

SISTEM MULTI-AGENT PENTRU MONITORIZAREA ȘI PREDICȚIA PROCESELOR DE MEDIU

CZU: 502.313:004.896

DOI: <https://doi.org/10.52673/18570461.25.1-76.01>

Doctor în științe ingineresti, conferențiar universitar **Victor ABABII**

E-mail: victor.ababii@calc.utm.md

ORCID: <https://orcid.org/0000-0002-0769-8144>

Doctor în științe ingineresti **Viorel CARBUNE**

E-mail: viorel.carbune@calc.utm.md

ORCID: <https://orcid.org/0000-0002-1556-4453>

Doctor în științe ingineresti, conferențiar universitar **Viorica SUDACEVSCHI**

E-mail: viorica.sudacevschi@calc.utm.md

ORCID: <https://orcid.org/0000-0003-0125-3491>

Doctor în informatică, conferențiar universitar **Galina MARUSIC**

E-mail: galina.marusic@adm.utm.md

ORCID: <https://orcid.org/0000-0002-2984-2055>

Doctorand **Rodica BRANIȘTE**

E-mail: rodica.braniste@ia.utm.md

ORCID: <https://orcid.org/0000-0002-6935-8444>

Student programul „Robotică și Mecatronică” **Nicu DRUMEA**

E-mail: nicu.drumea@iis.utm.md

Universitatea Tehnică a Moldovei

MULTI-AGENT SYSTEM FOR MONITORING AND PREDICTION OF ENVIRONMENTAL PROCESSES

Summary. The paper explores the development of a multi-agent scalable system (SMA) concept for monitoring and predicting environmental processes, addressing the challenges related to the organization of distributed computing processes and the application of knowledge-based models, machine learning and artificial intelligence. SMA offers an innovative solution based on autonomous agents that perceive the environment, collaborate with each other, with the data storage center and implement advanced computing models. The technical and technological development of the system provides for the use of a set of smart sensors and devices, such as the ESP32, which integrate acquisition, data preprocessing and network communication services. The agent functional diagram and the algorithm for collaboration between agents and the data storage center were developed. The process of predicting environmental events is based on the application of neural network models. It was analyzed the carbon dioxide pollution scenario and its evolution to validate the proposed concept. The paper demonstrates that multi-agent systems can provide efficient and scalable solutions for managing environmental problems, to help to prevent crises and to support environmental protection policies.

Keywords: multi-agent system, environmental process monitoring, spatio-temporal prediction, artificial intelligence, autonomous agents, machine learning, air quality, atmospheric pollutants, smart sensors.

Rezumat. Lucrarea explorează dezvoltarea unui concept de sistem scalabil multi-agent (SMA) destinat monitorizării și predicției proceselor de mediu, abordând provocările legate de organizarea proceselor de calcul distribuit și aplicarea modelelor bazate pe cunoștințe, învățare automată și inteligența artificială. SMA oferă o soluție inovativă bazată pe agenți autonomi care percep mediul înconjurător, colaborează între ei, cu centrul de stocare a datelor și implementează modele avansate de calcul. Dezvoltarea tehnică și tehnologică a sistemului prevede utilizarea unui set de senzori inteligenți și de dispozitive, precum ESP32, care integrează servicii de achiziție, preprocesare a datelor și comunicare în rețea. Sunt elaborate diagrama funcțională a agentului, algoritmul de colaborare între agenți și centrul de stocare a datelor. Procesul de predicție a evenimentelor de mediu se bazează pe aplicarea modelelor de rețele neuronale. Pentru validarea conceptului propus, s-a analizat un scenariu de poluare cu dioxid de carbon și evoluția acestuia în spațiu și timp. Lucrarea demonstrează că sistemele multi-agent pot oferi soluții eficiente și scalabile pentru gestionarea problemelor de mediu, contribuind la prevenirea crizelor și susținerea politicii de protecție a mediului.

Cuvinte-cheie: sistem multi-agent, monitorizare procese de mediu, predicție spațio-temporală, inteligența artificială, agenți autonomi, învățare automată, calitatea aerului, poluanți atmosferici, senzori inteligenți.

INTRODUCERE

Monitorizarea și predicția proceselor de mediu prezintă o provocare majoră în contextul schimbărilor climatice și al degradării mediului ambiant. Astfel, dezvoltarea unor soluții eficiente de monitorizare și predicție este esențială pentru protejarea ecosistemelor și a vieții pe Pământ. Sistemele multi-agent [1-4] oferă o abordare de perspectivă în acest sens, datorită capacității lor de a gestiona eficient complexitatea problemei soluționate și de a facilita cooperarea între diverse entități autonome și eterogene utilizând modele de inteligență artificială [5-8] (Rețele Neuronale, Logica Fuzzy și Algoritmi Genetici).

Avantajele oferite de sistemul multi-agent (SMA) pentru monitorizarea și predicția proceselor de mediu constau în prezența unui set de agenți autonomi care interacționează pentru a realiza un obiectiv comun: livrarea de informații corecte și prevenirea crizelor de mediu [1; 2]. Fiecare agent are capacitatea de a percepe mediul, de a lua decizii și de a acționa independent, dar și de a colabora cu alți agenți atunci când este necesar. Principalele caracteristici ale SMA sunt definite în numeroase cercetări științifice, și anume: agenții funcționează autonom/independent; agenții colaborează pentru a atinge obiective comune; SMA se poate adapta la schimbările din mediu pentru a oferi soluții optime; datele și procesele de calcul sunt distribuite între agenți asigurând robustețea SMA [1-4].

