

Îmbunătățirea capacității de răspuns a municipalităților prin analiza imaginilor bazată pe AI în e-Government

Catalin VRABIE,

Școala Națională de Studii Politice și Administrative (SNSPA), București, România
catalin.vrabie@snsa.ro

Abstract

Obiectivul studiului este evaluarea modului în care tehnicile de Machine Learning pot fi integrate în administrația publică pentru a analiza imaginile transmise de cetățeni și pentru a accelera soluționarea sesizărilor urbane. Cercetarea pornește de la evoluția e-Government către etapa 3.0 și de la necesitatea extinderii interacțiunilor digitale dincolo de prelucrarea textului. Pe baza literaturii privind Artificial Intelligence (AI), Computer Vision și paradoxul Jevons, este formulată ipoteza că simplificarea transmiterii petițiilor poate crește cererea asupra instituțiilor, ceea ce impune soluții robuste și scalabile. Abordarea utilizată este un studiu de caz realizat într-o municipalitate din România, pe un dataset de 5.712 imagini anonimizate, colectate pe parcursul anului 2022 și repartizate în trei clase principale: degradări ale infrastructurii, probleme privind depozitarea deșeurilor și parcuri ilegale sau alte incidente. Imaginile au fost supuse etapelor de preprocessing și data annotation, apoi analizate printr-un workflow care combină Faster R-CNN pentru object detection și ResNet-50 pentru classification. Modelul a obținut o accuracy de 92,8%, o precision de 0,93 și un recall de 0,91, iar întregul workflow – de la analiză la generarea raportului și formularea răspunsului către cetățean – a fost executat în mai puțin de șapte secunde pentru fiecare caz. Rezultatele indică o reducere de aproximativ 98,5% a timpului de procesare față de procedurile manuale și arată că o infrastructură hardware accesibilă poate susține servicii municipale de dimensiune medie. Valoarea studiului constă în demonstrarea fezabilității unei componente de visual analytics pentru sistemele de e-petitioning, cu implicații pentru eficiență administrativă, transparență, participare civică și alocarea resurselor, dar și cu limite privind model generalization, calitatea imaginilor, protecția juridică și funcționarea la sarcini ridicate.

Cuvinte cheie: Machine Learning, digital governance, participare civică, inovare publică, Computer Vision.

1. Introducere

Adoptarea tehnologiilor digitale a transformat furnizarea serviciilor publice, care a evoluat de la sisteme electronice elementare către e-Government 3.0, etapă ce integrează tehnologii emergente precum Artificial Intelligence (AI), blockchain și Internet of Things (IoT) [1]. Această evoluție evidențiază necesitatea unor soluții inovatoare pentru îmbunătățirea participării cetățenilor, a furnizării serviciilor și a guvernanței.

Artificial Intelligence (AI) și Machine Learning (ML) reprezintă instrumente transformative pentru administrația publică, depășind aplicațiile bazate pe date textuale, precum chatbots, pentru a răspunde cererii tot mai mari de transmitere a imaginilor prin sistemele de servicii publice. Această schimbare răspunde unor provocări urbane în care datele vizuale sunt utilizate tot mai frecvent pentru semnalarea degradărilor infrastructurii, a activităților ilegale și a problemelor de mediu [2], [3].

Una dintre provocările centrale ale administrațiilor publice constă în menținerea unui echilibru între eficiență și volumul în creștere al interacțiunilor cu cetățenii [4]. Paradoxul Jevons oferă un cadru util pentru înțelegerea acestei dinamici. Potrivit acestuia, creșterea eficienței, adesea posibilă prin progres tehnologic, poate determina o majorare a cererii totale și poate suprasolicita chiar sistemele concepute pentru îmbunătățirea performanței [5]. În e-Government, ușurința transmiterii petițiilor sau reclamațiilor prin platforme

digitale poate spori numărul solicitărilor, fiind astfel necesare soluții robuste și scalabile. Machine Learning oferă însă o abordare promițătoare pentru gestionarea acestui paradox, prin simplificarea proceselor și creșterea capacității sistemelor administrative.

Trecerea la e-Government 3.0 marchează o etapă în care tehnologii precum ML nu mai constituie doar instrumente auxiliare, ci componente integrate ale guvernantei, capabile să sprijine funcționarii publici în îndeplinirea atribuțiilor. Prin încorporarea unor asemenea tehnici, administrațiile pot prelucra volume mari de date, identifica tipare și estima rezultate cu o precizie mai ridicată. De exemplu, modelele ML antrenate pe imagini transmise de cetățeni pot detecta și clasifica automat probleme precum gropile din carosabil, construcțiile neautorizate sau deteriorările infrastructurii publice. Aceste sisteme reduc presiunea asupra operatorilor umani și permit timpi de răspuns mai scurți, contribuind la satisfacția cetățenilor și la încrederea în instituțiile publice.

Studiul de față se concentrează asupra utilizării ML pentru analiza imaginilor în sistemele e-Government. Folosind date furnizate de o municipalitate din România, cercetarea examinează modul în care modelele ML pot îmbunătăți eficiența și acuratețea serviciilor publice. Punctul de plecare este premisa că cetățenii contemporani solicită o guvernare promptă, eficientă și transparentă, în timp ce instituțiile sunt adesea constrânse de bugete limitate și de ineficiențe administrative. Utilizarea ML pentru analiza imaginilor poate contribui la depășirea acestor limite și la soluționarea în timp util a problemelor semnalate.

Integrarea ML în administrația publică răspunde și complexității tot mai mari a interacțiunilor cu cetățenii. Spre deosebire de datele textuale, a căror analiză necesită Natural Language Processing (NLP), datele vizuale presupun tehnici avansate de Computer Vision, inclusiv object detection, image segmentation și image classification. Aceste tehnici permit sistemelor să „înțeleagă” datele vizuale într-o manieră apropiată de cea umană, prin identificarea caracteristicilor relevante și încadrarea lor în criterii predefinite [6]. De exemplu, modelul ML poate analiza imaginea unui drum degradat pentru a estima gravitatea problemei, localizarea și intervenția necesară. Capacitatea respectivă sporește precizia identificării și facilitează prioritizarea resurselor pentru problemele critice.

După cum va demonstra studiul, orientarea către sisteme de e-petitioning bazate pe imagini este compatibilă cu obiectivele e-Government 3.0, care urmărește structuri de guvernare mai incluzive, transparente și eficiente. Integrarea ML poate contribui la: (1) creșterea participării cetățenești, deoarece platformele mobile facilitează raportarea problemelor și implicarea în guvernare [7]; (2) îmbunătățirea furnizării serviciilor, prin procesarea mai rapidă și mai exactă a solicitărilor [8] și prin prestarea la timp a serviciilor [9]; și (3) consolidarea transparenței și a încrederii, întrucât sistemele automatizate pot furniza răspunsuri consecvente și imparțiale, reducând riscul erorilor sau al tratamentului părtinitor [10], [11].

