

Contract TE_253/2010

**SOLUTII DE MODELARE, PREDICȚIE ȘI PROIECTARE,
CU MAXIM DE PERFORMANȚĂ, PENTRU REDUCEREA
IMPACTULUI CURENȚILOR DE DISPERSIE ASUPRA
CONDUCTELOR METALICE SUBTERANE DE TRANSPORT GAZ**

Etapă unică / 2011

**Dezvoltarea și implementarea unor tehnici de inteligență artificială
pentru rezolvarea problemelor de interferență dintre linii electrice
aeriene de înaltă tensiune și conducte metalice de transport gaz
Dezvoltarea unei soluții generalizate**

Data predării: 10.12.2011

COLECTIV CERCETARE

Conf. dr. ing. mat. Dan Doru MICU – **Director de proiect**

Ș.l. dr. ing. Denisa ȘTEȚ

Ș.l. dr. ing. Adina RĂCĂȘAN

Drd. ing. Levente CZUMBIL

Cuprinsul raportului anual de activitate II (Ianuarie – Decembrie 2011)

- II.1.** Dezvoltarea și implementarea unor arhitecturi de rețele neuronale pentru evaluarea potențialului magnetic vector, pentru un caz particular de interferență electromagnetică dintre o linie electrică aeriană (LEA) și o conductă metalică subterană (CMS) de transport gaz metan. Analiza bazei de date pentru identificarea mărimilor de intrare.
- II.2.** Determinarea arhitecturii optime a rețelelor neuronale implementate. Alegerea unui set de testare a arhitecturilor implementate și evaluarea rezultatelor obținute. Identificarea arhitecturii optime.
- II.3.** Implementarea unei soluții alternative bazate pe logică fuzzy. Determinarea parametrilor blocului fuzzy implementat prin utilizarea unui algoritm genetic de optimizare a acestora. Identificarea formei optime a setului de legi ce descriu blocul fuzzy implementat.
- II.4.** Implementarea unei rețele neuronale generale care să determine matricea de impedanțe proprii și mutuale ce descrie cuplajul inductiv dintre LEA și CMS în prezența unui sol stratificat cu trei straturi verticale de rezistivitate diferită.
- II.5.** Testarea și validarea metodelor implementate prin realizarea unor măsurători in situ.
- II.6.** Concluzii și contribuții științifice
- II.7.** Bibliografie

II.1. Dezvoltarea și implementarea unor arhitecturi de rețele neuronale

Configurația problemei studiate

Se consideră un caz particular de problemă de interferență electromagnetică LEA – CMS, problemă detaliat prezentată și studiată ca modelare hibridă în Raportul anual de activitate I corespunzător etapei din 2010, a prezentului contract [II.2], respectiv diseminată în [II.1]. Aceasta se referă la un sistem format dintr-o LEA și o CMS care împart un traseu comun de lungime 25 km. Într-un punct B de pe faza conductoare R (aflat la 30 km distanță față de sursă), se presupune apariția unui defect de punere la pământ.

Abordarea problemei prin intermediul tehnicilor de inteligență artificială

Rezolvarea acestei probleme prin intermediul metodei hibride, dezvoltată și prezentată în cadrul Raportului de activitate I [II.2], presupune evaluarea potențialului magnetic vector (PMV) în orice punct al domeniului studiat prin intermediul metodei elementului finit (FEM – finite element method), în vederea determinării ulterioare a matricei impedanțelor proprii și mutuale ce descrie cuplajul inductiv dintre LEA și CMS.

Deoarece FEM-ul presupune rediscretizarea sistemului studiat pentru fiecare nouă geometrie analizată și reluarea continua a calculului numerice, studiul interferențelor electromagnetice LEA IT – CMS pentru diferite geometrii ale sistemului prin FEM presupune un efort de calcul deosebit de ridicat. Așadar, este binevenită orice abordare a problemelor de interferență electromagnetică LEA IT – CMS care pornind de la un set de soluții obținute prin FEM pentru anumite geometrii constructive, să fie capabilă să deducă soluțiile unor geometrii diferite într-un timp efectiv mult mai scurt decât FEM. Astfel de metode, gândite și propuse în cadrul acestui proiect, sunt cele bazate pe aplicarea unor tehnici de inteligență artificială (AI – artificial intelligence), cum ar fi Rețele Neuronale (RN) [II.3] sau Logica Fuzzy (FLS – fuzzy logic system) [II.4].

Analiza bazei de date pentru identificarea mărimilor de intrare. Alegerea setului de date de antrenare

Pentru determinarea structurii RN de implementat, într-o primă etapă autorii au recurs, ca și modalitate de testare, la o evaluare în detaliu a bazei create și prezentate în Raportul de activitate I [II.2]. Baza de date aferentă acestei probleme de interferență electromagnetică conține valorile PMV evaluate cu ajutorul FEM pentru diferite configurații geometrice. În urma analizei efectuate, autorii au identificat parametrii geometrici și electrici care influențează în mod esențial valoarea PMV: d – distanța de separație LEA-CMS, în cazul practic expus aceasta poate varia între 70 m și 2000 m; ρ – rezistivitatea solului, care se variază între 30 $\Omega \cdot m$ și 1000 $\Omega \cdot m$; (x,y) – coordonatele punctului în care se dorește determinarea PMV, acestea fiind situate la orice poziție între 0 m și 2100 m, respectiv 0 m și -30 m.

