



UNIVERSITATEA „POLITEHNICA” din BUCUREȘTI
ȘCOALA DOCTORALĂ DE INGINERIE MECANICĂ ȘI MECATRONICĂ

Nr. Decizie din

TEZĂ DE DOCTORAT

***Monitorizare și mentenanță inteligentă a unui sistem
mechatronic***

***Intelligent monitoring and maintenance of a
mechatronic system***

REZUMAT

Autor: Daniel CORDONEANU

Conducător de doctorat: Prof.dr.ing. Constantin NIȚU

COMISIA DE DOCTORAT

Președinte	Prof. Dr. Ing. Radu CHIRIAC	de la	Universitatea POLITEHNICA din București
Conducător de doctorat	Prof. Dr. Ing. Constantin NIȚU	de la	Universitatea POLITEHNICA din București
Referent	Prof. Dr. Ing. Mircea NIȚULESCU	de la	Universitatea din CRAIOVA
Referent	Prof. Dr. Ing. Viorel PALEU	de la	Universitatea Tehnică „Gheorghe Asachi” din Iași
Referent	Conf. Dr. Ing. Bogdan GRĂMESCU	de la	Universitatea POLITEHNICA din București

BUCUREȘTI

2022

CAPITOLUL 1.....	4
INTRODUCERE. OBIECTIVELE TEZEI	4
1.1 Defecte ale componentelor și subsistemelor din mecatronică și robotică	4
1.1.1. Componentele unui sistem mecatronic.....	4
1.1.2. Defecte uzuale ale componentelor și subsistemelor	4
1.1.2.1 Defecte ce pot apărea în sistemele de acționare:	4
1.1.2.2 Defecte ce pot apărea în sistemele electrice și electronice:	5
1.1.2.3 Defecte ce pot apărea în sistemele mecanice:.....	5
1.2 Efecte funcționale și economice ale defectelor.....	5
1.3 Obiectivele tezei.....	6
CAPITOLUL 2.....	6
CLASIFICAREA DEFECTELOR ȘI CARACTERISTICILE LOR VIBRATORII	6
2.1 Defecte care caracterizează funcționarea subsistemelor mecanice	6
2.1.1 Dezechilibre	6
2.1.2 Dezalinierea arborilor.....	6
2.1.3 Jocuri mari și curse moarte.....	7
2.2 Defecte ale componentelor	7
2.2.1 Deformarea transversală a arborelui.....	7
2.2.2 Defecte ale rulmenților.....	7
2.2.3 Defectele transmisiilor cu curele	8
2.2.4 Defectele angrenajelor.....	8
2.2.5 Defecte electrice ale subsistemelor de acționare	8
CAPITOLUL 3.....	9
METODE, MIJLOACE ȘI REALIZĂRI PRIVIND MONITORIZAREA, PREDICȚIA ȘI	
DIAGNOZA DEFECTELOR ÎN SISTEME MECATRONICE	9
3.1 Fiabilitate și mentenanță	9
3.2 Metode și mijloace de detectare și diagnoză a defectelor în literatura de specialitate	
10	
CAPITOLUL 4.....	12
SENZORI, INSTRUMENTAȚIE VIRTUALĂ, ACHIZIȚIE ȘI PRELUCRARE A	
SEMNALELOR	12
4.1 Analiza vibrațiilor	12
4.2 Senzori.....	13
4.3 Achiziția semnalelor, instrumentație virtuală.....	13
4.4 Prelucrarea semnalelor	15
4.4.1 Metode de procesare a semnalului.....	15
4.4.1.1 Procesarea semnalului în domeniul timp	15
4.4.1.2 Procesarea semnalului în domeniul frecvență	15
4.4.1.3 Procesarea semnalului în domeniul timp-frecvență.....	16
CAPITOLUL 5.....	17
DETECTAREA ȘI IZOLAREA DEFECTELOR UTILIZÂND INTELIGENȚA	
ARTIFICIALĂ.....	17
5.1 Inteligența artificială	17

5.1.1	Algoritme de inteligență artificială.....	18
5.1.2	Învățarea automată	18
5.2	Algoritme de inteligență artificială folosite în diagnosticarea defectelor	18
5.2.1	Detectia anomaliilor	19
5.2.1.1	Algoritmul de detecție a anomaliilor prin distribuție normală.....	19
5.2.1.2	Pădure de izolare	19
5.2.1.3	Testul statistic Kolmogorov-Smirnov	20
5.2.2	Algoritme nesupervizate de clasificare.....	20
5.2.2.1	K cei mai apropiați vecini (k nearest neighbours - kNN)	20
CAPITOLUL 6.....	21	
SOFTWARE PENTRU DETECTAREA DEFECTELOR PRIN PRELUCRAREA		
DATELOR.....	21	
6.1 Algoritm de diagnoză pentru un sistem mecatronic complex.....	21	
6.1.1.	Achiziția semnalului	22
6.1.2.	Extragerea caracteristicilor proprii din semnal.....	22
6.1.2.1	Extragerea caracteristicilor folosind algoritmul Goertzel.....	22
6.1.2.2	Algoritme complexe pentru extragerea și procesarea caracteristicilor vibratorii la diagnosticarea defectelor.....	24
6.1.3.	Modul de detecție a defectelor.....	27
6.1.3.1	Modelarea lanțului cinematic printr-o rețea neuronală de regresie.....	28
6.1.4.	Modulul de diagnosticare	30
6.1.4.1	Algoritmul de diagnoză a defectelor folosind testul statistic Kolmogorov-Smirnov	30
6.1.5.	Modulul de alertare a operatorilor.....	33
6.1.6.	Modulul de antrenare a modelelor și de stocare a datelor de referință obținute de la sistemul funcțional	33
6.2 Obiectivele și descrierea aplicației.....	34	
CAPITOLUL 7.....	Error! Bookmark not defined.	
REZULTATE PRIVIND DIAGNOSTICAREA UNOR DEFECTE ALE		
COMPONENTELOR ȘI SISTEMELOR MECATRONICE.....	35	
7.1 Experiment pe un stand pentru determinarea comportării dinamice a arborilor dreپți	35	
7.1.1.	Descrierea standului	35
7.1.2.	Achiziția datelor	35
7.1.3.	Efectuarea experimentului.....	35
7.1.4.	Prelucrarea rezultatelor.....	36
7.2 Rezultate obținute pe datele achiziționate de la rulmenți	38	
7.2.1	Diferențe între metode de prelucrare a semnalului achiziționat de la accelerometre.....	38
7.2.2	Diagnosticarea defectelor din rulmenți folosind testul statistic Kolmogorov-Smirnov.....	44
7.2.3	Rezultate obținute prin aplicarea criteriului de încetare a descompunerii empirice în moduri.....	45
7.3 Testarea algoritmului de detecție pe un model matematic al vibrațiilor torsionale ale unui reductor cu roți dințate.....	47	
7.3.1	Modelul unui angrenaj.....	47
7.3.2.	Simularea vibrațiilor torsionale	48
7.3.3.	Diagnosticarea defectelor din reductoare folosind testul statistic Kolmogorov-Smirnov	50

7.4 Testarea sistemului de detecție pe un sistem mecatronic de poziționare, cu mișcare de translație	51
CAPITOLUL 8.....	54
CONCLUZII ȘI ÎMBUNĂȚĂȚIRI ULTERIOARE.....	54
8.1 Îndeplinirea obiectivelor tezei.....	54
8.2. Contribuții personale.....	55
8.3. Îmbunătățiri ulterioare	57
Bibliografie selectivă	57

CAPITOLUL 1

INTRODUCERE. OBIECTIVELE TEZEI

Acest capitol oferă o introducere în diagnoza defectelor și subliniază importanța acesteia prin prezentarea unei scurte descrieri a unui sistem mecatronic, a defectelor ce pot afecta funcționarea lui și a efectelor economice care derivă din acestea. Capitolul descrie atât obiectivele tezei cât și structura acesteia.

Diagnoza defectelor capătă din ce în ce mai multă importanță în industria de astăzi și, folosind progresele obținute în domeniul inteligenței artificiale, din ce în ce mai mulți cercetători caută moduri și soluții noi de a menține un sistem în stare de funcționare și de a evita timpii morți. Implicit, acest lucru duce la o producție neîntreruptă și mai eficientă. În ultimii ani au fost scrise multe articole în acest domeniu, cu precădere în câmpul mentenanței predictive și avantajele acesteia în diagnoza sistemelor.

1.1 Defecte ale componentelor și subsistemelor din mecatronică și robotică

1.1.1. Componentele unui sistem mecatronic

Un sistem mecatronic este format în general din alte subsisteme, fiecare fiind responsabil de buna funcționare a unei anumite părți a sistemului. Aceste subsisteme pot fi împărțite în 6 mari categorii:

1. subsisteme mecanice
2. subsisteme de acționare
3. subsisteme electrice și electronice
4. subsisteme de achiziție și senzori
5. subsisteme de control
6. subsisteme de interfață grafică și interacțiune cu mașina (GUI & HMI)

1.1.2. Defecte uzuale ale componentelor și subsistemelor

1.1.2.1 Defecte ce pot apărea în sistemele de acționare:

- a) Defecte electrice:
 - Fluctuații de putere
 - Căderi de tensiune
 - Oscilații de fază
 - Pierderi de fază
 - Variații în curentul absorbit
 - Scurt circuite

- b) Defecte mecanice
 - Rotor blocat
 - Suprasarcini
 - Încălzirea bobinei
 - Întreruperea circuitului bobinei

1.1.2.2 Defecte ce pot apărea în sistemele electrice și electronice:

- a) Defecte de izolare
- b) Defecte de contact
- c) Defecte din cauza plăcii de circuite imprimare
- d) Defecte din cauza întreruptoarelor
- e) Defecte din cauza semiconductoarelor

1.1.2.3 Defecte ce pot apărea în sistemele mecanice:

- a) Uzura, ruperea sau patinarea curelelor lise poate întrerupe transmiterea mișcării ori modificarea raportului de transmitere
- b) Uzura danturii roților dințate sau ruperea dinților la bază
- c) Uzura lagărelor și ghidajelor (rulmenți, bușe, etc.), generatoare de jocuri nedorite, respectiv pierderea preciziei
- d) Ruperea, prin oboseală, a elementelor elastice și a arborilor
- e) Pierderea etanșeității la dispozitivele care lucrează cu fluide

1.2 Efecte funcționale și economice ale defectelor

În lucrarea sa de doctorat, Michael Patrick Brennan [1] analizează impactul economic, respectiv cel tehnologic al defectelor în mediul de producție. Costurile pot fi împărțite în două mari categorii:

1. Costuri pro active pentru prevenția sau reducerea defectelor
2. Costuri reactive pentru găsirea defectelor care deja s-au produs, reparații, înlocuiri de piese și subansambluri.

În literatura de specialitate există așa numita “Regulă de 10”, care arată că, ***pentru fiecare unitate economică cheltuită pe prevenție se salvează 10 unități cheltuite pe remedierea defectelor interne și 100 de unități economice cheltuite pe remedierea defectelor externe.***

Există un număr important de lucrări în literatură care dezbat acest subiect promovând metode noi pentru stabilirea estimativă a intervalelor de timp dintre apariția defectelor, pentru crearea unui model de defecte din punct de vedere a fiabilității. ***De aceea dezvoltarea unui sistem de***

diagnoză robust este de interes pentru unitățile industriale, toate folosind sisteme electromecanice.

1.3 Obiectivele tezei

- I. Cercetarea literaturii de specialitate și expunerea stadiului actual al realizărilor, pentru identificarea oportunităților de îmbunătățire a algoritmilor curente de detecție a defectelor sistemelor tehnice, pe baza comportării vibratorii
- II. Identificarea potențialelor defecte din componentele sistemelor mecatronice și posibilitatea diagnosticării pe bază de vibrații
- III. Extragerea caracteristicilor esențiale din comportarea vibratorie a componentelor mobile ale sistemului, prin achiziția semnalelor de accelerație de la componentele monitorizate și analiza lor prin algoritme de învățare automată
- IV. Dezvoltarea și implementarea unui algoritm robust de diagnoză pentru diferite frecvențe de defect, care să poată fi aplicat la mai multe componente
- V. Dezvoltarea și implementarea unui algoritm de monitorizare și mentenanță predictivă pentru un sistem mecatronic format din subsistem de acționare, subsistem de transmisie a puterii și subsistem acționat (efector)

CAPITOLUL 2

CLASIFICAREA DEFECTELOR ȘI CARACTERISTICILE LOR VIBRATORII

Capitolul descrie în detaliu defectele uzuale mecanice care pot apărea în sisteme mecatronice ce presupun o mișcare de rotație sau translație. De asemenea, sunt oferite detalii despre caracteristicile vibratorii ale acestor defecte.

2.1 Defecte care caracterizează funcționarea subsistemelor mecanice

2.1.1 Dezechilibre

Sunt rezultatul unei excentricități, care apare atunci când centrul de masă al unei piese cilindrice (arbore) nu este situat pe axa de rotație a acesteia, creând un dezechilibru care produce vibrații transversale de încovoiere

2.1.2 Dezalinierea arborilor

Acest fenomen apare, în general, atunci când 2 arbori cuplați nu sunt aliniați corect de-a lungul axei longitudinale sau când axele arborilor și ale rulmenților sau angrenajelor prezintă abateri unghiulare importante.

2.1.3 Jocuri mari și curse moarte

Acestea pot fi rezultatul montajului necorespunzător, uzării excesive a cuplelor cinematice sau a desprinderii ori ruperii unei componente.

2.2 Defecte ale componentelor

2.2.1 Deformarea transversală a arborelui

Acest tip de defect are aceleași caracteristici de frecvență ca dezalinierea, fiind necesară analiza unghiului de defazaj. Dacă acest lucru nu este posibil, defectul poate fi considerat în aceeași categorie, dezalinierea necesitând verificarea arborelui.

2.2.2 Defecte ale rulmenților

De cele mai multe ori, defectele care apar în rulmenți sunt consecințe ale încărcărilor suplimentare, a pretensionării excesive, a lubrifierii necorespunzătoare, temperaturii mari de lucru, contaminării cu corpuri străine și a coroziunii. În lucrarea [2], sunt listate defectele care apar preponderent în lagărele de rostogolire, fără o sistematizare privind cauzele apariției lor și a consecințelor funcționale.

- a. Defecte provocate de uzura prin oboseala superficială
- b. Defecte provocate de uzura abrazivă
- c. Defecte provocate de uzura de aderență
- d. Defecte provocate de impact sau de sarcini statice
- e. Defecte provocate de coroziune
- f. Defecte provocate de montaj defectuos

Clasificarea expusă, mai sus, se dorește a fi o sistematizare, bazată pe fenomene fizico-chimice, a defectelor prezentate în [2] și în „Analiza defectelor rulmenților” a firmei Timken [3]. Majoritatea defectelor sunt favorizate de ungerea necorespunzătoare și de montajul rulmenților. Deși defectele prezentate nu au, în sine, caracteristici proprii, componentele rulmenților au frecvențe proprii prin care se poate identifica piesa defectă, pentru ca, apoi, operatorul uman să poată interveni și observa/repara defectul.

Frecvențele proprii de defect pentru fiecare componentă pot fi calculate pe baza geometriei rulmentului și, dacă un defect apare la aceasta, în domeniul frecvență, se poate observa o amplitudine mare la frecvența respectivă.

Este important de punctat faptul că analiza energiei unui semnal, captat de sistemul de monitorizare a vibrațiilor, este de mare interes în cazul defectelor mecanice. Acest lucru se datorează faptului că un impact produs de către defectul mecanic poate fi ascuns în frecvență de către componentele care sunt prezente între locul producerii impactului și locul monitorizării vibrațiilor. Astfel, în domeniul frecvență, amplitudinea obținută în urma impactului poate fi modulată în alte frecvențe, defazată din cauza componentelor care au o comportare caracteristică de amortizare. Spectrul ar conține vârfuri de amplitudine care ar fi distanțate pe scara frecvenței

cu o valoare egală cu frecvența de defect. Din punct de vedere al energiei, acest impact va genera un răspuns care mărește amplitudinea la frecvența de rezonanță și astfel evaluând spectrul energiei semnalului, perioada (și implicit frecvența) repetării acestor amplitudini ridicate poate fi evidențiată [4]. O altă abordare specifică pentru analiza semnalelor vibratorii provenite de la rulmenți este prin obținerea anvelopei semnalului și apoi trecerea acestuia în domeniul frecvență.

2.2.3 Defectele transmisiilor cu curele

Transmisiile cu curea asigură o transmitere lină și fără zgomot a mișcării de rotație. Acest lucru se poate realiza prin forță, la cele pe bază de aderență (lise și trapezoidale), sau prin formă, la cele dințate. Avantajul acestui tip de transmisie este că vibrațiile sunt amortizate și costurile de producție și mentenanță sunt scăzute. Un alt avantaj al transmisiei cu curea este că forța nu este transferată în timpul unei suprasarcini de scurtă durată, celelalte mecanisme din lanțul cinematic antrenat de transmisia prin curea fiind protejate de încărcări excesive care ar putea genera defectarea acestora. În plus, transmisia prin curele este puțin sensibilă la imperfecțiunile de montaj al fuliei pe arbore și poate distribui puterea de la arborele conducător la unul sau mai mulți arbori.

