

Cadru conceptual pentru predicția consumului de energie bazat pe Inteligența Artificială în clădiri

Eleonora TUDORA^{1,2*}, Eugenia TÎRZIU¹, Ana-Mihaela VASILEVSCHI¹

¹ Institutul Național de Cercetare-Dezvoltare în Informatică – ICI București

² Școala Doctorală de Inginerie Energetică, POLITEHNICA București

eleonora.tudora@ici.ro (*Corresponding author), eugenia.tirziu@ici.ro, ana.vasilevschi@ici.ro

Rezumat: Predicția consumului de energie în clădiri reprezintă un element esențial pentru creșterea eficienței energetice și atingerea obiectivelor de sustenabilitate. Această lucrare propune un cadru conceptual bazat pe un model conceptual formalizat, care descrie variabilele relevante și relațiile dintre acestea în contextul sistemelor de predicție bazate pe inteligența artificială. Modelul integrează variabile de intrare precum date istorice de consum, date meteorologice, caracteristici ale clădirii și date operaționale, alături de variabile de proces precum calitatea datelor, complexitatea modelului AI, arhitectura sistemului, latența și securitatea datelor. Acestea influențează rezultatele sistemului, exprimate prin acuratețea predicției, eficiența operațională și nivelul de încredere al utilizatorilor. Cadru propus evidențiază relațiile dintre aceste variabile, subliniind faptul că performanța sistemului depinde de interacțiunea dintre date, modele și infrastructură. Sunt formulate ipoteze de cercetare care permit evaluarea impactului integrării datelor eterogene, al calității datelor, al complexității modelelor AI și al arhitecturilor hibride asupra performanței sistemului. De asemenea, este evidențiat rolul mecanismelor blockchain în creșterea încrederii prin asigurarea integrității datelor. Spre deosebire de studiile existente, care se concentrează pe performanța algoritmilor sau pe descrierea arhitecturilor tehnologice, această lucrare propune o abordare conceptuală integrată, oferind o bază teoretică pentru proiectarea și evaluarea sistemelor inteligente de management energetic. Modelul poate fi utilizat pentru validări experimentale ulterioare în contexte reale de implementare.

Cuvinte cheie: predicția consumului de energie, Inteligența Artificială, model conceptual, IoT, blockchain.

Conceptual framework for Artificial Intelligence-based energy consumption prediction in buildings

Abstract: Energy consumption prediction in buildings is an essential element for increasing energy efficiency and achieving sustainability objectives. This paper proposes a conceptual framework based on a formalized conceptual model that describes the relevant variables and the relationships between them in the context of artificial intelligence-based prediction systems. The model integrates input variables such as historical consumption data, meteorological data, building characteristics, and operational data, together with process-related variables including data quality, AI model complexity, system architecture, latency, and data security. These influence system results, expressed through prediction accuracy, operational efficiency, and user trust. The proposed framework highlights the relationships among these variables, emphasizing that system performance depends on the interaction between data, models, and infrastructure. Research hypotheses are formulated to evaluate the impact of heterogeneous data integration, data quality, AI model complexity, and hybrid architectures on system performance. In addition, the role of blockchain mechanisms in increasing trust through ensuring data integrity is highlighted. Unlike existing studies that focus on algorithm performance or technological architectures, this work proposes an integrated conceptual approach, providing a theoretical basis for the design and evaluation of intelligent energy management systems. The model can be used for further experimental validations in real implementation contexts.

Keywords: Energy consumption prediction, Artificial Intelligence, Conceptual model, IoT, Blockchain.

1. Introducere

Predicția consumului de energie este importantă în optimizarea utilizării energiei, reducerea costurilor și asigurarea sustenabilității clădirilor moderne. Îmbunătățirea preciziei și a eficienței predicției energetice a devenit o prioritate pentru cercetători, factori de decizie și profesioniști din industrie, odată cu creșterea continuă a cererii globale de energie. Complexitatea și imprevizibilitatea modelelor de consum de energie reprezintă adesea o provocare pentru tehnicile tradiționale de predicție, care se bazează pe modele statistice și fizice (Fan et al., 2024).

Cadrul conceptual privind modelele consumului de energie a suferit o transformare semnificativă datorită apariției inteligenței artificiale (AI) și a metodologiilor centrate pe date, care oferă soluții mai precise și adaptive (Wei et al., 2018). Tehnologii precum învățarea automată (ML), învățarea profundă (DL) și modelele hibride demonstrează performanțe superioare prin valorificarea unor seturi extinse de date, identificarea unor modele complexe și generarea unor predicții din ce în ce mai precise în timp. Tehnologii digitale complementare precum Internetul Lucrurilor (IoT), tehnologia Blockchain, cloud computing-ul și analiza Big Data pot fi integrate pentru a îmbunătăți capacitățile predictive și a stimula luarea deciziilor în timp real (Andoni et al., 2019). În ciuda acestor progrese, stabilirea unor modele robuste bazate pe AI pentru consumul de energie continuă să se confrunte cu o multitudine de provocări legate de eficiența computațională, scalabilitate, precum și de interpretabilitatea modelului și de disponibilitatea și calitatea datelor. În plus, selectarea algoritmilor de AI adecvați și optimizarea acestora pentru tipuri specifice de clădiri și condiții climatice sunt importante pentru obținerea unei precizii ridicate.

Această lucrare extinde cercetările anterioare (Tudora & Tîrziu, 2024) prin trecerea de la o abordare descriptivă la una conceptuală. În timp ce studiul anterior analizează tehnologiile și metodele utilizate în predicția consumului de energie, lucrarea propune un cadru conceptual în care este definit un model conceptual formalizat, bazat pe identificarea variabilelor relevante și a relațiilor dintre acestea. În literatura de specialitate, majoritatea studiilor abordează predicția consumului de energie fie din perspectivă algoritmică, concentrându-se pe performanța modelelor de AI, fie din perspectivă arhitecturală, analizând integrarea tehnologiilor precum IoT, cloud computing sau blockchain. Totuși, aceste abordări tratează adesea componentele sistemului în mod izolat și nu definesc explicit relațiile dintre variabilele care determină consumul energetic.

Contribuția principală a lucrării constă în structurarea conceptuală a problemei de predicție, prin definirea unui model care include variabile de intrare, de proces și de ieșire și evidențiază interdependențele dintre date, modele și infrastructura sistemului. Modelul subliniază rolul calității datelor, al complexității modelelor AI, al arhitecturii și al mecanismelor de securitate asupra performanței sistemului. În acest context, sunt formulate ipoteze de cercetare care permit investigarea acestor relații și fundamentarea unor studii empirice ulterioare. Inteligența artificială, IoT, cloud computing și blockchain sunt analizate ca elemente suport ale acestui model, care facilitează colectarea, procesarea și utilizarea datelor, fără a constitui în sine contribuții experimentale. Integrarea cadrului conceptual propus este realizată în contextul proiectului PRECONERG, aflat în curs de dezvoltare, care oferă un cadru de aplicare pentru implementarea și validarea ulterioară a modelului. Astfel, lucrarea oferă o bază teoretică pentru dezvoltarea și validarea ulterioară a sistemelor de predicție a consumului de energie în clădiri.

