



(12)

## CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2017 00572

(22) Data de depozit: 16/08/2017

(41) Data publicării cererii:

30/03/2018

BOPI nr. 3/2018

(71) Solicitant:

• **ACADEMIA DE STUDII ECONOMICE DIN BUCUREȘTI, PIATA ROMANĂ, NR.6, SECTOR 1, BUCUREȘTI, B, RO;**  
• **UNIVERSITATEA ROMÂNNO-AMERICANĂ DIN BUCUREȘTI, BD.EXPOZIȚIEI NR.1B, SECTOR 1, BUCUREȘTI, B, RO;**  
• **STIMA SOFT S.R.L., STR.GRIGORE ȚĂRANU, NR.11, ET.2, AP.3, SECTOR 5, BUCUREȘTI, B, RO**

(72) Inventatori:

• **BĂRA ADELA, STR. PLUTONIER NEDELICU ION, NR.1, BL.1, AP.20, SECTOR 3, BUCUREȘTI, B, RO;**  
• **CĂRUȚĂȘU GEORGE, STR. SÔLD.VASILE CROITORU NR.5, BL.3, SC.1, ET.6, AP.39, SECTOR 5, BUCUREȘTI, B, RO;**

• **PÎRJAN ALEXANDRU,**

**STR. AURA BUZESCU, NR.83, SECTOR 2, BUCUREȘTI, B, RO;**

• **OPREA ȘIMONA VASILICA,**

**STR. RĂȘĂRITULUI, NR.1, BL.118, AP.114, SECTOR 6, BUCUREȘTI, B, RO;**

• **LUNGU ION, INTR. CIREȘOAIĂ, NR.5, SECTOR 1, BUCUREȘTI, B, RO;**

• **BOTEZĂTU CORNELIA PAULINA, ȘOS.ALEXANDRIA NR.94, BL. PC 11, SC.A, ET.1, AP.2, SECTOR 5, BUCUREȘTI, B, RO;**

• **ȘIMONCA IULIANA,**

**STR. COL. ȘTEFAN STOICA NR.20, BL.17 A, SC.A, AP.9, SECTOR 1, BUCUREȘTI, B, RO;**

• **BELCIU ANDA, ȘOS. COLENTINA, NR.16, BL.A5, AP.16, SECTOR 2, BUCUREȘTI, B, RO;**

• **FLOREA ALEXANDRA MARIA- IOĂNA, ALEEA ROTUNDĂ NR.4, BL.H6, SC.A, ET.1, AP.6, SECTOR 3, BUCUREȘTI, B, RO;**

• **TĂRANU IONUȚ CORNEL, STR.SERG.ION NUȚU, NR.57, SECTOR 5, BUCUREȘTI, B, RO**

(54)

## METODĂ ȘI SISTEM INFORMATIC INTELIGENT PENTRU PREDICȚIA, ANALIZA ȘI MONITORIZAREA PRODUCȚIEI ȘI CONSUMULUI ENERGIEI ELECTRICE PROVENITE DE LA FERMELE EOLIENE

(57) Rezumat:

Invenția se referă la o metodă și la un sistem informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centrale electrice eoliene. Metoda conform invenției constă într-o primă etapă în care sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și de prognozare cu ajutorul acestei rețele, și într-o a doua etapă în care sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție a energiei și de prognozare cu ajutorul acestei rețele. Sistemul informatic inteligent, conform invenției, cuprinde: o rețea (RNAmeteo) neurală artificială de predicție meteo, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate), o rețea (RNAenerg) neurală artificială de predicție a producției de energie eoliană și a energiei consumate, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină a centralei electrice eoliene, 12 neuroni pentru stratul ascuns și câte 2 neuroni pentru stratul de ieșire și pentru datele de ieșire (energia produsă și cea consumată), algoritmi Levenberg-Marquardt (LM), de Regularizare Bayesiană (BR) și

Gradientului Scalat Conjugat (SCG), instrumentul MATLAB Compiler SDK, o bibliotecă (Bibl-C) partajată de funcții în limbajul C, o bibliotecă (Bibl-C++) partajată de funcții în limbajul C++, un cadru de dezvoltare Microsoft.NET, un pachet Java(PJFPred) care oferă acces la funcțiile de predicție, și o componentă reutilizabilă, de tip Component Object Model.

Revendicări: 9

Figuri: 7

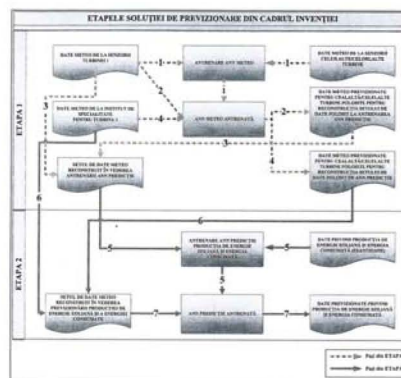


Fig. 1

Cu începere de la data publicării cererii de brevet, cererea asigură, în mod provizoriu, solicitantului, protecția conferită potrivit dispozițiilor art.32 din Legea nr.64/1991, cu excepția cazurilor în care cererea de brevet de invenție a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de invenție este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).



## **METODĂ ȘI SISTEM INFORMATIC INTELIGENT PENTRU PREDICȚIA, ANALIZA ȘI MONITORIZAREA PRODUCȚIEI ȘI CONSUMULUI ENERGIEI ELECTRICE PROVENITE DE LA CENTRALELE ELECTRICE EOLIENE**

Invenția se referă la o metodă și sistem informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centralele electrice eoliene, în principal la cele de mici dimensiuni, amplasate în zone deluroase. Invenția se poate aplica și pentru a analiza potențialul energetic al unei anumite zone, fiind utilă potențialilor investitori ce doresc să construiască acest tip de centrale electrice eoliene și au nevoie de o metodă performantă de predicție, cu grad ridicat de acuratețe. Invenția se poate aplica în dezvoltarea unei game largi de aplicații personalizate pentru predicția indicatorilor de performanță în domeniul energiei regenerabile.

Serviciul de căutare de brevete Espacenet, furnizat de Oficiul de Stat pentru Invenții și Mărci (OSIM) împreună cu Organizația Europeană de Brevete (European Patent Organization EPO), evidențiază faptul că în stadiul cunoscut al tehnicii sunt cunoscute câteva brevete românești ce abordează aspecte legate de domeniul energiei. Astfel, patentul RO130938 (A0) din 26 februarie 2016 se referă la o metodă și un sistem inteligent dezvoltate în vederea monitorizării și măsurării on-line, în timp real, a parametrilor aferenți energiei electrice (pentru energia produsă, transportată, distribuită, furnizată, consumată), al căror scop este de a oferi utilizatorilor posibilitatea de a lua decizii eficiente și rapide. Metoda conform invenției se bazează pe achiziționarea, stocarea și monitorizarea formelor undelor de curent și tensiune, de pe o fază sau toate cele trei faze ale unei rețele electrice. Sistemul conform invenției este alcătuit dintr-o serie de echipamente specializate (amplificatoare și module). Alte patente se referă la dezvoltarea unor sisteme inteligente în domeniul energiei, spre exemplu patentul RO131296 (A2) din 29 iulie 2016 se referă la controlul inteligent, prin utilizarea unui sistem electronic, al încărcării unor acumulatori ce sunt utilizați în vederea transferului de energie în cadrul unui circuit ce asigură conversia în energie electrică a energiei regenerabile; patentul RO131156 (A0) din 30 mai 2016 se referă la dezvoltarea unui sistem inteligent modular, în scopul eficientizării și optimizării consumului energetic al agenților economici.

În stadiul tehnicii mondiale, evidențiat prin studiul bazei de date internaționale Derwent Innovations Index, sunt cunoscute o serie de patente internaționale ce tratează aspecte legate de centralele eoliene, dintre care se remarcă: patentul EP3009670-A1 din 20 aprilie 2016 ce introduce o metodă de control, comandă și operare a unei instalații de producere a energiei eoliene, prin măsurarea vitezei vântului în fața instalației eoliene, în vederea construirii unui

model tridimensional de predicție; patentul CN105552970-A din 4 mai 2016 ce introduce o metodă de îmbunătățire a acurateții de predicție a energiei generate și reducere a consumului de energie și pierderilor de electricitate la nivelul centralei eoliene, ce implică crearea unui sistem de stocare a energiei, printr-o metodă specifică; patentul JP5886407-B1 din 16 martie 2016 ce introduce un echipament de predicție util în predicția cantității de energie produsă de către un generator ce folosește energie naturală; patentul EP2980403-A1 din 3 februarie 2016 ce introduce un sistem de control al turbinelor din cadrul centralelor electrice eoliene pentru a genera energie conform unor specificații, minimizând încărcarea mecanică a echipamentelor de generare a energiei și reducând costurile de mentenanță; patentul KR2015118699-A din 23 octombrie 2015 ce introduce o metodă de predicție în timp real a energiei generate, stocând informații în timp real cu privire la direcția și viteza vântului; patentul CN105914785-A din 31 august 2016 ce introduce o metodă de creștere a capacității puterii de absorbție a vântului, reducând costurile aferente investiției în stocarea energiei; patentul WO2016121202-A1 din 4 august 2016 ce introduce o metodă de estimare a cantității de energie solară sau eoliană produsă, utilizând o metodă ce extrage o valoare caracteristică reprezentând o fluctuație a unei serii de timp, necesitând date meteorologice pe parcursul ultimelor 2 ore înainte de momentul de predicție; patentul CN105930941-A din 7 septembrie 2016 ce introduce o metodă de predicție indirectă a energiei eoliene, obținând un istoric al profilului vitezei vântului și valoarea vitezei acestuia; patentul WO2017006371-A1 din 12 ianuarie 2017 ce introduce o metodă de management al sistemului ce produce energie din surse regenerabile, menținând producția de energie în anumite limite prestabilite, folosind un algoritm de optimizare și un parametru de toleranță.

O serie de lucrări din literatura de specialitate sunt dedicate predicției vitezei vântului [1], [2], [3] pentru intervale de timp ce diferă în funcție de obiectivul de predicție. Prin analiza acestor lucrări se evidențiază mai multe tipuri de intervale de predicție:

- pe termen scurt (intervale de ordinul orelor), utilizate pentru a asigura funcționarea în siguranță, în cazul unor condiții meteo extreme și, de asemenea, pentru cazul în care apar dezechilibre între energia produsă și necesarul de consum;
- pe termen mediu (intervale de ordinul zilelor), utilizate pentru notificarea producției și întreținere;
- pe termen lung (intervale de ordinul lunilor), utilizat pentru planificarea capacității, studii de oportunitate etc.

Predicția energiei eoliene produse depinde de intervalul de timp considerat. De exemplu, în cazul predicției pe termen scurt, sunt recomandate a fi folosite metodele stocastice (modele autoregresive [4] și modelul Markov generalizat [5]). Alte studii au utilizat filtrul Kalman integrat cu regresie vector suport (SVR) pentru a obține o îmbunătățire a predicției de 10%, comparativ cu modelele autoregresive (AR) [6].

În ceea ce privește predicția pentru ziua următoare, ce reprezintă scopul invenției din cadrul cererii de brevet, o abordare coerentă este obținută prin utilizarea rețelelor neurale artificiale (ANN) pentru prognoza producției de energie eoliană. În cazul ANN, sunt utilizați diverși algoritmi [7], [8]. În cadrul studiului de caz prezentat în lucrarea [9], sunt utilizați algoritmi de Regularizare Bayesiană (BR), Gradientului Scalat Conjugat (SCG) și Levenberg-Marquardt (LM). De asemenea, în literatura de specialitate a fost studiată rețeaua neurală de propagare inversă (Back Propagation), bazată pe metoda de optimizare "Particle Swarm Optimization" [10], [11].

Studiile [12], [13], [14] evidențiază faptul că un procent semnificativ din eroarea de estimare a energiei este cauzat de datele meteorologice de intrare. Modelele operaționale numerice de predicție meteo (NWP), ce au relevanță pentru predicția energiei eoliene în Europa sunt prezentate de proiectul ANEMOS Plus [15]. Mai mult decât atât, pentru prognozele meteorologice, modelul de predicție a vitezei vântului și produsele software specifice (ENFOR, ForecastPro, PredictWind) sunt prezentate în detaliu în [12], [13], [16]. Aceleași studii arată că eroarea medie pătratică (Mean Squared Error - MSE) a acestor modele de prognoză eoliană este în limita a 2,5% (în cazul centralelor electrice eoliene de mari dimensiuni din Germania) și de 15% în cazul SUA pentru prognoza din ziua următoare, în timp ce eroarea rădăcinii medii pătratice (Root Mean Square Error – RMSE) are valoarea de 10% în cazul Irlandei. Precizia de estimare a vitezei vântului depinde de scala de timp și de pătratul de rezoluție.

