

## Modelarea proceselor folosind rețele neuronale

**Abstract:** Dezvoltarea unei strategii de mentenanță la nivelul unei companii nu se reduce la un singur tip de mentenanță. Va exista întotdeauna o mixtura de mentenanță reactivă, corectivă, preventivă și predictivă. De asemenea, un factor important în alegerea unui tip de mentenanță este reprezentat de consecințele unei eventuale stări de defect la nivelul mașinii/echipamentului/sistemului. Apariția unui defect poate pune probleme de securitate a muncii sau a producției, sau poate duce la probleme de mediu. Din perspectiva realizării și implementării unei strategii de mentenanță predictivă, care furnizează timpul optim de reînnoire pentru un anumit echipament, deci care se modifică în concordanță cu starea de uzură a echipamentului, cercetarea din cadrul proiectului “AUTOMATED MONITORING & ANALYSIS PLATFORM (AMAP)”, Cod SMIS 142811, finanțat prin Actiunea 2.2.1, Apel 3, s-a focalizat pe partea de detecție a defectelor și de evaluare a gradului de uzură a echipamentului.

Analiza problemelor legate de eficiența diferitelor tipuri de echipamente de-a lungul a 30 de ani, a demonstrat că politica de mentenanță este responsabilă de aproximativ 17% din întreruperile producției sau ale problemelor de calitate. Celelalte 83 de procente se datorează de cele mai multe ori practicilor inadecvate de operare, proiectării defectuoase, etc.


În dezvoltarea unei politici eficiente de mentenanță predictivă este necesară implicarea factorilor de conducere, a echipei manageriale care trebuie să înțeleagă necesitatea implementării acesteia, cu costuri suplimentare, dar care în timp își vor dovedi eficacitatea. Astfel, pentru optimizarea proceselor și a funcționării firmei, în general, este necesară implementarea tehnicilor specifice de mentenanță predictivă, pentru detecția, izolarea și rezolvarea în timp util și cu costuri cât mai reduse a tuturor abaterilor de la performanțele stabilite. Utilizarea acestor tehnici de mentenanță trebuie însă acceptată la toate nivelele, lucru dificil de realizat. De aceea este esențială formarea unei categorii de personal care să aibă ca principal scop acela al dezvoltării și implementării politicii de mentenanță.

Alegerea personalului și organizarea lui nu este un demers ușor. Membrii echipei trebuie să aibă cunoștințe complete despre proiectarea mașinilor, echipamentelor și proceselor și să fie capabili să implementeze cele mai bune practici atât pentru operarea, cât și pentru mentenanța tuturor mașinilor/echipamentelor critice ale sistemelor industriale. De asemenea, echipa trebuie să cunoască și să utilizeze în mod corect tehnicile de mentenanță, în concordanță cu caracteristicile mașinii/echipamentului. Această problemă poate fi rezolvată în două moduri. Prima abordare se referă la selectarea personalului din rândul celor mai buni specialiști ai firmei, specialiști care să aibă cunoștințe solide fiecare în domeniul propriu. Cea de-a doua abordare se referă la angajarea unor ingineri specializați pe asigurarea calității și a mentenanței. De cele mai multe ori, specialiștii din această categorie își oferă serviciile în calitate de consultanți, de

obicei pe termen scurt, după care firma va fi nevoită să apeleze la angajații proprii pentru a continua această activitate.

