667

Πίνακας 8.1 Διαγνωστική ακρίβεια των μεθόδων SVM και QGA-SVM για την 1^η Εφαρμογή

Εφαρμογή 2^η. Στο Πίνακα 8.2 φαίνονται τα αποτελέσματα που προέκυψαν ανάμεσα στους δύο αλγορίθμους SVM και QGA-SVM για την 2^η Εφαρμογή. Τα αποτελέσματα της σύγκρισης μεταξύ των αλγορίθμων δίνουν μεγαλύτερη διαγνωστική ακρίβεια με τιμή ίση με 0.925 για την μέθοδο QGA-SVM και μόνο 0.85 για την μέθοδο SVM. Τα πλεονεκτήματα που αναφέρονται στην Εφαρμογή 1^η ισχύουν και εδώ, δηλ. η κβαντική εκδοχή του SVM επέφερε καλύτερο αποτέλεσμα σε σχέση με την απλή SVM μέθοδο.

Μέθοδος	Αριθμός δεδομένων δοκιμής	Αριθμός σωστά διαγνωσμένων λαθών	Διαγνωστική ακρίβεια
SVM	40	34	0.85
QGA-SVM	40	37	0.925

Πίνακας 8.2 Διαγνωστική ακρίβεια των μεθόδων SVM QGA-SVM για την 2^η Εφαρμογή


Η τεχνική QGA-SVM είναι προτιμητέα δεδομένου ότι ανιχνεύει αυτόματα τις βέλτιστες τιμές των παραμέτρων της συνάρτησης του πυρήνα που στην παρούσα εργασία ήταν η συνάρτηση rbf.

8.2 Ευαισθησία των συντελεστών C και σ^2

Οι τιμές των συντελεστών C και $1/(2\sigma^2)$ (=gamma) είναι υψίστης σημασίας μιας που καθορίζουν την εύρεση του βέλτιστου διαχωριστικού υπερ-επίπεδου, (C and gamma

in SVM, 2021). Αυτό έχει ως συνέπεια την καλύτερη δυνατή κατηγοριοποίηση των δεδομένων.

Συντελεστής C. Το C είναι η παράμετρος που έχει ρυθμιστεί από τον εκπαιδευτικό αλγόριθμο και χρησιμοποιείται για τον έλεγχο του σφάλματος και το gamma είναι επίσης μια παράμετρος που καθορίζεται από τον εκπαιδευτικό αλγόριθμο και χρησιμοποιείται για να προσδιορίσει την σωστή καμπυλότητα του ορίου απόφασης, (C and Gamma in SVM, 2021). Όπως φαίνεται και στο Σχήμα 8.1, εάν το C έχει χαμηλή τιμή αυτό σημαίνει χαμηλό σφάλμα ενώ αν έχει μεγάλη τιμή συνεπάγεται και μεγάλο σφάλμα. Στη περίπτωση του κατωτέρω σχήματος με χαμηλή τιμή C υπάρχει μόνο 1 σφάλμα, αλλά στην περίπτωση μεγάλης τιμής του C υπάρχουν 4 σφάλματα.

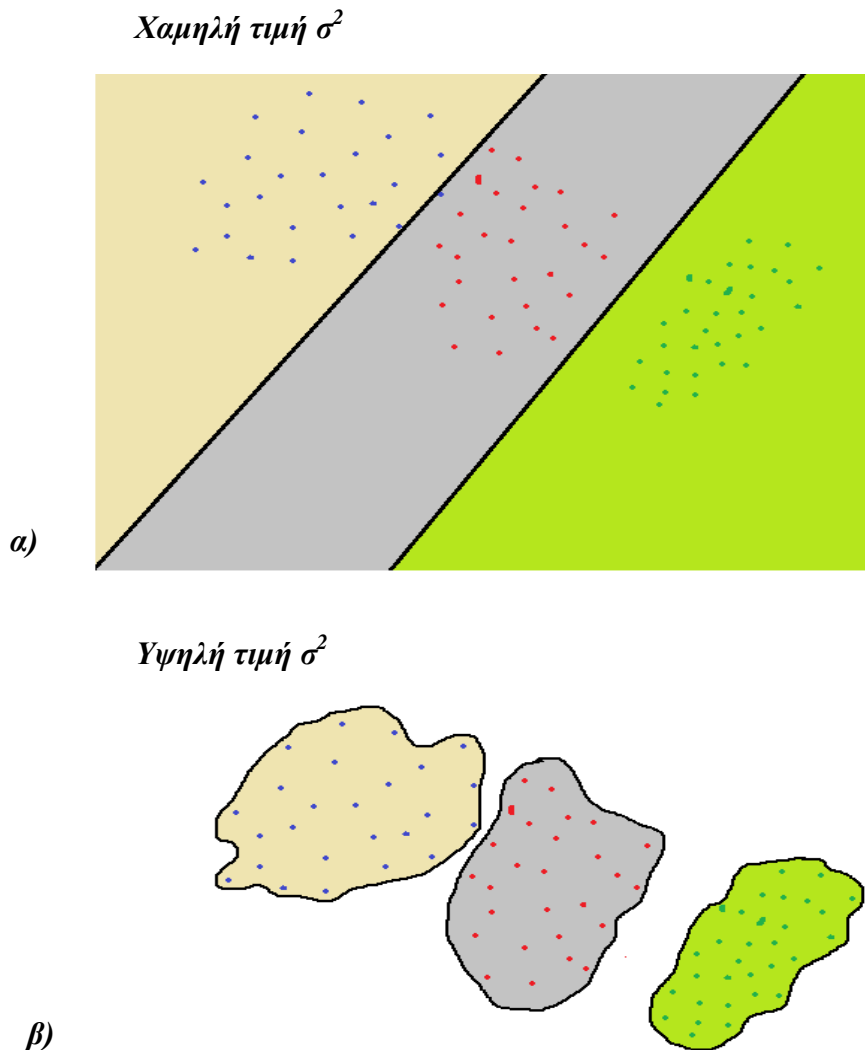


Σχήμα 8.1 Ενδείξεις χαμηλής και υψηλής τιμής του συντελεστή C

Τιμή του σ^2 . Το σ^2 χρησιμοποιείται στον πυρήνα rbf. Στον γραμμικό ή πολυωνυμικό πυρήνα δεν χρειάζεται η σ^2 αλλά μόνο η παράμετρος C. Στην πραγματικότητα, οι παράμετροι C και σ^2 σχετίζονται μεταξύ τους.