Pentru ilustrarea acestor concepte este utilizat studiul de caz al unei municipalități din România aflate în avangarda adoptării tehnologiilor Smart City. Municipalitatea a pus la dispoziție datasets anonimizate alcătuite din texte și imagini transmise de cetățeni cu

privire la diverse probleme urbane. Datele au fost prelucrate cu modele ML actuale, demonstrând potențialul algoritmilor de a îmbunătăți furnizarea serviciilor publice. Rezultatele arată că ML poate reduce considerabil timpul și efortul necesare identificării și soluționării problemelor, sporind totodată acuratețea și consecvența răspunsurilor.

Studiul contribuie la literatura în dezvoltare privind e-Government 3.0 și rolul tehnologiilor emergente în guvernare. Prin accentul pus asupra analizei imaginilor, cercetarea evidențiază un domeniu de inovare relativ puțin abordat. În timp ce o mare parte a literaturii recente se concentrează asupra datelor textuale și a Natural Language Processing, lucrarea subliniază necesitatea extinderii aplicațiilor AI către datele vizuale. Această schimbare este deosebit de relevantă pentru Smart Cities, unde informația vizuală constituie frecvent baza interacțiunilor dintre cetățeni și administrația publică.

2. Analiza literaturii de specialitate

Evoluția rapidă a e-Government a fost caracterizată de adoptarea tehnologiilor emergente care îmbunătățesc serviciile publice și participarea cetățenilor. Inițial, sistemele s-au concentrat asupra interacțiunilor textuale și a furnizării electronice elementare a serviciilor – e-Government 1.0. Ulterior, rețelele sociale și tehnologiile Web 2.0 au introdus o dimensiune participativă – e-Government 2.0 [12]. În prezent, e-Government 3.0 valorifică tehnologii avansate precum AI, ML și IoT, cu potențialul unor transformări substanțiale ale proceselor de guvernare [13].

Aplicațiile bazate pe AI în administrația publică au primit o atenție considerabilă în literatura recentă, numeroase studii evidențiind rolul lor în automatizarea sarcinilor repetitive și în sporirea eficienței guvernării. Chen, Ahn și Wang [14], precum și van Noordt și Misuraca [15], arată potențialul AI de a îmbunătăți transparența, participarea cetățenilor și procesul decizional, iar Kolkman [16] discută utilitatea modelelor algoritmice în elaborarea politicilor publice. Totuși, cea mai mare parte a acestor cercetări s-a concentrat asupra analizei textului, acordând o atenție limitată rolului tot mai important al imaginilor în guvernare.

Progresele recente în Computer Vision – ramură a AI care permite interpretarea datelor vizuale de către mașini – ofera un potențial considerabil pentru e-Government. Object detection, image segmentation și visual classification sunt deja utilizate în planificarea urbană, monitorizarea mediului și siguranța publică. Chui, Roberts și Yee [17], precum și Ahn și Chen [18], discută beneficiile sociale ale utilizării Deep Learning, inclusiv pentru gestionarea infrastructurii publice. În mod similar, Zhao și colaboratorii [19] evidențiază efectele progresului digital, inclusiv ale visual analytics bazate pe AI, asupra obiectivelor de dezvoltare durabilă.

Rolul Computer Vision a fost examinat în contexte variate. Kumari, Agarwal și Mittal [20] au dezvoltat modele neuronale pentru cross-domain sentiment analysis, iar Yu și colaboratorii [21] au propus metode de îmbogățire cu cunoștințe pentru sarcini de clasificare, relevante atât pentru date textuale, cât și vizuale. În e-Government, aceste progrese pot fi aplicate imaginilor prin care cetățenii semnalează degradări ale infrastructurii sau riscuri de mediu, permițând clasificarea automată și prioritizarea

intervențiilor. În domeniul siguranței urbane, Zaki și colaboratorii [22] au utilizat încă din 2013 tehnici de Computer Vision pentru identificarea conflictelor dintre pietoni și vehicule și a încălcărilor regulilor de circulație într-o intersecție importantă din Vancouver. Analiza automată a secvențelor video a permis evaluări proactive și a furnizat date utile pentru măsuri corective și planificare urbană. Modele de Deep Learning au fost folosite și pentru cartografierea așezărilor informale [23], evaluarea spațiilor urbane verzi [24] și analize de siguranță, demonstrând versatilitatea acestor tehnologii în mediul urban.

E-petitioning, aplicație esențială a e-Government, s-a bazat în mod tradițional pe Natural Language Processing pentru analiza petițiilor textuale. Vrabie [13] și Hashem și colaboratorii [25] au analizat rolul AI în trierea și soluționarea petițiilor, subliniind avantajele automatizării pentru reducerea sarcinii administrative. Integrarea petițiilor bazate pe imagini rămâne însă insuficient explorată. Pe măsură ce tehnologiile mobile se generalizează, cetățenii transmit tot mai frecvent imagini împreună cu descrieri textuale sau în locul acestora. Tendința justifică integrarea tehnicilor de Computer Vision în sistemele e-Government.

Mai multe studii au demonstrat eficiența ML în automatizarea proceselor administrative. Davenport și Ronanki [26] discută utilizarea AI pentru automatizarea deciziilor de rutină în sectorul public, iar Scholl și Rodríguez Bolívar [27] evidențiază avantajele de reglementare și competitive ale adoptării AI în guvernare. Aceste studii oferă o bază pentru înțelegerea potențialului tehnologiei, dar nu tratează în mod adecvat provocările specifice datelor vizuale.

Cercetările recente în Computer Vision urmăresc creșterea acurateței și a interpretabilității modelelor de image analysis. Arhitecturi precum Residual Neural Network — ResNet [28], You Only Look Once – YOLO [29] și, mai recent, Joint Embedding Predictive Architecture – JEPA [30] au devenit repere pentru object detection și segmentation, permițând identificarea cu precizie ridicată a tiparelor și anomaliilor. În e-Government, aceste modele pot analiza imaginile transmise de cetățeni pentru a identifica gropi, construcții neautorizate sau probleme privind depozitarea deșeurilor. Automatizarea acestor sarcini poate îmbunătăți substanțial eficiența serviciilor publice.