Structura acestei lucrări este următoarea. Secțiunea 2 prezintă stadiul actual al cercetărilor în domeniul predicției consumului de energie în clădiri și principalele tehnologii utilizate în acest domeniu. Cerințele unui sistem de predicție eficient sunt descrise în Secțiunea 3, concentrându-se pe tipurile de date și caracteristicile modelului. Cadrul conceptual propus este prezentat în Secțiunea 4, împreună cu principalele sale componente și relațiile dintre variabilele sistemului. Principalele provocări, limitări și direcțiile viitoare sunt discutate în Secțiunea 5, iar Secțiunea 6 prezintă concluziile lucrării.

2. Stadiu actual

Predicțiile privind consumul de energie al clădirilor prezintă un interes tot mai mare datorită importanței lor în promovarea sustenabilității mediului, creșterea eficienței energetice și implementarea managementului inteligent al clădirilor. Modele de predicție sunt mai precise și adaptive, depășind metodele statistice și fizice convenționale, datorită progreselor în domeniul AI.

Metodele de învățare automată și cele hibride care utilizează date multivariate pentru a îmbunătăți acuratețea predicției au făcut obiectul a numeroase studii. Analizând tehnicile de predicție pentru clădirile inteligente, Mathumitha et al. (2024) au identificat probleme precum fluctuația încărcării și comportamentul ocupanților. Luo (2022) a evidențiat utilizarea rețelelor de detectare bazate pe IoT pentru a susține strategiile de optimizare bazate pe date și rolul algoritmilor

ML în managementul energiei. Rețelele neuronale, logica fuzzy și algoritmi genetici sunt frecvent utilizate pentru predicția consumului de energie și pentru optimizarea eficienței operaționale. În special, modelele de deep learning, precum LSTM, sunt eficiente în modelarea dependențelor temporale din datele energetice și oferă rezultate superioare față de alte abordări tradiționale (Sivasankari & Rathika, 2024). De asemenea, modelele hibride contribuie la gestionarea datelor zgomotoase și la îmbunătățirea acurateții predicțiilor.

Analiza autonomă a datelor a devenit din ce în ce mai populară în studii pentru a facilita optimizarea energiei și controlul în timp real (Aguilar et al., 2021). Pentru a realiza o prognoză energetică robustă, este acum considerat esențial să se integreze elemente contextuale precum tipologia clădirilor, dinamica ocupării și condițiile meteorologice (Ahmad et al., 2018; Amasyali & El-Gohary, 2018). Chiar dacă integrarea IoT este esențială pentru achiziția de date în timp real, structuri mai complexe, cum ar fi arhitectura edge-computing propusă de Mohammadi et al. (2018) sunt necesare pentru optimizarea timpilor de răspuns și reducerea latenței. În afară de conectivitate, tehnologia blockchain este și ea importantă pentru a asigura transparența deciziilor și partajarea securizată a datelor (Reyna et al., 2018).

Analiza literaturii evidențiază existența a două direcții principale de cercetare în predicția consumului de energie în clădiri. Prima este orientată spre dezvoltarea și optimizarea algoritmilor de AI, cu accent pe creșterea acurateții predicțiilor și modelarea relațiilor complexe din date (Alexandru et al., 2023; Sivasankari & Rathika, 2024). Cea de-a doua direcție vizează integrarea tehnologiilor digitale, precum IoT, cloud computing și blockchain, în arhitecturi pentru clădiri inteligente (Andoni et al., 2019; Kumar et al., 2020). Cu toate acestea, majoritatea lucrărilor tratează aceste componente fie la nivel algoritmic, fie din perspectivă arhitecturală, fără a defini explicit relațiile dintre variabilele care determină consumul de energie (Ahmad et al., 2018; Amasyali & El-Gohary, 2018). În plus, studiile existente se concentrează preponderent pe performanța modelelor predictive sau pe integrarea tehnologică, fără a propune un model conceptual formalizat care să descrie interdependențele dintre factorii relevanți. În acest context, lucrarea propune o abordare conceptuală integrată, bazată pe definirea relațiilor dintre variabilele care determină consumul energetic.

3. Cerințele unui sistem de predicție

3.1. Tipuri de date

Pentru a dezvolta un model de predicție a consumului de energie, trebuie colectate și integrate mai multe seturi de date. Fiecare oferă informații utile care îmbunătățesc performanța și fiabilitatea modelului. Aceste seturi de date sunt grupate în patru categorii: date despre consumul de energie, date meteorologice, date privind caracteristicile clădirilor și date operaționale. Fiecare dintre aceste categorii are un impact semnificativ asupra performanței modelului.

Datele despre consumul de energie, istorice sau în timp real, reprezintă baza oricărui sistem de predicție, evidențiind tipare de utilizare și variații sezoniere (Alduailij et al., 2021; Kawa et al., 2024). Datele de înaltă rezoluție permit identificarea vârfurilor de consum, detectarea anomaliilor și estimarea cererii energetice, contribuind la o analiză mai precisă a comportamentului rețelei și a fluctuațiilor sezoniere (Du, 2024; Suriya et al., 2025).

Datele meteorologice, precum temperatura, umiditatea, radiația solară și viteza vântului, influențează semnificativ consumul de energie, în special prin impactul asupra sistemelor HVAC (Amin et al., 2024). Integrarea acestor date, inclusiv a prognozelor, contribuie la creșterea preciziei predicțiilor și la adaptarea dinamică a consumului energetic, permițând ajustarea setărilor de control în funcție de condițiile exterioare și facilitând strategii de optimizare precum prăcirea sau preîncălzirea clădirilor pentru reducerea consumului în perioadele de vârf (Khorsheed & Danook, 2022).

Caracteristicile clădirii, cum ar fi dimensiunea, nivelul de izolare, tipul ferestrelor și specificațiile sistemelor HVAC, determină modul în care energia este consumată și permit

adaptarea modelelor la specificul fiecărei clădiri, contribuind astfel la creșterea preciziei predicțiilor și la identificarea eficientă a posibilelor ineficiențe sau oportunități de optimizare (Nadeem et al., 2021; Latha et al., 2023; Anarene, 2024).

