

(12) CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2022 00215

(22) Data de depozit: 26/04/2022

(41) Data publicării cererii:  
30/09/2022 BOPI nr. 9/2022

(71) Solicitant:  
• ULMEANU ANATOLI PAUL,  
STR.IVAN PETROVICI PAVLOV, NR.62,  
BUCUREȘTI, B, RO;  
• BOICEA ADRIAN VALENTIN,  
CALEA FLOREASCA, NR.91-111, BL.F1,  
SC.2, AP.17, BUCUREȘTI, B, RO

(72) Inventatori:  
• ULMEANU ANATOLI PAUL,  
STR.IVAN PETROVICI PAVLOV, NR.62,  
BUCUREȘTI, B, RO;  
• BOICEA ADRIAN VALENTIN,  
CALEA FLOREASCA, NR.91-111, BL.F1,  
SC.2, AP.17, BUCUREȘTI, B, RO

(54) ARHITECTURĂ BAZATĂ PE PROCES DE TIP HIDDEN  
MARKOV PENTRU A DETERMINA ÎN TIMP REAL CELE MAI  
PROBABILE NIVELE DE INCERTITUDINE ȘI DE  
VARIABILITATE A DATELOR UNEI SERII TEMPORALE

(57) Rezumat:

Invenția se referă la procese de tip Hidden Markov (HM) și, în particular, la utilizarea acestora ca arhitecturi de tip "Machine Learning" (ML) pentru determinarea în timp real a celor mai probabile niveluri de variabilitate și de incertitudine a datelor din serii temporale. Arhitectura se poate implementa fie printr-un modul software, fie ca un dispozitiv autonom cuprinzând hardware specializat și software. Conform invenției, se generează noi serii temporale de marginare inferioară, respectiv superioară, a datelor dintr-o serie S printr-un calcul cunoscut de borne de tip minim, respectiv maxim, bazat pe medieri de tip medie mobilă (MA) și pe abateri standard mobile (MSD), pentru un interval de timp glisant, de mărime constantă și calculată ca un multiplu al pasului de timp al seriei temporale S. Pentru un interval de timp de referință, perechi de date temporale de tipul {MA-2\*MSD, MA+2\*MSD} sunt partiționate ca serii și pot fi utilizate pentru antrenarea unui proces stochastic  $\Pi_2$  de tip HM, în timp ce perechile de date temporale de tipul {MA-3\*MSD, MA+3\*MSD} sunt de asemenea partiționate și pot fi utilizate pentru antrenarea unui proces stochastic  $\Pi_3$  de tip HM, ambele procese stochastice,  $\Pi_2$  și  $\Pi_3$  având același număr de mecanisme ascunse. Pe baza unei proceduri cunoscute de decodare atribuită procesului stochastic  $\Pi_2$ , se pot transforma date {MA-MSD, MA+MSD} asociate tipurilor de date ale seriei S într-un șir de valori pozitive  $s_1, s_2,$

..., unde  $s_i$  aparține  $\{1, 2, \dots, N\}$ , iar pe baza unei proceduri de decodare asociată procesului stochastic  $\Pi_3$  se transformă aceleași date într-un șir de valori pozitive  $t_1, t_2, \dots$ , unde  $t_i$  aparține  $\{1, 2, \dots, N\}$ . Nivelurile de incertitudine, respectiv de variabilitate a datelor rezultă din compararea distanței Manhattan între șirul  $s_1, s_2, \dots$  și șirul  $t_1, t_2, \dots$  și au ca bază de fundamentare mecanismele rezultate din cele două antrenări ale proceselor  $\Pi_2$  și, respectiv,  $\Pi_3$ .

Revendicări: 3  
Figuri: 19




Fig. 10

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).



OFICIUL DE STAT PENTRU INVENȚII ȘI MĂRCI  
Cerere de brevet de invenție  
Nr. .... a 2022 00215  
26-04-2022  
Data depozit .....

RO 136007 A0

54

**Titlul invenției:** Arhitectură bazată pe procese de tip Hidden Markov pentru a determina în timp real cele mai probabile nivele de incertitudine și de variabilitate a datelor unei serii temporale

### Domeniul tehnic la care se referă invenția

Invenția se referă, în general, la procese de tip **Hidden Markov (HM)** și, în particular, la utilizarea acestora ca arhitecturi de tip «Machine Learning (ML)» pentru **determinarea în timp real a celor mai probabile nivele de variabilitate și de incertitudine** a datelor unei serii temporale.

Arhitectura se poate implementa eficient fie printr-un modul software pentru un calculator personal (PC), fie ca un dispozitiv autonom (hardware specializat și software).

Seriile temporale se referă la un șir de date statistice care descriu evoluția în timp a fenomenelor. Recunoașterea, interpretarea și știința analizei tipurilor de serii temporale este esențială pentru managementul infrastructurilor societății: mediu, energie (inclusiv dispecerizarea infrastructurilor în condițiile operării în piața de energie), piețele financiare, bursiere, etc.