Ca rezultat al studiului efectuat asupra acestei baze de date, autorii au selectat ca și mărimi de intrare a RN de implementat, parametrii geometrici și electrici prezentați mai sus, mărimea de ieșire care să fie returnată de RN fiind valoarea PVM, definită prin amplitudine și fază. Analiza statistică efectuată a evidențiat de asemenea că amplitudinea PMV variază pe intervalul $1 \cdot 10^{-6} \div 1 \cdot 10^{-3}$ [Wb/m], iar faza pe intervalul $-180^\circ \div 180^\circ$. Astfel, în vederea creșterii acurateții soluțiilor furnizate, s-a stabilit implementarea a două RN diferite pentru evaluarea amplitudinii și respectiv a fazei PMV. În același scop autorii au supus mărimile de intrare unei preprocesări prin care acestea sunt scalate pe intervalul de variație $[-1,1]$, prin raportare la valorile maxime corespunzătoare. În vederea antrenării RN propuse din baza de date aferentă problemei studiate și creată în cadrul Raportului de activitate I [II.2], s-a ales un set de 37 de perechi mărimi de intrare / date de ieșire. Tabelul II.A prezintă aleatoriu selectiv o parte din setul de date utilizat la antrenarea RN:

Tabelul II.A. Setul de date folosit la antrenarea RN

Nr. Crt.	d [m]	x [m]	y [m]	ρ [$\Omega \cdot m$]	PMV	
					Amp. 10^{-5} [Wb/m]	Faza [°]
1	70	70	-15	30	36.1	-22.8
9	400	384.81	-7.82	70	17.2	-44.46
14	70	40	0	100	55.9	-18.53
18	1000	1022.5	0	100	7.23	-67.27
23	300	290.26	-15.8	500	35.5	-26.74
28	700	670	-22.5	700	26	-33.74
33	1500	1499.1	-17.48	900	15.6	-46.35
37	2000	2030	-5	1000	12.2	-52.73

Implementarea Rețelelor Neuronale

Pentru implementarea RN propuse, autorii au dezvoltat **un algoritm și un cod software (m-file)** în cadrul utilitarului MatLab, care să construiască și să antreneze diferite arhitecturi de RN. Alegerea utilitarului MatLab se justifică datorită simplității în utilizare, precum și datorită faptului că permite crearea aproape a tuturor tipurilor de rețele neuronale, începând de la perceptrone, până la arhitecturi mai complicate de tip feed-forward sau rețele recurente [II.5]. Funcția de interfață:

$$[NNMat] = \text{Create_MVP_NN}(\text{InPut}, \text{Target}, \text{NNType}) \quad (2.1)$$

Funcția finală dezvoltată, *Create_MVP_NN*, implementează o serie de RN cu un singur strat ascuns de tip feed-forward sau layer recurent (RN recurente) în raport cu parametrul *NNType*. Funcția returnează aceste RN sub forma unei matrice ale cărei elemente sunt RN cu un număr variabil de neuroni pe stratul ascuns și diferite funcții de transfer definite după un tipar prestabilit de către cercetători.

În urma studiului literaturii de specialitate [II.6], [II.7] și a testării în prealabil a diferitelor tehnici de antrenare, s-a recurs la utilizarea tehnicii Levenberg-Marquardt care produce cele mai bune soluții, necesitând un timp de antrenare de ordinul secundelor, foarte scurt pentru setul ales. Pe baza unui alt cod software generat de către autori, acest set de date de antrenare este furnizat funcției *Create_MVP_NN* prin intermediul perechilor de date de intrare / ieșiri dorite, reprezentate de cei doi parametri *Input* și *Target*.

În scopul comparării rezultatelor obținute cu diferite RN implementate, autorii au dezvoltat **un alt algoritm software** având ca finalitate o a doua funcție *EvalMVPNN*, care să determine eroarea de calcul a soluțiilor furnizate de aceste RN. Funcția primește ca și parametri matricea de RN obținută prin intermediul funcției *Create_MVP_NN*, respectiv setul de date de antrenare și un set de testare care nu a fost furnizat RN în cadrul procesului de antrenare. Aceste date de antrenare, respectiv testare sunt definite prin intermediul parametrilor *TrInput*, *TrTarget*, respectiv *TsInput* și *TsTarget*:

$$[\text{ResMat}] = \text{EvalMVPNN}(\text{NNMat}, \text{TrInPut}, \text{TrTarget}, \text{TsInPut}, \text{TsTarget}) \quad (2.2)$$

Funcția *EvalMVPNN* returnează eroarea absolută, respectiv procentuală medie și maximă de determinare a soluțiilor furnizate de PMV, atât pentru setul de date de testare cât și pentru cel de antrenare.

II.2. Determinarea arhitecturii optime a rețelelor neuronale implementate

Pentru **determinarea arhitecturii optime** a RN propuse, **s-au implementat diferite arhitecturi de RN** de tip feed-forward (figura II.2a) și layer recurent (figura II.2b) cu un singur strat ascuns, folosind un cod software dedicat, având ca interfață funcția *Create_MVP_NN*. Numărul de neuroni din straturile ascunse a fost variat de la 5 la 30, cu un pas de 5 neuroni. Funcția de transfer a stratului de ieșire a fost setată ca fiind liniară, codată prin denumirea *purelin*, iar cea a stratului ascuns a fost variată între o formă sigmoidă *logsig*, respectiv una tangentă hiperbolică *tansig*. De asemenea, funcția de performanță a RN a fost variată între *mse* (eroare medie pătratică), *msereg* (eroare medie pătratică cu regularizare) și *sse* (eroare sumă pătratică). Ca urmare, autorii **au implementat 64 de arhitecturi** pentru ambele RN care returnează amplitudinea, respectiv faza PMV.




Figura II.2. Structura rețelelor neuronale implementate: a) RN feed-forward, b) RN recurentă

Scopul **implementării RN fiind determinarea PMV pentru geometrii noi**, care nu au fost evaluate în prealabil cu FEM, pentru a testa acuratețea rezultatelor furnizate de acestea, pe lângă setul de date de antrenare, s-a ales aleatoriu și un set de date de testare care nu a fost furnizat RN în cadrul procesului de antrenare. În urma **simulărilor optimele** cu ajutorul funcției *EvalMVPNN* a abaterii absolute și procentuale dintre valorile PMV furnizate de RN implementate, respectiv cele calculate cu FEM, autorii **au efectuat un studiu statistic** asupra abaterilor furnizate de cele 64 de arhitecturi studiate. Rezultatul s-a concretizat în **identificarea arhitecturilor optime** ale celor două RN propuse pentru evaluarea amplitudinii și fazei PMV [II.8].