În România, potrivit site-ului oficial al Administrației Naționale de Meteorologie, aceasta folosește în prognozele sale modele globale (ECMWF și ARPEGE) și modele de predicție numerică a vremii pe scurtă durată (ALADIN, Alaro și COSMO). Conform descrierii tehnice a modelelor pe arie limitată (LAM), rezoluția variază de la 2,8 la 10 km, orizontul de prognoză este de până la 76 de ore, iar frecvența de prelevare a eșantioanelor variază de la 1 până la 3 ore. Modelele de predicție studiate, bazate pe rețele neurale artificiale, trebuie să aibă o frecvență de eșantionare de 1 oră. Tipurile de erori introduse de modelele numerice de predicție meteo (NWP) sunt erori de amplitudine (timpul de producție este estimat în mod corect, dar valoarea vitezei vântului este subestimată sau supraestimată) și eroarea de fază (valoarea vitezei vântului este prognozată corect, dar nu și timpul de producție).

Alte lucrări studiază algoritmi de predicție, prezentând principiile generale de proiectare și studii de caz, acești algoritmi fiind studiați, în principal, pentru centralele electrice eoliene amplasate pe teren plat, pe uscat sau off-shore [15], [13]. Potrivit lucrării [15], în cazul terenului deluros, prognoza producției de energie eoliană are o plajă largă de erori atunci când se utilizează metodele existente. Operatorii de centrale electrice eoliene folosesc diverse instrumente comerciale (PredictWind, WPPT, Wind Speed Predictor, WINDcast etc.), dezvoltate de către furnizorii comerciali independenți sau rezultate din proiecte internaționale de cercetare.

Prin analiza literaturii de specialitate și a bazelor de date internaționale de brevete s-a constatat că o serie de lucrări de specialitate sau brevete în domeniul energiei (precum acelea menționate anterior) abordează subiecte legate de energia eoliană sau predicția cantității de energie produse, pe baza unor date meteorologice. Totuși, nici unul dintre brevetele menționate și nici una dintre lucrările analizate nu au abordat dezvoltarea de metode de prognozare a producției și a consumului de energie electrică printr-o metodă de predicție în două etape pentru centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, precum metoda prezentată în invenția din cadrul propunerii noastre de brevet.

Soluțiile tehnice cunoscute prezintă următoarele dezavantaje:

- instrumentele comerciale folosite de către operatorii centralelor electrice eoliene au o plajă largă de erori atunci când prognozează energia produsă precum și pe cea consumată în cadrul centralelor eoliene situate pe teren deluros
- în anumite situații, beneficiarul trebuie să instaleze pachete software ce necesită achitarea unor costuri suplimentare de licențiere
- soluțiile tehnice comerciale actuale necesită costuri ridicate de mentenanță
- soluțiile tehnice comerciale de predicție existente la ora actuală vizează cu precădere obținerea unei prognoze utile producătorilor de energie eoliană, nefiind adresate și potențialilor investitori ce doresc să evalueze potențialul unei anumite zone de a permite dezvoltarea de centrale electrice eoliene
- o mare parte din soluțiile tehnice existente la ora actuală au în vedere măsurarea și monitorizarea parametrilor energiei electrice, dar nu și prognozarea producției și consumului energiei electrice provenite de la centralele electrice eoliene
- soluțiile tehnice comerciale existente la ora actuală ce se adresează potențialilor investitori necesită montarea unor echipamente specializate, la costuri ridicate, nereușind să realizeze o estimare eficientă utilizând doar date meteo istorice

- soluțiile tehnice cunoscute nu pot fi folosite și integrate în dezvoltarea altor aplicații personalizate, pentru predicția indicatorilor de performanță în domeniul energiei regenerabile.

Metoda de predicție, conform prezentei invenții, a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate în zone deluroase rezolvă problema:

- îmbunătățirii acurateței de predicție a energiei produse și a celei consumate în cadrul centralelor electrice eoliene de mici dimensiuni, situate pe teren deluros
- operatorilor centralelor electrice eoliene în ceea ce privește îmbunătățirea acurateței predicției de energie pe oră, întrucât conform legii, operatorii sunt obligați să prezinte Dispecerului Energetic Național rapoarte pentru ziua următoare, cu privire la producția de energie pe oră, invenția contribuind astfel la asigurarea stabilității Sistemului Energetic Național și a unui management eficient al energiei produse prin utilizarea resurselor regenerabile
- întâmpinată de potențialii investitori ce doresc să construiască centrale electrice eoliene de mici dimensiuni pe teren deluros și au nevoie de o metodă performantă de predicție, cu grad ridicat de acuratețe, pentru a analiza potențialul energetic al zonei, fără să fie necesare investiții mari pentru instalarea de echipamente specializate de măsură, fiind suficientă doar achiziționarea datelor meteorologice de intrare
- dezvoltării unor sisteme suport pentru decizii, având în vedere necesitatea și utilitatea, pe plan național, a susținerii managementului resurselor regenerabile printr-un sistem informatic de asistare a deciziilor care să permită monitorizarea și analiza eficientă a resurselor energetice produse de aceste surse
- utilizării și integrării produselor reutilizabile realizate în dezvoltarea unei game largi de aplicații personalizate pentru predicția indicatorilor de performanță în domeniul energiei regenerabile, produsele astfel dezvoltate reprezentând nucleul în dezvoltarea unui sistem suport pentru decizii în vederea predicției indicatorilor de performanță în domeniul energiei regenerabile
- utilizării produselor reutilizabile realizate în cadrul unor aplicații ce pot fi apoi utilizate de către beneficiari fără a implica taxe de licențiere suplimentare și fără a necesita instalarea unor pachete de programe suplimentare.

Invenția vine în întâmpinarea nevoilor operatorilor centralelor eoliene, a potențialilor dezvoltatori precum și a altor categorii de utilizatori a căror activitate necesită utilizarea unor metode de prognoză a energiei eoliene produse și consumate în cadrul procesului de producție. Aceste metode trebuie să fie eficiente, performante, rapide, fiabile și avantajoase din punct de vedere economic.

În acest context, invenția oferă o soluție de realizare a acestei prognoze pornind de la date meteorologice de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului) și furnizează în final o metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene, cu un nivel ridicat de acuratețe.

Metoda dezvoltată se bazează pe dezvoltarea și implementarea unor rețele neurale artificiale, desfășurându-se în două etape, conform schemei bloc a metodei de predicție. Astfel, pe parcursul Etapei 1 sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și pași de predicție cu ajutorul acestei rețele, iar pe parcursul Etapei a 2-a, sunt efectuați pași de antrenare a rețelei neurale artificiale de predicție a energiei și pași de predicție cu ajutorul acestei rețele.

Metoda de predicție, conform prezentei invenții, a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate în zone deluroase prezintă următoarele avantaje:

- oferă un nivel ridicat de acuratețe a predicției energiei produse și a celei consumate în cadrul centralelor electrice eoliene de mici dimensiuni, situate pe teren deluros
- reprezintă un instrument util operatorilor centralelor electrice eoliene în ceea ce privește îmbunătățirea acurateței predicției de energie pe oră, pentru ziua următoare, pe care aceștia trebuie, conform legii, să o raporteze Dispecerului Energetic Național, invenția contribuind astfel la asigurarea stabilității Sistemului Energetic Național și a unui management eficient al energiei produse prin utilizarea resurselor regenerabile
- facilitează activitatea potențialilor investitori ce doresc să construiască centrale electrice eoliene de mici dimensiuni pe teren deluros și au nevoie de o metodă performantă de predicție, cu grad ridicat de acuratețe, pentru a analiza potențialul energetic al zonei, fără să fie necesare investiții mari pentru instalarea de echipamente specializate de măsură, fiind suficientă doar achiziționarea datelor meteorologice de intrare

- este utilă în dezvoltarea unor sisteme suport pentru decizii, având în vedere necesitatea și utilitatea, pe plan național, a susținerii managementului resurselor regenerabile printr-un sistem informatic de asistare a deciziilor care să permită monitorizarea și analiza eficientă a resurselor energetice produse de aceste surse
- reprezintă o metodă de predicție personalizată a producției de energie electrică ce ia în considerare influența reliefului deluros precum și deflexiunea vântului (cauzată de terenul deluros, distanța dintre turbine fiind în conformitate cu rezoluția modelelor numerice de predicție meteorologică)
- oferă posibilitatea utilizării și integrării produselor reutilizabile realizate în dezvoltarea unei game largi de aplicații personalizate pentru predicția indicatorilor de performanță în domeniul energiei regenerabile, produsele astfel dezvoltate reprezentând nucleul în dezvoltarea unui sistem suport pentru decizii în vederea predicției indicatorilor de performanță în domeniul energiei regenerabile
- oferă posibilitatea utilizării produselor reutilizabile realizate în cadrul unor aplicații ce pot fi apoi utilizate de către beneficiari, fără a implica taxe de licențiere suplimentare și fără a necesita instalarea unor pachete de programe suplimentare
- fiind un instrument adresat producătorilor de energie electrică provenită din surse eoliene, invenția facilitează utilizarea acestei resurse, contribuind astfel la efectele pozitive ce decurg din utilizarea energiei regenerabile: reducerea poluării, a cantității de deșeuri, reducerea costurilor aferente energiei produse, a costurilor de întreținere și mentenanță a centralelor, economisirea resurselor naturale ale solului.

Se dă în continuare un exemplu de realizare a metodei și sistemului informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centralele electrice eoliene, conform prezentei invenții, îndeosebi centralele electrice eoliene de mici dimensiuni amplasate în zone deluroase, în legătură și cu figurile 1,...,7, care reprezintă:

- fig. 1. - schema bloc a metodei și sistemului informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice, provenite de la centralele electrice eoliene, conform prezentei invenții



- fig. 2. - arhitectura rețelelor neurale de predicție a datelor meteorologice aferente celei de-a doua turbine pentru care s-a înregistrat cel mai înalt nivel de acuratețe a predicției
- fig. 3. - arhitectura rețelelor neurale dezvoltate pentru predicția energiei eoliene produse și consumate în cadrul grupului de producție de 5 MW
- fig. 4. - performanța de antrenare pentru rețeaua neurală de predicție a energiei eoliene produse și consumate în cadrul grupului de producție de 5 MW
- fig. 5. - histograma erorilor pentru rețeaua neurală de predicție a energiei eoliene produse și consumate în cadrul grupului de producție de 5 MW
- fig. 6. - regresiiile dintre valorile țintă și valorile de ieșire ale rețelei neurale de predicție a energiei eoliene produse și consumate în cadrul grupului de producție de 5 MW
- fig. 7. - compilarea și exportarea rețelelor neurale de predicție dezvoltate în vederea integrării ulterioare.

Metoda și sistemul informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centralele electrice eoliene, în principal de la cele de mici dimensiuni, amplasate în zone deluroase, are drept scop îmbunătățirea acurateței de prognoză a metodelor existente, prin dezvoltarea unei tehnici de estimare în două etape: pe parcursul primei etape sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și de predicție cu ajutorul acestei rețele, iar pe parcursul celei de-a doua etape sunt efectuați pași de antrenare a rețelei neurale artificiale de predicție a energiei și de prognozare cu ajutorul acestei rețele. Această metodă s-a dovedit a fi, în urma testelor experimentale, cea mai potrivită pentru centralele electrice eoliene situate pe teren deluros, tip de teren ce determină schimbări frecvente ale direcției vântului de la o turbină la alta, atunci când turbinele sunt situate la altitudini diferite.

În scopul îmbunătățirii acurateței de prognoză a metodelor existente, folosite în parcurile eoliene de mici dimensiuni, situate pe teren deluros (unde procesele sunt influențate de perturbații, au o dinamică complexă, sunt variabile în timp și sunt neliniare) invenția folosește rețele neurale artificiale în vederea predicției producției și consumului energiei electrice. Așa cum este cunoscut, rețelele neurale artificiale imită creierul uman, fac parte din inteligența artificială, sunt rețele de elemente simple legate prin "interconexiuni" prin care se transmit informații numerice.

Predicția producției și consumului energiei electrice provenite de la centralele electrice eoliene este greu de realizat prin metode convenționale. O metodă și un sistem inteligent de prelucrare a informațiilor folosind rețelele neurale artificiale are capacitatea de învățare atunci când interacționează cu mediul înconjurător, ceea ce îi asigură performanțe deosebite.