ML se referă la proiectarea și dezvoltarea de arhitecturi software care au ca intrare date statistice empirice colectate de la infrastructuri, de regulă, prin sisteme de tip «Supervisory Control and Data Acquisition (SCADA)», iar ca fundament recunoașterea mecanismelor și a profilurilor care se «ascund» în spatele acestor date. Obiectivul este de a rezolva probleme complexe cum ar fi: predicția, detectarea anomaliilor, managementul rezervelor instalate în infrastructuri, în condiții de variabilitate și incertitudine [BRC2021, LMZ2012, EDIH2013, CGM2019].

Un pachet important al ML este cel bazat pe utilizarea proceselor HM. În acest context, ne bazăm pe următoarele etape: proiectări de HM, antrenarea (învățarea) acestora pe seturi de date de intrare pentru a calibra statistic parametrii proiectelor HM și utilizarea celui mai bun HM deja antrenat cu datele culese de SCADA pentru: predicții, detectări de anomalii (abateri statistice anormale) în diverse scenarii de operare ale infrastructurilor în mecanismele de piață, determinarea celor mai probabile nivele de incertitudine și de variabilitate.

Cele două statistici în prezenta invenție sunt evidențiate distinct, variabilitatea se referă la schimbări așteptate la nivelul variației datelor, în timp schimbările care nu sunt așteptate fac obiectul incertitudinii. Considerăm că determinarea **distinctă** a acestor statistici este importantă pentru controlul, operarea și managementul proceselor din infrastructuri. De exemplu, în Sistemul Energetic Național (SEN) tipurile de rezerve, ca și capacitățile acestora sunt dispecerizate dinamic, de regulă din sfert în sfert de oră, în funcție de variabilitatea și incertitudinea consumului minut-cu-minut din curba de sarcină națională, de caracterul aleator al generării energiei în SEN din surse regenerabile (de exemplu: eolian, fotovoltaic), de retragerile neprogramate din exploatare ale grupurilor generatoare, coroborat cu tranzitul de puteri import-export. Arhitectura din prezenta invenție a fost concepută, realizată și testată pentru serii temporale de tip consum minut-cu-minut de putere electrică activă, la nivel de SEN și de aceea, în cele ce urmează, în prezentarea problemei tehnice va fi exemplificat acest tip particular de serie temporală. Trebuie însă accentuat caracterul general al aplicabilității metodei pentru toate tipurile de serii temporale cu date stohastice din diverse domenii, cum ar cele financiare, meteorologice, seismologice sau de generare a energiei din surse regenerabile.

### Stadiul tehnicii

În tehnica actuală sunt cunoscute dificultățile care apar în analiza statistică a datelor dintr-o serie temporală, în ceea ce privește determinarea **distinctă** a variabilității și a incertitudinii, ca părți

inerente ale tehnologiilor și proceselor moderne industriale care generează aceste date. Astfel, în patentul US9569804B2, conceptele de incertitudine și variabilitate sunt puse pe seama fenomenelor meteo care influențează consumul de energie electrică. Acestea sunt determinate pe baza unor algoritmi cunoscuți, bazați pe simulări Monte Carlo sau diverse modele liniare precum Generalized Additive Model (GAM), Regresia Liniară (RL), Support Vector Machine (SVM), Random Forest (RF). De regulă, metodele bazate pe Monte Carlo necesită un număr mare de simulări, mai ales în cazul unor volume mari de date, iar datele folosite la intrare trebuie să fie de calitate înaltă, fără erori, ceea ce face aceasta metodă mai puțin compatibilă cu conceptul de Big Data. Modelele liniare, pe de altă parte, au de cele mai multe ori o acuratețe redusă. SVM are toleranță scăzută la eventualele erori ce pot apărea în datele de intrare și funcționează împreună cu alți algoritmi, ceea ce înseamnă timpi de calcul suplimentari. RF este caracterizat de aceleași limitări ca și SVM. În patentul US9507367B2 este descris un sistem de control dinamic stohastic al circulației de puteri într-o rețea electrică. Aici, conceptele de incertitudine și variabilitate sunt corelate cu caracterul intermitent al surselor regenerabile de energie. Rețeaua electrică este, conform patentului US9507367B2, împărțită în două zone distincte, asociate unui controller. Spre deosebire de abordarea descrisă în cele ce urmează, acest tip de soluție este costisitoare, implicând atât componente software cât și componente hardware. În patentul US7203635B2 este prezentat un sistem asemănător celui descris în prezenta cerere, cu aplicabilitate în domeniul reprezentării statistice stratificate a datelor rezultate din surse multiple și care posedă diferite nivele de granularitate și abstractizare. Arhitectura stratificată de tip HMM se dovedește, ca și în cazul de față, a avea o robustețe crescută la variațiile subtile ale datelor, modelul permițând o adaptabilitate ridicată la aceste variații, cu reantrenare minimă.

