

Model Neuronal Decizional în Baza Experienței Operatorului Uman

Viorel CĂRBUNE
Universitatea Tehnică a Moldovei
viorel.carbune@calc.utm.md

Abstract — Modelarea procesului de turnare a microfiredelor magnetice, este un proces destul de complex, multi-parametric și prezintă anumite dificultăți esențiale. Practica arată că abordările clasice pentru reprezentarea acestor clase de sisteme nu asigură o precizie necesară, fie din cauza complexității modelelor sistemului, fie din cauza aproximărilor făcute în lipsa informației despre corelarea dintre parametrii acestui proces. Pentru a rezolva această problemă a fost propusă utilizarea experienței operatorului uman pentru crearea unei rețele neuronale artificiale. Această rețea neuronală are ca scop preluarea experienței operatorului uman, generalizarea acesteia și automatizarea procesului de turnare a microfiredelor magnetice prin substituția operatorului uman din bucla de reacție. Utilizarea rețelelor neuronale artificiale pentru automatizarea procesului de turnare a microfiredelor magnetice se realizează cu scopul de a îmbunătăți parametrii de calitate ai produsului final.

Cuvinte cheie — RNA, Proces Decizional, Expert Uman.

I. INTRODUCERE

Influența dezvoltării tehnico-științifice asupra dezvoltării societății moderne nu poate fi supraestimată. Una din tendințele moderne o reprezintă automatizarea proceselor industriale. Acest fapt presupune substituirea operatorilor umani, din bucla de reacție, cu un sistem decizional automat. Faptul dat necesită cunoașterea profundă a procesului pentru obținerea unui model matematic, care ar descrie procesul în conformitate cu cerințele tehnice specificate. Practica însă arată că nu toate procesele pot fi descrise matematic cu gradul necesar de aproximație. Acest fapt se datorează, fie modelelor matematice prea complicate, fie lipsei datelor inițiale. În cazul proceselor complexe, modelele matematice obținute se pot dovedi inaplicabile în timp real din cauza timpului de calcul sporit.

Soluționarea acestei clase de probleme o poate constitui reducerea gradului de aproximare a modelului matematic sau optimizarea procesului de calcul. În cazul proceselor industriale definite incomplet, obținerea modelelor matematice de comportare a acestora, poate deveni imposibilă. În acest caz se pot obține modele matematice care descriu parțial procesul studiat, sau îl descriu cu un grad foarte mare de aproximare. Acest fapt poate fi cauzat fie de complexitatea procesului cercetat, fie de natura acestuia. În unele cazuri, inexactitatea în descrierea procesului industrial poate fi cauzată de imposibilitatea elaborării experimentelor, care pot provoca întreruperea procesului de producție, sau chiar distrugerea sistemului cercetat. Acest grup de procese industriale formează o clasă de procese industriale specifice, care pune în fața cercetătorilor o clasă nouă de probleme, care trebuie rezolvate. Această clasă de probleme se caracterizează prin descrierea parțială a procesului industrial cercetat și ca urmare se obțin modele matematice incomplete, respectiv acestea au un grad foarte mic de aproximare, fapt ce face imposibilă aplicarea acestor modele în procesul de

automatizare a proceselor industriale specifice. În condițiile insuficienței de date, survenite din cauza imposibilității derulării experimentelor, sau cauzate de specificul proceselor industriale, utilizarea metodelor clasice de automatizare cu întreținerea cerințelor tehnice și de calitate a produsului finit devine practic imposibilă. Menționând acest fapt se poate crea impresia greșită că acest tip de probleme nu poate fi rezolvat, dar această afirmație este negată de existența operatorului uman în bucla de reacție care urmînd un algoritm, numai de el cunoscut, totuși participă productiv și în timp real la procesul decizional, asigurînd calitatea produsului finit. Astfel, prin existența sa operatorul uman demonstrează încă odată în plus inevitabilitatea soluționării acestei clase de probleme. Axîndu-se atenția asupra operatorului uman se poate face concluzia că acesta deja dispune de una din soluțiile problemei în cauză. Se cere menționat faptul că fiecare operator poate avea propria soluție și deci se poate ghida de propriul algoritm decizional pentru luarea deciziilor, care poate depinde de mai mulți factori cît interni, cum ar fi experiența, atît și externi, cum ar fi condițiile inițiale. Se poate constata cu siguranță faptul că operatorul nu se ghidează în procesul decizional de un model matematic sau de un algoritm strict, însă acesta manifestă mai mult un comportament tactic decît strategic. În acest caz problema poate fi redusă de la descrierea modelului procesului industrial de turnare a microfiredelor magnetice la descrierea modelului procesului decizional al operatorului uman. Astfel dispunînd de o serie de soluții, destul de eficiente, utilizate pe larg în procesul de producție de către echipa de operatori experimentați, se conturează o problemă nouă și anume problema formalizării modelelor de luare a deciziilor a operatorilor umani în procesele industriale.