Noua metodă expusă în această descriere constă în două etape, prima etapă conținând 4 pași iar cea de-a doua 3 pași (fig. 1). În Etapa 1, conform prezentei invenții, sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și apoi, de predicție cu ajutorul acestei rețele. Rețeaua neurală de predicție meteo, conform prezentei invenții, este dezvoltată pe baza algoritmului de Regularizare Bayesiană, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate în cadrul pătratului de rezoluție). Condițiile pentru începerea Etapei 1, condițiile inițiale sunt cunoașterea datelor meteorologice statistice, înregistrate de senzorii turbinelor, constând în eșantioanele reprezentative pentru o perioadă de timp corespunzătoare, astfel încât aceasta să acopere minimum un an de zile. În desfășurarea Etapei 1, trebuie respectate următoarele condiții: în vederea obținerii setului de date reconstruit pentru antrenarea rețelei neurale de predicție a energiei se impune cunoașterea datelor meteorologice statistice, înregistrate de senzorii turbinei 1 și datele meteo previzionate pentru cealaltă/celelalte turbine, folosind rețeaua neurală artificială de predicție meteo antrenată; în vederea reconstrucției setului de date, ce va fi folosit în predicția producției și consumului de energie cu ajutorul rețelei neurale artificiale de predicție a energiei, sunt necesare datele meteo de la senzorii turbinei 1 și datele meteo previzionate pentru cealaltă/celelalte turbine, obținute folosind rețeaua neurală artificială de predicție meteo antrenată.

În Pasul 1 al Etapei 1, conform prezentei invenții, este antrenată o rețea neurală artificială de predicție meteo. Rețeaua neurală de predicție meteo, conform prezentei invenții, este dezvoltată pe baza algoritmului de Regularizare Bayesiană, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate în cadrul pătratului de rezoluție). Condițiile pentru începerea Pasului 1, condițiile inițiale, sunt cunoașterea datelor meteo înregistrate de senzorii turbinelor.

În Pasul 2 al Etapei 1, conform prezentei invenții, se obțin datele meteo previzionate pentru cealaltă/celelalte turbine, ce vor fi folosite ulterior pentru reconstrucția setului de date folosit la antrenarea rețelei neurale artificiale de predicție a energiei. Condițiile pentru începerea Pasului 2, condițiile inițiale, sunt cunoașterea datelor meteorologice statistice, înregistrate de senzorii turbinei 1 și a rețelei neurale artificiale de predicție meteo antrenată anterior, în Pasul 1.

În Pasul 3 al Etapei 1, conform prezentei invenții, se obține setul de date meteo reconstruit în vederea antrenării rețelei neurale artificiale de predicție a energiei. Condițiile pentru începerea Pasului 3, condițiile inițiale, sunt cunoașterea datelor meteo înregistrate de senzorii turbinei 1 și a datelor meteo previzionate, obținute la Pasul 2 .

În Pasul 4 al Etapei 1, conform prezentei invenții, se obțin datele meteo previzionate pentru cealaltă/celelalte turbine folosite pentru reconstrucția setului de date, folosit la predicția cu ajutorul rețelei neurale artificiale de predicție a energiei produse și a celei consumate. Condițiile pentru începerea Pasului 4, condițiile inițiale, sunt cunoașterea datelor meteo de la institutul de specialitate pentru Turbina 1 și a rețelei neurale artificiale de predicție meteo antrenată anterior, în Pasul 1.

În Etapa 2, conform prezentei invenții, sunt efectuați pași de antrenare a rețelei neurale artificiale de predicție a energiei și de prognozare cu ajutorul acestei rețele. Rețeaua neurală de predicție a energiei, conform prezentei invenții, este dezvoltată pe baza algoritmului de Regularizare Bayesiană, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină, 12 neuroni pentru stratul ascuns, câte 2 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv energia produsă și cea consumată). Condițiile pentru începerea Etapei 2, condițiile inițiale sunt cunoașterea setului de date meteo reconstruit obținut în urma execuției Pasului 3 al Etapei 1, precum și a datelor cu privire la producția de energie eoliană și la energia consumată. În desfășurarea Etapei 2 trebuie respectate următoarele condiții: în vederea reconstruirii setului de date meteo, ce va fi folosit în predicția producției de energie eoliană și a energiei consumate, sunt necesare datele meteo de la institutul de specialitate pentru Turbina 1 precum și setul de date obținut în urma execuției Pasului 4 al Etapei 1; în vederea predicției producției de energie eoliană și a energiei consumate, este necesar setul de date meteo reconstruit, obținut în urma execuției Pasului 6 al Etapei 2, precum și rețeaua neurală artificială de predicție a energiei antrenată anterior, la Pasul 5 al Etapei 2.

În Pasul 5 al Etapei 2, conform prezentei invenții, este antrenată o rețea neurală artificială de predicție a producției de energie eoliană și a energiei consumate. Rețeaua neurală

de predicție a producției de energie eoliană și a energiei consumate, conform prezentei invenții, este dezvoltată pe baza algoritmului de Regularizare Bayesiană, folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină, 12 neuroni pentru stratul ascuns, câte 2 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv energia produsă și cea consumată). Condițiile pentru începerea Pasului 5, condițiile inițiale, sunt cunoașterea setului de date meteo reconstruit obținut în urma execuției Pasului 3 al Etapei 1, precum și a datelor cu privire la producția de energie eoliană și la energia consumată.

În Pasul 6 al Etapei 2, conform prezentei invenții, se obține setul de date meteo reconstruit în vederea predicției producției de energie eoliană și a energiei consumate. Condițiile pentru începerea Pasului 6, condițiile inițiale, sunt cunoașterea datelor meteo de la institutul de specialitate pentru Turbina 1 precum și a setului de date obținut în Pasul 4.

În Pasul 7 al Etapei 2, conform prezentei invenții, se obțin datele prognozate privind producția de energie eoliană și energia consumată. Condițiile pentru începerea Pasului 7, condițiile inițiale, sunt cunoașterea setului de date meteo reconstruit, obținut în urma execuției Pasului 6 al Etapei 2, precum și a rețelei neurale artificiale de predicție a energiei antrenată anterior, la Pasul 5 al Etapei 2.

În Tabelul 1 sunt prezentate principalele activități desfășurate în cadrul fiecărei etape și al fiecărui pas, elementele utilizate precum și cele obținute, conform metodei de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene din cadrul prezentei invenții.

Tabelul 1. Principalele activități desfășurate în cadrul fiecărei etape și al fiecărui pas

Etapa	Activități desfășurate în cadrul etapei	Pasul	Elemente utilizate	Activitatea desfășurată	Elemente obținute
1	antrenarea unei rețele neurale artificiale de predicție meteo și predicția cu ajutorul acestei rețele	1	datele meteo înregistrate de senzorii turbinelor	se antrenează o rețea neurală artificială de predicție meteo	rețea neurală artificială de predicție meteo, antrenată
		2	datele meteo înregistrate de senzorii turbinei 1 și rețeaua neurală artificială de predicție meteo	se utilizează rețeaua neurală artificială de predicție meteo antrenată la Pasul 1	datele meteo previzionate pentru cealaltă/celelalte turbine, folosite pentru reconstrucția setului de date folosit la antrenarea rețelei

			antrenată la Pasul 1		neurale artificiale de predicție a energiei
		3	datele meteo înregistrate de senzorii turbinei 1, datele meteo previzionate obținute în Pasul 2	se assemblează cele două seturi de date	setul de date meteo reconstruit în vederea antrenării rețelei neurale artificiale de predicție a energiei
		4	datele meteo de la institutul de specialitate pentru Turbina 1 și rețeaua neurală artificială de predicție meteo antrenată la Pasul 1	se utilizează rețeaua neurală artificială de predicție meteo antrenată la Pasul 1	datele meteo previzionate pentru cealaltă/celelalte turbine folosite pentru reconstrucția setului de date, folosit la predicția cu ajutorul rețelei neurale artificiale de predicție a energiei produse și a celei consumate
2	antrenarea unei rețele neurale artificiale de predicție a energiei și predicția cu ajutorul acestei rețele	5	setul de date meteo reconstruit și datele cu privire la producția de energie eoliană și la energia consumată	se antrenează rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate	rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate, antrenată
		6	datele meteo de la institutul de specialitate pentru Turbina 1 și a setul de date obținut în Pasul 4	se assemblează cele două seturi de date	setul de date meteo reconstruit în vederea predicției producției de energie eoliană și a energiei consumate
		7	setul de date meteo reconstruit, obținut în urma execuției Pasului 6 al Etapei 2 și rețeaua neurală artificială de predicție a energiei antrenată	se utilizează rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate	datele previzionate privind producția de energie eoliană și energia consumată

			anterior, la Pasul 5		
--	--	--	-------------------------	--	--

În cele ce urmează este prezentată schema bloc a metodei și sistemului informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice, provenite de la centralele electrice eoliene, conform prezentei invenții (fig. 1):

Etapa 1, pe parcursul căreia sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și de previzionare cu ajutorul acestei rețele, după cum urmează:

- Pasul 1. Utilizând datele meteo înregistrate de senzorii turbinei 1, precum și pe acelea înregistrate de senzorii celeilalte (celorlalte) turbine, se antrenează o rețea neurală artificială de predicție meteo.
- Pasul 2. Utilizând datele meteo înregistrate de senzorii turbinei 1 și rețeaua neurală artificială de predicție meteo antrenată anterior, se obțin datele meteo previzionate pentru cealaltă/celelalte turbine, folosite pentru reconstrucția setului de date folosit la antrenarea rețelei neurale artificiale de predicție a energiei.
- Pasul 3. Utilizând datele meteo înregistrate de senzorii turbinei 1, precum și pe acelea obținute în Pasul 2, se obține setul de date meteo reconstruit în vederea antrenării rețelei neurale artificiale de predicție a energiei.
- Pasul 4. Utilizând datele meteo de la institutul de specialitate pentru Turbina 1 și rețeaua neurală artificială de predicție meteo, se obțin datele meteo previzionate pentru cealaltă/celelalte turbine folosite pentru reconstrucția setului de date, folosit de rețeaua neurală artificială de predicție a energiei.

Etapa a 2-a, pe parcursul căreia sunt efectuați pași de antrenare a rețelei neurale artificiale de predicție a energiei și de prognozare cu ajutorul acestei rețele, după cum urmează:

- Pasul 5. Utilizând setul de date meteo reconstruit, precum și datele cu privire la producția de energie eoliană și la energia consumată, se antrenează rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate.
- Pasul 6. Folosind datele meteo de la institutul de specialitate pentru Turbina 1 precum și setul de date obținut în Pasul 4, se obține setul de date meteo reconstruit în vederea previzionării producției de energie eoliană și a energiei consumate.

- Pasul 7. Utilizând setul de date meteo reconstruit, obținut în Pasul 6 și rețeaua neurală artificială de predicție a energiei, se obțin datele previzionate privind producția de energie eoliană și energia consumată.

Sistemul informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centralele electrice eoliene, conform prezentei invenții, în scopul aplicării noii metode descrise mai sus, este alcătuit dintr-o rețea neurală artificială de predicție meteo (RNAmeteo), o rețea neurală artificială de predicție a producției de energie eoliană și a energiei consumate (RNAenerg), algoritmi Levenberg-Marquardt (LM), de Regularizare Bayesiană (BR) și Gradientului Scalat Conjugat (SCG), instrumentul MATLAB Compiler SDK, o bibliotecă partajată de funcții în limbajul C (Bibl-C), o bibliotecă partajată de funcții în limbajul C++ (Bibl-C++), un cadru de dezvoltare Microsoft.NET (CD), un pachet Java ce oferă acces la funcțiile de predicție (PJFpred), o componentă reutilizabilă de tip Component Object Model (CR).

Rețeaua neurală de predicție meteo RNAmeteo, cu referire la figura 2, este dezvoltată pe baza algoritmului de Regularizare Bayesiană (BR), folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate în cadrul pătratului de rezoluție).

Rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate RNAenerg, așa cum se arată în figura 3, este dezvoltată pe baza algoritmului de Regularizare Bayesiană (BR), folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină, 12 neuroni pentru stratul ascuns, câte 2 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv energia produsă și cea consumată).

Algoritmi Levenberg-Marquardt (LM), de Regularizare Bayesiană (BR) și Gradientului Scalat Conjugat (SCG) se folosesc pentru dezvoltarea rețelelor neurale artificiale de predicție atât în cazul rețelei neurale de predicție meteo (RNAmeteo), cât și în cel al rețelei neurale artificiale de predicție a producției de energie eoliană și a energiei consumate (RNAenerg).