Serviciile oferite de un SMA pentru monitorizarea proceselor de mediu sunt foarte diverse: agenții echipați cu senzori colectează date în timp real despre tipurile de poluanți atmosferici (calitatea aerului); agenții monitorizează parametri fizico-chimici ai râurilor, lacurilor sau apelor subterane (calitatea apei); agenții colectează date privind tipurile de sedimente și utilizarea terenurilor (eficiența utilizării solului); agenții urmăresc populațiile de specii și schimbările habitatelor naturale (o caracteristică universală a ecosistemelor) [9; 10]. În paralel cu monitorizarea proceselor de mediu, un SMA poate oferi și servicii de predicție pentru a anticipa evoluțiile în spațiu și timp a proceselor de mediu: agenții procesează datele istorice colectate pentru a identifica tendințele în spațiu și timp; agenții implementează algoritmi de învățare automată pentru a genera predicții precise; agenții creează scenarii ipotetice pentru a evalua impactul diversilor factori asupra mediului [11; 12].

Beneficiile oferite de SMA sunt evidente: sistemul poate fi extins cu ușurință prin includerea de noi agenți sau regiuni de monitorizare; sistemul este rezistent la defectele locale datorită naturii distribuite de stocare și procesare a datelor; colectarea și analiza datelor sunt realizate în mod rapid și eficient [13; 14].

Totodată, SMA implică provocări și limitări în procesul de proiectare, dezvoltare și exploatare, așa ca: integrarea datelor provenite din surse eterogene; dezvoltarea de algoritmi eficienți pentru gestionarea volumului mare de date; necesitatea de resurse eterogene de stocare și procesare a datelor, de senzori inteligenți de performanță și infrastructură de comunicații [15-17].

Obiectivele cercetărilor realizate în lucrarea de față au fost inspirate parțial din experiența și cercetările realizate anterior în lucrările [1-17] și sunt orientate spre: dezvoltarea unui cadru conceptual pentru un sistem multi-agent destinat monitorizării și predicției proceselor de mediu, care va integra informații acumulate în timp real de la puncte de achiziție localizate în blocurile de studii ale UTM; crearea unui model de calcul distribuit pentru colectarea și analiza datelor de stare a mediului folosind senzori și dispozitive inteligente; elaborarea algoritmilor de colaborare și coordonare între agenți pentru a asigura o monitorizare eficientă și precisă; integrarea tehnologiilor de învățare automată pentru a sprijini procesul de predicție a evoluțiilor proceselor de mediu.

STRUCTURA SISTEMULUI MULTI-AGENT

Conceptul sistemului multi-agent destinat monitorizării și predicției proceselor de mediu este determinat de amplasarea geografică a blocurilor de studii ale UTM (Figura 1), și de funcțiile și serviciile oferite de acesta (Figura 2).

Astfel, Figura 1 ilustrează modul de amplasare a punctelor de achiziție și procesare a datelor pentru monitorizarea și predicția proceselor de mediu, unde:

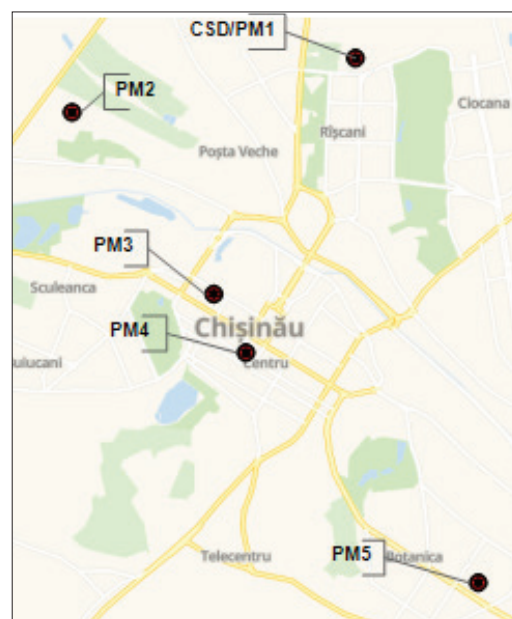


Figura 1. Amplasarea geografică a punctelor de achiziție și procesare a datelor.

CSD/PM1 – Centrul de stocare a datelor și Punctul de monitorizare 1 amplasat în sectorul Râșcani, str. Studenților, 9/7 (47.06219813308824, 28.868194068366083);

PM2 – Punctul de monitorizare 2 amplasat în sectorul Râșcani, str. Mircești, 54 (47.06149469535205, 28.809638706354598);

PM3 – Punctul de monitorizare 3 amplasat în sectorul Centru, bd. Ștefan cel Mare și Sfânt, 168 (47.030603683045406, 28.823850320614476);

PM4 – Punctul de monitorizare 4 amplasat în sectorul Centru, str. Mitropolit Bănulescu-Bodoni, 78 (47.02391969628778, 28.829544452911378);

PM5 – Punctul de monitorizare 5 amplasat în sectorul Botanica, bd. Dacia, 41 (46.9825936921273, 28.864778563802233).

În specificațiile pentru Figura 1, în paranteze, sunt indicate coordonatele GPS (latitudinea, longitudinea), care corespund adresei menționate.