Η υψηλή τιμή του σ^2 ή gamma σημαίνει μεγαλύτερη καμπυλότητα ενώ χαμηλή τιμή γ , μικρότερη καμπυλότητα. Όπως φαίνεται και στο Σχήμα 8.2α, η εικόνα αντιπροσωπεύει την υπόθεση με χαμηλές τιμές σ^2 , (Hyperparameter tuning for support vector machines - c and gamma parameters, 2020). Η ακτίνα καμπυλότητας είναι μεγάλη, ώστε όλα τα σημεία στις χρωματιστές περιοχές να θεωρούνται στην ίδια κατηγορία. Από την άλλη μεριά, Σχήμα 8.2β, είναι η περίπτωση με μεγάλη τιμή του σ^2 . Για να ομαδοποιηθούν τα σημεία δεδομένων στην ίδια τάξη πρέπει να βρίσκονται στην περιοχή εντός ορίου. Έτσι, ένας μικρός θόρυβος μπορεί να προκαλέσει το σημείο δεδομένων να πέσει εκτός τάξης. Οι μεγάλες τιμές σ^2 είναι πιθανό να καταλήξουν σε υπερβολική τοποθέτηση. Καθώς το σ^2 μειώνεται, οι περιοχές που χωρίζουν διαφορετικές τάξεις γίνονται πιο γενικευμένες. Πολύ μεγάλες τιμές σ^2 οδηγούν σε πολύ συγκεκριμένες

περιοχές κατηγορίας (υπερφόρτωση). Εάν πρέπει να χρησιμοποιηθεί ένας πυρήνας rbf, τότε τόσο η παράμετρος C όσο και η σ^2 πρέπει να βελτιστοποιηθούν ταυτόχρονα. Εάν το σ^2 είναι μεγάλο, το αποτέλεσμα που επιφέρει η τιμή αυτή γίνεται αμελητέο. Εάν το σ^2 έχει μικρή τιμή το C επηρεάζει το αλγόριθμο με τον ίδιο τρόπο που το επηρεάζει ένα γραμμικό μοντέλο.



Σχήμα 8.2 α) Ενδείξεις χαμηλής και β) υψηλής τιμής σ^2

Συντελεστές C και σ^2 παρούσας μελέτης. Στην εργασία αυτή, προκειμένου να επιλεχθούν σωστά οι παράμετροι C και σ^2 , γίνεται βελτιστοποίηση των παραμέτρων μέσω του κβαντικού αλγόριθμου QGA. Όπως αναφέρθηκε και σε προηγούμενη παράγραφο στην τελική ανακύκλωση της παρούσας εργασίας με $\text{best fitness}=0.9667$ η τιμή του $C=13.513$ και του $\text{gamma}=0.383$. Μετά από διαδοχικές επαναληπτικές διαδικασίες για το ίδιο πρόβλημα, το αποτέλεσμα της ακρίβειας υπολογίσθηκε ως ίσο

προς 0.9653 με τιμές $C=14.839$ και $\gamma=0.366$ που χρησιμοποιήθηκαν για να βρεθεί η λύση μετά από 77 ανακυκλώσεις. Σε άλλους υπολογισμούς το ίδιο βέλτιστο της ακρίβειας βρέθηκε να είναι $C=11.471$ και $\gamma=0.382$. Η βέλτιστη ακρίβεια επετεύχθη μετά από 9 ανακυκλώσεις. Συμπερασματικά η τιμή του σ^2 διαφοροποιείται ελάχιστα από υπολογισμό σε υπολογισμό ενώ η τιμή του C βρίσκεται γύρω στο 11.5-14.5 προκειμένου να βρεθεί η βέλτιστη τιμή.

8.3 Σύνοψη και συμπεράσματα

Επιτελικά επιλέχθηκε ένας αλγόριθμος βελτιστοποίησης ο οποίος δεν είχε εφαρμοστεί σε αντίστοιχες περιπτώσεις κατηγοριοποίησης των συγκεκριμένων δεδομένων. Η μέθοδος QGA-SVM σε αντίστοιχα πειράματα άλλων μελετητών είχε θετικά αποτελέσματα. Επιλέχθηκε λοιπόν να εφαρμοστεί σε πειραματικά δεδομένα που ήταν διαθέσιμα από το Πανεπιστήμιο του Case Western Reserve. Το τελικό συμπέρασμα ήταν ότι μέσω της βελτιστοποίησης των παραμέτρων του SVM, με τον κβαντικό γενετικό κώδικα, επέφερε καλύτερα αποτελέσματα (ακρίβεια). Η υπολογιστική τεχνική αυτή αποδείχθηκε ότι είναι πιο ευέλικτη από τη τυπική SVM τεχνική δεδομένου ότι οι παράμετροι επιλέγονται τυχαία σε κάθε επανάληψη με σκοπό την εύρεση της καλύτερης δυνατής ακρίβειας.