Instrumentul MATLAB Compiler SDK este folosit pentru a compila funcțiile apelabile, în care au fost înglobate rețelele neurale de predicție dezvoltate (RNAmeteo și RNAenerg), obținând astfel acces la funcțiile de predicție prin produsele reutilizabile rezultate: o bibliotecă partajată de funcții în limbajul C (Bibl-C), o bibliotecă partajată de funcții în limbajul C++ (Bibl-C++), un cadru de dezvoltare Microsoft.NET (CD), un pachet Java ce oferă acces la

funcțiile de predicție (PJFpred), o componentă reutilizabilă de tip Component Object Model (CR). Produsele reutilizabile astfel obținute sunt utile întrucât pot fi integrate în dezvoltarea unei game largi de aplicații personalizate, ce vizează predicția indicatorilor de performanță în domeniul energiei regenerabile.

Pe baza acestor produse reutilizabile se pot dezvolta o multitudine de aplicații în domeniul energiei eoliene, acestea putând fi utilizate de către beneficiari fără a implica taxe de licențiere suplimentare și fără a necesita instalarea pachetului de programe MATLAB. Bibliotecile software dezvoltate permit execuția funcțiilor compilate, fără a fi necesară instalarea software-ului MATLAB, întrucât acestea includ mediul de execuție MATLAB și un pachet de biblioteci partajate.

Noua metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene poate fi aplicată cu succes în domeniul energetic, de către producătorii de energie din cadrul centralelor electrice eoliene de mici dimensiuni, amplasate pe un teren deluros. Metoda, conform prezentei invenții este utilă atât pentru îmbunătățirea acurateței de predicție pentru centralele electrice eoliene de mici dimensiuni situate pe teren deluros cât și pentru potențialii investitori care doresc să construiască acest tip de centrale eoliene și au nevoie de o soluție performantă de predicție, cu un grad ridicat de acuratețe, pentru a analiza potențialul energetic al unei anumite zone.

Noua metodă expusă în această descriere își justifică importanța și utilitatea ținând cont de faptul că energia obținută din surse regenerabile oferă o multitudine de avantaje, în consecință la ora actuală în România și în multe alte țări europene se impune încurajarea utilizării acestui tip de energie. Utilizarea energiei produse din surse regenerabile creează premisele asigurării securității energetice, economisirii resurselor tradiționale, reducerii importurilor de resurse energetice, dezvoltării economiei la toate nivelurile (local, regional și global), creării de noi oferte pe piața muncii precum și ale reducerii gradului de poluare a mediului înconjurător.

Metoda, conform prezentei invenții, este necesară întrucât în România, Sistemul Energetic Național (SEN) trebuie să aibă capacitatea să echilibreze în orice moment producția de energie electrică cu nivelul consumului. Având în vedere natura impredictibilă a vântului, este dificil de estimat cantitatea de energie eoliană produsă pe parcursul fiecărei ore. Operatorul centralei electrice eoliene trebuie să notifice operatorul SEN în privința producției orare pentru ziua următoare. Operatorul centralei electrice eoliene primește o subvenție din partea guvernului, cunoscută sub denumirea de "certIFICATE VERZI". Valoarea certificatelor verzi și mecanismul de piață sunt reglementate de Uniunea Europeană și de legile naționale [17], [18].



Metodele actuale de predicție în cazul energiei eoliene au o acuratețe a predicției de 70% . Conform Codului Comercial, în cazul în care cantitatea de energie produsă este mai mică decât cea asumată prin notificarea oficială a operatorului centralei de energie eoliană, atunci acesta trebuie să plătească dezechilibrul. Dispecerul Energetic National trebuie să compenseze dezechilibrul prin activarea rezervelor terțiare de compensare rapidă. Cu cât este mai mare eroarea de predicție, cu atât cresc și costurile de compensare. Eforturile actuale sunt concentrate pe îmbunătățirea acurateței de predicție a energiei eoliene.

Majoritatea centralelor electrice eoliene din România au o putere de ieșire mică și sunt situate pe teren deluros [19]. În acest context, devine necesară dezvoltarea unei metode de predicție a producției și consumului de energie electrică eoliană printr-o tehnică de predicție în două etape, pentru centralele electrice eoliene de mici dimensiuni, amplasate pe teren deluros, ca aceea prezentată în cadrul cererii de brevet.

Noua metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene pe care am dezvoltat-o constă într-o soluție de prognoză personalizată a producției de energie electrică ce ia în considerare influența reliefului deluros și deflexiunea vântului (cauzată de terenul deluros, distanța dintre turbine fiind în conformitate cu rezoluția modelelor numerice de predicție meteo NWP), prin poziția turbinelor.

Acuratețea metodei dezvoltate a fost testată în parcurile eoliene din Romania împreună cu operatorii acestora, pentru parcuri ce sunt situate pe teren deluros, obținând și confirmând rezultate cu o acuratețe a prognozei mult îmbunătățită față de soluțiile comerciale existente, pe care operatorii le folosesc la ora actuală.

Metoda de predicție dezvoltată în cadrul invenției este parte dintr-un sistem integrat, implementat ca urmare a proiectului nostru de cercetare științifică "Sistem inteligent pentru predicția, analiza și monitorizarea indicatorilor de performanță a proceselor tehnologice și de afaceri în domeniul energiilor regenerabile" (SIPAMER).

Ca exemplu nelimitativ pentru aplicarea noii metode de predicție din cadrul invenției și a funcționalității acesteia vom prezenta cazurile parcului eolian de mici dimensiuni Baia, situat în România, în județul Tulcea, pe teren deluros, ce cuprinde două grupuri de producție de energie. Noua metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene poate fi implementată și în cazul altor parcuri eoliene de mici dimensiuni, din România sau din străinătate, situate pe terenuri deluroase.

În cele ce urmează prezentăm modul în care au fost dezvoltate, antrenate, validate și testate rețelele neurale de predicție a producției de energie eoliene, pe baza algoritmilor: Levenberg-Marquardt (LM), Regularizare Bayesiană (BR) și a Gradientului Conjugat Scalat

(SCG), folosind instrumentul Neural Network Toolbox din cadrul mediului de dezvoltare MatlabR2015a.

În dezvoltarea acestor soluții de prognoză, am identificat pentru început parametrii de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului) și de ieșire (energia produsă și energia consumată), ale căror date experimentale aferente constau din 17.491 de eșantioane ce au fost obținute prin măsurători directe efectuate pe parcursul a doi ani (1 Ianuarie 2013 – 31 Decembrie 2014), din oră în oră, în cadrul centralei electrice.

În cadrul parcului eolian din care provin datele experimentale există două tipuri de turbine Vestas V90 2MW/3MW IEC IA/IIA, având înălțimea de 90 metri, proiectate pentru parcuri eoliene situate la înălțimi medii și mari, cu turbulențe puternice ale vântului. Compania Vestas produce încă din anul 1979 echipamente pentru parcuri eoliene și are instalate, la ora actuală, peste 51.000 turbine la nivel mondial. Viteza de tăiere a vântului pentru V90 2 MW este de 4 m/s, iar pentru V90 3 MW este de 3,5 m/s. Parcul eolian conține două grupuri de producție, unul de 5 MW ce cuprinde două turbine și unul de 10 MW ce cuprinde 4 turbine.

Pentru grupul de producție de 5 MW, atunci când am dezvoltat metoda de predicție, am luat în considerare câte 3 parametri de intrare pentru fiecare dintre cele două turbine (temperatura, direcția absolută a vântului, viteza medie a vântului). Aceste turbine sunt situate la o distanță de 0,5189 km una față de cealaltă. În dezvoltarea metodei de predicție am folosit 17.491 eșantioane, pentru care datele au fost măsurate prin intermediul unor senzori montați pe turbine.

Pentru datele meteorologice necesare în vederea realizării predicției, parcul eolian primește un singur set de date, prognozat de un institut de specialitate, aferent turbinei 2MW-WEA01. În vederea obținerii unui set complet de date meteorologice necesar dezvoltării invenției, s-a impus pentru început dezvoltarea unei metode de prognoză a datelor meteorologice aferente celei de-a doua turbine, 3MW-WEA02. Aceasta este prima etapă a dezvoltării metodei de predicție din cadrul invenției.

În vederea dezvoltării unei metode pentru reconstituirea setului de date meteorologice de intrare pentru grupul de producție de 5 MW, am dezvoltat 3 rețele neurale de predicție, bazate pe 3 algoritmi: Levenberg-Marquardt (LM), Regularizare Bayesiană (BR) și Gradientului Conjugat Scalat (SCG). Astfel, în dezvoltarea, antrenarea, validarea și testarea celor 3 rețele neurale de predicție am alocat datele meteorologice înregistrate de senzorii primei turbine (temperatura, direcția absolută a vântului, viteza medie a vântului), ca date de intrare, iar pe acelea înregistrate de senzorii celei de-a doua turbine, ca date de ieșire.

În procesul de proiectare și dezvoltare a celor 3 rețele neurale am testat secvențial diverse setări cu privire la arhitectura acestora și apoi am ales varianta care a oferit cel mai ridicat nivel de performanță în privința acurateței de predicție. Astfel, am testat diverse variante de alegere a numărului de neuroni din stratul ascuns (variind între 3 și 50 de neuroni) și am constatat că rezultatele cele mai bune (cel mai înalt nivel de acuratețe a predicției) au fost înregistrate atunci când am proiectat rețelele neurale utilizând pentru datele de intrare 3 neuroni, pentru stratul ascuns 15 neuroni, iar pentru stratul de ieșire și pentru datele de ieșire, câte 3 neuroni (fig. 2).

În proiectarea rețelelor neurale de predicție a datelor meteorologice aferente celei de-a doua turbine am ales modalitatea de divizare a datelor care a furnizat cele mai bune rezultate de predicție, și anume: pentru procesul de antrenare 70% din setul de date, pentru procesul de testare 15% din date, iar restul de 15% din date sunt alocate diferit, de la caz la caz. Astfel, procentul rămas este alocat pentru procesul de validare în cazul rețelelor neurale dezvoltate pe baza algoritmilor Levenberg-Marquardt și Gradientului Conjugat Scalat, iar în cazul rețelei neurale dezvoltate pe baza algoritmului de Regularizare Bayesiană, acest procent rămâne nealocat (etapa de validare nu are loc în acest caz).

Utilizând această abordare, am reușit să alocăm seturi de date de dimensiuni comparabile în cazul celor trei rețele neurale, dezvoltate pe baza celor 3 algoritmi. Astfel, ne-am asigurat că în final, la compararea rezultatelor de predicție furnizate prin cele 3 rețele neurale, se obțin rezultate relevante, concludente. Pe de altă parte, această abordare în divizarea setului de date a furnizat, pentru toate rețelele neurale dezvoltate, rezultatele cele mai bune dintre toate abordările testate. În componența acestor procente, alegerea eșantioanelor a fost aleatoare.

Întrucât am urmărit obținerea unei metode de predicție a datelor meteorologice ce prezintă variații sezoniere legate de diversele anotimpuri ale anului, iar rețelele neurale permit predicția variațiilor sezoniere neregulate prin modificarea setărilor referitoare la numărul de neuroni din straturile ascunse, am testat două variante de dezvoltare a metodei de predicție.

Astfel, într-o primă variantă, am dezvoltat câte o rețea neurală, bazată pe datele anuale, pentru fiecare dintre cei trei algoritmi: algoritmul Levenberg-Marquardt, algoritmul de Regularizare Bayesiană și algoritmul Gradientului Conjugat Scalat. Am obținut astfel 3 rețele neurale anuale pentru predicția datelor meteorologice aferente celei de-a doua turbine, le-am antrenat și testat, validând 2 dintre acestea (după cum am menționat anterior, pentru rețeaua dezvoltată și antrenată pe baza algoritmului de Regularizare Bayesiană, pasul de

validare nu face parte din componența algoritmului). Rezultatele de predicție pe care le-am înregistrat în acest caz s-au dovedit a avea un nivel ridicat de acuratețe a predicției.

În vederea îmbunătățirii acurateței predicției obținute am testat o a doua abordare care a ținut cont de variațiile sezoniere neregulate ale datelor meteorologice și în acest scop am dezvoltat câte o rețea neurală, bazată pe datele aferente fiecărei luni și fiecărui anotimp, pentru fiecare dintre cei trei algoritmi.

Prin dezvoltarea rețelelor neurale de predicție meteo lunare și sezoniere am înregistrat rezultate de predicție mai slabe decât acelea din cazul anterior, când am dezvoltat câte o rețea neurală anuală pentru fiecare dintre cei trei algoritmi. De aceea am decis, în final, să utilizăm ca metodă de predicție a datelor meteorologice aferente celei de-a doua turbine, abordarea ce constă în dezvoltarea câte unei rețele neurale, bazate pe datele anuale, pentru fiecare dintre cei trei algoritmi: LM, BR și SCG.

