



(12) CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2020 00172

(22) Data de depozit: 01/04/2020

(41) Data publicării cererii:
29/10/2021 BOPI nr. 10/2021

(71) Solicitant:
• WATT PREDICT S.R.L.,
PIAȚA ALEXANDRU MOCIONI, NR.6,
ÎNCĂPEREA 5, AP.1, TIMIȘOARA, TM, RO

(72) Inventatori:
• NICHITA CRISTIAN-IOSIF, STR.HUNIADE,
NR.5, ET.3, AP.11, LUGOJ, TM, RO

(74) Mandatar:
CABINET DE PROPRIETATE
INDUSTRIALĂ TUDOR ICLĂNZAN, PIAȚA
VICTORIEI NR.5, SC.D, AP.2, TIMIȘOARA,
TM

(54) SISTEM ȘI METODĂ ADAPTIVĂ DE PREDICȚIE A ENERGIEI
ELECTRICE PROGNOZATE A FI GENERATE DE UN
GENERATOR DE ENERGIE ELECTRICĂ REGENERABILĂ

(57) Rezumat:

Invenția se referă la o metodă și un sistem de predicție a energiei electrice prognozate a fi generată de un generator de energie electrică regenerabilă pe baza datelor meteo. Metoda, conform invenției, cuprinde o etapă de decizie a divergenței de predicție, în care sunt comparate energia electrică măsurată într-o etapă de citire cu prognoza estimată într-o etapă de estimare și în care, atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență, este luată decizia de achiziție a unor noi date meteo sau de continuare a predicției folosind datele meteo inițiale revenind peste un interval de timp la etapele de citire și predicție, iar în cazul în care predicția este considerată a fi divergentă în etapa de decizie, metoda continuă cu etapele de stabilire a unui set de puncte de achiziție de interes al datelor meteo și achiziția de noi date meteo din punctele de interes și revenire la etapa de inițializare considerând noile date meteo.

Revendicări: 10
Figuri: 4

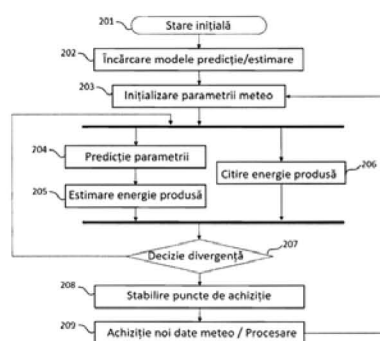


Fig. 2



| | |
|---|------------|
| OFICIUL DE S.T.I. PENTRU INVENȚII ȘI MĂRCII | |
| Cerere de brevet de invenție | |
| Nr. a | 2020 00172 |
| Data depozit | 01-04-2020 |

105

SISTEM SI METODĂ ADAPTIVĂ DE PREDICȚIE A ENERGIEI ELECTRICE PROGNOZATE A FII GENERATE DE UN GENERATOR DE ENERGIE ELECTRICĂ REGENERABILĂ

Sistemul si metoda inventiei se refera la predictia a necesarului de energie electrica regenerabila pe baza achizitiei datelor meteo. În conformitate cu un aspect al producției de energie electrică regenerabilă, producția de energie electrică fotovoltaica, eoliană sau hidroelectrică este afectata în timp de factorii meteo corespunzători amplasamentului geografic al panourilor solare și/sau a turbinelor eoliene și/sau al bazinelor de colectare a apei.

Este cunoscut faptul că, într-o economie de piață, producătorii de energie electrica doresc să optimizeze câștigul obținut din vânzarea energiei produse și astfel întocmesc contracte de furnizare bazate pe prognoze de capacitate de producție care eșalonează în timp energia ce urmează a fii generată și injectată în rețeaua de distribuție. În conformitate cu un aspect al producției de energie electrică regenerabilă, pentru o afacere de succes, este preferabil ca prognoza capacității de producție sa fie direct corelată cu timpul probabil local astfel încât producția reală să fie cât mai apropiată dar nu inferioară de cea contractată pe baza prognozelor. În caz contrar, este bine-cunoscut faptul că în cazul în care un producător de energie regenerabilă nu poate furniza cantitatea de energie contractată, el trebuie sa genereze prin alte mijloace sau să cumpere din alte surse, la prețul pieței, energia necesară acoperirii contractului și deci astfel să piardă bani. Pierderile datorate diferențelor de prognoză sunt de obicei usturătoare.

Din stadiul tehnicii, sunt cunoscute metodele clasice de predicție a puterii solare bazate pe un model de iradianță solară medie a unei locație geografice conform datelor meteo istorice măsurate.

Din EP 1660917B1 este cunoscută o metoda de prezicere pe termen scurt (i.e. următoarele ore și zile) este divulgată și care este adaptată pentru optimizarea câștigului comercial din vânzarea de energie. Este bine-cunoscut din stadiul tehnicii că, prognoza meteo depinde atât de modelul climatic de predicție local cât si de cunoașterea precisă, într-un număr cat mai mare de puncte de măsură, a factorilor meteo actuali și care pot fii mășurați atât prin metode de măsură directe (i.e. senzori de temperatură, radianță solară, umiditate, presiune, vectori de vânt, praf, compoziție gazoasă și chimică etc.) cât și prin metode de măsură indirecte (i.e. măsurarea emisiilor, reflexia, absorbtia și/ sau polarizarea de unde

electromagnetice printr-un mediu gazos). Din stadiul tehnicii, sunt bine cunoscute dispozitivele de măsurare directă precum stațiile meteo fixe sau cele mobile precum baloanele meteorologice și care permit achiziția pe altitudine a datelor meteo.