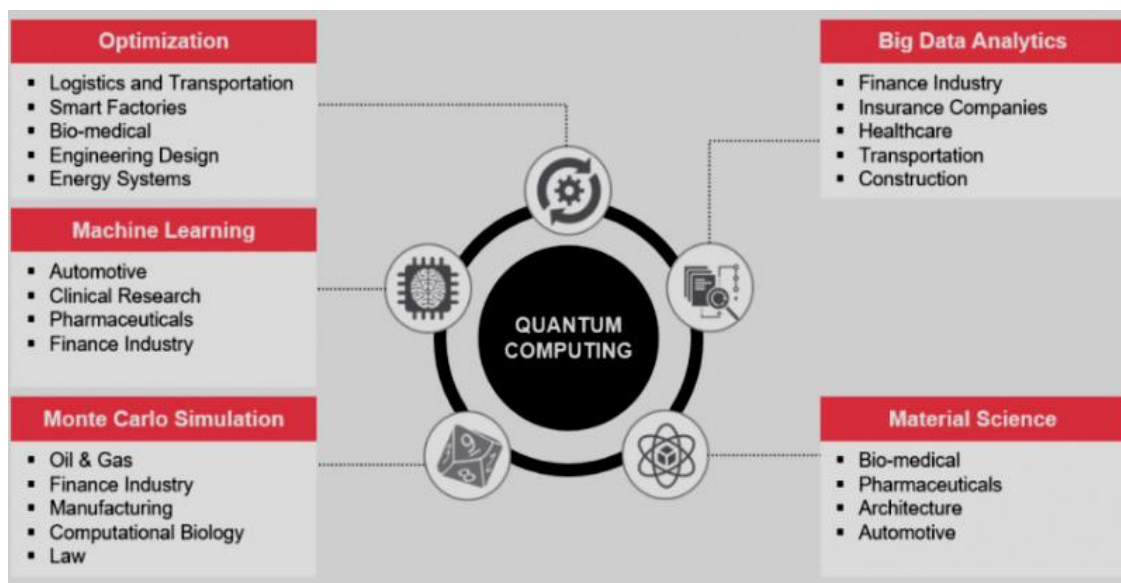
8.4 Όρια και περιορισμοί της έρευνας

Τα αποτελέσματα δείχνουν ότι επιτεύχθηκε ο καλύτερος στόχος. Ωστόσο, δεν έχει επιτευχθεί το βέλτιστο δυνατό αποτέλεσμα δηλ. το 100.0%. Το γεγονός αυτό μπορεί να οφείλεται σε θέματα λογισμικού αλλά και διαμόρφωσης των δεδομένων. Δηλαδή αν βρεθεί αλγόριθμος που κάνει καλύτερη κατηγοριοποίηση είναι εφικτό να βρεθεί ακόμα καλύτερο αποτέλεσμα. Ωστόσο, υπάρχουν εν γένει περιορισμοί, οι οποίοι αποτρέπουν το γεγονός της εύρεσης της καλύτερης λύσης σε συντομότερο χρόνο. Στη συγκεκριμένη περίπτωση, υπάρχουν δεδομένα, τα οποία βρίσκονται στο όριο των οποιονδήποτε διαφορετικών τύπων σφαλμάτων και έτσι η κατηγοριοποίησή τους γίνεται εσφαλμένα. Επίσης, θα υπάρχει πάντα η δυσκολία εύρεσης των παραμέτρων τόσο του SVM (C , ή γ), οι οποίοι κατηγοριοποιούν το πρόβλημα σε βέλτιστο βαθμό, όσο και του QGA, δηλ. αριθμό χρωμοσωμάτων, γωνία περιστροφής, μήκος χρωμοσώματος κ.ά. Ο συνδυασμός αυτών μεταξύ τους δυσκολεύει ακόμη περισσότερο τους υπολογισμούς. Τέλος, λόγω του μεγάλου όγκου των δεδομένων, χρειάζεται μεγάλη υπολογιστική ισχύ

και σωρεία επαναληπτικών υπολογιστικών διαδικασιών ώστε να βρεθεί το βέλτιστο δυνατό αποτέλεσμα.

8.5 Μελλοντικές επεκτάσεις

Για μελλοντική έρευνα, αναπόσπαστο κομμάτι θα παραμείνει η έννοια της κβαντικής μηχανικής και η εφαρμογή της σε υπολογιστικά συστήματα. Χρειάζεται μελέτη τόσο στις τιμές των παραμέτρων του SVM (C, gamma), όσο και στις τιμές του QGA (γωνία περιστροφής, αριθμός χρωμοσωμάτων...). Ο τρέχων αλγόριθμος υλοποιείται σε κλασικό περιβάλλον υπολογιστή με κβαντικές ιδιότητες, που όντας σαν υβριδικός αλγόριθμος, επιφέρει θετικά αποτελέσματα. Στις μέρες μας, τα δεδομένα έχουν αποκτήσει τεράστιο όγκο, και θα συνεχίσουν να αυξάνουν με γρήγορο ρυθμό. Απαιτείται λοιπόν να δοκιμασθούν νέες τεχνικές επεξεργασίας των δεδομένων τόσο σε επίπεδο υπολογιστών όσο και σε λογισμικό. Σκοπός είναι η συνεχής βελτίωση και εξέλιξη των ήδη υπάρχοντων συστημάτων που διαθέτει η επιστημονική κοινότητα. Η έννοια της κβαντικής μηχανικής και η εφαρμογή της σε υπολογιστικά συστήματα είναι σε πρώιμη φάση. Χρειάζεται συστηματική και χρόνια μελέτη ώστε αυτή να θεωρείται σαν ένα πλήρες και αξιόπιστο σύστημα υπολογισμού. Και αυτό με την έννοια ότι θα είναι ικανό να επεξεργάζεται με ταχύτατους ρυθμούς δεδομένα και να επιφέρει σημαντικά αποτελέσματα σε διάφορους τομείς και όχι μόνο της επιστήμης των υπολογιστών, Σχήμα 8.3.



Σχήμα 8.3 Εφαρμογές του κβαντικού υπολογισμού

9. Βιβλιογραφία-Αρθρογραφία, Διαδίκτυο

Βιβλιογραφία-Αρθρογραφία

Barenco, A. , Bennett, C.H., Cleve, R., DiVincenzo D.P., Margolus, N., Shor, P., Sleator, T., Smolin, J. and H. Weinfurter, (1995). *Elementary gates for quantum computation*. Phys .Rev. A52, 3457, [10.1103/PhysRevA.52.3457](https://doi.org/10.1103/PhysRevA.52.3457)

Bishop, C. M. 2006. *Pattern Recognition and Machine Learning*, Springer, [ISBN 978-0-387-31073-2](https://doi.org/10.1007/978-0-387-31073-2)

Combarro, E.F. 2020. *A practical introduction to quantum computing: From Qubits to quantum machine learning and beyond*, Cern OpenLab, Geneva, Switzerland

Friedman, J.H. (1998). *Data Mining and Statistics: What's the connection?* Computing Science and Statistics, 29(1): 3–9

Gosavi S. S., 2014. *Machine learning methods for fault classification*. Master's Thesis Nr. 3580, Institute of Computer Architecture and Computer Engineering, University of Stuttgart, Stuttgart

Gurucharan, M.K. 2020. *Machine learning basics: Support vector machine (SVM) classification. Understand the Support Vector Mechanism and apply it to an real-time example*. Towards Data Science

Jiang Z.-Q., Fu H.-G., & L.-J. Li, (2005). *Support Vector Machine for mechanical faults classification*. Univ. SCI, 6A(5): 433-439

Kotsianti, S.B., (2013). *Decision trees: a recent overview*. Artificial Intelligence Review, 39(4): 261–283

Koza, J.R., Bennett, F.H., Andre, D. &M.AKeane, (1996). *Automated design of both the topology and sizing of analog electrical circuits using genetic programming*. Artificial

intelligence in design '96. Springer, Dordrecht, 151–170. [doi:10.1007/978-94-009-0279-4_9](https://doi.org/10.1007/978-94-009-0279-4_9)

Lee, J.-C., Lin, W.-M., Liao, G.-C. & T.-P. Tsao, (2011). *Quantum genetic algorithm for dynamic economic dispatch with valvepoint effects and including wind power system*. International Journal of Electrical Power & Energy Systems, 33(2): 189–197

McCallum, A., 2019. *Graphical models, Lecture 2: Bayesian network representation*. Univ. Of Massachusetts, Amherst, Boston