Datele operaționale reflectă comportamentul utilizatorilor și modul de funcționare al sistemelor, incluzând programele de ocupare, utilizarea echipamentelor și setările sistemelor (Azhar et al., 2023). Acestea sunt esențiale pentru captarea variațiilor zilnice ale consumului și pentru modelarea energetică bazată pe comportament, permițând optimizarea funcționării sistemelor precum iluminatul și HVAC (Heer et al., 2024) și ajustări automate în timp real pentru îmbunătățirea eficienței energetice.

Integrarea acestor categorii de date permite dezvoltarea unor modele predictive mai precise și adaptabile, constituind baza modelului conceptual propus.

3.2. Caracteristicile modelului de predicție

Un sistem capabil să prezică consumul de energie trebuie să ia în considerare următoarele caracteristici din punct de vedere al eficienței operaționale și al aplicării practice:

- Atât supra-, cât și sub-dimensionarea energiei sunt consecințe costisitoare și ineficiente, modelul trebuie să genereze predicții precise, cu erori minime, pentru a facilita procesul decizional (Ramesh et al., 2023).
- Modelele hibride ajută la învățarea în timp real și la ajustarea optimă a parametrilor. Sistemul propus trebuie să fie adaptabil, ceea ce înseamnă că trebuie să se adapteze la schimbările condițiilor de mediu în și la modul în care sunt utilizate clădirile (Olawumi & Oladapo, 2025).
- Sistemul trebuie să fie scalabil, ceea ce înseamnă că poate gestiona complexitatea diferitelor infrastructuri ale clădirilor și a volumelor de date în creștere (Goel, 2024), fără a scădea semnificativ a eficiența operațională sau acuratețea predicțiilor.
- Chiar și atunci când calitatea datelor este slabă sau condițiile de mediu se abat de la așteptări, sistemul trebuie să își mențină integritatea operațională (Yin et al., 2024).
- Sistemul trebuie să genereze rezultate clare și ușor de înțeles, astfel încât utilizatorii să poată avea încredere în predicțiile modelului și să acționeze pe baza acestora (Olawumi & Oladapo, 2025).
- caracteristică esențială este capacitatea de a analiza datele și de a face predicții imediate, care permit sistemului să reacționeze rapid și să utilizeze energia mai eficient (Skaloumpakas et al., 2023).

Atunci când aspectele menționate mai sus sunt îndeplinite, un model de AI pentru predicția consumului de energie devine un instrument util pentru economisirea energiei și creșterea sustenabilității clădirilor moderne. În afară de performanța tehnică, un astfel de sistem ajută la atingerea obiectivelor de mediu pe termen lung. În acest context, caracteristicile prezentate definesc cerințele funcționale ale modelului conceptual propus, influențând modul în care relațiile dintre variabile sunt structurate și approximate.

4. Componentele cadrului conceptual

În cadrul acestei lucrări, cadrul conceptual reprezintă ansamblul elementelor teoretice și tehnologice relevante pentru dezvoltarea unui sistem de predicție bazat pe AI, incluzând arhitectura sistemului, mecanismele de colectare a datelor, modelele de AI și mecanismele de securitate și integritate a datelor. Abordarea propusă integrează tehnologii precum AI, IoT, cloud computing și blockchain într-o structură unitară, orientată spre modelarea consumului de energie. Aceste componente definesc contextul funcțional în care sunt generate, prelucrate și utilizate datele necesare procesului de predicție. Pe baza acestui cadru este construit un model conceptual

formalizat, care descrie explicit variabilele relevante, relațiile dintre acestea și ipotezele de cercetare asociate. Astfel, cadrul conceptual oferă fundamentul teoretic și tehnologic al sistemului, în timp ce modelul conceptual formalizat reprezintă o abstractizare a acestuia, utilizată pentru analiza relațiilor dintre factorii care influențează performanța procesului de predicție.

În continuare, sunt descrise principalele componente ale cadrului conceptual, incluzând tipurile de arhitecturi utilizate, rolul tehnologiilor IoT în colectarea datelor, modelele de AI pentru predicție și mecanismele de asigurare a securității și integrității datelor.

4.1. Tipuri de arhitecturi

Procesarea datelor poate avea loc la nivel de edge (descentralizat), în cloud (centralizat) sau printr-o abordare hibridă care le combină pe ambele. Într-o *arhitectură centralizată* (cloud computing), toate datele provenite de la senzori, contoare inteligente sau dispozitive IoT sunt transmise pentru procesare către un server la distanță. O arhitectură cloud centralizată îmbunătățește scalabilitatea și capacitatea de a antrena modele complexe pe seturi extinse de date istorice (Andriulo et al., 2024; Cherukuri, 2024). Cu toate acestea, dependența completă de infrastructura cloud provoacă latențe mari, necesită conectivitate constantă la internet și introduce probleme legate de confidențialitatea datelor. *Arhitecturile descentralizate* (edge computing) procesează datele local, pe dispozitive IoT, gateway-uri sau servere aflate la fața locului. Această metodă permite control cu latență redusă, un nivel sporit de confidențialitate și o reziliență mai mare în cazul întreruperilor de rețea, în ciuda provocărilor legate de mentenanța distribuită și de capacitatea de procesare redusă (Andriulo et al., 2024; Cherukuri, 2024). *Arhitectura hibridă* combină edge computing și cloud computing pentru a valorifica atât controlul local cu latență redusă, cât și puterea ridicată de calcul a cloud-ului (Bhoyar & Selvarajan, 2023; Andriulo et al., 2024). Modelele sunt antrenate în cloud și apoi implementate pentru inferență la nivel edge. Doar datele importante sau agregate sunt retransmise către cloud. Managementul inteligent al clădirilor, care folosește analize în cloud pentru a îmbunătăți strategiile pe termen lung și pentru a permite dispozitivelor locale să ia decizii operaționale instantanee, este un exemplu de aplicație care folosește această metodă. În plus, trebuie menționat că asigurarea actualizărilor constante ale modelelor pe mai multe dispozitive și creșterea complexității sistemului rămân probleme reale (Siripuram, 2024).

Analiza diferitelor tipuri de arhitecturi evidențiază rolul infrastructurii de procesare în performanța sistemului de predicție. Alegerea unei arhitecturi centralizate, descentralizate sau hibride influențează modul de procesare a datelor, timpul de răspuns al sistemului și eficiența operațională, aspecte care sunt ulterior integrate în modelul conceptual propus.

4.2. Utilizarea IoT pentru colectarea datelor în timp real

Combinarea senzorilor de tip IoT cu algoritmi de AI permite sistemelor să anticipeze și să se adapteze în timp real, îmbunătățind astfel eficiența energetică și sustenabilitatea. Rețelele IoT utilizează mai multe tipuri de senzori pentru a monitoriza continuu consumul de energie, temperatura, umiditatea și gradul de ocupare. Datele colectate de senzori sunt pre-procesate și transmise către modelele AI pentru realizarea predicțiilor și ajustărilor dinamice în timp real (Chaudhari et al., 2024). Aceste date sunt stocate în baze de date de tip serie temporală și sunt transmise prin protocoale IoT cu latență redusă (Poyyamozy et al., 2024). Modelele AI permit identificarea anomaliilor, anticiparea necesităților de mentenanță și modelarea comportamentului ocupanților, contribuind la optimizarea consumului energetic (Hachache et al., 2024).