În etapa următoare am comparat rezultatele furnizate de cele trei rețele neurale anuale: EMeteoLM5MW (dezvoltată pe baza algoritmului LM), EMeteoBR5MW (dezvoltată pe baza algoritmului BR), EMeteoSCG5MW (dezvoltată pe baza algoritmului SCG). Pentru fiecare dintre aceste rețele neurale am calculat și reprezentat graficele de performanță, histogramele erorilor și graficele de regresie dintre obiectivele și ieșirile rețelelor.

Astfel, am constatat că rezultatele de predicție cele mai bune au fost acelea furnizate de rețeaua neurală de predicție meteo dezvoltată pe baza algoritmului BR, EMeteoBR5MW, deoarece această rețea a înregistrat cea mai mică valoare a erorii medii pătratică, valoarea coeficientului de corelație R cea mai apropiată de valoarea 1, cel mai redus interval în care se găsesc majoritatea erorilor. Am remarcat în cazul tuturor celor 3 rețele neurale dezvoltate că acestea evită fenomenul de "suprapotrivire" ("overfitting") (Tabelul 2).

Tabelul 2. Analiza comparativă a rezultatelor furnizate de cele 3 rețelele neurale anuale de prognoză meteo pentru grupul de producție de 5 MW

Parametrii înregistrați	Algoritmul utilizat în dezvoltarea rețelei neurale		
	LM	BR	SCG
Eroarea medie pătratică	0,090774	0,082041	0,083352

Minimul valorii coeficienților de corelație	0,88623	0,89369	0,89210
Intervalul în care se află majoritatea erorilor	[-65,31; 67,97]	[-31,62; 35,16]	[-69,46; 93,48]

În concluzie, ținând cont de nivelul ridicat de acuratețe a predicției oferit de rețeaua neurală anuală dezvoltată pe baza algoritmului BR, EMeteoBR5MW, am decis să utilizăm această rețea de prognoză meteo pentru a obține temperatura, direcția absolută a vântului și viteza medie a vântului aferente turbinei 3MW-WEA02.

Folosind aceste date meteo previzionate pentru cea de-a doua turbină și setul de date inițial pentru prima turbină, am reconstruit setul de date de intrare pentru perioada de doi ani (1 Ianuarie 2013 – 31 Decembrie 2014) și am trecut apoi la etapa a doua a metodei de predicție a producției și consumului de energie electrică eoliană, ce constă în dezvoltarea unor soluții pentru prognozarea cantității de energie electrică produse și a celei consumate în cadrul procesului de producție.

Întrucât energia eoliană prezintă variații sezoniere legate de diversele anotimpuri ale anului iar rețelele neurale permit predicția variațiilor sezoniere neregulate prin modificarea setărilor referitoare la numărul de neuroni din straturile ascunse, am testat două variante de dezvoltare ale metodei de predicție.

Într-o primă variantă, am dezvoltat câte o rețea neurală, pe baza setului de date ce acoperă perioada de 2 ani, pentru fiecare dintre cei trei algoritmi (LM, BR și SCG). Am folosit ca date de intrare setul de date reconstruit, iar ca date de ieșire, producția de energie eoliană și energia consumată. Am obținut astfel 3 rețele neurale anuale pentru predicția indicatorilor de performanță în domeniul energiei eoliene, le-am antrenat și testat, validând 2 dintre acestea (pentru rețeaua dezvoltată și antrenată pe baza algoritmului de Regularizare Bayesiană, pasul de validare nu face parte din componența algoritmului). Rezultatele de predicție pe care le-am înregistrat în acest caz au oferit un nivel ridicat de acuratețe.

Pentru a îmbunătăți acuratețea predicției obținute am testat o a doua abordare ținând cont de variațiile sezoniere neregulate ale energiei eoliene și în acest scop am dezvoltat câte o rețea neurală, bazată pe datele aferente fiecărui anotimp, pentru fiecare dintre cei trei algoritmi. Pentru aceasta, am divizat setul de date reconstruit în 4 seturi de date, aferente celor 4 anotimpuri, specifice zonei temperate din România. Am dezvoltat câte 3 rețele neurale sezoniere pentru predicția indicatorilor de performanță în domeniul energiei eoliene, corespunzătoare fiecăruia dintre cei trei algoritmi, rezultând astfel un număr de 12 rețele neurale

sezoniere de prognoză a energiei. Prin dezvoltarea rețelelor neurale sezoniere am înregistrat rezultate de predicție îmbunătățite comparativ cu acelea din cazul anterior, când am dezvoltat câte o rețea neurală anuală pentru fiecare dintre cei trei algoritmi, pentru tot setul de date reconstruit.

În cele ce urmează vom prezenta rezultatele înregistrate în urma dezvoltării celor 15 rețele neurale și anume 3 rețele anuale și 12 rețele sezoniere de predicție a energiei produse și a energiei consumate, atunci când se cunosc temperatura, direcția absolută a vântului și viteza medie a vântului.

În procesul de proiectare și dezvoltare a tuturor acestor rețele neurale de predicție am testat printr-o abordare iterativă diverse setări cu privire la arhitectura acestora și apoi am ales varianta care a oferit cel mai ridicat nivel de acuratețe a predicției. Astfel, am proiectat rețelele neurale utilizând pentru datele de intrare 6 neuroni, pentru stratul ascuns 12 neuroni iar pentru stratul de ieșire și pentru datele de ieșire, câte 2 neuroni (fig. 3).

În vederea instruirii, validării și testării rețelelor neurale dezvoltate pe baza algoritmului Levenberg-Marquardt și a algoritmului Gradientului Conjugat Scalat am procedat astfel: pentru procesul de instruire am alocat 70% din setul total de eșantioane, pentru procesul de validare am alocat 15%, iar pentru procesul de testare am folosit restul de eșantioane. În cazul rețelelor neurale dezvoltate pe baza algoritmului de Regularizare Bayesiană am alocat 70% din setul total de eșantioane pentru procesul de instruire, 15% pentru cel de testare iar restul eșantioanelor de date nu au fost alocate.

Am procedat astfel pentru a asigura în cazul tuturor celor trei algoritmi dimensiuni egale ale eșantioanelor folosite în cadrul pașilor de instruire și testare, ceea ce facilitează realizarea unei comparații relevante între rezultatele furnizate de rețelele neurale dezvoltate pe baza celor trei algoritmi. Alegerea eșantioanelor ce compun procentele specificate anterior este identică cu aceea utilizată în cazul rețelelor neurale de prognoză meteo, dezvoltate în vederea obținerii setului de date de intrare reconstruit întrucât această abordare s-a dovedit a oferi cele mai bune rezultate.

În cele ce urmează este prezentată analiza performanței metodei de predicție din cadrul invenției, pentru grupul de producție de 5 MW, atunci când am ales un anotimp aleator, Vara, și rețeaua neurală dezvoltată pe baza algoritmului BR, EVaraBR5MW. Pentru a analiza performanța acestei rețele neurale, am generat rapoarte grafice reprezentând analiza performanței, histogramele erorilor și regresiiile dintre obiectivele și ieșirile rețelelor. Am analizat pentru început performanța de antrenare și precizia prognozei, obținute utilizând

rețeaua neurală EVaraBR5MW, dezvoltată, antrenată și testată pe baza algoritmului de Regularizare Bayesiană (fig. 4).

Reprezentând grafic curbele de antrenare și testare ale acestei rețele neurale am constatat că performanța de antrenare maximă înregistrată a fost aceea de la epoca 102, în care eroarea medie pătratică  $MSE$  a avut valoarea 0,059701. Performanța înregistrată este comparabilă cu aceea înregistrată la instruirea și utilizarea rețelei neurale anuale, dezvoltate pe baza algoritmului BR, EGlobalBR5MW, pentru care am obținut cea mai bună performanță la epoca 142, atunci când  $MSE$  a avut valoarea 0,057898.

Graficele funcțiilor de testare și de antrenare sunt foarte asemănătoare, ceea ce confirmă nivelul înalt de acuratețe a predicției. Întrucât nu are loc o creștere semnificativă a curbei de testare înaintea celei de antrenare, am concluzionat că nu se produce fenomenul de "suprapotrivire".

Pentru a analiza distribuția erorilor rețelei EVaraBR5MW, am reprezentat histograma erorilor, în cadrul căreia barele albastre corespund datelor de antrenare iar barele roșii, datelor de testare. Majoritatea datelor de antrenare au erori cuprinse între  $-0,2558$  și  $0,1779$ , dar anumite date de antrenare au erori care se află în afara acestui interval, cu toate că am minimizat numărul valorilor aberante folosind soluțiile menționate anterior. Majoritatea erorilor datelor de antrenare ale rețelei anuale EGlobalBR5MW se încadrează între  $-1,001$  și  $0,8677$ , iar numărul punctelor aberante este mai mare decât acela aferent rețelei neurale EVaraBR5MW. Gama de erori aferentă algoritmului EGlobalBR5MW este mult mai largă decât aceea aferentă algoritmului EVaraBR5MW.

Cele două elemente de ieșire în cazul analizat sunt: energia produsă și energia consumată. Gama de valori a primului element este mult mai largă decât aceea corespunzătoare celui de-al doilea element. Din acest motiv, dacă în dezvoltarea rețelei neurale nu s-ar lua măsuri corespunzătoare, precizia de predicție ar fi mult mai bună în cazul primului element de ieșire decât în cazul celui de-al doilea. Soluția pe care am identificat-o și aplicat-o în vederea depășirii acestui inconvenient a constat într-un proces de normalizare pe care l-am aplicat erorilor, configurând parametrul de normalizare a performanței la valoarea "standard". Astfel, în calculul erorilor, valorile ambelor elemente de ieșire au fost considerate ca fiind cuprinse în intervalul  $[-1,1]$ , ceea ce a avut drept efect obținerea unor nivele de acuratețe a predicției comparabile pentru cele două elemente de ieșire.

Deși rețeaua neurală EVaraBR5MW a fost utilizată pentru a prognoza doi parametri de ieșire, având ordine de mărime diferite (producția de energie eoliană variază între 0 și 5,007 MWh și energia consumată variază între 0 și 0,053 MWh), am înregistrat un nivel ridicat de

acuratețe a predicției, evidențiat prin histograma erorilor. Acest fapt dovedește importanța și utilitatea procesului de normalizare pe care l-am aplicat erorilor acestei rețele (fig. 5).

Pentru a evidenția relațiile dintre valorile de ieșire și cele țintă ale rețelei EVaraBR5MW, dezvoltată, antrenată și testată pe baza algoritmului de Regularizare Bayesiană, am calculat și analizat graficele de regresie aferente etapelor de antrenare, de testare, precum și setului de date în ansamblu. În cadrul acestor grafice, am reprezentat prin linii punctate și respectiv prin linii continue, cazul potrivirii perfecte (când valorile țintă și cele de ieșire coincid) și, respectiv, regresii liniare cele mai bune între cele două seturi de valori. Analizând graficele am constatat că valorile coeficientului de corelație sunt foarte apropiate de valoarea 1 (toate valorile fiind mai mari sau egale cu 0,95695), ceea ce evidențiază o foarte bună potrivire. Prin compararea acestui rezultat cu acela obținut atunci când am dezvoltat o singură rețea anuală pe baza algoritmului BR (când valorile coeficientului de corelație sunt mai mari sau egale cu 0,93306), am constatat că potrivirea este mai bună în cazul rețelei neurale sezoniere EVaraBR5MW (fig. 6).

Rezultatele pe care le-am obținut prin dezvoltarea rețelei neurale sezoniere pe baza algoritmului BR, EVaraBR5MW, sunt superioare rezultatelor înregistrate prin dezvoltarea rețelei neurale globale (EGlobalBR5MW) și oferă un nivel de acuratețe superior al predicției, confirmând eficiența soluției sezoniere comparativ cu aceea anuală.

Pentru a obține o imagine de ansamblu asupra performanțelor rețelelor neurale sezoniere și pentru a obține o comparație a acestor performanțe cu acelea oferite de rețelele neurale anuale, am pus în evidență, pentru fiecare dintre cele 12 rețele lunare și cele 3 rețele anuale, o serie de indicatori semnificativi: eroarea medie pătratică, minimul valorii coeficienților de corelație, intervalul în care se află majoritatea erorilor, iar apoi am comparat acești indicatori cu cei obținuți atunci când am dezvoltat rețelele neurale anuale, pe baza aceluiași algoritmi (Tabelul 3).