În Figura 2 este prezentată diagrama UML *Cazuri de utilizare* care specifică funcțiile realizate de sistemul multi-agent destinat monitorizării și predicției proceselor de mediu, unde:

Administrator de sistem – personalul responsabil de funcționalitatea sistemului multi-agent pentru monitorizarea și predicția proceselor de mediu;

Utilizator de servicii – mulțimea de utilizatori ai serviciilor oferite de sistemul multi-agent (locuitorii municipiului Chișinău și persoanele responsabile de starea proceselor de mediu în regiune);

Achiziția datelor – perceperea mediului înconjurător și preprocesarea datelor de la setul de senzori;

Comunicare – servicii de transport al datelor care integrează tehnici, tehnologii și protocoale de comunicare;

Stocarea datelor – servicii de management al bazei de date care conține istoria evoluției parametrilor de stare a mediului;

Procesarea datelor – aplicarea de metode și modele pentru procesarea datelor care include:

Predicție – modele de calcul bazate pe inteligența artificială (Rețele Neuronale) pentru prognoza și evoluția spațial-temporală a parametrilor de mediu;

Servicii de informare – acces liber din rețeaua Internet la informațiile oferite de sistemul multi-agent.

Diagrama sistemului multi-agent pentru monitorizarea și predicția proceselor de mediu este prezentată în Figura 3, unde: **CSD/PM1, PM2, PM3, PM4 și PM5** sunt punctele de monitorizare amplasate în blocurile de studii ale UTM și Centrul de stocare a datelor; **Web server** – pagina Web care oferă servicii de acces liber pentru utilizatori la informațiile privind starea mediului; **Database server** – stochează datele pe perioade îndelungate de timp; **Data processing** – servicii pentru procesarea și predicția proceselor de mediu; **A** – mulțimea de agenți cu capacități de inteligență artificială, care formează un cluster de dispozitive de calcul cu posibilitate de comunicare între acestea; **Wireless Router** – sistem pentru conectarea agenților la rețea; **Internet** – rețea globală cu tehnici și tehnologii (infrastructură tehnologică) pentru transport de date în bază de protocoale standard.

Modul de funcționare a sistemului multi-agent. Fiecare agent **A**, în raport cu obiectivele sale, percepe mediul înconjurător și achiziționează starea acestuia prin intermediul setului de senzori. Fiecare agent **A** preprocesează datele, aplicând modele bazate pe inteligența artificială, și prin serviciile oferite de Wireless Router și Internet le expediază la CSD care sunt stocate pe Database server. Serviciile Data processing acce-




Figura 2. Diagrama cazurilor de utilizare.




Figura 3. Diagrama sistemului multi-agent.

sează datele de pe Database server și în baza modelelor de calcul inteligent extrag informațiile utile pentru procesare și predicția proceselor de mediu rezultatele fiind integrate în pagina de pe Web server. Astfel, prin intermediul unei aplicații Browser, se oferă accesul deschis pentru utilizatori din rețeaua globală Internet.

MODELUL SPAȚIO-TEMPORAL DE EVOLUȚIE A PROCESULUI DE MEDIU

Funcționalitatea sistemului multi-agent este determinată de metodele și modelele matematice implementate. Modelarea spațio-temporală este esențială pentru a înțelege și a gestiona corect procesele de mediu, oferind posibilitatea de cercetare și prognozare a evoluției acestora. Modelele în cauză asigură o înțelegere holistică a proceselor de mediu și instrumente predictive pentru scenarii de viitor, ajutând la luarea deciziilor bazate pe date pentru politici și planuri de mediu.

Așadar, modelul spațio-temporal de evoluție a procesului de mediu este un instrument matematic destinat analizei dinamice a unui proces de mediu în timp și spațiu. Acest model permite investigarea interacțiunilor complexe dintre factorii naturali și umani, oferind o bază pentru luarea deciziilor în gestionarea mediului. Componentele principale ale unui model spațio-temporal sunt: dimensiunea spațială – care reprezintă distribuția geografică a procesului studiat și utilizează sisteme de coordonate spațiale, absolute sau de referință; dimensiunea temporală –

care analizează dinamica procesului pe axa de timp, include evenimente pe termen scurt (secunde, minute, ore sau zile) sau pe termen lung (ani, decenii, secole); factorii de influență – care reprezintă setul de variabile specifice procesului de mediu studiat (concentrație, umiditate, precipitații, temperatură, vânt, activitate geologică, urbanizare, defrișări, emisii industriale, activități agricole etc.).

În consecință, pot fi menționate următoarele modele de referință, care se află la baza modelării spațial-temporale și asigură analiza dispersiei poluanților atmosferici, pentru a evalua impactul surselor de poluare și pentru a dezvolta strategii de gestionare a calității mediului/aerului:

Modele Gaussiene – sunt utilizate pentru analiza dispersiei poluanților atmosferici la nivel local și regional și se bazează pe ipoteza că distribuția concentrației unui poluant emis într-o atmosferă în mișcare urmează o curbă gaussiană în jurul axei principale a traiectoriei sale de deplasare. Această traiectorie este influențată de factori precum viteza și direcția vântului, condițiile meteorologice și caracteristicile sursei de emisie. Modelele Gaussiene se bazează pe soluția ecuației de advecție-difuzie (1) [18; 19]:

$$C(x, y, z) = \frac{Q}{2\pi u \sigma_y \sigma_z} \exp\left(-\frac{y^2}{2\sigma_y^2}\right) \left[\exp\left(-\frac{(z-H)^2}{2\sigma_z^2}\right) + \exp\left(-\frac{(z+H)^2}{2\sigma_z^2}\right) \right] \quad (1)$$

unde: $C(x, y, z)$ – concentrația poluantului în punctul cu coordonatele (x, y, z) ; Q – rata de emisie a sursei de poluanți (g/s); u – viteza medie a vântului (m/s); σ_y, σ_z – parametrii de dispersie orizontală și verticală; H – înălțimea sursei de poluare (m).