Conform [5] și [6], defectele care pot apărea în transmisiile cu curele sunt:

- a. Ruperea
- b. Uzura

2.2.4 Defectele angrenajelor

Angrenajele reprezintă un mijloc de transmitere și transformare a mișcării de rotație foarte folosit, transferând puterea de la un arbore la altul, cu un randament foarte bun. Acest tip de transmisie are o durabilitate ridicată și un raport de transmitere teoretic constant. Ca dezavantaje pot fi enumerate faptul că fabricația trebuie să fie foarte precisă, respectiv că în timpul funcționării apar vibrații și zgomote. [7]

Principalele defecte specifice, care pot apărea în angrenaje, pe lângă cele de montaj în subsistem (dezechilibrare, etc.) sunt legate de deteriorarea danturii:

- a. Deteriorarea danturii prin ruperea dinților
- b. Deteriorarea flancurilor danturii prin oboseală superficială
- c. Deteriorarea flancurilor datorită alunecării relative

2.2.5 Defecte electrice ale subsistemelor de acționare

Componentele electromecanice oferă, de asemenea, caracteristici vibratorii în cazul unor defecte electrice. Acestea pot fi ușor de monitorizat, folosind dublul frecvenței curentului de alimentare, deoarece la fiecare rotație se produc două atracții magnetice către cel mai apropiat pol magnetic, ceea ce face ca semnalul electric să fluctueze de la 0 la dublul frecvenței de alimentare.

Se poate concluziona faptul că există un spectru larg de defecte uzuale care pot apărea în sistemele mecatronice și în componentele acestora. Deoarece defectele au comportări vibratorii specifice se poate implementa o soluție de achiziție ieftină prin analiza vibrațiilor, partea de diagnoză fiind făcută la nivel de algoritmi inteligenți.

CAPITOLUL 3

METODE, MIJLOACE ȘI REALIZĂRI PRIVIND MONITORIZAREA, PREDICȚIA ȘI DIAGNOZA DEFECTELOR ÎN SISTEME MECATRONICE

3.1 Fiabilitate și mentenanță

Termenul de fiabilitate a apărut datorită importanței deosebite pe care au căpătat-o problemele siguranței în funcționare a echipamentelor industriale. Acesta este caracteristica unui produs de a funcționa fără a se defecta într-un interval de timp. Matematic este posibil să se stabilească statistic comportarea unui produs în anumite condiții de funcționare.

Fiabilitatea poate fi:

- Calitativă – caracteristica unui produs de a-și îndeplini funcția în anumite condiții date într-un interval de timp dat
- Cantitativ – caracteristica unui produs exprimată prin probabilitatea funcționării conforme în anumite condiții

Defectarea este fenomenul fundamental din teoria fiabilității care se manifestă prin încetarea aptitudinii unui dispozitiv de a-și îndeplini funcția specificată. În funcție de consecințe, defectările pot fi:

- Minore – pot fi ușor remediabile și nu împiedică funcționarea sistemului
- Majore – întrerup funcționarea sistemului
- Critice – au consecințe pentru om sau mediul ambiant

Ansamblul tuturor acțiunilor tehnice și organizatorice pentru menținerea sau restabilirea funcției sistemului se numește mentenanță.

Costurile de mentenanță au o pondere mare în costurile de funcționare a sistemelor industriale, variind între 15 și 60%. Funcționarea optimă și performantă a sistemelor industriale este strâns legată de prevenția defectelor provenite prin manevre greșite, datorită neatenției operatorului sau prin suprasolicitări întâmplătoare. De aceea, tehnicile de monitorizare și diagnoză și implementarea lor asigură efecte pozitive asupra fiabilității și productivității.

Se pot defini 4 tipuri de mentenanță:

Mentenanța reactivă

Mentenanța corectivă

Mentenanța preventivă

Mentenanța predictivă - acest tip de mentenanță presupune monitorizarea periodică sau specifică a stării mecanice, electrice sau a altor parametri funcționali ai sistemului pentru a mări timpul între lucrările de reparații și a minimiza costul întreruperilor de producție neplanificate.

Mentenanța predictivă îmbunătățește și optimizează întreg sistemul industrial. Acest tip de mentenanță folosește monitorizarea vibrațiilor, termografia, tribologia, etc. pentru a obține parametri funcționali ai elementelor unui sistem pentru a programa activitățile de întreținere și reparație.

Prin acest tip de mentenanță se pot evita întreruperile neprogramate ale procesului de producție prin identificarea problemelor înainte ca ele să devină serioase. Cea mai mare parte a problemelor poate fi minimizată prin detectarea timpurie.

3.2 Metode și mijloace de detectare și diagnoză a defectelor în literatura de specialitate

În această secțiune sunt expuse numeroase metode din literatură utilizate pentru monitorizarea și diagnoza defectelor din sistemele mecatronice sau din componentele acestora. Se pune accentul pe diferențierea între metodele de diagnoză bazate pe model și cele bazate pe date conform figurii 3.1.

Metodele bazate pe model implică posibilitatea unei diagnosticări în detaliu a defectelor, comportamentul dinamic al sistemului fiind modelat matematic. Astfel, semnalele pot fi achiziționate de la orice componentă și un semnal numit rezidual poate fi calculat în funcție de o referință dată de modelul analitic și de rezultatele măsurătorilor obținute de la sistemul real. Pe baza acestor reziduuri, se pot extrage informații privind starea sistemului monitorizat. Cu toate acestea, modelele sistemelor actuale, din ce în ce mai complexe și având foarte multe neliniarități, pot introduce erori mari la rezolvarea numerică, rezultatele obținute fiind departe de comportamentul dinamic al sistemului real. De aceea, datorită creșterii puterii de calcul și a puterii de stocare a datelor, s-au dezvoltat din ce în ce mai multe algoritme de extragere a unor modele dinamice din datele înregistrate de la diferiți senzori. Astfel, aceste metode includ neliniaritățile intrinseci ale sistemului și pot fi folosite cu succes pentru a obține semnale de ieșire specifice sistemului real.

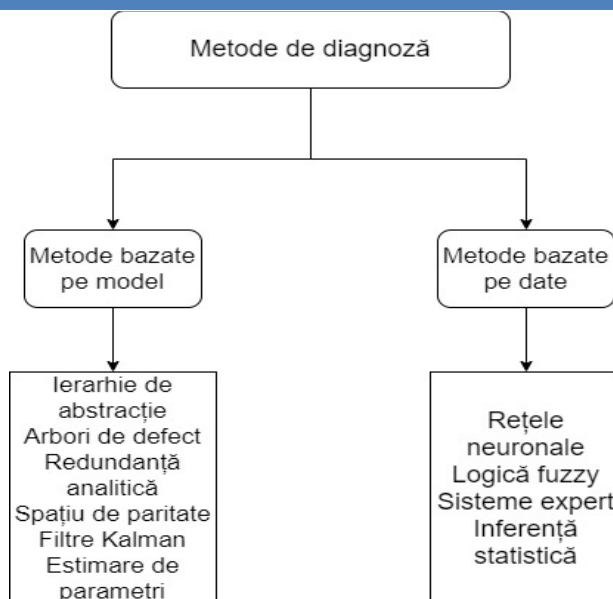


Figura 3.1: Metode de diagnoză și algoritme pentru implementare [8]

Pentru a obține niște date caracteristice unui defect, sistemul monitorizat trebuie definit cu ajutorul unor semnale ce pot oferi informații despre dinamica și starea sistemului.

Analiza prin vibrații reprezintă cea mai ieftină și non-invazivă metodă de detecție și diagnoză. În [9] este prezentată diferența dintre detecție și analiză, evidențiindu-se faptul că doar detecția unui defect sau a efectului acestuia nu este productivă, fiind necesară identificarea cauzei defectului. Vibrațiile reprezintă răspunsul dinamic al componentelor mecanice ale unui sistem la forțe interne sau externe. Fiecare problemă mecanică sau electrică generează un răspuns dinamic unic astfel încât prin analiza caracteristicilor date de vibrații pot fi detectate și identificate defectele. Componentele principale care pot fi analizate din vibrații sunt:

- **Frecvența** – reprezintă numărul de apariții ale un eveniment într-un interval de timp. De regulă, defectele se caracterizează prin frecvențe unice în analiza de vibrații a sistemului.
- **Amplitudinea** – reprezintă mărimea semnalului de vibrație. De obicei, amplitudinea indică existența defectului și se corelează cu severitatea acestuia. Amplitudinea semnalelor achiziționate în timpul monitorizării trebuie comparată cu cea înregistrată pentru sistemul funcțional.

Defectele pot fi diagnosticate prin cele două mărimi caracteristice vibrațiilor și prin metode/modele matematice bazate pe aceste caracteristici.

CAPITOLUL 4

SENZORI, INSTRUMENTAȚIE VIRTUALĂ, ACHIZIȚIE ȘI PRELUCRARE A SEMNALELOR

Acest capitol prezintă modalități de monitorizare a unui sistem electromecanic (analiza vibrațiilor, termografie) și descrie diferite tipuri de senzori, cu accent pe accelerometre și modul lor de funcționare. De asemenea, sunt oferite detalii despre instrumentația virtuală necesară achiziției semnalelor de interes și algoritme de prelucrare a acestora în vederea extragerii unor caracteristici intrinseci sistemului monitorizat.

4.1 Analiza vibrațiilor

Este una dintre cele mai utilizate metode de detecție și diagnoză a defectelor în sistemele electromecanice. Prin această metodă, se determină parametrii vibrațiilor sistemului, de obicei cu un accelerometru, după care se examinează amplitudinile la anumite frecvențe (figura 4.1) pentru a le identifica pe cele semnificative sistemului, ținând seama că anumite frecvențe sunt proprii sistemului la funcționare normală. Modificarea amplitudinii anumitor armonici poate semnifica prezența unui defect. Datele pot fi colectate periodic sau continuu.

Prin vibrații, se pot detecta defecte precum: dezechilibre, probleme în lagăre, rezonanță structurală, defecte ale rotorului la mașinile electrice, excentricități. Măsurătorile sunt rapide și non invazive, funcționarea sistemului testat nefiind tulburată.




Figura 4.1: Analiza vibrațiilor [10]

Pentru fiecare sistem electromecanic, într-o perioadă preliminară intrării în funcțiune, se definește un nivel propriu de vibrații, orice deviație de la acesta indicând o problemă, astfel încât să se poată interveni înainte ca sistemul să se deterioreze. Există, de asemenea, un standard care furnizează nivele de vibrații pentru grupe de echipamente și viteze de operare. Acestea pot fi folosite ca termen de comparație în stabilirea nivelului de vibrații ale unui anumit echipament.

4.2 Senzori

În [11], Stephen Hanly prezintă diferiți senzori de măsurare a vibrațiilor și indică și modul în care analiza vibrațiilor poate fi făcută corespunzător. Astfel, senzorii de vibrații pot fi împărțiți în mai multe categorii:

- Accelerometre;
- Mărci tensometrice
- Senzori de viteză
- Microfoane sau senzori de presiune acustică
- Senzori de deplasare cu laser
- Senzori de deplasare capacitivi

La rândul lor, accelerometrele pot fi împărțite în mai multe categorii:

- Accelerometre capacitivă – sunt cele mai mici și cele mai ieftine accelerometre care sunt folosite de obicei în telefoanele mobile; oferă o calitate scăzută a datelor, mai ales la frecvențele înalte, nefiind potrivite pentru aplicațiile industriale; sunt foarte ieftine și populare datorită tehnologiei de fabricație, bazându-se pe MEMS (sisteme micro-electromecanice)
- Accelerometre piezoelectrice – sunt cele mai populare și cele mai folosite în aplicațiile industriale; elementul sensibil din zirco-titanat de plumb produce o sarcină electrică sub acțiunea unei accelerații; dezavantajul este cuplarea prin curent alternativ și nu pot măsura accelerația gravitațională;
- Accelerometrele piezorezistive – sunt folosite în măsurătorile de impuls/impact; masa seismică a accelerometrului provoacă deformarea suportului său elastic, pe care sunt montate mărci tensometrice piezorezistive, deci au nevoie de amplificare și de compensare de temperatură; oferă un interval mare de frecvențe și sunt cuplate prin curent continuu.

4.3 Achiziția semnalelor, instrumentație virtuală

Un instrument este un dispozitiv care colectează date din mediu sau dintr-un sistem și le prelucrează, afișându-le utilizatorului. Osciloscopurile, multimetrele, analizatorul de spectru, etc. sunt exemple de instrumente fizice. Altă categorie este reprezentată de instrumentele virtuale care sunt formate din programe pe calculator și echipamente hardware modulare care pot da posibilitatea oricărui utilizator să își adapteze sistemul de achiziție la nevoile personale [12].

Se poate spune că o proprietate definitivă a unui instrument virtual este posibilitatea de a-și schimba funcționalitatea prin software, fiind astfel fiabil în multiple aplicații. De aceea, componenta de software este cea mai importantă componentă a unui instrument virtual [13].

Un instrument virtual poate fi împărțit în mai multe module (figura 4.2):

- Modul senzorial
- Interfață senzorială
- Modul de calcul și procesare
- Interfață grafică



Figura 4.2: Arhitectura unui instrument virtual

Se vor prezenta instrumentele virtuale folosite pentru achiziția de semnale în scopul prelucrării acestora și a identificării eventualelor defecte dintr-un sistem mecatronic, folosind analiza vibrațiilor. Algoritmii folosiți vor fi algoritmi hibridi de diagnoză, ei utilizându-se de date pentru a extrage caracteristici, în funcție de parametrii vibrațiilor ale căror valori vor fi comparate cu cele dintr-un model învățat anterior, atunci când sistemul era complet funcțional.

Sistemul mecatronic este reprezentat de un sistem de acționare (motor), un sistem de transmitere a mișcării (lanț cinematic) și un sistem care este acționat și trebuie să efectueze mișcarea (efector). Măsurarea vibrațiilor se va face cu doi senzori, unul montat pe motor și cel de-al doilea amplasat pe efector (fig. 4.3). Astfel, modulul senzorial va fi format din:

- Senzori de vibrații
- Placă de achiziție

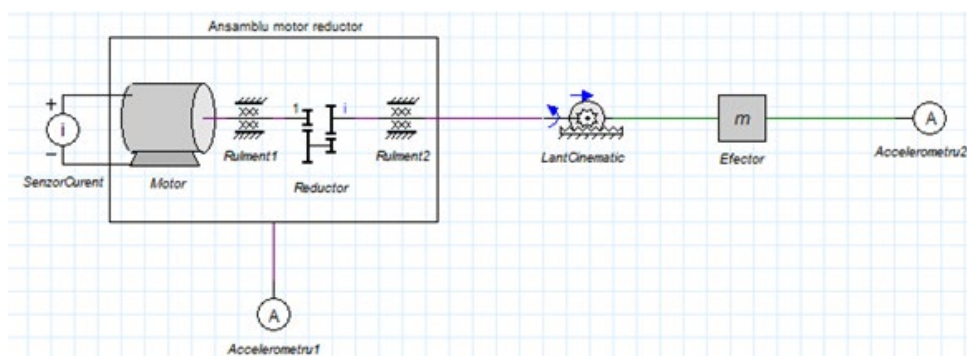


Figura 4.3: Sistem mecatronic uni-axial monitorizat

Interfața senzorială va fi una cu fir, pentru a permite achiziționarea datelor în timp real, când sistemul se află în mișcare. O posibilă alternativă este folosirea unui microcontroler în locul plăcii de achiziție, care va putea achiziționa datele și le va putea trimite către sistemul de calcul printr-un canal de comunicație fără fir. Astfel, interfața senzorială va fi compusă din:

- Placă de achiziție / microcontroler
- Computer cu placă de rețea wireless pentru comunicare fără fir / port serial

Unitatea de calcul va fi reprezentată de un calculator care va dispune de o placă de rețea wireless / port serial, pentru a putea comunica cu interfața senzorială.

Interfața grafică va fi reprezentată de un program software care va putea afișa diferitele caracteristici extrase dintr-un semnal și va putea anunța utilizatorul în cazul diagnosticării unui defect.

4.4 Prelucrarea semnalelor

Prelucrarea semnalelor reprezintă o etapă importantă într-un modul de diagnoză, deoarece pot fi extrase informații importante despre starea sistemului monitorizat. Acest domeniu este unul foarte vast și prin urmare vor fi prezentate, pe scurt, numai noțiunile teoretice care vor fi aplicate, ulterior, în diferite experimente și metode de diagnoză a defectelor.

4.4.1 Metode de procesare a semnalului

Un semnal poate fi procesat în domeniul timp, în domeniul frecvență sau în ambele domenii. Astfel, pentru fiecare domeniu există metode diferite de extragere a caracteristicilor acestuia. Ele sunt prezentate pe scurt, pentru a defini anumiți termeni și a oferi baza teoretică utilizată în scopul diagnosticării defectelor.

4.4.1.1 Procesarea semnalului în domeniul timp

Datele provenite în timp de la un senzor formează un semnal în domeniul timp din care se pot obține informații statistice. Pe lângă forma semnalului și caracteristicile statistice ale acestuia, alte două mărimi sunt de interes, respectiv energia semnalului și puterea acestuia. Acestea pot oferi informații importante despre cât de puternic este un semnal într-un anumit interval. Spre exemplu, în cazul semnalelor tranzitorii energia este importantă într-o fereastră de timp, iar puterea este folositoare într-un proces staționar.

4.4.1.2 Procesarea semnalului în domeniul frecvență

Pentru procesarea semnalului în domeniul frecvență, se apelează la transformata Fourier. Aceasta permite trecerea semnalului din domeniul timp în domeniul frecvență prin descompunerea semnalului inițial în componente sinusoidale de diferite perioade și prin găsirea amplitudinilor acestor componente. Această reprezentare a semnalului este cunoscută și sub forma de spectrul semnalului, termen folosit în continuare pentru a reprezenta graficul format din amplitudinile semnalului la anumite frecvențe.

Transformata Fourier

Transformata Fourier extrage corelațiile semnalului procesat cu semnale sinusoidale cu diferite frecvențe. Astfel, dacă se dorește trecerea unui semnal $x(t)$ în domeniul frecvență, următoarea ecuație poate fi folosită:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (4.1)$$

unde f este frecvența componentei sinusoidale cu care se face corelația și $X(f)$ amplitudinea acesteia.

