

METODE DE MODELARE A INSTALAȚIILOR DE PREPARARE, CU RECICLARE, A MIXTURILOR ASFALTICE

MODELING METHODS TO PREPARE FACILITIES, WITH RECYCLING OF ASPHALT MIXTURES

Oana TONCIU¹, Aurelian GAIDOȘ², Amelitta LEGENDI³

¹ șef lucrări univ. dr. ing., Facultatea de Utilaj Tehnologic, U. T. C. B., Romania

² conf. univ. dr. ing., Facultatea de Utilaj Tehnologic, U. T. C. B., Romania

³ conf. univ. dr. ing., Facultatea de Utilaj Tehnologic, U. T. C. B., Romania

Rezumat: Această lucrare prezintă pe scurt trei metode moderne de modelare matematică care pot fi aplicate pentru o descriere a fenomenelor și a fluxurilor de materiale și gaze ce se produc în timpul proceselor de preparare cu reciclarea mixturilor asfaltice. Dintre aceste metode a fost aleasă pentru detaliere, modelarea prin intermediul grafurilor.

Cuvinte cheie: mixture asfaltice, grafuri, reciclare

Abstract: This paper briefly presents three modern mathematical modeling methods can be applied towards the more reliable description of phenomena and materials and gas flows that exist between components of facility equipment cooking with recycling asphalt materials. Of these methods was chosen for application as user-friendly modeling using graphs.

Keywords: asphalt plants, graphs, recycling.

Instalațiile de preparare cu reciclare a mixturilor asfaltice reprezintă instalații complexe (caracterizate printr-un număr de parametri de proces aflați în interdependență) care pot fi modelate sub diverse aspecte, în scopul acoperirii unor cerințe de natură tehnologică și/sau economică, de mediu etc. Astfel, pentru instalația de preparare cu reciclare a mixturilor asfaltice, în flux discontinuu, schematizată în fig. 1, se prezintă trei metode matematice moderne de modelare, posibil a fi aplicate în direcția descrierii cât mai fidele a fenomenelor și fluxurilor de materiale și gaze care există între echipamentele componente ale instalației. Cele trei metode analizate sunt: calculul predictiv cu metoda rețelelor neuronale, conducerea de proces - metoda fuzzy și modelarea prin intermediul grafurilor a circulației materialelor și gazelor în interiorul instalației. Dintre acestea s-a ales spre aplicare ca fiind mai ușor de aplicat modelarea prin intermediul grafurilor.

1.C ALCULUL PREDICTIV CU METODA REȚELELOR NEURONALE

Activitatea de predicție în regim dinamic se realizează având drept fundament o bază de date recente pentru subsamblul considerat. Această bază de date cuprinde valorile variabilelor de intrare și cele ale funcției/funcțiilor obiectiv.