Tabelul 3. Analiza comparativă a rezultatelor furnizate de cele 12 rețelele neurale sezoniere și a celor 3 rețele anuale dezvoltate, în cazul grupului de producție de 5 MW

Perioada de predicție	Eroarea medie pătratică			Minimul valorii coeficienților de corelație			Intervalul în care se află majoritatea erorilor		
	LM	BR	SCG	LM	BR	SCG	LM	BR	SCG
2 ani	0,06090	0,05789	0,06640	0,92922	0,93306	0,92739	[-0,96; 0,87]	[-1,00; 0,86]	[-0,75; 0,70]
Primăvară	0,04817	0,03608	0,05079	0,96238	0,95877	0,94980	[-0,32; 0,23]	[-0,38; 0,18]	[-0,20; 0,30]



Vară	0,06692	0,05970	0,05985	0,95232	0,95695	0,93996	[-0,25; 0,17]	[-0,25; 0,17]	[-0,32; 0,28]
Toamnă	0,07313	0,06837	0,11224	0,92163	0,93524	0,93134	[-0,66; 0,57]	[-0,24; 0,26]	[-0,40; 0,26]
Iarnă	0,05927	0,05591	0,06317	0,95109	0,95147	0,94960	[-0,39; 0,51]	[-0,34; 0,49]	[-0,38; 0,54]

Analizând rezultatele, am constatat că acestea sunt comparabile, evidențiind un nivel ridicat de acuratețe a predicției, atunci când sunt prognozate producția de energie eoliană și energia consumată. Prin compararea indicatorilor de performanță a preciziei furnizați de rețelele sezoniere și de cele anuale am constatat că abordarea ce constă în dezvoltarea și antrenarea de rețele neurale ce se bazează pe date de intrare sezoniere este superioară abordării bazate pe antrenarea de rețele neurale anuale. Comparând între ele rezultatele furnizate de rețelele sezoniere, am constatat că acuratețea predicției este excelentă în toate anotimpurile, iar indicatorii de performanță au valori comparabile.

Prin compararea rezultatelor de prognoză obținute prin dezvoltarea de rețele neurale pe baza celor 3 algoritmi, am constatat că, în majoritatea cazurilor, rețelele neurale dezvoltate pe baza algoritmului de regularizare Bayesiană produc o generalizare mai bună decât rețelele dezvoltate pe baza algoritmului Levenberg-Marquardt și algoritmului Gradientului Conjugat Scalat.

Folosind același raționament al metodei de predicție din cadrul invenției de la grupul de producție de 5 MW, pentru a prognoza energia produsă și energia consumată, atunci când se cunosc temperatura, direcția absolută a vântului, viteza medie a vântului, am dezvoltat pentru grupul de producție de 10 MW o metodă de predicție în două etape. În prima etapă a metodei de predicție, am reconstruit setul de date meteorologice necesar în vederea realizării predicției. Parcul eolian primește un singur set de date prognozate de un institut de specialitate, aferent primei turbine. În vederea obținerii unui set complet de date meteorologice necesar dezvoltării soluției de prognoză prin rețele neurale, s-a impus pentru început dezvoltarea unei metode de prognoză a datelor meteorologice aferente celorlalte 3 turbine ale grupului.

Folosind setul de date meteo reconstruit, am trecut apoi la pasul al doilea al metodei de predicție pentru grupul de producție de 10 MW, ce constă în dezvoltarea unor soluții pentru prognozarea cantității de energie electrică produse și a celei consumate în cadrul procesului de producție. În acest scop, am dezvoltat, antrenat, validat și testat câte o rețea neurală pe baza fiecăruia dintre algoritmi analizați, utilizând ca date de intrare și de ieșire un set de date anuale.

Am obținut astfel 3 rețele neurale de predicție, am analizat rezultatele oferite de acestea și am ajuns la concluzia că rețelele neurale anuale oferă rezultate bune de predicție.

Pentru a îmbunătăți acuratețea predicției obținute am dezvoltat a doua metodă de predicție, ce a ținut cont de variațiile sezoniere neregulate ale energiei eoliene. În acest scop am dezvoltat câte o rețea neurală, bazată pe datele aferente fiecărui anotimp, pentru fiecare dintre cei trei algoritmi. Am obținut astfel 12 rețele neurale lunare pentru predicția indicatorilor de performanță în domeniul energiei eoliene.

În Tabelul 4 este prezentată o analiză comparativă a rezultatelor furnizate de cele 12 rețelele neurale sezoniere și a celor 3 rețele anuale dezvoltate, în cazul grupului de producție de 10 MW.

Tabelul 4. Analiza comparativă a rezultatelor furnizate de cele 12 rețelele neurale sezoniere și a celor 3 rețele anuale dezvoltate, în cazul grupului de producție de 10 MW

Perioada de predicție	Eroarea medie pătratică			Minimul valorii coeficienților de corelație			Intervalul în care se află majoritatea erorilor		
	LM	BR	SCG	LM	BR	SCG	LM	BR	SCG
2 ani	0,047731	0,04471	0,062753	0,83555	0,8401	0,78573	[-2,64; 3,04]	[-2,15; 2,35]	[-2,75; 2,79]
Primăvară	0,05445	0,039024	0,057401	0,94301	0,94797	0,94535	[-0,62; 0,97]	[-0,58; 0,49]	[-0,58; 0,50]
Vară	0,049832	0,039407	0,052288	0,95403	0,95035	0,94899	[-0,37; 0,55]	[-0,51; 0,32]	[-0,44; 0,61]
Toamnă	0,049133	0,037771	0,085324	0,85733	0,8831	0,8075	[-1,26; 1,56]	[-1,22; 0,83]	[-2,06; 2,05]
Iarnă	0,076718	0,062523	0,095643	0,73172	0,76579	0,72791	[-2,77; 2,69]	[-1,71; 2,18]	[-2,77; 2,95]

Analizând rezultatele, am constatat că acestea sunt comparabile, evidențiind un nivel ridicat de acuratețe a predicției, atunci când sunt prognozate producția de energie eoliană și energia consumată. Prin compararea indicatorilor de performanță a preciziei furnizați de rețelele sezoniere și de cele anuale am constatat că abordarea ce constă în dezvoltarea și antrenarea de rețele neurale ce se bazează pe date de intrare sezoniere este superioară abordării bazate pe antrenarea de rețele neurale anuale (cu excepția anotimpului iarnă). Analizând rezultatele

furnizate de rețelele sezoniere, am constatat că acuratețea predicției este foarte bună în toate anotimpurile (cu excepția anotimpului iarnă), iar indicatorii de performanță au valori comparabile.

Prin compararea rezultatelor de prognoză obținute prin dezvoltarea de rețele neurale pe baza celor 3 algoritmi, am constatat că, în majoritatea cazurilor, rețelele neurale dezvoltate pe baza algoritmului de regularizare Bayesiană produc o generalizare mai bună decât rețelele dezvoltate pe baza algoritmului Levenberg-Marquardt și algoritmului Gradientului Conjugat Scalat.

Pentru ambele grupuri de producție, în cazul în care, în vederea îmbunătățirii acurateții de predicție, se adaugă ulterior elemente noi în setul de date de intrare, algoritmul LM oferă avantajul unei viteze crescute de antrenare a rețelei comparativ cu algoritmul BR, însă are dezavantajul unui consum crescut de memorie. Dacă vor fi adăugate elemente de intrare noi și se va dori obținerea unei viteze mari de antrenare, în cazul în care vor fi întâmpinate dificultăți cu privire la memoria disponibilă a sistemului, atunci soluția optimă va consta în dezvoltarea unei rețele ce se bazează pe algoritmul SCG, întrucât acesta este mai rapid decât ceilalți doi algoritmi (LM și BR), necesitând un consum redus de memorie, având însă dezavantajul că oferă un nivel mai scăzut de precizie a predicției.

În vederea integrării rețelelor neurale de predicție dezvoltate în cadrul unui sistem suport pentru decizii în vederea predicției indicatorilor de performanță în domeniul energiei regenerabile, am dezvoltat, pe baza rețelelor neurale antrenate, funcții apelabile ce înglobează rețelele neurale dezvoltate, incluzând toți parametrii de antrenare și predicție într-un singur fișier.

Am obținut astfel funcții MATLAB de sine stătătoare, pe care le-am folosit apoi în cadrul instrumentului MATLAB Compiler SDK. În cazul energiei eoliene, pentru grupul de producție de 5 MW, am obținut pentru început 3 funcții apelabile ce înglobează rețelele neurale de predicție meteorologică, dezvoltate folosind ca date de antrenare datele anuale, pe baza celor trei algoritmi (Tabelul 5).

Tabelul 5. Funcțiile apelabile ce înglobează rețelele neurale de predicție meteorologică dezvoltate pentru grupul de producție de 5 MW

Nr. crt.	Denumirea funcției	Perioada aferentă datelor de antrenare folosite în dezvoltarea rețelei neurale	Algoritmul utilizat
1.	EMeteoLM5MW	Anuală	LM

2.	EMeteoBR5MW		BR
3.	EMeteoSCG5MW		SCG

Pentru predicția indicatorilor de performanță în domeniul energiei eoliene, în cazul grupului de producție de 5 MW, am generat 3 funcții apelabile ce înglobează rețelele neurale dezvoltate, folosind ca date de antrenare datele anuale și 12 funcții apelabile ce înglobează rețelele neurale dezvoltate, folosind ca date de antrenare datele sezoniere, pe baza celor trei algoritmi (Tabelul 6).

Tabelul 6. Funcțiile apelabile ce înglobează rețelele neurale dezvoltate pentru predicția indicatorilor de performanță în domeniul energiei eoliene pentru grupul de producție de 5 MW

Nr. crt.	Denumirea funcției	Perioada aferentă datelor de antrenare folosite în dezvoltarea rețelei neurale	Algoritmul utilizat
1.	EGlobalLM5MW	Anuală	LM
2.	EGlobalBR5MW		BR
3.	EGlobalSCG5MW		SCG
4.	EPrimavaraLM5MW	Primăvară	LM
5.	EPrimavaraBR5MW		BR
6.	EPrimavaraSCG5MW		SCG
7.	EVaraLM5MW	Vară	LM
8.	EVaraBR5MW		BR
9.	EVaraSCG5MW		SCG
10.	EToamnaLM5MW	Toamnă	LM
11.	EToamnaBR5MW		BR
12.	EToamnaSCG5MW		SCG
13.	EIarnaLM5MW	Iarnă	LM
14.	EIarnaBR5MW		BR
15.	EIarnaSCG5MW		SCG

Asemănător, pentru grupul de producție de 10 MW am obținut pentru început 3 funcții apelabile ce înglobează rețelele neurale de predicție meteorologică dezvoltate folosind ca date de antrenare datele anuale, pe baza celor trei algoritmi (Tabelul 7).

Tabelul 7. Funcțiile apelabile ce înglobează rețelele neurale de predicție meteorologică dezvoltate pentru grupul de producție de 10 MW

Nr. crt.	Denumirea funcției	Perioada aferentă datelor de antrenare folosite în dezvoltarea rețelei neurale	Algoritmul utilizat
1.	EMeteoLM10MW	Anuală	LM
2.	EMeteoBR10MW		BR
3.	EMeteoSCG10MW		SCG

Apoi, pentru predicția indicatorilor de performanță în domeniul energiei eoliene, în cazul grupului de producție de 10 MW, am generat 3 funcții apelabile ce înglobează rețelele neurale dezvoltate, folosind ca date de antrenare datele anuale și 12 funcții apelabile ce înglobează rețelele neurale dezvoltate folosind ca date de antrenare datele sezoniere, pe baza celor trei algoritmi (Tabelul 8).

Tabelul 8. Funcțiile apelabile ce înglobează rețelele neurale dezvoltate pentru predicția indicatorilor de performanță în domeniul energiei eoliene pentru grupul de producție de 10 MW

Nr. crt.	Denumirea funcției	Perioada aferentă datelor de antrenare folosite în dezvoltarea rețelei neurale	Algoritmul utilizat
1.	EGlobalLM10MW	Anuală	LM
2.	EGlobalBR10MW		BR
3.	EGlobalSCG10MW		SCG
4.	EPrimavaraLM10MW	Primăvară	LM
5.	EPrimavaraBR10MW		BR
6.	EPrimavaraSCG10MW		SCG
7.	EVaraLM10MW	Vară	LM
8.	EVaraBR10MW		BR
9.	EVaraSCG10MW		SCG
10.	EToamnaLM10MW	Toamnă	LM
11.	EToamnaBR10MW		BR
12.	EToamnaSCG10MW		SCG

13.	EIarnaLM10MW	Iarnă	LM
14.	EIarnaBR10MW		BR
15.	EIarnaSCG10MW		SCG

Folosind instrumentul MATLAB Compiler SDK, ce extinde funcționalitatea compilatorului MATLAB, am compilat funcțiile apelabile, ce înglobează rețelele neurale de predicție dezvoltate, obținând astfel acces la funcțiile de predicție (conform Tabelor 5,6,7,8) prin fiecare dintre următoarele produse reutilizabile rezultate (fig. 7):

- o bibliotecă partajată de funcții în limbajul C (Bibl-C)
- o bibliotecă partajată de funcții în limbajul C++ (Bibl-C++)
- un cadru de dezvoltare Microsoft.NET (CD)
- un pachet Java ce oferă acces la funcțiile de predicție (PJFpred)
- o componentă reutilizabilă, de tip COM (Component Object Model) (CR).