Mitchell, T., 1997. *Machine Learning*. New York: McGraw Hill. [ISBN 0-07-042807-7](https://www.isbn-international.org/product/0-07-042807-7). [OCLC 36417892](https://www.oclc.org/oclc2/oclcid/36417892)

Rychetsky, M., Ortmann, S., & M. Glesner, (1999). *Support vector approaches for engine knock detection*, Proc. Int. Joint Conf. Neural Netw., 2: 969-974

SaiToh, A., Rahimi, R. & M. Nakahara, (2014). *A quantum genetic algorithm with quantum crossover and mutation operations*, Quantum Information Processing, 13(3): 737–755

Simon, P., 2013. *Too big to ignore: The business case for big data*. Wiley, 89, [ISBN 978-1-118-63817-0](https://www.isbn-international.org/product/978-1-118-63817-0)

Wang, H., Liu, J., Zhi, J. & C. Fu, (2013). *Mathematical problems in engineering*. Hindawi, Article ID 730749, <https://doi.org/10.1155/2013/730749>

Wei, Y., Li, Y., Xu, N. & and W. Huang, (2019). *A Review of early fault diagnosis approaches and their applications in rotating machinery*. Entropy 2019, 21, 409; [doi:10.3390/e21040409](https://doi.org/10.3390/e21040409)

Xiao, H., Fan, K.Q., Wu, J.P. & S.Z. Yang, (2001). *Study on SVM for fault diagnosis*", J. Vib. Meas. Diagnosis, 21(4): 258-262

Zhang, X. & D. Jiang, (2017). *Screw remaining life prediction based on quantum genetic algorithm and support vector machine*. Hindawi, Shock and Vibration, Article ID 9581379, 13 pages, <https://doi.org/10.1155/2017/9581379>

Zhang, S., Zhang, S., Wang, B., & T. G. Habetler, 2020. *Deep learning algorithms for bearing fault diagnostics – A Comprehensive Review*. IEEE Access, 8: 29857-29981. [doi: 10.1109/ACCESS.2020.2972859](https://doi.org/10.1109/ACCESS.2020.2972859)

Jiang, Z.-Q, Fu, H.-G. & L.-J. Li, (2005). *Support vector machine for mechanical faults classification*. Journal of Zhejiang University Science, 6A(5): 433-439

Zhu, I., Xiong, J. & Q. Liang, 2018. *Fault diagnosis of rotation machinery based on support vector machine optimized by quantum genetic algorithm*. IEEE, Special section on key technologies for smart factory of industry 4.0, 8: 3583-33588. [doi: 10.1109/ACCESS.2018.2789933](https://doi.org/10.1109/ACCESS.2018.2789933).

Ιστοσελίδες

Bearing data center, Available at:

<https://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website> (Μάιος 31 2021).

Bearing data center drive end fault, Available at:

<https://csegroups.case.edu/bearingdatacenter/pages/12k-drive-end-bearing-fault-data> (May 31 2021).

Bearing data center download files, Available at:

<https://csegroups.case.edu/bearingdatacenter/pages/download-data-file> (May 31 2021).

Machine learning classification, Available at:

<https://d-nb.info/1055944281/34> (April 24 2014).

Genetic Algorithm, Available at:

<https://en.wikipedia.org/wiki/Crossover>

Λήψη και επεξεργασία δεδομένων, Available at:

https://en.wikipedia.org/wiki/Data_acquisition (May 21 2021).

Machine Learning, Available at:

https://en.wikipedia.org/wiki/Machine_learning (May 21 2021).

Bearing data center drive end fault, Available at :

https://github.com/biswajitsahoo111/cbm_codes_open/blob/master/notebooks/Calculating_time_domain_features_CWRU.ipynb (February 13 2020).

C and gamma in SVM, Available at:

<https://medium.com/@myselfaman12345/c-and-gamma-in-svm-e6cee48626be>

(December 17 2018).

Hyperparameter tuning for support vector machines c and gamma parameters, Available at:

<https://towardsdatascience.com/hyperparameter-tuning-for-support-vector-machines-c-and-gamma-parameters-6a5097416167> (May 21 2020).

SVM classification, Available at:

<https://towardsdatascience.com/machine-learning-basics-support-vector-machine-svm-classification-205ecd28a09d> (August 30 2020).

Idiot' s guide to SVM, MIT, Available at:

<https://web.mit.edu/6.034/wwwbob/svm.pdf>

Παράρτημα Ι Πίνακας μετρήσεων και διαστάσεις των δυο ρουλεμάν

Πίνακας 1.1 Πίνακας των αλλοιώσεων που εισήχθησαν στα ρουλεμάν στο Πανεπιστήμιο Case Western Reserve των Η.Π.Α. Όλες οι τιμές σε ίντσες, 1”=2.54 cm

<i>Ρουλεμάν</i>	<i>Θέση αλλοιώσεων</i>	<i>Διάμετρος ίντσες</i>	<i>Βάθος ίντσες</i>	
<i>Drive End</i>	<i>Inner Raceway</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Inner Raceway</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Inner Raceway</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Outer Raceway</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Outer Raceway</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Outer Raceway</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Ball</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Ball</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Drive End</i>	<i>Ball</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Inner Raceway</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Inner Raceway</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Inner Raceway</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Outer Raceway</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Outer Raceway</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Outer Raceway</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Ball</i>	<i>.007</i>	<i>.011</i>	<i>SKF</i>

<i>Fan End</i>	<i>Ball</i>	<i>.014</i>	<i>.011</i>	<i>SKF</i>
<i>Fan End</i>	<i>Ball</i>	<i>.021</i>	<i>.011</i>	<i>SKF</i>

Πίνακας I.2 Διαστάσεις των δυο ρουλεμάν που χρησιμοποιήθηκαν για τις μετρήσεις στο Case Western Reserve των Η.Π.Α. 1”=2.54 cm

6205-2RSJEMSKF

<i>Inside Diameter inches</i>	<i>Outside Diameter inches</i>	<i>Thickness inches</i>	<i>Ball Diameter inches</i>	<i>Pitch Diameter inches</i>
<i>0.9843</i>	<i>2.0472</i>	<i>0.5906</i>	<i>0.3126</i>	<i>1.537</i>

6203-2RS JEM SKF

<i>Inside Diameter inches</i>	<i>Outside Diameter inches</i>	<i>Thickness Inches</i>	<i>Ball Diameter inches</i>	<i>Pitch Diameter Inches</i>
<i>0.6693</i>	<i>1.5748</i>	<i>0.4724</i>	<i>0.2656</i>	<i>1.122</i>