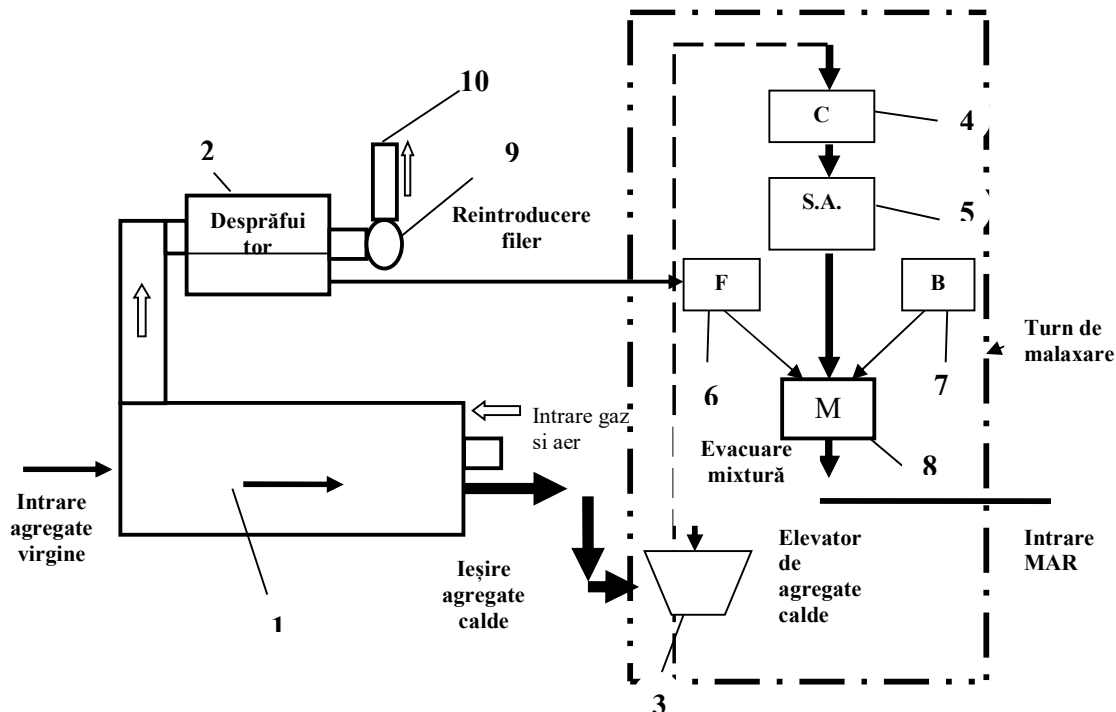


Fig. 1. Instalația de preparare cu reciclarea materialelor asfaltice recuperate, în flux discontinuu
 1 – uscător; 2 – desprăfuiitor; 3 – elevator de agregate calde; 4 – ciur; 5 – depozit stocare agregate calde; 6 – siloz filer; 7 – depozit bitum; 8 – malaxor; 9 – exhaustor; 10 – coș de fum

Drept variabile de intrare pot fi considerate: timpul, debite, temperaturi, caracteristici dimensionale, granulometria materialului; funcții scop se pot considera productivitatea, consumul specific de energie, prețul de cost, indicele de calitate pentru produs, emisii de noxe etc.

Reușita calculului depinde nu numai de metoda aleasă ci și de selecția corectă a variabilelor de intrare concomitent cu dimensionarea corespunzătoare a bazei de date. Astfel, se exclud valorile care corespund unor situații excepționale (pornirea sau oprirea unui subansamblu, eroarea umană în desfășurarea procesului etc.) și care pot fi determinate prin metode statistice sau chiar vizual.

Apariția unor modificări ale caracteristicilor constructiv – funcționale (neetanșeități, apariția de blocaje, formarea sau desprinderea unor dopuri de material) ale echipamentului termic considerat sau introducerea unei noi politici de conducere (strategii de management) a procesului, determină variații bruște (exprimate matematic prin funcțiile treaptă) între subsetul de date anterior saltului valoric și cel de după, variații de care trebuie să se țină cont în analiză.

2. MODELUL MATEMATIC

Rețeaua neuronală tipică este alcătuită după modelul sistemului nervos – dintr-un set de unități de calcul denumite neuroni între care există conexiuni complexe, similar cu sinapsele. Neuronii sunt grupați în straturi de intrare, straturi ascunse precum și un strat de ieșire. Fiecare neuron este conectat cu toți neuronii aflați pe nivelul următor.

METODE DE MODELARE A INSTALAȚIILOR DE PREPARARE, CU RECICLARE, A MIXTURILOR ASFALTICE

Modul de operare cu rețeaua neuronală presupune parcurgerea a două etape: învățarea rețelei și operarea, care presupune aplicarea unui set de date rețelei învățate care acum este capabilă să recunoască, să analizeze și să ia singură decizii într-un spațiu de activitate determinat. Procesul de învățare presupune stabilirea unor ponderi optime pentru fiecare legătură între neuroni.

Informații despre funcționarea rețelelor neuronale și despre aplicații ale acestora pot fi preluate din literatura de specialitate [1].