Evident, ecuația (4.1) este folosită într-un interval continuu, analogic. Deoarece un semnal este de obicei achiziționat cu o anumită rată de eșantionare, se recurge la transformata Fourier discretă (DFT):

$$X(k) = \frac{1}{N} \sum_{i=0}^{N-1} x(i)e^{-\frac{j2\pi ki}{N}} \quad (4.2)$$

unde N este numărul de puncte ale transformatei Fourier. DFT poate fi calculată într-un mod eficient folosindu-se transformata Fourier rapidă (FFT). Pentru implementarea transformatei Fourier rapide este necesar ca N să fie putere a lui 2 [14].

Conform teoremei lui Parseval și a legii conservării energiei[15]:

$$\sum_{n=0}^{N-1} |x_n|^2 = \sum_{k=0}^{N-1} |X_k|^2 \quad (4.3)$$

unde x_n este semnalul inițial, N este numărul de puncte și X_k este obținut conform ecuației (4.2). Ecuația (4.3) exprimă faptul că energia semnalului din domeniul timp este egală cu energia semnalului din domeniul frecvență.

Algoritmul Goertzel generalizat

O altă metodă de procesare a semnalului în frecvență este obținerea coeficienților DFT ai semnalului, la anumite frecvențe, prin algoritmul Goertzel, această abordare fiind folosită dacă se dorește monitorizarea unui număr finit de frecvențe, după cum este prezentat în [16]. Acest algoritm necesită doar N înmulțiri și $2N$ adunări. Este superior ca eficiență transformatei Fourier dacă numărul de frecvențe calculate K este mai mic decât $4N/7$ [17]. Un alt avantaj al acestui algoritm este faptul că N nu trebuie să fie putere a lui 2 pentru a obține o performanță ridicată a eficienței de calcul.

4.4.1.3 Procesarea semnalului în domeniul timp-frecvență

Cele două tipuri de procesare prezentate mai sus pierd informații importante care pot fi utile în diagnoza defectelor. De asemenea, transformata Fourier nu este potrivită pentru procesarea semnalelor tranzitorii, care apar de obicei în defecte. Astfel, există mai multe procedee prin care procesarea semnalului poate fi făcută în ambele domenii. Acestea vor fi enumerate, însă vor fi detaliate trei astfel de procedee, folosite în această lucrare pentru implementarea algoritmului de diagnoză.

Astfel, dintre tehnicile de analiză din domeniul timp-frecvență fac parte:

- Transformata Fourier în timp scurt (STFT) – prin această tehnică, semnalul este împărțit în ferestre scurte, asupra cărora este aplicată transformata Fourier.
- Distribuția Wigner-Ville - această metodă extrage distribuția unui semnal într-un anumit moment din timp și la o anumită frecvență.
- Transformata Wavelet – este o metodă care se bazează pe descompunerea semnalului în raport cu o funcție mamă, cu niște caracteristici bine definite, care poate fi dilatată și translatată, astfel încât există rezoluție adecvată în domeniile timp și frecvență.
- Transformata Hilbert-Huang – reprezintă combinația dintre transformata Hilbert (analiza anvelopei semnalului) și descompunerea empirică în moduri de oscilație. Este o metodă special creată pentru analiza semnalelor neliniare și nestaționare [18]. Funcțiile proprii extrase sunt caracteristice fiecărui semnal, ceea ce denotă faptul că este o metodă adaptivă, care oferă o rezoluție foarte bună în frecvență și în timp. A fost prezentată de Huang ș.a. în [19].
- Pachete Wavelet – o metodă care se bazează pe transformata Wavelet discretă, dar care înlocuiește funcția mama Wavelet cu două filtre, cu ajutorul cărora semnalul inițial poate fi descompus într-o manieră iterativă.
- Coefficienți cepstrali pe scară mel – este o metodă de extragere a caracteristicilor unui semnal foarte folosită în recunoașterea vocală. Se bazează pe transformata Fourier în timp scurt și pe transformata cosinus discretă, datele extrase fiind în raport cu un banc de filtre suprapuse.

CAPITOLUL 5

DETECTAREA ȘI IZOLAREA DEFECTELOR UTILIZÂND INTELIGENȚA ARTIFICIALĂ

Capitolul oferă o privire de ansamblu asupra domeniului inteligenței artificiale și detaliază din punct de vedere teoretic diferite algoritme de învățare automată (subdomeniu al inteligenței artificiale), respectiv algoritme folosite în dezvoltarea unui sistem de diagnoză robust.

5.1 Inteligența artificială

Inteligența artificială este o subcategorie a informaticii care se ocupă cu inteligența demonstrată de către mașini, de aici venind și denumirea de artificial (spre deosebire de inteligența oamenilor care este naturală). De obicei, principiul pe care inteligența artificială se bazează este cel de a maximiza șansele de succes într-o anumită operație. De exemplu, dacă un algoritm de inteligență artificială joacă șah, va analiza toate mișcărilor și va face acea mutare care îi va oferi o probabilitate de câștig mai mare.

5.1.1 Algoritme de inteligență artificială

Inteligența artificială a rezolvat în timp multe probleme complexe din informatică folosind diferite metode și algoritme. Cele mai generale metode din inteligența artificială pot fi clasificate în următoarele categorii conform [20]:

- Metode de căutare și optimizare
- Metode logice
- Metode bazate pe probabilități
- Metode de clasificare și învățare statistică
- Rețele neuronale

5.1.2 Învățarea automată

Învățarea automată este un subdomeniu al inteligenței artificiale care este format din tehnici prin care un sistem poate învăța automat. În urma învățării, un sistem va obține un model pe baza căruia poate aproxima un rezultat pentru problema pentru care a fost antrenat, indiferent de datele de intrare.

Modelele pot fi împărțite în:

- Rețele neuronale
- Grafuri de decizie
- **Mașini cu suport vectorial** (SVM-uri)
- Rețele bayesiene
- Algoritme genetice

5.2 Algoritme de inteligență artificială folosite în diagnosticarea defectelor

În [21], Chang et. al. prezintă diferite modalități prin care o mașină poate fi monitorizată folosind inteligența artificială. Astfel, se poate observa că rețelele neuronale sunt din ce în ce mai folosite în această industrie. Tipurile de rețele neuronale pot fi clasificate în următorul mod:

- Rețele neuronale recurente – un tip de rețele neuronale care formează între nodurile sale (neuronii săi) un graf direcționat de-a lungul unui secvențe temporale
- Rețele neuronale profunde (deep) – un tip de rețele neuronale folosite în învățarea profundă (deep learning); aceste rețele sunt pluri-stratificate reușind să compună estimări cu mai puțini neuroni decât o rețea neuronală clasică. Aceste tipuri de modele au tendința de a supra-modela un sistem (nu au o acuratețe crescută pentru date diferite de datele din setul de antrenare)

- Rețele neuronale convoluționale – un tip de rețele neuronale profunde. Aceste tipuri de rețele sunt regularizate pentru a preveni supra modelarea unui sistem

Există, de asemenea, și alte metode de inteligență artificială care pot diagnostica/detecta defecte. Depinde însă de tipul sistemului monitorizat, de resursele disponibile și de tipul de învățare care este disponibil pentru datele colectate.

5.2.1 Detectia anomaliilor

În general, un model de rețele neuronale este folosit împreună cu învățarea automată supervizată. De exemplu, pentru a putea distinge între mai multe clase de defecte, în setul de antrenare trebuie incluse de asemenea date pentru fiecare categorie de defecte.

Dacă se dorește doar detectarea unui defect, un alt tip de învățare, nesupervizată, poate fi folosită pentru acest lucru. Modele diferite pot fi implementate pe baza datelor sistemului care funcționează în parametri corecți.

5.2.1.1 Algoritm de detecție a anomaliilor prin distribuție normală

Acest algoritm se bazează pe densitatea de probabilitate a distribuției pe fiecare dimensiune a vectorului caracteristici analizate x . Este important de precizat faptul că datele folosite pentru antrenare trebuie să fie prelucrate astfel încât funcția distribuției de probabilitate să aibă o formă de “clopot”.

5.2.1.2 Pădure de izolare

Acest algoritm a fost introdus în 2008 de către Liu și Ting prin [22], fiind o metodă nouă de a detecta anomalii printr-o abordare nouă: izolarea. Algoritmul se bazează pe faptul că anomaliile sunt rare și foarte diferite față de mulțimea datelor normale și astfel sunt mult mai susceptibile la izolare.

O pădure de izolare are următoarele avantaje:

- este formată din arbori de izolare. Aceștia au caracteristica de a crea modele parțiale și de a exploata eșantioane mici. Un eșantion mic scade șansa unui copac de a avea rezultate fals pozitive sau fals negative.
- Nu folosește măsurători de distanță sau de densitate pentru a găsi anomaliile, astfel eliminând un cost major în puterea de calcul
- Are o complexitate liniară în timp și o complexitate spațială mică
- Se comportă foarte bine la seturi de date mari cu un număr ridicat de caracteristici

Într-un arbore bazat pe date aleatorii, partiționarea instanțelor este făcută recursiv până când toate instanțele sunt izolate. Deoarece anomaliile sunt foarte diferite, această partiționare este foarte scurtă și drumul în arbore de la frunză la rădăcină este foarte scurt. Așadar când o

pădure de arbori aleatorii produce drumuri scurte pentru anumite puncte, atunci acele puncte sunt considerate a fi anomalii.

5.2.1.3 Testul statistic Kolmogorov-Smirnov

O altă metodă de a detecta un potențial defect este prin compararea a două distribuții statistice obținute din caracteristicile dinamice extrase dintr-un sistem. Prima distribuție (cea de referință) este reprezentată de caracteristicile obținute de la sistemul funcțional, în timp ce de-a doua distribuție este bazată pe datele achiziționate în timpul funcționării și monitorizării sistemului.

Testul Kolmogorov-Smirnov (K-S test) este un test statistic pentru a decide dacă un punct sau o mulțime de puncte provin dintr-o anumită distribuție prin compararea distribuțiilor probabilistice unidimensionale. Este un test neparametric (poate fi aplicat pe date cu distribuții non-gaussiene) care poate compara un set de date cu o distribuție teoretică (K-S test cu un eșantion) sau două seturi de date (K-S test cu două eșantioane). Poate fi de asemenea folosit ca un test de potrivire (arată cât de bine o mulțime de puncte face parte dintr-o anumită distribuție). Această metodă presupune testarea prin ipoteză nulă folosind o statistică denumită *D-stat*. De asemenea, K-S test oferă o valoare *p* care, dacă este mai mică decât 0.05, respinge ipoteza nulă.

5.2.2 Algoritme nesupervizate de clasificare

5.2.2.1 K cei mai apropiați vecini (k nearest neighbours - kNN)

Acest algoritm permite sistemului să clasifice și să atribuie o nouă măsurătoare unei mulțimi învățate pe baza măsurătorilor anterioare; clasificarea se face în funcție de distanța euclidiană sau un alt tip de măsură care poate fi aplicată datelor multidimensionale, cum ar fi măsura Minkowski [18]:

$$\|x' - x_n\|_p = \left(\sum_{i=1}^M |(x_i)' - (x_i)_n|^p \right)^{\frac{1}{p}} \quad (5.1)$$

unde x' este noua măsurătoare, x_n este o măsurătoare anterioară și face parte din spațiul \mathbb{R}^M .

Antrenarea algoritmului se face în același timp cu clasificarea unei noi măsurători, acest lucru făcând această metodă ușor de folosit.

În [18], autorul folosește cu succes kNN ponderat pentru diagnoza defectelor în roți dințate, atribuind ponderi distanțelor față de diferite clase de defecte.

Acest algoritm poate reprezenta o metodă ușoară de a integra într-un sistem de monitorizare defecte despre care nu există date la punerea în funcțiune a sistemului monitorizat și care pot apărea în timpul funcționării. Defectele pot clasificate de către operatori la apariția lor ca apoi sistemul să poată diagnostica cu succes perturbații din aceeași categorie.

CAPITOLUL 6

SOFTWARE PENTRU DETECTAREA DEFECTELOR PRIN PRELUCRAREA DATELOR

În acest capitol sunt descrise algoritme proprii de extragere a caracteristicilor vibratorii necesare diagnozei defectelor (folosirea algoritmului Goertzel, aplicarea transformatei Wavelet sau Hilbert-Huang) precum și implementarea acestora într-o aplicație complexă de prelucrarea a semnalelor și diagnosticare a defectelor.

6.1 Algoritm de diagnoză pentru un sistem mecatronic complex

Unul dintre obiectivele tezei constă în proiectarea și implementarea unui sistem robust de diagnoză a defectelor care pot apărea într-un sistem mecatronic. Pentru a proiecta un astfel de sistem, trebuie stabilită structura sistemului mecatronic ce se dorește a fi monitorizat și complexitatea acestuia.

În această lucrare, algoritmul de monitorizare și diagnoză este aplicat la un sistem cartezian de poziționare uni-axial, format din subsistem de acționare, rulmenți, reductor, subsistem de transformare a rotației în translație și subsistem efector. Schema acestui sistem mecatronic este prezentată în figura 4.3.

Pornind de la acest sistem monitorizat, a fost conceput un algoritm inteligent de diagnoză, a cărui organigramă este prezentată în figura 6.1, unde se pot observa etapele întregului proces de diagnoză și modulele acestora.

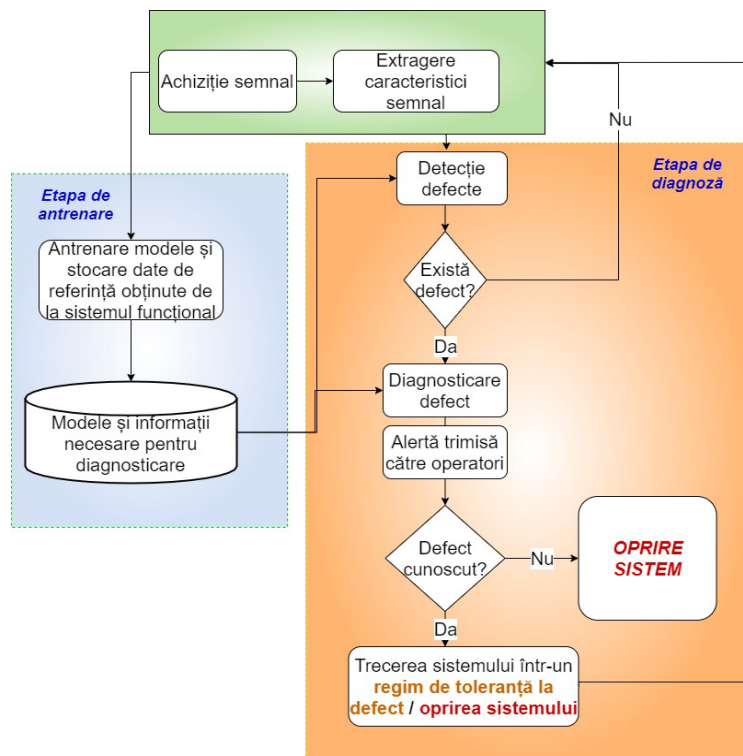


Figura 6.1: Modulele și etapele algoritmului de diagnoză la un nivel macro

6.1.1. Achiziția semnalului

Prima etapă a algoritmului constă din obținerea semnalelor caracteristice comportării vibratorii sistemului monitorizat. Pentru acest lucru este nevoie de alegerea unor accelerometre potrivite și a unei interfețe senzoriale potrivite, după cum a fost prezentat în capitolul 4. Pentru modulul senzorial, pot fi folosite accelerometre piezoelectrice cum ar fi cele de la Brüel & Kjær, care pot măsura oscilații ale accelerației la frecvențe foarte înalte, de ordinul kilohertzilor.

Pentru preluarea informației de la senzori se poate folosi o placă de achiziție profesională cum ar fi o placă de achiziție National Instruments, care poate fi ușor de folosit și configurat folosind mediul de programare grafic LabView.

Pentru un sistem care funcționează în timp real este necesară implementarea unui flux de date continuu către modulul de prelucrare a semnalului, lucru care este ușor de realizat în limbajul de programare python, acesta oferind o multitudine de biblioteci optimizate în acest sens.

6.1.2. Extragerea caracteristicilor proprii din semnal

Datele achiziționate de la sistemul monitorizat trebuie prelucrate pentru a se putea extrage informațiile necesare modulelor de detecție și diagnosticare. Sistemul de diagnoză conceput folosește analiza vibrațiilor pentru diagnosticarea defectelor, astfel că metodele expuse în capitolul 4 sunt potrivite pentru a extrage informații caracteristice comportării vibratorii a sistemului. Pentru a obține niște caracteristici definitorii pentru defectele mecanice sau electrice ce pot apărea în sistemul mecatronic, este necesară calcularea anumitor frecvențe la care amplitudinea este crescută în cazul apariției defectului, conform prezentării din capitolul 2.

În capitolul 4 este expusă o comparație între 3 metode de prelucrare a semnalului în domeniul frecvență-timp: transformata Wavelet prin pachete (WPT), transformata Hilbert-Huang (HHT) și extragerea coeficienților cepstrali pe scară mel; totodată, în capitolul 7 cele trei metode sunt testate pe date achiziționate de la rulmenți. Dintre aceste metode de prelucrare, au fost implementate în soluția software WPT și HHT, cele două oferind cea mai bună rezoluție atât în domeniul timp cât și frecvență.

6.1.2.1 Extragerea caracteristicilor folosind algoritmul Goertzel

Foarte multe defecte pot fi identificate în domeniul frecvență, pe baza amplitudinii la anumite frecvențe de interes, care pot fi calculate în funcție de diferiți parametri. Amplitudinea componentelor sinusoidale cu diferite frecvențe este importantă în identificarea semnalelor de defect și în consecință, existența unui algoritm rapid este necesară pentru monitorizarea unui sistem în timpul funcționării.