Tot din stadiul tehnicii, sunt cunoscute metodele de măsurare indirectă pentru determinarea prafului, a compoziției chimice, a densității și a vitezei deplasării gazelor atmosferice, prin măsurarea terestră sau din satelit a unei surse electromagnetice etalon cu proprietăți cunoscute aflate în unghi direct (i.e. Nadir) și care permite determinarea absorbției, a reflexiei, a polarizării sau a întârzierii undelor luminoase laser sau electromagnetice pe una sau mai multe căi de propagare și din care, prin calcule, se pot determina parametrii indirecti precum compoziția chimică gazoasă, densitatea ș.a.m.d.

Din US 2013/0325425A1 este cunoscută o metodă de măsurare indirectă a parametrilor atmosferici folosind semnale radio GNSS (i.e. sateliții GPS, GLONAS etc) provenite de la sateliți care sunt recepționate de un număr mare de dispozitive de poziționare (i.e. telefoane mobile inteligente etc.) și care, pe baza măsurării întârzierii semnalelor radio de frecvențe diferite, permit determinarea parametrilor atmosferici precum a umidității și/sau a prafului, a temperaturii etc.

În conformitate cu KR20190097773A, este cunoscută utilizarea dronelor aeriene pentru colectarea datelor de mediu conform unor coordonate geografice și al unui itinerar și care pot înlocui stațiile meteo fixe și parțial baloanele meteo. Sunt cunoscute exemple reale de sisteme de drone meteo precum MIRIAD al CNRM din Franța sau MeteoDrone XL al firmei Meteomatics din Elveția.

Din stadiul tehnicii, sunt cunoscute metodele de predicție bazate pe Rețele Neuronale și Rețele Neuronale Recurente care pot fi utilizate ca modele de predicție pentru fenomenele fizice ce evoluează în timp.

Tot din stadiul tehnicii, sunt cunoscute și metodele de optimizare bazate pe analiza componentelor principale, metodele de optimizare de tip "Black-Box" bazate pe învățarea Bayesiană și metodele de învățare în linie.

Tot din stadiul tehnicii, este cunoscut că sistemele complexe dinamice, puternic ne lineare precum prognozarea factorilor de mediu sunt dificil de prezis doar pe baza condițiilor inițiale deoarece nu există soluții matematice de formă închisă.

În conformitate cu un aspect al estimării producției de energie electrice regenerabile este cunoscut faptul că achiziția de date meteorologice este costisitoare de unde și interesul contradictoriu pe de o parte de a dispune de un număr mare de puncte de măsură a datelor meteo și o achiziție cât mai frecventă a acestora și care permit realizarea de predicții precise și, pe de altă parte, de a reduce numărul punctelor de măsură și frecvența de măsurare pentru a reduce costurile necesare prognozei.

Problema tehnică a invenției este realizarea unui sistem și a unei metode de optimizare a achiziției de date meteo adică stabilirea locației punctelor de interes din care datele meteo urmează a fi achiziționate, a ordinii de vizitare a acestora (i.e. descrescătoare ca influență) și a frecvenței de achiziție, și care sunt necesare pentru predicția energiei electrice regenerabile ce urmează a fi generată de un generator. Optimizarea achiziției de date meteo duce și la o optimizare a costurilor aferente achiziției datelor meteo.

Sistemul și metoda conform invenției utilizează o metodă adaptivă pentru predicția energiei electrice generate de un generator de energie electrică regenerabilă legat la o rețea de distribuție, în care generatorul este plasat într-o locație geografică dată și în care predicția de energie generată este pentru un interval de timp viitor. Metoda cuprinde mai multe etape.

O primă etapă este de încărcare a unor modele de predicție și de estimare, în care modelul de predicție permite predicția unor parametri de excitație specifici pentru locația generatorului la un moment de timp viitor dorit plecând de la un set de date meteo și, în care modelul de estimare permite estimarea energiei electrice generate de generatorul de energie electrică regenerabilă în cazul în care acesta este excitat cu parametri de excitație preziși.

O altă etapă este de inițializare a datelor meteo în care un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului sunt încărcate în modelul de predicție.

Într-o buclă de ajustare periodică metoda mai cuprinde și o etapă de citire al nivelului energiei electrice produse de generatorul la un moment ulterior etapei de inițializare în timpul funcționării acestuia.

În aceeași buclă de ajustare periodică metoda mai cuprinde și o etapă predicție a parametrilor de excitație ai generatorului pentru același moment cu cel din etapa de citire.

În aceeași buclă de ajustare periodică, ulterior etapei de predicție, metoda mai cuprinde o etapă de estimare a energiei electrice produse de generatorul când acesta este amplasat într-o

locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametrii de excitație preziși în etapa de predicție.

În aceeași buclă de ajustare periodică, metoda mai cuprinde o etapă de decizie a divergenței de predicție în care sunt comparate energia electrică măsurată în etapa de citire cu cea estimată în etapa de estimare și în care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență este luată decizia de a achiziționa un set de date meteo noi sau, atunci când criteriul de divergență nu este constatat, de a continua peste un interval de timp cu o nouă rundă de predicție revenind la etapele de citire și predicție.

În aceeași buclă de ajustare periodică, atunci când criteriul de divergență este constatat, metoda mai cuprinde o etapă de stabilire a unui set de puncte de achiziție de interes al datelor meteo urmată de o etapă de achiziție a datelor meteo în punctele de interes și revenire la etapa de inițializare considerând noile date meteo.