Aceste produse reutilizabile pot fi folosite și integrate în dezvoltarea unei game largi de aplicații personalizate pentru predicția indicatorilor de performanță în domeniul energiei regenerabile. Produsele astfel dezvoltate vor constitui nucleul în dezvoltarea unui sistem suport pentru decizii în vederea predicției indicatorilor de performanță în domeniul energiei regenerabile.

Aplicațiile ce vor fi dezvoltate pe baza acestor produse reutilizabile pot fi folosite de către beneficiari fără a implica taxe de licențiere suplimentare și fără a necesita instalarea pachetului de programe MATLAB. Bibliotecile software dezvoltate includ mediul de execuție MATLAB și un pachet de biblioteci partajate, ce permit execuția funcțiilor compilate, fără a fi necesară instalarea software-ului MATLAB.

Invenția este susceptibilă de aplicare industrială deoarece oferă un nivel ridicat de acuratețe a predicției energiei produse și a celei consumate în cadrul centralelor electrice eoliene de mici dimensiuni, situate pe teren deluros, în România sau în străinătate.

Invenția este susceptibilă de aplicare industrială deoarece metoda de predicție a energiei produse și energiei consumate din cadrul invenției, atunci când se cunosc temperatura, direcția absolută a vântului, viteza medie a vântului, pe care am dezvoltat-o anterior folosind rețele neurale artificiale, reprezintă un instrument util pentru operatorii centralelor electrice eoliene, în vederea îmbunătățirii acurateței predicției de energie pe oră. Aceștia sunt obligați conform legii să prezinte Dispecerului Energetic National rapoarte pentru ziua următoare, cu privire la producția de energie pe oră. Aceste rapoarte sunt esențiale în asigurarea stabilității Sistemului

Energetic Național și a unui management eficient al energiei produse prin utilizarea resurselor regenerabile.

Invenția este susceptibilă de aplicare industrială deoarece reprezintă o metodă de predicție personalizată a producției de energie electrică ce ia în considerare influența reliefului deluros precum și deflexiunea vântului (cauzată de terenul deluros, distanța dintre turbine fiind în conformitate cu rezoluția modelelor numerice de predicție meteorologică).

Invenția este susceptibilă de aplicare industrială deoarece facilitează activitatea potențialilor investitori ce doresc să evalueze posibilitatea de a dezvolta centrale electrice eoliene în anumite zone. Întrucât o astfel de investiție este de foarte mare amploare, se justifică pe deplin costurile necesare achiziționării datelor meteorologice de intrare necesare (temperatura, direcția absolută a vântului, viteza medie a vântului), chiar dacă se impune obținerea acestora pentru perioade mai lungi de timp (luni de zile sau chiar ani).

Invenția este susceptibilă de aplicare industrială deoarece este utilă în dezvoltarea unor sisteme suport pentru decizii, având în vedere necesitatea și utilitatea, pe plan național, a susținerii managementului resurselor regenerabile printr-un sistem informatic de asistare a deciziilor care să permită monitorizarea și analiza eficientă a resurselor energetice produse de aceste surse.

Invenția este susceptibilă de aplicare industrială deoarece modulele de predicție astfel dezvoltate, sub formă de biblioteci de funcții prin apelarea cărora se obține o predicție cu un grad ridicat de acuratețe, sunt utile în dezvoltarea de unei game largi de aplicații personalizate și a unor sisteme informatice complexe, în vederea prognozării indicatorilor de performanță în domeniul energiei eoliene, pentru a realiza o gestionare eficientă a resurselor de energie regenerabilă.

Invenția este susceptibilă de aplicare industrială deoarece oferă posibilitatea utilizării produselor reutilizabile realizate în cadrul unor aplicații ce pot fi apoi utilizate de către beneficiari, fără a implica taxe de licențiere suplimentare și fără a necesita instalarea unor pachete de programe suplimentare.

## BIBLIOGRAFIE

- 1 D'amico, G., F. Petroni, F. Pratico, *Wind speed and energy forecasting at different time scales: A nonparametric approach*, Physica A: Statistical Mechanics and its Applications, Volume 406, 2014, pp. 59-66.
- 2 Shi, J., J. Guo, S. Zheng, *Evaluation of hybrid forecasting approaches for wind speed and power generation time series*, Renewable and Sustainable Energy Reviews, Volume 16, Issue 5, 2012, pp 3471-3480.
- 3 Lei, M., L. Shiyan, J. Chuanwen, L. Hongling, Z. Yan, *A review on the forecasting of wind speed and generated power*, Renewable and Sustainable Energy Reviews, Volume 13, Issue 4, 2009, pp. 915-920.
- 4 Maatallah, O.A., A. Achuthan, K. Janoyan, P. Marzocca, *Recursive wind speed forecasting based on Hammerstein Auto-Regressive model*, Applied Energy, Volume 145, 2015, pp. 191-197.
- 5 Costa, A., A. Crespo, J. Navarro, G. Lizcano, H. Madsen, E. Feitosa, *A review on the young history of the wind power short-term prediction*, Renewable and Sustainable Energy Reviews, Volume 12, Issue 6, 2008, pp. 1725-1744.
- 6 Chen, K. J. Yu, *Short-term wind speed prediction using an unscented Kalman filter based state-space support vector regression approach*, Applied Energy, Volume 113, 2014, pp. 690-705.
- 7 Liu, H., H.Q. Tian, Y.F. Li, L. Zhang, *Comparison of four Adaboost algorithm based artificial neural networks in wind speed predictions*, Energy Conversion and Management, Volume 92, 2015, pp. 67-81.
- 8 Chitsaz, H. N. Amjady, H. Zareipour, *Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm*, Energy Conversion and Management, Volume 89, 2015, pp. 588-598.
- 9 Olaofe, Z.O., *A 5-day wind speed & power forecasts using a layer recurrent neural network (LRNN)*, Sustainable Energy Technologies and Assessments, Volume 6, 2014, pp. 1-24
- 10 Ren, C., N. An, J. Wang, L. Li, B. Hu, D. Shang, *Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting*, Knowledge-Based Systems, Volume 56, 2014, pp. 226-239.
- 11 Yeh, W.C., Y.M. Yeh, P.C. Chang, Y.C. Ke, V. Chung, *Forecasting wind power in the Mai Liao Wind Farm based on the multi-layer perceptron artificial neural network model with improved simplified swarm optimization*, International Journal of Electrical Power & Energy Systems, Volume 55, 2014, pp 741-748.
- 12 Foley, A.M., Leahy, P.G Marvuglia, A., Mckeogh, E.J., *Current methods and advances in forecasting of wind power generation*, Renewable Energy, volume 37, no. 1, 2012, pp 1-8.
- 13 Kariniotakis, G., Martí, I., Casas, D., et al, *What performance can be expected by short-term wind power prediction models depending on site characteristics*, Proceedings of the European Wind Energy Conference EWEC 2004.



- 14 Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J., Conzelmann, G.  
*Wind power forecasting: state-of-the-art 2009*, No. ANL/DIS-10-1. Argonne  
National Laboratory (ANL), 2009.
- 15 Giebel, G., R. Brownsword, G. Kariniotakis, M. Denhard, C. Draxl, *The state-of-  
the-art in short-term prediction of wind power: A literature overview, ANEMOS  
plus*, 2010 ([http://www.anemos-plus.eu  
/images/pubs/  
deliverables/aplus.deliverable\\_d1.2.stp\\_sota\\_v1.1.pdf](http://www.anemos-plus.eu/images/pubs/deliverables/aplus.deliverable_d1.2.stp_sota_v1.1.pdf)).
- 16 Wind Power Energy, official website, [www.wpe.ro](http://www.wpe.ro) , accesat la data de 13.11.2015.
- 17 European Commission, *Commission Decision C 4938/2011, Green certificates  
promotion scheme of energy produced from renewable energy sources*, 2011.
- 18 Parlamentul României, *Legea nr. 220/2008 pentru stabilirea sistemului de  
promovare a producerii energiei din surse regenerabile de energie*, republicată cu  
modificările și completările ulterioare.
- 19 Transelectrica - site web oficial,  
[http://www.transelectrica.ro/documents/10179/32316/7productie19.pdf/3fd49432-  
1dd5-46ea-bbd1-02964fe0b6c4](http://www.transelectrica.ro/documents/10179/32316/7productie19.pdf/3fd49432-1dd5-46ea-bbd1-02964fe0b6c4), accesat la data de 21.11.2015.

## REVENDICĂRI

1. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, **caracterizată prin aceea că** într-o primă etapă sunt efectuați pași de antrenare a unei rețele neurale artificiale de predicție meteo și de prognozare cu ajutorul acestei rețele, iar în a doua etapă a metodei de predicție, sunt efectuați pași de antrenare a rețelei neurale artificiale de predicție a energiei și de prognozare cu ajutorul acestei rețele (fig. 1).
2. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, **caracterizată prin aceea că** în vederea reconstruirii setului de date meteorologice în cadrul primei etape, se folosește o rețea neurală artificială, dezvoltată în prealabil pe baza algoritmului de Regularizare Bayesiană (BR), a cărei arhitectură este: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate în cadrul pătratului de rezoluție).
3. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, **caracterizată prin aceea că** în vederea reconstruirii setului de date meteorologice în cadrul primei etape, rețeaua neurală artificială antrenată și testată pe baza algoritmului de Regularizare Bayesiană (BR) folosește datele meteorologice înregistrate de senzorii primei turbine (temperatura, direcția absolută a vântului, viteza medie a vântului), ca date de intrare, iar datele înregistrate de senzorii celei de-a doua turbine, ca date de ieșire; după antrenarea rețelei, în vederea utilizării acesteia, se folosesc datele meteorologice furnizate de institutul de specialitate pentru prima turbină ca date de intrare ale rețelei de prognoză, aceasta oferind ca date de ieșire datele meteorologice corespunzătoare celeilalte turbine (fig. 1).
4. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, **caracterizată prin aceea că** în a doua etapă a metodei de predicție, se folosesc rețelele neurale artificiale dezvoltate în prealabil, pe baza algoritmului de Regularizare Bayesiană (BR), utilizând câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină, 12 neuroni pentru stratul ascuns, câte 2 neuroni

pentru stratul de ieșire și pentru datele de ieșire (respectiv energia produsă și cea consumată).

5. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, conform revendicărilor 1,...4, **caracterizată prin aceea că** este integrabilă în dezvoltarea unei game variate de aplicații și produse întrucât pe baza rețelelor neurale antrenate, au fost dezvoltate funcții apelabile ce înglobează rețelele neurale dezvoltate, incluzând toți parametrii de antrenare și predicție într-un singur fișier .
6. Metodă de predicție a producției și consumului energiei electrice provenite de la centralele electrice eoliene de mici dimensiuni amplasate pe teren deluros, **caracterizată prin aceea că** funcțiile apelabile dezvoltate conform revendicării 5, ce înglobează rețelele neurale de predicție dezvoltate au fost compilate, obținând astfel acces la funcțiile de predicție prin fiecare din următoarele produse reutilizabile rezultate (fig. 7):
  - ✓ o bibliotecă partajată de funcții în limbajul C
  - ✓ o bibliotecă partajată de funcții în limbajul C++
  - ✓ un cadru de dezvoltare Microsoft.NET
  - ✓ un pachet Java ce oferă acces la funcțiile de predicție
  - ✓ o componentă reutilizabilă, de tip COM (Component Object Model).
7. Sistem informatic inteligent pentru predicția, analiza și monitorizarea producției și consumului energiei electrice provenite de la centralele electrice eoliene, conform prezentei invenții, în scopul aplicării noii metode conform revendicărilor 1,...6, **caracterizat prin aceea că** este alcătuit dintr-o rețea neurală artificială de predicție meteo (RNAmeteo), o rețea neurală artificială de predicție a producției de energie eoliană și a energiei consumate (RNAenerg), algoritmi Levenberg-Marquardt (LM), de Regularizare Bayesiană (BR) și Gradientului Scalat Conjugat (SCG), instrumentul MATLAB Compiler SDK, o bibliotecă partajată de funcții în limbajul C (Bibl-C), o bibliotecă partajată de funcții în limbajul C++ (Bibl-C++), un cadru de dezvoltare Microsoft.NET (CD), un pachet Java ce oferă acces la funcțiile de predicție (PJFpred), o componentă reutilizabilă de tip Component Object Model (CR).
8. Sistemul informatic inteligent, conform revendicării 7, **caracterizat prin aceea că** rețeaua neurală de predicție meteo (RNAmeteo) este dezvoltată pe baza algoritmului de Regularizare Bayesiană (BR), folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a

vântului), 15 neuroni pentru stratul ascuns, câte 3 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv temperatura, direcția absolută a vântului, viteza medie a vântului, prognozate în cadrul pătratului de rezoluție).