Arhitectura bazată pe procese de tip HM pentru a determina în timp real cele mai probabile nivele de incertitudine și de variabilitate a datelor unei serii temporale prezintă următoarele caracteristici specifice:

- indică limitele cele mai probabile ale incertitudinii și variabilității, făcând distincția clară între cele două;
- prin indicarea acestor limite permite rafinarea politicilor de operare și securitate în sisteme complexe, cum ar fi rețelele de energie. Acestea înglobează la ora actuală soluții **innovative** la nivelul producerii energiei din resurse regenerabile, microrețelelor, stocării energiei, răspunsului la cerere, centralelor electrice virtuale și contorizării cu rată înaltă de raportare.

#### Descrierea figurilor

Problema tehnică și obiectivele prezentei invenții pot fi înțelese mai bine prin referire la următoarele figuri, după cum urmează:

- Fig.1, seria temporală S a datelor de consum minut-cu-minut de putere activă electrică din SEN, într-o zi (24 de ore) ;
- Fig.2, seria temporală a datelor de consum minut-cu-minut de putere activă electrică din SEN și filtrarea acestora prin Medie Alunecătoare (MA), pentru interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA rezultante pentru prima oră din ziua considerată în fig.1 ;
- Fig.3, seria temporală a datelor de consum minut-cu-minut de putere activă electrică din SEN și filtrarea acestora prin MA, pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA rezultante în ziua considerată ;
- Fig.4, seriile temporale MA și MA-MSD, pentru filtrare de tip « Moving Standard Deviation » (MSD), pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-MSD rezultante pentru ora considerată în fig.2 ;
- Fig.5, seriile temporale MA, MA-MSD și MA+MSD, pentru filtrarea seriei S cu o funcție de tip Moving Standard Deviation (MSD), pentru un interval de timp glisant de lățime 30 minute,



- cu indicarea seriei temporale de tip MA, respectiv MA-MSD și MA+MSD rezultante pentru ora considerată în fig.2 ;
- Fig.6, seriile temporale MA, MA-2\*MSD și MA+2\*MSD, pentru filtrarea seriei S cu o funcție de tip Moving Standard Deviation (MSD), pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-2\*MSD și MA+2\*MSD rezultante pentru ora considerată în fig.2 ;
  - Fig.7, seriile temporale MA, MA-3\*MSD și MA+3\*MSD, pentru filtrarea seriei S cu o funcție de tip MSD, pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-3\*MSD și MA+3\*MSD rezultante pentru ora considerată în fig.2 ;
  - Fig.8, seriile temporale MA-3\*MSD, MA, respectiv MA+3\*MSD pentru datele de consum minut-cu-minut de putere activă electrică din SEN, pentru ziua considerată în fig.1 ;
  - Fig. 9, seriile temporale S, MA, MA-3\*MSD, respectiv MA+3\*MSD pentru datele de consum minut-cu-minut de putere activă electrică din SEN, prin filtrarea seriei S cu o funcție de tip MSD, pentru un interval de timp glisant de lățime 30 minute pentru ziua considerată în fig.1 ;
  - Fig. 10, evidențierea variabilității pentru consum în banda (MA-MSD, MA-2\*MSD), respectiv în banda (MA+MSD, MA+2\*MSD), respectiv a incertitudinii pentru consum în banda (MA-2\*MSD, MA-3\*MSD), respectiv în banda (MA+2\*MSD,MA+3\*MSD) pentru datele de consum minut-cu-minut de putere activă electrică din SEN, cu filtrarea seriei S cu o funcție de tip MSD, pentru interval de timp glisant de lățime **30 minute** pentru ziua considerată în fig.1 ;
  - Fig.11, un exemplu de traiectorii ale unui HMM cu timp discret, omogen, de ordin 1 ;
  - Fig.12, un exemplu de partiționare la 24 de ore a observațiilor în vederea antrenării HMM ;
  - Fig.13, un exemplu de decodare a observațiilor prin intermediul unui HMM cu timp discret, omogen, de ordin 1 ;
  - Fig.14, nivelele de variabilitate V și de incertitudine (U) obținute prin decodarea observațiilor multivariate Z;
  - Fig.15, arhitectura de tip ML bazată pe procese de tip Hidden Markov pentru a determina în timp real cele mai probabile nivele de incertitudine și de variabilitate a datelor unei serii temporale;
  - Fig.16, exemplu de evoluție a celor mai probabile nivele medii orare de incertitudine (U) ale datelor din seria temporală din figura 19;
  - Fig.17, exemplu de evoluție a celor mai probabile nivele medii orare de variabilitate (V) ale datelor din seria temporală din figura 19;
  - Fig.18, corelarea evoluțiilor prezentate în figurile 16 și 17;
  - Fig.19, seria temporală pentru reprezentările grafice din figurile 16,17 și 18.