Dincolo de progresele tehnice, literatura examinează implicațiile sociale ale AI și Computer Vision în guvernare. Eom și Lee [31] arată că transformarea guvernării digitale bazată pe AI poate contribui la soluționarea unor provocări sociale complexe, iar Sorrell [32] reanalizează paradoxul Jevons în contextul progresului tehnologic și posibilitatea ca cererea suplimentară să compenseze câștigurile de eficiență. Paradoxul este relevant pentru e-Government, deoarece transmiterea facilă a petițiilor bazate pe imagini poate crește volumul solicitărilor și necesitatea unor soluții scalabile.

În contextul Smart Cities, Vlahovic și Vracic [33], respectiv Twizeyimana și Andersson [34], subliniază rolul guvernării digitale în îmbunătățirea managementului urban. Tehnicile de Computer Vision sunt utilizate pentru monitorizarea mediului urban, detectarea anomaliilor și anticiparea nevoilor de întreținere. Madan și Ashok [35] consideră maturitatea guvernării un factor critic pentru adoptarea AI, în timp ce Ahn și

Chen [18] evidențiază percepția favorabilă a angajaților publici asupra tehnologiilor AI, inclusiv în sarcinile bazate pe date vizuale.

Discursul românesc privind e-Government 3.0, reflectat inclusiv în lucrări publicate pe platforma scrd.eu, evidențiază rolul transformator al AI pentru eficiența administrației și bunăstarea socială. Vrabie [36] subliniază capacitatea AI de a stimula inovarea în Smart Cities și de a îmbunătăți participarea cetățenilor și capacitatea de răspuns instituțională. Sarcea [37] analizează intersecția critică dintre AI și cybersecurity și susține necesitatea unor mecanisme robuste pentru protejarea infrastructurilor digitale și a integrității datelor. În privința dimensiunilor culturale ale adoptării e-Government, Iqbal și Genie [38], împreună cu Schachtner [39], [40], arată că normele sociale și factorii culturali locali influențează intenția cetățenilor de a utiliza platformele publice digitale, ceea ce impune proiectarea unor servicii incluzive și adaptate contextului. Impactul transversal al digitalizării și AI este ilustrat și în educație [41], people analytics [42] și smart healthcare [43]. Acest ansamblu de cercetări conturează o perspectivă în care e-Government 3.0 consolidează capacitatea instituțională și se aliniază principiilor sustenabilității, transparenței și guvernantei centrate pe cetățean [44].

Revista Public Policy and Administration a publicat, la rândul său, cercetări privind integrarea instrumentelor digitale în administrația publică, potențialul lor transformator și provocările asociate. În articolul „Evolution of E-government in the States of the Eastern Border of the European Union”, Žilinskas [45] analizează diferențele dintre statele membre ale Uniunii Europene și rolul progresului tehnologic în îmbunătățirea serviciilor publice. Žilionienė [46] oferă o analiză timpurie a documentelor strategice care au orientat dezvoltarea e-Government, evidențiind importanța planificării. Revista a examinat, de asemenea, implicațiile etice și practice ale utilizării tehnologiei în guvernanta și necesitatea unui echilibru între inovare, protejarea încrederii publice și răspundere [47]. Aceste contribuții oferă repere utile pentru decidenții și practicienii care urmăresc utilizarea AI în interes public.

Deși cercetarea existentă s-a concentrat în principal asupra datelor textuale, răspândirea interacțiunilor bazate pe imagini impune o perspectivă mai largă. Studiul de față urmărește să acopere această lacună prin examinarea tehnicilor de Computer Vision în e-Government. Integrarea visual analytics în sistemele de e-petitioning poate crește capacitatea administrațiilor de a procesa și soluționa problemele semnalate de cetățeni, susținând o guvernanta mai eficientă și mai incluzivă. Secțiunile următoare prezintă studiul de caz și metodologia propusă pentru image analysis prin ML în sistemele administrației publice.

3. Materiale și metode

Studiul urmărește să demonstreze aplicarea tehnicilor de Machine Learning la prelucrarea și analiza imaginilor, pentru îmbunătățirea sistemelor e-Government și, în special, a gestionării petițiilor cetățenilor. Pornind de la inițiativa mai veche Civic Alert [2], [48], este propus un sistem extins, care integrează tehnici avansate de Computer Vision și Natural Language Processing. Etapele procesului sunt prezentate în continuare:

- Colectarea și anonimizarea datelor — datasets au fost obținute de la o municipalitate din România cunoscută pentru inițiativele sale avansate de Smart City. Datele acoperă un an complet, respectiv 2022:
 - Imagini – 5.712 fotografii asociate cu date de localizare, prin care cetățenii au documentat probleme ale infrastructurii publice, precum drumuri deteriorate, parcări ilegale și depozitarea necorespunzătoare a deșeurilor.
 - Date textuale – 12.935 de înregistrări constând în reclamații, sugestii și întrebări, inclusiv descrieri care însoțesc imaginile și petiții textuale independente, transmise prin e-mail, aplicații mobile și platforme web. Studiul de față se concentrează exclusiv asupra analizei imaginilor; metodologia și rezultatele privind textul sunt prezentate în articolul „E-Government 3.0: An AI Model to Use for Enhanced Local Democracies” [13].
- Descrierea și distribuția datasetului – datele au fost organizate în trei clase principale, în funcție de problemele raportate:
 - Degradări ale infrastructurii – 45%, incluzând gropi, trotuare deteriorate și corpuri de iluminat stradal defecte;
 - Depozitarea deșeurilor – 30%, incluzând abandonarea necorespunzătoare a gunoiului, depozite ilegale și containere supraaglomerate;
 - Parcări ilegale și alte situații – 25%, incluzând vehicule care blochează spațiile publice, mașini abandonate, graffiti și arbori sau crengi căzute.
- Condiții de mediu și vizuale – datasetul a fost analizat și din perspectiva condițiilor în care au fost realizate imaginile:
 - Condiții de iluminare – aproximativ 35% dintre imagini au fost realizate în lumină redusă sau pe timp de noapte, obligând modelul să gestioneze variații ale luminozității și contrastului. Restul imaginilor au fost captate în timpul zilei, în condiții diferite de umbră.
 - Condiții meteorologice – circa 20% dintre imagini au fost realizate în ploaie, ninsoare sau ceață, ceea ce a introdus dificultăți suplimentare, precum reflexii, neclaritate și obstrucții.
 - Aglomerare și ocluzie – aproape 25% dintre imagini conțin scene aglomerate, obiecte suprapuse sau probleme vizibile numai parțial, reflectând complexitatea mediului urban real.
 - Variație sezonieră – întrucât datele acoperă întregul an 2022, sunt reprezentate toate anotimpurile, inclusiv carosabil umed toamna și infrastructură acoperită de zăpadă iarna.