Modele Euleriene – sunt aplicate pentru analiza transportului de poluanți la nivel regional și global și reprezintă ecuații diferențiale parțiale care descriu transportul și transformarea poluanților într-un cadru fix de referință (2) [20]:

$$\frac{\partial C}{\partial t} + u \frac{\partial C}{\partial x} + v \frac{\partial C}{\partial y} + w \frac{\partial C}{\partial z} = D_x \frac{\partial^2 C}{\partial x^2} + D_y \frac{\partial^2 C}{\partial y^2} + D_z \frac{\partial^2 C}{\partial z^2} - R(C) + S(x, y, z, t) \quad (2)$$

unde: C – concentrația poluantului (kg/m^3); u, v, w – componentele vitezei vântului (m/s) pe direcția (x, y, z) ; D_x, D_y, D_z – coeficienți de difuziune (m^2/s); $R(C)$ – rata de reacție chimică a poluantului; $S(x, y, z, t)$ – sursa de poluare cu coordonatele (x, y, z) în momentul de timp (t) .

Modele Lagrangiene – sunt aplicate pentru simularea dispersiei poluanților din surse variabile în timp

și urmăresc particulele sau pachetele de aer ce transportă poluanți în atmosferă, bazându-se pe traiectoriile acestora (3) [21]:

$$\frac{dX}{dt} = u(X, t); \quad \frac{dY}{dt} = v(Y, t); \quad \frac{dZ}{dt} = w(Z, t), \quad (3)$$

unde: (X, Y, Z) – coordonatele particulei; u, v, w – componentele vitezei vântului.

Modele CFD (Computational Fluid Dynamics) (se mai numesc și ecuațiile Navier-Stokes) – sunt aplicate pentru analiza dispersiei în zonele urbane sau industriale complexe, acestea folosesc simulări detaliate ale fluxului de aer pentru a analiza dispersia poluanților la scară mică (4) [22]:

$$\frac{\partial u}{\partial t} + (u \cdot \nabla)u = -\frac{1}{\rho} \nabla p + \nu \nabla^2 u + f, \quad (4)$$

unde: u – viteza aerului; ρ – densitatea aerului; p – presiunea aerului; ν – vâscozitatea cinematică; f – forțele externe, care acționează asupra mediului.

În urma analizei modelelor matematice și statistice utilizate pentru predicția proceselor de mediu (ecuații diferențiale, modele stocastice, rețele neuronale și simulări numerice) s-au selectat modelele clasice în combinație cu rețelele neuronale, care oferă o flexibilitate și adaptabilitate înaltă, precum și posibilitatea de învățare.

DIAGRAMA FUNCȚIONALĂ A AGENȚILOR

În sistemul multi-agent destinat monitorizării și predicției proceselor de mediu, agenții sunt acele dispozitive inteligente care livrează informații pentru funcționarea sistemului integral și predicția cât mai corectă a evenimentelor în spațiu și timp. Astfel, un agent realizează un șir de funcții: achiziția datelor privind starea mediului, stocarea datelor, preprocesarea datelor, comunicarea cu alți agenți, comunicarea cu

baza de date, aplicarea modelelor de procesare a datelor bazate pe cunoștințe, evaluarea și actualizarea cunoștințelor referitor la starea mediului. În Figura 4 este prezentată diagrama funcțională a unui agent, unde: **SD** – mulțimea de senzori digitali; **SA** – mulțimea de senzori analogici; **Porturi digitale** – pentru comunicarea cu setul de senzori digitali în baza de protocoale standard (I2C, SPI etc.); **Porturi analogice** – pentru achiziția și conversia analog-numerică a semnalelor generate de setul de senzori analogici; **Control** – comanda cu procesul de achiziție a datelor de la setul de senzori; **Stocare locală** – memorie pentru stocarea datelor de stare a agentului și a mediului monitorizat; **Procesare date** – unitatea logico-aritmetică pentru preprocesarea datelor; **Comunicare WiFi** – stiva de protocoale și circuite pentru transferul datelor în baza undelor electromagnetice; **Modele de cunoștințe** – setul de reguli care determină comportamentul și operațiile efectuate de agent pentru procesarea datelor și colaborarea cu alți agenți; **Interpreter de cunoștințe** – transformă cunoștințele în semnale de comandă cu blocurile funcționale ale agentului; **Evaluator de cunoștințe** – bloc de învățare automată care evaluează actualitatea cunoștințelor și la necesitate le modifică în baza datelor de stare a mediului sau în baza datelor oferite de alți agenți; **D** – fluxuri de date; **C** – semnale de control.

Complexitatea funcțională a agentului este realizată pe baza dispozitivelor electronice ESP32 care oferă următoarele caracteristici tehnice și tehnologice [23-25]: procesor dual-core cu frecvența de lucru până la 240 MHz; comunicare WiFi în standardele 802.11 b/g/n, și Bluetooth clasic și BLE; memorie SRAM integrată 520 KB și Flash externă; porturi de intrare/ieșire: Digitale, PWM, ADC, DAC, SPI, I2C și UART; consum redus de energie; criptarea datelor AES, SHA și RSA.