Prin asigurarea colectării continue a informațiilor privind consumul energetic, condițiile de mediu și funcționarea clădirii, tehnologiile IoT constituie baza informațională necesară procesului de predicție. Aceste categorii de date reprezintă elemente esențiale ale modelului conceptual prezentat ulterior.

4.3. Modele de AI folosite pentru predicția consumului de energie

Modelele de AI sunt utilizate pentru a aproxima relația dintre variabilele care influențează consumul de energie, în funcție de caracteristicile datelor și de contextul de implementare. În această lucrare sunt considerate trei categorii principale de modele.

a) Rețele neuronale

Rețelele neuronale sunt adecvate pentru modelarea relațiilor neliniare complexe și a dependențelor temporale din datele de consum (Alexandru & Pupăză, 2020; Alexandru et al., 2023). Modelele de tip RNN și LSTM sunt utilizate în special pentru serii temporale, unde este necesară captarea dinamicii consumului în timp, în timp ce rețelele neuronale artificiale (ANN) sunt frecvent aplicate pentru scenarii mai statice de predicție. Aceste modele oferă acuratețe ridicată, dar implică costuri computaționale mari și o interpretabilitate redusă.

b) Arbori de decizie și Random Forests

Arborii de decizie oferă modele interpretabile, bazate pe reguli, fiind utili pentru identificarea relațiilor dintre variabilele de intrare și consumul energetic (Hachache et al., 2024). Random Forest îmbunătățește performanța prin agregarea mai multor arbori, reducând supraînvățarea și crescând robustețea, fiind frecvent utilizat pentru a obține predicții mai stabile și mai precise. Aceste modele sunt potrivite în special în scenarii unde interpretabilitatea și eficiența sunt prioritare, însă pot avea limitări în modelarea dependențelor temporale complexe comparativ cu modelele bazate pe rețele neuronale.

c) Tehnici de învățare de tip ensemble

Metodele de tip ensemble, precum Gradient Boosting și variantele sale (XGBoost, LightGBM), combină mai multe modele pentru a obține performanțe predictive superioare (Hachache et al., 2024). Acestea sunt eficiente în gestionarea datelor eterogene și zgomotoase, fiind potrivite pentru scenarii de predicție a consumului energetic în contexte operaționale complexe, însă implică o complexitate mai ridicată, timpi de antrenare mai mari și o interpretabilitate mai redusă comparativ cu modelele mai simple (Rotună et al., 2022).

d) Analiza comparativă a tipurilor de modele de AI

Analiza comparativă și avantajele metodelor de AI sunt prezentate în Tabelul 1.

Tabel 1. Analiză comparativă a metodelor AI

Metodă	Acuratețe	Interpretabilitate	Timp de antrenare	Avantaje
Rețele neuronale	Ridică	Scăzută	Ridicat	Potrivite pentru serii temporale și relații neliniare complexe
Arbori de decizie	Medie	Ridică	Scăzut	Interpretabilitate ridicată, implementare simplă
Random Forests	Ridică	Medie	Mediu	Robust la zgomot, reduce supraînvățarea
XGBoost / LightGBM	Foarte ridicată	Scăzută–medie	Mediu–ridicat	Performanță ridicată pe date eterogene și complexe

Notă: Evaluarea prezentată este de natură calitativă și sintetizează caracteristicile raportate în studiile analizate anterior. Acuratețea și performanța modelelor pot varia în funcție de setul de date utilizat, tipul de clădire și contextul de implementare.

Alegerea modelului depinde de contextul de utilizare: modelele mai simple și interpretabile sunt preferate în aplicații de tip edge, în timp ce modelele complexe pot fi utilizate în medii cloud pentru obținerea unei acurateți ridicate. În cadrul modelului conceptual propus, aceste metode sunt considerate mecanisme de aproximare a relației dintre variabilele sistemului.

Diversitatea metodelor de AI evidențiază compromisurile existente între acuratețe, interpretabilitate și costul computațional al procesului de predicție. Aceste caracteristici sunt

reflectate în modelul conceptual prin includerea dimensiunilor asociate procesării și performanței predictive.

4.4. Blockchain pentru securitate și transparența datelor

Blockchain este utilizat pentru a securiza procesul de predicție a consumului de energie electrică bazat pe AI, prin păstrarea integrității și trasabilității datelor și a rezultatelor predicțiilor.

Figura 1 prezintă o arhitectură securizată de predicție bazată pe AI, prin integrarea tehnologiei blockchain și a sistemelor IoT, care oferă integritatea datelor, trasabilitatea și încrederea pe parcursul întregului proces de predicție.




Figura 1. Arhitectura de predicție AI-IoT securizată (Source: authors own research)

Arhitectura este organizată pe mai multe etape, astfel:

Colectarea datelor IoT: senzorii colectează frecvent, date operaționale și de mediu în formă brută (de ex. consumul de energie, temperatura, umiditatea, gradul de ocupare)

Preprocesarea Edge: unitățile locale de preprocesare filtrează zgomotul, normalizează datele și extrag caracteristici pentru a reduce volumul și latența înainte de analiza AI.

Predicția modelelor de AI: Datele curățate sunt procesate folosind modele antrenate pentru a genera rezultate utile.

Integrarea tehnologiei Blockchain: Hash-uri de model, timestamp-uri și metrice de performanță sunt stocate într-un registru distribuit de contractele inteligente, astfel asigurându-se conformitatea și transparența.

Odată ce predicțiile sunt validate și înregistrate, blockchain-ul asigură autenticitatea procesului de luare a deciziilor. Înregistrările imuabile protejează integritatea datelor, jurnalele permit trasarea fiecărui pas într-un proces de predicție, contractele inteligente verifică consecvența modelului și securizează fluxurile de date, înregistrările verificate asigură responsabilitatea și stocarea descentralizată facilitează colaborarea securizată între diferite părți. Platformele rezistente și conforme, care pot funcționa în medii distribuite, cu mai mulți agenți, fără a compromite acuratețea sau confidențialitatea sunt create prin această integrare.

Din perspectiva cadrului conceptual, tehnologia blockchain contribuie la asigurarea integrității, trasabilității și securității informațiilor utilizate în procesul de predicție. Aceste aspecte influențează nivelul de încredere asociat rezultatelor generate de sistem și justifică includerea dimensiunii de securitate în modelul conceptual.