Rezultate obținute pentru RN feed-forward

În cazul RN care determină amplitudinea PMV, arhitectura optimă s-a dovedit a fi o structură cu 10 neuroni pe stratul ascuns având ca transfer funcția *tansig* și ca performanță funcția *mse*. Figura II.3 prezintă abaterea absolută obținută, atât pentru setul de date de antrenare cât și pentru cel de antrenare. Eroarea relativă medie de evaluare a amplitudinii PMV este de 0.71%.




Figura II.3. Eroarea Absolută de determinare a amplitudinii și fazei PMV

Pentru RN care determină faza PMV, arhitectura optimă s-a dovedit a fi o structură cu 5 neuroni pe stratul ascuns, având ca funcție de transfer funcția *logsig* și ca funcție de performanță funcția *sse*. În acest caz, eroarea procentuală medie de determinare a fazei PMV este de 1.19%, iar cea maximă de 5.47%.

Rezultate obținute pentru RN recurente (layer recurrent)

În cazul RN care determină amplitudinea PMV, arhitectura optimă s-a dovedit a fi o structură cu 10 neuroni pe stratul ascuns, având ca transfer funcția *logsig* și ca performanță funcția *mse*. Figura II.4 prezintă abaterea absolută obținută, pentru ambele seturi de date. Eroarea relativă medie de determinare a amplitudinii PMV este de 0.35%, iar cea maximă de 1.08%.




Figura II.4. Eroarea Absolută de determinare a amplitudinii și fazei PMV

Pentru RN care determină faza PMV, arhitectura optimă s-a dovedit a fi o structură cu 5 neuroni pe stratul ascuns având ca transfer funcția *tansig* și ca performanță funcția *msereg*. Eroarea relativă medie de determinare a fazei PMV este de 1.19%. Analizând rezultatele prezentate în figurile II.3÷II.4, autorii au constatat că atât RN de tip feed-forward, cât și cele de tip layer recurrent furnizează soluții de o acuratețe ridicată. Cu toate că RN de tip *layer recurrent* prezintă soluții de o mai mare acuratețe, acestea necesită un timp de antrenare de 3÷4 ori mai lung decât cele de tip *feed-forward*. Se sugerează utilizarea RN de tip *feed-forward* dacă setul de date de antrenare depășește 1000 de perechi de date de intrare / valori de ieșire dorite.

II.3. Implementarea unei soluții alternative bazate pe logică fuzzy

Implementarea unei soluții alternative bazate pe logică fuzzy

O posibilă alternativă în evaluarea PMV în orice punct al domeniului studiat ar fi **aplicarea unei tehnici de inteligență artificială bazată pe logica fuzzy** [II.9], [II.10]. Ca urmare, colectivul de cercetare implicat **propune spre testare un Bloc Fuzzy (BLF)** care primește ca și parametri direcți de intrare, distanța d de separație LEA-CMS, respectiv rezistivitatea solului ρ , iar ca parametri indirecti, distanța l dintre punctul în care se dorește evaluarea PMV și faza defectă, respectiv distanța l' dintre punctul de evaluare și CMS. Pe baza cunoștințelor dobândite din studiul bazei de date creată anterior și a experienței profesionale în domeniul interferențelor electromagnetice LEA – CMS, colectivul de cercetare **propune un set de legi fuzzy** care să guverneze funcționarea blocului fuzzy și care poate fi descris de forma generală a legii j în modul următor:

$$L^j : \text{DACA } d \text{ și } \rho \text{ aparțin funcției de apartenență } \mu_d^j \text{ și } \mu_\rho^j \text{ ce descriu legea } j \quad (2.3)$$

$$\text{ATUNCI } A^j = \lambda_0^j + \lambda_1^j \cdot \frac{1}{l^2 + c} + \lambda_2^j \cdot \frac{1}{l'^2 + c}$$

unde c reprezintă o constantă introdusă pentru înlăturarea erorilor de calcul numeric care pot apărea în cazul în care punctul de calcul se găsește pe suprafața conductei, sau în punctul de origine (0,0), iar λ_0^j , λ_1^j și λ_2^j reprezintă un set coeficienți care determină valoarea PMV de ieșire, A^j , furnizată de fiecare lege j . Pentru stabilirea apartenenței unei perechi de parametri de intrare direcți (d, ρ) la o lege j , s-au utilizat funcții de apartenență de tip Gauss, relația (2.4), iar valoarea de ieșire furnizată de către **blocul fuzzy implementat ca și cod software**, se obține pe baza mediei algebrice ponderate a valorilor de PMV furnizată de fiecare lege j în parte, relația (2.5):

$$\mu_\Delta^j(\Delta) = \exp \left[-\frac{1}{2} \cdot \left(\frac{\Delta - \bar{\alpha}_\Delta^j}{\sigma_\Delta^j} \right)^2 \right] \quad (2.4)$$

$$A(d, \rho) = \frac{\sum_{j=1}^m (A^j \cdot \mu^j)}{\sum_{j=1}^m \mu^j} \quad (2.5)$$

unde $\Delta \in \{d, \rho\}$, iar $\bar{\alpha}_\Delta^j$ și σ_Δ^j reprezintă valoarea medie și abaterea standard a funcției de apartenență de tip Gauss, iar $\mu^j = \mu_d^j(d) \cdot \mu_\rho^j(\rho)$. Acest BLF a fost implementat ca interfață în Matlab sub forma unei funcții, f_BLF .