Conform informațiilor din lucrarea [2], o metodă utilă pentru a obține performanță la operarea cu rețeaua neuronală este următoarea:

- se antrenează inițial rețeaua cu toate datele disponibile;
- se reprezintă grafic valorile funcției obiectiv obținute în urma experimentărilor și prin intermediul rețelei antrenate;
- sunt eliminate din subșetul de date de antrenare acele valori de date care corespund valorilor izolate din norul statistic;
- rețeaua se antrenează din nou și este pregătită pentru rularea valorilor de verificare și de predicție.

Principiul de bază constă în furnizarea către rețeaua neuronală de date experimentale și stabilirea unei legături între datele de intrare și datele de ieșire (inputuri și outputuri).

Dacă rezultatele experimentale conțin informații relevante despre proprietatea obiectiv, atunci rețeaua antrenată va putea reproduce nu numai rezultatele experimentale ci va avea și capacități de generalizare, permițând o bună aproximare a rezultatelor altor experimente.

Pentru etapa de învățare se folosesc următoarele formule [2]:

$$r_i = \sum_{j \in A} \sigma_j \cdot \omega_{ji}, \forall i, i \in B \quad (1)$$

în care A reprezintă setul de neuroni din stratul curent;

B – setul de neuroni din stratul următor;

σ_j - valoarea de ieșire (activarea) neuronului j;

ω_{ji} - ponderea atribuită conexiunii între neuronul j și i.

Transformarea valorii de rețea în valoare de ieșire (activarea neuronului) se realizează cu ajutorul funcției sigmoide [2]:

$$\sigma_i = f(r_i) = \frac{1}{1 + e^{-r_i}} \quad (2)$$

După identificarea valorii de ieșire pentru toți neuronii din rețea urmează stabilirea erorii obținută pe stratul de ieșire [18]:

$$\delta_i = f'(r_i)(y_i - o_i), \forall i : i \in C \quad (3)$$

în care y_i reprezintă setul de valori țintă, furnizate de către utilizator rețelei pentru învățare;

C – setul de neuroni din stratul de ieșire;

f' - derivata de ordinul I a funcției de activare.

Procesul continuă prin propagarea inversă a erorii, pentru a atribui erorile fiecărui neuron din straturile ascunse:

$$\delta_i = f'(r_i) \cdot \sum_{i \in E} \delta_j \cdot \omega_{ij}, \forall i: i \in D \quad (4)$$

După ce fiecare neuron din rețea are asociate atât o activare cât și o eroare, se poate trece la actualizarea ponderilor [18]:

$$\begin{aligned} (\omega_{ij})_{t+1} &= (\omega_{ij})_t + \Delta\omega_{ij} \\ \omega_{ij} &= L \cdot o_j \cdot \delta_j, \forall i, j: j \in B \end{aligned} \quad (5)$$

în care ω_{ij} reprezintă valoarea modificării ponderilor între neuronii i și j ;

t – momentul de timp (pasul de calcul);

L – rata de învățare a rețelei (constantă impusă); controlează amplitudinea modificărilor ponderilor, și deci afectează convergența și rata de convergență a răspunsului către valorile țintă.

Regula de modificare a ponderilor pentru fiecare conexiune este ca diferența dintre activarea neuronilor de ieșire și valoarea corespunzătoare a mărimii țintă pentru fiecare astfel de entitate să fie minimă. După ce ponderile au fost stabilite, se consideră că s-a încheiat un pas de calcul. Numărul de pași se impune de către utilizator; creșterea numărului de pași nu implică și obținerea unor rezultate mai bune [1].

Ca și în cazul parametrului L , alegerea corectă a numărului de pași de antrenare precum și a raportului dintre numărul de straturi de intrare și cel de straturi ascunse depind de experiența utilizatorului. Depășind o valoare critică pentru numărul de pași de calcul, se poate produce fenomenul de supraînvățare, ceea ce presupune că în etapa a doua se vor putea efectua calcule numai pentru valori aflate în setul de date furnizat pentru antrenare.