### Prezentarea problemei tehnice

Pentru a putea modela și estima distinct cele două statistici, utilizăm o tehnică automată binecunoscută, bazată pe procese stohastice HM, respectiv construim un Hidden Markov Model (HMM). Aceste modele au fost și sunt utilizate cu succes în probleme de biologie moleculară, finanțe, procesarea semnalelor, recunoașteri de voce, de gesturi sau de scris. Pentru orice tip de problemă, un HMM este proiectat și antrenat, astfel încât parametrii modelului sunt ajustați, pentru ca pentru setul de date de antrenare propus, funcția obiectiv a HMM, cea de verosimilitate, să fie maximă. Aceasta reflectă probabilitatea ca, o data propus un set de date de intrare, altul decât cel de antrenare, acesta să aparțină unei clase modelate de acel HMM. Pentru fiecare HMM proiectat, se estimează valorile criteriilor: Akaike Information Criteria (AIC), respectiv Bayesian Information Criteria (BIC), pentru a decide care HMM este cel mai potrivit [ODUK2021].

În această invenție se proiectează un HMM, reprezentat de:

- un proces Markov  $X$ , cu timp discret, omogen și de ordin 1. Stările asociate acestui proces sunt în număr de  $N$  și sunt cunoscute în literatură ca « emitting states » sau « hidden states ».
- un proces observat  $Z$  care este, fie un proces Markov condiționat de ordin 1, fie o secvență de variabile aleatoare dependente condiționat de stările procesului  $X$ . Prin emisiile stărilor de tip « hidden » se generează o traiectorie a procesului  $Z$ , respectiv seria temporală  $S$ ;
- un set de distribuții probabilistice, toate continue și univariate, asociate emisiilor generate  $D = \{D_1, D_2, \dots, D_N\}$ , unde  $D_i$  este distribuția probabilistă a emisiei generate de starea «hidden», pentru  $\forall i \in \{1, 2, \dots, N\}$ ;
- o matrice stohastică  $A = (a_{ij})_{1 \leq i \leq N, 1 \leq j \leq N}$ , unde  $a_{ij}$  reprezintă probabilitatea de tranziție din starea «i» într-o stare «j» a procesului  $X$ , într-un pas de timp, cu  $\sum_{j=1}^N a_{ij} = 1$ , pentru  $\forall i \in \{1, 2, \dots, N\}$ ;
- un vector al probabilităților inițiale de stare:  $\pi = \pi_1, \pi_2, \dots, \pi_N$ , unde  $\pi_i$  reprezintă probabilitatea ca starea modelului, la momentul de timp  $t=0$ , să fie  $i \in \{1, 2, \dots, N\}$ , cu  $\sum_{i=1}^N \pi_i = 1$ .

Două direcții fundamentale sunt de interes:

- antrenarea unui HMM( $A, D, \pi$ ): fiind date șirurile de observații din seria temporală  $S$ , prelucrate statistic, prin discretizarea timpului și analizate multivariat, se dorește obținerea printr-un algoritm cunoscut, de tip Viterbi, a celor mai bune estimări pentru elementele matricei  $A$  a HMM, ca și pentru parametrii distribuțiilor din  $D = \{D_1, D_2, \dots, D_N\}$ ;
- decodarea: fiind dat un nou șir de observații din seria temporală, se dorește prin intermediul unui algoritm cunoscut de tip Viterbi Posterior Decoding, aplicat pentru HMM( $A, D, \pi$ ), obținerea celei mai probabile secvențe  $X$  de stări «hidden» care au emis acel șir.

**Problema** pe care o rezolvă invenția este realizarea și utilizarea unei arhitecturi de tip HM pentru determinarea în timp real a incertitudinii și variabilității datelor unei serii temporale, bazată pe procese stohastice de tip HM omogene, de ordin 1, cu emisii de tip discret și multivariat.

Arhitectura prezintă următoarele caracteristici specifice ce îi pot conferi aplicabilitate industrială:

- punerea la dispoziția operatorilor, dispecerilor sau managerilor de risc a celor două statistici descriptive ce conduc la ameliorarea predictibilității, identificarea de regimuri caracteristice de operare și creșterea siguranței în funcționare;
- după un proces de antrenare / învățare a HMM, arhitectura propune cele mai probabile mecanisme care sunt «ascunse» în datele seriei temporale;
- ameliorarea predictibilității variabilității și incertitudinii producției de energie electrică din surse regenerabile, care au caracter intermitent;
- ameliorarea predictibilității variabilității și incertitudinii consumului casnic de gaze naturale;
- se poate implementa eficient fie printr-un modul software pentru un calculator personal (PC), fie ca un dispozitiv autonom (hardware specializat și software).