Determinarea parametrilor blocului fuzzy implementat prin utilizarea unui algoritm genetic de optimizare a acestora

În continuare, pentru a determina parametrii optimi ($\bar{\alpha}_d^j$, $\bar{\alpha}_\rho^j$, σ_d^j , σ_ρ^j , λ_0^j , λ_1^j și λ_2^j) ce descriu setul de legi ai blocului fuzzy, autorii **au implementat un cod software propriu unui algoritm genetic (GA) de optimizare** a selecției acestora [II.11]. **Algoritmul genetic propus** pornește de la o populație de 50 de indivizi generați aleatoriu, fiecare individ al populației reprezentând o combinație posibilă de parametri ai BLF. Evaluarea acestor indivizi se realizează pe baza abaterii medii pătratice dintre valoarea furnizată de FLS corespunzător și valoarea PMV obținută prin analiză FEM, pe modelele testate:

$$J_{av} = \frac{1}{2q} \cdot \sum_{p=1}^q [A_{FLS}^p(d, x, y, \rho) - A_{FEM}^p(d, x, y, \rho)]^2 \quad (2.6)$$

unde q este numărul de perechi de parametri de intrare / parametri de ieșire folosiți în cadrul procesului de optimizare, $A_{FLS}^p(d, x, y, \rho)$ este valoarea PMV furnizată de BLF corespunzător individului testat, iar $A_{FEM}^p(d, x, y, \rho)$ este valoarea PMV obținută cu FEM pentru un set de date de intrare (d, ρ, x, y).

Pentru a optimiza parametrii (α , σ și λ), indivizii populației de pornire sunt supuși unui proces iterativ format din următorii pași: **Pasul 1:** Toți indivizii populației curente sunt evaluați, după care se alege cel mai bun individ și se plasează direct în populația corespunzătoare următoarei generații (iterații); **Pasul 2:** Se aleg aleatoriu doi indivizi din populația curentă și se supun unui proces de încrucișare în urma căreia se obțin alți doi indivizi noi pentru populația generației viitoare; **Pasul 3:** Se repetă **Pasul 2** până când populația generației viitoare va atinge același număr de indivizi ca și generația curentă; **Pasul 4:** Toți indivizii din noua generație, mai puțin individul reprezentând cea mai bună soluție, sunt supuși unui proces de mutație.

Acest proces iterativ este repetat de un număr stabilit pentru acest caz de 5000 de ori, sau până când eroarea medie pătratică pentru cea mai bună soluție este mai mică decât o valoare impusă în prealabil.

Parametrii care descriu setul de legi ai BLF și care trebuie supuși procesului de optimizare sunt reprezentați sub forma valorii lor reale în structura cromozomială a fiecărui individ:

$$C = \left(\alpha_A^{n(A)}, \sigma_A^{n(A)}, \lambda_{\delta}^j \right), A = d, \rho, \delta = 0, 1, l', j = 1..m \quad (2.7)$$

În urma procesului de încrucișare din cei doi indivizi selectați pe post de părinți se obțin patru noi indivizi (copii). Primii doi urmași sunt obținuți în urma unui operator de încrucișare aritmetic, iar următorii doi pe baza unui operator de încrucișare genetic:

$$C_1^t = \alpha \cdot P_1^t + (1-\alpha) \cdot P_2^t; C_2^t = \alpha \cdot P_2^t + (1-\alpha) \cdot P_1^t \quad (2.8) \quad C_3 = (P_1^1 \dots P_1^k P_2^{k+1} \dots P_2^r); C_4 = (P_2^1 \dots P_2^k P_1^{k+1} \dots P_1^r) \quad (2.9)$$

unde α este o valoare aleatoare între 0 și 1, r este numărul total de cromozomi, iar k este poziția, aleasă în mod aleatoriu, în care să se aplice operatorul de încrucișare genetică asupra celor doi părinți.

Operatorul de mutație este aplicat cu o probabilitate diferită asupra fiecărui cromozom al unui individ selectat spre a fi supus procesului de mutație. Dacă testul de probabilitate este trecut cu succes, atunci are loc mutația, ceea ce presupune că al t -lea cromozom va lua următoarea valoare:

$$C^t = C^t + (0.5 - \alpha) \cdot h \quad (2.10)$$

unde α este o valoare aleatoare în palierul 0 și 1 ce reprezintă nivelul de mutație aplicat, iar h reprezintă distanța minimă dintre valoarea parametrului reprezentat de cromozomul C^t și limitele de variație a acestui parametru.

Pentru a implementa GA propus, autorii **au dezvoltat un algoritm software** în cadrul programului MatLab, având ca interfață funcția de optimizare:

$$[SolQualSol, Time] = f_GAFuzz(RNo, DNo) \quad (2.11)$$

care determină parametrii (α , σ și λ) pentru un set dat de legi fuzzy. Funcția primește ca și parametri de intrare numărul (RNo , DNo) de funcții de apartenență care partajează cei doi parametri direcți de intrare ai BLF (ρ și d), și returnează setul de parametri optimizați (Sol), eroarea medie pătratică obținută pentru setul de date de antrenare folosit ($SolQual$), respectiv timpul de antrenare necesar determinării parametrilor optimi ($Time$).

Identificarea formei optime a setului de legi ce descriu blocul fuzzy implementat

Pentru a identifica structura optimă a BLF implementat, s-au testat diferite seturi de legi fuzzy variind între 3 și 7 numărul de funcții de apartenență care partajează distanța de separație d , respectiv rezistivitatea solului ρ pe intervalele lor de variație, obținându-se un număr total de 25 de structuri diferite de BLF. Parametrii acestor BLF au fost determinați folosindu-se setul de date de antrenare utilizat și la implementarea RN prezentate în cadrul paragrafului II.2, respectiv GA prezentat mai sus. După determinarea valorilor optime (α , σ și λ), s-a evaluat eroarea medie pătratică de determinare a PMV cu aceste BLF și s-a comparat timpul de antrenare a acestora. Tabelul II.B prezintă cele mai bune trei structuri de BLF identificate de către autori, după analiza în detaliu a soluțiilor furnizate de cele 25 structuri diferite implementate:

Din tabelul II.B se observă că cele mai bune soluții se obțin pentru o structură de tip 5x7, adică un număr total de 35 de legi fuzzy. Creșterea numărului de legi fuzzy care descriu BLF implementat are și un efect secundar negativ, reprezentat de creșterea semnificativă a timpului de calcul necesar pentru determinarea valorilor optime ale parametrilor (α , σ și λ), prin intermediul GA implementat. Figura II.5 prezintă abaterea absolută a PMV determinate cu ajutorul structurii optime a BLF, identificate atât pentru setul de antrenare, cât și pentru cel de testare folosite și pentru antrenarea RN.