Παράρτημα II Δεδομένα κανονικής και προβληματικής λειτουργίας

Πίνακας II.1 Δεδομένα κανονικής λειτουργίας του κινητήρα χωρίς αλλοιώσεις. Case Western Reserve των Η.Π.Α

<i>Motor Load (HP)</i>	<i>Approx. Motor Speed (rpm)</i>	<i>Normal Baseline Data</i>
0	1797	<u>Normal 0</u>
1	1772	<u>Normal 1</u>
2	1750	<u>Normal 2</u>
3	1730	<u>Normal 3</u>

Πίνακας II.2 Δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 12.0 kHz. Case Western Reserveτων Η.Π.Α

<i>Fault Diameter</i>	<i>Motor Load (HP)</i>	<i>Approx. Motor Speed (rpm)</i>	<i>Inner Race</i>	<i>Ball</i>	<i>Outer Race Position Relative to Load Zone (Load Zone Centered at 6:00)</i>		
					<i>Centered @6:00</i>	<i>Orthogonal @3:00</i>	<i>Opposite @12:00</i>
0.007"	0	1797	<u>IR007_0</u>	<u>B007_0</u>	<u>OR007@6_0</u>	<u>OR007@3_0</u>	<u>OR007@12_0</u>
	1	1772	<u>IR007_1</u>	<u>B007_1</u>	<u>OR007@6_1</u>	<u>OR007@3_1</u>	<u>OR007@12_1</u>
	2	1750	<u>IR007_2</u>	<u>B007_2</u>	<u>OR007@6_2</u>	<u>OR007@3_2</u>	<u>OR007@12_2</u>
	3	1730	<u>IR007_3</u>	<u>B007_3</u>	<u>OR007@6_3</u>	<u>OR007@3_3</u>	<u>OR007@12_3</u>
0.014"	0	1797	<u>IR014_0</u>	<u>B014_0</u>	<u>OR014@6_0</u>	*	*
	1	1772	<u>IR014_1</u>	<u>B014_1</u>	<u>OR014@6_1</u>	*	*
	2	1750	<u>IR014_2</u>	<u>B014_2</u>	<u>OR014@6_2</u>	*	*
	3	1730	<u>IR014_3</u>	<u>B014_3</u>	<u>OR014@6_3</u>	*	*
0.021"	0	1797	<u>IR021_0</u>	<u>B021_0</u>	<u>OR021@6_0</u>	<u>OR021@3_0</u>	<u>OR021@12_0</u>
	1	1772	<u>IR021_1</u>	<u>B021_1</u>	<u>OR021@6_1</u>	<u>OR021@3_1</u>	<u>OR021@12_1</u>
	2	1750	<u>IR021_2</u>	<u>B021_2</u>	<u>OR021@6_2</u>	<u>OR021@3_2</u>	<u>OR021@12_2</u>
	3	1730	<u>IR021_3</u>	<u>B021_3</u>	<u>OR021@6_3</u>	<u>OR021@3_3</u>	<u>OR021@12_3</u>
0.028"	0	1797	<u>IR028_0</u>	<u>B028_0</u>	*	*	*
	1	1772	<u>IR028_1</u>	<u>B028_1</u>	*	*	*

	2	1750	<u>IR028_2</u>	<u>B028_2</u>	*	*	*
	3	1730	<u>IR028_3</u>	<u>B028_3</u>	*	*	*

Πίνακας II.3 Δεδομένα προβληματικής λειτουργίας του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 48.0 kHz. Case Western Reserve των Η.Π.Α.

<i>Fault Diameter</i>	<i>Motor Load (HP)</i>	<i>Approx. Motor Speed (rpm)</i>	<i>Inner Race</i>	<i>Ball</i>	<i>Outer Race Position Relative to Load Zone (Load Zone Centered at 6:00)</i>		
					<i>Centered @6:00</i>	<i>Orthogonal @3:00</i>	<i>Opposite @12:00</i>
0.007"	0	1797	<u>IR007_0</u>	<u>B007_0</u>	<u>OR007@6_0</u>	<u>OR007@3_0</u>	<u>OR007@12_0</u>
	1	1772	<u>IR007_1</u>	<u>B007_1</u>	<u>OR007@6_1</u>	<u>OR007@3_1</u>	<u>OR007@12_1</u>
	2	1750	<u>IR007_2</u>	<u>B007_2</u>	<u>OR007@6_2</u>	<u>OR007@3_2</u>	<u>OR007@12_2</u>
	3	1730	<u>IR007_3</u>	<u>B007_3</u>	<u>OR007@6_3</u>	<u>OR007@3_3</u>	<u>OR007@12_3</u>
0.014"	0	1797	<u>IR014_0</u>	<u>B014_0</u>	<u>OR014@6_0</u>	*	*
	1	1772	<u>IR014_1</u>	<u>B014_1</u>	<u>OR014@6_1</u>	*	*
	2	1750	<u>IR014_2</u>	<u>B014_2</u>	<u>OR014@6_2</u>	*	*
	3	1730	<u>IR014_3</u>	<u>B014_3</u>	<u>OR014@6_3</u>	*	*
0.021"	0	1797	<u>IR021_0</u>	<u>B021_0</u>	<u>OR021@6_0</u>	<u>OR021@3_0</u>	<u>OR021@12_0</u>
	1	1772	<u>IR021_1</u>	<u>B021_1</u>	<u>OR021@6_1</u>	<u>OR021@3_1</u>	<u>OR021@12_1</u>
	2	1750	<u>IR021_2</u>	<u>B021_2</u>	<u>OR021@6_2</u>	<u>OR021@3_2</u>	<u>OR021@12_2</u>
	3	1730	<u>IR021_3</u>	<u>B021_3</u>	<u>OR021@6_3</u>	<u>OR021@3_3</u>	<u>OR021@12_3</u>

Πίνακας II.4 Δεδομένα προβληματικής λειτουργίας του άκρου του ανεμιστήρα (fan end) του κινητήρα με δειγματοληψία 12.0 kHz. Case Western Reservetov H.Π.Α.

