

Guvernarea electronică 3.0: Un model AI de soluționare automatizată a petițiilor

Catalin VRABIE,

*National University of Political Studies and Public Administration (SNSPA), Bucharest, Romania
catalin.vrabie@snsa.ro*

Abstract

În timp ce guvernarea electronică (care înseamnă aici prima generație de e-guvernare) era doar o modalitate simplă de furnizare a serviciilor publice prin mijloace electronice, e-gov 2.0 se referă la utilizarea rețelelor sociale și a tehnologiilor Web 2.0 în operațiunile guvernamentale și în furnizarea serviciilor publice. Cu toate acestea, utilizarea termenului „e-government 2.0” devine din ce în ce mai rară, pe măsură ce atenția se îndreaptă către inițiativele mai ample de transformare digitală, care pot include tehnologii AI, blockchain, realitatea virtuală și realitatea augmentată. În acest studiu, prezentăm conceptul relativ nou de e-guvernare 3.0, care este construit pe principiile e-guvernării 2.0, dar se referă la utilizarea tehnologiilor emergente pentru a transforma furnizarea serviciilor publice și pentru a îmbunătăți guvernarea. Obiectivul studiului este de a explora potențialul e-guvernării 3.0 de a îmbunătăți participarea cetățenilor, de a îmbunătăți furnizarea serviciilor publice și de a crește receptivitatea și conformitatea sistemelor administrative în raport cu cetățenii, prin integrarea tehnologiilor emergente în operațiunile guvernamentale, folosind ca fundal evoluția e-guvernării în timp. Lucrarea analizează provocările cu care se confruntă primăriile în răspunsul la petițiile cetățenilor, care sunt o aplicație centrală a democrațiilor locale. Autorul începe prin a prezenta un exemplu de sistem de e-petiții (așa cum este utilizat astăzi) și analizează date anonimizate dintr-un corpus de texte de petiții adresate uneia dintre primăriile din România. Autorul va propune un model AI capabil să gestioneze mai rapid și mai precis numărul crescut de intrări, încercând să-l promoveze către primăriile care, din diverse motive, sunt încă reticente în a implementa AI în operațiunile lor. Concluziile vor sugera că poate fi mai eficient să ne concentrăm pe îmbunătățirea noilor algoritmi, mai degrabă decât doar pe tehnologiile „vechi”.

Cuvinte cheie: Machine Learning; G2C; guvernare; inovație; participarea cetățenilor; inteligență artificială; Natural Language Processing

1. Introducere

Adoptarea rapidă a tehnologiilor digitale în furnizarea serviciilor publice și guvernare a transformat modul în care guvernele operează, interacționează cu cetățenii și furnizează servicii publice. Evoluția guvernării electronice a progresat de la furnizarea electronică de bază a serviciilor (e-guvernare 1.0) până la utilizarea rețelelor sociale și a tehnologiilor Web 2.0 (e-guvernare 2.0), ducând la schimbări semnificative în rolurile cetățenilor și guvernelor în furnizarea serviciilor publice [1, 2].

Cu toate acestea, apariția de noi tehnologii, precum inteligența artificială (AI), blockchain și Internet of Things (IoT), a deschis calea către o nouă eră a e-guvernării, denumită e-guvernare 3.0 [3, 4, 5, 6]. Această nouă versiune a conceptului promite să transforme furnizarea serviciilor publice și guvernarea prin integrarea tehnologiilor emergente în operațiunile guvernamentale [7, 8].

Acest articol va explora potențialul e-guvernării 3.0 de a îmbunătăți participarea cetățenilor, de a îmbunătăți furnizarea serviciilor publice și de a crește receptivitatea și conformitatea sistemelor administrative în raport cu cetățenii. Autorul va începe analiza bazată pe dovezi empirice dintr-un studiu de caz asupra municipiului Brașov, considerat unul dintre cele mai smart orașe din România în prezent [9, 10, 11], pentru a evalua

impactul e-guvernării 3.0 asupra unui aspect particular al guvernării și administrației publice: e-petiționarea. În cele din urmă, această lucrare își propune să contribuie la dezbateră științifică în curs de desfășurare privind viitorul e-guvernării și potențialul tehnologiilor emergente de a transforma furnizarea serviciilor publice și guvernarea.

Așa cum este menționat în câteva dintre studiile anterioare ale autorului [9, 10, 11, 12], în timp ce municipalitățile urmăresc să îmbunătățească participarea cetățenilor și transparența prin dezvoltarea unor platforme online pentru comunicare, unul dintre instrumentele utilizate pe scară largă este e-petiționarea, folosită atât de guvernele locale, cât și de cele centrale. Deși rețelele sociale au fost, de asemenea, utilizate de organizațiile publice pentru a se angaja în dialog cu cetățenii și pentru a primi feedback, majoritatea instanțelor administrative nu consideră discuțiile de pe rețelele sociale acțiuni legale, spre deosebire de e-petiții, care au statut oficial. Deși AI poate asista în abordarea preocupărilor cetățenilor pe rețelele sociale, e-petiționarea ar trebui considerată soluția preferată, alimentată de AI, pentru soluționarea problemelor administrative [13, 14, 15, 16, 17, 18, 19].