Figura II.5. Eroarea Absolută de determinare a PMV

Tabelul II.B. Diferite structuri de BLF implementate

Nr. Crt.	RNo	DNo	SolQual	Time
1	4	6	6.530	16min06sec
2	5	5	5.317	16min35sec
3	5	7	3.641	20min52sec

II.4. Implementarea unei rețele neuronale generale care să determine matricea de impedanțe

Configurația problemei studiate

O conductă metalică subterană de transport gaze naturale împarte același coridor de distribuție cu o linie electrică aeriană de 220 kV/50 Hz (Figura II.6). În vederea studierii unei game mult mai largi de probleme de interferență LEA – CMS, se consideră un sol multistrat (cu trei straturi verticale) cu rezistivități diferite. Conducta este considerată a fi îngropată la o adâncime de 2 m, are o rază de 0.195 m, un perete de grosime 5 mm și o izolație de bitum de 15 mm. Conductoarele de fază a LEA sunt plasate pe stâlpi triunghiulari mono-circuit de tip IT.Sn102 cu un singur fir de gardă.




Figura II.6. Problema de interferență LEA-CM în prezența solului cu 3 straturi verticale

Determinarea matricei de impedanțe proprii și mutuale ce descrie cuplajul inductiv dintre LEA și CMS

Colectivul de cercetare a implementat o RN generală care să calculeze direct matricea de impedanțe proprii și mutuale care descrie cuplajul inductiv dintre LEA și CMS. O dată evaluată matricea de impedanțe, aceasta permite evaluarea tensiunilor induse în CMS atât în regim de funcționare normală a LEA, cât și în regimuri de defect prin intermediul modelului de circuit electric echivalent dezvoltat și implementat în cadrul Raportului de activitate I [II.2].

Analizând baza de date obținută prin evaluare cu ajutorul FEM a mai multor configurații geometrice de bază, s-au stabilit parametrii de intrare a RN propus și domeniul de variație al acestora: d care variază între 0 m și 1000 m; ρ_1, ρ_2, ρ_3 – rezistivitatea straturilor verticale, între 30 $\Omega \cdot m$ și 1000 $\Omega \cdot m$; D – lățimea stratului de mijloc, între 50 m și 1100 m.

Aceste mărimi de intrare sunt supuse unei preprocesări prin care sunt scalate pe intervalul de variație $[-1,1]$. Mărimile de ieșire ale RN implementate vor fi elementele matricei de impedanțe. Considerând faptul ca matricea de impedanțe proprii și mutuale este o matrice pătratică simetrică, RN propusă trebuie să determine doar elementele de deasupra diagonalei principale. Astfel Z_{ii} reprezintă impedanța proprie a conductorului i , iar Z_{ij} reprezintă impedanța mutuală dintre conductorul i și conductorul j ($i = \overline{1,3}$ reprezintă conductoarele de fază a LEA, $i = 4$ reprezintă firul de gardă, iar $i = 5$ reprezintă CMS).

Studiul detaliat al matricelor de impedanțe proprii și mutuale obținute pentru diferite configurații geometrice a evidențiat faptul că în vederea obținerii unor soluții cu o acuratețe sporită, ar fi mai convenabil să se implementeze RN diferite pentru partea reală și imaginară a acestor impendante. De asemenea, s-a constatat că ar fi indicat să se implementeze 3 RN diferite: RN1 care să calculeze impedanța proprie a tuturor conductoarelor ($Z_{11}, Z_{22}, Z_{33}, Z_{44}, Z_{55}$); RN2 care să calculeze impedanțele mutuale dintre CMS și celelalte conductoare ($Z_{15}, Z_{25}, Z_{35}, Z_{45}$); respectiv RN3 care să calculeze restul elementelor matricei de impedanțe. Pentru antrenarea acestor RN propuse, s-a utilizat un set de date de antrenare de peste 5000 de elemente determinate prin evaluarea FEM a diferitelor configurații geometrice de bază [II.12], [II.13]. Tabelul II.C prezintă o parte din aceste date de antrenare:

Tabelul II.C. Setul de date folosit la antrenarea RN

Nr. Crt.	d [m]	D [m]	ρ_2 [$\Omega \cdot m$]	ρ_1 [$\Omega \cdot m$]	ρ_3 [$\Omega \cdot m$]	Nr.Crt.	d [m]	D [m]	ρ_2 [$\Omega \cdot m$]	ρ_1 [$\Omega \cdot m$]	ρ_3 [$\Omega \cdot m$]
8	5	60	500	50	500	2301	20	550	30	250	30
373	100	60	500	750	500	2532	100	550	100	500	100
875	20	120	100	750	100	2914	5	1050	10	250	10
1231	500	120	100	30	100	3274	100	1050	500	1000	500
1391	0	240	50	10	50	3545	750	1050	30	750	30
1891	250	240	500	30	500	4320	750	1500	50	10	50
2134	0	550	50	250	50	4442	1000	1500	250	1000	250

