



## PLATFORMĂ DE MENTENANȚĂ ÎN INDUSTRIA 4.0

- *Abstract* -

Doctorand  
Georgescu (Deac) Crina Narcisa

Coordonator științific  
Prof. dr. ing. Costel Emil COTEȚ

## Cuprins

### CAPITOLUL 1. INTRODUCERE GENERALĂ

.....**Eroare! Marcaj în document nedefinit.**

1.1. Prezentarea domeniului tezei de doctorat. Motivația temei de cercetare**Eroare! Marcaj în document nedefinit.**

1.2. Obiectivele tezei de doctorat .....**Eroare! Marcaj în document nedefinit.**

1.3. Structura tezei de doctorat.....**Eroare! Marcaj în document nedefinit.**

### CAPITOLUL 2. SISTEMELE CYBER-FIZICE (CPS) ȘI UTILIZAREA LOR ÎN

MANAGEMENTUL MENTENANȚEI .....**Eroare! Marcaj în document nedefinit.**

2.1. Introducere .....**Eroare! Marcaj în document nedefinit.**

2.2. Industria 4.0. Fabrica inteligentă.....**Eroare! Marcaj în document nedefinit.**

2.3. Integrarea verticală. Integrarea orizontală prin intermediul rețelelor. Integrarea digitală de la un capăt la altul pe tot lanțul.....**Eroare! Marcaj în document nedefinit.**

2.4. Utilizarea sistemelor cyber-fizice (CPS) în managementul mentenanței în contextul Industriei 4.0.....**Eroare! Marcaj în document nedefinit.**

2.4.1. Arhitectura 5C a sistemelor cyber-fizice..**Eroare! Marcaj în document nedefinit.**

2.4.2. Arhitectura 7C a sistemului cyber-fizic-social și evoluția acestuia **Eroare! Marcaj în document nedefinit.**

2.4.3. Modelul D-CPSS.....**Eroare! Marcaj în document nedefinit.**

2.5. Mentenanța .....**Eroare! Marcaj în document nedefinit.**

2.5.1. Evoluția conceptului de mentenanță .....**Eroare! Marcaj în document nedefinit.**

2.5.2. Comparatie între conceptele de mentenanță existente .....**Eroare! Marcaj în document nedefinit.**

2.6. Concluzii .....**Eroare! Marcaj în document nedefinit.**

### CAPITOLUL 3. DETECTAREA ANOMALIEI. ALGORITMI DE DIAGNOSTICARE A

DEFECȚIUNILOR. ALGORITMI DE PROGNOZĂ ÎN MONITORIZAREA STĂRII

ECHIPAMENTELOR ȘI ESTIMAREA TIMPULUI UTIL RĂMAS DE FUNCȚIONARE

.....**Eroare! Marcaj în document nedefinit.**

3.1. Introducere .....**Eroare! Marcaj în document nedefinit.**

3.2. Detectarea anomaliei prin analiză statistică multivariată.**Eroare! Marcaj în document nedefinit.**

3.2.1. Detectarea anomaliei folosind modelul distribuției gaussiene....**Eroare! Marcaj în document nedefinit.**

3.2.2. Detectarea anomaliei folosind distribuția gaussiană multivariată **Eroare! Marcaj în document nedefinit.**

3.2.3. Detectarea anomaliei prin reducerea dimensionalității, utilizând analiza componentelor principale (PCA). .....**Eroare! Marcaj în document nedefinit.**

3.3. Detectarea anomaliei în seriile de timp folosind rețele neuronale artificiale cu învățare supravegheată și nesupravegheată.....**Eroare! Marcaj în document nedefinit.**

3.3.1. Detectarea anomaliei folosind rețele neuronale artificiale feedforward de tip Autoencoder în învățarea nesupravegheată.....**Eroare! Marcaj în document nedefinit.**

3.3.2. Detectarea anomaliei prin clasificare folosind rețele neuronale feedforward cu învățare supravegheată .....**Eroare! Marcaj în document nedefinit.**

3.4. Diagnosticarea defecțiilor .....**Eroare! Marcaj în document nedefinit.**

3.4.1. Diagnosticarea bazată pe model .....	<b>Eroare! Marcaj în document nedefinit.</b>
3.4.2. Diagnosticarea bazată pe date. Tehnici de clasificare utilizând algoritmi de Machine Learning și Deep Learning. ....	<b>Eroare! Marcaj în document nedefinit.</b>
3.5. Prognosticul defectelor și a vieții utile rămase a componentelor/echipamentelor. ....	<b>Eroare! Marcaj în document nedefinit.</b>
3.5.1. Predictibilitatea vieții utile rămase (Remaining Useful Life PDF) .	<b>Eroare! Marcaj în document nedefinit.</b>
3.5.2. Tehnici de prognoză .....	<b>Eroare! Marcaj în document nedefinit.</b>
3.6. Concluzii .....	<b>Eroare! Marcaj în document nedefinit.</b>
<b>CAPITOLUL 4. PLATFORME DE MENTENANȚĂ ȘI ANALIZĂ PREDICTIVĂ.....</b>	<b>100</b>
4.1. Introducere .....	100
4.2. Dataiku .....	100
4.3. RapidMiner.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.4. Aplicațiile IBM Maximo .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.4.1. IBM Maximo Predict .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.4.2. IBM Maximo Monitor.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.4.3. IBM Maximo Visual Inspection.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.4.4. IBM Maximo Health .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.5. HP Haven Predictive Analytics.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.6. Microsoft Azure Machine Learning .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.7. H2O.ai .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.8. DataRobot.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.9. SAP HANA XSA & Predictive Maintenance and Services SDK.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.10. Siemens MindSphere.....	<b>Eroare! Marcaj în document nedefinit.</b>
4.11. GE Predix .....	<b>Eroare! Marcaj în document nedefinit.</b>
4.12. Concluzii .....	<b>Eroare! Marcaj în document nedefinit.</b>
<b>CAPITOLUL 5. PLATFORMA DE MENTENANȚĂ IOTIA - CMMS PENTRU MANAGEMENTUL MENTENANȚEI ÎN INDUSTRIA 4.0. ..</b>	<b>Eroare! Marcaj în document nedefinit.</b>
5.1. Introducere .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2. Conceptul platformei.....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.1. Dashboard.....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.2. Modulul Configurator .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.3. Modulul Administrare .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.4. Modulul Mentenanță Preventivă .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.5. Aplicația mobilă pentru mentenanță cu tehnologie AR .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.6. Modulul Monitorizare .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.2.7. Modulul Mentenanță Predictivă .....	<b>Eroare! Marcaj în document nedefinit.</b>
5.3. Concluzii .....	<b>Eroare! Marcaj în document nedefinit.</b>
<b>CAPITOLUL 6. CONCLUZII, CONTRIBUTII ȘI PERSPECTIVE .....</b>	<b>Eroare! Marcaj în document nedefinit.</b>
6.1. Concluzii generale.....	<b>Eroare! Marcaj în document nedefinit.</b>

6.2. Contribuții originale .....	29
6.3. Perspective de dezvoltare ulterioară.....	34
6.4. Lucrări științifice publicate .....	<b>Eroare! Marcaj în document nedefinit.</b>
BIBLIOGRAFIE .....	201

## Rezumat

Ca urmare a noii revoluții industriale (Industry 4.0), ne regăsim într-o perioadă caracterizată de automatizarea, digitizarea și interconectarea componentelor din procesele de producție și integrarea acestora în sisteme cyber-fizice (CPS) capabile să gestioneze producția într-un mod flexibil, eficient și ecologic. Aceste sisteme asigură totodată suport pentru strategii de mentenanță avansate, oferind informații în timp real și capacitate de predicție pentru gestionarea activelor. Configurarea soluțiilor predictive depinde de cazul studiat și echipamentele folosite și presupune o perfecționare continuă a acestora în funcție de răspunsul din practică într-un interval de timp. Predicția datelor în mentenanța predictivă, prin Machine Learning (ML) și Deep Learning (DL), aparține domeniului “data science”, este într-o continuă evoluție și cercetare și necesită, în aceeași măsură, o formare continuă de specialiști în studiul datelor.

În momentul actual sunt prea puțini specialiști în “data-science”, pregătiți în analiză statistică și predicția datelor, în special în domeniul industrial. Activitatea acestora trebuie să fie strâns corelată cu activitatea specialiștilor din domeniul industrial, informațiile colectate de analiști depinzând în mare măsură de colaborarea cu inginerii din industrie.

În ceea ce privește activitatea de mentenanță, în prezent, în România, o mare parte din întreprinderile industriale implementează cel mult mentenanța preventivă, fiind prea puțin aliniată cerințelor Industriei 4.0. Mentenanța predictivă reduce costurile de mentenanță și costurile de achiziție ale pieselor de schimb, îmbunătățind calitatea producției, însă necesită hardware și software specializat. Soluțiile actuale existente pe piață sunt încă extrem de scumpe, puține și provin de la marile companii multinaționale.

Prea puține companii stochează datele preluate de la mașini în cloud, pentru o gestionare ulterioară a acestora cu ajutorul unor instrumente software care să analizeze, raporteze, previzioneze sau să coordoneze activitatea de producție. Este necesară așadar dezvoltarea unor instrumente software CMMS (Computerized Maintenance Management System) pentru managementul mentenanței.

### Obiectivele tezei de doctorat

Pornind de la analiza contextului celei de-a patra revoluții industriale și a soluțiilor software existente pe piață pentru mentenanța aplicată cu ajutorul sistemelor CMMS, a dispozitivelor IIoT și a modelelor matematice predictive aplicate pe date de mari dimensiuni (Big Data), teza își propune să abordeze într-un context larg toate tipurile de mentenanță ce pot fi aplicate în cadrul acestor sisteme.

**Obiectivul principal** al acestei lucrări este realizarea unui sistem CMMS – o platformă de mentenanță – care se dorește a fi un instrument flexibil, modular, extensibil, astfel încât să poată gestiona toate tipurile de mentenanță din cadrul unei întreprinderi industriale: mentenanță corectivă, preventivă, mentenanță bazată pe monitorizarea stării, mentenanță predictivă, în funcție de strategiile de mentenanță ale companiei, în una sau mai multe locații de producție, într-un sistem multilingv. Platforma va permite totodată coordonarea cu celelalte departamente din companie, cum ar fi departamentul de achiziții, departamentul IT, departamentul de producție etc., astfel încât procesele de mentenanță și implicit procesele de producție să fie optimizate într-un sistem integrat. Acest obiectiv principal asumă dezvoltarea unui instrument software de e-mentenanță care să poată fi implementat atât în regim SaaS (Software as a Service) cât și On premise (aplicația software este instalată pe serverele companiei care o utilizează) și care să se adreseze tuturor întreprinderilor industriale care utilizează echipamente și linii de producție automatizate în activitatea de producție și prelucrare a materialelor.

Pentru atingerea acestui obiectiv principal a fost necesară abordarea unor **obiective secundare** ce includ o serie de analize teoretice și dezvoltări conceptuale după cum urmează::

- studiul arhitecturii sistemelor cyber-fizice pentru identificarea elementelor ce vor fi racordate la platformă
- studiul conceptelor de mentenanță aplicate în cadrul Industriei 4.0 și selectarea celor utile

- pentru funcționarea platformei;
- studiul tehnicilor de detectare a anomaliilor prin metode statistice și inteligență artificială și alegerea celor ce vor fi integrate în funcțiile platformei;
- identificarea tehnicilor de diagnosticare a defectelor în componente/echipamente și a metodelor de prognoză a eșecului prin algoritmi predictivi de Machine Learning și Deep Learning potrivite pentru soluția propusă;
- selectarea unor algoritmi privind predicția vieții utile rămase a echipamentelor adecvați pentru platforma concepută;
- studiul platformelor de analiză predictivă și mentenanță existente pe piață și evidențierea limitărilor acestora;

Din perspectiva concepției și dezvoltării efective a platformei propuse ca obiectiv principal, sunt de asemenea definite o serie de obiective secundare:

- implementarea unui sistem de monitorizare și stocare a datelor prin tehnologie IoT;
- implementarea unui sistem de asistență la distanță pentru tehnicienii de mentenanță;
- monitorizarea stării activelor și a cheltuielilor legate de intervențiile de mentenanță;
- implementarea unui configurator pentru echipamente / mașini
- implementarea unui configurator pentru operațiunile de mentenanță programate
- implementarea unui planificator pentru operațiunile de mentenanță programate
- implementarea unui sistem de ticketing între departamentele companiei
- implementarea unei biblioteci de modele ML și DL, construite și perfecționate în timp în funcție de cazurile din industrie
- implementarea unei biblioteci de instrucțiuni pentru tehnicienii de mentenanță, construit în timp, cu ajutorul sistemului CMMS;
- construirea unor biblioteci tehnice care să poată fi apelate cu ușurință de tehnicieni sau ingineri în operațiunile de mentenanță programate sau neprogramate.

## **Structura tezei de doctorat**

### **Teza de doctorat este structurată în 6 capitole:**

În Capitolul 1 sunt prezentate domeniul tezei, motivația temei de cercetare și obiectivele tezei de doctorat.

În Capitolul 2 sunt analizate structura și componentele unui sistem CPS necesare pentru concepția și dezvoltarea platformei pentru managementul mentenanței și identificate principalele tipuri de mentenanță ce ar trebui abordate în cadrul platformei.

Sunt abordate aspecte relevante referitoare la:

- conceptul fabricii inteligente și implementarea acesteia conform piramidei automatizării;
- evoluția sistemelor informaționale de mentenanță predictivă și producție inteligentă;
- sistemul cyber-fizic pentru managementul mentenanței în contextul Industriei 4.0, în arhitectura 5C (CPS), 7C (CPSS) și evoluția acestuia (D-CPSS);
- rezumatul istoricului celor patru generații de mentenanță și tehnicile lor;
- evoluția conceptului de mentenanță: mentenanță reactivă, preventivă, mentenanță bazată pe monitorizarea stării, mentenanță predictivă, mentenanță total productivă, mentenanță centrată pe fiabilitate, mentenanță realizată cu sistemele CMMS;
- introducerea conceptului de PHM (Prognostics and Health Management);
- comparația între conceptele de mentenanță prezentate.

În Capitolul 3 sunt cercetați o serie de algoritmi ce ar putea fi folosiți în platformă pentru managementul stării de funcționare și prognosticul echipamentelor și componentelor. Sunt prezentați o serie de algoritmi pentru:

- detectarea anomaliilor: prin analiză statistică multivariată, prin reducerea dimensionalității cu analiza PCA, folosind rețelele neuronale artificiale cu învățare supravegheată și nesupravegheată;
- diagnosticarea defectărilor bazată pe model folosind: metode bazate pe identificarea parametrilor, metode bazate pe ecuații de paritate, metode bazate pe observatori, metode

- bazate pe rețele neuronale pentru generare reziduală;
- diagnosticarea bazată pe date folosind tehnici de clasificare utilizând algoritmi de Machine Learning tradiționali: arbori de decizie, mașini cu suport vectorial, algoritmul k-Nearest Neighbor, rețele neuronale artificiale;
- diagnosticarea bazată pe date folosind tehnici de clasificare utilizând algoritmi de Deep Learning, precum autoencoderele, rețelele neuronale convoluționale CNN, rețelele neuronale recurente RNN, rețelele hibride;
- prognosticul defectelor și ale vieții utile rămase a componentelor/ echipamentelor (RUL);
- tehnici de prognoză – abordarea prognosticului bazată pe experiență prin: metode AI de Deep Learning, modele de supraviețuire, filtrare stocastică, metode de similaritate între traiectoriile de degradare;
- tehnici de prognoză – abordarea prognosticului bazată pe date prin: modele de degradare liniară și exponențială, metode AI de Deep Learning;
- tehnici de prognoză – abordarea prognosticului bazată pe model prin estimatori recursivi.

În Capitolul 4 sunt analizate câteva platforme de analiză predictivă și mentenanță existente pe piață: Dataiku, RapidMiner, Aplicațiile IBM, HP Haven Predictive Analytics, Microsoft Azure Machine Learning, H2O.ai, Data Robot, SAP HANA XSA, SAP Predictive Maintenance and Service, Siemens MindSphere, GE Predix. Acest studiu a fost realizat pentru identificarea stadiului actual și a posibilelor direcții de cercetare pentru dezvoltarea platformei IOTIA.

În Capitolul 5 este atins obiectivul principal al tezei prin prezentarea concepției și dezvoltării platformei. Acest capitol cuprinde:

- Introducere în sistemele CMMS, în care s-a prezentat contextul actual în ceea ce privește mentenanța și implementarea acestui instrument de e-mentenanță
- Conceptul platformei, în care sunt prezentate pe rând modulele platformei:

Interfața Dashboard, Modulul Configurator, Modulul de Administrare, Modulul de Mentenanță Preventivă, Aplicația mobilă pentru mentenanță utilizând tehnologia AR (și implementarea cu coduri QR), Modulul de Monitorizare, Modulul Predicției, în care s-au prezentat două studii de caz - predicția eșecului componentelor într-o fereastră de timp, folosind algoritmi de multclasificare (Random Forest, Gradient Boosting, XGBoost, Naïve Bayes, Neural Network) și diagnosticarea defectelor în rulmenți prin analiza vibrațiilor folosind abordarea Deep Learning (CNN, RNN, RNN CNN, LSTM CNN, LSTM)

În Capitolul 6 sunt prezentate concluziile finale care se desprind din aspectele teoretice și aplicative ce au concurat la dezvoltarea platformei propuse, sintetizându-se contribuțiile originale și menționându-se perspectivele de dezvoltare ulterioară. De asemenea, este trecut în revistă lista publicațiilor din perioada studiilor doctorale.

### **Platforma de Mentenanță IOTIA – CMMS pentru managementul mentenanței în industria 4.0**

Platforma IOTIA (Internet of Things Industrial & Automation) este un proiect pilot, scopul său este de a fi un instrument pentru gestionarea tuturor tipurilor de mentenanță și de a fi aplicat mai multor tipuri de producție din industrie. Platforma este scalabilă și poate fi configurată și în cazul unor companii care dețin mai multe fabrici.