Diversitatea datasetului a generat dificultăți precum distingerea între probleme asemănătoare – de exemplu, suprafețe umede și gropi – și identificarea incidentelor în imagini complexe sau de calitate redusă. Tocmai aceste dificultăți reproduc situațiile reale întâlnite de sistemele municipale și fac din dataset un benchmark adecvat pentru testarea soluției propuse.

- Preprocessing – această etapă a asigurat curățarea, standardizarea prin TensorFlow/Keras [49] și anonimizarea datelor:

- Resizing, cropping and normalization – imaginile au fost redimensionate și decupate la 256×256 pixeli, pentru standardizarea dimensiunilor de intrare, apoi normalizate în intervalul $[0, 1]$.
- De-noising – au fost aplicate filtre precum Gaussian blur.
- Data augmentation – rotation, flipping și zoom au fost utilizate pentru sporirea variabilității datasetului și a robusteții modelului.




Fig. 1. Transformarea imaginilor — preprocessing (reprezentare vizuală)

Sursa: Autorul.

Notă: Calculatoarele interpretează imaginile ca date. Fiecare imagine este reprezentată prin matrice de numere, în care fiecărui pixel îi corespund coordonatele și valorile de culoare pentru canalele RGB. De exemplu, o imagine de 256×256 pixeli poate fi reprezentată printr-un vector cu 327.680 de valori. La compararea imaginilor, sistemul compară de fapt acești vectori numerici. Figura oferă o reprezentare vizuală a datelor asociate fiecărei imagini.

- Feature extraction – pentru a permite algoritmilor ML să interpreteze datele de intrare, au fost aplicate tehnici de feature extraction. Faster R-CNN și ResNet au fost utilizate în roluri complementare în workflow-ul de analiză a imaginilor:
 - Region proposals – cu ajutorul Faster R-CNN au fost identificate regions of interest (ROIs) relevante pentru clasificarea incidentelor. Acestea sunt zone localizate care pot conține probleme urbane, precum gropi sau deșeuri. Object detection a fost esențială pentru scenele complexe, cu mai multe probleme sau cu fundal aglomerat.
 - Convolutional features – o Convolutional Neural Network (CNN) pre-trained pe ImageNet, respectiv ResNet-50 [50], a fost utilizată pentru extragerea marginilor, formelor și texturilor. ROIs identificate de Faster R-CNN au fost prelucrate pentru obținerea high-level features și clasificarea problemelor în categorii precum „degradări ale infrastructurii”, „parcări ilegale” și „depozitarea deșeurilor”. Modelul ResNet a fost fine-tuned pe dataset pentru creșterea acurateței.

Integrarea Faster R-CNN pentru object detection și a ResNet pentru clasificare a produs un workflow robust, capabil să realizeze eficient ambele sarcini.




Fig. 2. Feature extraction (reprezentare vizuală)

Sursa: Autorul.

- Data annotation – o echipă de specialiști, alcătuită din analiști ai serviciilor publice municipale, a adnotat manual o parte a datasetului pentru crearea training and validation labels. Categoriile au fost „degradări ale infrastructurii”, „parcări ilegale” și „depozitarea deșeurilor”.
- Model development – un model ResNet fine-tuned a fost antrenat pentru clasificarea problemelor pe baza caracteristicilor vizuale extrase din imaginile transmise de cetățeni, după preprocessing prin TensorFlow/Keras. Arhitectura a inclus convolutional layers pentru feature extraction și fully connected layers pentru clasificare.
- Model training and validation:
 - Training – datele au fost împărțite într-un training set de 4.570 de imagini (80%) și un validation set de 1.142 de imagini (20%). În timpul trainingului au fost folosite date augmentate pentru prevenirea overfitting.
 - Hyperparameter optimization – learning rate, batch size și number of epochs au fost optimizate prin grid search.
 - Evaluation metrics – modelele au fost evaluate prin accuracy, precision și recall. Confusion matrices au fost utilizate pentru analiza clasificărilor eronate.

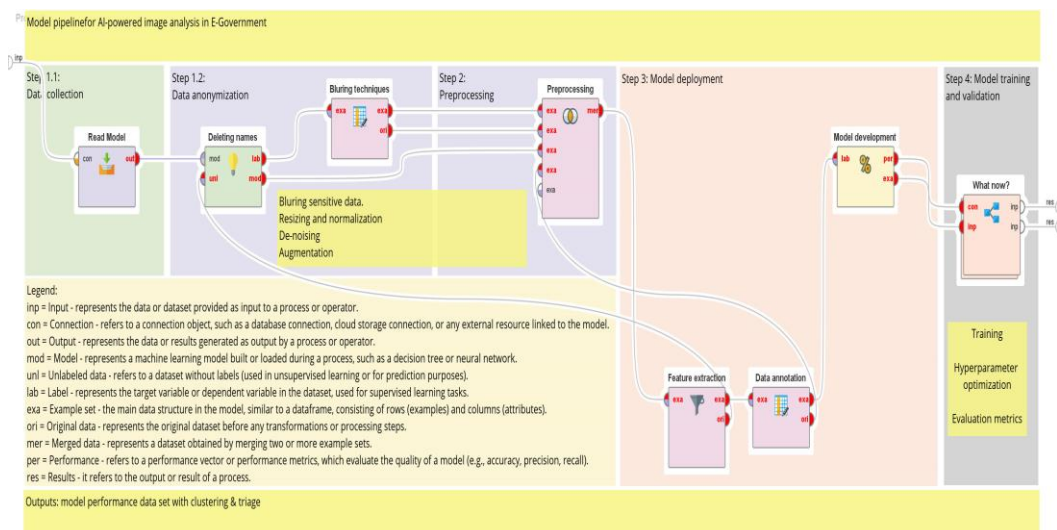


Fig. 3. Model workflow (reprezentare vizuală)
Sursa: Autorul.

4. Rezultate

Studiul a testat eficiența și acuratețea unui image classification model integrat într-un sistem e-Government, destinat analizării datelor vizuale transmise de cetățeni și automatizării acțiunilor ulterioare. Sistemul prelucrează sesizările privind problemele urbane prin analiza imaginilor, clasificarea incidentelor identificate, generarea documentelor relevante pentru autoritățile competente și comunicarea promptă a soluțiilor către cetățeni. Rezultatele prezentate mai jos au fost obținute exclusiv pe un laptop Dell XPS 9510, cu procesor Intel Core i9-11900H din generația a 11-a, la 2,50 GHz, placă grafică NVIDIA GeForce RTX 3050 Ti, 32 GB RAM și sistem de operare Windows 11 Pro pe 64 de biți.