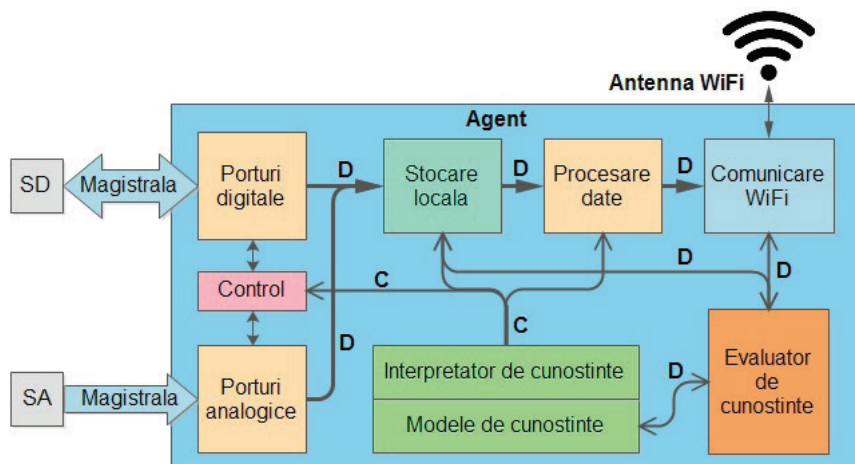


Figura 4. Diagrama funcțională a agentului.

Pentru dezvoltarea produselor program este utilizat mediul de dezvoltare Arduino IDE [24; 25].

ALGORITMUL DE COLABORARE ÎNTRE AGENȚI ȘI CSD

Procesul de colaborare dintre agenți și CSD (Centrul de Stocare a Datelor) are loc în baza protocoalelor de comunicare în rețelele de calculatoare. Pentru a realiza transferul de date, agenții funcționează în regim de client și CSD în regim server. Pentru comunicarea dintre agenți se formează o topologie de rețea Mesh care asigură transferul datelor la nivel local al punctului de monitorizare PM. În Figura 5 este prezentată diagrama UML care explică modul de interacțiune dintre agent-agent și agent-CSD, unde: secvența 1 explică comunicarea dintre doi agenți care aparțin punctului de monitorizare PM3; secvența 2 explică comunicarea dintre un agent care aparține punctului de monitorizare PM3 cu centrul de stocare a datelor CSD amplasat în punctul de monitorizare CSD/PM1; secvența 3 explică comunicarea dintre un agent care face parte din punctul de monitorizare CSD/PM1 cu un agent din punctul de monitorizare PM3; secvența 4 explică comunicarea dintre un agent din punctul de monitorizare CSD/PM1 cu CSD. Din diagrama UML se observă că secvența 1 și secvența 4 interacționează concomitent, ceea ce asigură funcționarea paralelă a dispozitivelor.

Pentru dezvoltarea produselor program de funcționare a CSD s-a utilizat limbajul Python cu bibliotecile specifice pentru dezvoltarea aplicațiilor bazate pe învățare automată și inteligență artificială: Tensor-

Flow, Scikit-learn, PyTorch și Keras. Pentru dezvoltarea web s-a utilizat biblioteca Flask [26].

MODELAREA PREDICȚIEI PROCESELOR DE MEDIU

Evaluarea calității mediului implică măsurarea și analiza mai multor parametri care reflectă starea ecosistemelor naturale, a resurselor și condițiilor de viață pentru oameni. Acești parametri pot fi grupați în funcție de componentele evaluate ale mediului: aer, apă, sol sau biodiversitate. Deoarece toate aceste componente se află în dependență directă una față de alta, pentru a obține o imagine complexă a stării mediului sunt aplicate metode de măsurare și analiză complexă/integrală.

În lucrarea de față ne vom concentra pe evaluarea calității aerului, din aceste considerente vom măsura, analiza și modela așa parametri ca: intervalul de timp; temperatura și umiditatea aerului; presiunea atmosferică; viteza și direcția vântului; concentrația dioxidului de carbon ($CO_2 < 1000 \text{ ppm}$); concentrația oxizilor de azot ($NO_x < 10 \mu\text{g} / m^3$); concentrația dioxidului de sulf ($SO_2 < 40 \mu\text{g} / m^3$); concentrația monoxidului de carbon ($CO < 4 \text{ mg} / m^3$) etc. În paranteze sunt indicate valorile admisibile recomandate de Organizația Mondială a Sănătății.

Pentru validarea conceptului prezentat în lucrare s-a modelat în mediul MATLAB R2022b un scenariu definit de setul de date prezentat în Tabelul 1, cu intervale de 60 de minute între măsurări. Scenariul este simplificat la maxim posibil și prevede declanșarea unui incendiu de vegetație în regiunea punctului de moni-