Structura platformei este modulară (Fig.1) și permite:

- în secțiunea *Configurator*, definirea fabricilor, configurarea activelor (componente, subansambluri, mașini) și a operațiilor de mentenanță din Planificator, definirea erorilor în Glosarul de erori, definirea furnizorilor, consumabilelor și setarea vocabularului și limbilor.
- în secțiunea *Setări*, definirea personalului companiei, definirea conturilor de utilizator, setarea permisiunilor și rolurilor acestuia, configurarea sistemului de ticketing pentru asistență și alte setări generale.

- în secțiunea *Administrare*, instanțierea și administrarea liniilor de producție și a mașinilor asociate acestora, planificarea și programarea intervențiilor în Generatorul de Intervenții, definirea sesiunilor de instruire personal.

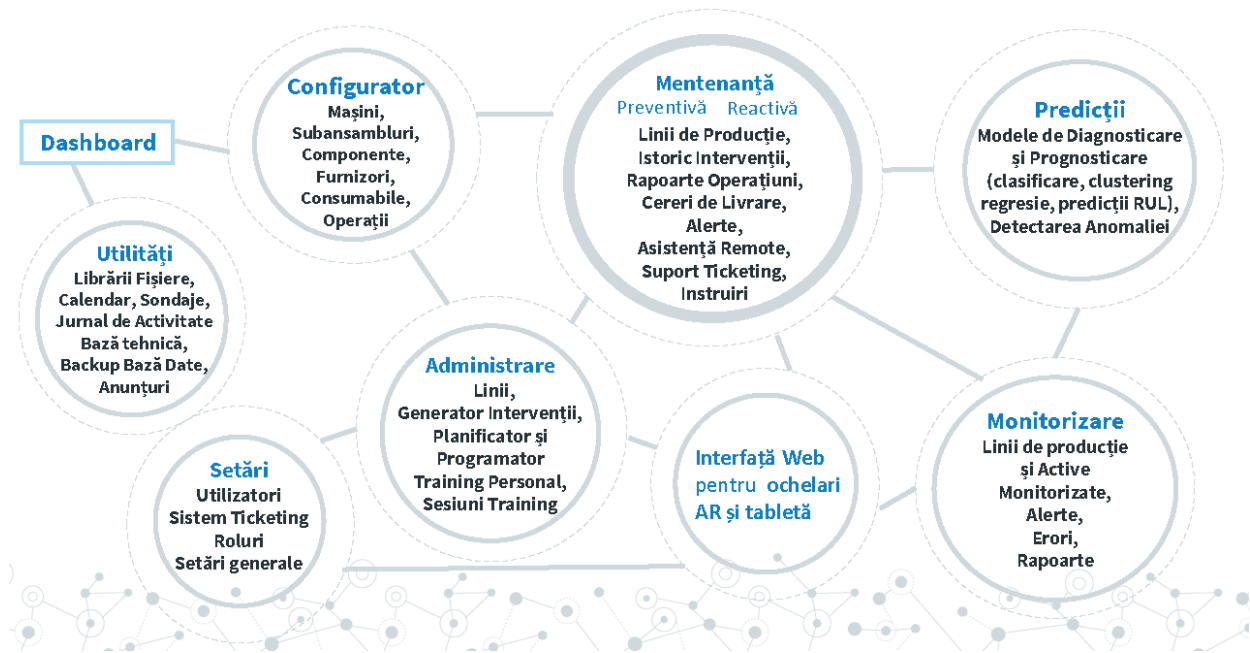


Fig. 1. Module în Platforma IOTIA

- în secțiunea *Mentenanță*, managementul intervențiilor și al operațiilor de mentenanță preventivă și reactivă. Secțiunea gestionează operațiunile de mentenanță pentru fiecare utilizator logat, cu rol de tehnician sau director de mentenanță, cererile de livrare componente sau consumabile, alertele, asistență de la distanță printr-un sistem de videoconferință, suportul de ticketing, rapoarte de instruire,

- în secțiunea *Interfață Web pentru ochelari AR și tabletă*, operarea intervențiilor de către tehnicienii de mentenanță aflați pe teren cu ajutorul aplicației AR pentru mentenanță, utilizând tehnologia de realitate augmentată și dispozitivele mobile,

- în secțiunea *Monitorizare*, monitorizarea activelor, subansamblelor și componentelor de pe liniile de producție,

- în secțiunea *Predicții*, implementarea modelelor predictive pentru detectarea defecțiunilor și prognosticare, utilizând algoritmi de clasificare, regresie sau algoritmi pentru detectarea anomaliiilor în vibrații; modelele sunt asociate activelor/componentelor monitorizate în cadrul platformei și sunt incluse în fișiere Jupyter Notebook,

- în secțiunea *Utilități*, definirea librăriilor de fișiere publice și private (definite de utilizatori), construirea bazei tehnice de documentație legată de siguranța sănătății în muncă, practicile de mediu standardizate, documentație tehnică privind realizarea operațiilor de mentenanță, jurnalul de activități zilnice al utilizatorilor din platformă, configurator de anunțuri și opțiuni pentru backupul bazei de date.

- în *Dashboard*, panoul de control cu navigare și vizualizare sumară a statisticilor operațiunilor de mentenanță și a activităților personalizate, în funcție de utilizatorul logat.

Platforma utilizează o abordare *Model-View-Controller* și este o platformă web-based.

## Dashboard

Panoul de control (*Dashboard*) este panoul introductiv care este configurat în funcție de utilizatorul conectat cu diverse roluri sau drepturi de acces: mai larg pentru administratori, director general, director IT, directori de mentenanță, sau mai restrânse, pentru tehnicienii de mentenanță, operatorii de achiziții, specialiștii coordonatori de operații de mentenanță, care



operează într-una sau mai multe locații sau asistenții pentru suport tehnic, definiți în cadrul departamentelor.

Panoul de control reprezintă o sinteză și un link către secțiunile platformei. Afișează un calendar cu operațiunile de mentenanță programate cu trimitere la fișele de operație, evenimente sau memento pentru anumite sarcini personale setate de utilizator sau de administratorul sistemului. Se evidențiază lista ticketelor în așteptare de la diverse departamente (mentenanță, achiziții, IT), statusul ultimelor cereri către departamentul de achiziții pentru piese de schimb (componente) și informații privind comanda și livrarea.

Sunt afișate linkuri la activele monitorizate, ultimele anunțuri de la departamentele fabricii (management/producție /mentenanță) și o listă de acțiuni *To do* introduse de utilizatorul conectat pentru o mai bună gestionare a activităților sale.

## Modulul Configurator

Configuratorul conține 9 subsecțiuni de configurare așa cum se observă în meniul din Fig.2:

- definirea limbilor platformei,
- definirea componentelor,
- definirea subansamblelor,
- definirea mașinilor,
- definirea furnizorilor,
- definirea consumabilelor,
- definirea operațiunilor de întreținere – planificatorul,
- definirea glosarului de erori,
- definirea fabricilor.

Platforma este inițiată în 6 limbi, dar poate fi extinsă prin adăugarea altor module de limbă.

Crt	Cod Subansamblu	Denumire	Id Schiță	Opțiuni
1	281737	Cap de modelare	1	[Edit] [Add] [Share] [Delete]
2	284489	Role de centrare	2	[Edit] [Add] [Share] [Delete]
3	284472	Banda Incarcare	3	[Edit] [Add] [Share] [Delete]
4	284394	Rulou Rulant	4	[Edit] [Add] [Share] [Delete]
5	284467	Plasa Rulanta	5	[Edit] [Add] [Share] [Delete]
6	284848	Rola cu Caneluri	6	[Edit] [Add] [Share] [Delete]

Fig.2. Configurator – Subansambluri

Prima subsecțiune – *Gestionează Limba* permite inserarea de limbi noi și editarea frazelor în toate limbile definite, folosind o procedură de import CSV pentru expresiile care se doresc traduse, dar și o procedură locală pentru traducere. Această caracteristică facilitează funcționarea platformei într-o organizație multiculturală.

A doua subsecțiune – *Componente* – inițiază librăria de componente. Toate codurile de componente care compun mașinile utilizate în fabrică conform documentațiilor din cărțile tehnice ale producătorilor, împreună cu alte caracteristici ale componentei, precum și o bibliotecă de fișiere tehnice.

Durata de viață în ore este stabilită în funcție de datele producătorului și este recalculată pe baza datelor de înlocuire a componentelor, ca medie a orelor de funcționare între două înlocuiri succesive și ajustată ulterior de modelele predictive.

După inițierea întregii liste de componente ce vor fi supuse procesului de mentenanță (înlocuire planificată sau la incident), în cea de-a treia subsecțiune a configuratorului, *Subansambluri*, se definesc toate subansamblurile care compun mașinile din fabrică, după codul subansamblului furnizat de producător și indicele de poziție din schița activului.

Fiecare subansamblu va avea definită, la rândul său, o librărie specifică de fișiere, reprezentând mai multe vederi ale subansamblului, în schițe, disponibile tehnicienilor de mentenanță pe dispozitivele mobile. Schițele afișează componentele marcate printr-un indicator de poziție.

Secțiunea *Mașini* inițiază structura tuturor mașinilor/echipamentelor din fabrică supuse activităților de mentenanță reactivă/planificată sau monitorizate în cloud. Fiecare activ este construit din structurile subansamblelor și componentelor create inițial.

În următoarea subsecțiune sunt definiți Furnizorii, iar în cea de-a șasea sunt definite consumabilele indicate de producător, fiecare consumabil fiind asociat unei liste de subansambluri. Astfel, când se scanează AR (sau QR) codul de subansamblu, operatorul poate verifica cu ușurință consumabilele indicate în operațiunile de mentenanță.

Subsecțiunea *Planificator*, din Configurator, configurează cu opțiunea *Operațiune nouă*, pentru fiecare subansamblu (cod de subansamblu), toate operațiunile de mentenanță asociate acestuia și existente în documentația tehnică a activului.

Pe lângă operațiile de mentenanță specificate în documentație pentru lubrifiere, control, curățare, setare ș.a., cu opțiunile *Generează operații la avarie*, respectiv *Generează Înlocuiri Planificate*, administratorul Configuratorului va genera o operație generică de „înlocuire break-down componentă” pentru fiecare componentă din subansamblu care necesită înlocuire în intervențiile de avarie și operațiunea generică „înlocuire planificată componentă” pentru componentele subansamblului care necesită înlocuire regulată (această operațiune având ca frecvență – numărul de ore estimat de funcționare a componentei).

În denumirea operației de înlocuire a componentei, scriptul generator al *Planificatorului - Generează Înlocuiri Planificate* - va include, codul componentei și indexul de poziționare din diagrama subansamblului, pentru o identificare rapidă.

Odată inițiate toate operațiile pe subansamblu, atunci când se instanțiază liniile și mașinile reale de producție, planificarea operațiunilor de mentenanță din *Generatorul de Intervenții / secțiunea Administrare*, devine o sarcină mai ușoară. Aceasta, deoarece toate operațiunile sunt instanțiate automat, pe baza frecvenței setate în *Planificator*, de către un script Cron sau instanțiate în cazul mentenanței la avarie, în urma inspecției tehnicianului de mentenanță și a validărilor date de către directorul de mentenanță.

Fișa unei operațiuni de mentenanță conține descrierea procedurii, frecvența de funcționare în număr de ore, fereastra de avertizare în număr de ore, o bibliotecă de fișiere (care acceptă orice extensie acceptată în secțiunea *Setări*) disponibilă operatorilor în timpul intervenției și toate consumabilele permise pentru subansamblu. Fișierele descriptive ale procedurii operației (în format pdf sau video) vor fi disponibile în aplicația tabletă, în *Librăria Tehnică* asociată operației, atunci când tehnicianul de mentenanță scanează codul subansamblului, în etapa de efectuare a operației de mentenanță.

Configuratorul mai înregistrează și un glosar de erori (mecanice, electrice), în care utilizatorul împuternicit setează toate codurile de eroare definite pe subansamblu/ cod mașină. În acest fel, în fișa operațiunii de mentenanță, tehnicianul va putea adăuga codul de eroare care a declanșat evenimentul, acest lucru fiind de asemenea valoros ulterior, în algoritmi de predicție, în estimarea duratei de viață rămase RUL a unei componente.

Codul de eroare este însoțit în bibliotecă de informații precum cauze potențiale și modalități de remediere a erorii, care pot ajuta tehnicienii de mentenanță în timpul intervențiilor. Ultima subsecțiune din Configurator configurează fabricile companiei, cu datele de contact, locații și reprezentanți.



Această secțiune creează și gestionează entitățile reale din fabrică: linii de producție, mașinile de pe liniile de producție, subansambluri și componente, pe baza Configuratorului, toate aceste entități fiind atribuite unei fabrici și codificate unic printr-un ID.

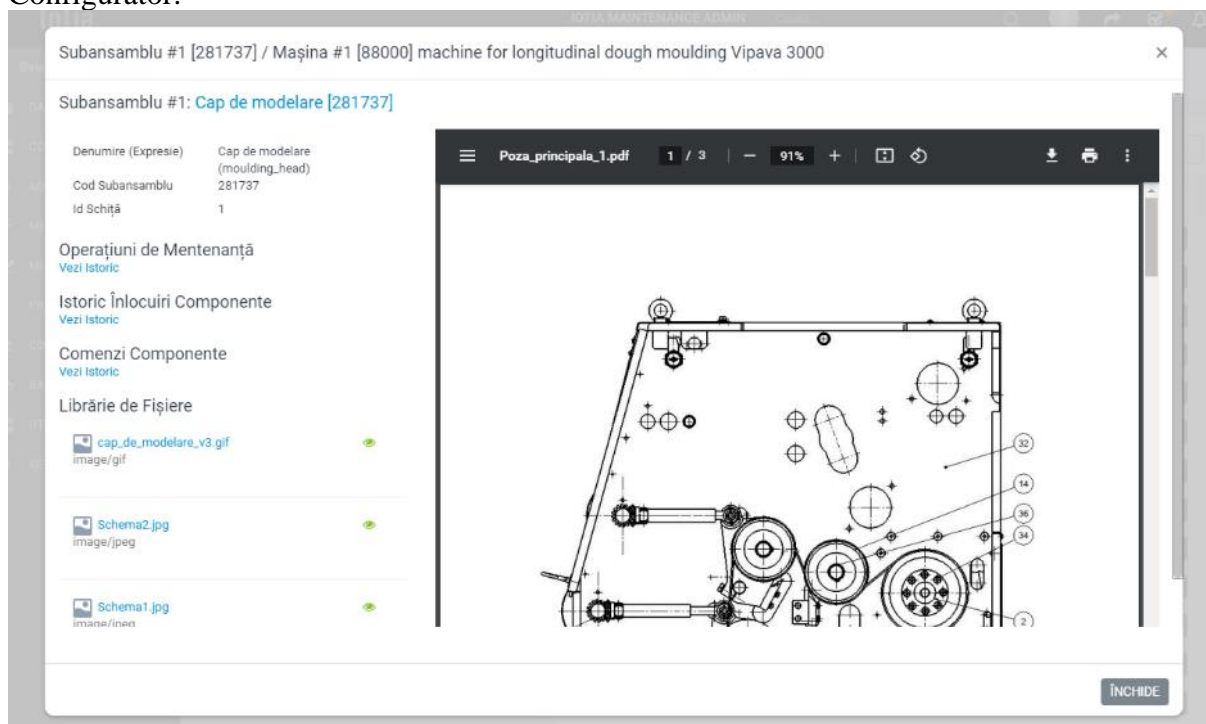
Subsecțiunea *Linii* afișează liniile de producție pentru una sau mai multe fabrici, iar prin selectarea unei linii se obține acces spre o vizualizare arborescentă cu lista mașinilor, subansamblelor și componentelor acestora prin butoane sugestive.

Ecranul unei linii de producție afișează activele asupra cărora se efectuează mentenanță, iar statusul actual al mașinii (*Disponibil/ În pauză/ În mentenanță/ Indisponibil*) este citit de la PLC-uri și afișat în culori sugestive. Fiecare mașină instanțiată pe linie este însoțită de un cod AR (sau QR).

Platforma IOTIA are două variante de implementare pentru codurile de scanare asociate mașinilor și subansamblelor: varianta AR prin coduri ArUco și varianta care implementează coduri QR. Prima variantă are avantajul tehnologiei AR de a supra-augmenta conținut virtual la scanare, dar are dezavantajul că oferă un număr limitat de marcatoare/ coduri, de numai  $2^{10} = 1024$  coduri ArUco. Aceasta poate să limiteze soluția în cazul întreprinderilor industriale cu sute de mașini și mii de coduri de subansambluri, în timp ce varianta QR este mai versatilă.

Un cod ArUco este o grilă de 5x5, de culoare alb și negru, în care, prima, a treia și a cincea coloană reprezintă biți de paritate. Cea de-a doua și a patra coloană reprezintă biții de date. Prin urmare, există doar zece biți de date în total.

Prin scanarea codului AR/QR, prin intermediul dispozitivelor mobile sau utilizând aplicația desktop, cu butoanele sugestive   se poate ajunge la o vizualizare mai profundă a situației subansamblelor și componentelor aferente (Fig.3), respectiv a intervențiilor asupra activului selectat și la o vizualizare de ansamblu a mașinii monitorizate. În figura 3, selectarea unui subansamblu afișează istoricul operațiunilor de mentenanță, istoricul înlocuirilor componentelor, istoricul comenzilor componentelor și librăria de fișiere atașată din Configurator.



**Fig. 3.** Administrare – Fișa subansamblu: Cap de modelare (Cod Subansamblu: 281737)

Istoricul înlocuirilor componentelor unui subansamblu va fi utilizat de modelul predictiv, atât pentru înlocuirile planificate cât și pentru cele neplanificate, când intervine o degradare puternică sau o avarie. În primul caz - *Înlocuire Planificată Componentă* - istoricul este util pentru construirea caracteristicii: *numărul de zile de funcționare a componentei de la ultima înlocuire*, iar în al doilea caz - *Înlocuire Break-down Componentă* - istoricul este utilizat pentru construirea valorii target: *eșec\_componenta*, pentru etichetarea datelor “de eșec” ale componentelor.

O altă caracteristică importantă pentru modelul predictiv, de estimare RUL a timpului rămas până la eșecul componentei, este “vârsta mașinii” sau numărul de ani de funcționare, și modelul mașinii, exprimat prin Cod Mașină, care vor fi extrase din fișa activului.