Din perspectiva realizării și implementării unei strategii de mentenanță predictivă, care furnizează timpul optim de reînnoire pentru un anumit echipament, deci care se modifică în concordanță cu starea de uzură a echipamentului, cercetarea din cadrul proiectului “AUTOMATED MONITORING & ANALYSIS PLATFORM (AMAP)”, Cod SMIS 142811 finanțat prin Acțiunea 2.2.1, Apel 3, s-a focalizat pe partea de detecție a defectelor și de evaluare a gradului de uzură a echipamentului

Sistemul de diagnoză din cadrul strategiei de mentenanță predictivă propusă are structura prezentată în figura de mai jos:




*Structura sistemului de mentenanță predictivă*

Sistemul de predicție primește la intrare date măsurate din procesul real și, pe baza prelucrării acestora, realizată la nivelul subsistemului specific, îndeplinește următoarele funcții:

- la nivelul subsistemului SDD – identifică apariția unui defect în sistem și generează un semnal de alarmare al operatorului;
- la nivelul subsistemului SEU – evaluează și estimează gradul de uzură al sistemului;
- la nivelul subsistemului SID – identifică tipul defectului și momentul apariției acestuia.

Pentru proiectarea sistemului de diagnoză care să îndeplinească funcțiile mai sus menționate s-a utilizat metoda bazată pe modelul procesului. Descrierea schematică a metodei de detecție a defectelor pe bază de model este prezentată în figura de mai jos.




*Sistemul de detecție a defectelor*

### Rețeaua neuronală pentru estimarea gradului de uzură a sistemului


În acest scop, pot fi abordate două soluții, ambele având beneficii și, respectiv, inconveniente. Rămâne la latitudinea inginerilor de exploatare și/sau mentenanță să abordeze soluția adecvată procesului tehnologic precum și structurii organizatorice. Astfel, evaluarea permanentă a funcționării sistemului, precum și estimarea gradului de uzură pot fi realizate în două variante:

1. Folosind o rețea neuronală similară cu cea care a fost proiectată pentru sistemul de detecție a defectului (care are ca mărimi de intrare:  $X(k)$ ,  $P1(k)$ ,  $P2(k)$ ,  $T(k)$ , ținta fiind reprezentată de  $F(k)$ ) și considerând, de data aceasta, ca intrare a rețelei neuronale inclusiv intensitatea defectului,  $f(k)$ , prezentată în Figura de mai jos.



*Structura rețelei neuronale în regim staționar pentru uzură – varianta 1*

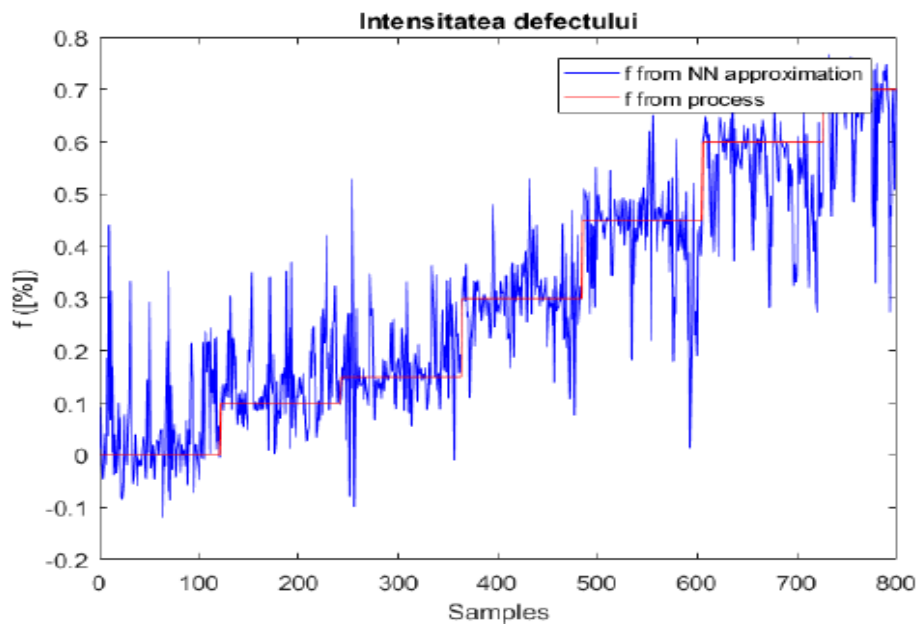
2. Utilizând o nouă rețea neuronală, care va avea ca mărimi de intrare:  $X(k)$ ,  $P1(k)$ ,  $P2(k)$ ,  $F(k)$ , iar ținta va fi reprezentată de intensitatea defectului/gradul uzurii  $f(k)$ , ca în Figura de mai jos.