II. METODE DE SOLUȚIONARE A CLASELOR DE PROBLEME SPECIFICE

Pentru soluționarea acestei clase de probleme se propune abordarea acesteia dintr-un alt punct de vedere și anume se

propune de a valorifica experiența și potențialul operatorului uman. Se poate remarca faptul că operatorul uman reprezintă un “regulator” care deja răspunde cerințelor de calitate, Fig.1. Ca rezultat nu este necesar de a urma metoda clasică care constă în identificarea modelului sistemului, apoi proiectarea unui regulator pentru acesta, ci operatorul însuși este privit ca un sistem decizional ce trebuie identificat. Acest model va servi drept regulator pentru procesul de turnare. Astfel operatorul uman devine obiect de studiu, dar nu instalația de turnare. Așadar, problema se reduce la preluarea comportamentului operatorului uman prin captarea și reutilizarea experienței acestuia în procesul de turnare automată. Pentru aceasta mai întâi este nevoie de a cerceta procesul tehnologic cu scopul de a identifica variabilele procesului de turnare care se desfășoară nemijlocit la instalația de turnare a microfiredelor magnetice. Observațiile făcute pe parcursul procesului tehnologic de turnare a microfiredelor magnetice evidențiază faptul că operatorul uman nu operează cu valori numerice directe ale vidului din tubul de sticlă în procesul decizional, dar cu mărimi relative la valoarea curentă a vidului. În același timp, pentru variabila de ieșire (rezistența liniară a microfiredului magnetic), mai comodă este reprezentarea numerică relativ la valoarea rezistenței caracteristice care este individuală pentru fiecare operator. Astfel se poate deduce faptul că operatorul reglează procesul de turnare variind parametrul de intrare al sistemului condus și respectiv cel de ieșire pentru sine. În acest caz operatorul poate fi descris astfel:

$$\Delta P_{V_i} = f(\Delta R_{P_i})$$

$$\Delta R_{P_i} = R_{P_i} - R_{P_i}^{\text{Caracteristic}}$$

$$\Delta P_{V_i} = P_{V_{i+1}} - P_{V_i}$$

unde $R_{P_i}^{\text{Caracteristic}}$ este valoarea rezistenței liniare cu cea mai mare frecvență de apariție pe parcursul întregului proces de turnare a microfiredului magnetic, iar P_{V_i} și $P_{V_{i+1}}$ sînt două măsurări consecutive ale vidului efectuate în procesul de turnare.

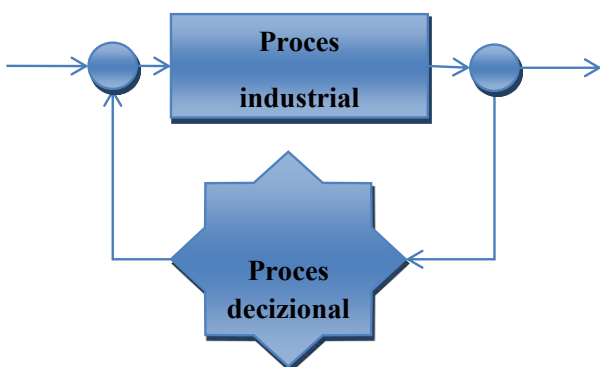


Fig.1 Schema de structură a procesului industrial de turnare a microfiredelor magnetice.

Pentru determinarea parametrului rezistenței liniare de referință caracteristice $R_{P_i}^{\text{Caracteristic}}$ a operatorului uman a fost construit graficul repartizării frecvenței de apariție a valorilor rezistenței liniare pe întreg parcursul duratei de turnare a microfiredului magnetic, Fig.2.




Fig.2 Graficul repartizării frecvenței de apariție a valorilor rezistenței liniare.