Identificarea arhitecturii optime a RN implementate. Rezultate obținute

Pentru a identifica structura optimă a RN propuse, autorii au dezvoltat un program de interfață cu programul Matlab, prin care să se implementeze și să antreneze arhitecturi de tip feed-forward cu două straturi ascunse, la care s-a variat numărul de neuroni între 5 și 30 pentru primul strat ascuns și între 5 și 20 pentru cel de al doilea strat ascuns. Funcția de transfer a straturilor ascunse a fost setată la *tansig*, iar a stratului de ieșire la *purelin*. Pentru antrenarea RN implementate s-a utilizat metoda Levenberg-Marquard. Astfel, prin intermediul funcției de interfață *CreateImpedNN* s-au implementat și antrenat un număr total de 24 arhitecturi diferite pentru toate cele trei RN prezentate mai sus (RN1, RN2 și RN3):

$$[NNMat] = CreateImpedNN(InPut, Target) \quad (2.12)$$

Pentru a se putea compara rezultatele obținute cu diferitele arhitecturi de RN implementate, autorii au dezvoltat o funcție *EvalNNErrorClass* care să determine eroarea de evaluare a soluțiilor furnizate, atât pentru setul de date de antrenare cât și pentru un set de date de testare aleatoriu determinate, care nu a fost furnizat RN implementate în cadrul procesului de antrenare. Luând în considerare dimensiunea mare a seturilor de date de antrenare (5000 de elemente), respectiv de antrenare (100 de elemente), pentru a compara mai ușor erorile de evaluare furnizate de diferitele RN, funcția *EvalNNErrorClass* returnează distribuția erorilor de evaluare pe clase de erori. În urma efectuării unui studiu statistic al acestor distribuții procentuale a erorilor de evaluare, autorii au identificat arhitecturile optime pentru cele trei tipuri de RN. În cazul rețelei RN1 pentru evaluarea părții reale a impedanțelor, s-a constatat că arhitectura optimă o reprezintă o rețea feed-forward cu 30 de neuroni pe primul strat ascuns și 10 neuroni pe cel de al doilea strat ascuns, iar pentru a evalua partea imaginară a impedanțelor, arhitectura optimă o constituie o structură cu 20 de neuroni pe cele două straturi ascunse. Figura II.7 prezintă distribuția erorii procentuale obținute, atât pentru setul de date de antrenare, cât și pentru un set de date de testare care nu a fost furnizat RN în cadrul procesului de antrenare.




Figura II.7. Distribuția erorii procentuale în cazul RN1 și RN 2: a) Evaluarea părții Reale, b) Evaluarea părții Imaginare

În cazul rețelei RN3 pentru evaluarea părții reale a impedanțelor s-a constatat că arhitectura optimă o reprezintă o rețea feed-forward cu 20 de neuroni pe ambele straturi ascunse, iar pentru a evalua partea imaginară a impedanțelor arhitectura optimă o constituie o structură cu 30, respectiv 20 de neuroni pe primul, respectiv al doilea strat ascuns.

Datorită faptului că partea reală a impedanțelor mutuale dintre CMS și restul conductoarelor variază într-o gamă foarte largă de valori, între 1E-11 și 1E-6, implementarea RN3, pentru evaluarea părții reale și imaginare a acestor impedanțe a condus la

furnizarea unor soluții de o acuratețe scăzută. Pentru eliminarea acestui inconvenient, autorii au recurs la **implementarea a două RN3** care să evalueze modulul și argumentul acestor impedanțe mutuale. În cazul RN3 care evaluează modulul, arhitectura optimă o constituie o RN cu 30 de neuroni pe primul strat ascuns și 25 de neuroni pe al doilea strat ascuns. Iar în cazul RN3 care evaluează argumentul, arhitectura optimă conține 20 de neuroni pe cele două straturi ascunse.

De asemenea, pe modelul acestor RN s-au implementat o serie de alte RN care să evalueze matricea impedanțelor proprii și mutuale care descriu cuplajul inductiv dintre LEA – CMS pentru diferite configurații ale LEA. A fost creat un bloc fuzzy care identificând structura LEA pe baza unui parametru de intrare (identificator număr tip de stâlp), să apeleze RN corespunzătoare și să construiască matricea completă de impedanțe proprii și mutuale.

II.5. Testarea și validarea metodelor implementate prin realizarea unor măsurători in situ

În cadrul colaborării inițiate cu Operatorul de Transport gaze naturale, **SNTGN TRANSGAZ România**, în contextul în care în următorii ani se va realiza magistrala gazoduct NABUCCO, există un interes deosebit încă din faza de proiectare, pentru stabilirea, identificarea exactă și prevenirea interferențelor electromagnetice datorate unor LEA care actualmente sunt plasate pe coordonatele traseului magistralei de gaz. În această problemă, pe lângă caracteristicile fizice și electrice ale surselor perturbatoare, se ia în calcul și compoziția pe straturi a solului, sau modalitatea de pozare a conductei de gaz.

În vederea **validării și testării metodelor implementate pentru calculul tensiunilor induse** în CMS, plasate în apropierea LEA-IT s-au efectuat o serie de **măsurători in-situ** pentru un caz practic furnizat de SNTGN TRANSGAZ. [II.15]

Datele colectate în urma măsurătorilor efectuate au fost utilizate ca și valori de referință în procesul de validare a rezultatelor furnizate cu ajutorul BLF și RN dezvoltate.

Problema studiată prezintă cazul unei conducte de transport a gazului metan, care împarte pe o porțiune același coridor de distribuție cu o LEA de înaltă tensiune. În vederea **determinării tensiunilor induse** au fost necesare o serie de date care să descrie parametrii constructivi ai problemei. O parte dintre acești parametri au fost selectați din planurile tehnice de construcție a coridorului comun de distribuție LEA-CMS și din cataloage de material: diametru conductă interior : 1219 mm; izolație cu bitum; adâncimea de îngropare - 1,1 m de la generatoarea superioară; grosime izolație : 10 mm; grosime perete conductă : 14 mm; lungime paralelism : 2000 m; distanța la LEA – 70 m până la conductorul de gardă (axul liniei); distanța conductă până la cea mai apropiată împământare a unui stâlp LEA - 35 m. LEA funcționează la nivelul de tensiune 400 kV cu o încărcare medie de 500A pe fază, conform informațiilor primite de la **TRANSELECTRICA**.