*Structura rețelei neuronale în regim staționar pentru determinarea gradului uzură – varianta 2*

*În acest subcapitol, s-a optat pentru varianta 2 care oferă direct gradul de uzură.*

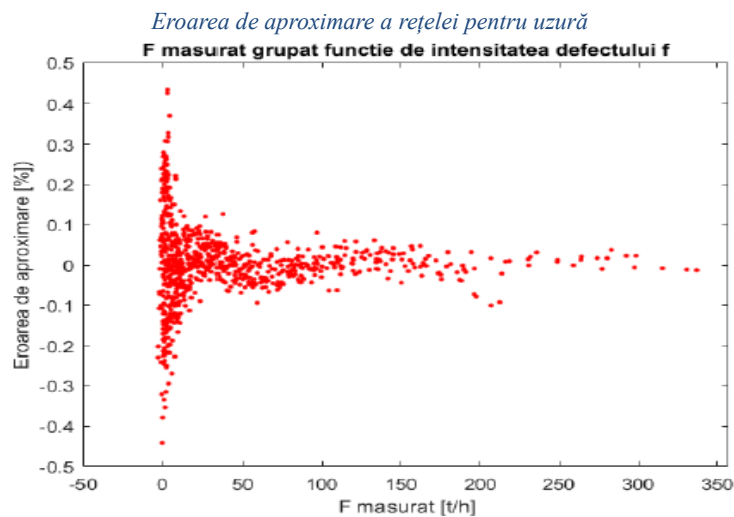
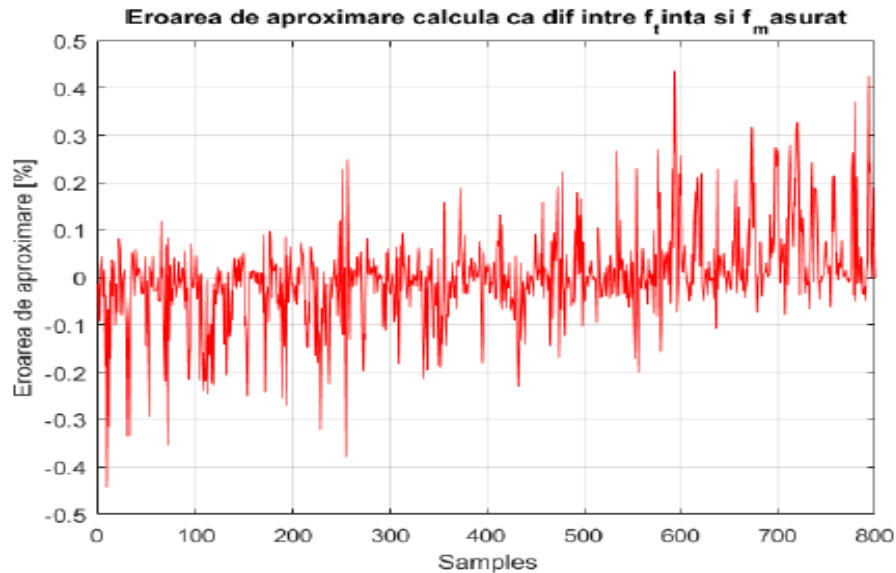
În primă instanță, s-a pornit de la un set de date de 800 de eșantioane extras din setul de date care s-a folosit anterior la validarea rețelei neuronale în regim staționar. Cercetările realizate au demonstrat că arhitectura de rețea neuronală cea mai adecvată dinamicii datelor procesului este o rețea de tip feed-forward cu un singur strat ascuns și 7 neuroni.