Utilizînd valorile de referință a rezistenței liniare caracteristice pentru fiecare operator cercetat se calculează variația relativă a rezistenței liniare după formula $\Delta R_{P_i} = R_{P_i} - R_{P_i}^{\text{Caracteristic}}$, Fig.3.

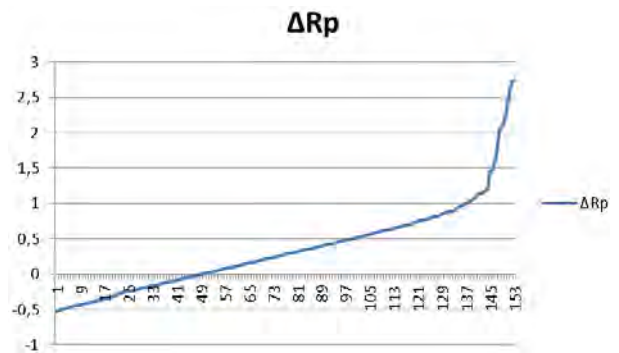


Fig.3 Graficul domeniului de valori pentru variația relativă a rezistenței liniare.

Parametrul ΔP_{V_i} se calculează păstrînd ordinea și natura datelor experimentale colectate de la operatorul uman, care au fost supuse procedurii de filtrare pentru a se păstra caracteristica și proprietatea de reacție relativă la valoarea curentă a vidului în tubul de sticlă.

Analizînd graficele din Fig.4 se pot identifica următoarele trăsături comportamentale specifice în procesul decizional al operatorului uman : acesta conduce procesul de turnare utilizînd o metodă decizională ce asigură o dependență aproape liniară a vidului în tubul de sticlă.

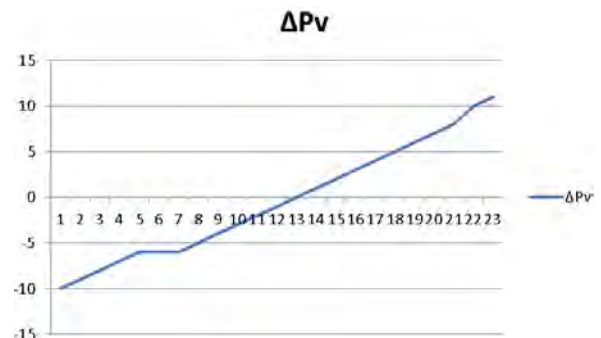


Fig.4 Graficul repartizării domeniului de valori în creștere pentru variația vidului în tubul de sticlă.

III. RNA PENTRU AUTOMATIZAREA PROCESULUI DECIZIONAL

Funcțiile caracteristice ΔRp și ΔPv calculate anterior, individual pentru fiecare operator uman, vor fi utilizate pentru elaborarea metodologiilor decizionale în baza rețelelor neuronale artificiale, care vor prelua proprietățile decizionale caracteristice ale operatorului. Pentru crearea și antrenarea rețelelor neuronale artificiale se va utiliza Neural Network Toolbox din pachetul de programe Matlab.

Parametrii caracteristici ΔRp și ΔPv vor fi utilizați în procesul de antrenare a rețelei neuronale artificiale. În rezultatul utilizării acestor funcții caracteristice în procesul de antrenare a rețelei neuronale artificiale se va obține un model decizional specific care va generaliza procesul decizional al expertului uman și va păstra proprietățile individuale ale acestuia.

Utilizând valorile pentru ΔRp se poate construi o rețea neuronală artificială care aproximează funcția caracteristică $\Delta Pv=f(\Delta Rp)$. Pentru aceasta este nevoie de a utiliza Toolkit – ul *Neural Network* din mediul *Matlab*. În rezultatul utilizării acestui program se generează o mulțime de grafice printre care și graficul care prezintă modul în care descrește eroarea pătratică a rețelei neuronale pe parcursul procesului de antrenare. În Fig.5 sînt prezentate graficele care caracterizează starea procesului de antrenare a rețelei neuronale artificiale. Primul grafic din Fig.5 descrie dependența gradientului de epoca de antrenare a rețelei neuronale artificiale [1]. Se observă faptul că valoarea gradientului scade odată cu creșterea numărului de epoci de antrenare. Acest fapt semnifică că, cu fiecare epocă de antrenare, rețeaua neuronală caracterizează din ce în ce mai bine operatorul uman și preia tot mai mult experiența acestuia, evoluînd în procesul decizional și apropiindu-se de procesul decizional caracteristic acestuia. Graficul din Fig.5 prezintă variația gradientului în raport cu numărul de epoci. Valoarea finală a gradientului în epoca a 13-a este 0.13726 care este aproximativ egală cu zero. Minimizarea valorii gradientului duce la o antrenare și testare mai calitativă a rețelei neuronale dezvoltate [2]. Cea mai bună performanță de validare o constituie valoarea 5.2366 și este prezentă în epoca 7 [2].