Modelul de clasificare, bazat pe arhitectura Faster R-CNN, a fost antrenat și evaluat pe un dataset de 5.712 imagini transmise de cetățeni. Sistemul, implementat și testat exclusiv pe configurația menționată, a demonstrat următoarele capabilități:

- Identificarea exactă a problemelor urbane:
 - Modelul a detectat și clasificat probleme uzuale precum gropi, depozitarea necorespunzătoare a deșeurilor, parcuri ilegale, arbori sau crengi căzute, animale abandonate, pierderi de apă, vehicule abandonate, graffiti, acte de vandalism și alte deteriorări ale infrastructurii publice. Pentru analiză, acestea au fost grupate în trei clase principale: degradări ale infrastructurii, depozitarea deșeurilor și parcuri ilegale/alte situații. Pentru fiecare clasă au fost calculate accuracy, precision, recall și F1-score.
 - Pe validation set a fost obținută o classification accuracy de 92,8%, calculată ca raport între predicțiile corecte și numărul total de predicții. Precision a fost 0,93, iar recall 0,91.

- Rata clasificărilor eronate a fost redusă, erorile fiind concentrate în imaginile ambigue vizual, de exemplu cele realizate în lumină slabă sau în scene foarte aglomerate.

Tabelul 1. Performanța modelului pe clase

CLASS	PRECISION (%)	RECALL (%)	F1-SCORE (%)
Degradări ale infrastructurii	94	92	93
Depozitarea deșeurilor	91	90	91
Parcări ilegale / Alte situații	89	85	87

Sursa: elaborarea autorului.

Rezultatele arată că modelul are o performanță ușor mai redusă pentru clasa „Parcări ilegale / Alte situații”, probabil din cauza variabilității interne mai mari și a ambiguității vizuale a imaginilor din această categorie.

- Rapid data processing:
 - Pe laptopul Dell XPS 9510, fiecare imagine a fost prelucrată în medie în 3,1 secunde, inclusiv identificarea regions of interest (ROIs) și generarea rezultatului.
 - Workflow-ul complet — clasificare, generarea raportului și comunicarea cu cetățeanul – a fost executat în mai puțin de șapte secunde pentru fiecare caz.
- Generarea automată a rapoartelor – rezultatele clasificării sunt integrate într-un automated workflow cu următoarele funcționalități:
 - Generating actionable reports – după detectarea unei probleme, modelul produce un raport adaptat autorității responsabile. Rapoartele sunt formate în conformitate cu cerințele administrative prin funcția „compare and comply”, reducând necesitatea intervenției umane [51].
 - Răspunsul către cetățean – simultan, sistemul redactează un mesaj care confirmă primirea sesizării și descrie măsurile inițiate, folosind aceeași funcție de verificare a conformității.
- Gestionarea mai bună a timpului – automatizarea analizei și a răspunsului, realizată pe configurația hardware menționată, a produs îmbunătățiri importante în utilizarea timpului și a muncii. Procedura tradițională necesita în medie opt minute pentru analizarea imaginii, identificarea problemei și pregătirea răspunsului; sistemul ML a redus durata la mai puțin de șapte secunde, ceea ce corespunde unei economii de aproximativ 98,5%. Personalul municipal poate astfel să se concentreze asupra sarcinilor strategice, nu asupra activităților administrative repetitive.
- Performanța pe hardware limitat – laptopul Dell XPS 9510 a executat toate calculele fără echipamente externe suplimentare. În condiții normale, sistemul a prelucrat până la 500 de cazuri pe oră, demonstrând că această configurație poate fi utilizată de municipalități de dimensiune medie.

- Scalabilitatea – desi configurația este adecvată pentru municipalități mici sau servicii e-Government locale, modelul permite extinderea workflow-ului către volume mai mari prin ajustări moderate ale batch processing și ale model optimization.

Rezultatele indică faptul că o soluție hardware accesibilă poate fi suficientă pentru implementarea unui sistem municipal bazat pe ML și orientat către image classification. Pe măsură ce volumul datelor crește, trebuie însă luate în considerare configurații mai performante. Capacitatea sistemului de a procesa eficient sesizările, de a genera rezultate operaționale și de a comunica cu cetățenii arată potențialul de transformare a workflow-urilor administrative. Reducerea timpului de procesare, creșterea capacității de răspuns și posibilitatea extinderii fac abordarea potrivită pentru municipalitățile care urmăresc servicii mai bune și o utilizare mai eficientă a resurselor.

5. Discuții

Studiul a demonstrat integrarea eficientă a tehnicilor de Machine Learning, în special a image classification, în workflow-urile e-Government destinate gestionării problemelor urbane. Printr-o arhitectură robustă, rulată pe hardware disponibil pe scară largă, soluția propusă a obținut îmbunătățiri importante ale eficienței temporale și ale utilizării muncii și poate susține o participare cetățenească mai intensă. Capacitatea de a prelucra imagini, de a genera actionable reports și de a comunica cu cetățenii evidențiază potențialul unei furnizări scalabile și rentabile a serviciilor publice.

Machine Learning poate avea un rol esențial în e-Government prin automatizarea practicilor administrative, simplificarea workflow-urilor și consolidarea încrederii cetățenilor prin răspunsuri exacte și furnizate la timp. Extinderea proiectului inițial Civic Alert demonstrează rolul transformator al sistemelor bazate pe AI în guvernanta contemporană.

Scalabilitatea sistemului arată capacitatea AI de a susține data-driven governance și de a optimiza alocarea resurselor. Prelucrarea eficientă a volumelor mari și analiza metadatelor pot genera actionable insights utile pentru planificarea urbană și pentru gestionarea perioadelor cu cerere ridicată.

Implementarea unor asemenea tehnologii presupune însă soluționarea unor probleme practice și etice: capacitatea hardware, optimizarea sistemului, pregătirea cetățenilor și evitarea inegalităților de acces la tehnologie. Studiul indică aplicabilitatea mai largă a AI în teoria administrației publice, oferind un cadru pentru implementări scalabile și contribuind la dezbateră privind data-driven și ethical decision-making.

6. Limitări

Deși rezultatele sunt promițătoare, studiul prezintă mai multe limite care trebuie avute în vedere în cercetările și dezvoltările ulterioare.