*Ieșirea rețelei neuronale pentru evaluarea gradului de uzură a sistemului*

La analiza Figurii de mai sus, care reprezintă ieșirea rețelei neuronale și a Figurii de mai jos care reprezintă valoarea erorii de aproximare a rețelei neuronale, se poate observa că rețeaua neuronală astfel antrenată nu reușește să învețe din exemplele aplicate pe intrarea ei. Din cercetările ulterioare (arhitecturi diferite ale rețelei neuronale și/sau algoritmi de învățare diferiți) și din analiza succesivă a performanțelor rețelelor neuronale și, în mod special, din reprezentarea erorilor de măsură grupate funcție de valorile măsurate s-a observat că, de fiecare dată, erorile de

aproximare ale rețelei neuronale au frecvență mai mare și valori mai mari în zona valorilor mici ( $F_{\text{măsurat}} < 50 \mu\text{m}$ ).



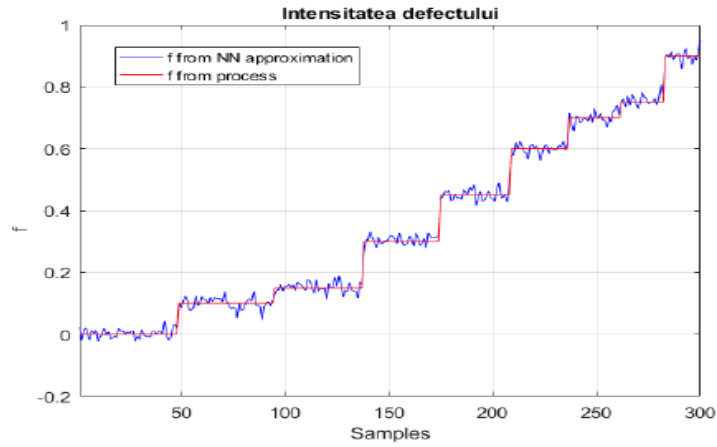
*Eroarea de aproximare a RN grupată funcție de F măsurat din proces*

Urmare a acestei constatări și în virtutea faptului că la stabilirea pragului de alarmare, s-a considerat orice valoare a semnalului măsurat mai mică de 40 [ $\mu\text{m}$ ] ca fiind uzură acceptabilă, s-a decis în continuare că, la antrenarea rețelei neuronale pentru evaluarea gradului de uzură, să fie luate în considerare date din proces care corespund doar semnalelor cu valori mai mari de 50 [ $\mu\text{m}$ ].

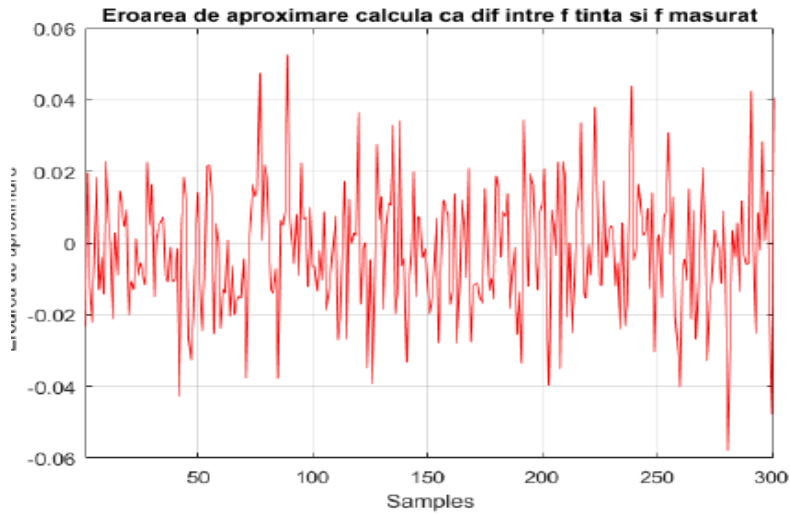
După eliminarea datelor care corespundeau unor valori ale debitelor mai mici de 50 [ $\mu\text{m}$ ] din setul de antrenare și s-a reantrenarea rețelei neuronale s-au obținut rezultatele prezentate în următoarele 4 figuri de mai jos.