În etapa de operare, pe baza datelor de intrare (de analizat) și a ponderilor stabilite în etapa precedentă, rețeaua face o aproximare a rezultatului. Procesul necesită o singură parcurgere pentru calculul valorilor nodurilor [1].

3. CONDUCEREA DE PROCES: METODA FUZZY – SCURTĂ PREZENTARE

Logica fuzzy permite rezolvarea unor probleme complexe printre care se numără și conducerea de proces, prin formularea și interpretarea matematică a unor cunoștințe umane imprecise, formulate astfel: puțin mai mare, scade puțin etc.

Un controller fuzzy este alcătuit dintr-o serie de construcții verbale care încorporează experiența umană într-un format de tipul: dacă o premisă este adevărată atunci este îndeplinită o consecință (acțiune). Controllerul este reprezentat de o interfață - utilizator, o bază de reguli în care se stochează strategiile de conducere și un motor de inferență. Inferența (concluzia, deducția logică) poate fi exprimată în termeni de proces, de exemplu:

Regulă: Dacă timpul de retenție în uscător este de 4 minute, atunci productivitatea atinsă de acest tip de utilaj este de 120 t/h.

Fapt: Timpul de retenție în acest uscător este de 4 minute.

Consecință: Acest uscător asigură o productivitate de 120 t/h.

METODE DE MODELARE A INSTALAȚIILOR DE PREPARARE, CU RECICLARE, A MIXTURILOR ASFALTICE

Termenii lingvistici (puțin mărit, foarte cald) sunt exprimați numeric cu ajutorul funcțiilor de apartenență care acoperă întreg intervalul de variație a mărimii studiate și au valori între 0 și 1 (fig. 2).

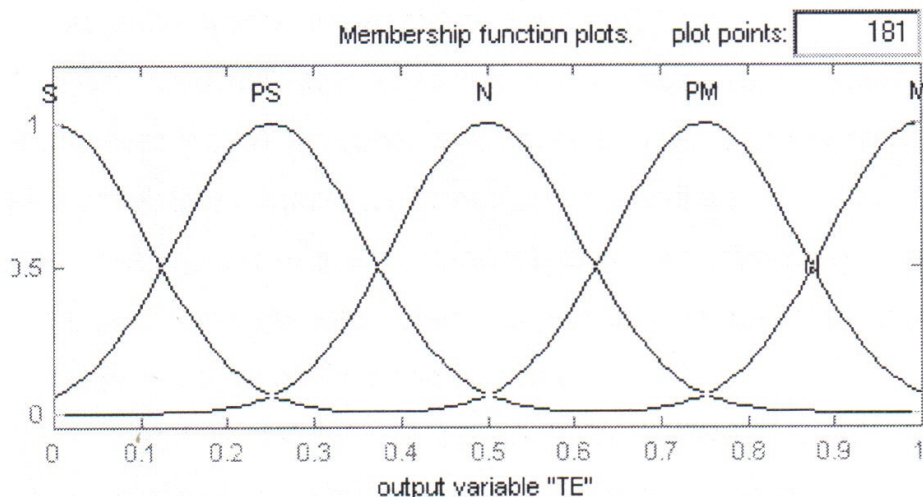


Fig. 2. Variația funcțiilor de apartenență

Se poate utiliza o mare varietate de astfel de funcții: trapezoidale, triunghiulare, gaussiene. Între acestea pot exista relații care matematic sunt interpretate ca fiind intersecții (pentru operatorul **și**), reuniuni (**sau**) și complementaritate (**negația**). Ultima etapă de lucru (cea de defuzificare), se poate realiza prin intermediul mai multor metode, printre care cea mai utilizată este metoda Centrului de Greutate.