- Calitatea și ambiguitatea imaginilor – fotografiile de calitate slabă sau ambigue au produs ocazional clasificări eronate ori au necesitat validare manuală. Ajustarea luminozității (brightness adjustment) și reducerea zgomotului (noise reduction) pot îmbunătăți performanța, iar informarea cetățenilor cu privire la realizarea unor imagini clare poate diminua problema.
- High-resolution image processing – imaginile 4K au determinat o creștere moderată a cerințelor de calcul și a timpului de procesare. Resizing a redus acest efect fără pierderi semnificative de acuratețe, însă sunt necesare optimizări suplimentare.
- Evaluarea pe un singur train-validation split – acuratețea de 92,8% a fost calculată pe baza unei singure împărțiri a datelor și poate să nu surprindă pe deplin model generalization. Limitarea este relevantă având în vedere varietatea restrânsă a condițiilor urbane, de iluminare și meteorologice. Dimensiunea datasetului și caracterul exploratoriu al cercetării nu au permis utilizarea unui independent test set. Versiunile viitoare trebuie să includă un asemenea set pentru o evaluare mai sigură în condiții nevăzute.
- Scalabilitatea sistemului – laptopul Dell XPS 9510 a funcționat bine pentru sarcinile analizate, dar a prezentat thermal throttling în condiții de sarcină maximă susținută (sustained peak load). Pentru performanță constantă este necesar hardware mai puternic.
- Model generalization – performanța în alte municipalități sau regiuni, cu alte caracteristici urbane, nu a fost testată. Extinderea training datasets cu situații și tipuri de incidente mai diverse ar crește adaptabilitatea și robustețea.
- Considerente juridice și etice – comunicarea automată cu cetățenii trebuie formulată cu atenție pentru a evita interpretările eronate, în special în contexte juridice. Modulele de Natural Language Processing necesită perfecționare pentru a asigura claritatea și conformitatea cu standardele administrative.
- Dependența de hardware – configurația utilizată a fost suficientă pentru acest studiu, dar municipalitățile care gestionează volume mai mari pot necesita echipamente mai performante sau sisteme de calcul distribuit.

7. Direcții viitoare de cercetare

În primul rând, studiul trebuie interpretat ca un proof-of-concept, nu ca o soluție municipală complet operațională. Realizarea unei versiuni finale ar necesita colaborarea unei echipe dedicate dezvoltării, testării și perfecționării sistemului.

În al doilea rând, pentru depășirea limitelor identificate, cercetarea viitoare trebuie să urmărească următoarele direcții:

- Model optimization – creșterea eficienței și acurateței, în special pentru imaginile ambigue sau de înaltă rezoluție, prin algoritmi și preprocessing methods mai avansate.
- Testarea extinsă – implementarea în contexte municipale diverse pentru evaluarea adaptabilității și scalabilității.
- Educația cetățenilor – elaborarea unor ghiduri și materiale care să ajute cetățenii să transmită date clare și relevante.
- Îmbunătățirea infrastructurii – analizarea modernizărilor hardware și a cloud-based solutions pentru datasets mai mari și sarcini susținute.

În pofida limitelor, cercetarea oferă o bază solidă pentru integrarea AI-driven image classification în workflow-urile e-Government. Abordarea provocărilor identificate poate conduce la versiuni mai eficiente, mai scalabile și mai satisfăcătoare pentru cetățeni, favorizând adoptarea pe scară largă a tehnologiilor e-Government avansate.

8. Concluzii

Integrarea tehnicilor ML actuale în workflow-urile e-Government ilustrează impactul transformator al AI asupra furnizării serviciilor publice. Studiul arată că AI poate crește eficiența administrativă și capacitatea de răspuns prin identificarea problemelor urbane, generarea rapoartelor și transmiterea rapidă a unui feedback către cetățeni, cu acuratețe ridicată și folosind hardware disponibil pe scară largă.

Rezultatele confirmă că modelul a prelucrat cu succes imagini privind gropi, deșeuri, parcuri ilegale și infrastructură deteriorată, obținând o classification accuracy de aproximativ 93%. Întregul workflow, de la analiza imaginii la generarea raportului și notificarea cetățeanului, a fost finalizat în medie în șapte secunde pentru fiecare caz. Față de procedura manuală, care poate dura opt minute, aceasta reprezintă o reducere de aproximativ 98,6% a timpului de procesare.

Sistemul automatizat nu doar simplifică workflow-urile, ci poate îmbunătăți și participarea cetățenească prin răspunsuri imediate și personalizate. Cetățenii pot primi confirmarea înregistrării, detalii despre măsurile inițiate și actualizări asupra stadiului sesizării, ceea ce sprijină transparența și încrederea. În paralel, departamentele municipale pot primi rapoarte detaliate, conforme cu cerințele administrative și pregătite pentru utilizare.

Sistemul a demonstrat și capacitate de extindere, procesând până la 500 de cazuri pe oră pe laptopul Dell XPS 9510. O asemenea performanță indică posibilitatea gestionării unor volume ridicate, inclusiv în perioade de vârf, cum sunt situațiile ulterioare dezastrelor. Analiza metadatelor poate amplifica utilitatea prin generarea de heatmaps și data-driven insights, necesare prioritizării resurselor și planificării urbane.

Adoptarea tehnologiei produce și beneficii pentru utilizarea muncii. Automatizarea sarcinilor repetitive reduce dependența de echipe administrative numeroase și permite

personalului să se concentreze asupra deciziilor complexe și a inițiativelor strategice. Schimbarea poate îmbunătăți calitatea serviciilor și reduce costurile operaționale, făcând soluția viabilă pentru municipalități.

Studiul a identificat însă dificultăți. Imaginile de înaltă rezoluție sau de calitate slabă au produs uneori întârzieri ori clasificări eronate, necesitând intervenție manuală. Sunt importante îmbunătățirea continuă a preprocessing și educarea cetățenilor în privința imaginilor transmise. Totodată, funcționarea susținută la peak load a produs uneori thermal throttling, ceea ce justifică optimizarea workload management.

În ansamblu, cercetarea evidențiază potențialul transformator al ML-powered image processing în e-Government. Câștigurile de eficiență, acuratețe și satisfacție a cetățenilor susțin fezabilitatea unor soluții pentru o guvernare urbană îmbunătățită. Prin utilizarea unui hardware accesibil, municipalitățile pot implementa sisteme scalabile și rentabile, capabile să abordeze proactiv problemele urbane. Cercetarea viitoare trebuie să urmărească accelerarea procesării, extinderea capacităților către probleme mai complexe și creșterea robusteții în contexte operaționale diverse. Adoptarea unor asemenea sisteme constituie un pas important către e-Government 3.0, caracterizat prin transparență, eficiență și orientare către cetățean.