Metoda adaptivă de predicție a energiei electrice prognozate a fii generate de un generator de energie electrică regenerabilă plasat într-o locație geografică dată într-un interval de timp viitor,

cuprinde etapele de:

- a. Încărcare a unor modele de predicție și de estimare, în care:
 - i. modelul de predicție permite predicția unor parametrii de excitație specifici pentru locația generatorului la un moment de timp viitor dorit plecând de la un set de date meteo și,
 - ii. modelul de estimare permite estimarea energiei electrice generate de generatorul de energie electrică regenerabilă în cazul în care acesta este excitat cu parametrii de excitație preziși și,
- b. Inițializare date meteo în care un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului (104), sunt încărcăți in modelul de predicție ,

iar într-o buclă de ajustare periodică etapele de:

- c. Citire a nivelului energiei electrice produse de generatorul la un moment ulterior etapei de inițializare și,
- d. Predicție a parametrilor de excitație ai generatorului pentru același moment cu cel din etapa de citire și,

e. Estimare a energiei electrice prognozate a fii produse de generatorul când acesta este amplasat într-o locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametrii de excitație preziși în etapa de predicție și,

metoda fiind caracterizată prin aceea că, ulterior etapelor de citire și estimare a energiei electrice prognozate, în aceeași buclă de ajustare periodică, metoda cuprinde și etapele de:

f. Decizie a divergenței de predicție în care sunt comparate energia electrică măsurată în etapa de citire (206) cu prognoza estimată în etapa de estimare și în care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență este luată decizia de:

- i. Achiziție a unor noi date meteo sau,
- ii. Continuare a predicției folosind datele meteo inițiale revenind peste un interval de timp la etapele de citire (206) și predicție ,

și în cazul în care predicția este considerată a fii divergentă în etapa de decizie metoda continua cu etapele de:

- g. Stabilire a unui set de puncte de achiziție de interes al datelor meteo și,
- h. Achiziție de noi date meteo din punctele de interes și revenire la etapa de inițializare considerând noile date meteo.

Metoda cuprinde în etapa de achiziție o parte din punctele de interes pentru achiziție sunt aranjate într-un itinerar de vizitare ce urmează a fii parcurs de o stație meteo mobilă.

Metoda realizeaza în etapa de stabilire setul de puncte de achiziție de interes maximiza o funcție obiectiv în ordine descrescătoare.

Metoda realizeaza în etapa de stabilire funcția obiectiv ce trebuie optimizată este un model meteo definit peste o arie geografică vecină generatorului și care este o rețea neuronală multistrat în care neuronii din primul strat corespund punctelor geografice din aria geografică vecină generatorului organizați sub forma unei lactice de neuroni inter conectați prin intrări de legătură și în care neuronii au și un număr de intrări parametrice prin care datele meteo locale măsurate sunt introduse și în care ieșirea fiecărui neuron este un parametru meteo prezis.

Metoda în rețea neuronală multistrat este o rețea neuronală recurentă în care ieșirea a unui neuron este o intrare întârziată pentru stratul următor.

Sistemul de predicție adaptiv al energiei electrice prognozate a fii generate de un generator de energie electrică regenerabilă plasat într-o locație geografică dată într-un interval de timp viitor, sistemul cuprinzând:

i. Un modul de comandă care:

i. încarcă dintr-o bază de date asociativă

1. un model de predicție într-un modul de predicție , modelul de predicție fiind specific pentru predicția parametrilor de excitație specifici pentru locația generatorului la un moment de timp viitor dorit plecând de la un set de date meteo și,

2. un model de estimare a energiei electrice prognozate a fii generate de generatorul de energie electrică regenerabilă în cazul în care acesta este excitat cu parametrii de excitație preziși și,

ii. Inițializează modulele ale sistemului inteligent, al busului de comunicație intern prin care modulele comunică între ele și cu un număr de interfețe de comunicație externe și care prin inițializare încarcă în modulul de predicție un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului și,

j. Un modul de achiziție care:

i. citește în timp real nivelului energiei electrice produse de generatorul și,

ii. achiziționează date meteo, atunci când modulul de comandă decide necesară achiziția de noi date meteo, dintr-un număr de puncte de interes folosind un număr de stații meteo care sunt accesibile printr-o rețea de comunicație radio și,

k. Un modul de estimare care estimează energia electrică prognozată a fii produsă de generatorul când acesta este amplasat într-o locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametrii de excitație preziși de modulul de predicție pentru același moment cu cel de citire și,

Sistemul este caracterizat prin aceea că, modul de comandă orchestrează modulele de achiziție, de estimare și de predicție într-o buclă de control în care:

i. decide asupra divergenței de predicție comparând energia electrică citită cu prognoza estimată și care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență ia decizia de a:

1. a achiziție noi date meteo cu ajutorul modulului de achiziție și al stațiilor meteo sau,
2. continua predicția folosind datele meteo inițiale.

ii. stabilește un unui set de puncte de achiziție de interes al datelor meteo și,

iii. comandă modulul de achiziție pentru achiziția de noi date meteo din punctele de interes stabilite și, când datele meteo sunt achiziționate, comandă inițializarea acestora și continuă bucla de control cu o nouă rundă.

Sistem în care în modulul de achiziție o parte din punctele de interes pentru achiziție sunt aranjate într-un itinerar de vizitare ce urmează a fi parcurs de o stație meteo mobilă.