<i>Fault Diameter</i>	<i>Motor Load (HP)</i>	<i>Approx. Motor Speed (rpm)</i>	<i>Inner Race</i>	<i>Ball</i>	<i>Outer Race Position Relative to Load Zone (Load Zone Centered at 6:00)</i>		
					<i>Centered @6:00</i>	<i>Orthogonal @3:00</i>	<i>Opposite @12:00</i>
0.007"	0	1797	<u>IR007_0</u>	<u>B007_0</u>	<u>OR007@6_0</u>	<u>OR007@3_0</u>	<u>OR007@12_0</u>
	1	1772	<u>IR007_1</u>	<u>B007_1</u>	<u>OR007@6_1</u>	<u>OR007@3_1</u>	<u>OR007@12_1</u>
	2	1750	<u>IR007_2</u>	<u>B007_2</u>	<u>OR007@6_2</u>	<u>OR007@3_2</u>	<u>OR007@12_2</u>
	3	1730	<u>IR007_3</u>	<u>B007_3</u>	<u>OR007@6_3</u>	<u>OR007@3_3</u>	<u>OR007@12_3</u>
0.014"	0	1797	<u>IR014_0</u>	<u>B014_0</u>	<u>OR014@6_0</u>	<u>OR014@3_0</u>	*
	1	1772	<u>IR014_1</u>	<u>B014_1</u>	*	<u>OR014@3_1</u>	*
	2	1750	<u>IR014_2</u>	<u>B014_2</u>	*	<u>OR014@3_2</u>	*
	3	1730	<u>IR014_3</u>	<u>B014_3</u>	*	<u>OR014@3_3</u>	*
0.021"	0	1797	<u>IR021_0</u>	<u>B021_0</u>	<u>OR021@6_0</u>	*	*
	1	1772	<u>IR021_1</u>	<u>B021_1</u>	*	<u>OR021@3_1</u>	*
	2	1750	<u>IR021_2</u>	<u>B021_2</u>	*	<u>OR021@3_2</u>	*
	3	1730	<u>IR021_3</u>	<u>B021_3</u>	*	<u>OR021@3_3</u>	*

Παράρτημα III Δεδομένα των πρώτων σειρών της σφαίρας

"Ball_007_1"

Πίνακας III.1 Τυπικά δεδομένα των πρώτων σειρών της σφαίρας "Ball_007_1" του άκρου κίνησης (drive end) του κινητήρα με δειγματοληψία 48.0 kHz με τις τιμές των χαρακτηριστικών, "max", "min", "mean", "sd", "rms", "skewness", "kurtosis", "crest", "form", "fault". Case Western Reserve των Η.Π.Α.

"max", "min", "mean", "sd", "rms", "skewness", "kurtosis", "crest", "form", "fault"

"0.35986", "0.4189", "0.0178404615917969", "0.122746393739283", "0.1240064614036", "0.118571177953009", "0.0422192362415159", "2.90194555934286", "6.95085498575995", "Ball_007_1"

"0.46772", "0.36111", "0.0222547985693359", "0.132487982381237", "0.134312213525282", "0.174698897226241", "-0.0815475723724686", "3.48233409102411", "6.03520239047888", "Ball_007_1"

"0.46855", "0.43809", "0.0204702956054688", "0.149650511997173", "0.15100785923242", "0.0403389535040056", "-0.274068941842734", "3.10281863726605", "7.37692616378619", "Ball_007_1"

"0.58475", "-0.54303", "0.0209597297949219", "0.157067463672051", "0.158421754904881", "0.0232661286769481", "0.134692325939394", "3.69109659434774", "7.55838727192294", "Ball_007_1"

"0.44685", "-0.57891", "0.0221673441357422", "0.138188796289513", "0.139922157920744", "0.0815336788586023", "0.402783305604845", "3.19356138184425", "6.31208488774874", "Ball_007_1"

"0.43726", "-0.44435", "0.0211192745117188", "0.138763372626031", "0.140327813883771", "0.131328677344107", "-0.168557468476016", "3.11598953834034", "6.64453761448599", "Ball_007_1"

"0.45353", "-0.49129", "0.0214640222363281", "0.138461383829647", "0.140081754528684", "0.114174680280226", "0.308106789277399", "3.23760936266067", "6.52635153776507", "Ball_007_1"

"0.43955", "-0.45228", "0.020860203203125", "0.150120010555445", "0.151526109076997", "0.0219554713919627", "-0.272298053513555", "2.90082021294856", "7.26388461327631", "Ball_007_1"

Παράρτημα IV Υπολογιστικός αλγόριθμος QGA-SVM

Πίνακας IV.1 Υπολογιστικός αλγόριθμος QGA-SVM

Libraries

```
import numpy as np
import pandas as pd
from tensorflow.keras.utils import to_categorical
from sklearn import svm
from sklearn.model_selection import train_test_split
from sklearn import metrics
import random
import math
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import confusion_matrix, accuracy_score
import seaborn as sns
```

1. Process Data

```
def load_data():
    data_time = pd.read_csv("svm_data.txt")
    data_time['fault'] = pd.Categorical(data_time['fault'])

    train_data, test_data = train_test_split(data_time, test_size = 750, stratify =
        data_time['fault'], random_state = 1234)

    test_data['fault'].value_counts()
    scaler = StandardScaler()
    train_data_scaled = scaler.fit_transform(train_data.iloc[:, :-1])
    test_data_scaled = (test_data.iloc[:, :-1].values - scaler.mean_) / np.sqrt(scaler.var_)
    return train_data_scaled, train_data['fault'], test_data_scaled, test_data['fault']
```

2. QGA Algorithm

class QGA(object):

2.1 Initialize class parameters

```
def __init__(self, population_size, chromosome_num, chromosome_length,  
            max_value, min_value, iter_num, deta):
```

```
population_size(int): Number of population
```

```
chromosome_num(int): The number of chromosomes, corresponding to the  
number of parameters that need to be optimize chromosome
```

```
length(int): Chromosome length max_value(float): Chromosome decimal value
```

```
maximum min_value(float): Chromosome decimal value minimum
```

```
iter_num(int): Number of iterations deta(float): Quantum rotation angle """
```

```
self.population_size = population_size
```

```
self.chromosome_num = chromosome_num
```

```
self.chromosome_length = chromosome_length
```

```
self.max_value = max_value
```

```
self.min_value = min_value
```

```
self.iter_num = iter_num
```

```
self.deta = deta
```