În subsecțiunea *Generator Intervenții* (Fig.4) se inițiază intervențiile de mentenanță de pe liniile de producție, planificate sau la avarie (*break-down*). Fiecare intervenție va include operațiuni distincte pentru unul sau mai multe subansambluri ale unei mașini. Operațiunile componente ale intervenției sunt generate de scriptul Cron sau manual, la intervenția directorului de mentenanță, în urma inspecțiilor tehnice de avarie, în funcție de *Planificatorul Operațiilor* din *Configurator* care setează toate operațiunile de mentenanță și intervalele de timp pentru efectuare.

ID Intervenție	Tip Intervenție	Mașina	Data Generării	Data Începerii	Data Finalizării	Status	Tip Tarif	Generat de	Opțiuni
1	Planificată	#1 [88000]	28-11-2020 00:37	29-12-2020	05-02-2021 19:10	Finalizat	Cost Fix	CRON	[Edit] [Delete]
5	Planificată	#1 [88000]	06-01-2021 00:00	31-01-2021	05-02-2021 19:11	Finalizat	Ore Intervenție	CRON	[Edit] [Delete]
6	Planificată	#1 [88000]	10-01-2021 00:00	09-02-2021	11-02-2021 20:54	Finalizat	Ore Operație	CRON	[Edit] [Delete]
7	Planificată	#1 [88000]	15-01-2021 23:30	25-01-2021		În Desfășurare	Ore Operație	CRON	[Edit] [Delete]
8	Planificată	#1 [88000]	19-01-2021 00:00	02-02-2021		În Desfășurare	Cost Fix	CRON	[Edit] [Delete]
9	Planificată	#1 [88000]	22-01-2021 00:00	09-02-2021	11-02-2021 20:51	Finalizat	Ore Operație	CRON	[Edit] [Delete]
10	Planificată	#1 [88000]	28-01-2021 00:00	02-02-2021	02-02-2021 22:52	Finalizat	Ore Operație	CRON	[Edit] [Delete]
11	Planificată	#1 [88000]	06-04-2021 00:00			În Așteptare	Ore Operație	CRON	[Edit] [Delete]
12	Planificată	#1 [88000]	13-05-2021 00:00			În Așteptare	Ore Operație	CRON	[Edit] [Delete]
13	Planificată	#1 [88000]	20-05-2021			În Așteptare	Ore	CRON	[Edit] [Delete]

Fig. 4. Administrare – Generare Intervenții – Vizualizare și creare intervenții pe linie

În cazul intervenției de avarie vor fi selectate automat operațiunile de tip „break-down”, setate în *Configurator* pentru fiecare tip de defecțiune descoperită la inspecția activului și atribuite pe cod de subansamblu.

Imediat după generarea automată efectuată de Cron, intervenția are statusul *În Așteptare*, urmând ca administratorul de sistem sau directorul de mentenanță să programeze operațiunile dorite, stabilind echipa de intervenție din grupul de tehnicieni ai fabricii sau subcontractanții, dacă externalizează serviciile de mentenanță. Acesta va mai seta data de începere și o dată limită pentru finalizarea operațiunilor intervenției, urmând ca intervenția să intre în status *Neînceput*. Când tehnicianul începe execuția primei operații, statusul intervenției devine: *În Desfășurare*.

Pentru fiecare operațiune în parte generată de Cron, în fișa operațiunii se vor estima numărul de ore astfel încât, pentru o întreagă intervenție, sistemul va putea estima numărul total de ore necesar pentru toate operațiile intervenției. Numărul de ore estimat va genera și un cost

estimat al intervenției (manopera) în funcție de tipul de tarifare care este setat pe intervenție: intervenție cu cost fix, tarif pe oră de intervenție sau tarif pe ora de operație. Numărul de ore realizat pentru o anumită operație va fi calculat în baza validării de către tehnician a timpilor de începere și finalizare ai unei operațiuni.

Există situații în care acest interval de timp poate să includă și timpi de așteptare, din diverse motive (lipsa unor componente sau materiale necesare pentru intervenție, lipsa de personal disponibil), iar numărul de ore efectiv realizat de tehnician să fie mult mai mic.

Timpul real poate fi captat prin sistemul de pontare din interfața tehnicianului (aplicația mobilă/tabletă sau desktop), prin cronometrarea timpului cu opțiunea *Start Cronometru* și *Stop Cronometru*. Astfel, modalitatea de tarifare a intervențiilor și operațiilor este foarte flexibilă prin sistemul creat, iar cheltuielile cu operațiile de mentenanță pot fi proiectate flexibil în ce privește: cheltuielile cu manopera, cheltuielile cu piesele de schimb, cheltuieli cu consumabilele și alte tipuri de cheltuieli.

Fiecare operațiune din fișa de intervenție este marcată de un Status, marcat inițial *Neînceput*, și modificat de tehnician ca: *În Desfășurare*, *Finalizat*, *Amânat* și de un grad de Prioritate: *Scăzută*, *Medie*, *Mare*, *Urgent*, setată de administrator.

Astfel, vor fi posibile rapoartele cu privire la intervențiile și starea operațiunilor cât și la situațiile de pontaj, atât în modulul de Administrare al mentenanței, în mod generalizat, cu drepturi largi de acces/editare/vizualizare, pentru directorul de mentenanță, cât și restrâns, în modulul de Mentenanță, pentru tehnicienii logați, care vor putea vizualiza doar propriile operații și rapoarte, având acces la intervențiile la care au fost atribuiți să intervină.

Platforma IOTIA integrează scripturi pentru trimitere alerte prin email, în funcție de gradul de prioritate, de fiecare dată când sunt atribuite sarcini tehnicienilor sau sunt întreprinse operațiuni de mentenanță de către aceștia, prin comunicarea statusului lucrării.

Acest nivel de configurare a operațiilor de mentenanță, prin atribuirea unui interval de timp fiecărei intervenții în parte și de operațiuni specifice echipei de mentenanță, prioritizarea, dar și feedback-ul tehnicienilor, oferă o imagine mai clară a stării activelor și sarcinilor și va genera o vizualizare mai clară a operațiunilor în secțiunea Mentenanță, utilizatorilor logați, cu drepturi diferite de acces.

*Sesiunile de instruire* sunt inițiate în modulul de Administrare. În cadrul acestei secțiuni directorul de mentenanță/evaluatorul poate crea diverse chestionare de evaluare, iar răspunsul de feedback și fișele de instruire ale angajaților vor putea fi vizualizate în secțiunea *Instruire Personal*.

### **Modulul Mentenanță Preventivă**

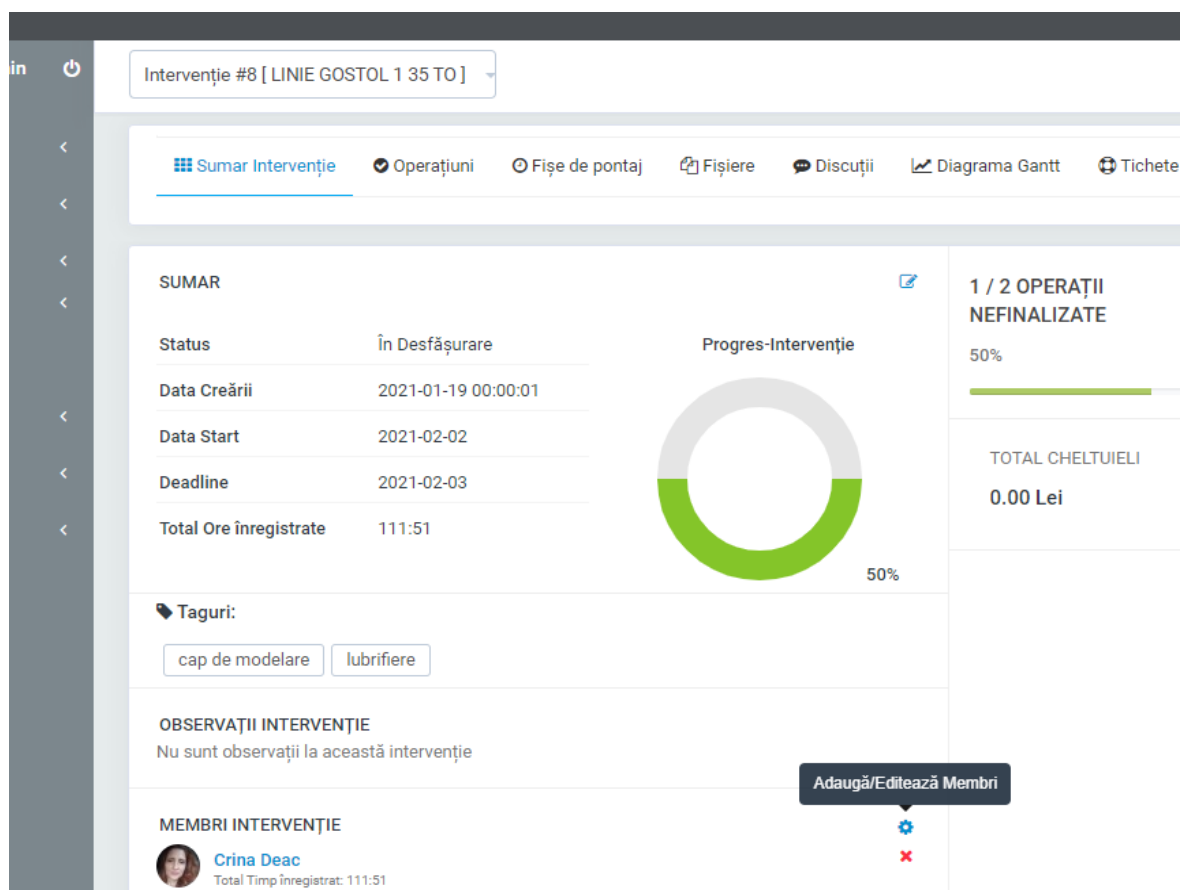
Secțiunea reflectă toate elementele setate în Administrare, dar filtrate pentru vizualizare după gradul de permisiune și tipul de utilizator. Această secțiune conține:

- *Liniile de producție*, prin vizualizarea activelor de pe liniile de producție cu toate subansamblurile și informațiile despre structurile componentelor și bibliotecile definite care sunt permise utilizatorului logat în secțiune.

- *Intervenții*, prin vizualizarea tuturor intervențiilor la care utilizatorul este desemnat să efectueze operațiuni și să le opereze în cadrul *Fișelor de Operațiune*. Fiecare *Fișă de intervenție* oferă tehnicianului alocat/supervizorului/directorului de mentenanță/ inginerului de fiabilitate o vizualizare mai complexă după:

- sumarul intervenției (Fig. 5),
- lista operațiunilor componente și fișele de operațiune,
- fișele de pontaj,
- fișierele atașate de membrii intervenției,
- discuțiile întreprinse de echipa alocată,
- diagrama Gantt a situației operațiunilor în funcție de status/tehnicieni alocați, atât pe linie de producție cât și pe intervenție,

- ticketele emise între departamente în cadrul operațiunilor intervenției și situația cheltuielilor.
    - *Operațiuni*, prin vizualizarea cumulată a tuturor operațiunilor din cadrul tuturor intervențiilor atribuite tehnicianului/supervizorului conectat.
    - *Alerte* (o listă de alerte trimise utilizatorului)
    - Suport prin *Asistență de la distanță*, subsecțiune care integrează o soluție de videoconferință între asistenții de suport/directori de mentenanță/supervizori/specialiști și tehnicienii de pe teren care întreprind operațiuni.
    - Suport prin *Sistem de Ticketing*, cu tichete deschise/în curs/cu răspuns/în așteptare și închise, între departamentele de Mentenanță, Producție, Achiziții, IT, etc. Subsecțiunea permite comunicarea între departamente, fiecare ticket deschis poate conține o succesiune de răspunsuri în ordine cronologică și poate fi definit de mai multe statusuri.
    - *Training*, prin vizualizarea sesiunilor de instruire ale utilizatorului conectat sau vizualizate pe întreaga echipă / fabrică, în funcție de permisiuni și rol.
- Elementele acestui modul sunt legate doar de mentenanța preventivă și break-down, mentenanța bazată pe stare și mentenanța predictivă sunt disponibile în module separate.



**Fig. 5.** Mentenanță Preventivă – Sumar Intervenție

Modulul Mentenanță permite utilizatorului să vizualizeze toate informațiile legate de active și intervenții în două moduri: fie din interiorul platformei (prin aplicația desktop), fie folosind o aplicație AR bazată pe web, concepută pentru rezoluția tabletă și Ochelari AR. Proiectul pilot a utilizat modelul Vuzix M400 pentru ochelarii AR.

### Aplicația mobilă pentru mentenanță cu tehnologie AR

Aplicația mobilă cu tehnologie AR (Deac et al, 2017) a fost lansată inițial ca temă de cercetare de partenerul FESTO Didactic și a constat în realizarea unei aplicații web-based mobile pentru mentenanță, folosind tehnologiile WEB și AR open-source. Ulterior a fost inclusă în platforma

IOTIA ca interfață web mobilă pentru tehnicienii din teren, fiind conectată cu aplicația software de desktop, dar utilizând coduri QR în locul codurilor ArUco datorită limitării numărului acestora din urmă.

Scopul acestei aplicații este acela de a furniza informații utile pentru echipele de intervenție și de a facilita validarea fișelor de inspecție și de operațiuni prin:

- identificarea mașinilor și componentelor acestora
- vizualizarea stării componentelor și subansamblelor mașinilor
- accesarea de informații cu privire la istoricul proceselor de mentenanță anterioare (operațiunile efectuate, observațiile tehnicienilor, cauzele eșecurilor, membrii echipei)
- informații cu privire la stocurile de componente, furnizori, prețuri
- completarea cu ușurință a fișei de inspecție tehnică sau a fișei de operațiune din cadrul unei intervenții, prin validarea acțiunilor întreprinse, a materialelor și consumabilelor utilizate
- trimiterea de comenzi către departamentul de achiziție pentru piese de schimb/consumabile
- accesarea librăriei tehnice atașate subansamblelor și componentelor (cu manuale de utilizare, manuale tehnice, schițele tehnice de amplasare a componentelor)
- accesarea bibliotecii media ce conține clipuri video privind operațiunile de mentenanță
- solicitarea de suport, prin asistență de la distanță, prin intermediul aplicației de videoconferință augmentată.
- deschiderea unui ticket către departamentele din companie, folosind suportul de ticketing.

Pentru realizarea aplicației s-au utilizat exclusiv *tehnologii web*, astfel încât aplicația poate rula direct în browser web, pe orice tip de dispozitiv sau sistem de operare. Prin tipul arhitecturii client-server, se asigură centralizarea informațiilor și ușurința întreținerii bibliotecilor. Provocarea majoră a fost aceea de a identifica tehnologiile web existente care ar putea susține această implementare.

S-a pornit de la principiul de bază pentru realizarea unei aplicații de realitate augmentată și anume:

- preluarea unui flux video de la o cameră web
- analiza unor markere AR de identificare
- generarea de conținut augmentat 2D sau 3D
- afișarea fluxului video și a conținutului augmentat

Pentru fluxul video provenit de la cameră s-a ales varianta *WebRTC / getUserMedia*, care este o tehnologie nouă HTML5, care nu necesită instalarea nici unui driver sau plugin suplimentar. Interfața aplicației a fost realizată utilizând HTML5, CSS și javascript, iar pentru aplicația de server s-a utilizat PHP și MySQL.

Pentru markererele AR s-au ales librăriile *ArUco*, pentru care există deja implementare în javascript (librăriile ArUco sunt bazate pe tehnologia OpenCV).



**Fig. 6.** Markere AR – ARUCO

Pentru conținutul augmentat 2D sau 3D s-a aplicat tehnologia *WebGL 2.0*. (web graphics library) implementată în librăria *THREE.js*, care permite crearea, importul și afișarea animațiilor 3D utilizând Javascript, fără să fie necesar importul de plugin-uri.



**Fig. 7.** Interfața Scan

Principiul de funcționare este următorul:

- Tehnicianul scanează cu tableta, telefonul sau laptopul, utilizând camera video, markeretele amplasate pe fiecare mașină (markerul reprezentativ al mașinii sau markeretele subansamblurilor acesteia).
- La identificarea markerelor, peste imaginea furnizată de cameră se suprapun informațiile de identificare a mașinii/subansamblului și descrierea minimală a acestora (imagine, denumire, cod).
- Tehnicianul se apropie de subansamblul vizat, iar în acel moment în urma identificării pe baza markerului AR, în interfața web se încarcă toate informațiile utile legate de acesta.

Interfața *Start (Home)* include:

- *Operațiunile mele*: include lista tuturor operațiilor atribuite tehnicianului
- *Inspecțiile mele*: include lista tuturor inspecțiilor efectuate de tehnician
- *Calendar*: conține sarcinile atribuite tehnicianului pe date calendaristice
- Butonul de *Start Scan*: se selectează camera video (față sau spate)

Interfața de *Scanare (SCAN)* (Fig. 7) include:

- ecranul de scanare în care este implementată aplicația AR,
- link la secțiunea *Librărie* în care se încarcă selectiv o librărie tehnică, în funcție de markerul AR scanat,
- link la secțiunea *Istoric Mentenanță*, în care se vor încărca informații legate de istoricul mentenanței subansamblului scanat (cod subansamblu) cu fișele operațiilor,
- link la *Achiziții*, în care se va încărca istoricul cererilor de livrare și achizițiilor componentelor subansamblului scanat.

La click pe fiecare tab afișat, în ecranul *Librărie* se deschid scheme, manuale pdf de instrucțiuni sau filme video demonstrative legate de operațiunile de mentenanță efectuate pe subansamblul scanat, definite în secțiunea *Configurator* în librăria *Planificatorului*, odată cu definirea operațiilor pe cod de subansamblu sau în librăria *Subansambluri*.

Ecranul *Istoric Mentenanță* conține istoricul operațiilor de mentenanță efectuate la subansamblul scanat, afișate după status: *Neînceput/În Desfășurare/Finalizat/Amânat* cu informații detaliate, la click, despre fiecare operație.



Interfața include acces pentru suport la distanță, prin aplicația de videoconferință bazată pe Web RTC, inclusă în aplicația web, dar care poate fi lansată și de ochelarii AR și mai include suportul ticketing, pentru deschiderea unui ticket către departamentele de achiziție, mentenanță, producție sau IT.