Algoritmul de extragere a caracteristicilor semnalului de vibrație folosind algoritmul Goertzel constă în următoarele etape:

- Se înregistrează viteza unghiulară a sistemului de acționare sau a arborelui. Conform capitolului 2, toate frecvențele de defect depind de viteza unghiulară. Anumite componente (ex. rulmenți) necesită și alți parametri pentru calculul frecvențelor de interes;
- Se găsesc parametrii necesari pentru calculul frecvențelor de defect ale componentelor monitorizate;
- Se calculează frecvențele de defect care trebuie monitorizate.
- Se aplică algoritmul Goertzel pentru a extrage coeficienții transformatei Fourier discrete la frecvențele calculate anterior și se calculează amplitudinea spectrală în funcție de acești coeficienți pentru fiecare frecvență; o implementare a acestui algoritm fiind realizată atât în *anexa A* (secțiunea **Utilities.py**), cât și în *anexa B*;

În figura 6.2 se poate observa organigrama acestui algoritm. Achiziția datelor de la un accelerometru poate fi făcută prin orice metodă, atât timp cât se asigură o frecvență de eșantionare corespunzătoare nevoilor aplicației.

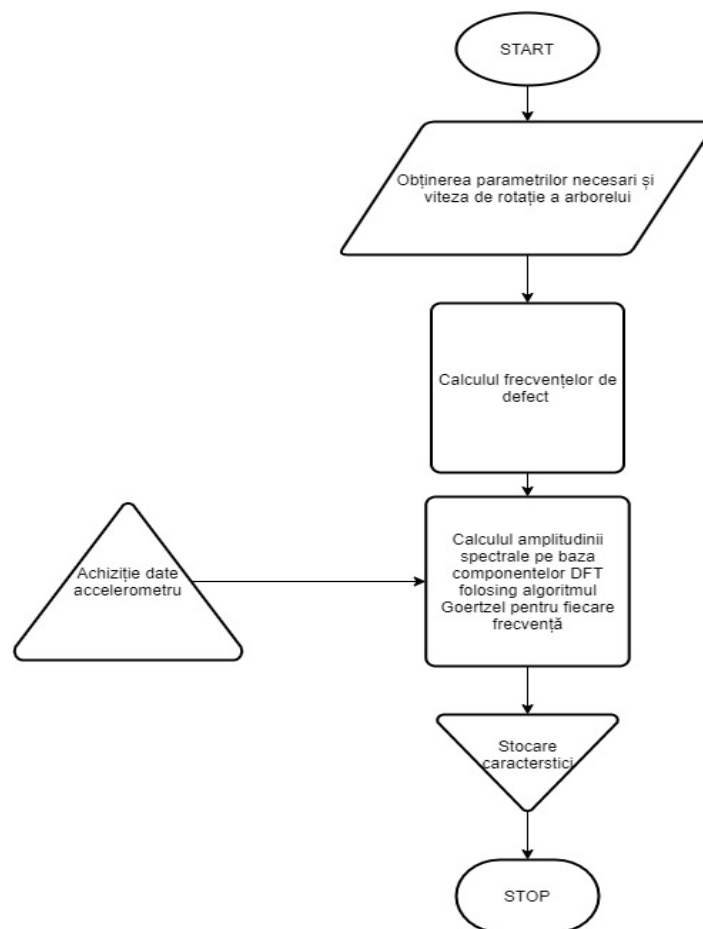


Figura 6.2: Organigrama algoritmului extragere a caracteristicilor

Defectele minore nu sunt observabile în spectrul semnalului deoarece pot fi mascate de către amplitudinile frecvențelor de rotație. Impulsurile rezultate în urma existenței unui defect măresc energia semnalului în intervalul de frecvență aferent perioadei de apariție a impactului cauzat de defect. Așadar, conform teoremei lui Parseval exprimată în ecuația (4.3), se poate căuta banda de frecvență cu energia cea mai ridicată pentru a fi analizată. Ulterior, se extrag caracteristicile necesare diagnosticării defectelor.

6.1.2.2 Algoritme complexe pentru extragerea și procesarea caracteristicilor vibratorii la diagnosticarea defectelor

Pentru a se putea extrage caracteristici relevante prin algoritmul prezentat mai sus, este necesară procesarea semnalului achiziționat de accelerometre în vederea obținerii informațiilor relevante pentru fenomenul fizic apărut în urma defectării unei componente. După cum a fost menționat mai sus, pentru o astfel de procesare s-au ales două metode de procesare: WPT și HHT.

Prin aceste două metode se pot observa diferite benzi de frecvență relevante pentru apariția unui impact în comportarea vibratorie a sistemului și mai mult, se pot extrage date statistice pentru semnale obținute în urma unor defecte necunoscute inițial. Aceste date pot fi folosite ulterior în clasificarea unor defecte asemănătoare.

În continuare, este prezentat modul în care se pot utiliza pachetele Wavelet sau transformata Hilbert-Huang, fiind *propus un criteriu nou de încetare a descompunerii empirice în moduri de oscilație, care poate fi folosit și pentru diagnosticarea anumitor defecte.*

Utilizarea pachetelor Wavelet

Această metodă permite analizarea semnalelor în diferite intervale de frecvență și reprezintă astfel o metodă potrivită extragerii caracteristicilor bazate pe frecvențele de interes. Aplicând metoda pachetelor Wavelet, se va obține un arbore binar perfect. Cu toate acestea, descompunerea anumitor pachete nu ar oferi informații adiționale, fiind astfel redundantă. Pentru evitarea acestei situații se poate implementa o descompunere în funcție de entropia semnalului cu obținerea unui arbore binar plin, unde orice nod ar avea 0 sau 2 copii. Concret, se caută baza minimă prin care poate fi reprezentat un semnal.

După obținerea unui arbore optim, se propune analiza energiilor semnalelor din „frunzele” acestuia. Algoritmul va căuta nodul din arbore care are semnalul cu energia maximă. Odată găsit acest nod, se presupune că defectul poate fi identificat prin extragerea caracteristicilor semnalului corespunzător (de energie maximă).

Schema logică a acestui algoritm este:

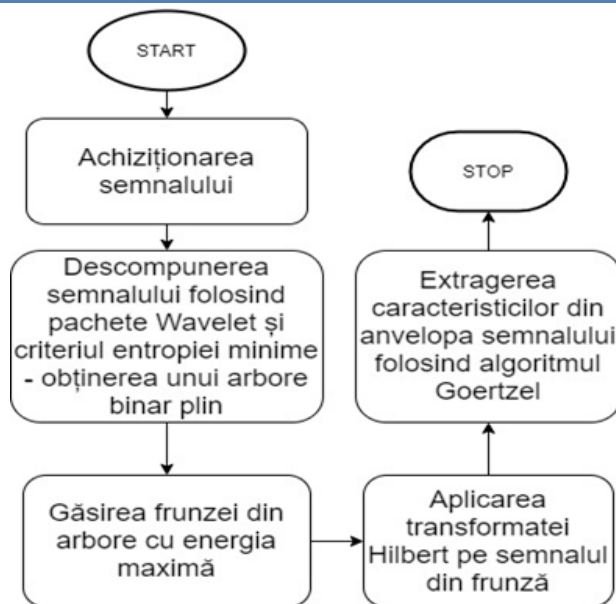


Figura 6.3: Algoritm de extragere a caracteristicilor folosind pachete Wavelet

Pentru diagnoza defectelor în rulmenți și reductoare este de interes analiza anvelopei semnalului prin obținerea spectrului anvelopei. Anvelopa semnalului se obține prin aplicarea transformatei Hilbert și extragerea amplitudinilor vectorilor formați de semnalul rezultat (care va fi complex). Anvelopa este folosită la rândul ei ca un semnal din care se extrag caracteristicile vibratorii pentru frecvențele de interes. Astfel, în loc de calculul spectrului, se pot extrage direct amplitudinile necesare folosind algoritmul Goertzel prezentat mai sus.

Implementarea acestui algoritm este realizată în secțiunea *WPTHandler.py* din *Anexa A*, unde este folosită biblioteca PyWavelets [23]

Utilizarea transformatei Hilbert-Huang

Acest algoritm este în special folosit pentru a extrage funcții proprii semnalului analizat și a obține spectrul Hilbert. Spectrul Hilbert este construit pe baza energiei instantanee care poate fi analizată din punct de vedere al frecvenței instantanee.

O altă abordare este similară cu cea descrisă anterior în utilizarea pachetelor Wavelet unde, odată extrase funcțiile proprii, se poate calcula anvelopa fiecărei funcții și din aceasta se pot extrage caracteristici folosind algoritmul Goertzel. De asemenea, se pot extrage caracteristici direct din semnalul dat de funcția proprie, în cazul în care defectul monitorizat nu apare în spectrul anvelopei semnalului. Având în vedere că această metodă de descompunere se oprește doar atunci când se atinge un număr maxim de funcții proprii (număr ales de dinainte de către utilizator) sau când semnalul rezidual este o funcție constantă sau strict monotonă, ***se propune drept criteriu de încetare a descompunerii în funcții proprii chiar găsirea defectului.*** Acest fapt creează posibilitatea luării unei decizii rapide în cazul depistării unui defect, în special pentru un sistem mecatronic la care timpul este o mărime critică pentru dinamica acestuia.

Implementarea HHT este prezentată în secțiunea *HHTHandler.py* din *Anexa A*, unde este folosită biblioteca PyEMD [24] pentru descompunerea empirică în moduri de oscilație.

Nou criteriu de încetare a procesului de descompunere empirică prin utilizarea algoritmului Goertzel pentru diagnosticarea defectelor la frecvențe specifice

Un criteriu care accelerează descompunerea empirică în moduri proprii de oscilație, pentru diagnosticarea anumitor defecte este reprezentat de învățarea anumitor caracteristici care indică prezența unui defect în cadrul unei funcții proprii extrase. Aceste caracteristici pot fi reprezentate de informații statistice calculate pentru distribuțiile compuse din coeficienții DFT extrași prin algoritmul Goertzel din fiecare funcție proprie. ***În momentul în care un nou set de date ar fi considerat în afara valorilor admise pentru caracteristici, se poate considera că funcția proprie conține un defect și descompunerea poate lua sfârșit.***

Pentru ca acest algoritm să fie robust trebuie să conțină două etape:

1. Etapa de învățare – etapa unde valorile caracteristicilor sunt calculate pe seturi de date achiziționate de la sistemul funcțional
2. Etapa de diagnoză – unde algoritmul compară noi caracteristici calculate pentru date achiziționate în timpul monitorizării cu caracteristicile învățate la punctul 1

Caracteristicile folosite sunt: valoarea medie a semnalului, abaterea standard a semnalului și intervalul setului de date:

Aceste 3 caracteristici sunt îndeajuns pentru a testa un nou set de date și abaterea lor de la o distribuție învățată anterior. Algoritmul are următorii pași:

1. Se creează o listă de frecvențe monitorizate
2. Se execută algoritmul de descompunere empirică în moduri pentru un semnal de antrenare achiziționat de la sistemul în stare funcțională
3. După ce toate funcțiile proprii au fost calculate, se definește o matrice A cu m linii și n coloane, unde m este numărul de frecvențe monitorizat și n numărul de funcții proprii; valorile din A reprezintă valorile absolute ale coeficienților DFT extrași prin algoritmul Goertzel, pentru fiecare frecvență monitorizată din anvelopele semnalelor calculate pentru funcțiile proprii;
4. Fiecare rând din A reprezintă un set de date din care se extrag datele statistice menționate mai sus; aceste date și matricea A vor fi stocate
5. În etapa de diagnoză, odată ce o funcție proprie a fost extrasă, coeficienții DFT sunt calculați pentru frecvențele monitorizate și valorile lor absolute sunt calculate și adăugate ca o nouă coloană a matricei A , formând astfel matricea B
6. Caracteristicile statistice sunt calculate pentru matricea B și comparate cu cele stocate la punctul 4. Dacă fiecare caracteristică diferă cu mai mult de un coeficient ales, în prealabil, rezultă prezența unui defect și, prin urmare, descompunerea poate lua sfârșit.

Coeficientul poate fi ales printr-un proces automat în timpul învățării. Acesta reprezintă variația maximă admisă pentru oricare dintre caracteristicile extrase. Metoda de găsimă a acestui coeficient este formată din două etape:

- Se împart datele achiziționate de la sistemul funcțional în două mulțimi de date: date pentru antrenare și date pentru validare
- Folosind datele antrenare se extrag caracteristicile folosind pașii 1-4 de mai sus. Apoi, pornind de la un coeficient cu valoarea 0.1, acesta este incrementat cu valoarea 0.1 până când algoritmul nu detectează niciun defect folosind datele de validare ca date analizate

Implementarea acestui algoritm este realizată în secțiunea *CustomHHT.py* din *Anexa A*.

Calcularea frecvențelor de defect

Conform datelor prezentate în capitolul 2, un număr ridicat de defecte poate fi identificat, pe baza analizei vibrațiilor, prin monitorizarea amplitudinilor la anumite frecvențe de interes. În acest fel, aceste frecvențe devin caracteristicile care trebuie căutate într-un model de diagnoză bazat pe vibrații. Având în vedere că defectele în rulmenți și reductoare sunt mai ușor de observat în spectrul anvelopei semnalelor, se vor defini caracteristici atât pentru acest tip de spectru cât și pentru cel al semnalelor.

Calcularea frecvențelor specifice diferitelor defecte este implementată în secțiunea *DiagnosisHandler.py* din *Anexa A*. Acestea sunt calculate pe baza datelor de construcție a sistemului mecatronic și a componentelor acestuia. Alegerea metodei de prelucrare a semnalului se face de către inginerul care instalează sistemul de monitorizare în funcție de datele achiziționate de la sistem, WPT fiind mult mai rapidă decât HHT cu mențiunea că pentru WPT este necesară specificarea familiei de funcții Wavelet folosite pe când HHT este o metodă adaptivă.

6.1.3. Modul de detecție a defectelor

Pentru detecție și diagnosticare, aplicația va încărca modelele salvate pentru a avea date de referință și modele pre-antrenate în diagnosticarea unor defecte cunoscute.

Pentru detecția defectelor se folosesc caracteristicile extrase cu ajutorul WPT. Motivul pentru care a fost ales WPT ca metodă de prelucrare a datelor este viteza și faptul că familia de funcții Wavelet Daubechies oferă niște caracteristici vibratorii similare cu HHT, care pot fi folosite cu succes pentru diagnosticarea sistemului mecatronic analizat. Aceste caracteristici sunt evaluate de către o pădure de izolare (algoritm prezentat în 5.2.1.2), stabilindu-se o corespondență între semnalele obținute din frunzele arborelui de descompunere (semnalele provenind de la sistemul de acționare și de la sistemul efector). ***Având mai multe eșantioane și existând posibilitatea unor răspunsuri fals negative, se apelează la un calcul statistic constând din media răspunsurilor date de pădurile de izolare. Astfel, dacă media este pozitivă nu există defect, iar dacă este negativă, un defect este detectat.***

Procedura se aplică pe matricele A și B , formate din pachetele obținute la un moment dat pentru semnalele achiziționate de la cele două accelerometre. A și B sunt de forma $n \times m$, unde n este numărul de eșantioane aferent unui pachet de pe ultimul nivel al arborelui de descompunere prin pachete Wavelet și m este numărul de pachete ($m=2^l$ unde l este ultimul nivel al arborelui).

Pentru primul filtru de detecție se folosesc două modele create pe baza a două păduri de izolare. Astfel, eventualele anomalii în comportarea vibratorie a motorului și în cea a efectorului pot fi ușor detectate. În vederea determinării existenței unui defect în sistemul de transmisie dintre motor și efector se folosește algoritmul descris în următoarea secțiune.

6.1.3.1 Modelarea lanțului cinematic printr-o rețea neuronală de regresie

Pentru a putea folosi un algoritm de învățare automată, datele achiziționate de la senzor trebuie procesate pentru a obține informații cu semnificație intrinsecă sistemului și care poate caracteriza semnalul din punct de vedere matematic; această caracterizare trebuie să fie folositoare pentru o funcție de cost care este minimizată de algoritmul de învățare automată. Pentru a extrage caracteristicile importante din punct de vedere spectral trebuie folosit un algoritm de procesare care poate oferi rezultate despre comportarea vibratorie într-o formă vectorială.

Caracteristicile extrase prin procesarea semnalelor achiziționate sunt folosite pentru a modela sistemul cinematic de transmisie a sistemului mecatronic monitorizat.

Descrierea și rezolvarea problemei

Problema abordată este estimarea comportării vibratorii a sistemului efector în funcție de caracteristicile vibratorii ale sistemului actuator. Pentru rezolvarea acestei probleme neliniare este necesar un model bazat pe date, model reprezentat de către ponderile rețelei neuronale de regresie antrenate. Fie A un spațiu vectorial cu baza formată din vectorii caracteristicilor extrase din semnalul provenit de la motor și B spațiul vectorial având ca bază vectorii caracteristicilor extrase din semnalul provenit de la efector; dacă T este un sistem atunci:

$$\tilde{Y}(t) = X(t)T \quad (6.2)$$

unde $\tilde{Y}(t)$ este valoarea estimată dată de sistemul T la momentul t dacă datele de intrare sunt reprezentate de $X(t)$. Găsirea unui sistem T care să aproximeze corect $\tilde{Y}(t)$ permite monitorizarea sistemului de transmisie și identificarea unor probleme necunoscute ce pot apărea datorită diferiților factori implicați. Folosind un model bazat pe date, orice sistem cinematic de transmisie poate fi caracterizat prin această metodă (fără a necesita schimbarea algoritmului sau a implementării acestuia).