Sistem în care modulul de comandă stabilește setul de puncte de interes stabilite maximizând o funcție obiectiv în ordine descrescătoare.

Sistem în care funcția obiectiv ce trebuie optimizată este un model meteo definit peste o arie geografică vecină generatorului și care este o rețea neuronală multistrat în care neuroni din primul strat corespund punctelor geografice din aria geografică vecină generatorului organizați sub forma unei lăcșe de neuroni inter conectați prin intrări de legătură și în care neuronii au și un număr de intrări parametrice prin care datele meteo locale măsurate sunt introduse și în care ieșirea fiecărui neuron este un parametru meteo prezis.

Sistem în care rețea neuronală multistrat este o rețea neuronală recurentă în care ieșirea a unui neuron este o intrare întârziată pentru stratul următor.

Sistemul și metoda conform invenției prezintă următoarele avantaje :

- asigură prognoza capacității de producție direct corelată cu timpul probabil local
- asigură o optimizare a costurilor aferente achiziției datelor meteo.
- minimizează pierderile datorate diferențelor de prognoză

Se da în continuare, un exemplu de realizare a invenției în legătură cu figurile care reprezintă:

- Figura 1 prezintă structura unui sistem inteligent pentru predicția de energie electrică regenerabilă adecvat implementării metodei de predicție propuse;
- Figura 2 prezintă sub forma unei digrame de activități o implementare preferabilă a etapelor metodei de predicție inteligente a energiei electrice generate de un sistem pentru energia regenerabilă;
- Figura 3 prezintă primul strat dintr-o rețea neuronală multistrat și care este o parte a modelului de predicție pentru energia electrică prognozată;
- Figura 4 prezintă primul o rețea neuronală multistrat care un modelului de predicție preferabil pentru energia electrică prognozată;

Conform unei implementări preferabile se dă o metodă de predicție adaptivă (figura 2) a energiei electrice generate de un generator (104) (figura 1) de energie regenerabilă, cum este

spre exemplu un sistem de celule fotovoltaice sau un parc de turbine eoliene, prin care se achiziționează noi date meteo doar atunci când prognoza de energie electrică ce urmează a fi generată, și care este bazată pe un model de predicție și un set de date meteo inițial, diverge față de realitate adică nu mai este suficient de precisă pentru a fi utilizată ca prognoză validă în baza căreia se pot stabili contracte de furnizare a energiei electrice sau în baza căreia se poate evalua cu suficientă precizie dacă un contract aflat în derulare către o rețea de distribuție (105) mai poate fi onorat. O astfel de metodă ce optimizează achiziția de date meteo necesare în sensul că numărul de puncte de măsură, locația lor, ordinea de vizitare și frecvența de achiziție sunt optimizate adică reduse la atât cât este necesar dar nu mai mult sau mai puțin, pe lângă faptul ca este mai rapidă și se adaptează din mers condițiilor meteorologice excepționale are și marele avantaj economic de a reduce costurile aferente achiziției de date meteo. Această metodă poate fi perfect cuplată cu ideea de a folosirii de stații meteo mobile precum dronele meteo, avioanele de agrement, telefoanele mobile inteligente sau alte metode ieftine, în care senzorii de achiziție nu se pierd cum este de cele mai multe ori cazul baloanelor meteo ci care sunt recuperați pentru noi achiziții de date ulterioare.

Într-o implementare preferabilă această metodă este implementată printr-un sistem de achiziție adaptiv (110) (figura 1) care implementează etapele metodei sub forma unui program software ce rulează pe un computer ce are memorie persistentă sau disc dur HD, o memorie RAM cu acces aleator, o unitate centrală de procesare CPU și un număr de interfețe de comunicație precum o plăcile de rețea care permit comunicarea cu alte dispozitive externe precum o stație meteo (103) sau un generator de energie regenerabilă (104) prin intermediul unor rețele de date mobile precum rețelele de tip LoRa, NB-IOT, GSM, WiFi sau altele sau prin intermediul altor interfețe hardware.

Conform unei implementări preferabile ilustrate în figura 2, într-o primă etapă de încărcare (202) un model de predicție a parametrilor de excitație dintr-un set de date meteo inițial este încărcat din memoria persistentă în memoria RAM a computerului ce execută pașii metodei. Așa cum este bine-cunoscut din literatura de specialitate, pentru un sistem fotovoltaic parametrii de excitație principali sunt radianța solară directă și difuză iar pentru un sistem eolian acești parametrii sunt vectorii de vânt (i.e. direcție și intensitate) specifici unei locații și altitudinii date. Așa cum este cunoscut din artă, predicția meteo este un fenomen complex, puternic ne linear și care nu poate fi descris printr-o formulă matematică închisă și deci care diverge în timp în sensul că o cauză mică poate induce efecte total ne așteptate în viitor, acest fenomen fiind bine cunoscut din literatura de specialitate sub numele de efectul