Pentru efectuarea operațiilor alocate, tehnicianul va apela simbolul *Home*, va ieși din interfața AR și va accesa *Operațiile mele*. Aici va putea vizualiza o listă pe statusuri cu toate operațiunile pe subansambluri care i-au fost atribuite în *Generatorul de Intervenții*. Prin selectarea unei operațiuni, se va deschide fișa operațiunii (Fig. 8), iar codul subansamblului la care operațiunea face referire va fi actualizat în memorie și datele referitoare la acesta vor repopula taburile: *Librărie*, *Istoric Mentenanță*, *Achiziții*.

Fig.8. Interfața Operațiile mele / Fișa Operație

Tehnicianul va marca începerea operațiunii prin selectarea unui nou status cu opțiunea: *Marchează în Desfășurare*, iar pentru pontare va porni cronometrul. Va verifica pas cu pas descrierea operației și eventual observațiile directorului de mentenanță. În cazul în care dorește informații tehnice despre operațiune (scheme subansamblu, video despre operațiune), va accesa *Librăria* pentru consultare sau va cere suport de la distanță prin accesarea aplicației de videoconferință.

Tehnicianul va completa *Fișa de Consum* cu consumabilele folosite sau piesele înlocuite și va putea emite cereri de livrare la departamentul de achiziții (*Comanda*) pentru consumabile sau piese de schimb, în cazul în care nu are necesarul pentru înlocuire.

În momentul finalizării operației, dacă operația este de tip înlocuire componentă, tehnicianul marchează status *Finalizat*, iar operația de înlocuire planificată componentă este marcată automat în baza de date în tabela de înlocuiri planificate. Operația de înlocuire la avarie va fi înregistrată în tabela *eșec componente*, înregistrându-se data, id-ul și codul componentei, pentru modelul predictiv. În *Fișa de consum*, consumabilele utilizate și piesele înlocuite la avarie sunt marcate prin bifare în lista afișată a componentelor subansamblului.

În fișa operațiunii, tehnicianul va introduce note de observație. Dacă este necesară o nouă achiziție, operatorul va accesa butonul Cerere de Livrare, în care va bifa codul componentelor solicitate din lista de componente a subansamblului și numărul de piese, generând astfel o cerere de livrare la achiziții. Toate cererile de livrare vor fi vizualizate și pe platformă, în submeniul Comenzi / Cereri de Livrare.

Întreaga operare descrisă mai sus, poate fi efectuată și din interiorul platformei (aplicația desktop), prin selectarea Fișei de Intervenție din secțiunea Intervenții sau accesând direct subsecțiunea Operațiuni în modul Listă sau în modul Kan Ban.

*Support videoconferință* permite conectarea simultană a mai multor utilizatori și include următoarele facilități:

- comunicare audio video High Definition,
- partajare de ecran,
- transfer de fișiere,
- chat text,
- partajarea de materiale video de pe Youtube,
- conectarea SIP cu alte sisteme de conferință proprietare.

Videoconferințele pot fi înregistrate și încărcate ulterior în biblioteca video a Configuratorului, pentru a fi disponibile altor tehnicieni / operatori.

## Modulul Monitorizare

Monitorizarea mașinilor în cadrul platformei se face fie pe baza datelor preluate de la PLC-uri (datele telemetrice, starea mașinii, alerte, coduri de eroare de tip electric sau mecanic), fie pe baza senzorilor montați pe mașini pentru analiza diferiților parametri de stare: vibrații, temperaturi, etc.

În proiectul pilot s-au utilizat senzori TA312-M12A pentru măsurarea vibrațiilor și a temperaturii, care s-au instalat pe o mașină din industria panificației pentru modelarea aluatului - mașina de modelat lung Vipava 3000 500.

Senzorii TA312-M12A au următoarele caracteristici: tensiune de alimentare între 3-5V, sensibilitate 25mV/g, un răspuns în frecvență între 0,5-15000 Hz și interval de temperatură între 3 și 121 grade Celsius.

Senzorii montați pe mașini sunt conectați la câte un microcontroler ESP32 printr-un canal al ADC (convertor analog digital).

ADC-ul microcontrolerului dispune de o arhitectură SAR (Successive Approximation Register) cu o rezoluție de 12 biți. Pentru a putea captura informații în gama de frecvențe tipică vibrațiilor rulmenților (cel puțin până la 5kHz) este nevoie de o frecvență de eșantionare dublă de cel puțin 10kHz.

Senzorul piezoelectric TA312-M12A utilizat are un eșantion nominal specificat de producător cu o diviziune de 25mV/g, o gamă de răspuns în frecvență până la 12kHz ( $\pm 10\%$ ) și o plajă dinamică de măsurare până la 50g. Pentru acoperirea plajei dinamice este nevoie de o rezoluție a ADC-ului care în funcție de eșantionul nominal specificat de producător să acopere valoarea maximă posibilă. ADC-ul din specificația microcontroler-ului îndeplinește această marjă:  $2^{(12-1)}/25 = 81.92g > 50g$  (Minimumul acceptat al rezoluției este 11biți, caz în care se atinge o plajă dinamică maximă de 40.96g, pierzându-se doar 9 eșantioane în marja dinamică specificată).

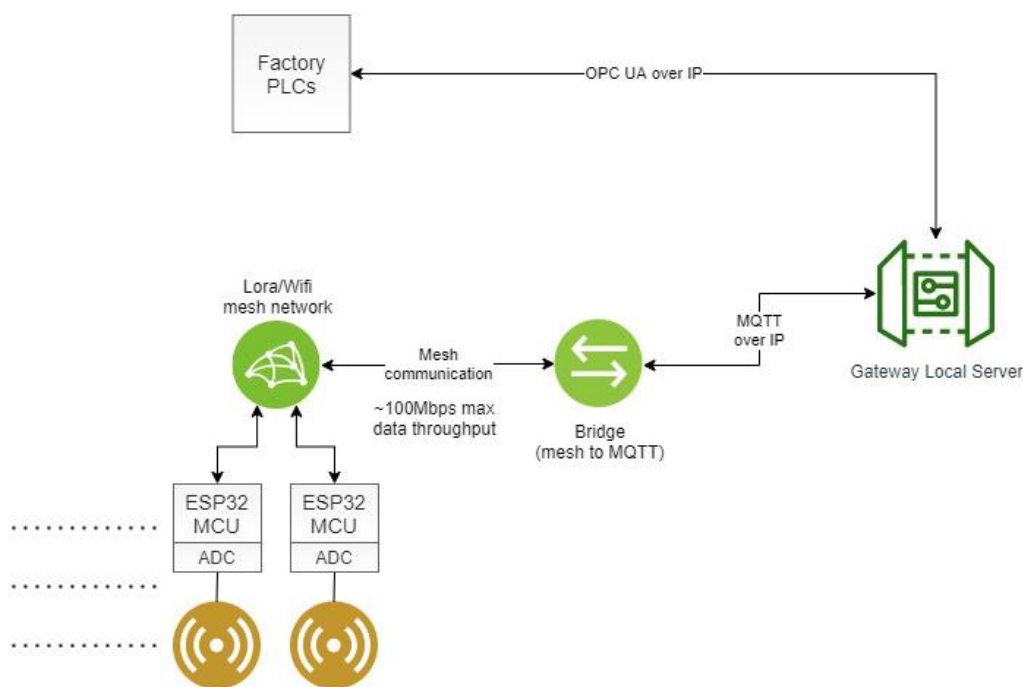
Având în vedere lățimea de bandă analogică efectivă a ADC-ului integrat de 6kHz pentru care acesta menține un răspuns liniar în funcție de frecvența de eșantionare, s-a urmărit:

- Implementarea unui tabel de căutare (*look-up table*) pentru normalizarea răspunsului în frecvență, cu o rutină de calibrare inițială ce folosește DAC-ul microcontroler-ului pentru a implementa un *feedback loop*. Acesta este folosit pentru maparea tuturor punctelor în gamele de frecvență din afara specificației.
- Implementarea unei corecții polinomiale înfășurătoare

Pentru îmbunătățirea SNR (Signal-to-Noise Ratio), a raportului dintre semnalul dorit și zgomot, în scopul reducerii zgomotului s-a urmărit:

- Implementarea unui filtru analog RC pentru frecvența de eșantionare nominală de 10kHz
- Testarea unei soluții de supra-eșantionare (oversampling)
- Implementarea unui filtru digital cu trecere-jos pentru eliminarea zgomotului spectral datorat reflecțiilor, cu posibilitate de folosire în conjuncție cu supra-eșantionarea pentru anti-aliasing
- Utilizarea unui amplificator de instrumentație cu răspuns nominal în gama de frecvențe de până la 10kHz pentru îmbunătățirea SNR (raport semnal dorit – zgomot)

Comunicarea cu serverul se face wireless peste IP, la nivel de frame prin protocolul MQTT, iar la nivel de informație transmisă se utilizează formatul specific *InfluxDB* din protocolul *Line protocol*. Există și posibilitatea creării unei rețele de tip *mesh* între microcontrolere cu un singur gateway MQTT (Fig. 9) în marja limitării ratei de date ce pot fi procesate de fiecare nod.



**Fig. 9.** Transportul datelor în fabrică cu rețea Mesh

Pentru soluția curentă de monitorizare cu o rată mare de date s-a utilizat o conexiune directă cu *router-ul wifi* care preia datele de la microcontroler și le transmite la server.

La nivel superior protocolului de comunicație (MQTT) s-au încercat două implementări: MQTT over TCP frame și MQTT over Websockets. Prima implementare este utilizată pentru eșantioanele de date trimise în bloc, iar cea din urmă are performanțe mai mari pentru datele trimise serial.

Așadar, și implementarea din cadrul microcontroler-ului poate avea 2 variante de transmitere a eșantioanelor în pachete: în bloc (eșantioane acumulate pe o perioadă predefinită în timp, de mărimea blocului) și serial, în timp real (fiecare pachet conține un singur eșantion). Această ultimă variantă are performanțe slabe în cazul unui flux mare de date.

Datele telemetrice de la mașini sunt colectate de la PLC-uri prin OPC UA, prin IP sau alte protocoale acceptate. Pentru vizualizarea datelor se utilizează *Grafana Dashboards*.

Secțiunea de monitorizare afișează liniile de producție cu mașinile monitorizate și fișele activelor monitorizate. Prin selectarea unei mașini monitorizate se afișează o prezentare

generală a mașinii. Aceasta conține date despre mașină, cum ar fi: denumirea, codul de producător, ID-ul, numărul mașinii, anul de producție, statusul actual al mașinii, greutatea (Kg), tensiunea nominală (V), frecvența (Hz), tensiunea de conectare (kW), data instalării, disponibilitatea în ore, timpul indisponibil în ore, numărul total de alerte, jurnalele de erori, numărul total de probleme critice (prin numărarea tuturor operațiilor de tip „break-down” din istoricul intervențiilor, ultimul service cu ultima intervenție (data) și următoarea intervenție (data), indicele de stare al mașinii.

De asemenea, ecranul afișează o tabelă cu toate operațiunile întreprinse pe subansamblele mașinii din istoricul de intervenție, inclusiv operațiuni de tip break-down și înlocuire planificată componente.

În funcție de parametrii monitorizați pe fiecare mașină, o vizualizare i-frame, denumită Panel, generată în *Grafana*, o platformă open-source pentru interogare, vizualizare și alertare a parametrilor seriilor de timp și a logurilor, afișează grafice ale parametrilor de stare, media mobilă la 6 sau 12 ore, în funcție de intervalul configurat, prin utilizarea capacității de mediere a graficelor (diagramelor). Mai poate utiliza un *contor* în timp, folosind facilitatea *Legend*, pentru a afișa media, minimumul, maximumul, folosind linia de mediere (*Plot average line*) a graficului sau alte date de agregare, cum ar fi Media și Median-ul.

Principalii parametri telemetrici care caracterizează evoluția mașinii vor fi luați în considerare în caracteristicile care vor forma setul final de intrare care va antrena modelul predictiv.



**Fig. 10.** Vizualizarea datelor telemetrice cu Grafana

## Modulul Mentenanță Predictivă

Această secțiune conține modelele predictive dezvoltate în platformă pe baza datelor acumulate de la senzori și PLC-uri și transmise serverului central cât și a datelor stocate în CMMS care provin de la echipele de mentenanță sau de la alte baze de date importate. Modelele predictive sunt scrise în Jupyter Notebook, o aplicație web open-source, apelată de platformă, care partajează documente care includ cod, vizualizări și descrieri suplimentare.

Platforma utilizează notebook-uri pentru analiza datelor exploratorii, acumulate într-o bibliotecă organizată în foldere și fișiere, rulând un server notebook. Conexiunile se fac la serverul central care găzduiește baza de date unificată și la serverele locale din fabrică care stochează datele de telemetrie primite de la senzori sau PLC-uri. Datele sunt citite și încărcate cu librăria *Pandas*. Alte biblioteci sunt utilizate pentru afișarea grafică a datelor, vizualizare, calcule științifice (*Matplotlib*, *Seaborn*, *biblioteca SciPy*) și modelare.

Modelele sunt construite folosind API-uri de nivel înalt cum ar fi Keras pentru implementări *Deep Learning*, scikit-learn pentru implementări ML în Python, preprocesare, selectarea modelelor, clasificare, regresie, clusterizare și reducerea dimensionalității.

## **Predicția eșecului componentelor într-o fereastră de timp folosind algoritmi de multi-clasificare. Studiu de caz.**

Detectarea anomaliei, diagnosticarea defectelor, precum și cunoașterea probabilității ca o anumită mașină să eșueze din cauza unor componente în intervalul de timp următor sunt subiecte cruciale de analiză în domeniul Industriei 4.0. Astfel, putem preveni din timp defecțiunile majore și întreprinde acțiuni înainte ca evenimentul să se întâmple prin intervenții de mentenanță la timp, cu resurse limitate, într-un mod mai rentabil, îmbunătățind calitatea și lanțul de aprovizionare.

În această implementare dorim să cunoaștem care este probabilitatea ca o anumită mașină să eșueze din cauza eșecului unei componente critice într-un interval de timp următor.

Se știe că operațiunile de înlocuire planificată se efectuează la un interval de timp regulat, când încă unele componente ar mai putea funcționa. Cunoscând probabilitatea de eșec a componentei într-un interval de zile, se poate controla costul mentenanței efectuându-se intervențiile de mentenanță preventivă la momentul potrivit, aproape de eșec și extinzând cât se poate funcționarea componentei, dar prevenind avariile majore.

Operațiile de înlocuire planificată din cadrul mentenanței preventive sunt efectuate *“just in time”*, iar intervențiile de mentenanță corectivă sunt reduse, prevenindu-se avariile critice și timpii mari de nefuncționare. Mai mult, cunoscând timpul de eșec, inventarierea pieselor de schimb existente în stoc sau cererile de livrare la departamentul de achiziții pot fi rezolvate în timp util, înainte de intervenție.

Deoarece există mai multe componente critice într-o mașină, determinarea probabilității de eșec a componentelor într-un interval de timp se reduce la o problemă de multi-clasificare utilizând seriile de timp și algoritmi de Machine Learning.

Un model de multi-clasificare va fi antrenat pe datele colectate de la mai multe linii de producție similare (de la una sau mai multe fabrici), iar fiecare eșantion de date marcat de un moment de timp *timestamp* va fi etichetat cu starea componentelor critice: “componenta critică” care a eșuat, dacă eșantionul descrie o stare de eșec, sau cu “normal”, dacă eșantionul reprezintă o stare normală în care nici una din componentele critice nu a eșuat.

Pentru fiecare tip de mașină se pot identifica câteva coduri de componente - componente critice, ce pot fi considerate Etichete țintă (*target label*) în modelul predictiv.

Datele de telemetrie capturate în procesul de monitorizare de la PLC-uri, cum ar fi tensiunea, presiunea, rotația, vibrația, vor fi utilizate în setul de caracteristici ale modelului, alături de alte caracteristici, printre care un set de măsuri agregate, calculate pe o fereastră rulantă de timp (*lagging window*) de 6 sau 12 ore (media rulantă, deviația standard, valoarea minimă sau valoarea maximă din acel interval).

La acest set de caracteristici se vor adăuga alte caracteristici, cum ar fi logurile de eroare primite de la mașini în timp ce acestea sunt încă operaționale. Se va alege din glosarul de erori doar acele erori (id-uri de eroare) care sunt cruciale în prezicerea unui eșec viitor și deoarece acestea nu pot fi mediate, fiind valori categorice, se va considera numărul total de erori din fiecare tip, în fereastra de întârziere setată, pentru fiecare mașină,.

De asemenea, numărul de zile de la ultima înlocuire pentru fiecare cod de componentă, de la fiecare ID de mașină, va fi calculat utilizând istoricul intervențiilor din secțiunea Mentenanță, căutând operațiunile de înlocuire de tip break-down și istoricul înlocuirilor planificate ale componentelor, cunoscând că intervalul de timp de la ultima înlocuire reprezintă numărul de ore de funcționare al componentei, care este foarte corelat cu nivelul de degradare al acesteia.

Variabila target, componenta care a eșuat, va fi extrasă din istoricul de intervenții *break-down*, din operațiile de înlocuire componentă la avarie, de unde se va extrage codul de componentă, ID-ul mașinii și timestamp-ul care marchează momentul eșecului pentru fiecare mașină în parte. O altă caracteristică utilă care ar putea completa setul de date de intrare furnizat modelului, este vechimea mașinii preluată din fișa tehnică a mașinii (An producție /Data

instalării), cunoscându-se faptul că numărul de ore de funcționare al mașinii este corelat cu gradul de uzură.

Pe baza acestor caracteristici extrase din datele istorice, modelele predictive învață tiparele de degradare și vor prezice rezultatele viitoare cu o anumită probabilitate. Validarea metodelor propuse a fost făcută prin compararea eșecurilor reale din setul de testare cu cele prezise de modelul antrenat pe setul de antrenare. S-a calculat matricea de confuzie care afișează defecțiunile prezise pe coloană și defecțiunile reale al componentelor pe rânduri.

În predicție vor fi considerate mai multe modele de clasificare: modele bazate pe arbori de decizie sau modele bazate pe rețele neuronale. Modelul cu cele mai bune rezultate în metricile de evaluare va fi ales în final pentru a face predicția asupra setului de date în timp real, în procesul de monitorizare al mașinilor.