Algoritmul prezentat mai sus a fost testat folosind diferite metode de prelucrare a semnalului, cum ar fi coeficienți cepstrali pe scară mel (MFCC) sau coeficienți obținuți în urma aplicării transformatei Wavelet prin pachete. Rezultatele testului pe MFCC au fost prezentate în cadrul "*International Conference of MECHATRONICS & CYBER-MIXMECHATRONICS*"

(2020). Articolul [25] a fost publicat în jurnalul “*International Journal of Mechatronics and Applied Mechanics*” indexat *SCOPUS*. În teză algoritmul este implementat în secțiunea *NeuralNetManager.py* din *Anexa A*.

Extragerea caracteristicilor și folosirea lor pentru detecția defectelor

Fie un nou eșantion x_{ij} pentru fiecare accelerometru, acesta fiind prelucrat pentru a obține arborele optim folosind pachetele Wavelet și criteriul entropiei (conform 6.1.2):

$$X_{prelucrat_j} = Extragere_{WPT}(x_{ij}) \quad (6.3)$$

$X_{prelucrat_j}$ poate fi considerată matricea egală cu A sau B în funcție de indicele j :

$$\begin{aligned} A, \text{dacă } j &= 1 \\ B, \text{dacă } j &= 2 \end{aligned} \quad (6.4)$$

În continuare, A și B se testează:

$$\begin{aligned} scor_{izolare_{motor}} &= Test_{model_{motor}}(A) \\ scor_{izolare_{manipulator}} &= Test_{model_{manipulator}}(B) \end{aligned} \quad (6.5)$$

Dacă scorul obținut pentru motor este -1, atunci a fost detectat un defect în cadrul motorului. Dacă scorul obținut pe efectore este -1 atunci fie există un defect în efectore, fie există un defect în sistemul de transmisie.

Pentru a putea detecta unde a apărut defectul, se va folosi sistemul de transformare T , pentru a efectua următoarele operații:

$$\begin{aligned} B' &= AT \\ B_{eroare} &= B - B' \end{aligned} \quad (6.6)$$

Pentru a obține matricele A și B se folosește o fereastră cu o durată aleasă pentru a extrage mici semnale care reprezintă eșantioane de antrenare pentru modelul rețelei neuronale și pentru modelele pădurilor de izolare. Pe semnalul fiecărei ferestre se aplică descompunerea în pachete Wavelet. Pentru stocarea pachetelor se folosește un vector tridimensional: prima dimensiune a vectorului reprezintă numărul de eșantioane rezultat, cea de-a doua dimensiune - numărul de frunze din arborele de pachete rezultat și cea de-a treia dimensiune - numărul de puncte dintr-un pachet.

Întreg algoritmul de detecție a defectelor este implementat în secțiunea *DiagnosisHandler.py* din *Anexa A*, funcția *startDiagnosis*. Este important de menționat că modulul de detecție și diagnosticare sunt implementate în aceeași secțiune însă sunt folosite funcții separate sau biblioteci separate.

6.1.4. Modulul de diagnosticare

După depistarea și localizarea defectelor (în semnalul de la motor sau în semnalul de la efector), se aplică **descompunerea în pachete Wavelet**, folosind identificarea nodului din arborele optim cu energie maximă. Arborele a fost deja construit în etapa de detecție a defectelor, astfel că din punct de vedere al complexității în timp și spațiu, efortul pentru găsirea nodului cu energie maximă este minim.

În cazul în care este găsit un defect la o frecvență comună mai multor defecte, se încearcă delimitarea defectelor în funcție de amplitudine.

Pentru diagnosticarea motorului se creează grupuri de eșantioane de mărime prestabilită (cu cât valoarea este mai mare, cu atât crește acuratețea analizei statistice). Pentru fiecare grup, se determină o distribuție dată de fiecare caracteristică de frecvență calculată pentru spectrul semnalului și pentru spectrul anvelopei semnalului. Semnalul este extras din nodul cu cea mai mare energie din arborele optim de pachete Wavelet. După obținerea distribuțiilor datelor nou achiziționate, acestea se compară cu referința dată de modelul antrenat.

Practic, diagnosticarea defectelor se face cu ajutorul unor vectori binari (care conțin doar 1 sau 0), construiți pe baza caracteristicilor extrase de la sistemul funcțional în etapa de antrenare. Un astfel de vector are numărul de elemente egal cu numărul de frecvențe monitorizate și valoarea fiecărui element este fie 0, dacă distribuția amplitudinilor nou înregistrate nu diferă față de distribuția de referință construită în timpul antrenării, fie 1 dacă distribuția amplitudinilor diferă față de cea de referință. Pentru a compara cele două distribuții se utilizează următorul algoritm.

6.1.4.1 Algoritm de diagnoză a defectelor folosind testul statistic Kolmogorov-Smirnov

În [26] este prezentat un algoritm pentru detecția și identificarea defectelor în rulmenți. Algoritmul a fost prezentat la conferința *“THE 9th INTERNATIONAL CONFERENCE ON ADVANCED CONCEPTS IN MECHANICAL ENGINEERING”* și a fost publicat în *“IOP Conference Series: Materials Science and Engineering”*, jurnal indexat *ISI Web of Science* și *Scopus*. Pe scurt, algoritmul este compus din următorii pași:

1. Se stochează caracteristicile extrase din semnal într-o matrice de dimensiuni $m \times n$ unde m este numărul de eșantioane și n este numărul de frecvențe de interes. Această etapă reprezintă antrenarea modelului și se face pe datele achiziționate de la sistemul funcțional
2. Se achiziționează date noi pentru un interval de timp egal cu timpul folosit pentru antrenare și se extrag caracteristicile de interes
3. Pentru fiecare defect posibil, se aplică testul Kolmogorov-Smirnov (K-S test) unde distribuțiile de referință folosite sunt reprezentate de fiecare coloană din matricea construită la punctul 1, interpretând statistica D în raport cu valoarea critică a acesteia

4. Probabilitatea ca un defect să fie prezent pentru o frecvență caracteristică este dată de:

$$P_{eșantion} = \frac{\#ipoteze\ nule\ respinse}{\#frecvențe} \quad (6.7)$$

5. Având n eșantioane, se poate folosi probabilitatea condițională prin folosirea legii probabilității totale; dacă mai multe evenimente măsurabile și disjuncte au loc, atunci probabilitate de apariție a unui eveniment A este:

$$P(A) = \sum_i^n P(A|B_i)P(B_i) \quad (6.8)$$

6. Dacă A este evenimentul în care sistemul are un defect într-o anumită componentă și B_i este evenimentul în care un defect este prezent prin caracteristici vibratorii în datele noi achiziționate, atunci probabilitatea ca A să se întâmple dată fiind apariția lui B_i este:

$$P(A|B_i) = \frac{P(B_i)}{n} \quad (6.9)$$

Algoritmul a fost implementat în cadrul secțiunii **DiagnosisHandler.py** din **Anexa A**, funcția **doKSTest**. Funcția folosește implementarea testului Kolmogorov-Smirnov din biblioteca `scipy` [27], calculează statistica D critică (pasul 3) și întoarce valoarea 1 dacă cele două distribuții nu corespund sau 0 dacă cele două distribuții fac parte din aceeași clasă de distribuții. Funcția este folosită mai departe în funcția **diagnoseMotor**, care implementează pașii 4, 5 și 6 pentru a calcula o probabilitate de defect și pentru a putea diagnostica defectul (în cazul în care acesta există) din sistem.

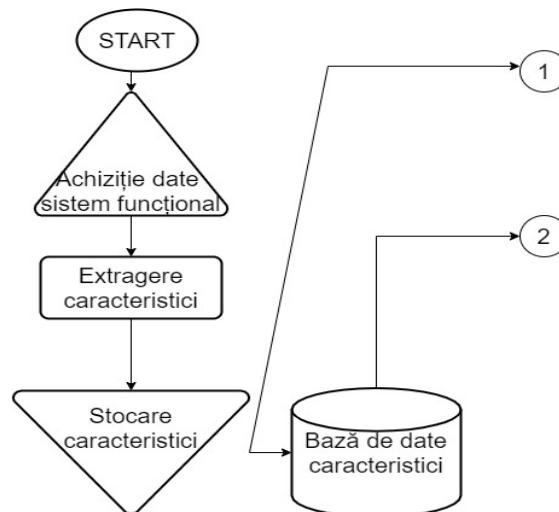


Figura 6.4: Partea 1 a organigramei algoritmului de diagnoză folosind testul Kolmogorov-Smirnov

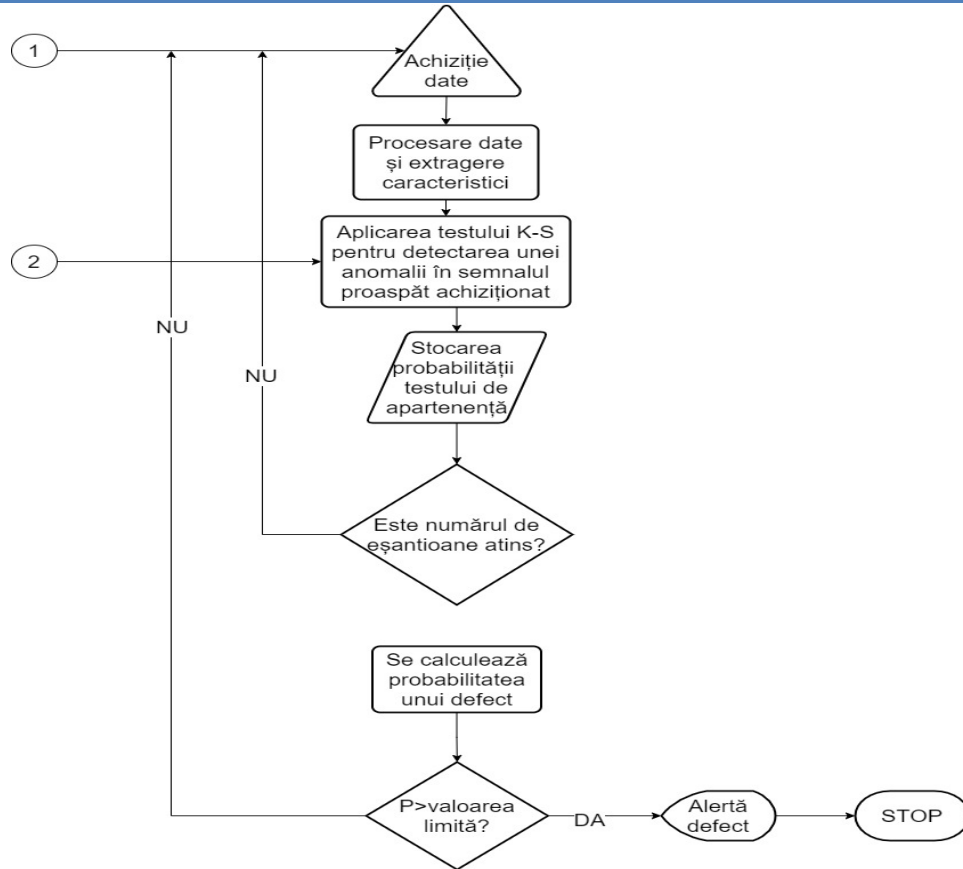


Figura 6.5: Partea a 2-a a organigramei algoritmului de diagnostică folosind testul Kolmogorov-Smirnov

Pentru extragerea caracteristicilor poate fi folosit orice algoritm, de exemplu cel prezentat de autor în cadrul conferinței “*International Conference of MECHATRONICS & CYBER-MIXMECHATRONICS*” (2019) și a fost publicat în jurnalul “*International Journal of Mechatronics and Applied Mechanics*” indexat *SCOPUS*. În teză este folosită o versiune modificată a acestui algoritm implementată în secțiunea *Utilities.py* din *Anexa A*, în funcția *getGoertzelCoeffs*.

Implementarea diagnozei este prezentată în secțiunea *DiagnosisHandler.py* din *Anexa A* în funcția *diagnoseMotor*. **Dacă defectul nu poate fi clasificat**, se extrag caracteristicile în domeniul timp, pentru fiecare frunză a arborelui din pachetele Wavelet (implementarea prezentată în *DiagnosisHandler.py* din *Anexa A* în funcția *getSignalFeaturesFromWptData*) și se trece la căutarea caracteristicilor unui defect similar întâlnit anterior, folosind sistemul de clasificare nesupervizat, kNN prin biblioteca scikit [28].

În cazul în care clasificarea eșuează, sistemul este oprit automat și operatorii sunt anunțați că există un defect necunoscut. În acest moment, se înregistrează caracteristicile extrase anterior. După găsirea și repararea defectului, operatorii sunt rugați să-l eticheteze pentru o diagnosticare ulterioară. Evident, pot fi implementate soluții informatice pentru a stoca aceste caracteristici în Cloud, însă nu fac obiectul acestei teze.

Vectorii de caracteristici înregistrați vor fi folosiți în sistemul de clasificare kNN menționat mai sus. Atunci când va fi detectat un nou defect care nu poate fi clasificat de către prima parte a algoritmului, se va încerca încadrarea lui în una din categoriile deja existente în kNN. Dacă acest lucru nu este posibil, se va forma o nouă categorie, pe baza caracteristicilor vibratorii extrase (care caracterizează defectul în contextul sistemului monitorizat).

6.1.5. Modulul de alertare a operatorilor

Operatorii din fabrică sau alte persoane interesate de funcționarea sistemului trebuie atenționate în momentul apariției unui defect. De aceea, un modul de alertare este necesar care să poată afișa mesaje de eroare pe ecranele dedicate ale sistemului, să poată trimite mesaje electronice sau să pornească diferite semnale sonore sau vizuale de atenționare. Acest lucru se va întâmpla indiferent dacă defectul este cunoscut sau nu (deoarece sistemul trebuie reparat sau programat pentru reparații). După identificarea defectului, acest modul va afișa și tipul defectului care a fost diagnosticat. Acest modul face parte din secțiunea *DiagnosisHandler.py* din *Anexa A* fiind folosit prin funcția *addToDiagnosticText*.

6.1.6. Modulul de antrenare a modelelor și de stocare a datelor de referință obținute de la sistemul funcțional

Deși antrenarea modelelor are loc înainte de procesul de diagnoză, prima etapă depinde de procesul de diagnoză și de algoritmele folosite și de aceea au fost prezentate întâi modulele din etapa de diagnoză și apoi etapa de antrenare, pentru a oferi o mai bună înțelegere a algoritmului de antrenare și a datelor folosite pentru a fi salvate și pentru a reprezenta o referință validă.

Acest modul realizează antrenarea modelelor pe bază de date, calcularea frecvențelor de defect și stocarea amplitudinilor obținute pentru aceste frecvențe, pentru crearea unei referințe folosite ulterior, în etapa de diagnosticare. Modelele construite sunt folosite de pădurile de izolare, de o rețea neuronală și de algoritmele de diagnoză folosite în etapa de diagnosticare.

Vectorii de diagnoză, cu frecvențele de defect calculate conform 6.1.2.2. vor reprezenta referința pentru diagnosticarea pe baza datele nou achiziționate.

Extragerea caracteristicilor și antrenarea modelelor

Așa cum a fost prezentat în capitolul 4, pentru identificarea anumitor tipare în semnale este necesar ca acestea să fie prelucrate. În urma prelucrării lor, se pot extrage caracteristici semnificative care pot oferi informații importante asupra stării sistemului.

Pentru modulul de detecție, conform 6.1.3.1, este necesară definirea matricelor *A* și *B*. Se definesc două semnale de antrenare achiziționate de la motor, respectiv de la efectuator.

Aceste matrice se utilizează la antrenarea rețelei neuronale și a modelelor pădurilor de izolare. După antrenare, aceste modele sunt salvate în fișierele menționate de către utilizator.

Același arbore de pachete Wavelet este folosit și pentru construirea modelului de frecvențe de defect. Asupra semnalelor din fiecare nod al arborelui se aplică transformata Hilbert și se calculează modulul semnalului rezultat, obținându-se, astfel, anvelopa superioară. Din aceasta și din semnalul original se extrag amplitudinile la frecvențele calculate anterior, folosind algoritmul Goertzel. Rezultatele sunt stocate în doi vectori tridimensionali, unul pentru spectrul anvelopei și unul pentru spectrul semnalului. Dimensiunile acestor vectori sunt $p \times 2^l - 1 \times k_i$, unde p este numărul de eșantioane, l este nivelul maxim al arborelui de pachete și k_i este numărul de frecvențe pentru anvelopa ($i=1$) și pentru semnal ($i=2$). Acești vectori sunt salvați într-un fișier definit de către utilizator.

Implementarea întregului modul de antrenare este prezentată în secțiunea *DiagnosisHandler.py* din *Anexa A* în funcția *startTrainingAllModels*.

6.2 Obiectivele și descrierea aplicației

Aplicația software dezvoltată îndeplinește două scopuri:

1. Procesare de semnal prin diferite metode și vizualizarea rezultatelor obținute, permițând utilizatorului să modifice diferiți parametri pentru a observa caracteristicile vibratorii de interes
2. ***Diagnoză online a unui sistem mecatronic în timpul funcționării cu atenționarea automată a operatorilor în cazul unui defect și oprirea sistemului monitorizat (sau intrarea într-un regim de funcționare cu toleranță la defect).***

Primul obiectiv este dedicat utilizatorilor cu scopul de a permite acestora vizualizarea diferitelor caracteristici prezente într-un semnal. Modalitățile de prelucrare a semnalului sunt reprezentate de transformata Wavelet în pachete și transformata Hilbert-Huang. Pe baza acestora, un utilizator poate observa care este metoda cea mai bună prin care poate fi procesat un semnal achiziționat de la un sistem funcțional. Pe baza acestei decizii, utilizatorul poate folosi metoda aleasă pentru antrenarea unui model de diagnoză ce caracterizează sistemul care funcționează în parametri nominali.