de fluture. Conform unui aspect al acestei invenții, utilizarea unui model de predicție bazat pe rețelele neuronale recurente RNN are avantajul de a putea fii perfect ajustabil reliefului și de a învăța bine comportamentul meteo local în timp (i.e. interacțiunile dintre teren și masele de aer locale și între masele de aer la diverse altitudini) datorită structurii alese și anume primul strat de neuroni (figura 3) este preferabil o lattice de neuroni conectați în care fiecare neuron corespunde unei unități de suprafață (i.e. 10×10 metrii, 100×100 m) sau de volum (i.e. voxel de $N \times N \times N$ metrii) și care este conectat la vecinii lui (i.e. 4 la 8 vecini direcți pentru un model 2D matriceal sau 6 la 26 vecini direcți pentru un model spațial 3D). Această structură este similară cu cea a metodei de simulare mecanice așa zise a elementului finit în care un corp ce urmează a fii simulat mecanic este descompus într-o structură de tip meșă/plasă având noduri și legături iar interacțiunile între noduri sunt calculate ținând cont doar de legăturile cu nodurile vecine directe. Este evident că alte structuri cu ar fii o lattice ne omogenă și ne ortogonală adică în formă de plasă poate fii aleasă atâta timp cât structura obținută este adaptată mediului și generează rezultate practice de predicție acceptabile. Conform unui aspect al acestei invenții, fiecare neuron (301) are ca intrări pe lângă cele ce stabilesc interacțiunile spațiale (303a 303b), adică între vecinii geografici, și un număr de intrări de parametrii meteo (303a 303b 303c) (i.e. temperatură, presiune, umiditate, praf, radianță solară, vectori de vânt etc) și care influențează parametrii de excitație specifici ariei geografice ocupate de neuron și care urmează a fii prezis. Este de la sine înțeles că doi neuroni diferiți pot avea un număr de intrări de parametrii meteo diferite fiind specializați spre exemplu în funcție de poziția lor în spațiu. Astfel, radianța solară are un impact pregnant la nivelul solului sau la altitudini medii și înalte unde există nori ce pot absorbi lumina solară etc.

Conform unei implementări preferabile ilustrate în figura 4, primul strat de neuroni (401) și, care este detaliat în figura 3, este integrat în rețeaua neuronală de predicție. Conform unui aspect al acestei invenții, penultimul strat (402) are aceeași structură spațială ca și primul strat iar ieșirile lui sunt valorile datelor meteo prezise (403). Ultimul strat de neuroni (404) este o mapare care, pornind de la setul de date meteo prognozate adică ieșirile din penultimul strat (402), estimează parametrii de excitație (405). Conform unui aspect al acestei invenții, rețeaua neuronală formată între straturile inițial (401) și penultim (402) este o rețea neuronală de prognoză meteo ce poate fii înlocuită cu orice alt sistem de prognoză meteo fără a restricționa caracterul acestei invenții. Doar ultimul strat prezice parametrii de excitație (405) pornind de la un set de date meteo. Antrenarea unei astfel de rețele este foarte simplă întrucât

ea nu este dependentă de timp. Conform unui aspect al acestei invenții, în stratul final ieșirea fiecărui neuron (405) este specifică unui parametru de excitație ce este prezis. Astfel, pentru a determina mai mulți parametrii sunt necesare mai multe rețele neuronale.

Conform unei implementări preferabile ilustrate în figura 2, în aceeași etapă de încărcare (202) un model de estimare al energiei electrice prognozate a fii generate este de asemenea încărcat în memorie. Un astfel de model este o funcție de transfer care este specifică generatorului amplasat în condiții reale de exploatare și care poate fii sau obținută prin teste de calibrare. Într-o implementare mai puțin pretențioasă funcția de estimare este funcția de transfer furnizată în fișa tehnică a generatorului (104) și care nu ia în calcul amplasamentul (i.e. configurația de montaj), parametrii de funcționare (i.e. temperatura și presiunea atmosferică etc) sau îmbătrânirea echipamentului ce vor deteriorează funcția de transfer către o variantă mai puțin eficientă. Așa cum este cunoscut din artă, modelul de estimare este de obicei static în sensul ca nu este modificat o dată stabilit și el poate fii implementat cel mai simplu sub forma unui tabel asociativ în care parametrii de excitație sunt asociați unei puteri instantanee prognozată a fii produsă.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de inițializare (203) încarcă un set de date meteo dintr-o bază de date asociativă (106) (figura1) sau de la un număr de stații meteo (103) (figura 1) și pornește o buclă de procesare ce cuprinde mai multe etape.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de predicție (204) prezice parametrii de excitație dintr-un interval de timp folosind modelul de predicție încărcat și activat inițial cu datele meteo. Practic, modelul de predicție este o rețea neuronală recurentă RNN care a fost antrenată în prealabil și a cărei structură adică dendritele de reacție între straturi sunt concepute cu întârzieri ce sunt preferabil corelate cu periodicitatea comportamentelor meteo (i.e. 10 minute, 1oră, 1 zii, 1 an). O astfel de rețea este excitată cu datele meteo inițiale și activată succesiv de N ori pentru N intervale de timp DT succesive care însumate dau timpul viitor T pentru care se dorește predicția. Ieșirile rețelei după pașii de simulare reprezintă parametrii de excitație preziși pentru timpul viitor T.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de estimare (205) convertește parametrii de excitație preziși într-un nivel de energie prognozat pe baza modelului de estimare încărcat în prealabil.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de citire (206) citește nivelul de energie instantanee produs de generatorul (104).