Pentru ilustrarea soluției, s-au folosit seturi de date diferite, preluate de pe Microsoft Azure cloud, cu înregistrări ale istoricului operațional provenit de la un set de 500 de mașini de 4 tipuri, pe o perioadă de funcționare de aproximativ un an de zile.

Analizând metricile de evaluare, clasificatorul XGBoost a obținut cel mai mare scor  $F1 = 0,83$ , fiind cel mai bun clasificator pentru datele studiului.

XGBoost (*Extreme Gradient Boosting*) folosește principiul gradient boosting, cu diferențe însă în detaliile de modelare. XGBoost folosește o formă de regularizare mai complexă a modelului pentru controlul over-fittingului și obține performanțe mai bune.

Funcția obiectiv ce trebuie optimizată este funcția Loss regularizată de termenul  $\Omega$  conform formulei:

$$\text{Obj}^{(t)}(\Theta) = L(\Theta) + \Omega(\Theta) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^t \Omega(f_i) \quad (1)$$

Complexitatea arborelui este dată de termenul de regularizare  $\Omega(f)$  și este definită pentru XGBoost astfel:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (2)$$

unde  $\omega$  este vectorul scorurilor frunzelor arborelui,  $T$  este numărul de frunze.

Arborii în XGBoost pot avea un număr variat de noduri terminale.

Algoritmul XGBoost suportă mai bine procesarea *multi-core*, ceea ce reduce timpul de antrenare.

**Tabelul 1.** Matricea de confuzie pentru clasificatorul XGBoost

Eșec prezis	componenta1	componenta2	componenta3	componenta4	none
Eșec					
componenta1	1495	34	4	10	386
componenta2	20	2014	16	9	475
componenta3	7	10	608	4	141
componenta4	21	30	1	983	189
none	196	255	144	127	178366


Acuratețe = 0.988795

Precizie = 0.851703

Recall = 0.810682

**F1 = 0.830687**

Din studiile efectuate și rezultatele obținute, algoritmul Random Forest, de asemenea, poate fi utilizat, pentru acesta obținându-se un scor  $F1 = 0,76$ , fiind mai rapid decât clasificatorul Gradient Boosting.



**Fig. 11.** Importanța *Caracteristicilor* pentru modelul XGBoost

Rețeaua neuronală nu a obținut rezultate atât de bune precum arborii de decizie, neavând suficiente exemple de avarii pentru a învăța comportamentul de degradare al componentelor, scorul obținut fiind de doar  $F1 = 0.55$ .

### **Diagnosticarea defectelor în rulmenți prin analiza vibrațiilor, folosind abordarea Deep Learning. Studiu de caz.**

Utilizarea datelor etichetate pentru a învăța reprezentări expresive ale normalității/anormalității este crucială pentru detectarea precisă a anomaliilor. Modelele propuse în prezentul studiu de caz sunt modele de învățare supravegheată, cu o bună precizie în clasificare, care învață direct din datele brute ale seriilor temporale furnizate de accelerometre. Singura condiție este ca eșantioanele să fie etichetate corect.

Studiul de caz utilizează un set de algoritmi de învățare profundă pentru diagnosticarea defectelor în rulmenți, care vor detecta patternul de degradare din vibrațiile măsurate de senzori și vor efectua în final o clasificare după tipurile de defect etichetate în setul de antrenare.

Metoda prezentată este pentru anomalii punctiforme - purtând defecte în fazele incipiente și nu poate fi utilizată pentru anomalii de grup. Se concentrează, de asemenea, pe detectarea anomaliilor din surse de date unice, nu din surse de date eterogene multiple.


Studiul testează mai multe rețele neuronale pe setul de date open-source CWRU (Case Western Reserve University), folosind serii de timp multivariate.

S-au testat: rețelele neuronale profunde (DNN) compuse din straturi complet conectate, rețelele neuronale convoluționale (CNN) definite de grupuri variate de straturi convoluționale și straturi de *pooling* (restrângere), rețelele neuronale recurente (RNN), rețelele neuronale recurente pe termen lung (LSTM) construite pe straturi recurente și rețele hibride - combinații de RNN și LSTM cu convoluții. Toate modelele sunt evaluate și comparate.

În cele din urmă, studiul obține cele mai bune rezultate pe rețelele RNN îmbunătățite cu convoluții și apoi prin media rezultatului cu cel de-al doilea cel mai bun model obținut (CNN), obține o precizie în setul de date de testare de 98,50%.

Metoda captează dinamica vibrațiilor ambilor rulmenți din două serii de timp simultane și dependența între cele două serii, având o etichetare mai complexă, pentru predicții mai fiabile.

Pentru a valida această metodologie de diagnosticare bazată pe rețele neuronale de învățare profundă, am folosit date furnizate de *Case Western Reserve University* (CWRU - <https://csegroups.case.edu/bearingdatacenter/pages/12k-drive-end-bearing-fault-data>), provenind de la senzorii de vibrație montați pe un motor într-un stand experimental (Fig. 12).



**Fig. 12.** Standul experimental CWRU

Standul utilizat pentru achiziționarea setului de date de la rulmenți constă dintr-un motor electric de 2 CP (1), un traductor de cuplu (2), un dinamometru (3) și un modul electronic de control. Rulmenții de testare susțin arborele motorului. Au fost introduse defecțiuni punctuale, utilizându-se o mașină cu descărcări electrice la rulmentul de testare (B1), cu diametre de defect de 0,007” și 0,021” la două viteze de rotații diferite: 1797 rot/min, sarcină motor (CP) 0 și 1772 rot/min, sarcină motor (CP) 1.

Defectele în inelul exterior sunt defecte staționare deoarece inelul exterior este fix. Ca rezultat, plasarea defectului relativ la zona de încărcare a lagărului are implicații directe asupra răspunsului vibrațional al sistemului. Rulmentul capătului de acționare DE(B1) are defecte în inelul exterior, situate în zona de încărcare în poziția orei 6, la ora 3 (ortogonal față de zona de încărcare) și la ora 12 (opus zonei de încărcare) (Fig. 13).

Au fost plasate de asemenea defecte punctuale de 0,007” și 0,021” în rulmentul B1, în inelul interior și în role.




**Fig. 13.** Plasarea defectelor relativ la zona de încărcare (6), opus zonei de încărcare (12) și ortogonal acesteia (3).

Toate seturile de date au fost colectate folosind accelerometre atașate la carcasa motorului pe bază magnetică și plasate în poziția orei 12, atât la capătul de acționare DE(B1) la rulmentul B1, cât și la capătul ventilatorului FE(B2) la rulmentul B2, pentru fiecare viteză de rotație. Datele au fost colectate la o rată de eșantionare (*sampling rate*) de 12.000 de probe/secundă pentru ambii rulmenți.

Rulmentul B2 de la capătul ventilatorului este considerat normal, fără defecte în studiu, dar modelul propus ar putea foarte bine să modeleze și defecte în B2, ceea ce implică adăugarea



mai multor etichete, indicative ale defectelor capătului ventilatorului (B2), la eșantioanele furnizate.



**Fig. 14.** Patru scenarii de nealiniere care pot cauza defecțiuni în rulmenți:

- a. Arbore nealiniat, b. Arbore curbat, c. Inel exterior inclinat, d. defect în inelul interior

	B1	B2
0	-0.277602	0.040885
1	-0.044345	0.069855
2	0.117603	0.337767
3	-0.145055	0.251682
4	-0.111430	0.108891
...	...	...

**Fig. 15.** Setul de date [mV/g] cu defect în inelul interior în rulmentul (B1), diametru defect 0,007” și rulment capăt ventilator (B2) normal, sarcină 1

Seturile de date care cuprind accelerațiile rulmenților de la capătul de acționare (B1) și capătul ventilatorului (B2) sunt luate în considerare separat, pentru două diametre de defect, 0,007” și 0,021”, în două cazuri diferite de sarcină - încărcare motor 0 CP și încărcare motor 1 CP, pentru 5 tipuri de defect. Seturile conține defecte în cursa interioară, defecte în role și 3 tipuri de defect în cursa exterioară: centrat, ortogonal, respectiv opus zonei de încărcare. De asemenea, s-au considerat două seturi de date pentru comportamentul normal, la fiecare sarcină, rezultând în final 11 clase /etichete (Tabel 2).

Aceasta înseamnă că studiul se va face pentru fiecare sarcină în parte (sarcină 0 și sarcină 1) folosind 11 seturi de date fiecare (11 serii de timp), un total de 22 de seturi de date furnizate de CWRU:

- două seturi de date pentru comportamentul normal al rulmenților, fără defect, pentru fiecare sarcină, cinci seturi de date pentru cele cinci tipuri de defecte, cu diametru defect 0,007”, la sarcina 0, cinci seturi de date pentru aceleași cinci tipuri de defecte, dar având 0,021” diametru defect, la sarcina 0, cinci seturi de date pentru cele cinci tipuri de defecte, cu diametru 0,007”, la sarcina 1 și cinci seturi de date pentru cele cinci tipuri de defecte la diametru de 0,021” și încărcare 1. Fiecare set de date va fi etichetat, în fiecare caz de încărcare, conform tabelului 2.

**Tabelul 2.** Seturile etichetate la sarcină 0

Tip date (B1)	Tip date (B2)	Nr. Eșantioane (B1, B2)	Etichetă
Normal	Normal	243938	Eticheta 0
Defect în cursa interioară 0,007”	Normal	121265	Eticheta 1
Defect în cursa exterioră centrat 0,007”	Normal	121991	Eticheta 2
Defect în cursa exterioră ortogonal 0,007 ”	Normal	122281	Eticheta 3
Defect în cursa exterioră opus 0,007”	Normal	122281	Eticheta 4
Defect în role 0,007”	Normal	122571	Eticheta 5
Defect în cursa interioară 0,021”	Normal	122136	Eticheta 6
Defect în cursa exterioră centrat 0,021”	Normal	122426	Eticheta 7
Defect în cursa exterioră ortogonal 0,021”	Normal	121701	Eticheta 8
Defect în cursa exterioră opus 0,021”	Normal	121846	Eticheta 9
Defect în role 0,021”	Normal	121991	Eticheta 10

Seriile de timp vor fi, în continuare, segmentate în eșantioane spre a fi furnizate modelelor propuse. Trebuie să cunoaștem lungimea seriilor de timp. Numărul total de date înregistrate de accelerometre în seturile de date originale, poate fi observat în Tabelul 5.23. Un total de 1464427 de eșantioane, incluse în toate cele 11 fișiere, vor constitui dimensiunea buffer-ului din setul de date din studiul pentru sarcina 0.

La sarcina 0, turația motorului este 1797 rot/min (RPM) și deoarece rata de eșantionare este de 12000/s, înseamnă că 12000 de date punctuale sunt înregistrate într-o secundă și avem o turație de 30 rot/s, cu 400 de puncte de date conținute într-o perioadă de rotație. La sarcină 1, viteza de rotație este 1772 rot/min (RPM), la aceeași rată de eșantionare, aceasta înseamnă 29,53 rot/s, deci pentru ambele cazuri viteza de rotație va fi aproximată la 30 de rot/s.

S-au format serii de timp multivariate, luându-se în considerare secvențe paralele de date furnizate de accelerometre montate pe B1 și B2 (Fig. 16):

$$\begin{matrix} \vdots \\ B1 & B2 \\ \vdots \end{matrix}$$

**Fig.16.** Compunerea seriei de timp multivariate  
(serie de două variabile, o variabilă din B1 și o variabilă din B2)

Fiecare dintre cele 11 serii de timp multivariate vor fi împărțite în trei părți (70%, 15%, 15%) și apoi părțile seriilor vor fi concatenate. Primele părți de 70% din fiecare serie de timp vor fi concatenate pentru a obține setul de date de antrenament, următoarele 15% părți sunt concatenate pentru a forma setul de date de validare și respectiv ultimele 15% părți din toate cele 11 serii de timp vor fi concatenate pentru a compune setul de testare.

Setul de validare va ajuta la prevenirea supra-antrenării (*overfittingului*) setului de antrenament pe parcursul epocilor de antrenare și la definirea celei mai bune rețele neuronale.

Setul de date de testare va fi utilizat pentru a calcula acuratețea clasificării modelului.

După pregătirea celor trei seturi de date s-a efectuat o segmentare a datelor prin împărțirea lor în loturi secvențiale de sfert de rotație, constând în ferestre de 100 de puncte de date care au fost servite modelului ca vectori bidimensionali de caracteristici, în tensori de lungime 100, prin utilizarea unei funcții de segmentare.

La tensorul de lungime 100, funcția va mapa eticheta, care este un alt tensor de lungime 11, marcând clasele (o clasă pentru normal și zece clase pentru defecte), obținute printr-o codificare *one hot* a etichetelor.

Funcția va amesteca eșantioanele astfel formate și va forma loturi de 20 de tensori de acest tip (Fig. 17):

$$\langle \text{tf.Tensor: shape} = (20,100,2)\rangle, \langle \text{tf.Tensor: shape} = (20,11) \rangle$$

$$\begin{array}{ccc} [[B_1, B_2], \dots, [B_1, B_2]], & & [[L_0, L_1, \dots, L_{10}], \\ \vdots & & \vdots \\ [[B_1, B_2], \dots, [B_1, B_2]], & & [[L_0, L_1, \dots, L_{10}]] \end{array}$$

**Fig. 17.** Un lot de 20 de tensori – Segmentarea setului de date bidimensional în tensori bidimensionali, de lungime 100

Această segmentare a setului de date bidimensional va alimenta modelele CNN, RNN, RNN-CNN, LSTM-CNN, LSTM propuse în studiu, toate acceptând o intrare multidimensională, loturi de 100 de tensori bidimensionali. Aceste modele vor potrivi un total de 100+100 caracteristici unei singure etichete.

Se va antrena și un model DNN, în acest caz reducându-se bidimensionalitatea printr-o concatenare a celor două segmente provenite de la cei doi senzori, datorită intrării unidimensionale acceptate de rețeaua DNN, obținându-se un tensor unidimensional de 200 de puncte.

$[L_0, L_1, \dots, L_{10}]$  este codificarea vectorială *one hot* a etichetei,

$[L_0, L_1, \dots, L_{10}] = [1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]$  înseamnă reprezentarea stării normale, clasa 0, fără defecte, având 1 în prima poziție a vectorului, la indexul 0.

$[L_0, L_1, \dots, L_{10}] = [0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0]$  reprezintă defectul în rolă de 0,007", care este clasa 5, având 1 pe 6 -a poziție, la indexul 5 al vectorului.

Când apar defecte locale în inelul exterior/ interior și în elementul de rulare (fisuri, scobituri), interacțiunea dintre calea de rulare și elementul de rulare are ca rezultat forțe de contact discontinue, variabile în timp și neuniforme, care generează o semnătură specifică în semnalul vibrațional.

S-a putut observa semnătura vibrațiilor specifice fiecărui tip de defect și dimensiune și modul în care defectul unui rulment induce vibrații în al doilea rulment fără defect, prin arbore. Pentru fiecare sarcină s-a încercat definirea și instruirea mai multor modele.

Pentru unele modele a fost necesară o schimbare în structură, un număr mai mare de straturi sau un număr mai mare de epoci de antrenament, la trecerea de la sarcina 0 la sarcina 1, pentru a obține rezultate comparabile, dar cele mai bune modele au funcționat la fel pentru ambele cazuri.

Funcția obiectiv (numită funcție *Cost* sau *Loss*) utilizată pentru toate modelele propuse a fost Entropia încrucișată categorică (*Categorical Cross Entropy*) care calculează pierderea unui eșantion prin calcularea următoarei sume:

$$\begin{aligned} C(y_i, \hat{y}_i) &= \text{Entropia încrucișată categorică} \\ &= - \sum_{i=1}^{\text{dimensiune ieșirii} = 11} y_i \cdot \log \hat{y}_i \end{aligned} \quad (3)$$

unde  $\hat{y}_i$  este valoarea scalară de pe poziția  $i$  (a nodului  $i$ ) prezisă în ieșirea modelului,  $y_i$  este valoarea țintă (reală) corespunzătoare, iar dimensiunea ieșirii este numărul valorilor scalare din ieșirea modelului (11 valori pentru 11 clase).

Scopul este de a minimiza funcția obiectiv  $C$ , utilizând metoda de coborâre gradientală. Deplasarea către minim este determinată de gradientul funcției obiectiv:

$$\nabla C = \left( \frac{\partial C}{\partial \omega_1}, \frac{\partial C}{\partial \omega_2}, \dots, \frac{\partial C}{\partial \omega_n}, \frac{\partial C}{\partial b} \right) \quad (4)$$

Metoda iterativă de optimizare a funcției obiectiv a fost realizată cu optimizatorul *Adam* în locul optimizatorului *Stochastic Gradient Descend* (SGD), care a obținut rezultate mai bune. Optimizatorul *Adam* calculează pași de coborâre gradientală (learning rates) individuali,

adaptiv, pentru fiecare pondere în parte, pe care o adaptează separat la fiecare epocă (6), învățarea fiind îmbunătățită, în timp ce SGD menține o rată de învățare – un pas de coborâre unic (alfa), pentru toate actualizările de ponderi și nu îl schimbă în timpul antrenamentului.

Funcția de activare aleasă în ultimul strat de ieșire este în toate modelele funcția *Softmax*, deoarece în acest caz am vrut să prezicem doar un defect în fiecare eșantion, seturile de date din studiu conținând un singur tip de defect.

Cu funcția *Softmax*, probabilitatea  $P(c_j|x_i)$  a unei clase  $c_j$  (unde  $c_j \in \{0,1,\dots, 10\}$ ), dat fiind eșantionul  $x_i$  (care este un tensor), este dependentă de probabilitățile celorlalte clase, ca în formula (5) :

$$P(c_j|x_i) = \frac{e^{z_j}}{\sum_{k=0}^{10} e^{z_k}} \quad (5)$$

unde  $z_j = \sum \omega_{ij}a_i + b_j$  este suma combinației liniare a activărilor din stratul anterior și a bias-ului unității  $j$  din stratul final.

În teste ulterioare, schimbarea funcției de activare cu funcția *sigmoid*, în ultimul strat, pentru predicția mai multor defecte simultane, a dat predicții la fel de bune.

Pentru studiul realizat în Python, au fost utilizate: bibliotecile TensorFlow 2.0 și NumPy pentru calcul științific, Matplotlib Pyplot pentru afișarea grafică a datelor, Pandas pentru citirea fișierelor csv și compunerea setului de date în DataFrame, sklearn pentru metrici și Keras pentru definirea modelelor de învățare profundă.