Cel de-al doilea obiectiv permite utilizatorului de a obține modele de diagnoză într-un mediu offline (datele analizate au fost achiziționate în trecut – antrenarea și analiza se face pe un calculator personal), ca apoi acestea să poată fi folosite în diagnoza defectelor într-un mediu online (datele sunt achiziționate în timp real). În acest caz, algoritmul de diagnoză poate funcționa și pe un microcontroler (însă acest lucru trebuie evaluat pentru fiecare caz în parte, procesarea semnalului putând fi costisitoare). În momentul în care sistemul de monitorizare detectează un defect, sistemul observat fie este oprit automat, fie este dus într-un regim de toleranță la defect. În ambele cazuri, operatorii sunt atenționați de existența defectului în sistem.

CAPITOLUL 7

REZULTATE PRIVIND DIAGNOSTICAREA UNOR DEFECTE ALE COMPONENTELOR ȘI SISTEMELOR MECATRONICE

7.1 Experiment pe un stand pentru determinarea comportării dinamice a arborilor drepți

7.1.1. Descrierea standului

Standul servește, în general, la măsurarea săgeților dinamice, în plan orizontal și vertical, în timpul accelerării arborelui din starea de repaus până la o turație superioară celei critice, în vederea ridicării curbelor de comportare dinamică a acestuia, în prezența vibrațiilor transversale de încovoiere.




Figura 7.1: Standul pentru determinarea turației critice la un arbore drept

Amplitudinile și frecvențele vibrațiilor transversale ale arborelui și discului (masa inertială) din figura 7.1 sunt măsurate în timp real de traductoarele inductive T_1 și T_2 (Wenglor, IW045CM65MG31), ale căror semnale sunt achiziționate cu ajutorul unei plăci de achiziție NI-6221 de la National Instruments. Turația arborelui este reglabilă în domeniul 0-1500 rot/min și se măsoară cu un traductor incremental de rotație, atașat motorului. Limitatorul săgeții masei inertiiale este constituit dintr-un suport (figura 7.1), care conține un rulment 61816, cu inelul interior rotitor.

7.1.2. Achiziția datelor

Programul de achiziție a datelor (pentru placa NI-6221, la care se conectează T_1 și T_2) este dezvoltat în mediul de programare LabView de la National Instruments. Cu ajutorul acestuia, au fost achiziționate și salvate datele, în fișiere de tipul *.tdms*. Experimentul a furnizat date privind săgeata dinamică pentru turații diferite ale arborelui, respectiv la prima turație critică și la o turație inferioară acesteia. De asemenea, au fost achiziționate datele pentru cazul în care există o perturbație externă sub forma unei frânări exercitate asupra arborelui.

7.1.3. Efectuarea experimentului

Obiectivele experimentului au fost verificarea eficacității algoritmilor și a programelor dezvoltate, pentru punerea în evidență a perturbării intenționate a mișcării, prin frânare, ca substitut al unei coliziuni accidentale, respectiv a turației critice. În acest scop, au fost

achiziționate datele în timpul funcționării normale a standului, respectiv în cele două situații de defect, utilizându-se montajul din figura 7.2.




Figura 7.2: Montaj pentru realizarea experimentului

Motorul a fost alimentat de la o sursă de curent continuu, prin intermediul unui potențiomtru, care, prin tensiunea de alimentare, reglează valoarea turației acestuia. O a doua sursă a fost necesară pentru alimentarea traductoarelor la o tensiune de 20 V.

Intrarea în domeniul turației critice a fost sesizată prin manifestarea dinamică zgomotoasă a arborelui, achiziționându-se datele furnizate de traductoare, în acest regim de funcționare, iar pentru cazul când a fost exercitată câte o frânare asupra arborelui, la interval de 4 secunde, s-a achiziționat un alt set de date.

7.1.4. Prelucrarea rezultatelor

În urma efectuării experimentului și a achiziției seturilor de date, acestea au fost procesate prin eliminarea medianei (algoritm prezentat în 4.5.4.1). Datele rezultate au fost încărcate în aplicația descrisă în subcapitolul 6.2. Prin aplicarea atât a transformatei Wavelet, prin pachete, cât și a transformatei Hilbert-Huang, frânarea este observată și poate fi identificată prin pădurea de izolare (algoritm inteligent de detecție a punctelor externe unui model antrenat anterior, algoritm prezentat în capitolul 5). Acest algoritm este folosit în sistemul de diagnoză descris în subcapitolul 6.1 pentru detecția timpurie a unor posibile defecte.

În figurile 7.3 și 7.4 sunt prezentate semnalele procesate cu transformata Wavelet prin pachete, pentru funcționarea normală a standului, respectiv pentru perturbația prin frânare.

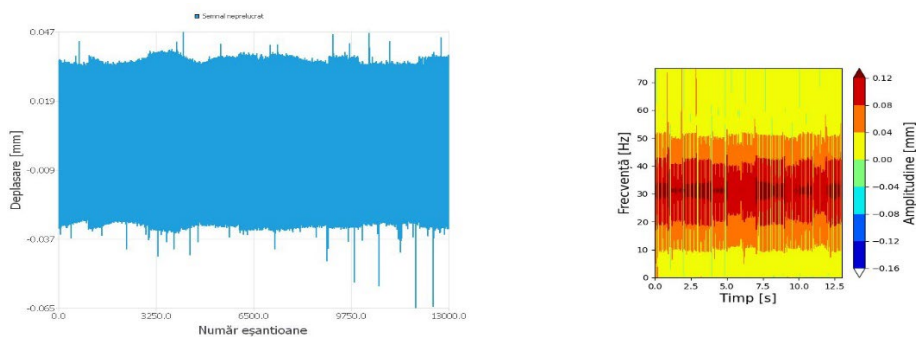


Figura 7.3: Semnal achiziționat în timpul funcționării normale a standului (stânga) și scalograma sa obținută prin WPT (dreapta)

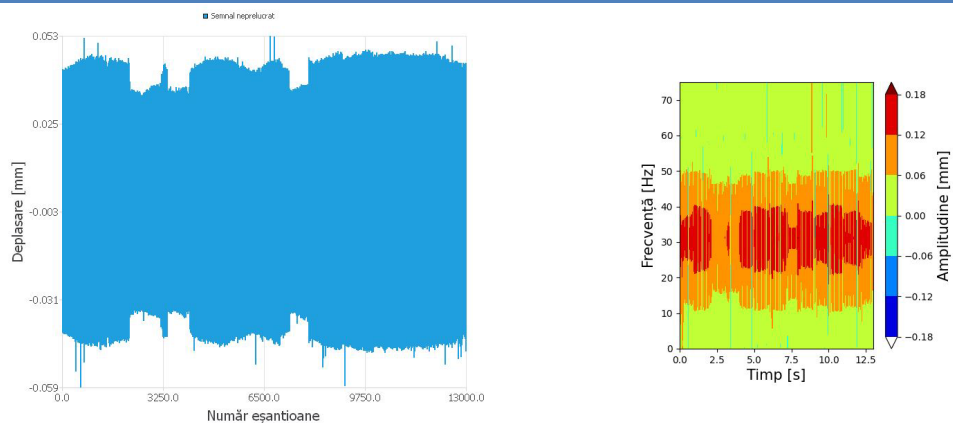


Figura 7.4: Semnal achiziționat în timpul funcționării standului cu aplicarea unei frânări (stânga) și scalograma sa obținută prin WPT (dreapta)

Din figura 7.4 se poate observa diminuări ale energiei în momentul apariției fenomenului de frânare (secundele 2,5 și 7,5), constatare identificată cu ușurință.

De asemenea, au fost înregistrate date și pentru momentul când valoarea turației motorului iese din intervalul de funcționare normală, începând să apară amplitudini mari ale săgeții arborelui. Acest lucru se poate observa în creșterea amplitudinii semnalului (figura 7.5).




Figura 7.5: Semnal achiziționat când valoarea turației motorului iese din intervalul de funcționare (stânga) și scalograma sa obținută prin WPT

Evaluând datele prezentate grafic în figura 7.4 și în figura 7.5, împărțite în eșantioane prin utilizarea unei ferestre de 500 ms, pădurea de izolare a identificat un defect în semnalul cu frânare cu o probabilitate de 65% și în semnalul cu turație critică cu o probabilitate de 95%. În aceste situații, algoritmul de diagnoză trimite o comandă către microcontrolerul atașat sistemului pentru oprirea acestuia, evitând o degradare ulterioară a sistemului. Rezultatele demonstrează faptul că sistemul de diagnoză este robust și probabilitățile arată și faptul că în cazul frânării, doar o parte din eșantioane sunt considerate a fi defecte, acele eșantioane care sunt afectate de frânare; în situația când turația devine critică, aproape toate eșantioanele sunt considerate a nu fi conforme cu modelul antrenat, rezultat corespunzător cu dinamica sistemului fizic.

7.2 Rezultate obținute pe datele achiziționate de la rulmenți

7.2.1 Diferențe între metode de prelucrare a semnalului achiziționat de la accelerometre

În capitolul 4 au fost prezentate trei metode de prelucrare a semnalului obținut de la accelerometre, metode relevante pentru extragerea caracteristicilor folositoare într-un sistem de diagnoză inteligent bazat pe analiza vibrațiilor. Utilizând aceste metode, au fost extrase caracteristici din semnalul achiziționat de accelerometre de la un rulment cu scopul de a observa care metodă este mai robustă și care poate oferi informații relevante pentru sistemele mecatronice complexe.

Pentru testarea cu cele trei metode s-au folosit datele achiziționate de la rulmenți care provin de la Universitatea “Case Western Reserve”. Datele sunt disponibile la adresa [29]. Testele au fost făcute folosind aplicația descrisă în subcapitolul 6.2 și codul dezvoltat de către autorul tezei în limbajul python disponibil în *Anexa D*. O parte din funcții refolosesc codul din aplicația din *Anexa A*.

În fișierele analizate există date pentru rulmenți funcționali și pentru rulmenți cu diferite componente defecte. Defectele constau în mici denivelări de diferite dimensiuni făcute printr-un aparat de puncție electrică. Diametrele denivelărilor sunt cuprinse în intervalul 0.178 mm și 1.016 mm. Datele au fost achiziționate cu o rată de eșantionare de 12 kHz. Rulmenții sunt de tipul 6205-2RS JEM SKF și viteza de rotație este de 1797 rotații pe minut (rpm). În tabelul 7.1 sunt prezentate datele rulmentului și în tabelul 7.2 sunt calculate frecvențele de defect. Metodele de prelucrare a semnalelor vor fi aplicate pe măsurătorile vibratorii achiziționate de la rulmenți funcționali și rulmenți cu defecte pe inelul interior și pe cel exterior.

Tabelul 7.1: Date rulmenți

Diametrul interior	25 mm
Diametrul exterior	52 mm
Grosime	15 mm
Diametru bile	7.94 mm
Diametru de rostogolire	39.04 mm

Tabelul 7.2: Frecvențele de defect pentru rulmenții studiați

Ford	107.36 Hz
Fird	162.18 Hz
Fbd	141.16 Hz
Fc	11.92 Hz

Astfel, aplicând **metoda de extragere a MFCC (coeficienți cepstrali pe scara mel)**, au fost obținute cepstograme prezentate în figurile 7.6, 7.7, 7.8. O cepstogramă este similară cu o scalogramă, însă axa ordonată conține numărul coeficienților cepstrali, fiecare coeficient corespunzând unui interval de frecvențe.




Figura 7.6: Coeficienții cepstrali pe scară mel pentru un rulment funcțional




Figura 7.7: Coeficienții cepstrali pe scară mel pentru un rulment cu defect pe inelul interior




Figura 7.8: Coeficienții cepstrali pe scară mel pentru un rulment cu defect pe inelul exterior

Se poate observa din figurile 7.6, 7.7 și 7.8 că există diferențe clare între cepstograme; un algoritm de învățare automată ar putea clasifica cu ușurință cele 3 stări dacă ar exista date de defect pentru fiecare componentă monitorizată. Acest lucru nu este însă fiabil pentru un sistem

complex, sistemul de diagnoză având nevoie să înglobeze cunoștințele acumulate de-a lungul timpului despre comportarea vibratorie a componentelor în prezența unui defect. Acest lucru permite diagnosticarea defectelor cunoscute, ușurând clasificarea acestora pe baza caracteristicilor vibratorii.

Un alt dezavantaj al acestei metode este rezoluția în frecvență deoarece nu prezintă posibilitatea de a localiza exact o anumită frecvență.

A doua metodă de prelucrare a semnalului este cea care presupune descompunerea în pachete Wavelet. Pentru analiza semnalelor a fost folosit modulul aplicației prezentate în 6.2.

În figurile de mai jos sunt reprezentate scalograme pentru cele 3 semnale analizate:




Figura 7.9: Scalogramă pentru semnalul achiziționat de un accelerometru pentru un rulment funcțional




Figura 7.10: Scalogramă pentru semnalul achiziționat de un accelerometru pentru un rulment cu defect pe inelul exterior




Figura 7.11: Scalogramă pentru semnalul achiziționat de un accelerometru pentru un rulment cu defect pe inelul interior

Se observă clar diferențele între scalograme. Extrăgând arborii de pachete Wavelet și analizând energiile nodurilor, se observă că aceștia diferă deoarece informația care este relevantă este prezentă doar în anumite benzi de frecvență, acolo unde impactul generat de către defect induce mărirea energiei semnalului.

Conform algoritmului descris în 6.1.2, analizând nodurile frunză cu energia maximă din arborii optimi găsiți, spectrele anvelopelor semnalelor din aceste noduri sunt:




Figura 7.12 Spectrul anvelopei semnalului pentru un rulment funcțional pentru nodul 4 de pe nivelul 4 al descompunerii prin pachete Wavelet (banda de frecvență 750-1125 Hz)

Se poate observa că în cazul rulmentului funcțional frecvența dominantă este aproximativ 30 Hz, frecvență corespunzătoare cu viteza de rotație a arborelui de 1797 RPM.

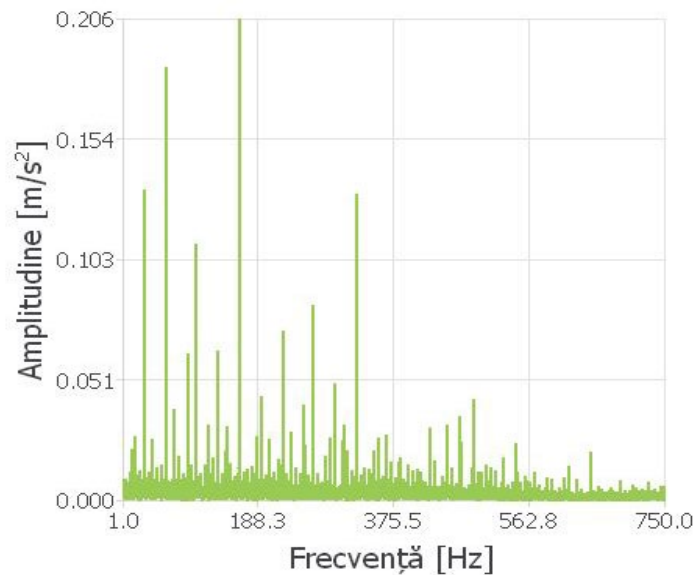


Figura 7.13: Spectrul anvelopei semnalului pentru un rulment cu inel interior defect pentru nodul 7 de pe nivelul 3 al descompunerii prin pachete Wavelet (banda de frecvență 3000-3750 Hz)




Figura 7.14: Spectrul anvelopei semnalului pentru un rulment cu inel exterior defect pentru nodul 7 de pe nivelul 3 al descompunerii prin pachete Wavelet (banda de frecvență 3000-3750 Hz)




Figura 7.15: Spectrul anvelopei semnalului pentru un rulment cu funcțional pentru nodul 7 de pe nivelul 3 al descompunerii prin pachete Wavelet (banda de frecvență 3000-3750 Hz)

În figurile 7.13 și 7.14 se observă că vârfurile proeminente se află la frecvențele de defect (162 Hz și 107 Hz) pentru inelul interior, respectiv exterior. În figura 7.15 este afișat spectrul anvelopei semnalului nodului cu aceeași bandă de frecvență ca cea în care au fost depistate defectele: amplitudinea semnalului la toate frecvențele este mult mai mică decât cea din nodurile corespondente din arborii obținuți în urma analizării semnalelor provenite de la rulmenții defecti.

Un alt aspect important este faptul că vibrațiile provenite în urma defectelor sunt modulate în aceeași bandă de frecvență, ceea ce fizic este normal având în vedere că viteza de rotație a arborelui și componentele rulmentului sunt aceleași.