Pentru determinarea **rezistivității solului și a rezistențelor de dispersie** ale prizelor de pământare s-au realizat o serie de **măsurători in-situ**. Măsurarea rezistivității solului s-a realizat cu un tester specializat de tip MEGGER DET 5/4 R având domeniu de măsurare $0.02\Omega \dots 19.99K\Omega$, prin metoda celor 4 electrozi, specifică metodei Wenner de măsurare. În urma măsurătorilor efectuate în diferite locații de-a lungul coridorului comun de distribuție s-a constatat că pe lungimea de 2000 m solul se poate considera a fi stratificat în 3 straturi verticale cu rezistivități între 100 - 120 Ω/m .




Figura II.8: Măsurarea potențialului indus

Potențialul electric indus s-a măsurat cu ajutorul unui voltmetru electronic (rezistența de intrare peste 1 $M\Omega/V$), și un electrod de referință, conform figurii II.8 (1 - priza de potențial, 2 – milivoltmetru, 3 - electrod Cu/CuSO₄). **Prezența curenților de dispersie** este observată instantaneu pe ecranul unui osciloscop portabil de tip Fluke 105 Scopemeter, prezentând o formă de undă neregulată. S-au pus în evidență **amplitudinea maximă a semnalului**, valorile efective ale potențialului conductă - sol. În urma plasării schemei de montaj în diverse puncte de-a lungul coridorului comun LEA-CMS au rezultat următoarele valori ale tensiunii induse în conductă măsurate din 400 m în 400 m.




Figura II.9.: Valorile experimentale (măsurate) ale tensiunii induse




Figura II.10: Reprezentarea grafică a tensiunii induse la capătul conductei



Tabel II.D: Înregistrarea măsurătorilor

Locația	Tensiunea indusă
0 m	5.91 V
400 m	3.86 V
800 m	1.51 V
1200 m	1.48 V
1600 m	3.98 V
2000 m	5.96 V

Figura II.10 prezintă **înregistrările osciloscopului portabil** la capătul coridorului comun de distribuție, unde tensiunea indusă este maximă deoarece la capetele coridorului sunt poziționate joncțiunile de izolare a conductei față de sol și restul traseului.

Rezultate obținute prin implementarea problemei cu ajutorul tehnicilor de inteligență artificială dezvoltate

Implementând același studiu de caz în **BLF dezvoltat**, s-au determinat **valorile potențialului magnetic vector** pe suprafața secțiunii transversale a conductei metalice, a conductoarelor de fază și respectiv a firelor de gardă. S-au implementat două blocuri de **Logică Fuzzy** care au evaluat amplitudinea respectiv faza PMV într-un punct al secțiunii transversale a coridorului de distribuție, specificat de utilizator. Cele două blocuri de **Logică Fuzzy** au fost antrenate folosind un set de date obținute printr-o analiză a problemei, bazată pe metoda elementului finit pentru mai multe configurații geometrice LEA-CMS și cu 3 straturi de separare verticale. Folosind valorile PMV pe suprafața secțiunilor transversale ale conductei metalice, conductoarelor de fază și respectiv firelor de gardă, pe baza relațiilor de calcul dezvoltate în [II.2], se calculează **valorile inductivităților proprii și mutuale LEA-CMS**.



Tabelul II.E: Inductivitățile proprii pe unitate de lungime

Structura Metalică	$L_{prop} \cdot 10^{-7} [H/m]$
Conductorul de fază R (CF1)	23.45005-1.50212j
Conductorul de fază S (CF2)	23.46877-1.53024j
Conductorul de fază T (CF3)	23.49061-1.53031j
Firul de Gardă 1 (FG1)	28.88256-1.44776j
Firul de Gardă 2 (FG2)	28.90446-1.44777j
Conducta Metalică (CM)	14.48759-1.97304j

Figura II.11: Tensiunea respectiv curentul indus în CMS

Se face apel la structurile de calcul și rezultatele obținute în [II.2]. Astfel în urma soluționării sistemului de ecuații corespunzător metodelor de rezolvare al circuitului electric echivalent și în urma implementării datelor în BLF și RN dezvoltat, se determină curenții din conductorii de fază precum și curenții induși în CMS și în firele de gardă. Se determină și **forma tensiunii electromotoare induse** în CMS.

Din grafic se poate observa că **valoarea maximă a tensiunii induse** în conducta metalică este de 5.74 V, ceea ce este o valoare apropiată față de cea măsurată 5.96 V la capetele coridorului comun. Se obține o **valoare maximă a curentului indus** de aproximativ 0.1 A, la mijlocul tronsonului de conductă care împarte același coridor de distribuție cu LEA.

II.6. Concluzii și contribuții științifice

Deoarece FEM-ul presupune rediscrétizarea sistemului studiat pentru fiecare nouă geometrie analizată și reluarea de la zero a tuturor calculului numerice, studiul interferențelor electromagnetice LEA IT – CMS, pentru diferite geometrii ale sistemului prin FEM, presupune un efort de calcul deosebit de ridicat. Așadar, este binevenită orice abordare a problemelor de interferență electromagnetică LEA IT – CMS, care pornind de la un set de soluții obținute prin FEM pentru anumite geometrii constructive, să fie capabilă să deducă soluțiile unor geometrii diferite într-un timp efectiv mult mai scurt decât FEM și astfel să permită abordarea unui palier larg de situații practice posibile.

Prezentul raport anual de cercetare reflectă sintetic **dezvoltarea și implementarea unor tehnici de inteligență artificială** cum ar fi rețelele neuronale și logica fuzzy care **să determine potențialul magnetic vector** în orice punct al domeniului studiat pentru un caz practic de problemă de interferență LEA-CMS, în multiple configurații geometrice și fizice posibile. Pornind de la experiența dobândită în urma acestei probleme concrete studiată, **s-au implementat o serie de rețele neuronale generale** care să determine **matricea de impedanțe proprii și mutuale** care descrie cuplajul inductiv dintre LEA și CMS pentru diverse configurații specifice de LEA și CMS. Activitatea de cercetare se finalizează prin **implementarea unui program software - bloc fuzzy** capabil să **identifice** tipul problemei de interferență LEA – CMS studiate și să **apeleze** rețelele neuronale corespunzătoare studiului problemei respective.