Toate modelele au fost instruite mai întâi pe 100 de epoci pentru a selecta cea mai bună rată de învățare - cel mai bun *learning rate* pentru aflarea dimensiunii pasului inițial de coborâre gradientală pentru optimizatorul Adam.

O funcție *callback* a fost utilizată pentru calcularea celui mai bun *learning rate*, notată cu *lr\_schedule*, care diminuează pierderea cel mai bine, valoarea acestuia fiind ajustată la fiecare epocă conform formulei (7).

*lr\_schedule* este un hiperparametru configurabil, controlează viteza cu care învață modelul, este pasul de deplasare către minim a funcției obiectiv la fiecare iterație, prin actualizarea ponderilor după formulele (5.9):

$$\begin{aligned} \omega &= \omega + lr\_schedule \frac{\partial C}{\partial \omega} \\ \mathbf{b} &= \mathbf{b} + lr\_schedule \frac{\partial C}{\partial \mathbf{b}} \end{aligned} \quad (6)$$

Pentru alegerea celui mai bun *learning rate* s-a efectuat o reprezentare grafică a acestuia în funcție de valoarea pierderii obținute la fiecare epocă și s-a ales cea valoare *lr\_schedule* care minimizează cel mai mult pierderea (Loss), conform formulei (7).

$$lr\_schedule = tf.keras.callbacks.LearningRateScheduler ( \lambda epoch: 1e-7 * 10^{**}(epochs / 20)) \quad (7)$$

Cele 6 modele construite pentru ambele cazuri de sarcină vor avea ca metrici de evaluare: acuratețea categorică (raportul între numărul de eșantioane prezis corect și numărul total de eșantioane), pierderea și scorul F1.

### Modelul RNNCNN – Rețea Neuronală Recurentă cu Convoluții

S-a construit un model RNNCNN prin alternarea a două secvențe formate din două straturi recurente și două convoluții 1D. Primele două convoluții au un strat de *max-pooling* care restrânge de 3 trei ori cantitatea de parametri și următoarele două convoluții din a doua secvență RNN sunt urmate de un strat de restrângere globală, *global average pooling*, urmate de un ultim strat dens cu 11 unități neuronale, pentru predicția celor 11 clase.

S-au utilizat 12 filtre cu un nucleu de 5 pentru fiecare convoluție și s-a schimbat numărul de celule de memorie de la 100 la 50, deoarece 100 de celule au supra-antrenat modelul. Rezultatele obținute au fost remarcabile.

După selectarea celui mai bun *learning rate* de start, de  $1e-5$  la sarcina 1 (Fig. 5.84) și  $7e-5$  la sarcina 0, modelul a fost antrenat pe o perioadă de 1000 de epoci în ambele cazuri. O acuratețe totală de 99,75% a fost obținută pe setul de antrenare, respectiv de 98,40% pe setul de validare, la sarcina 0 și o acuratețe totală de 100% pe setul de antrenare și 96,62% pe setul de validare, la sarcina 1.

La evaluarea pe setul de testare, o acuratețe foarte bună de 98,54% s-a atins la sarcina 0, respectiv 97,33% la sarcina 1, acest rezultat depășind toate celelalte modele testate. Recunoașterea defectului de diametru 0,007" în rolă - Eticheta 5 - a fost îmbunătățită, obținându-se un Recall de 87% la sarcina 1 și 99% la sarcina 0 (Tabelul 3).

**Tabelul 3.** Raport de clasificare Model RNNCNN, pe setul de testare, sarcină 0 și sarcină 1

Eticheta	Precizie sarcina 0	Recall sarcina 0	F1 sarcina 0	Precizie sarcina 1	Recall Sarcina 1	F1 Sarcina 1
Eticheta 0	1.00	1.00	1.00	1.00	1.00	1.00
Eticheta 1	1.00	0.99	1.00	1.00	1.00	1.00
Eticheta 2	0.99	0.97	0.98	0.99	0.96	0.97
Eticheta 3	1.00	1.00	1.00	1.00	0.98	0.99
Eticheta 4	0.99	0.96	0.98	0.95	0.96	0.96
Eticheta 5	1.00	0.99	0.99	0.93	0.87	0.90
Eticheta 6	0.99	0.97	0.98	0.98	0.99	0.99
Eticheta 7	0.93	0.98	0.95	0.95	0.98	0.96
Eticheta 8	0.97	1.00	0.99	0.99	0.99	0.99
Eticheta 9	1.00	0.96	0.98	0.99	0.98	0.99
Eticheta 10	0.95	1.00	0.97	0.86	0.91	0.88
Acuratețe		sarcina 0	0.985		sarcina 1	0.973
F1		sarcina 0	0.99		sarcina 1	0.98

Precizia, de asemenea, pentru Eticheta 5 este de 93% la sarcina 1, ceea ce înseamnă că 93% din predicțiile totale pentru Eticheta 5 sunt adevărate, matricea de confuzie ilustrând, de asemenea, acest rezultat în Fig. 18 (158 probe corect detectate și 11 alocate altor clase).

Predicted	0	1	2	3	4	5	6	7	8	9	10
Actual											
0	725	0	0	0	0	0	0	0	0	0	0
1	0	182	0	0	0	0	0	0	0	0	0
2	0	0	175	0	3	1	0	2	0	0	2
3	0	0	0	179	0	0	3	0	0	0	0
4	0	0	0	0	175	0	0	5	0	0	2
5	0	0	0	0	0	158	0	0	0	1	23
6	0	0	0	0	0	0	181	0	0	0	1
7	0	0	2	0	0	0	0	178	1	1	0
8	0	0	0	0	0	0	0	2	180	0	0
9	0	0	0	0	0	2	0	1	0	180	0
10	0	0	0	0	6	9	1	0	0	0	166

**Fig. 18.** Matricea de confuzie pe setul de testare în modelul RNNCNN la sarcină 1

Performanțele cele mai mari au fost obținute de modelele RNNCNN și CNN, conform rezumatului scorurilor din Tabelul 3.

O funcție în Python este scrisă, pentru a face o medie ponderată *elementwise* între predicțiile modelelor pentru fiecare clasă, încercându-se încă o îmbunătățire a scorului. Funcția ia ca argument o matrice care conține cele mai bune modele și setul de testare.

**Tabelul 3.** Sumarul Modelelor

Modelul	Acuratețe totală pe setul de testare sarcina 0	F1 pe setul de testare sarcina 0	Acuratețe totală pe setul de testare sarcina 1	F1 pe setul de testare sarcina 1
1. CNN	94%	0,96	92%	0,94
2. DNN	89%	0,93	79%	0,82
3. RNN	90%	0,94	89%	0,91
4. RNNCNN	98,50%	0,99	97,35%	0,98
5. LSTM	79%	0,85	66%	0,68
6. LSTMCNN	86,61%	0,91	82,29%	0,85

La sarcina 0, modelul de mediere a obținut acuratețe maximă de 97,94% și un scor F1 = 0,987 prin medierea modelelor CNN și RNNCNN, fără a declassa RNNCNN, iar la sarcină 1, modelul mediat a îmbunătățit predicția cu aproximativ 1%, ajungând în final la o acuratețe de 98,19% (Tabel 4).

**Tabelul 4.** Sumarul celor mai bune modele

Cele mai bun modele	Acuratețe Set testare sarcina 0	F1 Set testare sarcina 0	Acuratețe Set testare sarcina 1	F1 Set testare sarcina 1
RNNCNN	98,50%	0.990	97,35%	0.980
Modelul de mediere (CNN, RNNCNN)	97,94%	0.987	98,19%	0.987

## Contribuții originale

Contribuțiile originale sunt structurate în conformitate cu obiectivele tezei, fixate în primul capitol al prezentei lucrări. Principala contribuție a cercetărilor realizate în cadrul tezei constă în concepția și dezvoltarea unei platforme colaborative web-based pentru managementul mentenanței, un instrument CMMS care să gestioneze mai multe tipuri de mentenanță: reactivă, predictivă, mentenanță bazată pe monitorizarea stării și mentenanță predictivă.

În această cercetare s-a reușit concepția, dezvoltarea și implementarea cu succes a platformei web-based IOTIA care integrează o serie de studii pentru identificarea metodelor bazate pe învățare automată pentru diagnosticarea și prognosticarea stării echipamentelor monitorizate și detectarea anomaliei. Munca de cercetare pe parcursul anilor de studiu doctoral nu a constatat însă doar în realizarea platformei, ci și în parcurgerea stadiului actual în domeniu, analiza conceptelor matematice care stau la baza algoritmilor de inteligență artificială, analiza metodelor tradiționale de analiză statistică a datelor pentru identificarea anomaliei, diagnosticare și prognosticare, dar și a metodelor moderne care înglobează inteligența artificială și tehnologia IoT, pentru diagnosticare, prognosticare cu tehnici de ML și DL și prognoză cu diverse metode de predicția eșecului și estimarea RUL a unui echipament /componentă.

Astfel, principalele contribuții personale ale tezei bazate pe obiectivele secundare teoretice, conceptuale și de analiză înglobate în realizarea platformei sunt următoarele:

1. S-au realizat analize conceptuale privind soluțiile pentru fabrica inteligentă în contextul Industriei 4.0, în special sistemul cyber-fizic și arhitectura sistemului CPS ce ar permite

realizarea unei interfețe CMMS capabile să se conecteze și să comunice la toate nivelurile acestuia. Scopul cercetării a fost alegerea unei arhitecturi pentru sistemul CPS pe baza căruia platforma de mentenanță dezvoltată în teză să poată fi implementată.

2. S-au analizat soluțiile specifice generațiilor de mentenanță de a lungul timpului și s-au prezentat tehnicile de mentenanță din cadrul lor. S-a studiat evoluția conceptului de mentenanță, prezentându-se principalele tipuri de mentenanță ce pot fi aplicate în Industria 4.0 precum și limitările acestora. Scopul acestor cercetări a fost identificarea conceptelor de mentenanță aplicate în Industria 4.0 și care pot fi integrate în platforma IOTIA precum și modificările necesare pentru a elimina unele limitări ale acestora.
3. S-au analizat metodele actuale bazate pe învățare automată, folosind algoritmi de inteligență artificială de ML sau DL, dar și metode statistice pentru detectarea anomaliei în datele monitorizate provenite de la măsurătorile senzorilor. Scopul cercetării a fost selectarea unor metode pentru detectarea anomaliei în funcție de particularitățile ce pot fi întâlnite în industrie, în scopul utilizării în platformă: unele metode necesită resurse mai mari pentru calcul și sunt mai sensibile la zgomot, alte metode depind de dimensiunea setului de antrenare și dau rezultate atunci când avem un număr mare de eșantioane, mai mare decât numărul de caracteristici, în timp ce alte metode se scalează bine pentru valori mari ale numărului de caracteristici. Unele metode necesită etichetarea datelor (date purtătoare de anomalie și date normale) și pot fi adoptate atunci când în setul de antrenare avem un număr suficient de mare de anomalii, alte metode bazate pe învățarea nesupravegheată, cum ar fi rețelele de tip Autoencoder, nu utilizează date etichetate pentru a face o clasificare, ci folosesc antrenarea modelului pe un echipament fără uzură (nu avem anomalii), pentru a putea mai târziu detecta deviațiile când echipamentul începe să se degradeze.
4. Au fost investigate performanțele și limitările tehnicilor moderne de diagnosticare a defectiunilor cu algoritmi care pe lângă detectarea anomaliei detectează și cauza, folosind abordarea bazată pe date și abordarea bazată pe model. În abordarea bazată pe date, cu o mai largă aplicabilitate în sfera industrială, s-au studiat tehnici de diagnosticare prin clasificare bazate pe algoritmi de machine learning tradiționali și algoritmi de deep learning. Finalitatea acestor cercetări a fost selectarea algoritmilor moderni de DL într-o mare măsură pentru diagnosticarea defectelor în cadrul platformei IOTIA, deoarece au o putere de reprezentare superioară comparativ cu algoritmi tradiționali de ML și capacitate de extragere și selectare automată a caracteristicilor reprezentative din setul de date monitorizat. În acest sens, în Capitolul 5 s-a efectuat un studiu de caz pentru diagnosticarea defectelor incipiente în rulmenți cu algoritmi de deep learning, prin analiza vibrațiilor. S-au utilizat datele brute transmise de senzori (acelerații), iar caracteristicile au fost extrase direct de rețelele neuronale
5. Au fost realizate o serie de cercetări pentru selecția tehnicilor de predicție RUL folosind ML și DL adecvate pentru dezvoltarea platformei propuse. Pentru predicția timpului util rămas al echipamentelor s-au prezentat mai multe tehnici de prognoză în paragraful 3.4.2 al Capitolului 3 care se bazează pe trei abordări: abordarea bazată pe model, abordarea bazată pe experiență și abordarea bazată pe date. Finalitatea cercetărilor acestor tehnici a fost selectarea lor pentru a fi înglobate în concepția platformei și utilizate în funcție de cazurile din industrie. Metodele DL de estimare directă RUL sunt foarte la îndemână atunci când avem un istoric bogat al evoluției până la eșec al unui număr mare de echipamente/componente similare din care modelele neuronale DL sunt capabile să învețe diferite paternuri de eșec specifice diverselor stadii de uzură. Dar pentru implementarea acestor modele este nevoie de arhivarea unor cantități imense de date pe o durată mare de

timp (ani), de la mai multe surse similare și cunoașterea stării de degradare a eșantioanelor istorice (RUL) în momentul arhivării istorice. Acest lucru este valabil și pentru modelele de similaritate care estimează RUL după similaritatea traiectoriilor de degradare ale instanțelor istorice. Metoda necesită calcularea indicatorului de stare pe baza stării de degradare  $RUL/max\_RUL$  și construirea modelului de degradare pentru fiecare instanță cu metode statistice. Modelele de similaritate a traiectoriei de degradare se aplică acelor sisteme asupra cărora se efectuează prea puțină mentenanță, modelele intuind paternul complet de rulare până la degradarea completă a sistemului (rulare până la eșec). De asemenea, în cazurile în care nu avem un istoric complet de rulare până la eșec, dar cunoaștem durata de viață a componentelor similare, se pot alege metodele tradiționale de modelare a supraviețuirii care modelează timpul de eșec al componentei din datele istorice (componente similare din flotă), funcție doar de numărul de ore de operare sau eventual și de caracteristicile de stare ale mașinii (regim de operare, lot de fabricație s.a.) utilizând funcții de hazard.

Din perspectiva concepției și dezvoltării efective a platformei CMMS pentru managementul mentenanței teza înglobează o serie de contribuții originale după cum urmează:

6. Realizarea unei structuri modulare, astfel încât serviciile platformei să poată fi accesate în funcție de dimensiunea întreprinderii și strategiile de mentenanță pe care le adoptă. Modulele de Mentenanță Preventivă, Predictivă și Mentenanță bazată pe monitorizarea stării sunt construite separat în structura Model / View / Controller a aplicației și pot fi activate independent în funcție de nevoile întreprinderii. Configuratorul, Baza Tehnică, modulul Utilități și cel de Setup sunt module de bază care se vor regăsi în componența de bază a platformei. Platforma poate configura și gestiona unul sau mai multe puncte de lucru cu una sau mai multe linii de producție.
7. Realizarea unui configurator al activelor pe liniile de producție după o structură modulară - componente/subansambluri/mașini. Cu ajutorul configuratorului, se pot instanția cu ușurință echipamentele dintr-una sau mai multe fabrici, doar selectând și adăugând echipamentul configurat. Se obține o vizualizare mult mai bună a procesului de mentenanță cât și monitorizarea echipamentului la nivel de componentă și subansamblu, nu doar la nivel de mașină. Istoricul operațiilor de mentenanță și rapoartele generate sunt evidențiate la nivel de cod mașină, cod subansamblu, cod componentă.
8. Realizarea unui configurator al liniilor de producție în cadrul unei întreprinderi. Se definesc cu ușurință liniile de producție, se adaugă echipamentele prin selectare, odată ce structura activelor este definită deja în configurator. Prin selectarea unei linii de producție se obține o vizualizare rapidă a statusului real al tuturor mașinilor de pe linie, prin citirea stării echipamentelor transmisă de PLC-uri și afișată în interfața utilizator.
9. Realizarea unui sistem de management al pieselor de schimb și al consumabilelor. Fiecare entitate de pe linia de producție (mașină, subansamblu sau componentă) este identificată printr-un ID unic. Istoricul operațiilor de înlocuire componente (la avarie sau înlocuire planificată) cât și al operațiilor de întreținere echipamente construiește o evidență clară asupra mișcării fluxurilor de consumabile din cadrul întreprinderii, deoarece în cadrul fiecărei fișe de operațiune, tehnicianul marchează consumabilele utilizate (cantități) sau/și piesele de schimb la înlocuire.
10. Generarea și planificarea intervențiilor de mentenanță, a inspecțiilor și intervențiilor corective, planificarea echipelor de mentenanță, rapoarte legate de intervențiile preventive



și operațiunile acestora, pontaj automat al forței de muncă corelat cu timpii de lucru ai tehnicienilor într-un sistem integrat.

Directorul de mentenanță deține o situație exactă a desfășurătorului intervențiilor din întreprindere, prin evidența furnizată de Generatorul de Intervenții. Generatorul va crea automat la data exactă, conform setării din Configurator, intervenția ce trebuie efectuată pe fiecare mașină, cu o fereastră de avertizare. Intervenția poate fi compusă din una sau mai multe operațiuni definite pe subansamblele mașinii și afișează termenul limită scadent. Aplicația permite atribuirea echipelor pentru fiecare intervenție în parte, asignarea tehnicienilor pentru fiecare operațiune cât și a supervisorilor. Operarea sarcinilor programate din cadrul intervențiilor, prin instrumentele incluse în modulul Mentenanță, generează rapoarte multiple legate de activitățile întreprinse de personal în intervalele de timp prin fișele de pontaj, completarea fișelor de operațiuni, ticket-urile trimise cu diverse solicitări către departamente, prin istoricul discuțiilor și fișierelor atașate în cadrul activităților, prin istoricul acțiunilor efectuate în platformă captate în subsecțiunea Activități, prin istoricul sesiunilor de instruire și feedback-urile online provenite din chestionare. Se generează rapoarte asupra activelor, cu operațiuni întreprinse pe echipament sau subansamblu, în intervale de timp, care împreună cu rapoartele de stare obținute prin monitorizarea unor parametri de stare completează jurnalul de stare al activelor. În cazul avariilor sau la inspecții, fișele de inspecție completate de tehnicieni generează intervențiile corective ce trebuie efectuate, cu toate operațiunile necesare.