2.2 Quantum formalization of population

```
def species_origin_angle(self):
```

```
population_Angle = []
```

```
"""population initialization input:self(object):QGAClass output:population_Angle(list):
```

```
Population quantum point list population_Angle2(list):A list of quantum angles of empty
```

```
populations used to store a list of quantum angles after intersection"""
```

```
for i in range(self.chromosome_num):
```

```
    tmp1 = [] ##Store the quantum angle of all values for each chromosome
```

```
    for j in range(self.population_size):
```

```
        tmp2 = [] ## Storage Quantum Angle
```

```
        for m in range(self.chromosome_length):
```

```
            a = np.pi * 2 * random.random()
```

```
            tmp2.append(a)
```

```

        tmp1.append(tmp2)
    population_Angle.append(tmp1)
    return population_Angle
def population_Q(self,population_Angle):
    """Convert the initialized quantum angle sequence to a list of quantum coefficients
    of the population input:self(object):QGAClass population_Angle(list):
    Population quantum point list output:population_Q(list):List of quantum
    coefficients of the population """
    population_Q = []
    for i in range(len(population_Angle)):
        tmp1 = [] ##Store pairs of quantum coefficients for all values of each
                chromosome
        for j in range(len(population_Angle[i])):
            tmp2 = [] ## store a quantum pair of each value of each chromosome
            tmp3 = [] ## Store half of the quantum pair
            tmp4 = [] ## Store the other half of the quantum pair

            for m in range(len(population_Angle[i][j])):
                a = population_Angle[i][j][m]
                tmp3.append(np.sin(a))
                tmp4.append(np.cos(a))
                tmp2.append(tmp3)
                tmp2.append(tmp4)
                tmp1.append(tmp2)
            population_Q.append(tmp1)
    return population_Q

```

2.3 Calculating the fitness function value

```

def translation(self,population_Q):
    """Convert the quantum list of the population into a binary list
    input:self(object):QGAClass population_Q(list):Quantum list of populations
    output:population_Binary:Binary list of populations """
    population_Binary = []

```



```

for i in range(len(population_Q)):
    tmp1 = [] # Store the binary form of all values for each chromosome
    for j in range(len(population_Q[i])):
        tmp2 = [] ##Store the binary form of each value of each chromosome
        for l in range(len(population_Q[i][j][0])):
            if np.square(population_Q[i][j][0][l]) > random.random():
                tmp2.append(1)
            else:
                tmp2.append(0)
        tmp1.append(tmp2)
    population_Binary.append(tmp1)
return population_Binary

def fitness(self,population_Binary):
    """To obtain a list of fitness function values, the fitness function used in this
    experiment isRBF_SVMof3_fold cross validation average
    input:self(object):QGAClass population_Binary(list):Binary list of populations
    output:fitness_value(list):Fitness function value class table
    parameters(list):List of corresponding optimization parameters """

    ##1.The binary representation of the chromosome is converted to decimal and
    set in[min_value,max_value]Between
    parameters = [] ##Store the possible values of all parameters
    for i in range(len(population_Binary)):
        tmp1 = [] ##Store the possible values of a parameter
        for j in range(len(population_Binary[i])):
            total = 0.0
            for l in range(len(population_Binary[i][j])):
                total += population_Binary[i][j][l] * math.pow(2,l)
                ##Calculate the decimal value corresponding to the binary
            value = (total * (self.max_value - self.min_value)) /
                math.pow(2,len(population_Binary[i][j])) + self.min_value
                ## places the decimal value in[min_value,max_value]Between
            tmp1.append(value)

```

```

        tmp1.append(value)
    parameters.append(tmp1)
    fitness_value = []
    for l in range(len(parameters[0])):
        rbf_svm = svm.SVC(kernel = 'rbf', C = parameters[0][l], gamma =
            parameters[1][l])
        rbf_svm.fit(trainX, trainY)
        sc = rbf_svm.predict(testX)
        sc1 = rbf_svm.predict(trainX)
        train_accuracy = accuracy_score(trainY, sc1)
        test_accuracy = accuracy_score(testY, sc)
        train_confu_matrix = confusion_matrix(trainY, sc1)
        test_confu_matrix = confusion_matrix(testY, sc)
        fitness_value.append(test_accuracy)

```

3. Find the optimal fitness function value and the corresponding parameter binary representation

```

    best_fitness = 0.0
    best_parameter = []
    best_parameter_Binary = []
    for j in range(len(population_Binary)):
        tmp2 = []
        best_parameter_Binary.append(tmp2)
        best_parameter.append(tmp2)
    for i in range(len(population_Binary[0])):
        if best_fitness < fitness_value[i]:
            best_fitness = fitness_value[i]
            for j in range(len(population_Binary)):
                best_parameter_Binary[j] = population_Binary[j][i]
            best_parameter[j] = parameters[j][i]
    return parameters, fitness_value, best_parameter_Binary, best_fitness, best_parameter, train_
    confu_matrix, sc1

```

2.4 Full interference cross

```
def crossover(self,population_Angle):
    """Full interference crossover for the population quantum angle list
    input:self(object):QGAClass population_Angle(list):Population quantum point
    list"""

    ## Initialize an empty list, a list of quantum angles after full interference crossover
    population_Angle_crossover = []
    for i in range(self.chromosome_num):
        tmp11 = []
        for j in range(self.population_size):
            tmp21 = []
            for m in range(self.chromosome_length):
                tmp21.append(0.0)
            tmp11.append(tmp21)
        population_Angle_crossover.append(tmp11)
    for i in range(len(population_Angle)):
        for j in range(len(population_Angle[i])):
            for m in range(len(population_Angle[i][j])):
                ni = (j - m) % len(population_Angle[i])
                population_Angle_crossover[i][j][m] = population_Angle[i][ni][m]
    return population_Angle_crossover

def mutation(self,population_Angle_crossover,population_Angle,
best_parameter_Binary,best_fitness):
    """Quantum variation using quantum gate transformation matrix
    input:self(object):QGAClass population_Angle_crossover(list):Quantum angle
    list after full interference crossover output:population_
    Angle_mutation(list):List of quantum angles after mutation """

    ##1.Find the list of fitness function values after the intersection
    population_Q_crossover = self.population_Q(population_Angle_crossover)
    ## List of population quantum coefficients after intersection
    population_Binary_crossover = self.translation(population_Q_crossover)
```

```

        ## List of population binary numbers after intersection
parameters,fitness_crossover,best_parameter_Binary_crossover,best_fitness_crossover,
best_parameter,train_confu_matrix,sc1 = self.fitness(population_Binary_crossover)
        ## List of fitness function values after crossin

```

```

##2.Initialize the rotation angle of each qubit

```

```

Rotation_Angle = []
    for i in range(len(population_Angle_crossover)):
        tmp1 = []
        for j in range(len(population_Angle_crossover[i])):
            tmp2 = []
            for m in range(len(population_Angle_crossover[i][j])):
                tmp2.append(0.0)
            tmp1.append(tmp2)
        Rotation_Angle.append(tmp1)
deta = self.deta
    for i in range(self.chromosome_num):
        for j in range(self.population_size):
            if fitness_crossover[j] <= best_fitness:
                for m in range(self.chromosome_length):
                    s1 = 0
                    a1 = population_Q_crossover[i][j][0][m]
                    b1 = population_Q_crossover[i][j][1][m]
                    if population_Binary_crossover[i][j][m] == 0 and
                    best_parameter_Binary[i][m] == 0 and a1 * b1 > 0:
                        s1 = -1
                    if population_Binary_crossover[i][j][m] == 0 and
                    best_parameter_Binary[i][m] == 0 and a1 * b1 < 0:
                        s1 = 1
                    if population_Binary_crossover[i][j][m] == 0 and
                    best_parameter_Binary[i][m] == 0 and a1 * b1 == 0:
                        s1 = 1
                    if population_Binary_crossover[i][j][m] == 0 and