Conform unei implementări preferabile ilustrate în figura 2, o etapă de decizie (207) compară nivelul citit curent cu cel prognozat plecând de la ratele meteo inițiale și atunci când un criteriu de divergență este verificat comandă achiziția de noi date meteo printr-o etapă de stabilire a punctelor de achiziție (208) urmată de o etapă de achiziție a datelor meteo (209) și în final revenind la etapa de inițializare (203) cu noul set de date. Conform unui aspect al acestei invenții, într-o implementare trivială, criteriul de divergență este un prag numeric. Într-o implementare preferabilă criteriul de divergență este o integrală peste eroarea de predicție înmulțită cu o fereastră alunecătoare. Într-o altă implementare preferabilă, criteriul de divergență este incertitudinea de predicție Bayes a funcției de predicție în punctul de timp T.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de stabilire (208) a punctelor de achiziție în care datele meteo urmează a fi măsurate alege un număr de puncte de măsură (i.e. coordonate geografice și de altitudine) preferabil utilizând o metodă de optimizare de tip Black Box. Se obțin astfel locațiile de achiziție ordonate după importanța lor descrescătoare în care punctul cel mai important (i.e. cu impactul cel mai mare) este prioritarizat. Conform unui aspect al acestei invenții, setul de puncte ordonat ca importanță este re ordonat conform unui algoritm de minimizare a drumului critic care alege punctele de interes ca un drum minim ce poate parcurs de o dronă meteo și care ține cont și de importanța punctelor. Algoritmul de drum critic ține cont deci de importanța punctului măsurat și de lungimea drumului parcurs.

Conform unei implementări preferabile ilustrate în figura 2, o etapă de achiziție (209) a datelor meteo achiziționează noi date meteo dintr-o bază de date externă (106) sau cu ajutorul unui număr de stații meteo (103) accesibile printr-o rețea radio (102). Conform unui aspect al acestei invenții, în etapa de achiziție (209) un modul de comandă (115) (figura 1) al unui sistem inteligent pentru predicția energiei electrice generate (110) comandă un număr de drone meteo (103) conform cu itinerariile stabilite în etapa de stabilire (208) și atunci când aceste sunt achiziționate le inițializează. Conform unui aspect al acestei invenții, în etapa de stabilire (209) numărul de punctele de interes poate fi mic decât numărul de date meteo inițiale. Într-o implementare preferabilă datele meteo achiziționate în punctele de interes în pasul de achiziție se înlocuiesc în setul de date meteo prezis (403) (figura 4).

Conform figurii 1, metoda adaptivă din figura 2 poate fi implementată și ca un sistem de predicție adaptiv al energiei electrice prognozate (110) a fii generate de un generator de energie electrică regenerabilă (104) plasat într-o locație geografică dată într-un interval de timp viitor.

Conform unei implementări preferabile ilustrate în figura 1 sistemul adaptat cuprinde un modul de comandă (115) care încarcă dintr-o bază de date asociativă (106) un model de predicție într-un modul de predicție (114), modelul de predicție fiind specific pentru predicția parametrilor de excitație specifici pentru locația generatorului (104) la un moment de timp viitor dorit plecând de la un set de date meteo și, un model de estimare a energiei electrice prognozate a fii generate de generatorul de energie electrică regenerabilă (104) în cazul în care acesta este excitat cu parametrii de excitație preziși și, inițializează celelalte modulele (112, 113 și 114) ale sistemului inteligent și busul de comunicație intern (111) prin care modulele comunică între ele și cu un număr de interfețe de comunicație externe și care prin inițializare încarcă în modulul de predicție (114) un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului (104).

Conform unei implementări preferabile ilustrate în figura 1 sistemul adaptat cuprinde și un modul de achiziție care citește în timp real nivelul energiei electrice produse de generatorul (104) și achiziționează date meteo, atunci când modulul de comandă decide necesară achiziția de noi date meteo, dintr-un număr de puncte de interes folosind un număr de stații meteo (103) care sunt accesibile printr-o rețea de comunicație radio (102) și, un modul de estimare (113) care estimează energia electrică prognozată a fii produsă de generatorul (104) când acesta este amplasat într-o locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametrii de excitație preziși de modulul de predicție (114) pentru același moment cu cel de citire.

Conform unei implementări preferabile ilustrate în figura 1 sistemul adaptat are un modul de decizie (207) care este caracterizat prin aceea că, modul de comandă (115) orchestrează modulele de achiziție (112), de estimare (113) și de predicție (114) într-o buclă de control în care decide asupra divergenței de predicție comparând energia electrică citită cu prognoza estimată și care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență ia decizia de a achiziționa noi date meteo cu ajutorul modulului de achiziție (112) și al stațiilor meteo (103) sau de a continua predicția folosind datele meteo inițiale.

Conform unei implementări preferabile ilustrate în figura 1 sistemul adaptat are un modul de stabilire (208) un unui set de puncte de achiziție de interes al datelor meteo.

Conform unei implementări preferabile ilustrate în figura 1 sistemul adaptat are un modul de achiziție (209) pentru achiziția de noi date meteo din punctele de interes stabilite și, când datele meteo sunt achiziționate, comandă inițializarea acestora și continuă bucla de control cu o nouă rundă.