11. O vizualizare complexă a intervenției; orice intervenție oferă prin informațiile stocate vederi din mai multe perspective: stare, costuri, performanța echipelor. Sumarul intervenției conține o ilustrare grafică a statusului și date legate de performanță, structura arborescentă a operațiilor și fișele descriptive de operațiuni cu statusurile lor, diagrama Gantt a intervenției, tickete trimise către departamente, cheltuielile, librăria de fișiere și arhiva de discuții generată de echipa de intervenție. Această structură conferă o vedere mai clară asupra activității de mentenanță.
12. Monitorizarea online a activelor printr-un sistem de preluare a datelor de mari dimensiuni în cloud și implementarea unor algoritmi de detectare a anomaliei, trimiterea și afișarea de alarme.  
Sistemul de monitorizare permite o vizualizare activă a statusului echipamentului, prin afișarea parametrilor monitorizați cu ajutorul panel-urilor grafice Grafana. Se obțin totodată informații istorice ale activului, prin afișarea tuturor intervențiilor efectuate și a rapoartelor de stare privind orele de funcționare/nefuncționare. Datele acumulate la acest nivel de la PLC-uri și de la senzorii adiționali montați sunt preluate de algoritmi de detectare a anomaliei pentru evaluarea stării de normalitate și transmiterea de alarme, în cazul identificării unor anomalii. Platforma implementează algoritmi de detectare a anomaliei prin învățare nesupervizată cu rețele neuronale de tip Autoencoder, prin clasificare folosind rețelele neuronale feedforward cu învățare supravegheată sau poate implementa modelul statistic al distribuției gaussiene, în funcție de cazurile din industrie.
13. Aplicație pentru tabletă care implementează tehnologie AR pentru identificarea rapidă a subansamblelor, trimiterea și primirea informațiilor legate de istoricul de mentenanță când tehnicienii sunt aflați pe teren pentru inspecții tehnice sau efectuarea de intervenții.
14. Integrarea aplicațiilor de mentenanță predictivă și preventivă cu procesele fizice de operare efectivă a mentenanței, prin transmiterea și înregistrarea directă de pe teren a informațiilor, prin intermediul echipei de tehnicieni. Prin implementarea unor coduri pe subansambluri și mașini, ce sunt ușor scanate și identificate de tehnicieni în timpul intervențiilor, se accesează toate informațiile necesare privind starea și istoricul de mentenanță, împreună

cu documentația tehnică aferentă. În același timp, se transmit informații către sistemul CMMS și se construiește un istoric al operațiunilor și o librărie de cazuri concrete de defecțiuni. Librăria de Discuții integrată în intervenții (modulul mentenanță) poate crea în timp o bază solidă de răspunsuri prin implementarea algoritmilor AI, atunci când se cercetează cauza în diagnosticarea unor defecțiuni sau se caută informații cu privire la efectuarea unor operații de mentenanță.

15. Integrarea unei soluții de videoconferință pentru suport la distanță, accesată de aplicația CMMS desktop, aplicația tabletă sau ochelarii AR.  
Sistemul de videoconferință este un mijloc de comunicare între tehnicienii de pe teren și supervizori și este integrat și de ochelarii AR pentru confort în timpul inspecțiilor sau intervențiilor.
16. Suport de ticketing pentru departamentele întreprinderii. Sistemul de ticketing integrat în platformă generează o comunicare mai bună între departamentele de mentenanță, producție și achiziție, pentru rezolvarea rapidă a urgențelor legate de comenzile de consumabile, piese de schimb, interogare stocuri, s.a. Acesta va putea fi ulterior extins și către furnizori, pentru o mai bună implementare pe orizontală a întreprinderii.
17. Librării tehnice accesate la nivel de componentă/ subansamblu/ mașină/ operațiune mentenanță, în diverse formate (documente electronice sau video). Sistemul propus adună librării de documentații tehnice la mai multe niveluri. Există librării de fișiere construite în Configurator și Baza Tehnică a platformei CMMS, de către administratorii acestor module, care au drepturi de creare/editare. S-au implementat librării construite de utilizatori, în modulul de Mentenanță - secțiunile Fișiere, Discuții și Fișe de operațiuni, unde aceștia pot atașa diverse formate de fișiere disponibile tuturor celor care au drepturi de acces în secțiuni. Există librării de documente personale, accesibile doar utilizatorului logat, în modulul Utilități - secțiunea Librăria de fișiere.
18. Urmărirea cheltuielilor legate de mentenanță prin contabilizarea detaliată a costului intervențiilor. Sistemul implementat permite un mod flexibil de calcul al cheltuielilor legate de operațiunile de mentenanță și cheltuielile cu forța de muncă pentru fiecare intervenție și operațiunile constituente în parte. Sistemul cuantifică cheltuielile cu forța de muncă pentru realizarea intervențiilor de mentenanță, stabilite de fișele de pontaj și timpii de lucru marcați în sistem, cheltuielile cu piesele de schimb și consumabilele și alte tipuri de cheltuieli existente în întreprindere pentru realizarea mentenanței și desfășurarea proceselor. Acest sistem permite raportare detaliată legată de costuri la nivel de componentă / subansamblu / mașină / operațiune / intervenție / linie de producție / tehnician / fabrică.
19. Implementarea unei librării de modele predictive programate în Python și integrate în fișiere Jupyter Notebook.
20. Realizarea unui studiu de caz pentru prognoza eșecului unei componente într-o fereastră de timp. Studiul de caz prezentat în Capitolul 5, la paragraful 5.2.7.1, efectuează prognosticul componentei în sisteme supuse mentenanței preventive, în cadrul unui proces regulat de înlocuire componente. De aceea, metoda prezentată nu este o estimare RUL, este o metodă de prognostic a eșecului componentei într-o fereastră de timp și s-a considerat că poate fi o metodă ce poate fi integrată la mai multe companii industriale.
21. Realizarea unui studiu de caz pentru diagnosticul defectelor în rulmenți utilizând mai mulți algoritmi de deep learning. Studiul de caz prezentat în Capitolul 5, la paragraful 5.2.7.2, efectuează diagnosticarea defectelor în rulmenți prin analiza vibrațiilor folosind tehnici de

clasificare a defectelor cu rețele neuronale, fără o selectare a caracteristicilor în prealabil. Studiul identifică perfect exemplele purtătoare de anomalie și clasifică defectele incipiente în rulmenți.

Semnificația studiilor de caz prezentate este potențată de faptul că există puține informații disponibile legate de aplicarea tehnicilor ML și DL în domeniul industrial, care să aibă o descriere detaliată a metodelor de diagnoză și prognoză și o exemplificare pentru punerea în practică din punct de vedere informatic. Poate și pentru faptul că puține întreprinderi arhivează datele în cloud, monitorizând echipamentele pe distanțe lungi de timp. În prezent, inteligența artificială se bucură de o aplicabilitate mai largă în domeniul financiar, retail, banking, cyber-security, dar prea puțin este folosită în domeniul industrial cu exemple și tehnici concrete. Studiul a inclus și necesitat aprofundarea limbajului informatic dedicat (Python/Anaconda, Octave, Matlab, s.a.) dar și implementarea și adaptarea algoritmilor matematici la domeniul de studiu.

### **Perspectivă de dezvoltare ulterioară**

În această teză s-a încercat o abordare integrată a procesului de mentenanță, prin implementarea unei aplicații software flexibile și modulare care îndeplinește cel mai bine cerințele industriei inteligente. În viitor se intenționează extinderea acestei platforme pe baza unor noi studii de caz cu diferite scenarii privind mentenanța predictivă și crearea unor modele cât mai generale, valabile pentru mai mulți clienți.

Munca de cercetare în domeniul mentenanței și cea de implementare, prin intermediul platformei, este departe de a se fi terminat. Platforma IOTIA este într-un proces continuu de dezvoltare, completare, perfecționare și automatizare. Menirea unui astfel de instrument este să devină interfața unui sistem cyber-fizic. Există diverse strategii de mentenanță și fluxuri operaționale în cadrul întreprinderilor, există diverse grade de automatizare, platforma trebuie să ajungă la un anumit grad de flexibilitate pentru o integrare cât mai diversă.

În România, acest tip de serviciu (e-mentenanță) este abia la început. Se intenționează dezvoltarea acestui produs/instrument de management al mentenanței, implementarea în regim *SaaS* sau *On Premise* la cât mai multe companii, conform planului de afaceri elaborat în ultimul an de studiu doctoral, în cadrul Programului *BeAntreprenor*, plan care a fost premiat cu Premiul I în cadrul Universității Politehnica București.

## **BIBLIOGRAFIE**

1. Ahmadi, A., C. Cherifi, V. Cheutet and Y. Ouzrout. 2017. A Review of CPS 5 Components Architecture for Manufacturing Based on Standards. In: *11<sup>th</sup> IEEE International Conference on Software, Knowledge, Information Management and Applications (SKIMA 2017)*: (December) Colombo, Sri Lanka, 6 p. fhal-01679977
2. Andrew Ng, Note de curs: *Machine Learning*, Stanford University
3. Appana, D. K., Islam, M. R., and Kim, J.-M. 2017. Reliable fault diagnosis of bearings using distance and density similarity on an enhanced k-nn. In: *Australasian Conference on artificial life and computational intelligence*. Editors M. Wagner, X. Li, and T. Hendtlass (Cham, Switzerland: Springer), 193–203
4. Arpit, D., Zhou, Y., Ngo, H.Q., Govindaraju, V., 2016. Why Regularized Auto-Encoders Learn Sparse Representation?, *Proceedings of the 33<sup>rd</sup> International Conference on Machine Learning*, New York, USA. JMLR: W&CP, Vol.48.
5. Arunraj, N., Maiti, J. 2007. Risk -based maintenance – Techniques and applications. *Journal of Hazardous Materials*, Vol. 142, Issue 3 (April): 653-661

6. Ayhan, B., Chow, M.-Y., and Song, M.-H. 2006. Multiple discriminant analysis and neural-network-based monolith and partition fault-detection schemes for broken rotor bar in induction motors. *IEEE Trans. Ind. Electron.* 53, 1298–1308. DOI:10.1109/tie.2006.878301
7. Baheti, R. and H. Gill. 2011. *The Impact of Control Technology: Cyber-physical systems*, IEEE, Control Systems Society.
8. Banabic, D. 2016. Industry 4.0 started. Is it ready Romania for the challenges of this new revolution? In: *Revista de Politica Științei și Scientometrie – Serie Nouă*, Vol.5 (September), 194-201
9. Benkercha, R., and Moulahoum, S. 2018. Fault detection and diagnosis based on c4.5 decision tree algorithm for grid connected pv system. *Sol. Energy* 173, 610–634. DOI:10.1016/j.solener.2018.07.089
10. Berti, J., 2020. New IBM Maximo Application Suite provides monitoring, maintenance, and reliability applications in one single platform, available at: <https://www.ibm.com/blogs/internet-of-things/iot-maximo-asset-management-suite/>
11. Burrus, C.S., Gopinath, R., Guo, H. 2013. *Introduction to Wavelets and Wavelet Transforms*, Rice University, Houston, Texas
12. Biau, G., Devroye, L. 2015. *Lectures on the Nearest Neighbor Method*. Springer
13. Biehl, M., Hammer, B., Verleysen, M., Villman, T. 2009. *Similarity Based Clustering*. Springer-Verlag [Berlin]
14. Biggio, L., Kastanis, I. 2020. Prognostics and Health Management of Industrial Assets: Current Progress and Road Ahead. *Frontiers in Artificial Intelligence*, Vol.3 (November). DOI: 10.3389/frai.2020.578613
15. Bousdekis, A., Apostolou, D. and G. Mentzas. 2020. A human cyber physical system framework for operator 4.0 – artificial intelligence symbiosis. *Manufacturing Letters*, Vol. 25 (August): 10-15. <https://doi.org/10.1016/j.mfglet.2020.06.001>
16. Brettel, M., N. Friederichsen, M. Keller and M. Rosenberg. 2014. How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective. *International Journal of Information and Communication Engineering* 8, no. 1.
17. Brownlee, J. 2020, *Introduction to Time Series Forecasting with Python*, Edition v1.8.
18. Bearing Vibration Data, Case Western Reserve University, <https://csegroups.case.edu/bearingdatacenter/pages/12k-drive-end-bearing-fault-data>
19. Chauvin, Y., Rumelhart, D.E., 1995. *Backpropagation – Theory, Architectures, and Applications*, Psychology Press.
20. Chen, J., Patton, R.J., Nielsen, S.B. 1995. Model-based methods for fault diagnosis, *Transactions of the Institute of Measurement and Control* (April), DOI: 10.1177/014233129501700203
21. Chen X-W, Zeng X and Alphen D.V., 2006. Multi-class feature selection for texture classification. *Pattern Recognit Lett*; 27(14): 1685–1691.
22. Chen, A., Kurfess, T. 2017. A new model for rolling element bearing defect size estimation, *Measurement* 114 (Sept), DOI: 10.1016/j.measurement.2017.09.018
23. Chui, C.K., Chen, G., 1998. *Kalman Filtering with Real-Time Applications*, Berlin, Springer

24. Ciocoiu, I.B., 2001. Rețele neurale artificiale, Editura Cantes, Iași, ISBN 973-8173-16-7
25. Deac C.N., Deac G.C., Popa C. L., Ghinea M., Coteș E.C., 2017. Using Augmented Reality in Smart Manufacturing, *Proceedings of the 28<sup>th</sup> International DAAAM Symposium on Intelligent Manufacturing and Automation*, 7-11 Nov.2017, DOI: 10.2507/28th.daaam.proceedings.102, Festo Prize for Young Researchers and Scientists.
26. Deac, C.N., Deac, G.C., Parpală, R., Popa, C., Coteș, C., 2020. Vibration Anomaly Detection using Deep Neural Network and Convolutional Neural Network, *International Journal of Modeling and Optimization* (February), DOI: 10.7763/IJMO.2021.V11.772
27. Deac, C.N., Deac, G.C., Parpală, R., Popa, C., Popa, C., Popescu, C., 2021.Vibration Anomaly Detection using Multivariate Time Series, *International Journal of Modeling and Optimization*
28. Debnath, L., 2001. *Wavelet Transforms and Time-Frequency Signal Analysis*, Springer Science + Business Media New York
29. Deng, N, Tian, Y., Zhang, C., 2012. *Support Vector Machines. Optimization Based Theory, Algorithms, and Extensions*, Chapman and Hall/CRC Press
30. Dertat, A., 2017, Applied Deep Learning – Part 3: Autoencoders, <https://towardsdatascience.com/applied-deep-learning-part-3-autoencoders-1c083af4d798>
31. Dong, S., Luo, T., Zhong, L., Chen, L., and Xu, X., 2017. Fault diagnosis of bearing based on the kernel principal component analysis and optimized k-nearest neighbor model. *J. Low Freq. Noise Vib. Act. Contr.* 36, 354–365. doi:10.1177/ 1461348417744302
32. Du, C., Yang, Z., 2015. Inspiration of transformation and upgrading of manufacturing industry in China from German Industry 4.0 strategy, *Research on Economics and Management*, Vol. 7: 82-87.
33. Dunn, A., 2015, The Fourth Generation of Maintenance,Assetivity Pty Ltd., [https://plant-maintenance.com/articles/4th\\_Generation\\_maintenance.pdf](https://plant-maintenance.com/articles/4th_Generation_maintenance.pdf)
34. Fink, O., 2020. Data-driven intelligent predictive maintenance of industrial assets, in *Women in industrial and systems engineering*. Editor A. Smith (New York, NY: Springer), 589–605
35. Flovik, V., How to use Machine Learning for anomaly detection and condition monitoring, [towardsdatascience.com](https://towardsdatascience.com)
36. Flovik, V., Machine Learning for anomaly detection and condition monitoring, [towardsdatascience.com](https://towardsdatascience.com)
37. Galar, D., Goebel, K., Sandborn, P., Kumar, U., 2022. *Prognostics and Remaining Useful Life (RUL) Estimation. Predicting with Confidence*, CRC Press, Taylor & Francis Group.
38. Goto, F., 1989, Maintenance prevention, in Nakajima, S. (Ed.), Total Productive
39. Maintenance Development Program: Implementing Total Productive Maintenance,
40. Gryllias, K. C., and Antoniadis, I. A., 2012. A support vector machine approach based on physical model training for rolling element bearing fault detection in industrial environments.
41. Gröchenig, K., 2001. *The Short-Time Fourier Transform*, Springer Science + Business Media New York
42. Guillén, A.J.,Crespo, A., Macchi, M., Gomez, J., 2016. On the role of Prognostics and Health Management in advanced maintenance systems, *Spanish Ministry of Science and Innovation unde*