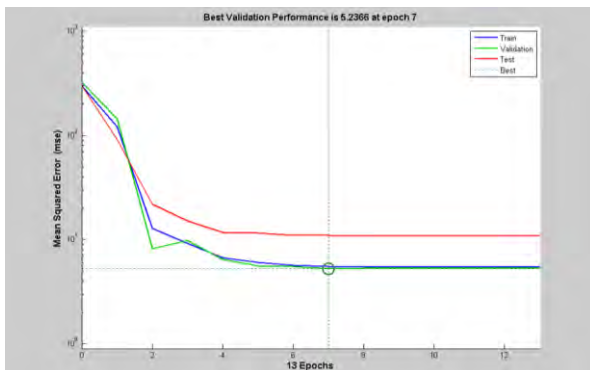


Fig.5. Diagrama stării procesului de antrenare a rețelei neuronale NET1

În Fig.7 sînt prezentate histogramele erorilor în care sînt prezentate seturile de date utilizate pentru antrenarea,

validarea și testarea rețelei neuronale.

Aceste histograme pot servi pentru verificarea suplimentară a performanței rețelei.

Histogramele prezentate în figura Fig.7 constituie o dovadă suplimentară a performanței rețelei. Histogramele prezintă datele de antrenament, de validare și de testare. Cea mai mare parte a datelor corespunde liniei de eroare zero. Acest fapt semnifică că erorile de aproximare a datelor sunt distribuite într-un interval relativ mic în jurul valorii zero [3].




Fig.7. Histogramele distribuției erorilor în procesele de antrenare, testare și validare a rețelei neuronale NET1

Graficele de regresie, Fig.8 afișează ieșirile rețelei în ceea ce privește obiectivele pentru antrenare, validare și seturile de teste.

Coeficientul de corelație (R) determină asocierea valorilor ieșirilor rețelei neuronale și ieșirilor de control. Pentru rețeaua NET1, parametrul $R = 0,19611$ este obținut utilizând întregului set de date. Valoarea acestui parametru dovedește încă o dată în plus caracterul preponderent aleator al modelului decizional obținut prin captarea experienței operatorului uman. Pe de o parte se poate spune că modelul nu aproximează pe deplin modelul decizional real, dar pe de altă parte se poate menționa faptul că acesta a moștenit comportamentul aleator de la operator [3]. Se poate face concluzia că metodele clasice de estimare a performanței modelelor obținute nu sînt aplicabile în cazul acestei clase de probleme din cauza caracterului și naturii aparent aleatorii a datelor de intrare și ieșire a operatorului. Din cauză că operatorul poate fi privit ca o funcție matematică multivaloare, aplicarea calculului erorii capătă un caracter nedefinit și necesită o metodă nouă de calcul a acestui indicator, care ar exprima caracteristicile de performanță a modelelor destinate rezolvării claselor de probleme specifice.

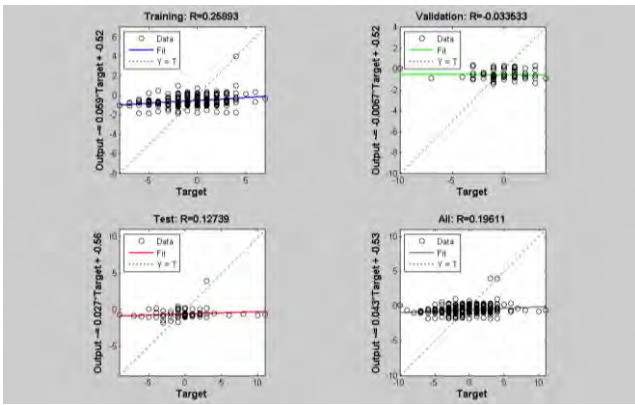


Fig.8. Graficele de regresie a rețelei neuronale NET1

În graficul din Fig.9 este prezentat modul în care rețeaua neuronală aproximează datele. Pe axa orizontală sunt plasate datele de intrare ΔRp iar pe axa verticală sunt prezentate datele de control ΔPv^{exp} marcate cu simbolul + și datele obținute de la ieșirea rețelei neuronale artificiale ΔPv^{net} marcate cu simbolul o.