REVENDICĂRI

1. Metodă adaptivă de predicție a energiei electrice prognozate a fii generate de un generator de energie electrică regenerabilă (104) plasat într-o locație geografică dată într-un interval de timp viitor,

metoda cuprinzând etapele de:

- a. Încărcare (202) a unor modele de predicție și de estimare, în care:
 - i. modelul de predicție permite predicția unor parametri de excitație specifici pentru locația generatorului (104) la un moment de timp viitor dorit plecând de la un set de date meteo și,
 - ii. modelul de estimare permite estimarea energiei electrice generate de generatorul de energie electrică regenerabilă (104) în cazul în care acesta este excitat cu parametri de excitație preziși și,
- b. Inițializare (203) date meteo în care un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului (104), sunt încărcate în modelul de predicție și,

și într-o buclă de ajustare periodică etapele de:

- c. Citire (206) al nivelului energiei electrice produse de generatorul (104) la un moment ulterior etapei de inițializare și,
- d. Predicție (204) a parametrilor de excitație ai generatorului (104) pentru același moment cu cel din etapa de citire (206) și,
- e. Estimare a energiei electrice (205) prognozate a fii produse de generatorul (104) când acesta este amplasat într-o locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametri de excitație preziși în etapa de predicție (204) și,

metoda fiind caracterizată prin aceea că, ulterior etapelor de citire (206) și estimare a energiei electrice (205) prognozate, în aceeași buclă de ajustare periodică, metoda cuprinde și etapele de:

- f. Decizie (206) a divergenței de predicție în care sunt comparate energia electrică măsurată în etapa de citire (206) cu prognoza estimată în etapa de estimare (205) și în care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență este luată decizia de:

- i. Achiziție a unor noi date meteo sau,
 - ii. Continuare a predicției folosind datele meteo inițiale revenind peste un interval de timp la etapele de citire (206) și predicție (204),

și în cazul în care predicția este considerată a fi divergentă în etapa de decizie (206) metoda continua cu etapele de:

 - g. Stabilire (208) a unui set de puncte de achiziție de interes al datelor meteo și,
 - h. Achiziție (209) de noi date meteo din punctele de interes și revenire la etapa de inițializare (203) considerând noile date meteo.
2. Metoda conform revendicării 1 în care în etapa de achiziție (209) o parte din punctele de interes pentru achiziție sunt aranjate într-un itinerar de vizitare ce urmează a fi parcurs de o stație meteo mobilă.
3. Metoda conform revendicării 1 în care în etapa de stabilire (208) setul de puncte de achiziție de interes maximizează o funcție obiectiv în ordine descrescătoare.
4. Metoda conform revendicării 3 în care în etapa de stabilire (208) funcția obiectiv ce trebuie optimizată este un model meteo (figura 3) definit peste o arie geografică vecină generatorului (104) și care este o rețea neuronală multistrat în care neuronii (301) din primul strat corespund punctelor geografice din aria geografică vecină generatorului (104) organizați sub forma unei lactice de neuroni (301) interconectați prin intrări de legătură (303a-303b) și în care neuronii au și un număr de intrări parametrice (302a-302c) prin care datele meteo locale măsurate sunt introduse și în care ieșirea (304) fiecărui neuron este un parametru meteo prezis.
5. Metoda conform revendicării 4 în rețea neuronală multistrat este o rețea neuronală recurentă în care ieșirea (304) a unui neuron (301) este o intrare întârziată pentru stratul următor.
6. Sistem de predicție adaptiv al energiei electrice prognozate (110) a fi generate de un generator de energie electrică regenerabilă (104) plasat într-o locație geografică dată într-un interval de timp viitor, sistemul cuprinzând:
 - a. Un modul de comandă (115) care:

- i. încarcă dintr-o bază de date asociativă (106):
 1. un model de predicție într-un modul de predicție (114), modelul de predicție fiind specific pentru predicția parametrilor de excitație specifici pentru locația generatorului (104) la un moment de timp viitor dorit plecând de la un set de date meteo și,
 2. un model de estimare a energiei electrice prognozate a fii generate de generatorul de energie electrică regenerabilă (104) în cazul în care acesta este excitat cu parametrii de excitație preziși și,
 - ii. Inițializează modulele (112, 113 și 114) ale sistemului inteligent, al busului de comunicație intern (111) prin care modulele comunică între ele și cu un număr de interfețe de comunicație externe și care prin inițializare încarcă în modulul de predicție (114) un set de date meteo măsurate în unul sau preferabil mai multe puncte geografice din vecinătatea locației generatorului (104) și,
- b. Un modul de achiziție care:
- i. citește în timp real nivelul energiei electrice produse de generatorul (104) și,
 - ii. achiziționează date meteo, atunci când modulul de comandă decide necesară achiziția de noi date meteo, dintr-un număr de puncte de interes folosind un număr de stații meteo (103) care sunt accesibile printr-o rețea de comunicație radio (102) și,
- c. Un modul de estimare (113) care estimează energia electrică prognozată a fii produsă de generatorul (104) când acesta este amplasat într-o locație geografică de montaj dată și configurat pentru funcționare și când acesta este excitat cu parametrii de excitație preziși de modulul de predicție (114) pentru același moment cu cel de citire și,

sistemul fiind caracterizat prin aceea că, modul de comandă (115) orchestrează modulele de achiziție (112), de estimare (113) și de predicție (114) într-o buclă de control în care:

- i. decide asupra divergenței de predicție comparând energia electrică citită cu prognoza estimată și care atunci când evoluția erorii de predicție corespunde sau nu unui criteriu de divergență ia decizia de a:
 1. a achiziție noi date meteo cu ajutorul modulului de achiziție (112) și al stațiilor meteo (103) sau,
 2. continua predicția folosind datele meteo inițiale.
 - ii. stabilește un set de puncte de achiziție de interes al datelor meteo și,
 - iii. comandă modulul de achiziție (209) pentru achiziția de noi date meteo din punctele de interes stabilite și, când datele meteo sunt achiziționate, comandă inițializarea acestora și continuă bucla de control cu o nouă rundă.
7. Sistem conform revendicării 6 în care în modulul de achiziție (209) o parte din punctele de interes pentru achiziție sunt aranjate într-un itinerar de vizitare ce urmează a fi parcurs de o stație meteo mobilă.
8. Sistem conform revendicării 6 în care modulul de comandă stabilește setul de puncte de interes stabilite maximizând o funcție obiectiv în ordine descrescătoare.
9. Sistem conform revendicării 8 în care funcția obiectiv ce trebuie optimizată este un model meteo definit peste o arie geografică vecină generatorului (104) și care este o rețea neuronală multistrat în care neuronii (301) din primul strat corespund punctelor geografice din aria geografică vecină generatorului (104) organizați sub forma unei lactice de neuroni (301) inter conectați prin intrări de legătură (303a 303b) și în care neuronii au și un număr de intrări parametrice (302a-302c) prin care datele meteo locale măsurate sunt introduse și în care ieșirea (304) fiecărui neuron este un parametru meteo prezis.
10. Sistem conform revendicării 9 în care rețea neuronală multistrat este o rețea neuronală recurentă în care ieșirea (304) a unui neuron (301) este o intrare întârziată pentru stratul următor.

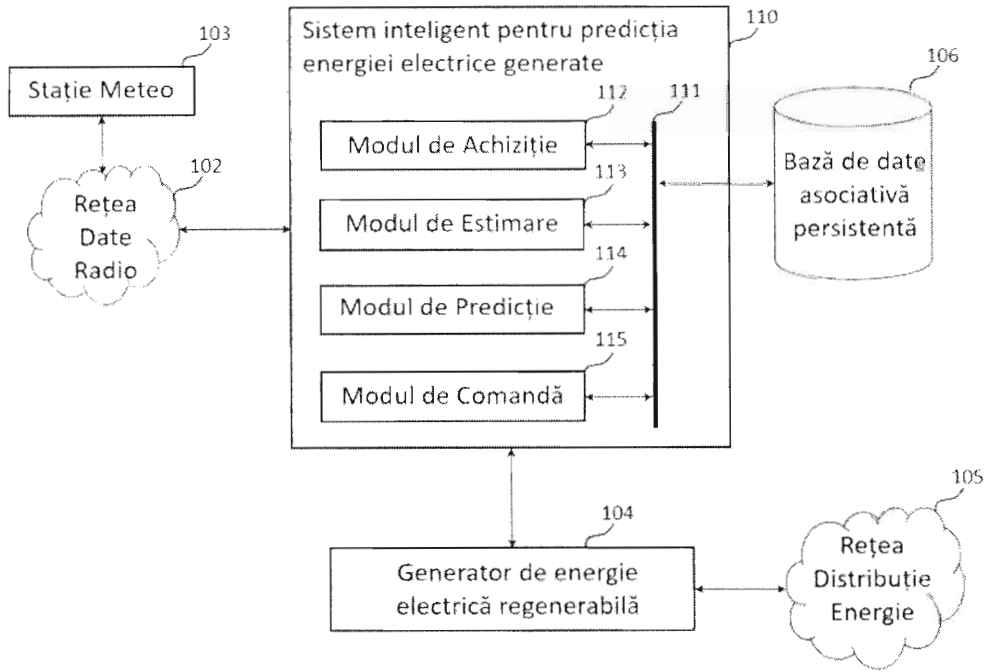


Figura 1

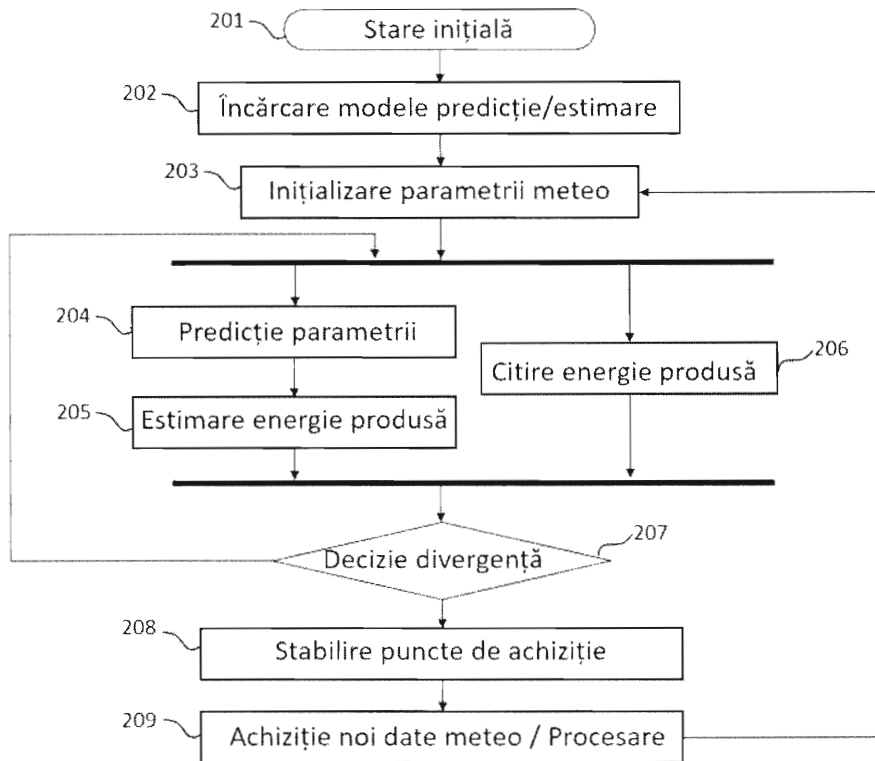


Figura 2




Figura 3




Figura 4