4.5. Model conceptual pentru predicția consumului de energie bazat pe AI

Analiza componentelor prezentate anterior evidențiază necesitatea unei reprezentări integrate a factorilor care influențează predicția consumului de energie în clădiri. În acest scop, este propus un model conceptual formalizat care organizează variabilele relevante într-o structură coerentă și descrie relațiile dintre date, modelele de AI și componentele infrastructurii sistemului. Spre deosebire de abordările care analizează separat algoritmi de predicție sau arhitecturile tehnologice, modelul propus integrează aceste elemente într-o perspectivă unitară, prin definirea explicită a variabilelor, a relațiilor dintre acestea și a ipotezelor asociate. Astfel, modelul oferă un cadru teoretic pentru înțelegerea și evaluarea sistemelor de predicție a consumului de energie în clădiri.

Modelul conceptual propus este organizat în jurul a trei categorii principale de variabile, corespunzătoare etapelor fundamentale ale unui sistem de predicție a consumului de energie, așa cum este prezentat în Figura 2.




Figura 2. Modelul conceptual pentru predicția consumului de energie în clădiri (Source: authors own research)

Prima categorie include *variabilele de intrare*, care descriu contextul operațional și condițiile externe ale clădirii:

V1 – Date istorice de consum (serii temporale ale consumului energetic)

V2 – Date meteorologice (temperatură, umiditate, radiație solară, vânt, precipitații etc.)

V3 – Caracteristici ale clădirii (dimensiune, izolație, tip HVAC, orientare, vechime etc.)

V4 – Date operaționale (grad de ocupare, program de funcționare, setări HVAC, evenimente speciale etc.)

A doua categorie este reprezentată de *variabilele de proces*, care reflectă modul în care datele sunt prelucrate și utilizate în cadrul sistemului. Acestea includ:

V5 – Calitatea datelor (completitudine, acuratețe, consistență, lipsă zgomot, corectitudine)

V6 – Complexitatea modelului AI (tip algoritm, număr parametri, capacitate de învățare)

V7 – Configurația arhitecturală a sistemului (centralizată, descentralizată sau hibridă), care definește modul de distribuire a funcțiilor de colectare, procesare și analiză a datelor și influențează performanța operațională a procesului de predicție.

V8 – Latența sistemului (timp de răspuns în procesarea datelor, generarea predicțiilor)

V9 – Nivelul de securitate și integritate a datelor (securitate, trasabilitate, integrare asigurate prin blockchain)

Împreună, aceste variabile descriu mecanismele interne ale sistemului și influențează performanța procesului de predicție.

În final, *variabilele de ieșire* exprimă rezultatele obținute, fiind reprezentate de:

V10 – Acuratețea predicției (evaluată prin metrici precum MAE, MAPE etc.)

V11 – Eficiența operațională a sistemului (optimizarea consumului energetic)

V12 – Încrederea în sistem (încrederea utilizatorilor în fiabilitatea predicțiilor și în securitatea datelor)

Modelul stabilește *relații* explicite între aceste variabile, evidențiind interdependențele dintre componente. Astfel, variabilele de intrare (V1–V4) influențează calitatea datelor (V5) și performanța modelului AI (V6), în timp ce calitatea datelor contribuie direct la creșterea acurateței predicției (V10). Complexitatea modelului AI (V6) influențează atât acuratețea predicției, cât și latența sistemului (V8). Configurația arhitecturală a sistemului (V7) influențează modul de procesare și transfer al datelor, având efect direct asupra latenței sistemului (V8) și, indirect, asupra eficienței operaționale (V11). În același timp, nivelul de securitate (V9) influențează încrederea în sistem (V12), iar acuratețea predicției (V10) se reflectă direct în eficiența operațională (V11).

Relațiile propuse în modelul conceptual descriu mecanismele prin care variabilele sistemului influențează performanța procesului de predicție. Aceste relații exprimă efectele cauzale dintre variabilele de intrare, proces și ieșire și constituie baza formulării *ipotezelor de cercetare* prezentate în continuare.

I1: Integrarea datelor meteorologice (V2) și operaționale (V4) crește semnificativ acuratețea predicției (V10)

I2: Calitatea ridicată a datelor (V5) are un impact pozitiv asupra performanței modelului AI (V10)

I3: Modelele AI cu complexitate ridicată (V6) cresc acuratețea predicției, dar pot crește latența sistemului (V8)

I4: Configurația arhitecturală a sistemului (V7) influențează latența sistemului (V8), arhitecturile hibride fiind asociate cu valori mai reduse ale latenței comparativ cu arhitecturile complet centralizate

I5: Reducerea latenței (V8) îmbunătățește eficiența operațională a sistemului (V11)

I6: Integrarea mecanismelor blockchain (V9) crește nivelul de încredere în sistem (V12)

I7: Acuratețea ridicată a predicției (V10) conduce la optimizarea consumului energetic (V11)

Modelul conceptual evidențiază faptul că performanța unui sistem de predicție a consumului de energie nu depinde exclusiv de alegerea algoritmilor de AI, ci de interacțiunea dintre calitatea datelor, arhitectura sistemului și mecanismele de securitate. Prin formalizarea acestor relații, modelul oferă un cadru teoretic pentru proiectarea și evaluarea sistemelor inteligente de management energetic. Modelul poate fi utilizat ca bază pentru validări experimentale ulterioare, prin testarea ipotezelor formulate în contexte reale de implementare.

5. Provocări, limitări și direcții viitoare în sistemele de predicție a consumului de energie

AI îmbunătățește acuratețea, eficiența și timpii de răspuns în sistemele de predicție a consumului de energie. În ciuda acestor beneficii, rămân acele probleme legate de implementarea acestor sisteme în scenarii reale. Abordarea acestor provocări este importantă pentru realizarea adopției pe scară largă și a integrării modelelor de predicție a consumului de energie bazate pe AI. În continuare, detaliem câteva dintre aceste provocări și limitări și sugerăm potențiale direcții viitoare de cercetare și dezvoltare.

a) Calitatea și disponibilitatea datelor. Această provocare este direct asociată variabilei V5 – Calitatea datelor, care influențează în mod direct acuratețea predicției (V10). Datele incomplete, zgomotoase sau inconsistente reduc performanța modelelor AI și afectează fiabilitatea rezultatelor. În modelul conceptual, această relație este reflectată prin ipoteza I2, care subliniază impactul pozitiv al calității datelor asupra performanței predictive. Astfel, mecanismele de preprocesare și validare a datelor devin componente esențiale ale sistemului.