Avantajele utilizării modelelor fuzzy pentru conducerea de proces sunt următoarele:

- pot folosi experiența operatorilor umani cei mai pricepuți;
- permit abordarea simplă - fără a necesita cunoștințe de specialitate privind implementarea unor probleme neliniare, care nu pot fi descrise cu ușurință, în mod analitic;
- asigură funcționarea uniformă a unui utilaj pentru care parametrii de intrare prezintă variații aleatoare în timp.

4. MODELAREA CIRCULAȚIEI MATERIALELOR ȘI GAZELOR ÎN INTERIORUL UNEI INSTALAȚII DE PREPARARE CU RECICLAREA MATERIALELOR ASFALTICE, PRIN INTERMEDIUL GRAFURILOR

Pentru a se efectua bilanțurile termice în raport cu un contur precizat este necesară efectuarea unui bilanț de materiale. Se impune deci identificarea tipurilor de fluxuri de materiale care intră/ies în/din diferite echipamente componente ale stației. Un mod de a cunoaște aceste fluxuri este realizarea matricilor de circulație asociate fluxului tehnologic pe operații și echipamente.

Fie schema de principiu a unei instalații complexe de preparare a materialelor asfaltice (conform modelului prezentat în fig.1), cu funcționare discontinuă, în care sunt figurate principalele fluxuri de materiale și gaze care intră sau ies în/ din diferite sisteme componente ale instalației.

Din punct de vedere matematic, atât circulația gazelor (fig. 3b) cât și cea a materialelor (fig. 3a) pot fi reprezentate prin câte un graf în care echipamentele din schemă sunt reprezentate prin nodurile grafului iar transportoarele de material, respectiv gaz – prin săgeți, orientate în sensul de circulație a acestora.

Grafurile de modelare a circulației materialelor și respectiv a gazelor pentru instalația din fig. 1 pot fi reprezentate și matricial (matricile A și D).

Matricea A de modelare a circulației materialului este prezentată în fig. 4 iar matricea D de modelare a circulației gazelor este prezentată în fig. 5.

Elementele matricilor, care au un rol reprezentativ în cazul de față, sunt notate cu 1 – în cazul în care există relații între elementele grafului care modelează echipamentele instalației și corespund pozițiilor considerate sau cu 0 – în cazul lipsei legăturilor directe.

Elementele aflate pe diagonala principală au fost simbolizate cu -1 cu semnificația că relația unui element cu el însuși este fără sens.

În cazul utilizării matricilor pentru reprezentarea cuantificată a transferului de materiale sau de gaze de la un echipament la altul, un element de matrice a_{ij} va trebui să arate fracția gravimetrică de material din echipamentul i și care trece în echipamentul j. Definierea unei astfel de matrici nu face obiectul acestui articol.