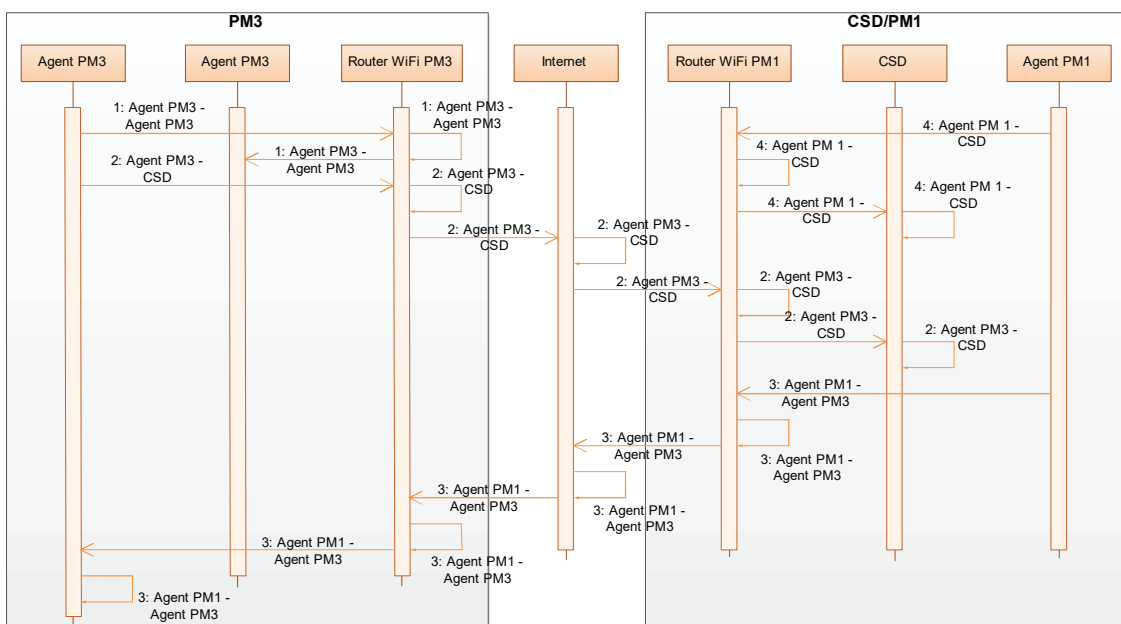


Figura 5. Diagrama UML de interacțiune agent-agent și agent-CSD.

Tabelul 1

Setul de date privind evoluția parametrilor de stare a mediului

Datele de intrare a rețelei neuronale artificiale					Datele de ieșire a rețelei neuronale artificiale				
Nr.	PM2: °C	PM2: U (%)	PM2: V (m/s)	PM2: D (rad)	PM2: CO ₂ (ppm)	PM1: CO ₂ (ppm)	PM3: CO ₂ (ppm)	PM4: CO ₂ (ppm)	PM5: CO ₂ (ppm)
1.	5,0	70,0	2,50	0,0	460	450	600	600	650
2.	5,5	70,0	2,50	0,0	460	450	600	600	650
3.	5,5	70,0	2,60	0,0	465	460	650	650	700
4.	5,5	70,0	2,65	0,0	470	465	660	660	750
5.	6,0	70,0	2,70	0,0	2000	470	670	670	750
6.	6,0	70,0	2,75	0,0	1900	475	1200	680	750
7.	5,5	71,0	2,80	0,0	1800	475	1150	1100	800
8.	5,0	72,0	2,85	0,0	1600	470	1100	1050	1050
9.	4,5	73,0	2,90	0,0	1400	470	1000	1000	1000
10.	4,0	74,0	2,90	0,0	1200	465	950	950	950
11.	3,5	75,0	2,80	0,0	1000	465	900	900	900
12.	3,0	76,0	2,70	0,0	900	465	800	800	800
13.	2,5	77,0	2,60	0,0	800	460	700	700	700
14.	2,0	78,0	2,50	0,0	700	455	600	600	600
15.	1,0	79,0	2,40	0,0	600	450	600	600	600

torizare PM2 amplasat în sectorul Râșcani, str. Mircești, 54 (47.06149469535205, 28.809638706354598), care elimină CO₂, unde: °C – temperatura aerului; U – umiditatea aerului; V – viteza vântului; D – direcția vântului; și CO₂ – concentrația dioxidului de carbon în părți per milion.

Partea stângă a Tabelului 1 prezintă **Datele de intrare** care sunt aplicate la intrarea **Input** a modelului de rețea neuronală, iar partea dreaptă prezintă **Datele de ieșire** utilizate pentru antrenarea modelului prezentat în Figura 6. Procesul de învățare a rețelei neuronale se efectuează printr-un mecanism iterativ de optimizare, în care are loc ajustarea parametrilor în funcție de erorile rezultate din comparația dintre predicțiile rețelei și valorile reale așteptate.

Pentru modelare s-a utilizat arhitectura de rețea neuronală multistrat, structura căreia este prezentată în Figura 6. Topologia rețelei neuronale include: 5 neuroni în stratul de intrare; 10 neuroni în stratul ascuns în care este utilizată funcția de transfer sigmoidă simetrică (Sigmoid Symmetric Transfer Function). Stratul de ieșire include: 4 neuroni în care este utilizată funcția de transfer liniară (Linear Transfer Function).




Figura 6. Structura rețelei neuronale pentru modelarea scenariului din Tabelul 1.

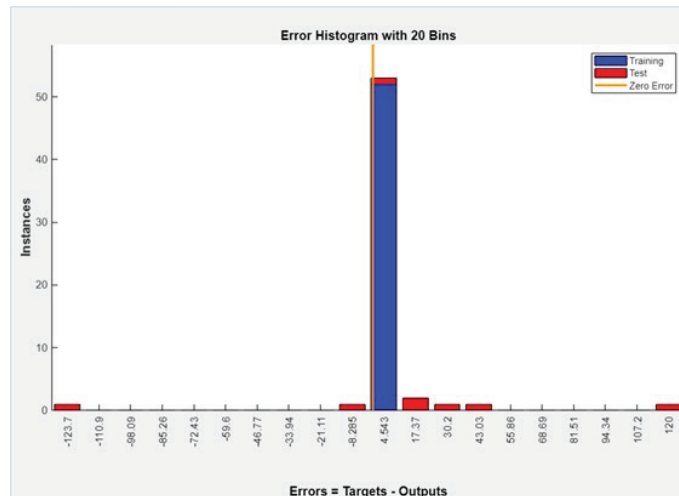


Figura 7. Histograma erorii generate în procesul de testare a modelului de rețea neuronală.