În acord cu invenția, se generează noi serii temporale de mărginire inferioară, respectiv superioară a datelor din  $S$ , printr-un calcul cunoscut de borne de tip minim, respectiv de maxim, bazat pe medieri de tip MA și pe abateri standard de tip MSD, pentru un interval de timp glisant de lățime constantă și calculată ca un multiplu al pasului de timp al seriei temporale  $S$ . Bornele de tip minim sunt MA-MSD, MA-2\*MSD, respectiv MA-3\*MSD. Bornele de tip maxim sunt MA+MSD, MA+2\*MSD, respectiv MA+3\*MSD.

Pentru un interval de timp de referință (uzual de tip o oră, o zi, o săptămână, o lună, etc.), **perechile** de date temporale  $\{MA-MSD, MA+MSD\}$  reprezintă un șir multivariat de observații discrete, fiind

partiționate ca serii (orare, zilnice, săptămânale, lunare, etc.) și vor fi utilizate pentru antrenarea unui proces stohastic  $\Pi_1$  de tip HM. Similar, pentru același interval de timp de referință, **perechile** de date temporale  $\{MA-2*MSD, MA+2*MSD\}$  reprezintă un șir multivariat de observații discrete, fiind partiționate ca serii (orare, zilnice, săptămânale, lunare, etc.) și vor fi utilizate pentru antrenarea unui proces stohastic  $\Pi_2$  de tip HM, în timp ce **perechile** de datele temporale  $\{MA-3*MSD, MA+3*MSD\}$  reprezintă un șir multivariat de observații discrete, de asemenea, partiționate și vor fi utilizate pentru antrenarea unui proces stohastic  $\Pi_3$  de tip HM, ambele procese stohastice  $\Pi_2, \Pi_3$  având același număr  $N$  propus de mecanisme ascunse / stări de tip hidden. În mod uzual, 80% din datele seriei  $S$  pot fi utilizate pentru antrenare, respectiv 20% pot fi utilizate pentru testarea acurateții statistice a antrenării.

Pe baza unei proceduri cunoscute de tip ML de decodare atribuită procesului stohastic  $\Pi_1$ , se pot transforma date  $\{MA-MSD, MA+MSD\}$  asociate tipurilor de date ale seriei  $S$ , într-un șir de valori pozitive  $s_1, s_2, \dots$ , unde  $s_i \in \{1, 2, \dots, N\}$ . Similar, pe baza aceleași proceduri de decodare atribuită procesului stohastic  $\Pi_2$ , se pot transforma date  $\{MA-2*MSD, MA+2*MSD\}$  asociate tipurilor de date ale seriei  $S$ , într-un șir de valori pozitive  $t_1, t_2, \dots$ , unde  $t_i \in \{1, 2, \dots, N\}$ , iar pe baza unei proceduri de decodare asociată procesului stohastic  $\Pi_3$ , se transformă, de asemenea, date de tipul  $\{MA-3*MSD, MA+3*MSD\}$  într-un șir de valori pozitive  $u_1, u_2, \dots$ , unde  $u_i \in \{1, 2, \dots, N\}$ .

Nivelele cele mai probabile de incertitudine, respectiv variabilitate ale datelor din seria temporală  $S$  rezultă din calculul și compararea distanțelor Manhattan între șirul  $s_1, s_2, \dots$  și șirul  $t_1, t_2, \dots$ , respectiv între șirul  $s_1, s_2, \dots$  și șirul  $u_1, u_2, \dots$ , după cum este ilustrat în figurile 14 și 15.

Se dă, în continuare, un exemplu de aplicare a procedurii pentru determinarea variabilității și incertitudinii datelor, pentru o serie temporală constituită din curbe de sarcină zilnice, monitorizate la nivelul datelor de consum minut-cu-minut de putere activă electrică în SEN. Un exemplu de astfel de sarcină zilnică este reprezentată în fig. 1. În vederea aplicării metodei, se construiesc seriile temporale de mărginire, care sunt reprezentate grafic în figurile 2,3,4,5,6,7,8 și 9, în timp ce o reprezentare grafică a celor două concepte de variabilitate și incertitudine este ilustrată în figura 10. Pentru proiectarea HMM, se propune, în acest exemplu, un număr  $N=6$  de stări de tip «hidden», în fapt șase mecanisme care sunt apriori ascunse operatorilor de transport, respectiv comercial ai Rețelei Electrice de Transport al Energiei Electrice, fiind asociate diverselor strategii ale consumatorilor de putere din SEN, pe nivele de putere, respectiv pe paliere orare, în vederea eficientizării activităților lor. Toate cele șase distribuții din  $D = \{D_1, D_2, \dots, D_6\}$  din acest exemplu sunt independente statistic, oricare dintre ele fiind propuse spre analiză ca fiind produse de două distribuții normale (Gauss), în total 12 distribuții marginale Gauss sunt considerate:  $D_1 = \text{ProductDistribution}(N(\mu_1, \sigma_1), N(\mu_2, \sigma_2)), \dots, D_6 = \text{ProductDistribution}(N(\mu_{11}, \sigma_{11}), N(\mu_{12}, \sigma_{12}))$ .

