

PROGNOSTICAREA ÎN MENTENANȚA BAZATĂ PE STARE

Gheorghe DONCA¹, Ioan MIHĂILĂ², Macedon GANEA², Dorin HIRȚE³, Marius NICA³

1. eng. drd., University of Oradea, donca.gheorghe@gmail.com,

2. prof. PhD. eng., University of Oradea, 3. eng. drd., University of Oradea

Keywords : maintenance, CBM, prognostic, predictor, diagnostic

Abstract : Prognostic algorithms for condition based maintenance of critical machine components are presenting major challenges to software designers and control engineers. Predicting time-to-failure accurately and reliably is absolutely essential if such maintenance practices are to find their way into the industrial floor. Moreover, means are required to assess the performance and effectiveness of these algorithms.

1. Introducere

Pe măsură ce procedeele de fabricație devin mai complexe și extrem de sofisticate, calitatea devine crucială. Defecțiunile în funcționarea mașinilor limitează timpii de producție, iar practica întreținerilor programate tinde să reducă perioada de lucru a mașinilor având drept rezultat pierderea de productivitate.

Recentele progrese în domeniul aparatelor de măsură, al telecomunicațiilor și al calculatoarelor au făcut disponibile întreprinderilor industriale noi senzori și strategii de detecție, rețele la nivel de fabrică și tehnologii informatice, care ajută la îmbunătățirea substanțială a ciclurilor de producție.

Diagnosticarea și prognosticarea pentru Condition-Based Maintenance (CBM) implică un sistem integrat cu o arhitectură care încorporează un modul de diagnoză – diagnosticianul – care evaluează prin intermediul senzorilor activi starea curentă a componentelor instalației, modulul de prognosticare – prognosticatorul – care preia informația de la diagnostician și decide pe baza unui istoric al defecțiunilor și al unui model de defecțiuni, programarea operațiilor de mentenanță, fără a afecta funcționarea sistemului. Ierarhia metodelor de prognosticare se prezintă în figura 1.

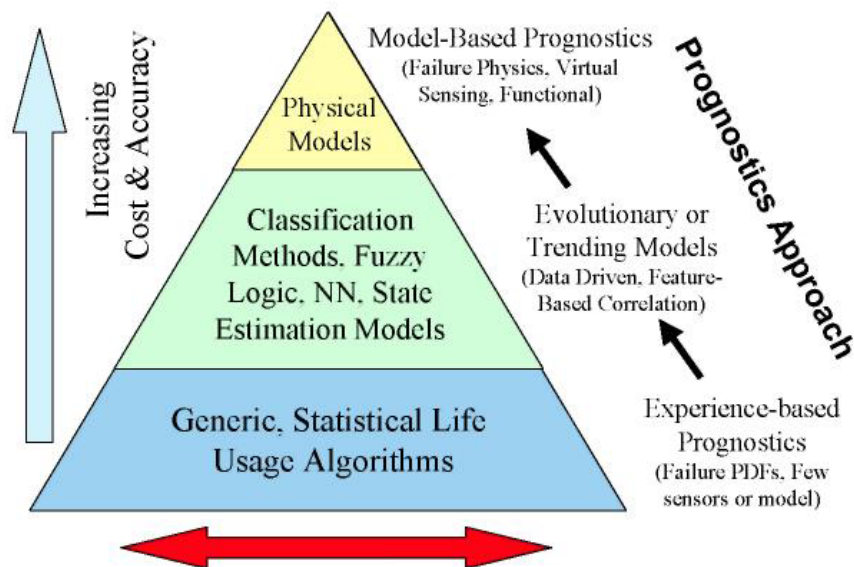


Fig. 1. Ierarhia metodelor de prognosticare [1]

Cea mai grea problemă este determinarea timpului de funcționare rămas din momentul detectării anomaliei până în momentul în care trebuie oprită din funcționare

sistemul. Metodele de prognoșticare folosite sunt prezentate în tabelul 1.

Tabel 1. Metode de prognoșticare [2]

	Experienced - based	Evolutionary	Physics - based
Engineering model	Not required	Beneficial	Required
Failure history	Required	Not required	Beneficial
Fast operating conditions	Beneficial	Not required	Required
Current conditions	Beneficial	Required	Required
Identified fault patterns	Not required	Required	Required
Maintenance history	Beneficial	Not required	Beneficial
In general	No Sensors / No Model	Sensors / No Model	Sensors & Model

2. Prognoșticatorul

Prognoșticatorul realizează legarea informației de diagnoșă cu planificatorul mentenanței. Realizează predicția dinamică recepționând datele de la modulele de diagnoșă și determinând intervalul de timp în care mentenanța este obligatorie de executat pentru a fi păstrată integritatea proceselor de execuție. Predicția este dinamică deoarece pe măsură ce primește date noi ajustează intervalul de timp. În figura 2 se prezintă arhitectura sistemului de prognoșticare.