Astfel, se consideră că s-au îndeplinit obiectivele propuse în proiect, anume s-a realizat: Dezvoltarea și implementarea unor arhitecturi de rețele neuronale pentru determinarea unei soluții viabile în studiul interferențelor electromagnetice LEA-CMS; Determinarea arhitecturii optime pentru rezolvarea unei probleme tipice de interferența electromagnetică dintre liniile electrice aeriene și conductele metalice de transport gaz; Implementarea unei soluții alternative bazate pe logică fuzzy; Determinarea parametrilor blocului fuzzy implementat prin utilizarea unui algoritm genetic de optimizare a acestora; Identificarea formei optime a setului de legi ce descriu blocul fuzzy dezvoltat; Implementarea unor rețele neuronale generale care să determine matricea de impedanțe proprii și mutuale care descrie cuplajul inductiv dintre LEA și CMS, în prezența unui sol stratificat cu trei straturi verticale de rezistivitate diferită pentru orice configurație LEA – CMS; Implementarea unui Bloc Fuzzy principal care să identifice tipul de problemă de interferență LEA – CMS studiată și care să apeleze Rețelele Neuronale specifice pentru a construi matricea de impedanțe proprii și mutuale ce descrie cuplajul inductiv dintre LEA și CMS; Testarea și validarea metodelor implementate prin realizarea unor măsurători in situ.

Bibliografie

- [II.1]. D.D. Micu, L. Czumbil, G.C. Christoforidis, A. Ceclan, *Proposed Monte Carlo – Neural Network method for solving Electromagnetic Interference Problems*, 45th International Universities Power Engineering Conference, UPEC 2010, Proceedings on CD, ISBN: 978-0-9565570-1-8, Cardiff, Whalse, September 1-3, **2010**.
- [II.2]. D. D. Micu, D. Ștef, A. Răcășan, L. Czumbil, *Dezvoltarea unei metode hibride generalizate pentru determinarea efectelor interferențelor inductive și conductive asupra conductelor metalice subterane de transport gaz care împart același coridor de distribuție cu o LEA*, Raport de activitate I, Contract TE_253/2010.
- [II.3]. S. Al-Alawi, A. Al-Badi, K. Ellity: *An artificial neural network model for predicting gas pipeline induced voltage caused by power lines under fault conditions*. COMPEL: Intern. Journal for Computation and Mathematics in Electrica land Electronic Engineering, Vol. 24, No. 1, **2005**.
- [II.4]. K.J. Satsios, D.P. Labridis: *Finite Element Calculations and Fuzzy Logic Development*. IEEE Trans. Magn., Vol. 35, No. 1, **1999**.
- [II.5]. M.H. Beale, M.T. Haga, H.B. Demuth, *Neural Network Toolbox – User's Guide*, ver. 7.0.2 (2011b), The MATHWORKS Inc., **2011**.
- [II.6]. M. Caudil, C. Butler: *Understanding Neural Networks: Computer Exploration*, Vol. 1÷2, MA: the MIT Press, Cambridge, **1992**.
- [II.7]. C. Voloșenco: *Sisteme Fuzzy și Neuronale*, Timișoara, Editura Politehnica, **2007**.
- [II.8]. D.D. Micu, L. Czumbil, G.C. Christoforidis, A. Ceclan, *Layer Recurrent Neural Network Solution for an Electromagnetic Interference Problem*, IEEE Transaction on Magnetics, ISSN: 0018-9464, Vol. 47, No. 5, pp. 1410-1413, **2011**.
- [II.9]. K.J. Satsios, D.P. Labridis, P.S. Dokopoulos: *An Artificial Intelligence System for a Complex Electromagnetic Fiels Problem: Part I – Finite Element Calculations and Fuzzy Logic Development*. IEEE Trans. Magn., ISSN: 0018-9464, Vol. 35, No. 1, pp. 516-522, **1999**.
- [II.10]. K.J. Satsios, D.P. Labridis, P.S. Dokopoulos: *An Artificial Intelligence System for a Complex Electromagnetic Fiels Problem: Part II – Method Implementation and Performance Analysis*. IEEE Trans. Magn., ISSN: 0018-9464, Vol. 35, No. 1, pp. 523-527, **1999**.
- [II.11]. D.E. Goldberg, *Genetic Algorithms in Search Optimization & Machine Learning*, ISBN: 978-0201157673, Addison Longman Inc., **1989**.

- [II.12]. **D.D. Micu, L. Czumbil**, A. Ceclan, L. Dărăbant, “Accurate methods for solving Electromagnetic Interference problems between Power Lines and underground Metallic Pipelines”, 44th International Universities’ Power Engineering Conference, UPEC, ISBN: 978-095655702-2, Glasgow, Scotland, September 1-4, **2009**.
- [II.13]. **D. D. Micu**, A. Ceclan, Laura Darabant, **Denisa Stet**, *Analytical and Numerical Development of the Electromagnetic Interference Between a High-Voltage Power Line and an Underground structures*, 6th International Symposium on Advanced Electromechanical Motion Systems, **2009**, Lille, France, ISBN: 978-2-915913-25-5, EAN: 9782915913255.
- [II.14]. A. Al-Badi, K. Ellithy, S. Al-Alawi: Prediction of Voltages on Mitigated Pipelines Paralleling Electric Transmission Lines Using an Artificial Neural Network. The Journal of Corrosion Science and Engineering, Vol. 10, ISSN: 1466-8858, **2007**.
- [II.15]. L. Ancas, **D. D. Micu**, V. Topa: *Right of Way - Buried Metallic Pipelines HV-Power Lines. Mitigation Techniques*, 46th International Universities Power Engineering Conference, UPEC 2011, Soest, Germany, 5 Sept – 8 Sept 2011, Proceedings on CD, ISBN 978-0-9565571-1-8, **2011**.