Rezultatul antrenării rețelei neuronale este prezentat în Figura 7, care indică histograma erorii obținute în procesul de antrenare și testare a modelului de rețea neuronală pentru întreg setul de date. Se observă o distribuție a erorii (barele albastre pentru antrenare și roșii pentru testare) preponderent în apropierea valorii 0, indicată prin linia de culoare galbenă.

Drept rezultat al modelării procesului de antrenare a rețelei neuronale și testarea acesteia s-au generat: matricele de coeficienți W și vectorii bias b pentru stratul ascuns și de ieșire a rețelei neuronale. În continuare, matricele W și vectorii b pot fi utilizați în procesul de implementare software a modelelor de predicție a proceselor de mediu.

CONCLUZII

În lucrarea de față sunt prezentate rezultatele dezvoltării unui concept al unui sistem multi-agent pentru monitorizarea și predicția proceselor de mediu care utilizează informații acumulate în timp real de la puncte de achiziție amplasate în blocurile de studii ale UTM. Sistemul prezintă o arhitectură de calcul distribuit care asigură colectarea și analiza datelor privind starea mediului folosind senzori și dispozitive inteligente bazate pe modele de cunoștințe, algoritmi de colaborare și coordonare între agenți, precum și tehnologii de învățare automată.

Eficiența sistemului multi-agent este determinată de faptul că acesta oferă o soluție robustă și scalabilă pentru colectarea, procesarea și analiza datelor de mediu, facilitând luarea deciziilor bazate pe date. Funcționarea distribuită asigură reziliență la defecțiuni și posibilitatea extinderii în funcție de necesitate. Aceste caracteristici ale sistemului sunt definite de funcționalitatea autonomă/individuală a fiecărui agent, capacitatea acestuia de a se adapta la mediu și arhitectura

sistemului, iar în caz de defecțiune, funcțiile acestuia sunt îndeplinite de alți agenți.

Totodată, prin utilizarea algoritmilor de învățare automată bazați pe seturi de date acumulate din spațiul monitorizat, sistemul permite realizarea de predicții ale evoluțiilor spațio-temporale ale proceselor de mediu, care ajută la evaluarea impactului poluării și planificarea strategică pentru termen scurt și mediu.

Sistemul se bazează pe dezvoltarea unei arhitecturi de calcul distribuit alcătuite din dispozitive MCU, precum ESP32, care combină funcționalități avansate de achiziție a datelor, de preprocesare și comunicare wireless, ceea ce reduce costurile de proiectare și dezvoltare și îmbunătățește performanțele acestuia. Utilizarea dispozitivelor MCU ESP32 asigură o flexibilitate sporită sistemului, exprimată prin posibilitatea de adăugare de noi puncte de monitorizare sau de agenți în arhitectura sistemului și soluționarea problemei legate de integrarea datelor eterogene, volumul mare de date și necesitatea unei infrastructuri de comunicații fiabile.

Pe viitor sunt planificate activități de testare și validare funcțională a sistemului.

BIBLIOGRAFIE

1. Athanasiadis, I.N. and Mitkas, P.A. An agent-based intelligent environmental monitoring system. In: Management of Environmental Quality, vol. 15, no. 3, 2004, 238-249, <https://doi.org/10.1108/14777830410531216>
2. Di Lecce, V., Pasquale C. and Piuri, V. A basic ontology for multi agent system communication in an environmental monitoring system. In: 2004 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 2004. CIMSA, Boston, MA, USA, 2004, 45-50, doi: 10.1109/CIMSA.2004.1397228
3. Zheng, H., and Shi, D. A multi-agent system for environmental monitoring using boolean networks and reinforcement learning. In: Journal of Cyber Security, 2(2), 2020, 85-96, doi:10.32604/jcs.2020.010086