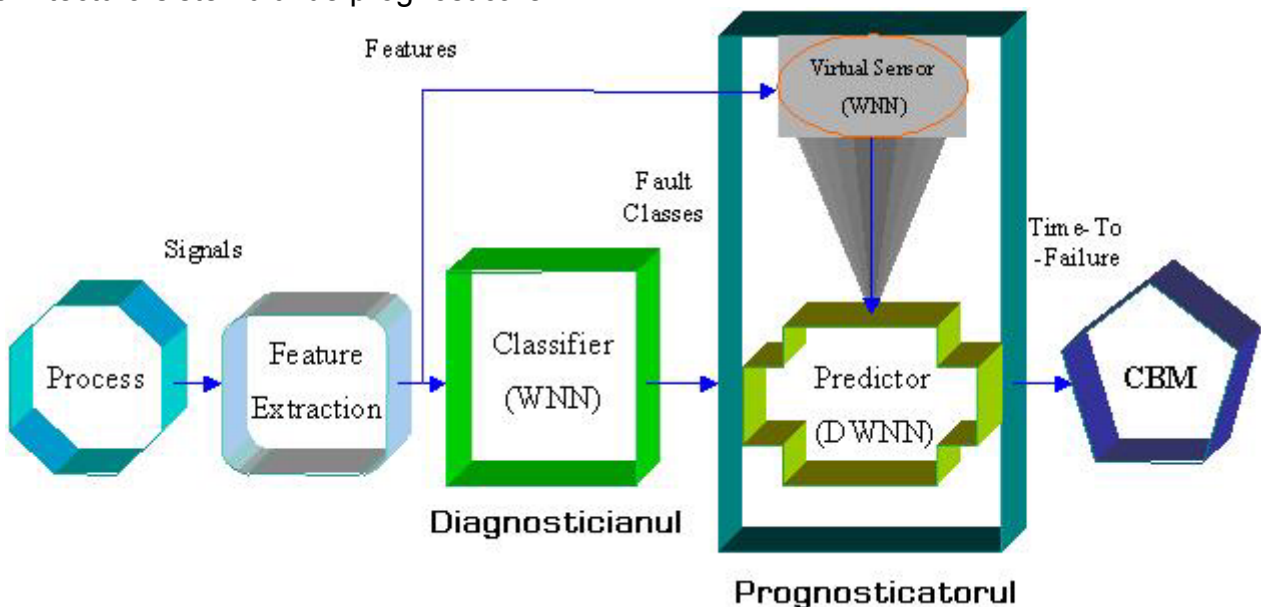


Figura 2. Arhitectura sistemului de prognoșticare [4]

Diagnosticianul monitorizează continuu datele primite de la senzori și decide despre existența unor condiții inițiale de defecțiune. Detecția și identificarea unei defecțiuni declanșează prognoșticatorul, care va trimite un raport modulului CBM privind la durata de funcționare rămasă pentru componenta și mașina de lucru.

Arhitectura prognoșticatorului este bazată pe un model de rețea neuronală de tip wavelet (WNN) și cuprinde două elemente :

- un senzor virtual, care acumulează toate datele măsurate cu privire la defecțiune
- predictorul, care pe baza stării curente ale componentelor, estimează durata de viață rămasă pentru mașina de lucru.

WNN (Wavelet Neural Network) aparține unei noi clase de rețele neuronale cu capabilități unice în domeniul identificării și clasificării problemelor. Wavelet – urile sunt o clasă de elemente de bază cu oscilații cu durată finită, care le face să semene cu niște

unde mici și oferă un cadru natural, pentru analiza semnalelor și a imaginilor. Pe de altă parte, rețelele artificiale neuronale constituie o puternică clasă de funcții neliniare pentru aproximări. Prin îmbinarea celor două a luat naștere WNN.

Pentru a putea modela evoluția în timp a sistemelor dinamice s-a elaborat DWNN (Dynamic Wavelet Neural Network) a cărei structură de bază este prezentată în fig. 3 [4].

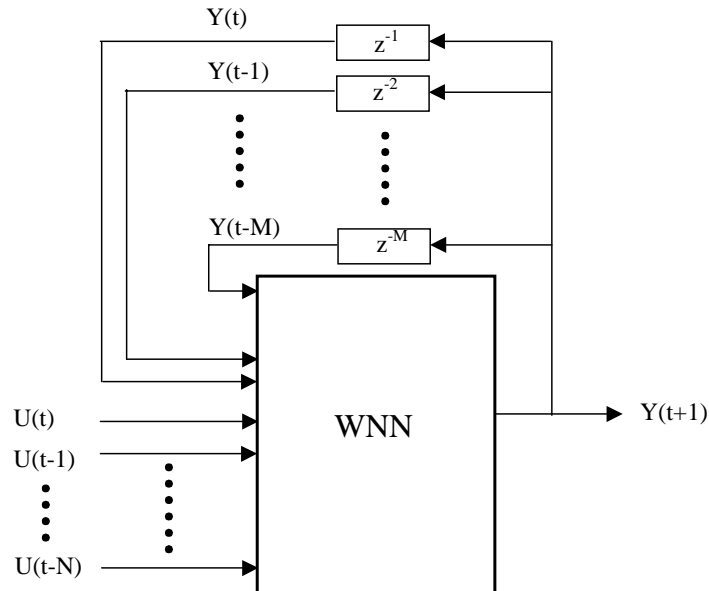


Figura 3. Dynamic Wavelet Neural Network : $Y(t+1) = WNN(Y(t), \dots, Y(t-M), U(t), \dots, U(t-N))$