43. Guyon, I. Weston, J. and Barnhill S., 2002. Gene selection for cancer classification using support vector machine. *Mach Learn*; 46(1–3): 389–422.
44. Islam, M. M. M., and Kim, J.-M., 2019. Automated bearing fault diagnosis scheme using 2d representation of wavelet packet transform and deep convolutional neural network. *Comput. Ind.*
45. Ismail, M., Klausen, A., 2018. Multiple Defect Size Estimation of Rolling Bearings using Autonomous Diagnosis and Vibrational Jerk – *The 7th World Conference on Structural Control and Monitoring*, China
46. Jardine, A.K., Lin., D., Banjevic, D., 2006. A review on machinery diagnostics and prognostics implementing condition-based maintenance, *Mechanical Systems and Signal Processing* 20(7) (October). 10.1016/j.ymssp.2005.09.012
47. Jazdi, N., 2014. Cyber Physical Systems in the context of Industry 4.0. *IEEE, International Conference on Automation, Quality and Testing, Robotics* (May): 1-4. doi: 10.1109/AQTR.2014.6857843
48. Jia, Z., Liu, Z., Vong, C.-M., and Pecht, M., 2019. A rotating machinery fault diagnosis method based on feature learning of thermal images. *IEEE Access* 7, 12348–12359. doi:10.1109/access.2019.2893331no 065107
49. Jolliffe, I.T., 2002. *Principal Component Analysis*, Second Edition, New York, Springer.
50. Kagermann, H., Helbig, J., Hellinger, A. and Wahlster, W., 2013. *Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0: Securing the Future of German Manufacturing Industry, Final Report of the Industrie 4.0 Working Group*, Forschungsunion, ACATECH - National Academy of Science and Engineering
51. Karumanchi, N., 2016. *Data Structure and Algorithmic - Thinking with Python*, CareerMonk Publications, 390-399.
52. Khan, S., and Yairi, T., 2018. A review on the application of Deep Learning in system health management. *Mech. Syst. Signal Process.* 107, 241–265. doi:10.1016/j.ymssp.2017.11.024
53. Kienzler, R., Manchev, N., *Advanced Machine Learning and Signal Processing, IBM Course* Coursera.org.
54. Kingma, D. P., and Welling, M., 2013. Auto-encoding variational bayes. arXiv.
55. Kingma, D.P. and Ba, J., 2014. Adam: A Method for Stochastic Optimization. arXiv:1412.6980
56. Kirill, E., Ponteves, H., 2021, *Deep Learning A-Z™: Hands-On Artificial Neural Networks*, *Udemy*
57. Kirkwood, J.R., 2015. *Markov Processes*. CRC Press.
58. Kukanov, I., Siniscalchi, M., Li, K., 2016. Deep Learning with maximal figure-of-merit cost to advance multi-label speech attribute detection, *IEEE Spoken Language Technology Workshop* (December). doi: 10.1109/SLT.2016.7846308
59. Laurence Moroney, *Introduction to TensorFlow for Artificial Intelligence, Machine Learning and Deep Learning*, Course 1 of 4 in the *TensorFlow in Practice Specialization*, deeplearning.ai
60. Lee, J., Bagheri, B. and Kao, H.A., 2014. Recent Advances and Trends of Cyber-Physical Systems and Big Data Analytics in Industrial Informatics, *In: International Conference on Industrial Informatics* (July). doi: 10.13140/2.1.1464.1920

61. Lee, J., Bagheri, B. and Kao, H.A., 2015. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing Letters* 3 (January): 18-23.
62. Lee, J., Bagheri, B., 2015. Cyber-Physical Systems in Future Maintenance. 9<sup>th</sup> *WCEAM Research Papers* (February): 299-305.
63. Lei, J., Liu, C., and Jiang, D., 2019. Fault diagnosis of wind turbine based on long short-term memory networks. *Renew. Energy* 133, 422–432. doi:10.1016/j.renene.2018.10.031
64. Li, G., Deng, C., Wu, J., Xu, X., Shao, X., and Wang, Y., 2019. Sensor data-driven bearing fault diagnosis based on deep convolutional neural networks and s-transform. *Sensors* 19, 2750. doi:10.3390/s19122750
65. Liu, Z., Zuo, M. J., and Xu, H., 2013. Feature ranking for support vector machine classification and its application to machinery fault diagnosis. *Proc. IME C J. Mech. Eng. Sci.* 227, 2077–2089. doi:10.1177/0954406212469757
66. Lu, P.-J., Zhang, M.-C., Hsu, T.-C., and Zhang, J., 2001. An evaluation of engine faults diagnostics using artificial neural networks. *J. Eng. Gas Turbines Power* 123, 340. doi:10.1115/1.1362667
67. Lu, C., Wang, Z., and Zhou, B., 2017. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification, *Adv. Eng. Informat.* vol.32, pp.139-157
68. Luttmann, L., Mercorelli, P., 2021. Comparison of Backpropagation and Kalman Filter-based Training for Neural Networks, Preprints, 2021040523 (doi: 10.20944/preprints202104.0523.v1)
69. Macaulay, S., 1988. Amazing things can happen if you ... Keep it clean, *Production*, May, pp.72-74
70. Malhotra, P., TV, V., Ramakrishnan, A., Anand, G., Vig, L., Agarwal, P., Shroff, G., 2016. Multi-Sensor Prognostics using an Unsupervised Health Index based on LSTM Encoder-Decoder, *TCS Research*, New Delhi, India (August)
71. Marta, S., Angelink, M., Juergen, M., Biffli, S., Tu, W., 2018. Collective Intelligence Aspects of Cyber-Physical Social Systems: Results of a Systematic Mapping Study. In *Proceedings of the ACM Collective Intelligence Conference*, Zurich, Switzerland, 7–8 July 2018; pp. 1–4.
72. Marti, K., 2008. *Stochastic Optimization Methods*, Springer.
73. Mehrotra, K.G., Mohan, C.K., Huang, H., 2017. *Anomaly Detection Principles and Algorithms*, Syracuse, NY, USA, Springer
74. Miller, F.P., Vandome, A., McBrewster, J., 2010. *Mahanalobis Distance*, VDM Publishing
75. Mobley, R.K., 2001, *Plant Engineer's Handbook*, Elsevier Inc.
76. Mobley, R.K., Higgings, L and Smith, R., 2002, *Maintenance Engineering Handbook*, 6<sup>th</sup> Edition, McGraw-Hill
77. Moubray, J., 1991. *Reliability-Centred Maintenance*, 2<sup>nd</sup> Edition, Great Britain, Butterworth-Heinemann
78. Moosavi, S.S., N'Diaye, A., Djerdir, A., Ait-Amirat, Y., and Arab Khaburi, D., (2016). Artificial neural network-based fault diagnosis in the AC-DC converter of the power supply of series hybrid electric vehicle. *IET Electr. Syst. Transp.* 6, 96–106. doi:10.1049/iet-est.2014.0055

79. Mosterman, P., Zander, J., 2016. Industry 4.0 as a Cyber-Physical System Study. *Software and Systems Modelling*, vol (October). doi 10.1007/s10270-015-0493-x
80. Mujica, L., Guemes, A., Rodellar, J., 2008. PCA based measures: Q-statistic and T2-statistic for assessing damages in structures, *Structural Health Monitoring*, doi: 10.1177/1475921710388972
81. NASA, 2000. Reliability Centered Maintenance Guide for Facilities and Collateral Equipment. National Aeronautics and Space Administration, Washington, D.C.
82. Ng, A., 2011, Sparse autoencoder. CS294A Lecture notes 72, 1–19
83. Ng, A., 2018, Machine Learning, *Online Course authorised by Stanford University and offered through Coursera*
84. Nowlan, F. et al., 1978. *Reliability-Centred Maintenance*, United Airlines, San Francisco, California, U.S. Department of Commerce.
85. O’Donovan, K., P. Leahy, K. Bruton and O’Sullivan, D.T.J., 2015. An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities. *Journal of Big Data*, 2:25(1), 1. doi:10.1186/s40537-015-0034-z
86. Oppenheim, A.V., Willsky, A.S., Nawab, S.H., 1983. *Signals and Systems*. New Jersey, Prentice Hall.
87. Pang, G., Shen, C., Cao.,L., Hengel, AVD., 2017. Deep Learning for Anomaly detection: A review, *ACM Computing Surveys*, Vol.54
88. Patton, R. J., Frank, P. M. and Clark, R. N. (eds), 1989. *Fault Diagnosis in Dynamic Systems, Theory and Application*, Control Engineering Series, Prentice Hall, London.
89. Peng, H., Long, F., Ding, C., 2005. Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy, *IEEE Transactions on Pattern Analysis and Machine Intelligence* 27(8):1226-38, DOI:10.1109/TPAMI.2005.159
90. Pintelon, L., Gelders, L., 1992. Maintenance management decision making, *European Journal of Operations Research*, no.3, Vol.58: 301-317
91. Prihatno, A.T., Y.M. Jang and H. Nurcahyanto. 2020. Smart Factory Based on IoT Platform, Conference Paper (September)
92. Ray, A. and Tangirala, S., Stochastic modeling of fatigue crack dynamics for on-line failure prognostics. *IEEE Transactions on Control Systems Technology*, 4(4):443– 451, JUL 1996. ISSN 1063-6536.
93. Rokach, L., Maimon, O., 2014. *Data Mining with decision tress*. World Scientific Publishing Co Pte Ltd
94. Rong, Z., Shandong, D., Xin, N., Shiguang, X., 2018. Feedforward Neural Network for Time Series Anomaly Detection, Cornell University, arXiv:1812.08389 [cs.LG]
95. Saha, B., Goebel, K. and Christophersen, J., 2009. Comparison of prognostic algorithms for estimating remaining useful life of batteries. *Transactions of the Institute of Measurement and Control*, 31(3-4):293–308, JUN-AUG 2009. ISSN 0142-3312. doi: 10.1177/0142331208092030.
96. Sakthivel, N. R., Sugumaran, V., and Babudevasenapati, S., 2010. Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. *Expert Syst. Appl.* 37, 4040–4049. doi:10.1016/j.eswa.2009.10.002
97. Samanta, B., 2004. Gear fault detection using artificial neural networks and support vector



- machines with genetic algorithms. *Mech. Syst. Signal Process.* 18, 625–644. doi:10.1016/s0888-3270(03)00020-7
98. Saxena, A., Roychoudhury, I., Celaya, J.R., Saha, S., Saha, B., Goebel, K., 2010. Requirements specifications for prognostics: An overview. *AIAA Infotech at Aerospace 2010*, art.no. 2010-3398
  99. Shah, T.N., Khan, M.Z., Mumtaz, A., Khan, B., 2020. CART, J-48graft, J48, ID3, Decision Stump and Random Forest: A comparative study. In: *University of Swabi Journal (USJ); Open access*, (November).
  100. Shamrat, J.M., Hasib, K.M., Siddique, A., Yadav, A., 2021, Performance evaluation among ID3, C4.5, and CART Decision Tree Algorithms. In: *International Conference on Pervasive Computing and Social Networking, salem, 19-20, India* (March)
  101. Stone, J.V., 2013. *Bayes's Rule: A Tutorial Introduction to Bayesian Analysis*, Sebtel Press
  102. Sufian, A.T., Abdullah, B.M., Ateeq, M., Wah, R. and Clements, D., 2019. A Roadmap towards the Smart Factory. In: *12<sup>th</sup> International Conference on Developments in eSystems Engineering* (October): 978-983. doi:10.1109/DeSE.2019.00182
  103. Sullivan, G., Pugh, R. and Hunt, W., 2010. *Operations & Maintenance Best Practices - A Guide to Achieving Operational Efficiency*. Release 3.0., Pacific Northwest National Laboratory for the Federal Energy Management Program, U.S. Department of Energy, Vers.3: 49-57
  104. Sundararajan, D., 2001. *The Discrete Fourier Transform. Theory, Algorithms and Applications*, <https://doi.org/10.1142/4610>, World Scientific.
  105. Svard, C., 2009. *Residual Generation Methods for Fault Diagnosis with Automotive Applications*, Linköping, Sweden, LiU-Tryck.
  106. Tan, C.C., 2009, *Autoencoder Neural Networks : A Performance Study Based on Image Reconstruction, Recognition and Compression*, LAP Lambert Academic Publishing.
  107. Tian, Y., Yuan, J., 2019. An intelligent fault diagnosis method using GRU neural network toward sequential data in dynamic processes. *Processes* 7, 152. doi:10.3390/pr7030152
  108. The Economist, 2012. Special report: Manufacturing and innovation, A third industrial revolution (April), <https://web.mit.edu/pie/news/Economist.pdf>
  109. Vachtsevanos, G., Lewis, F., Roemer, M. and A. Hess., 2006. *Intelligent fault diagnosis and prognosis for engineering systems*. John Wiley & Sons, Inc., 1 edition.
  110. Verma, V., 2020. A comprehensive guide to Feature Selection using Wrapper methods in Python, *Data Science Blogathon* (<https://www.analyticsvidhya.com/blog/2020/10/a-comprehensive-guide-to-feature-selection-using-wrapper-methods-in-python/>)
  111. Vincent, P., Larochelle, H., Bengio, Y., and Manzagol, P.-A., 2008. “Extracting and composing robust features with denoising autoencoders,” In *Machine Learning, proceedings of the twenty-fifth international conference (ICML 2008)*, Helsinki, Finland, June 5–9, 2008, 1096–1103. doi:10.1145/1390156.1390294
  112. Vinzi, V.E., Chin, W.W., Henseler, J., Wang, H., 2010. *Handbook of Partial Least Squares. Concepts, Methods and Applications*, Springer.
  113. Vegard Flovik, 2019. Machine Learning for anomaly detection and condition monitoring, *Towards Data Science* ([towardsdatascience.com/machine-learning-for-anomaly-detection-and-condition-monitoring-d4614e7de770](https://towardsdatascience.com/machine-learning-for-anomaly-detection-and-condition-monitoring-d4614e7de770))
  114. Xia, M., Li, T., Xu, L., Liu, L. and C. W. de Silva, 2018. “Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks,” *IEEE/ASME Trans.*

- Mechatronics, vol. 23, no. 1, pp. 101– 110, (February)
115. Xia, M., Li, T., Shu, T., Wan, J., de Silva, C. W., and Wang, Z., 2019. A two-stage approach for the remaining useful life prediction of bearings using deep neural networks. *IEEE Trans. Ind. Inf.* 15, 3703–3711. doi:10.1109/tii.2018. 2868687
  116. Zhao, Z., Anand, R., Wang, M., 2019. Maximum Relevance and Minimum Redundancy Feature Selection Methods for a Marketing Machine Learning Platform. *arXiv:1908.05376v1 [stat.ML]* (August)
  117. Zhang, B., Georgoulas, G., Orchard, M., Saxena, A., Brown, D., 2008. Rolling Element Bearing Feature Extraction and Anomaly Detection Based on Vibration Monitoring, 16 th Mediterranean Conference on Control and Automation Congress Centre, June 25-27.
  118. Zhang, S., Wang, B., Habetler, T., 2020. Deep Learning Algorithms for Bearing Fault Diagnostics – A Comprehensive Review, *arXiv:1901.08247v3 [cs.LG]* (February)
  119. Wang, B., Tao, F., Fang, X., Liu, C., Liu Y. and Freiheit, T., 2020. Smart Manufacturing and Intelligent Manufacturing: A Comparative Review. *Journal Elsevier*, China
  120. Wang, S., Li, J., Wan, D., Zhang, C., 2016. Implementing Smart Factory of Industry 4.0: An Outlook. *International Journal of Distributed Sensor Networks*, (January).
  121. Wang, T., 2010. Trajectory Similarity Based Prediction for Remaining Useful Life Estimation, UMI 3432353, ProQuest LLC. (August)
  122. Wang, Z., Zhang, Q., Xiong, J., Xiao, M., Sun, G., and He, J., 2017. Fault diagnosis of a rolling bearing using wavelet packet denoising and random forests. *IEEE Sensor. J.* 17, 5581–5588. doi:10.1109/jsen.2017.2726011
  123. Wen, L., Dong, Y. and L. Gao, 2019. A new ensemble residual convolutional network for remaining useful life estimation, *Mathematical Biosciences and Engineering*, 16(2): 862–880. DOI: 10.3934/mbe.2019040
  124. Weeks, M., 2007. *Digital Signal Processing using Matlab and Wavelets*, Infinity Science Press LLC, Hingham, Massachusetts
  125. Wong, K.K., 2019. Mastering Partial Least Squares Structural Equation Modeling (PLS-SEM) with SmartPLS in 38 hours, *iUniverse*, Bloomington.
  126. Wortmann, F., Flüchter, K., 2015. Internet of things. *Business & Information Systems Engineering*, 57 (March): 221-224.
  127. Yao, X.; Lin, Y., 2016. Emerging manufacturing paradigm shifts for the incoming industrial revolution. *Int. J. Adv. Manuf. Technol*, 85, 1665–1676.
  128. Yang, B.-S., Di, X., and Han, T. 2008. Random forests classifier for machine fault diagnosis. *J. Mech. Sci. Technol.* 22, 1716–1725. doi:10.1007/s12206-008-0603-6
  129. Yang, B.-S., Han, T., and Hwang, W.W. 2005. Fault diagnosis of rotating machinery based on multi-class support vector machines. *J. Mech. Sci. Technol.* 19, 846–859. doi:10.1007/BF02916133
  130. Yin, D., Ming, X. and Zhang, X., 2020. Understanding Data-Driven Cyber-Physical-Social System (D-CPSS) Using a 7C Framework in Social Manufacturing Context, *Sensors – Open Access Journal from MDPI*, no.20(18), 5319: (September). doi.org/10.3390/s20185319
  131. <https://www.emerson.com/en/us/news/corporate/iiot-survey>
  132. <https://www.ibm.com/analytics/us/en/technology/predictive-analytics/>
  133. <https://www.coursera.org/learn/tensorflow-sequences-time-series-and-prediction>

134. <https://www.coursera.org/advanced-machine-learning-signal-processing>
135. <https://www.coursera.org/learn/introduction-tensorflow>
136. <https://csegroups.case.edu/bearingdatacenter/pages/12k-drive-end-bearing-fault-data>,  
Bearing Vibration Data, Case Western Reserve University
137. [http://www.alteryx.com/?utm\\_source=PredictiveAnalyticsToday&utm\\_medium=Review  
&utm\\_campaign=PAT](http://www.alteryx.com/?utm_source=PredictiveAnalyticsToday&utm_medium=Review&utm_campaign=PAT)
138. <https://www.continuum.io/>
139. <https://www.dataiku.com/>
140. <http://dmway.com/>
141. [https://mediacenter.ibm.com/media/t/1\\_jg5ynql0](https://mediacenter.ibm.com/media/t/1_jg5ynql0)
142. <https://my.vertica.com/register/>
143. [http://www.oracle.com/technetwork/database/options/advanced-analytics/odm/overview/  
index.html](http://www.oracle.com/technetwork/database/options/advanced-analytics/odm/overview/index.html)
144. <https://turi.com/>
145. <https://greenwavesystems.com/>
146. <https://www.h2o.ai/>
147. <https://www.datarobot.com/>
148. [http://www.sap.com/pc/analytics/predictive-analytics/software/predictive-  
analysis/index.html?utm\\_source=PredictiveAnalyticsToday&utm\\_medium=Review&utm  
\\_campaign=PAT](http://www.sap.com/pc/analytics/predictive-analytics/software/predictive-analysis/index.html?utm_source=PredictiveAnalyticsToday&utm_medium=Review&utm_campaign=PAT)
149. <https://www.getmaintainx.com/learning-center>
150. <https://www.grafana.com>