Din următoarea figura se poate observa că rezultate antrenării rețelei neuronale cu acest set de date se îmbunătățesc considerabil. Rețeaua neuronală poate aproxima acum cu precizie


gradul de uzură a componentei țintă, erorile de aproximare având acum valori mici iar densitatea de repartiție a erorii de măsură este acum egală (nu se mai concentrează în jurul valorilor mici).



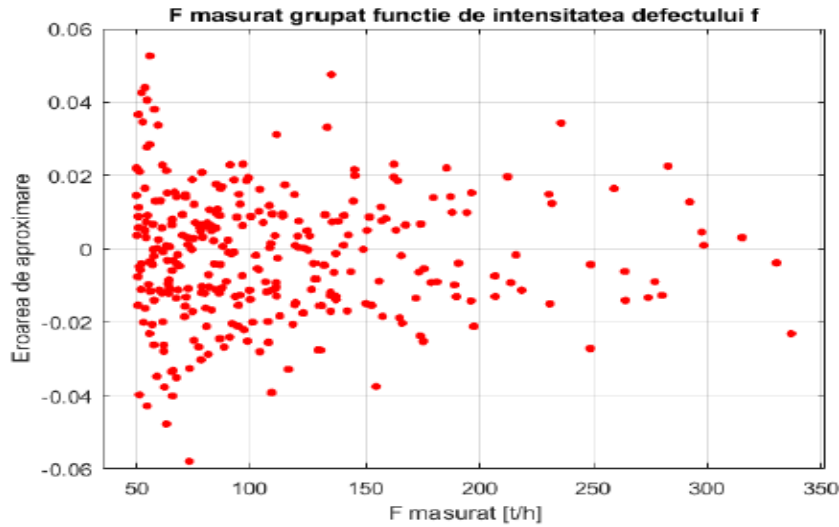
*Ieșirea rețelei neuronale pentru evaluarea gradului de uzură al sistemului*





*Eroarea de aproximare a rețelei pentru estimarea uzurii*



*Eroarea de aproximare a RN ca modul de diferență f țintă și f măsurat*



*Eroarea de aproximare a rețelei pentru estimarea uzurii*



*Eroarea medie pătratică și histograma erorilor*

Indicatorii de performanță ai rețelei neuronale, Figurile „Eroarea de aproximare a rețelei pentru estimarea uzurii” și „Eroarea de aproximare a RN ca modul de diferență  $f$  țintă și  $f$  măsurat”, reflectă aceeași precizie a rezultatului observat în subcapitolul precedent. Totuși, deși eroarea medie pătratică este mică pentru toate cele trei seturi de date în care rețeaua a divizat datele aplicate pe intrarea sa (antrenare, validare și testare), un aspect care se observă și trebuie menționat aici constă în faptul că aceste erori sunt totuși diferite între ele: eroarea medie pătratică pentru seturile de testare și validare este totuși mai mare decât eroarea medie pătratică obținută pe setul de antrenare.

*Cercetarea s-a derulat în cadrul proiectului “AUTOMATED MONITORING & ANALYSIS PLATFORM (AMAP)”, Cod SMIS 142811, finanțat prin Programul Operațional Competitivitate, Axa prioritară 2 - Tehnologia Informației și Comunicațiilor (TIC) pentru o economie digitală competitivă, Prioritatea de investiții 2b - Dezvoltarea produselor și serviciilor TIC, a comerțului electronic și a cererii de TIC, Obiectiv Specific OS 2.2 - Creșterea contribuției sectorului TIC pentru competitivitatea economică, Acțiunea 2.2.1 - Sprijinirea creșterii valorii adăugate generate de sectorul TIC și a inovării în domeniu prin dezvoltarea de clustere, Apelul de proiecte nr. 3*

*„Conținutul acestui material nu reprezintă în mod obligatoriu poziția oficială a Uniunii Europene sau a Guvernului României”*