9. Sistemul informatic inteligent, conform revendicării 7, **caracterizat prin aceea că** rețeaua neurală artificială de predicție a producției de energie eoliană și a energiei consumate (RNAenerg) este dezvoltată pe baza algoritmului de Regularizare Bayesiană (BR), folosind următoarea arhitectură: câte un neuron pentru fiecare dintre datele de intrare (temperatura, direcția absolută a vântului, viteza medie a vântului), pentru fiecare turbină, 12 neuroni pentru stratul ascuns, câte 2 neuroni pentru stratul de ieșire și pentru datele de ieșire (respectiv energia produsă și cea consumată).

DESENE

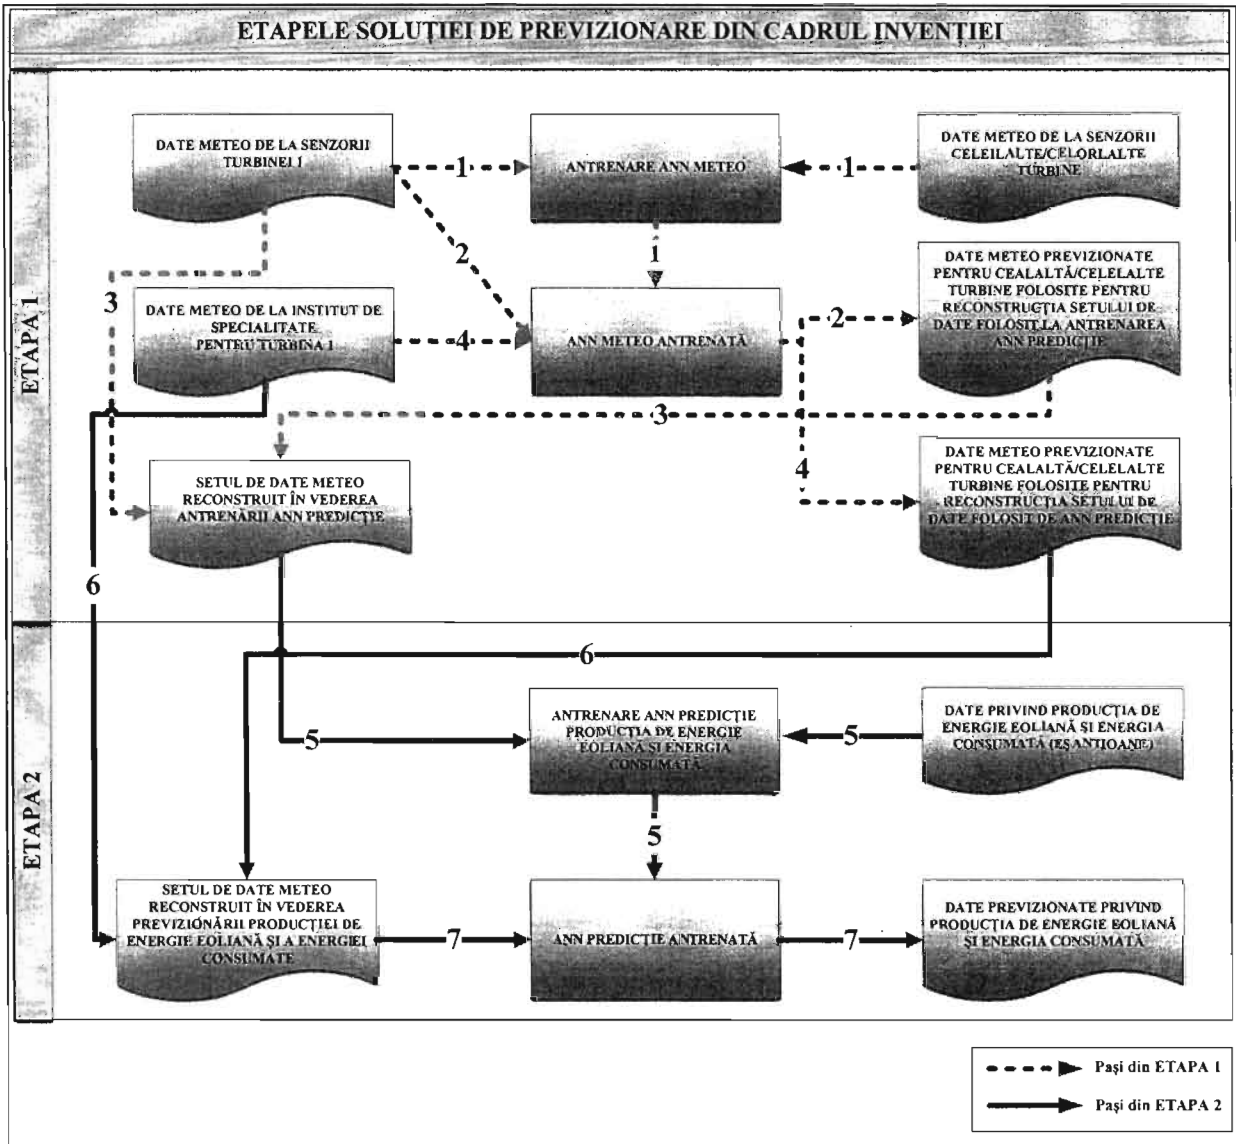


fig. 1.

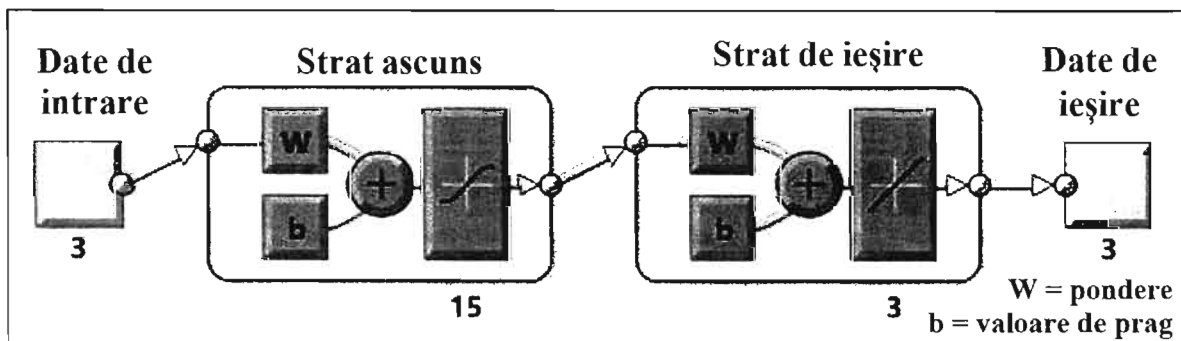


fig. 2.




fig. 3.




fig. 4.




fig. 5.

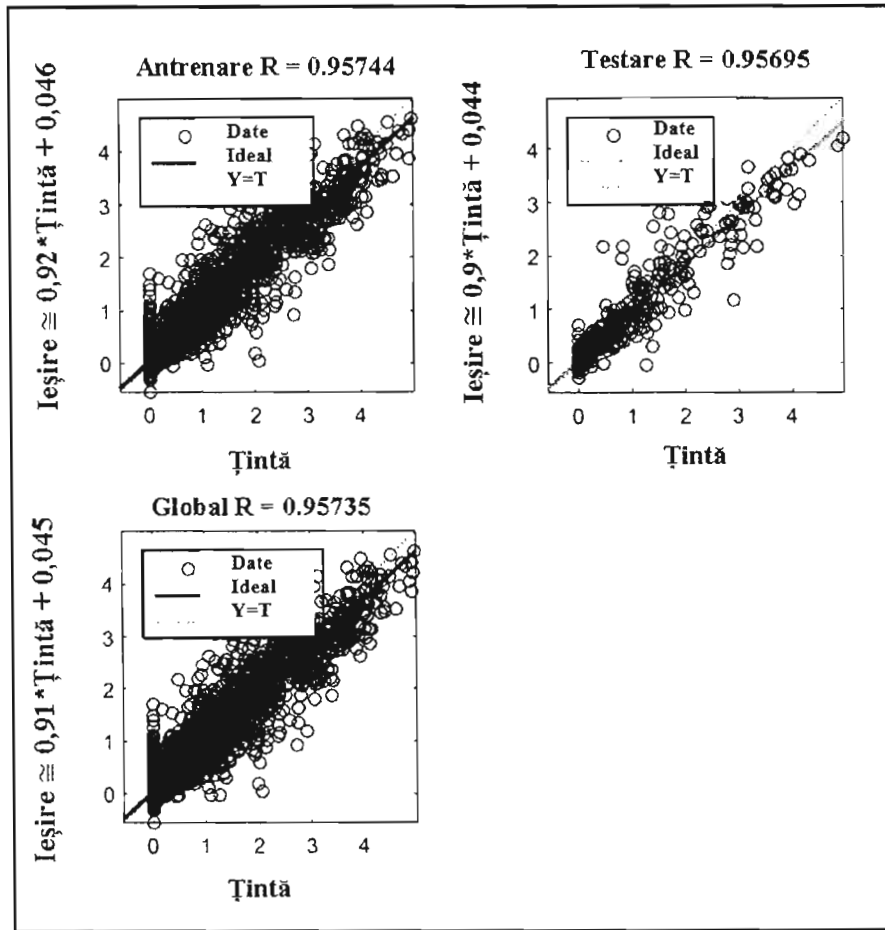


fig. 6.

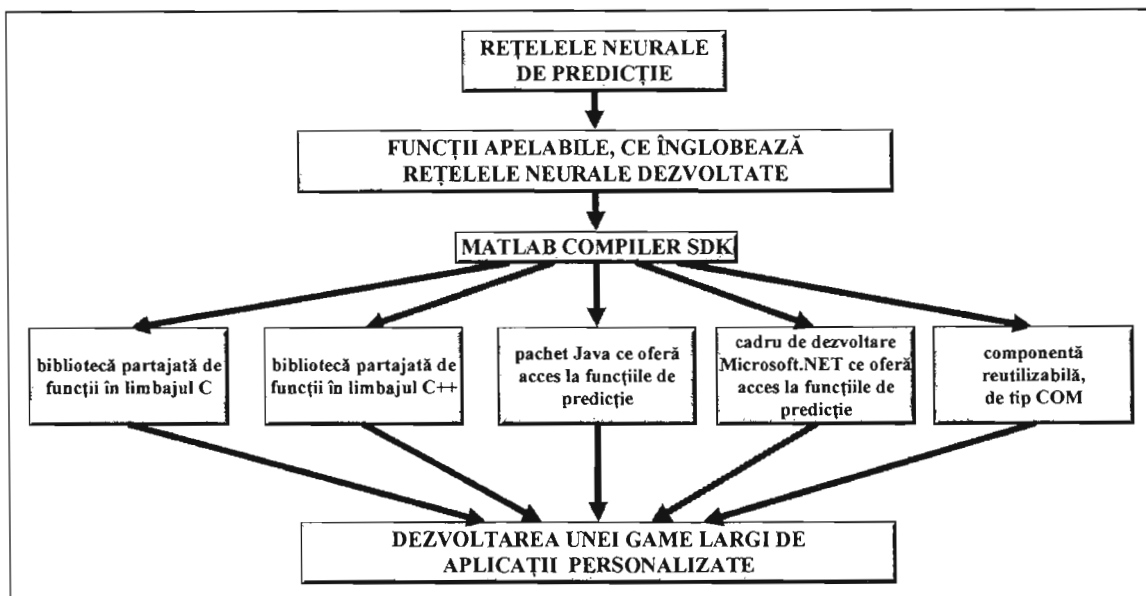


fig. 7.