Referințe

- [1] C. Vrabie and E. Dumitrascu, Smart cities: de la idee la implementare, sau, despre cum tehnologia poate da strălucire mediului urban. Bucharest, Romania: Universul Academic, 2018.
- [2] Digi24, „Civic Alert, o aplicație de mobil pentru sesizări, reclamații, petiții sau inițiative civice,” Nov. 23, 2015. [Online]. Available: <https://www.digi24.ro/stiri/sci-tech/lumea-digitala/civic-alert-o-aplicatie-de-mobil-pentru-sesizari-reclamatii-petitii-sau-initiative-civice-460270>. [Accessed: Dec. 9, 2024].
- [3] C. Vrabie, AI: de la idee la implementare. Traseul sinuos al Inteligenței Artificiale către maturitate. Bucharest, Romania: Pro Universitaria, 2024.
- [4] M. Glaukande and L. B. T. Mzini, „Evaluation of participatory governance for enhancing quality of local governments: Towards a new model,” Smart Cities and Regional Development Journal, 2019. [Online]. Available: <https://scrd.eu/index.php/scrd/article/view/50>.
- [5] B. Alcott, „Jevons’ paradox,” Ecological Economics, 2005, doi: 10.1016/j.ecolecon.2005.03.020.
- [6] C. Vrabie, „Artificial Intelligence Promises to Public Organizations and Smart Cities,” in Digital Transformation: 14th PLAIS EuroSymposium on Digital Transformation, Sopot, Poland, 2022, pp. 3–14. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-031-23012-7_1.
- [7] C. Vrabie, „Book Review: ‘Grown Up Digital: How the Net Generation is Changing Your World’ by Don Tapscott,” HOLISTICA Journal of Business and Public Administration, vol. 6, no. 1, 2015. [Online]. Available: <https://ssrn.com/abstract=2673666>.
- [8] A. F. Rahmat, C. Vrabie, and G. B. Soesilo, „Exploring the Cybercrime Prevention Campaign on Twitter: Evidence from the Indonesian Government,” Smart Cities and Regional Development, vol. 7, no. 2, pp. 9–24, 2023.
- [9] A. Tirziu and C. Vrabie, „Living Labs – Instruments of Social Innovation in Rural Areas,” in Proc. Central and Eastern European e|Dem and e|Gov Days, 2017. [Online]. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2992192.
- [10] B. Zankova, „Smart societies, gender and the 2030 spotlight – are we prepared?,” Smart Cities and Regional Development, vol. 5, no. 3, pp. 63–76, 2021.
- [11] A.-M. Tirziu and C. Vrabie, „NET Generation. Thinking outside the box by using online learning methods,” MPRA Paper, 2016. [Online]. Available: https://mpra.ub.uni-muenchen.de/77708/1/MPRA_paper_77708.pdf.

- [12] R. Garuckas and A. Kaziliūnas, „Analysis of the E-Government and Public Sector Interaction in Lithuania,” *Public Policy and Administration*, 2008. [Online]. Available: <https://vpa.ktu.lt/index.php/PPA/article/view/26967>.
- [13] C. Vrabie, „E-Government 3.0: An AI Model to Use for Enhanced Local Democracies,” *Sustainability*, vol. 15, 2023, doi: 10.3390/su15129572.
- [14] Y.-C. Chen, M. J. Ahn, and Y.-F. Wang, „Artificial Intelligence and Public Values: Value Impacts and Governance in the Public Sector,” *Sustainability*, vol. 15, 2023, doi: 10.3390/su15064796.
- [15] C. van Noordt and G. Misuraca, „Artificial intelligence for the public sector: Results of landscaping the use of AI in government across the European Union,” *Government Information Quarterly*, 2022, doi: 10.1016/j.giq.2022.101714.
- [16] D. Kolkman, „The usefulness of algorithmic models in policy making,” *Government Information Quarterly*, 2020, doi: 10.1016/j.giq.2020.101488.
- [17] M. Chui, R. Roberts, and L. Yee, „Generative AI is here: How tools like ChatGPT could change your business,” *McKinsey & Company*, Dec. 20, 2022. [Online]. Available: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/generative-ai-is-here-how-tools-like-chatgpt-could-change-your-business>. [Accessed: Nov. 25, 2024].
- [18] M. J. Ahn and Y.-C. Chen, „Digital transformation toward AI-augmented public administration: The perception of government employees and the willingness to use AI in government,” *Government Information Quarterly*, 2022, doi: 10.1016/j.giq.2021.101664.
- [19] S. Zhao, Y. Zhang, H. Iftikhar, A. Ullah, J. Mao, and T. Wang, „Dynamic Influence of Digital and Technological Advancement on Sustainable Economic Growth in Belt and Road Initiative (BRI) Countries,” *Sustainability*, vol. 14, 2022, doi: 10.3390/su142315782.
- [20] S. Kumari, B. Agarwal, and M. Mittal, „A Deep Neural Network Model for Cross-Domain Sentiment Analysis,” *International Journal of Information System Modeling and Design*, 2021, doi: 10.4018/IJISMD.2021040101.
- [21] H. Yu, G. Lu, Q. Cai, and Y. Xue, „A KGE Based Knowledge Enhancing Method for Aspect-Level Sentiment Classification,” *Mathematics*, vol. 10, 2022, doi: 10.3390/math10203908.
- [22] M. Zaki, T. Sayed, A. Tageldin, and M. Hussein, „Application of Computer Vision to Diagnosis of Pedestrian Safety Issues,” *Transportation Research Record*, pp. 75–84, 2013, doi: 10.3141/2393-09.
- [23] M. Wurm, T. Stark, X. X. Zhu, M. Weigand, and H. Taubenböck, „Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks,” *ISPRS Journal of Photogrammetry and Remote Sensing*, pp. 59–69, 2019, doi: 10.1016/j.isprsjprs.2019.02.006.
- [24] M. Helbich, Y. Yao, J. Zhang, P. Liu, and R. Wang, „Using deep learning to examine street view green and blue spaces and their associations with geriatric depression in Beijing, China,” *Environment International*, pp. 107–117, 2019, doi: 10.1016/j.envint.2019.02.013.
- [25] I. A. T. Hashem, R. S. A. Usmani, M. S. Almutairi, A. O. Ibrahim, A. Zakari, F. Alotaibi, S. M. Alhashmi, and H. Chiroma, „Urban Computing for Sustainable Smart Cities: Recent Advances, Taxonomy, and Open Research Challenges,” *Sustainability*, vol. 15, 2023, doi: 10.3390/su15053916.
- [26] T. H. Davenport and R. Ronanki, „Artificial Intelligence for the Real World,” *Harvard Business Review*, Jan.–Feb. 2018. [Online]. Available: <https://hbr.org/2018/01/artificial-intelligence-for-the-real-world>. [Accessed: Nov. 25, 2024].
- [27] H. J. Scholl and M. P. Rodríguez Bolívar, „Regulation as both enabler of technology use and global competitive tool: The Gibraltar case,” *Government Information Quarterly*, 2019, doi: 10.1016/j.giq.2019.05.003.
- [28] W. Gu, S. Bai, and L. Kong, „A review on 2D instance segmentation based on deep neural networks,” *Image and Vision Computing*, 2022, doi: 10.1016/j.imavis.2022.104401.
- [29] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, „You Only Look Once: Unified, Real-Time Object Detection,” *arXiv:1506.02640*, 2015. [Online]. Available: <https://arxiv.org/abs/1506.02640>.
- [30] Y. LeCun, „V-JEPA: The next step toward Yann LeCun’s vision of advanced machine intelligence (AMI),” *Meta AI*, Feb. 15, 2024. [Online]. Available: <https://ai.meta.com/blog/v-jepa-yann-lecun-ai-model-video-joint-embedding-predictive-architecture/>. [Accessed: Nov. 25, 2024].
- [31] S.-J. Eom and J. Lee, „Digital government transformation in turbulent times: Responses, challenges, and future direction,” *Government Information Quarterly*, 2022, doi: 10.1016/j.giq.2022.101690.
- [32] S. Sorrell, „Jevons’ Paradox revisited: The evidence for backfire from improved energy efficiency,” *Energy Policy*, 2009, doi: 10.1016/j.enpol.2008.12.003.