```

```

best_parameter_Binary[i][m] == 1 and a1 * b1 > 0:
    s1 = 1
if population_Binary_crossover[i][j][m] == 0 and
best_parameter_Binary[i][m] == 1 and a1 * b1 < 0:
    s1 = -1
if population_Binary_crossover[i][j][m] == 0 and
best_parameter_Binary[i][m] == 1 and a1 * b1 == 0:
    s1 = 1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 0 and a1 * b1 > 0:
    s1 = -1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 0 and a1 * b1 < 0:
    s1 = 1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 0 and a1 * b1 == 0:
    s1 = -1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 1 and a1 * b1 > 0:
    s1 = 1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 1 and a1 * b1 < 0:
    s1 = -1
if population_Binary_crossover[i][j][m] == 1 and
best_parameter_Binary[i][m] == 1 and a1 * b1 == 0:
    s1 = 1
Rotation_Angle[i][j][m] = deta * s1
else:
for m in range(self.chromosome_length):
    s2 = 0
    a2 = population_Q_crossover[i][j][0][m]
    b2 = population_Q_crossover[i][j][1][m]
    if population_Binary_crossover[i][j][m] == 0 and

```

$best_parameter_Binary[i][m] == 0$ and $a2 * b2 > 0$:
 $s2 = -1$
if $population_Binary_crossover[i][j][m] == 0$ and
 $best_parameter_Binary[i][m] == 0$ and $a2 * b2 < 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 0$ and
 $best_parameter_Binary[i][m] == 0$ and $a2 * b2 == 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 0$ and
 $best_parameter_Binary[i][m] == 1$ and $a2 * b2 > 0$:
 $s2 = -1$
if $population_Binary_crossover[i][j][m] == 0$ and
 $best_parameter_Binary[i][m] == 1$ and $a2 * b2 < 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 0$ and
 $best_parameter_Binary[i][m] == 1$ and $a2 * b2 == 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 1$ and
 $best_parameter_Binary[i][m] == 0$ and $a2 * b2 > 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 1$ and
 $best_parameter_Binary[i][m] == 0$ and $a2 * b2 < 0$:
 $s2 = -1$
if $population_Binary_crossover[i][j][m] == 1$ and
 $best_parameter_Binary[i][m] == 0$ and $a2 * b2 == 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 1$ and
 $best_parameter_Binary[i][m] == 1$ and $a2 * b2 > 0$:
 $s2 = 1$
if $population_Binary_crossover[i][j][m] == 1$ and
 $best_parameter_Binary[i][m] == 1$ and $a2 * b2 < 0$:
 $s2 = -1$
if $population_Binary_crossover[i][j][m] == 1$ and

```

best_parameter_Binary[i][m] == 1 and a2 * b2 == 0:
    s2 = 1
Rotation_Angle[i][j][m] = deta * s2

```

4. Generate a new list of quantum angles for each population based on the rotation angle of each qubit

```

for i in range(self.chromosome_num):
    for j in range(self.population_size):
        for m in range(self.chromosome_length):
            population_Angle[i][j][m] = population_Angle[i][j][m] +
                Rotation_Angle[i][j][m]

return population_Angle

```

2.5 Draw a graph of the results

```

def plot(self, results, train_confu, sc1):
    X = []
    Y = []

    for i in range(self.iter_num):
        X.append(i + 1)
        Y.append(results[i])

    fault_type = ['C1', 'C2', 'C3', 'C4', 'C5', 'C6', 'C7', 'C8', 'C9', 'C10']
    plt.figure(1, figsize=(18, 8))
    plt.subplot(121)
    train_confu_matrix = confusion_matrix(trainY, sc1)
    sns.heatmap(train_confu_matrix, annot=True, fmt="d",
                xticklabels=fault_type, yticklabels=fault_type, cmap="Blues", cbar=False)
    plt.title('Training Confusion Matrix')
    plt.xlabel('Predicted')
    plt.ylabel('True')
    plt.subplot(122)

```

```

sns.heatmap(train_confu_matrix/155, annot= True,
            xticklabels=fault_type, yticklabels=fault_type, cmap = "Blues",cbar = False)
plt.title('Training Confusion Matrix (in %age)')
plt.xlabel('Predicted')
plt.ylabel('True')
plt.show()
plt.plot(X,Y)
plt.xlabel('Number of iteration',size = 15)
plt.ylabel('Value of CV',size = 15)
plt.title('QGA_RBF_SVM parameter optimization')
plt.show()

```

2.6 Main function

```

def main(self):
    results = []
    best_fitness = 0.0
    best_parameter = []
    population_Angle= self.species_origin_angle()
    for i in range(self.iter_num):
        population_Q = self.population_Q(population_Angle)
        ## Converting quantum coefficients to binary form
        population_Binary = self.translation(population_Q)
        ## Calculate the list of fitness function values for this iteration, the optimal
        fitness function value and the corresponding parameters
        parameters,fitness_value,current_parameter_Binary,current_fitness,current_parameter,t
rain_confu_matrix,sc1 = self.fitness(population_Binary)
        ## Find the optimal fitness function value and corresponding parameters so far
        if current_fitness > best_fitness:
            best_fitness = current_fitness
            best_parameter = current_parameter
        print('iteration is :',i+1,';Best parameters:',best_parameter,';Best
            fitness',best_fitness)
        results.append(best_fitness)

```



```

## Full interference cross
    population_Angle_crossover = self.crossover(population_Angl
## Quantum rotation variation
    population_Angle
self.mutation(population_Angle_crossover,population_Angle,current_parameter_Binary,
current_fitness)
    results.sort()
    self.plot(results,train_confu_matrix,sc1)
    print('Final parameters are :',parameters[-1])
if __name__ == '__main__':
    print('-----1.Load Data-----')
    trainX,trainY,testX,testY = load_data()
    print('-----2.Parameter Seting-----')
    population_size=20
    chromosome_num=2
    chromosome_length=17
    max_value=15
    min_value=0.01
    iter_num=500
    deta=0.1 * np.pi
    print('-----3.QGA_RBF_SVM-----')
    qga
QGA(population_size,chromosome_num,chromosome_length,max_value,min_value,iter_
num,deta)
    qga.main().

```