Cele mai bune estimări statistice pentru cele douăzeci și patru de valori ale parametrilor  $\mu_1, \sigma_1, \mu_2, \sigma_2, \dots, \mu_{11}, \sigma_{11}, \mu_{12}, \sigma_{12}$  pot fi obținute după antrenările celor trei HMM, fiind propuse un număr de 181 de curbe de sarcină zilnice din perioada ianuarie-iunie, monitorizate la nivelul datelor de consum minut-cu-minut de putere activă electrică în SEN. Un exemplu de decodare a observațiilor prin intermediul HMM cu timp discret, omogen, de ordin 1, este reprezentat în fig. 13, cu referire la fig. 15. După decodările unui set de volum  $n$ , multivariat de date de tip  $S$ , se evidențiază în fig. 14 două distanțe de tip Manhattan pentru determinarea celui mai probabil nivel de incertitudine  $U$ , respectiv pentru determinarea celui mai probabil nivel de variabilitate  $V$ :

$$U = 100/n \cdot \sum_{i=1}^n \frac{|t_i - u_i|}{|t_i - s_i| + |t_i - u_i| + |s_i - u_i|} \quad (\%)$$

$$V = 100/n \cdot \sum_{i=1}^n \frac{|t_i - s_i|}{|t_i - s_i| + |t_i - u_i| + |s_i - u_i|} \quad (\%)$$

pentru orice pas  $i=1,2,\dots,n$  pentru care  $|t_i - s_i| + |t_i - u_i| + |s_i - u_i| > 0$ ; altfel  $U_i = 0$ ;  $V_i = 0$ .

Invenția este susceptibilă de aplicare industrială deoarece facilitează prin cunoașterea nivelelor de variabilitate și incertitudine a diverselor serii temporale asociate proceselor și tehnologiilor industriale o gestiune mai eficientă de exploatare a resurselor și de management al rezervelor și stocurilor. Pentru cazul SEN, integrarea resurselor regenerabile de energie (eoliană, fotovoltaică, hidroelectrică, biocombustibili) în piața de energie introduce mai multă incertitudine și dezechilibre între cererea de consum și disponibilitatea resurselor clasice (nuclear, combustibili fosili) și regenerabile. Aplicarea invenției în SEN va conduce la economii substanțiale la nivelul pieței de echilibrare (PE), a celei a Zilei Următoare (PZU) și a celei de servicii de sistem (PSS).

### Referințe

- BRC2021 Xu, Bing and Fu, Rong and Lau, Chi Keung Marco, Energy market uncertainty and the impact on the crude oil prices, Journal of Environmental Management, vol. 298, 113403, <https://doi.org/10.1016/j.jenvman.2021.113403>
- CGM2019 Chang-Gi Min, Analyzing the Impact of Variability and Uncertainty on Power System Flexibility, Appl. Sci. 2019, 9(3), 561; <https://doi.org/10.3390/app9030561>
- EDIH2013 E. Ela, V. Diakov, E. Ibanez, and M. Heaney, Impacts of variability and uncertainty in solar photovoltaic generation at multiple timescales, Contract vol. 303, p. 2753000, 2013 [Online]. Available: <http://www.nrel.gov/docs/fy13osti/58274.pdf>
- LMZ2012 R. Langrock, I. L. MacDonald, and W. Zucchini, Some nonstandard stochastic volatility models and their estimation using structured hidden Markov models, J. Empiric. Finance vol. 19, no. 1, pp. 147–161, Jan. 2012 [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0927539811000661>
- ODUK2021 Ozgur Danisman, Umay Uzunoglu Kocer, Hidden Markov models with binary dependence, Physica A: Statistical Mechanics and its Applications, Vol 567, 1 April 2021, 125668, <https://doi.org/10.1016/j.physa.2020.125668>
- US7203635B2 N. Oliver et al., Layered models for context awareness, U.S. Patent US7203635B2, Apr. 10, 2007.
- US9507367B2 G. K. Venayagamoorthy et al., Method and system for dynamic stochastic optimal electric power flow control, U.S. Patent US9507367B2, Nov. 29, 2016.
- US9569804B2 A. R. Stein et al., Systems and methods for energy consumption and energy demand management, U.S. Patent US9569804B2, Feb. 14, 2017.

### Revendicări

1. Arhitectură pentru determinarea în timp real a incertitudinii și variabilității datelor unei serii temporale  $S$ , **caracterizată prin aceea că** permite *cunoașterea* celui mai probabil nivel de variabilitate, respectiv a celui mai probabil nivel de incertitudine, asociate unui set de date  $S$ , continuu observate în timp (serie temporală).
2. Arhitectură, conform cu revendicarea 1, **caracterizată prin aceea că** folosește procese de tip Hidden Markov, omogene și de ordin 1, cu emisii de tip discret și multivariat, pentru *cunoașterea* prin decodare a stărilor asociate seriilor temporale de mărginire inferioară și superioară a datelor  $S$ .
3. Arhitectură, conform cu revendicările 1 și 2, **caracterizată prin aceea că** prin *cunoașterea* distanțelor Manhattan între stările decodate în raport cu un nivel de referință ales, se pot stabili cel mai probabil nivel de variabilitate și, respectiv, cel mai probabil nivel de incertitudine, asociate setului de date observate.