- [33] N. Vlahovic and T. Vracic, „An Overview of E-Government 3.0 Implementation,” in *Encyclopedia of Information Science and Technology*, 3rd ed., M. Khosrow-Pour, Ed. IGI Global, 2014, doi: 10.4018/978-1-4666-5888-2.ch263.
- [34] J. D. Twizeyimana and A. Andersson, „The public value of E-Government – A literature review,” *Government Information Quarterly*, 2019, doi: 10.1016/j.giq.2019.01.001.
- [35] R. Madan and M. Ashok, „AI adoption and diffusion in public administration: A systematic literature review and future research agenda,” *Government Information Quarterly*, 2023, doi: 10.1016/j.giq.2022.101774.
- [36] C. Vrabie, „Promisiunile Inteligenței Artificiale (AI) Administrației Publice și Orașelor Inteligente,” in *Sustainability and Innovation*, C. Vrabie, Ed. Bucharest, Romania: Pro Universitaria, 2023, pp. 9–46. [Online]. Available: <https://scrd.eu/index.php/scic/article/view/482>.
- [37] O.-A. Sarcea, „AI & Cybersecurity – connection, impacts, way ahead,” in *Security Above All!*, C. Vrabie, Ed. Bucharest, Romania: Pro Universitaria, 2024, pp. 17–26. [Online]. Available: <https://www.scrd.eu/index.php/trust/article/view/543>.
- [38] M. Iqbal and C. Genie, „Local culture and behaviour intention to adopt e-government,” *Smart Cities and Regional Development*, pp. 19–25, 2022. [Online]. Available: <https://www.scrd.eu/index.php/scrd/article/view/118>.
- [39] C. Schachtner, „Smart government in local adoption – Authorities in strategic change through AI,” *Smart Cities and Regional Development Journal*, vol. 5, no. 3, pp. 53–61, 2021.
- [40] C. Schachtner, „Wise Governance – Elements of the digital strategies of municipalities,” *Smart Cities and Regional Development*, vol. 6, no. 2, pp. 23–29, 2022.
- [41] D. Iancu, C. Vrabie, and M. Ungureanu, „Is Blended Learning Here to Stay? Public Administration Education in Romania,” in *Central and Eastern European eDem and eGov Days*, Budapest, 2021, doi: 10.24989/ocg.v341.4.
- [42] Ž. Stankevičiūtė and V. Kumpikaitė-Valiūnienė, „Educational Innovation through Information and Communication Technologies: The Case of People Analytics Course,” *Public Policy and Administration*, pp. 321–331, 2023, doi: 10.5755/j01.ppaa.22.3.34299.
- [43] R. D. Zota and A. Clim, „Smart healthcare for smart cities,” in *Smart Cities International Conference (SCIC) Proceedings*, 2023, pp. 177–183. [Online]. Available: <https://scrd.eu/index.php/scic/article/view/311>.
- [44] V. Stoicescu, T. I. Bițoiu, and C. Vrabie, „The Smart Community: Strategy Layers for a New Sustainable Continental Framework,” *Smart Cities*, vol. 6, pp. 410–444, 2023, doi: 10.3390/smartcities6010020.
- [45] G. Žilinskas, „Evolution of E-government in the States of the Eastern Border of the European Union,” *Public Policy and Administration*, 2014, doi: 10.5755/j01.ppaa.13.1.6504.
- [46] I. Žilionienė, „Planning the Development of Electronic Government: Overview of Main Documents,” *Public Policy and Administration*, 2004. [Online]. Available: <https://vpa.ktu.lt/index.php/PPA/article/view/27232>.
- [47] J. Čeičytė and M. Petraitė, „The Concept of Responsible Innovation,” *Public Policy and Administration*, 2014, doi: 10.5755/j01.ppaa.13.3.8302.
- [48] HotNews, „În primul an de la lansare, aplicația Civic Alert, prin care cetățenii pot transmite sesizări autorităților, a înregistrat 56.000 de utilizatori,” Nov. 18, 2016. [Online]. Available: <https://hotnews.ro/in-primul-an-de-la-lansare-aplicatia-civic-alert-prin-care-cetatenii-pot-transmite-sesizari-autoritatilor-a-inregistrat-56-000-de-utilizatori-448365>. [Accessed: Dec. 9, 2024].
- [49] TensorFlow, „Keras: The high-level API for TensorFlow,” 2024. [Online]. Available: <https://www.tensorflow.org/guide/keras>. [Accessed: 2024].
- [50] Viso.ai, „Deep Residual Networks (ResNet, ResNet-50) – 2024 Guide,” Nov. 2023. [Online]. Available: <https://viso.ai/deep-learning/resnet-residual-neural-network/>. [Accessed: Mar. 2024].
- [51] IBM, „Watson Compare and Comply element classification,” IBM Cloud Pak for Data 3.2.x documentation. [Online]. Available: <https://www.ibm.com/docs/en/cloud-private/3.2.x?topic=paks-watson-compare-comply-element-classification>. [Accessed: Dec. 9, 2024].