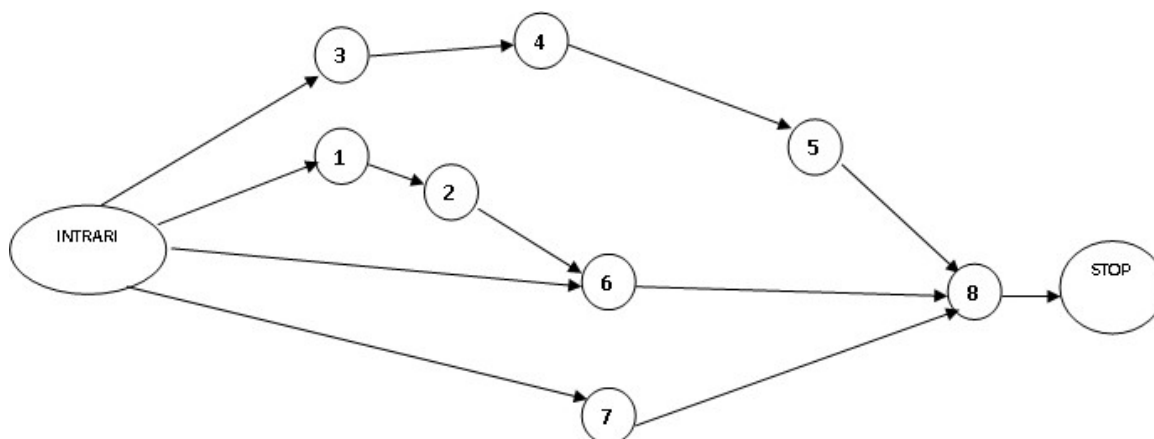


Fig. 3a). Modelarea circulației materialelor prin intermediul grafului

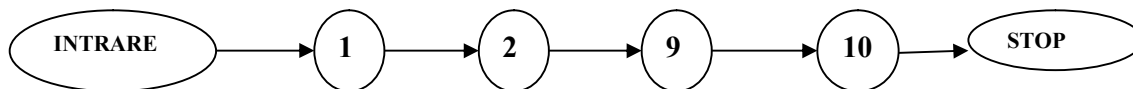


Fig.3b). Modelarea circulației gazelor prin intermediul grafului

Matricea A de circulație a materialelor este definită astfel:

METODE DE MODELARE A INSTALAȚIILOR DE PREPARARE, CU RECICLARE,
A MIXTURILOR ASFALTICE

i/j	1	2	3	4	5	6	7	8	9
1	-1	1	0	0	0	0	1	0	0
2	0	-1	1	0	0	0	0	0	0
3	0	0	-1	1	0	0	0	0	0
4	0	0	0	-1	1	0	0	0	0
5	0	0	0	0	-1	1	0	0	0
6	0	0	0	0	0	-1	0	0	0
7	0	0	0	0	1	0	-1	0	0
8	0	0	0	0	0	0	0	-1	0
9	0	0	0	0	0	0	0	0	-1

Fig. 4. Matricea A de circulație a materialelor

Matricea D de circulație a gazelor este definită astfel :

i/j	1	2	3	4	5	6	7	8	9
1	-1	0	0	0	0	0	1	0	0
2	0	-1	0	0	0	0	0	0	0
3	0	0	-1	0	0	0	0	0	0
4	0	0	0	-1	0	0	0	0	0
5	0	0	0	0	-1	0	0	0	0
6	0	0	0	0	0	-1	0	0	0
7	0	0	0	0	0	0	-1	1	0
8	0	0	0	0	0	0	0	-1	1
9	0	0	0	0	0	0	0	0	-1

Fig. 5. Matricea D de circulație a gazelor

5. CONCLUZII

Dintre metodele matematice de modelare a instalațiilor de preparare a mixturilor asfaltice prezentate, s-a ales spre exemplificare, fiind mai ușor de aplicat în cazul de față metoda modelării circulației materialelor și gazelor în interiorul unei instalații cu funcționare discontinuă, prin intermediul grafurilor și matricilor. În studiile ulterioare trebuie urmărită posibilitatea de reprezentare printr-o matrice cuantificabilă a cantităților de material ce circulă în interiorul instalației. Modelarea instalațiilor poate fi extinsă și în domeniul protecției mediului.

BIBLIOGRAFIE

- [1] Dumitrescu, D., Costin, H. – *Inteligența artificială. Rețele neuronale – Teorie și aplicații, Artificial Intelligence. Neural Networks - Theory and Applications* Editura Teora, , Bucharesti, **1996**;
- [2] Ghizdăveț, Z. D., Guslicov, G., Coarnă M. – “*Modele de prognoză a rezistenței standard a cimenturilor de tip CEM I*”, *Materiale de Construcții*, nr. 2, 2001; *Models for forecasting the strength of standard cement type CEM I*, *Building Materials*, **no. 2, 2001**;
- [3] Tonciu, O. – „*Cercetări privind modelarea alocării resurselor tehnice la procesele de reabilitare a structurilor rutiere, cu reciclarea materialelor asfaltice*” *Research on modeling technical resource allocation processes of rehabilitation of road structures, the recycling of asphalt*”, *PhD thesis* , teza de doctorat, conducător științific: Supervisor: Prof univ. dr. ing. Gh. P. Zafiu, U.T.C.B., **iulie 2010**.