b) Integrarea infrastructurii 5G și limitările de conectivitate. Tehnologia 5G are potențialul de a crește viteza de transmitere a datelor și de a oferi procesare în timp real, ceea ce poate reduce eficient latența în gestionarea energiei. Cu toate acestea, integrarea infrastructurii 5G are dezavantajele ei, mai ales în orașe, acolo unde clădirile pot bloca semnalele. Limitările de conectivitate influențează variabila V7 – Arhitectura sistemului și implicit V8 – Latența sistemului. Acestea pot afecta transmiterea datelor și timpul de răspuns al sistemului, reducând capacitatea de predicție în timp real. În model, această relație este surprinsă prin ipoteza I4, care evidențiază avantajele arhitecturilor hibride edge–cloud în reducerea latenței și creșterea rezilienței sistemului.

c) Adoptarea în clădirile existente. Această provocare este corelată atât cu variabilele de intrare (V3 – Caracteristicile clădirii, V4 – Date operaționale), cât și cu variabilele de proces (V6 – Complexitatea modelului AI). Clădirile existente pot avea infrastructuri limitate de senzori, ceea ce afectează disponibilitatea și calitatea datelor (V5). În acest context, modelul sugerează utilizarea unor algoritmi adaptabili la date incomplete, precum și optimizarea complexității modelelor AI pentru scenarii cu resurse limitate.

d) Lipsa validării experimentale. Absența validării empirice reflectă faptul că relațiile dintre variabilele modelului (V1–V12) nu au fost încă testate în condiții reale. În modelul conceptual, acest aspect este abordat prin formularea ipotezelor I1–I7, care oferă un cadru pentru testarea experimentală viitoare. Astfel, modelul funcționează ca o bază teoretică pentru studii ulterioare, în care se pot evalua relațiile dintre acuratețea predicției (V10), latență (V8) și eficiența operațională (V11).

e) Direcții viitoare de cercetare. Direcțiile viitoare sunt derivate din relațiile modelului conceptual. De exemplu, dezvoltarea unor metode de învățare federată poate îmbunătăți V5 – Calitatea datelor și V6 – Complexitatea modelului AI, în timp ce integrarea tehnologiilor avansate de comunicație poate reduce V8 – Latența sistemului. În plus, extinderea utilizării blockchain contribuie la îmbunătățirea V9 – Nivelului de securitate, ceea ce influențează pozitiv V12 – Încrederea în sistem, conform ipotezei I6.

Această lucrare are un caracter conceptual și nu include o validare experimentală a modelului propus. Scopul acesteia este de a defini relațiile dintre variabilele relevante și de a structura un cadru teoretic pentru predicția consumului de energie în clădiri. Validarea modelului, prin utilizarea unor seturi de date reale și evaluarea performanței diferitelor metode de AI, reprezintă o direcție viitoare de cercetare. În acest context, dezvoltarea unui prototip și testarea acestuia în condiții reale vor permite analiza acurateței predicțiilor și a aplicabilității modelului în scenarii operaționale.

6. Concluzii

Această lucrare prezintă un cadru conceptual pentru predicția consumului de energie în clădiri, având ca element central definirea unui model conceptual formalizat bazat pe variabile, relații și ipoteze explicite. Spre deosebire de abordările existente, care se concentrează predominant pe performanța algoritmilor sau pe descrierea arhitecturilor tehnice, această lucrare urmărește structurarea conceptuală a problemei de predicție într-o manieră sistematică.

Contribuția principală constă în definirea unui set de variabile de intrare, de proces și de ieșire, precum și a relațiilor dintre acestea, evidențiind rolul calității datelor, al complexității modelelor de AI, al arhitecturii sistemului și al mecanismelor de securitate asupra performanței sistemului. Modelul propus arată că acuratețea predicției și eficiența operațională nu sunt determinate exclusiv de alegerea algoritmilor, ci de interacțiunea dintre componentele sistemului și

de modul în care acestea sunt integrate. Prin formularea relațiilor conceptuale și a ipotezelor asociate, lucrarea oferă un cadru teoretic care poate fi utilizat pentru investigarea relațiilor dintre variabile în contexte reale, facilitând trecerea de la modelare conceptuală la validare experimentală. În acest sens, modelul propus permite nu doar descrierea sistemului de predicție, ci și fundamentarea unor studii empirice viitoare. Din perspectivă teoretică, cadrul propus contribuie la structurarea relațiilor dintre componentele sistemelor inteligente de management energetic și oferă o bază conceptuală pentru dezvoltarea unor modele predictive integrate. Tehnologiile precum IoT, cloud computing și blockchain sunt integrate în model din perspectiva rolului lor funcțional, contribuind la colectarea, procesarea și securizarea datelor, fără a reprezenta în sine contribuții experimentale. Lucrarea are un caracter predominant conceptual, iar relațiile dintre variabilele modelului nu au fost încă validate experimental. Performanța sistemului propus depinde de calitatea datelor, contextul de implementare și configurația arhitecturală utilizată.

Direcțiile viitoare de cercetare includ implementarea modelului într-un cadru aplicativ, testarea ipotezelor formulate pe seturi de date reale și evaluarea impactului diferitelor configurații ale sistemului asupra acurateței predicției și eficienței energetice. Astfel, cadrul conceptual propus poate constitui un punct de plecare pentru dezvoltarea și evaluarea viitoarelor sisteme inteligente de predicție a consumului de energie în clădiri.

Contribuția autorilor

Conceptualizare, metodologie, investigație, resurse, analiză formală și validare, E.T. (Eleonora Tudora), E.T. (Eugenia Tîrziu) și A.-M.V.; gestionarea datelor, E.T. (Eugenia Tîrziu) și A.-M.V.; redactarea versiunii inițiale a manuscrisului, E.T. (Eleonora Tudora), E.T. (Eugenia Tîrziu) și A.-M.V.; revizuirea și editarea manuscrisului, E.T. (Eleonora Tudora), E.T. (Eugenia Tîrziu) și A.-M.V.; supervizare, administrarea proiectului și finanțare, E.T. (Eleonora Tudora). Toți autorii au citit și au fost de acord cu versiunea publicată a manuscrisului.

Acknowledgment

Această lucrare a fost susținută prin proiectul „Sistem inteligent de predicție a consumului de energie în clădiri (PRECONERG)”, finanțat prin Programul Nucleu al Ministerului Cercetării, Inovării și Digitalizării (2023-2026).

Submission received: 01 September 2025; Review: 28 January 2026; Accepted: 08 June 2026; Published: 30 September 2026.