Rețeaua neuronală obținută descrie cu un grad mare de eroare comportamentul operatorului uman, fapt ce nu constituie neapărat un neajuns deoarece obiectivul primordial constă în conducerea automată a procesului de turnare. Această rețea manifestă un comportament determinist fiind descrisă printr-o funcție surjectivă și nu una multivaloare ca în cazul operatorului uman real.




Fig.9. Graficul funcției de aproximare a modelului decizional uman generat de rețeaua neuronală NET1.

Pentru testarea și evaluarea proprietăților modelului sistemului decizional s-a elaborat în *Simulink* schema de testare, Fig.10, în care a fost introdus blocul *Function Fitting Neural Network*, care implementează procesul decizional elaborat în baza unei rețele neuronale artificiale, antrenarea căreia a fost realizată cu ajutorul parametrilor calculați utilizând experiența operatorului uman.




Fig.10. Schema de testare a modelului rețelei neuronale artificiale NET1.

În rezultatul simulării modelului sistemului decizional la baza căruia se află o rețea neuronală artificială, antrenarea căreia a fost realizată în baza parametrilor calculați utilizând integral experiența operatorului uman, s-a obținut graficul prezentat în Fig.11. În această figura este prezentată grafic evoluția în timp a curbelor PvTeor – vidul în tubul de sticlă calculat și PvEx – vidul în tubul de sticlă preluat experimental. Analizând aceste grafice se poate remarca faptul că curba obținută teoretic pentru vidul în tubul de sticlă, PvTeor, interpoolează aproape liniar curba obținută pe cale experimentală – PvEx, însă asigură o eroare destul de mare în comparație cu comportamentul operatorului uman. O concluzie obiectivă asupra aplicabilității și performanței modelului obținut va putea fi enunțată doar în rezultatul testării în condiții reale, însă trebuie menționată dinamica pozitivă a modelului decizional obținut.

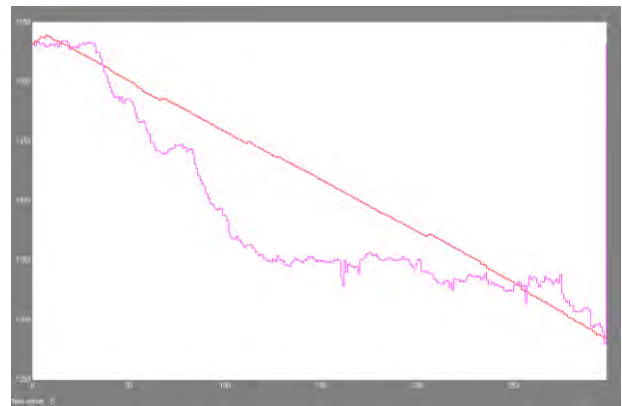


Fig.11. Graficul vidului în tubul de sticlă obținut experimental și calculat teoretic.

IV. CONCLUZII

Au fost obținut un model cu un comportament mai mult sau mai puțin intuitiv, cu un grad mai mare sau mai mic de eroare, acest model demonstrează o dată în plus posibilitatea preluării experienței expertului uman și utilizarea acestor soluții, poate nu optime, pe alocuri imperfecte dar totuși soluții, pentru a înțelege mai bine procesului de turnare a microfibrelelor. Aplicabilitatea acestei metode poate fi confirmată sau infirmată doar practic. Acest model poate fi aplicat la rezolvarea altor clase de probleme specifice pentru care contează mai mult viteza de reacție decât precizia deciziei luate.

BIBLIOGRAFIE

- [1] I. Lazaros, Applications of Neural Networks, 14th International Conference, EANN 2013, Halkidiki, Greece, September 13-16, 2013 Proceedings, Part I.
- [2] K. Kaushal, Knowledge Extraction From Trained Neural Networks, October 2012.
- [3] K. Yadav, Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models, Renewable and Sustainable Energy Reviews, March 2014.