Deoarece majoritatea componentelor nu pot fi măsurate direct în timpul funcționării, se folosește WNN ca și un senzor virtual, care preia datele măsurate și generează evoluția în timp a șabloanelor de defecte.

Cea mai importantă noțiune în cazul predicției este Time-To-Failure (TTF) – timpul până la căderea componentei mașinii. Reprezentarea schematică a DWNN cu funcția de Predictor este realizată în figura 4.

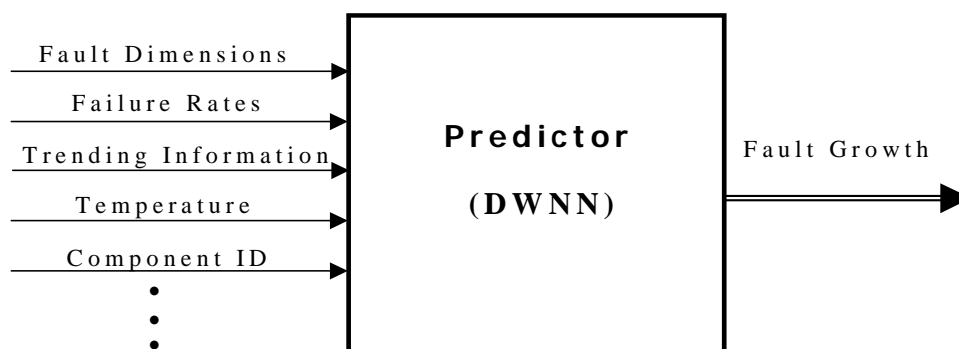


Figura 4. Reprezentarea schematică a DWNN cu funcția de Predictor [4]

Procesul este monitorizat în timp real folosind senzori adecvați sau senzori virtuali. Datele obținute sunt prelucrate în timp continuu, iar rezultatele sunt organizate după timp într-un vector care este intrarea în DWNN unde se procesează rezultând o identificare și clasificare dinamică.

Cel mai important criteriu pentru alegerea algoritmilor trebuie să fie raportul cost / beneficiu, aplicat la întregul sistem CBM. Pentru a crește precizia se poate folosi un mecanism de învățare adaptivă sau un algoritm genetic, care va optimiza rezultatele.

3. Exemplu

Studiul vibrațiilor unui rulment este cel mai elecvent. Figura 5 prezintă vibrațiile unui rulment bun, respectiv a unuia cu defect, iar în figura 6 se prezintă densitatea de putere spectrală a acestora. Figura 7 prezintă analiza realizată cu un model auto-regresiv iar în figura 8 cu un model WNN în acest caz algoritmul WNN aproximând mai exact [4].




Figura 5. Vibrațiile unui rulment bun și a unuia cu defect




Figura 6. Densitatea de putere spectrală la un rulment bun și la unul cu defect




Figura 7. Predicția cu un model AR




Figura 8. Predicția cu model WNN

4. Concluzii

Economiile aduse de CBM nu sunt aduse numai de micșorarea numărului de căderi accidentale ci în special de micșorarea numărului de intervenții planificate care pot fi planificate cu exactitate pe baza predicțiilor bazate pe starea și evoluția viitoare a echipamentelor. În ultima perioadă se folosește și noțiunea de PHM – managementul predictiv al sănătății echipamentelor.

5. BIBLIOGRAFIE

- [1] Byington, C.S., Roemer, M.J., Galie, T. - Prognostic enhancements to diagnostic systems for improved condition-based maintenance, Aerospace Conference Proceedings IEEE, 2002
- [2] Roemer, Michael J., Byington, Carl S., - An Overview of Selected Prognostic Technologies with Reference to an Integrated PHM Architecture, ISHEM Forum, Napa Valley, CA, November 7-10, 2005
- [3] Vachtsevanos, G., Thakker, A., Galie, T., A Real-Time Architecture for Prognostic Enhancements to Diagnostic Systems, MARCON, Knoxville, Tennessee, 2002.
- [4] Vachtsevanos, G., Wang, P., Khiripet, N., "Prognostication: algorithms and performance assessment methodologies," Proc. of MARCON 2000 Conference, pp. 8.01-8.12, 2000.