REFERENCES

- Aguilar, J. S., Garces-Jimenez, A., R-Moreno, M. D. & Garófallo Garcia, R. (2021) A systematic literature review on the use of artificial intelligence in energy self-management in smart buildings. *Renewable and Sustainable Energy Reviews*. 151, 111530. <https://doi.org/10.1016/J.RSER.2021.111530>.
- Ahmad, T., Chen, H., Guo, Y. & Wang, J. (2018) A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand: A review. *Energy and Buildings*. 165, 301-320. <https://doi.org/10.1016/j.enbuild.2018.01.017>.
- Alduailij, M. A., Petri, I., Rana, O. et al. (2021) Forecasting peak energy demand for smart buildings. *The Journal of Supercomputing*. 77, 6356-6380. <https://doi.org/10.1007/s11227-020-03540-3>.
- Alexandru, T. G. & Pupăză, C. (2020) Machine Learning Generalization of Lumped Parameter Models for the Optimal Cooling of Embedded Systems. *Studies in Informatics and Control*. 29(2), 169-177. <https://doi.org/10.24846/v29i2y202003>.
- Alexandru, T. G., Alexandru, A., Popescu, F. D. & Andraș, A. (2023) The Development of an Energy Efficient Temperature Controller for Residential Use and Its Generalization Based on LSTM. *Sensors*. 23(1), 453. <https://doi.org/10.3390/s23010453>.

Amasyali, K. & El-Gohary, N. M. (2018) A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*. 81(1), 1192-1205. <https://doi.org/10.1016/j.rser.2017.04.095>.

Amin, A. & Mourshed, M. (2024) Weather and climate data for energy applications. *Renewable and Sustainable Energy Reviews*. 192, 114247. <https://doi.org/10.1016/j.rser.2023.114247>.

Anarene, B. (2024) Revolutionizing Energy Efficiency in Commercial and Institutional Buildings: A Complete Analysis. *International Journal of Scientific Research and Management (IJSRM)*. 12(9), 7444-7468. <https://doi.org/10.18535/ijssrm/v12i09.em12>.

Andoni, M., Robu, V., Flynn, D. et al. (2019) Blockchain technology in the energy sector: A systematic review of challenges and opportunities. *Renewable and Sustainable Energy Reviews*. 100, 143-174. <https://doi.org/10.1016/j.rser.2018.10.014>.

Andriulo, F. C., Fiore, M., Mongiello, M. et al. (2024) Edge Computing and Cloud Computing for Internet of Things: A Review. *Informatics*. 11(4), 71. <https://doi.org/10.3390/informatics11040071>.

Azhar, N., Arif, F. & Khan, A. B. (2023) Framework for Energy Performance Measurement of Residential Buildings Considering Occupants' Energy Use Behavior. *Engineering Proceedings*. 44(1), 15. <https://doi.org/10.3390/engproc2023044015>.

Bhoyar, M. & Selvarajan, G. P. (2023) Hybrid Cloud-Edge Architectures for Low Latency IoT Machine Learning. *International Journal of Innovative Research in Science, Engineering and Technology*. 12(3), 1831-1842. <https://doi.org/10.15680/ijirset.2023.1203004>.

Chaudhari, P., Xiao, Y., Cheng, M. M.-C. & Li, T. (2024) Fundamentals, Algorithms, and Technologies of Occupancy Detection for Smart Buildings Using IoT Sensors. *Sensors*. 24(7), 2123. <https://doi.org/10.3390/s24072123>.

Cherukuri, B. R. (2024) Edge Computing Vs. Cloud Computing: A Comparative Analysis for Real-Time AI Applications. *International Journal for Multidisciplinary Research*. 6(5). <https://doi.org/10.36948/ijfmr.2024.v06i05.29316>.

Du, Z. (2024) Prediction of Building Energy Consumption Based on LSTM-SVR-Random Forest Hybrid Model. *Applied and Computational Engineering*. 115, 69-79.

Fan, Z., Pei, C., Zhao, Y. et al. (2024) Building Energy Consumption Prediction and Optimization. *Applied and Computational Engineering*. 99, 128-133.

Goel, P. K. (2024) AI for Energy Efficiency and Conservation. In: Riswandi, B., Singh, B., Kaunert, C. & Vig, K. (eds.) *AI Applications for Clean Energy and Sustainability*. IGI Global Scientific Publishing, pp. 32-49. <https://doi.org/10.4018/979-8-3693-6567-0.ch003>.

Hachache, R., Labrahmi, M., Grilo, A. et al. (2024) Energy Load Forecasting Techniques in Smart Grids: A Cross-Country Comparative Analysis. *Energies*. 17(10), 2251. <https://doi.org/10.3390/en17102251>.

Heer, P., Derungs, C., Huber, B., et al. (2024) Comprehensive energy demand and usage data for building automation. *Scientific Data*. 11, 469. <https://doi.org/10.1038/s41597-024-03292-2>.

Kawa, K., Mularczyk, R., Bauer, W. et al. (2024) Prediction of Energy Consumption on Example of Heterogenic Commercial Buildings. *Energies*. 17(13), 3220. <https://doi.org/10.3390/en17133220>.

Khorsheed, Y. A. & Danook, S. H. (2022) Building cooling loads calculation with local weather data. *NTU Journal of Engineering and Technology*. 1(3). <https://doi.org/10.56286/ntujet.v1i3.62>.

Kumar, N. M., Chand, A. A., Malvoni, M., et al. (2020) Distributed Energy Resources and the Application of AI, IoT, and Blockchain in Smart Grids. *Energies*. 13(21), 5739. <https://doi.org/10.3390/en13215739>.

Latha, H., Patil, S. & Kini, P. G. (2023) Influence of architectural space layout and building perimeter on the energy performance of buildings: A systematic literature review. *International Journal of Energy and Environmental Engineering*. 14, 431-474. <https://doi.org/10.1007/s40095->

022-00522-4.

Luo, J. (2022) A Bibliometric Review on Artificial Intelligence for Smart Buildings. *Sustainability*. 14(16), 10230. <https://doi.org/10.3390/su141610230>.

Mathumitha, R., Rathika, P. & Manimala, K. (2024) Intelligent deep learning techniques for energy consumption forecasting in smart buildings: a review. *Artificial Intelligence Review*. 57, 35. <https://doi.org/10.1007/s10462-023-10660-8>.

Mohammadi, M., Al-Fuqaha, A., Guizani, M. & Oh, J. (2018) Semisupervised deep reinforcement learning in support of IoT and smart city services. *IEEE Internet of Things Journal*. 5(2), 624-635. <https://doi.org/10.1109/JIOT.2017.2712560>.

Nadeem, A., Abzhanov, Y., Tokbolat, S. et al. (2021) The Impacts of Climate Zone, Wall Insulation, and Window Types on Building Energy Performance. In: El Dimeery, I. et al. (eds.) *Design and Construction of Smart Cities. JIC Smart Cities 2019. Sustainable Civil Infrastructures*. Cham, Springer. https://doi.org/10.1007/978-3-030-64217-4_31.

Olawumi, M. A. & Oladapo, B. I. (2025) AI-driven predictive models for sustainability. *Journal of Environmental Management*. 373, 123472. <https://doi.org/10.1016/j.jenvman.2024.123472>.