42




Fig.1 Seria temporală S a datelor de consum minut-cu-minut de putere activă electrică din SEN, într-o zi (24 de ore)




Fig.2 Seria temporală a datelor de consum minut-cu-minut de putere activă electrică din SEN și filtrarea acestora prin MA, pentru interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA rezultante pentru prima oră din ziua considerată în fig.1. Pentru un minut « i », media asociată de tip MA este  $ma_i = 1/30 \cdot \sum_{k=i}^{i+29} c_k$




Fig.3 Seria temporală a datelor de consum minut-cu-minut de putere activă electrică din SEN și filtrarea acestora prin MA, pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA rezultante în ziua considerată




Fig.4 Seriile temporale MA și MA-MSD, pentru filtrarea seriei S cu o funcție de tip Moving Standard Deviation (MSD), pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-MSD rezultante pentru ora considerată în fig.2

45




Fig.5 Seriiile temporale MA, MA-MSD și MA+MSD, pentru filtrarea seriei S cu o funcție de tip Moving Standard Deviation (MSD), pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-MSD și MA+MSD rezultante pentru ora considerată în fig.2




Fig.6 Seriiile temporale MA, MA-2\*MSD și MA+2\*MSD, pentru filtrarea seriei S cu o funcție de tip Moving Standard Deviation (MSD), pentru un interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-2\*MSD și MA+2\*MSD rezultante pentru ora considerată în fig.2




Fig.7 Seriile temporale MA, MA-3\*MSD și MA+3\*MSD, pentru filtrarea seriei S cu o funcție de tip MSD, pentru interval de timp glisant de lățime 30 minute, cu indicarea seriei temporale de tip MA, respectiv MA-3\*MSD și MA+3\*MSD rezultante pentru ora considerată în fig.2




Fig.8 Seriile temporale MA-3\*MSD, MA, respectiv MA+3\*MSD pentru datele de consum minut-cu-minut de putere activă electrică din SEN, pentru ziua considerată în fig.1




Fig.9 Seriile temporale S, MA, MA-3\*MSD, respectiv MA+3\*MSD pentru datele de consum minut-cu-minut de putere activă electrică din SEN, prin filtrarea seriei S cu o funcție de tip MSD, pentru un interval de timp glisant de lățime **30 minute** pentru ziua considerată în fig.1




Fig. 10 Evidențierea variabilității pentru consumul în banda/intervalul (MA-MSD,MA-2\*MSD), respectiv în banda (MA+MSD, MA+2\*MSD) și a incertitudinii pentru consumul in banda/intervalul (MA-2\*MSD, MA-3\*MSD), respectiv în banda (MA+2\*MSD, MA+3\*MSD) - pentru datele de consum minut-cu-minut de putere activă electrică din SEN, cu filtrarea seriei S cu o funcție de tip MSD, pentru interval de timp glisant de lățime **30 minute** pentru ziua considerată în fig.1




Fig.11 Un exemplu de traiectorii ale unui HMM cu timp discret, omogen, de ordin 1




Fig. 12 Un exemplu de partiționare la 24 de ore a observațiilor din seria temporală S, în vederea antrenării HMM




Fig.13 Un exemplu de decodare a observațiilor prin intermediul unui HMM cu timp discret, omogen, de ordin 1




Fig.14 Nivelele de variabilitate (V) și de incertitudine (U) obținute prin decodarea observațiilor multivariate Z