Aplicând algoritmul Goertzel prezentat în capitolul 6.1 pe semnalul obținut în urma căutării nodului cu cea mai mare energie din arborele rezultat prin procesarea prin pachete Wavelet, au fost măsurate următoarele valori pentru coeficienții DFT:

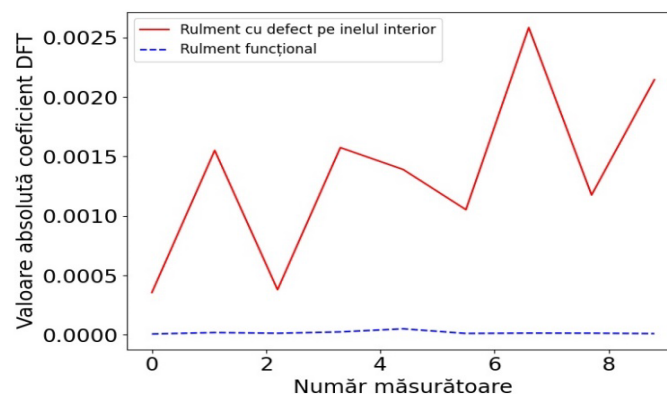


Figura 7.16: Comparare între valorile absolute a coeficienților DFT pentru un rulment funcțional cu un rulment cu defect pe inelul interior

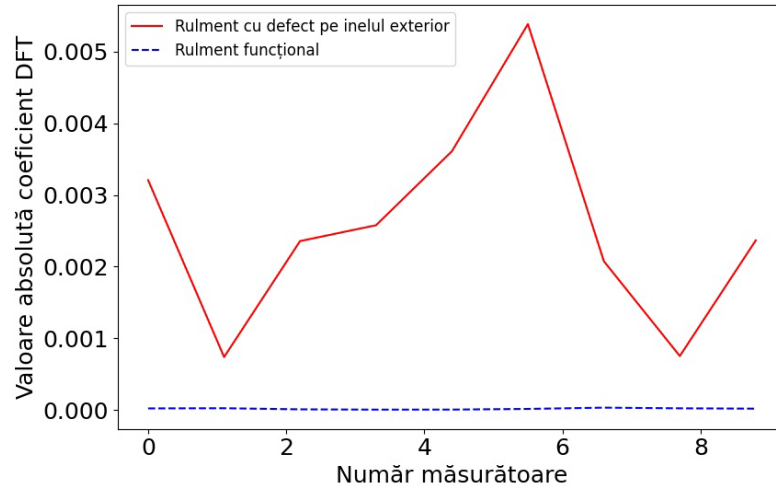


Figura 7.17: Comparație între valorile absolute a coeficienților DFT pentru un rulment funcțional cu un rulment cu defect pe inelul exterior

În figurile 7.16 și 7.17 se observă diferențele clare între amplitudinile extrase folosind algoritmul Goertzel pentru cele două tipuri de defecte.

7.2.2 Diagnosticarea defectelor din rulmenți folosind testul statistic Kolmogorov-Smirnov

Folosind algoritmul descris la subcapitolul 6.1.4.1 se pot depista eventuale defecte apărute în rulmenți, extrăgând caracteristici din semnalul de vibrații achiziționat și comparându-le cu distribuțiile deja existente pentru aceste caracteristici. Caracteristicile pot fi extrase prin algoritmul Goertzel, de interes fiind doar amplitudinea frecvențelor de defect.

De exemplu, distribuțiile din figurile 7.16 și 7.17 sunt evident diferite. În următoarele figuri sunt prezentate funcțiile de distribuție cumulativă empirică (ECDF) ale acestor date:




Figura 7.18: Comparație între ECDF pentru un rulment funcțional cu un rulment cu defect pe inelul interior

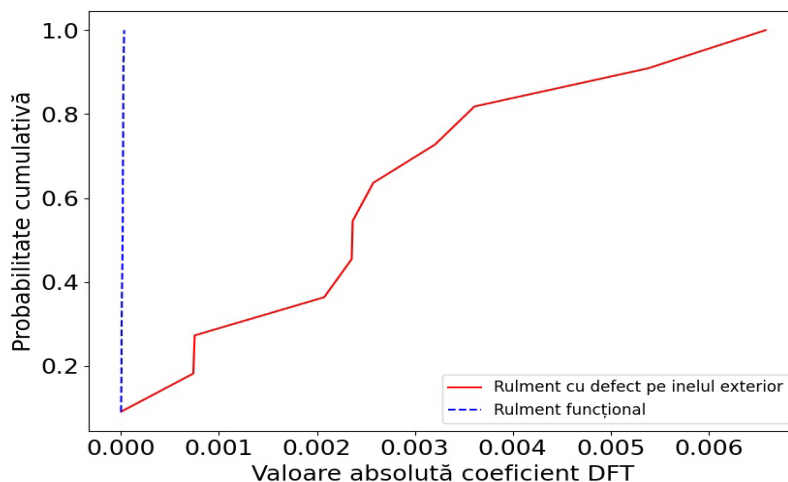


Figura 7.19: Comparație între ECDF pentru un rulment funcțional cu un rulment cu defect pe inelul exterior

Dacă aceste date sunt folosite pentru aplicarea testului KS (Kolmogorov-Smirnov), defectele sunt identificate cu următoarele probabilități (luând în considerare un număr de 10 măsurători):

Tabel 7.3: Probabilitățile de defect pentru rulmenții cu defect pe inelul exterior și interior

P_{ext}	P_{int}
100%	100%

unde P_{ext} este probabilitatea de defect pentru rulmentul cu defect pe inelul exterior și P_{int} este probabilitatea de defect pentru rulmentul cu defect pe inelul interior.

7.2.3 Rezultate obținute prin aplicarea criteriului de încetare a descompunerii empirice în moduri

Spre deosebire de procesarea prin pachete Wavelet, procesarea prin HHT poate consuma mult mai multe resurse de calcul și timp din cauza modului de extragere a funcțiilor proprii. Acești timpi pot fi mult micșorați prin aplicarea algoritmului prezentat în subcapitolul 6.1.2.2.

Aplicând acest criteriu au fost obținute următoarele rezultate:




Figura 7.20: Spectrul funcției proprii la care descompunerea a luat sfârșit pentru un rulment cu defect pe inelul interior

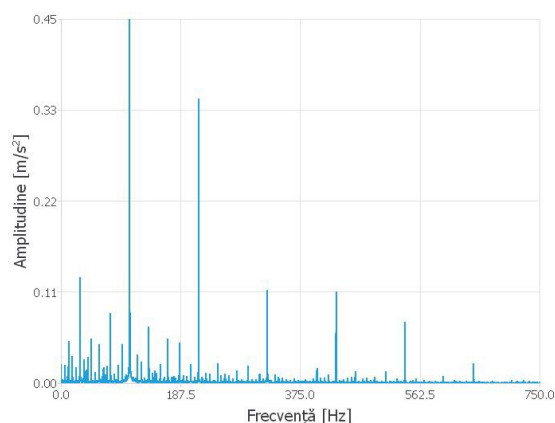


Figura 7.21: Spectrul funcției proprii la care descompunerea a luat sfârșit pentru un rulment cu defect pe inelul exterior

Se poate observa din figurile 7.20 și 7.21 că algoritmul se oprește la funcția proprie corectă, depistând defectul corespunzător frecvențelor monitorizate.

Ca timpuri de execuție s-au obținut următoarele rezultate:

Tabelul 7.4: Timp de execuție pentru EMD pentru un semnal de 10 s

Componentă cu defect	Timp de execuție pentru EMD fără algoritmul de optimizare [s]	Timp de execuție pentru EMD cu algoritmul de optimizare [s]
Inel interior	64.1	5.2
Bilă	12.9	1.1
Inel exterior	81.1	31.6

Tabelul 7.5: Timp de execuție pentru EMD pentru un semnal de 1 s

Componentă cu defect	Timp de execuție pentru EMD fără algoritmul de optimizare [s]	Timp de execuție pentru EMD cu algoritmul de optimizare [s]
Inel interior	0.7	0.1
Bilă	0.2	0.07
Inel exterior	2.9	2.7

7.3 Testarea algoritmului de detecție pe un model matematic al vibrațiilor torsionale ale unui reductor cu roți dințate

Anumite defecte pot fi detectate doar prin vibrațiile torsionale, dar câteodată aceste semnale sunt dificil de achiziționat de la un sistem real. Existența unui model matematic care poate simula astfel de vibrații este importantă pentru testarea și implementarea unui sistem de diagnosticare. Modelul descris, în continuare, este subiectul articolului [30], publicat de autor în *Lecture Notes Network Systems, vol.143, 2020*.

7.3.1 Modelul unui angrenaj

În cadrul lucrării de doctorat a fost publicat un articol prin care se poate construi un model pentru vibrațiile torsionale care provin de la un angrenaj. Pentru implementarea suportului matematic într-un mediu de simulare, s-a folosit programul 20-sim, ecuațiile fiind reprezentate prin utilizarea formalismului “Bond Graphs”. Folosind parametrii distribuți, un angrenaj format din două roți dințate identice poate fi reprezentat astfel:

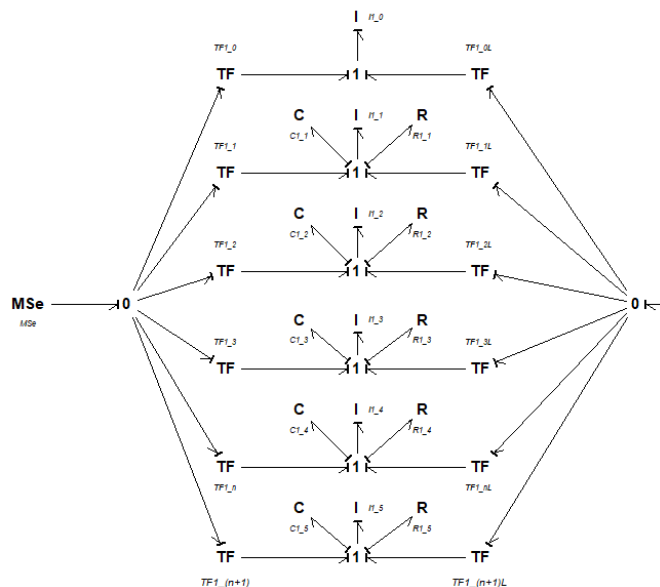


Figura 7.22: Graf Bond pentru roata conducătoare dintr-un angrenaj de roți dințate




Figura 7.23: Graf Bond pentru partea de angrenare dintr-un angrenaj de roți dințate

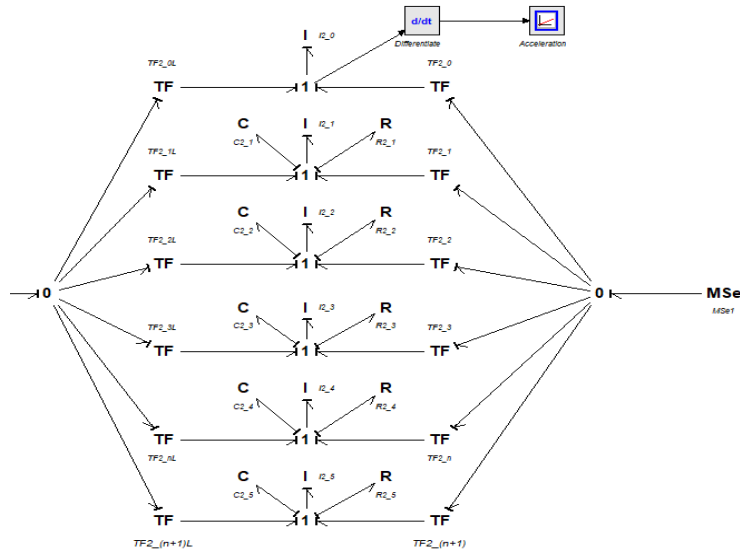


Figura 7.24: Graf Bond pentru roata condusă dintr-un angrenaj de roți dințate

7.3.2. Simularea vibrațiilor torsionale

Simularea a fost făcută folosind grafuri Bond și programul 20sim.

În modelul din figura 7.22 se poate observa existența unei surse modulate de flux care permite introducerea unei viteze adiționale în model pentru simularea unui defect. Viteza ar trebui să fie proporțională cu viteza de rotație a arborelui și cu mărimea defectului. Pentru a testa modelul de mai sus se folosește un angrenaj format din două roți dințate identice și arbori identici. În urma simulării cu și fără defect indus, accelerația unghiulară măsurată formează următoarele semnale:




Figura 7.25: Accelerația unghiulară a arborelui condus, pentru angrenajul fără defect




Figura 7.26: Accelerația unghiulară a arborelui condus, pentru angrenajul cu defect

Atunci când apar impacturi generate la fiecare rotație, generate cu pulsația de 85 rotații/s, echivalentă cu frecvența de 13,53 Hz, acestea sunt vizibile clar în graficul semnalului, oferind posibilitatea detectării defectului. Astfel, în figurile 7.27 și 7.28 au fost descompuse aceste semnale prin pachete Wavelet și au fost analizate nodurile cu energie maximă.




Figura 7.27: Semnalul din nodul cu energia maximă obținut în urma prelucrării prin pachete Wavelet pentru angrenajul fără defect

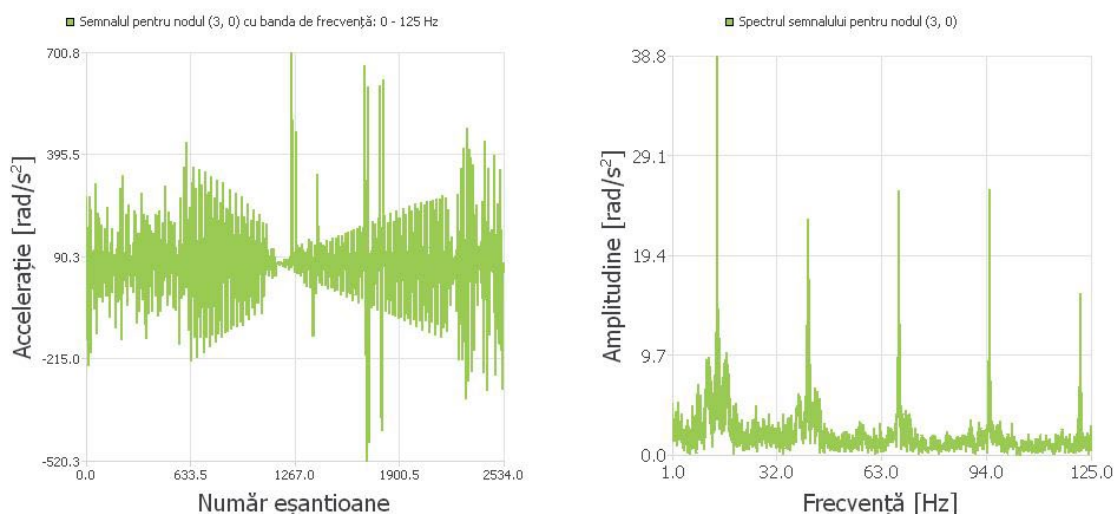


Figura 7.28: Semnalul din nodul cu energia maximă obținut în urma prelucrării prin pachete Wavelet pentru angrenajul cu defect

Se observă (figura 7.28) că, spre deosebire de semnalul descompus în același nod din figura 7.27, frecvența cu amplitudinea maximă care domină semnalul este la 13,5 Hz, fiind aceeași frecvență cu care impactul dat de un posibil defect este introdus în sistem.

7.3.3. Diagnosticarea defectelor din reductoare folosind testul statistic Kolmogorov-Smirnov

Algoritmul prezentat în 7.2.1 și 7.2.2 a fost aplicat pe semnalele din figurile 7.27 și 7.28, a depistat defectul și a evidențiat faptul că acest algoritm poate fi aplicat pe orice defect a cărui frecvență de defect poate fi calculată.

Distribuția valorilor absolute ale coeficienților DFT este prezentată mai jos:

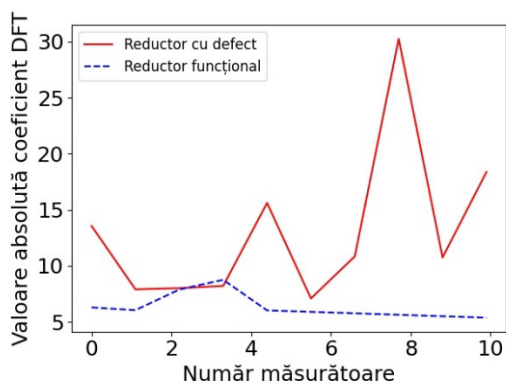


Figura 7.29: Comparație între valorile absolute ale coeficienților DFT pentru un reductor funcțional cu cele ale unui reductor cu defect în angrenaj

Defectul a fost identificat cu o acuratețe de 100%. Trebuie menționat că acest algoritm trebuie testat pe multe alte seturi de date pentru a obține o acuratețe statistică semnificativă.

7.4 Testarea sistemului de detecție pe un sistem mecatronic de poziționare, cu mișcare de translație

Pentru a testa algoritmele propuse pe un sistem complex, s-au achiziționat date de la un sistem mecatronic. Pe baza acestor date au fost testate algoritmele prezentate anterior și au fost propuse noi abordări inteligente pentru diagnoza defectelor complexe.

Accelerometrele au fost montate pe o axă de translație a unui sistem cartezian astfel:




Figura 7.30: Amplasarea primului accelerometru pe carcasa motorului care pune în mișcare sistemul pe axa de translație monitorizată




Figura 7.31: Amplasarea celui de-al doilea accelerometru pe efector în direcția de mișcare dată prin acționarea motorului

Ca placă de achiziție a fost folosită NI 9234 de la National Instruments:



Figura 7.32: Placă de achiziție NI 9234

Pentru achiziția vibrațiilor s-a folosit programul oferit de National Instruments, LabView.