Poyyamozhi, M., Murugesan, B., Rajamanickam, N. et al. (2024) IoT—A Promising Solution to Energy Management in Smart Buildings: A Systematic Review, Applications, Barriers, and Future Scope. *Buildings*. 14(11), 3446. <https://doi.org/10.3390/buildings14113446>.

Ramesh, R., Dharani, S., Asuvanti, M. A. et al. (2023) Artificial Intelligence Techniques Based Energy Prediction Analysis and Load Forecasting Using a Dynamic Website. In: *2023 International Conference on Intelligent Technologies for Sustainable Electric and Communications Systems (iTech SECOM), Coimbatore, India, 2023*. IEEE, pp. 535-540. <https://doi.org/10.1109/iTechSECOM59882.2023.10435264>.

Reyna, A., Martín, C., Chen, J. et al. (2018) On blockchain and its integration with IoT: Challenges and opportunities. *Future Generation Computer Systems*. 88, 173-190. <https://doi.org/10.1016/j.future.2018.05.046>.

Rotună, C.-I., Dumitrache, M. & Sandu, I.-E. (2022) Assessment of Machine Learning algorithms for automated monitoring. *Romanian Journal of Information Technology and Automatic Control*. 32(3), 73-84. <https://doi.org/10.33436/v32i3y202206>.

Siripuram, S. S. (2024) Leveraging Edge Computing for Scalable Real-time Cloud Systems. *International Journal for Multidisciplinary Research*. 6(6). <https://doi.org/10.36948/ijfmr.2024.v06i06.31998>.

Sivasankari, N. & Rathika, P. (2024) Predictive Modeling of Energy Consumption for Building Automation Systems Using Deep Learning. In: *Proceedings of the 2024 Third International Conference on Intelligent Techniques in Control, Optimization and Signal Processing (INCOS), 26-28 June 2024, Tamil Nadu, India*. IEEE, pp. 01-06. <https://doi.org/10.1109/INCOS59338.2024.10527774>.

Skaloumpakas, P., Mylona, Z., Stropoulos, S. et al. (2023) An Integrated AI-Based Information System for Energy Forecasting. In: *2023 14th International Conference on Information, Intelligence, Systems & Applications (IISA), Volos, Greece*. IEEE, pp. 1-7. <https://doi.org/10.1109/IISA59645.2023.10345891>.


Suriya, S. & Agusthiyar, R. (2025) Predicting peak demand for electricity consumption using time series data and machine learning model. *Indonesian Journal of Electrical Engineering and Computer Science*. 38(1), 668-676. <https://doi.org/10.11591/ijeecs.v38.i1.pp668-676>.

Tudora, E. & Tîrziu, E. (2024) Advanced approaches in building energy consumption prediction. *Romanian Journal of Information Technology and Automatic Control*. 34(2), 21-34. <https://doi.org/10.33436/v34i2y202402>.

Wei, Y., Zhang, X., Shi, Y. et al. (2018) A review of data-driven approaches for prediction and

classification of building energy consumption. *Renewable and Sustainable Energy Reviews*. 82(1), 1027-1047. <https://doi.org/10.1016/j.rser.2017.09.108>.

Yin, Q., Han, C., Li, A., et al. (2024) A Review of Research on Building Energy Consumption Prediction Models Based on Artificial Neural Networks. *Sustainability*. 16(17), 7805. <https://doi.org/10.3390/su16177805>.



Eleonora TUDORA este doctorand în cadrul Școlii Doctorale de Inginerie Energetică al Universității Naționale de Știință și Tehnologie POLITEHNICA București și este cercetător științific gradul III în Departamentul Comunicații, Aplicații și Sisteme Digitale din cadrul Institutului Național de Cercetare-Dezvoltare în Informatică – ICI București. A absolvit Facultatea de Energetică din cadrul Universității Naționale de Știință și Tehnologie POLITEHNICA București. Principalele domenii de interes pentru activitatea de cercetare includ: energie, schimbări climatice, eficiență energetică și energii regenerabile, agricultură, e-Health, dezvoltarea de sisteme informatice, utilizarea Big Data în guvernare, utilizarea TIC în sănătate.

Eleonora TUDORA is a Ph.D. student at the Doctoral School of Energy Engineering of the National University of Science and Technology POLITEHNICA Bucharest and is a third-degree scientific researcher in the Department Communications, Digital Applications and Systems at National Institute for Research and Development in Informatics – ICI Bucharest. She graduated the Faculty of Energetics of the National University of Science and Technology POLITEHNICA Bucharest. The main areas of interest for the research activity include: energy, climate change, energy efficiency and renewable energies, agriculture, e-Health, the development of information systems, the use of Big Data in governance, the use of ICT in health.



Eugenia TÎRZIU lucrează în prezent la Institutul Național de Cercetare-Dezvoltare în Informatică – ICI București în calitate de cercetător științific gradul III în cadrul Departamentului Comunicații, Aplicații și Sisteme Digitale. A absolvit Universitatea Națională de Știință și Tehnologie POLITEHNICA București, Facultatea de Automatică și Calculatoare. Principalele domenii de interes pentru activitatea de cercetare sunt: Inteligența Artificială, e-Learning, e-Health.

Eugenia TÎRZIU is currently working at the National Institute for Research and Development in Informatics – ICI Bucharest as third-degree Scientific Researcher in the Department Communications, Digital Applications and Systems. She graduated the National University of Science and Technology POLITEHNICA Bucharest – Faculty of Automatic Control and Computer Science. Her research interests include: Artificial Intelligence, e-Learning, e-Health.



Ana-Mihaela VASILEVSCHI lucrează în prezent la Institutul Național de Cercetare-Dezvoltare în Informatică – ICI București, în calitate de programator în cadrul Departamentului Comunicații, Aplicații și Sisteme Digitale. A absolvit Universitatea Națională de Știință și Tehnologie POLITEHNICA București, Facultatea de Inginerie Medicală, și a finalizat studiile de master în domeniul Sistemelor Inteligente și Vederii Artificiale la Facultatea de Electronică, Telecomunicații și Tehnologia Informației. Domeniile principale de interes pentru activitatea de cercetare includ Inteligența Artificială, blockchain și e-Health.

Ana-Mihaela VASILEVSCHI is currently working at the National Institute for Research and Development in Informatics – ICI Bucharest as a software engineer within the Communications, Applications, and Digital Systems Department. She graduated from the National University of Science and Technology POLITEHNICA Bucharest, Faculty of Medical Engineering, and completed a master's degree in Intelligent Systems and Computer Vision at the Faculty of Electronics, Telecommunications, and Information Technology. Her main research interests include Artificial Intelligence, Blockchain, and e-Health.



This is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.