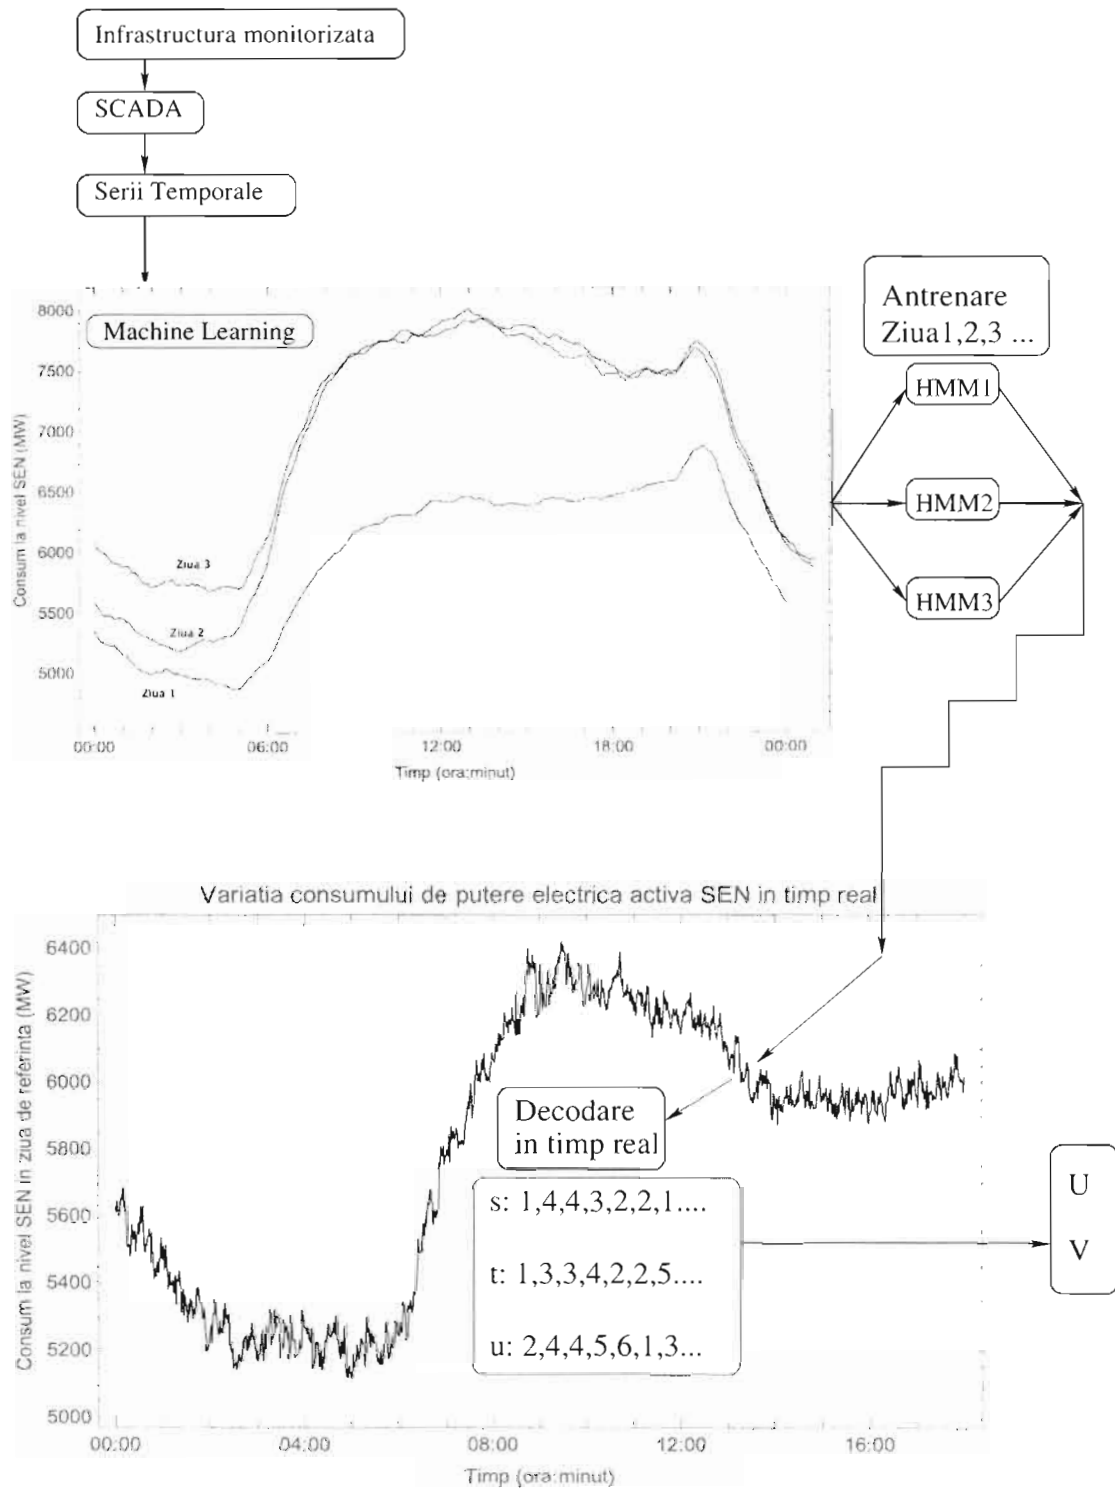


Fig.15 Arhitectura de tip ML bazată pe procese de tip Hidden Markov pentru a determina în timp real cele mai probabile nivele de incertitudine și de variabilitate a datelor unei serii temporale






Fig.16 Exemplu de evoluție a celor mai probabile nivele medii orare de incertitudine (U) ale datelor din seria temporală din figura 19




Fig.17 Exemplu de evoluție a celor mai probabile nivele medii orare de variabilitate (V) ale datelor din seria temporală din figura 19




Fig.18 Corelarea evoluțiilor prezentate în figurile 16 și 17




Fig.19 Seria temporală pentru reprezentările grafice din figurile 16, 17 și 18