În următoarele figuri sunt prezentate datele achiziționate în timpul mișcării pentru o durată de 60 de secunde și prelucrarea datelor prin pachete Wavelet pentru obținerea scalogramelor:

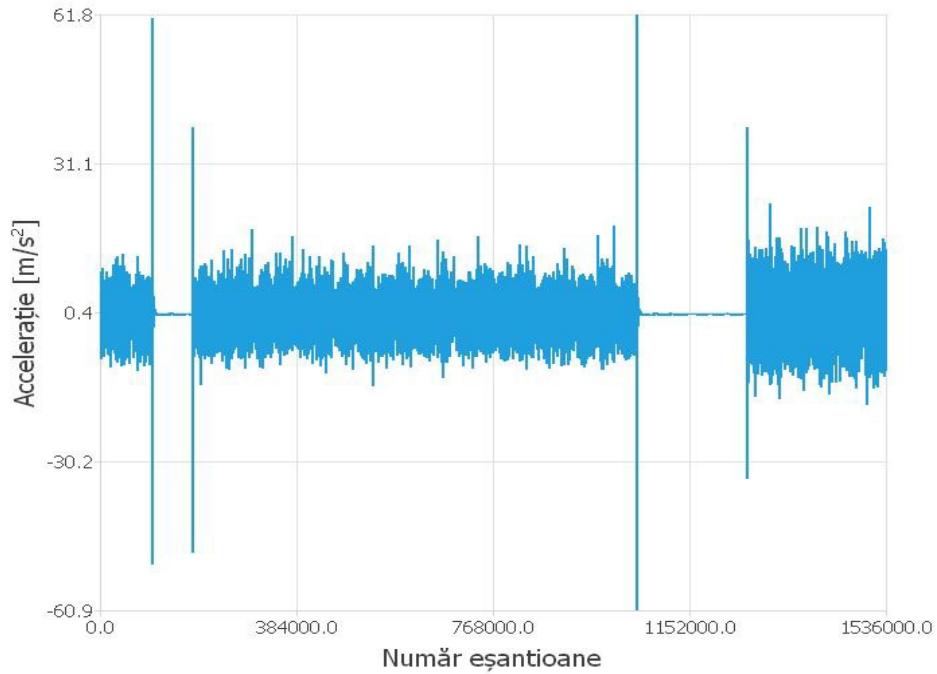


Figura 7.33: Semnal actuator




Figura 7.34: Semnal efector

Din figurile 7.33 și 7.34 se observă o corelație între cele două semnale, astfel încât comportamentul diferit al vibrațiilor la nivelul motorului afectează vibrația de la nivelul efectorului (vitezele se schimbă, sensul de mișcare se modifică). În concluzie, între cele două semnale se poate stabili o legătură dată de sistemul cinematic, acesta putând fi considerat un operator de transformare între cele două semnale. ***Pentru obținerea graficelor a fost folosită aplicația descrisă în 6.2. Este important de evidențiat utilitatea programului dezvoltat prin ușurința cu care diferite semnale pot fi analizate folosind diferite algoritme de procesare a datelor, oferind o privire de ansamblu asupra unor potențiale achiziții de date.***

CAPITOLUL 8 CONCLUZII ȘI ÎMBUNĂTĂȚIRI ULTERIOARE

8.1 Îndeplinirea obiectivelor tezei

Teza are ca scop dezvoltarea unui sistem robust de diagnoză a defectelor care pot apărea într-un sistem mecatronic. Sistemul de monitorizare poate asigura adaptarea funcționării mașinii astfel încât aceasta să poată fi într-un regim de toleranță la defect. Reamintind obiectivele propuse în introducere, se poate afirma că acestea au fost îndeplinite în totalitate:

- I. *„S-a realizat cercetarea literaturii de specialitate și expunerea stadiului actual al realizărilor, pentru identificarea oportunităților de îmbunătățire a algoritmilor curente de detecție a defectelor sistemelor tehnice, pe baza comportării vibratorii”, care demonstrează adaptarea și îmbunătățirea metodelor existente pentru a obține un sistem robust de diagnostic (capitolul 3)*
- II. *„S-au identificat potențiale defecte din componentele sistemelor mecatronice și posibilitatea diagnosticării pe bază de vibrații”, lucru ce a ajutat la identificarea anumitor algoritme potrivite de diagnostic al defectelor care pot fi folosite în monitorizarea a cât mai multe componente din sistemul mecatronic (capitolul 2)*
- III. *„Au fost extrase caracteristici esențiale din comportarea vibratorie a componentelor mobile ale sistemului, prin achiziția semnalelor de accelerație de la componentele monitorizate și analiza lor prin algoritme de învățare automată”. Caracteristicile oferă informații importante despre starea sistemului și pot fi ușor analizate de algoritme statistice sau de învățare automată. În capitolul 4 sunt prezentate metodele de achiziție a semnalelor de accelerație precum și diferite algoritme de procesare a acestora în vederea obținerii informațiilor de interes, intrinseci sistemului.*
- IV. *„A fost dezvoltat și implementat un algoritm robust de diagnoză pentru diferite frecvențe de defect, care să poată fi aplicat la mai multe componente”. În capitolul 6 sunt prezentate diferite algoritme dezvoltate și implementate pentru analiza semnalelor provenite de la diferite componente care au frecvențe de defect cunoscute și pe baza cărora sistemul poate fi monitorizat. Rezultatele aplicării acestor algoritme pe diferite componente sunt prezentate în capitolul 7.*

V. „A fost dezvoltat și implementat un algoritm de monitorizare și mentenanță predictivă pentru un sistem mecatronic format din subsistem de acționare, subsistem de transmisie a puterii și subsistem acționat (efector)”, algoritm de monitorizare care îmbină tehnicile de procesare a semnalului cu algoritme de inteligență artificială specifice (capitolul 5) pentru detectarea și identificare atât a defectelor cu o comportare vibratorie cunoscută cât și necunoscută (prin clasificarea ulterioară pe baza informațiilor de la operatori). În capitolul 6 este prezentată o aplicație construită atât pentru acest scop cât și pentru procesarea avansată a semnalelor de accelerație pentru a obține caracteristici folositoare. Sistemul mecatronic complex este caracterizat dinamic folosind doar 2 accelerometru atașate subsistemului de acționare și efectorului. Folosind modele bazate pe date și corelații de semnale, sistemul de transmisie a puterii este de asemenea monitorizat, subsistemul de achiziție de date fiind unul ieftin și neintrusiv.

8.2. Contribuții personale

Cercetarea și realizarea tezei a durat 4 ani, dintre care 2 ani au fost în timpul pandemiei lucru care a afectat posibilitatea testării extensive a sistemului de diagnosticarea pe sisteme reale. Cu toate acestea, s-au folosit diferite resurse disponibile în mediul virtual pentru a cerceta și testa diferiți algoritmi pe diferite componente mecanice și unde acest lucru nu a fost posibil, a fost creat un model matematic pentru obținerea datelor prin simulări.

La un sistem de diagnoză robust care are ca scop diagnosticarea a cât mai multe defecte dintr-un sistem mecatronic doar prin semnale de vibrații, lucrează de obicei o echipă interdisciplinară care să asigure atât corectitudinea matematică în raport cu semnalele achiziționate și cu caracteristicile defectelor cunoscute, cât și implementarea programelor necesare pentru un astfel de sistem de diagnoză.

Astfel, în decursul cercetării și dezvoltării tezei au fost aduse următoarele contribuții prin metode dintre care unele, la momentul publicării (din cunoștințele autorului), nu mai fuseseră abordate.

Principalele contribuții ale tezei pot fi considerate următoarele:

- Folosirea algoritmului Goertzel pentru extragerea coeficienților transformatei Fourier discrete pentru frecvențele de defect pentru rulmenți și reductoare – algoritmul Goertzel este superior ca eficiență și timp de execuție față de transformata Fourier atunci când un număr mic de frecvențe trebuie monitorizat. Astfel, folosind acest algoritm au fost extrase caracteristici care modelează comportamentul dinamic al rulmenților
- Dezvoltarea unui algoritm statistic inteligent, prin folosirea testului Kolmogorov-Smirnov, pentru detectarea defectelor din distribuțiile caracteristicilor extrase

pentru defecte apărute în rulmenți și reductoare – o metodă inteligentă de a “învăța” modelul dinamic al rulmenților/reductoarelor dat de caracteristicile extrase din semnalele de vibrații

- *Modelarea și simularea vibrațiilor torsionale într-un reductor folosind parametri distribuiți și grafuri Bond* – vibrațiile torsionale sunt mai greu de achiziționat în realitate, însă printr-un model dinamic folosind parametri distribuiți și grafuri Bond, semnalele de vibrații au fost simulate și datele au fost folosite la testarea algoritmilor de diagnoză
- Dezvoltarea și antrenarea unei rețele neuronale pentru modelarea lanțului cinematic dintre actuator și manipulator, folosind caracteristici extrase din datele achiziționate de accelerometre de la nivelul actuatorului și manipulatorului – modelarea unui astfel de sistem non-liniar prezintă o provocare și de multe reprezentările analitice sunt departe de comportamentul dinamic al sistemului real. Astfel, obținerea unui model dinamic ne-liniar pe bază de date este robust, permițând captarea tuturor fenomenelor care apar, specifice sistemului sub observație
- Dezvoltarea unui criteriu inteligent de încetare a descompunerii empirice în moduri pentru diagnoză a defectelor cu frecvență specifică – aceste algoritmi de prelucrare a semnalului este foarte robust, descompunerea unui semnal fiind făcută în moduri caracteristice semnalului. Cu toate acestea, pentru diagnosticarea unui defect, o dată acesta identificat, descompunerea nu își mai are rostul
- Dezvoltarea unui sistem robust de diagnoză pentru un sistem mecatronic uni-axial care permite diagnoza defectelor cunoscute cât și înregistrarea defectelor noi și învățarea lor folosind algoritmi de învățare automată supervizați și nesupervizați – diagnoza defectelor este importantă pentru fiabilitatea unui sistem în timp și pentru a evita timpii morți de producție. Folosirea unui sistem de diagnoză poate fi câteodată imposibilă datorită costului ridicat sau a faptului că acest sistem este invaziv. Dezvoltarea și implementarea unui sistem de diagnoză non-invaziv și inteligent bazat doar pe 2 senzori poate reprezenta un avantaj major în industrie pentru oricine folosește un sistem mecatronic care presupune actuatori și efectori (roboți, mecanisme de imprimare, etc).
- Dezvoltarea unui program de diagnoză care permite vizualizarea și prelucrarea datelor achiziționate cât și antrenarea sistemului de diagnoză – un program de vizualizare și prelucrare a datelor achiziționate de la 1 sau 2 accelerometre prin metode de prelucrare a semnalului cum ar fi transformata Wavelet sau descompunerea empirică în moduri și antrenarea algoritmului de diagnoză folosind aceste date (programul a fost scris în Python folosind QtPython pentru interfață)

- Compararea diferitelor metode de prelucrare a semnalului de vibrații pentru extragerea unor caracteristici relevante pentru diagnoza defectelor mecanice – există numeroase metode de prelucrare a semnalului pentru diagnoză, însă este nevoie de extragerea celor mai relevante date pentru obținerea unor caracteristici care pot fi folosite în algoritmi de inteligență artificială
- Efectuarea unei comparații între semnalele date de accelerație, viteză și deplasare pentru carcasa unui rulment, ajungând la concluzia că cel mai indicat mod de a monitoriza un sistem prin carcasa sa este prin intermediul accelerometrelor și a semnalelor oferite de accelerație, mărime fizică care oferă cea mai bună caracteristică vibratorie a sistemului

8.3. Îmbunătățiri ulterioare

Sistemul de monitorizare dezvoltat trebuie testat pe cât mai multe sisteme mecatronice complexe. Această teză oferă o soluție inițială pentru monitorizarea unei singure axe a unui robot cartezian de exemplu, axă care poate fi considerată un sistem mecatronic. În momentul în care apar mai multe axe care lucrează în comun, există nevoia de mai multe informații despre sistem și un algoritm de monitorizare care să fuzioneze datele achiziționate de la senzori. Rezumând, în continuare ar trebui abordate următoarele probleme:

- Testarea algoritmului de diagnoză pe un sistem mecatronic complex cu cât mai multe defecte prezente
- Extinderea algoritmului pentru un sistem de axe (fiecare axă fiind considerată un sistem monitorizat)
- Achiziția de date poate fi făcută fără o placă de achiziție dedicată, în locul acesteia fiind folosit un microcontroler Raspberry Pi

Bibliografie selectivă

- [1] M. P. Brennan, „ECONOMIC IMPACT FAILURE MODE AND EFFECTS ANALYSIS”, 2017.
- [2] T. J. Mănescu, „Defecte semnalate la lagărele de rostogolire în timpul exploatării”, în *A XVI-a Conferință internațională - multidisciplinară „Profesorul Dorin PAVEL - fondatorul hidroenergeticii românești”*, 2016, pp. 611-620.
- [3] Timken, „Analiza defectelor rulmenților”, p. 7352, 2019.
- [4] N. G. Nikolaou și I. A. Antoniadis, „Rolling element bearing fault diagnosis using wavelet packets”, *NDT E Int.*, vol. 35, nr. 3, pp. 197-205, 2002.
- [5] „Probleme tipice ale cureleor si motivul aparitiei acestora - Manual | Pasy klinowe - Harvest Belts”. [Online]. Valabil la: <http://www.harvestbelts.biz/ro/manual/probleme-tipice-ale-cureleor-si-motivul-aparitiei-acestora/>. [Data accesării: 01-iul-2021].
- [6] „Drive-Belt-Analysis-Poster_Page_01.png (2550×3394)”. [Online]. Valabil la:

- https://blog.woodscyclecountry.com/wp-content/uploads/2013/08/Drive-Belt-Analysis-Poster_Page_01.png. [Data accesării: 01-iul-2021].
- [7] Z. Korca, „Fiabilitatea angrenajelor”. [Online]. Valabil la: <https://www.ttonline.ro/revista/transmisii-mecanice/fiabilitatea-angrenajelor>. [Data accesării: 01-iul-2021].
- [8] A. Mouzakis, „Classification of fault diagnosis methods for control systems”, *Meas. Control (United Kingdom)*, 2013.
- [9] SKF, „SKF Reliability Systems ® Vibration Diagnostic Guide CM5003”, 2018.
- [10] „Vibration Pen, Shock Pulse Measurement (SPM), & Vibration Analysis - What’s the Difference? - Maintenance WorldMaintenance World – An article source for reliability and maintenance management professionals”. [Online]. Valabil la: <http://www.maintenanceworld.com/vibration-pen-shock-pulse-measurement-spm-vibration-analysis-whats-the-difference/>. [Data accesării: 26-iun-2021].
- [11] S. Hanly, „What’s the Difference Between Vibration Sensors?”, 2016. [Online]. Valabil la: <https://www.machinedesign.com/motion-control/what-s-difference-between-vibration-sensors>. [Data accesării: 03-nov-2018].
- [12] S. A. A. Rizvi, S. Sunder, F. Haroon, și A. Mirza, „Virtual instrumentation for control applications”, în *Communications in Computer and Information Science*, 2012.
- [13] Ž. Obrenovic, D. Starcevic, și E. Jovanov, „Virtual Instrumentation”.
- [14] „(No Title)”. [Online]. Valabil la: http://www.comm.pub.ro/psc/curs/PSC_cap_7.pdf. [Data accesării: 04-iul-2021].
- [15] „(No Title)”. [Online]. Valabil la: http://www.ee.ic.ac.uk/hp/staff/dmb/courses/E1Fourier/00700_TransformParseval.pdf. [Data accesării: 04-iul-2021].
- [16] D. Cordoneanu și C. Nițu, „An Approach of Extracting Features for Fault Diagnosis in Bearings Using the Goertzel Algorithm”, în *Lecture Notes in Networks and Systems*, 2020.
- [17] P. Sysel și P. Rajmic, „Goertzel algorithm generalized to non-integer multiples of fundamental frequency”, *EURASIP J. Adv. Signal Process.*, vol. 2012, nr. 1, p. 56, mar. 2012.
- [18] Y. Lei, *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. Elsevier Inc., 2016.
- [19] N. E. Huang *et al.*, „The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis”, *Proc. R. Soc. A Math. Phys. Eng. Sci.*, vol. 454, nr. 1971, pp. 903-995, 1998.
- [20] Wikipedia, „Artificial Intelligence”. [Online]. Valabil la: https://en.wikipedia.org/wiki/Artificial_intelligence#Tools. [Data accesării: 30-iun-2019].
- [21] C.-W. Chang, H.-W. Lee, și C.-H. Liu, „A Review of Artificial Intelligence Algorithms Used for Smart Machine Tools”, *Inventions*, 2018.
- [22] F. T. Liu, K. M. Ting, și Z. H. Zhou, „Isolation forest”, în *Proceedings - IEEE*

International Conference on Data Mining, ICDM, 2008.

- [23] G. R. Lee, R. Gommers, F. Waselewski, K. Wohlfahrt, și A. O’Leary, „PyWavelets: A Python package for wavelet analysis”, *J. Open Source Softw.*, vol. 4, nr. 36, p. 1237, apr. 2019.
- [24] D. Laszuk, „Python implementation of Empirical Mode Decomposition algorithm”. GitHub, 2017.
- [25] D. Cordoneanu, „An approach on predicting a machine’s effector vibrations based on motor vibrations using a regression artificial neural network”, *Lect. Notes Networks Syst.*, vol. 143, pp. 113-122, 2020.
- [26] D. Cordoneanu, „Bearing fault diagnosis using the Kolmogorov-Smirnov test on frequency features extracted using the Goertzel algorithm”.
- [27] P. Virtanen *et al.*, „SciPy 1.0: fundamental algorithms for scientific computing in Python”, *Nat. Methods* 2020 173, vol. 17, nr. 3, pp. 261-272, feb. 2020.
- [28] F. Pedregosa *et al.*, „Scikit-learn: Machine Learning in Python”, *J. Mach. Learn. Res.*, vol. 12, nr. 85, pp. 2825-2830, 2011.
- [29] „Bearing Data Center”. [Online]. Valabil la: <http://csegroups.case.edu/bearingdatacenter/home>. [Data accesării: 02-iun-2019].
- [30] D. Cordoneanu și C. Nițu, „Mathematical modeling of torsional vibrations in a gearbox with faults using distributed parameters and bond graphs”, *Lect. Notes Networks Syst.*, vol. 143, pp. 100-112, 2020.