4. Liu, J. and Williams, R.K. Coupled Temporal and Spatial Environment Monitoring for Multi-Agent Teams in Precision Farming. In: 2020 IEEE Conference on Control Technology and Applications (CCTA), Montreal, QC, Canada, 2020, 273-278, doi: 10.1109/CCTA41146.2020.9206322
5. Alotaibi, E., Nassif, N. Artificial intelligence in environmental monitoring: in-depth analysis. In: *Discov Artif Intell* 4, 84 (2024), <https://doi.org/10.1007/s44163-024-00198-1>
6. Arabelli, R., Boddepalli, E., Buradkar, M., Goriparti, N.V.S. and Chakravarthi, M.K. IoT-Enabled Environmental Monitoring System Using AI. In: 2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI), Chennai, India, 2024, 1-6, doi: 10.1109/ACCAI61061.2024.10602131
7. Ullo, S.L., and Sinha, G.R. Advances in smart environment monitoring systems using IoT and sensors. In: *Sensors* 2020, 20(11), 3113, 1-18, <https://doi.org/10.3390/s20113113>
8. Montaser, N.A., Mohammed, A.H., Shin Yee Khoo, Mohammad Alkhedher, Mohammad Alherbawi, Real-time IoT-powered AI system for monitoring and forecasting of air pollution in industrial environment. In: *Ecotoxicology and Environmental Safety*, 2024, vol. 283, 116856, 1-15, 0147-6513, <https://doi.org/10.1016/j.ecoenv.2024.116856>
9. Bezborodova, O.E., Bodin, O.N. and Polosin, V.G. Monitoring of Environmental Safety of the Territorial Technosphere on the Basis of Multi-Agent Technology. In: 2018 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon), Vladivostok, Russia, 2018, 1-6, doi: 10.1109/FarEastCon.2018.8602540
10. Zhai, C., Wang, Z. and Dou, J. Multi-agent coverage control for enhanced geohazard monitoring: a brief review. In: *Control Theory Technol.*, 2021, 19, 418-420, <https://doi.org/10.1007/s11768-021-00057-9>
11. Ghazi, S., Khadir, T., Dugdale, J. Multi-Agent Based Simulation of Environmental Pollution Issues: A Review. In: Corchado, J.M., et al. Highlights of Practical Applications of Heterogeneous Multi-Agent Systems. The PAAMS Collection. PAAMS 2014. Communications in Computer and Information Science, vol. 430. Springer, 2014, 13-21, https://doi.org/10.1007/978-3-319-07767-3_2
12. Monaco, R., Soares, A.J. A New Mathematical Model for Environmental Monitoring and Assessment. In: Gonçalves, P., Soares, A. (eds) From Particle Systems to Partial Differential Equations. PSPDE 2015. Springer Proceedings in Mathematics & Statistics, vol. 209, 2017, Springer, Cham, https://doi.org/10.1007/978-3-319-66839-0_13
13. Wooldridge, M. An introduction to multiagent systems. Second Edition, John Wiley & Sons, 2009. 453 p.
14. Horling, B. and Lesser, V. A survey of multi-agent organizational paradigms. In: *The Knowledge engineering review*, 2004, 19(4), 281-316, <https://hdl.handle.net/20.500.14394/10377> (20.XII.2024).
15. Vallejo, D., Castro-Schez, J. J., Glez-Morcillo, C., & Albusac, J. Multi-agent architecture for information retrieval and intelligent monitoring by UAVs in known environments affected by catastrophes. In: *Engineering Applications of Artificial Intelligence*, 2020, 87, 103243.
16. Oprea, M., Dragomir E. and Cărbureanu, M. On the use of collaborative intelligence in an agent-based environmental monitoring and analysis system. In: 15th International Conference on System Theory, Control and Computing, Sinaia, Romania, 2011, 1-6.
17. Kumar, A., Kim, H. and Hancke, G. P. Environmental Monitoring Systems: A Review. In: *IEEE Sensors Journal*, vol. 13, no. 4, April 2013, 1329-1339, doi: 10.1109/JSEN.2012.2233469
18. Erickson, P., Cline, M., Tirpankar N. and Henderson, T. Gaussian processes for multi-sensor environmental monitoring. In: The 2015 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), San Diego, CA, USA, 2015, 208-213, doi: 10.1109/MFI.2015.7295810
19. Gupta, R. D., and Bariar, A. Modelling of Gaseous Effluents by Implementing Gaussian Model under GIS Environment. In: *Journal of Environmental Science & Engineering*, 48(1), 2006, 21-26.
20. Pudykiewicz, J.A., & Koziol, A.S. The application of Eulerian models for air quality prediction and the evaluation of emission control strategies in Canada. In: *International journal of environment and pollution*, 16(1-6), 2001, 425-438, <https://doi.org/10.1504/IJEP.2001.000638>
21. Alessandrini, S., and Ferrero, E. A Lagrangian particle model with chemical reactions: application in real atmosphere. In: *International Journal of Environment and Pollution*, 2011, 47(1-4), 97-107, <https://doi.org/10.1504/IJEP.2011.047350>
22. Sung-Eun, K., Ferit, B. Application of CFD to environmental flows. In: *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 81, 1999, Issues 1-3, 145-158, [https://doi.org/10.1016/S0167-6105\(99\)00013-6](https://doi.org/10.1016/S0167-6105(99)00013-6)
23. Maier, A., Sharp, A., and Vagapov Y. Comparative analysis and practical implementation of the ESP32 microcontroller module for the internet of things. In: The 2017 Internet Technologies and Applications (ITA), Wrexham, UK, 2017, 143-148, doi: 10.1109/ITECHA.2017.8101926
24. Babiuch, M., Foltýnek P. and Smutný, P. Using the ESP32 Microcontroller for Data Processing. In: The 20th International Carpathian Control Conference (ICCC), Krakow-Wieliczka, Poland, 2019, 1-6, doi: 10.1109/CarpathianCC.2019.8765944
25. Cameron, N. ESP32 Microcontroller. In: *ESP32 Formats and Communication. Maker Innovations Series*. Apress, Berkeley, CA, 2023, 1-54, https://doi.org/10.1007/978-1-4842-9376-8_1
26. Lutz, M. Programming python. O'Reilly Media, Inc. 2010.

NOTĂ. Cercetările fac parte din tematica tezelor de doctorat realizate în cadrul proiectului 01-23p-018/02-48-2024 pe tema *Soluții inovative computaționale pentru predicția evoluției spațio-temporale a poluanților în ecosistemele acvatice de tip râu*, implementat de Departamentul Informatică și Ingineria Sistemelor, Universitatea Tehnică a Moldovei.