2. Recenzie a literaturii de specialitate

Cetățenii moderni așteaptă servicii publice prompte, eficiente și de înaltă calitate de la autoritățile publice [20], iar declinul încrederii în administrații și în serviciile acestora este un fenomen global [21, 22]. Acest lucru a dus la o cerere tot mai mare de infrastructură mai bună, servicii îmbunătățite și leadership adaptiv [23]. Cu toate acestea, bugetele publice limitate și cerințele în creștere creează constrângeri serioase pentru îndeplinirea acestor așteptări, ducând la întârzieri în prezentarea soluțiilor eficiente, personal subcalificat și capacități administrative slabe în general [24].

Progresele tehnologice oferă soluții atât pentru afaceri, cât și pentru guverne, iar integrarea inteligenței artificiale are potențialul de a influența pozitiv productivitatea globală și rezultatele de mediu, iar dezvoltarea unor modele de afaceri durabile este necesară [25].

Literatura privind managementul public sugerează că aplicațiile AI pot aborda aceste provocări și pot ajuta la generarea și menținerea unei bune guvernante [26, 27, 28]. De exemplu, AI poate îmbunătăți furnizarea serviciilor publice prin creșterea calității și eficienței serviciilor [29, 28], automatizarea sarcinilor administrative [30] și susținerea proceselor de luare a deciziilor [31, 32]. Mai mult, AI poate spori transparența și responsabilitatea, precum poate crește participarea și angajamentul cetățenilor [33, 34]. Ibtissem et al au utilizat metode statistice avansate pentru a investiga provocările cu care se confruntă economiile emergente în abordarea problemelor de guvernare slabă în serviciile publice [35]. Astfel, AI are potențialul de a transforma managementul public și guvernarea, ajutând autoritățile publice să îndeplinească mai bine așteptările cetățenilor și să îmbunătățească încrederea în serviciile guvernamentale.

AI poate juca un rol crucial în e-petiționare prin rezumarea și trierea petițiilor, oferind răspunsuri automate la întrebările de rutină [36, 37] și identificând petițiile care necesită analize suplimentare din partea departamentelor specializate [38, 39]. Aceasta poate asista la luarea deciziilor, oferind dovezi pentru un răspuns mai complet care este conform cu reglementările naționale sau internaționale [40]. AI poate filtra petițiile pentru a verifica

eligibilitatea acestora, compara subiectele și frecvențele apariției anumitor cuvinte cheie în acestea și măsura eficiența organizațională [41]. Prin realizarea acestor sarcini, AI poate economisi timp, energie și resurse și poate limita redundanțele și pierderile de timp [42]. De asemenea, poate folosi funcțiile compare and comply pentru a naviga în reglementări și pentru a asigura corectitudinea și completitudinea răspunsurilor oficiale. AI poate identifica urgențele din textele petițiilor utilizând sentiment analysis și poate declanșa reacții mai rapide din partea guvernului, sporind încrederea în autoritățile publice [43, 44]. Învățarea și raționamentul sunt, de asemenea, componente critice de luat în considerare în utilizarea AI în e-petiționare [45].

După revizuirea cercetărilor expuse în revistele Sustainability (numerele din anii 2020–2023), Mathematics (numerele din anii 2020–2023), Government Information Quarterly (numerele din anii 2020–2023) și International Journal of Web Services Research (numerele din anii 2020–2023), se poate concluziona că accentul se pune în mare măsură pe guvernarea electronică în general și mai puțin pe utilizarea tehnologiilor de vârf (AI, machine learning (ML), procesarea limbajului natural (NLP) și robotic/intelligent process automation (RPA/IPA)), pentru îmbunătățirea proceselor de guvernare.

Încă din 1999, Jon M. Kleinberg de la Universitatea Cornell [46] a studiat structura rețelelor într-un mediu hiperlinkat și a dezvoltat un set de instrumente algoritmice pentru extragerea informațiilor din structurile de linkuri ale acestor medii. La acea vreme, studiul s-a concentrat pe o varietate de contexte pe World Wide Web. Mai târziu, în 2011, Hreňo et al [47] au descris abordarea interoperabilității semantice a serviciilor de e-guvernare. Piaggese [48] a cercetat viitorul conectivității și a oferit o privire de ansamblu asupra Americii Latine, recomandând că rolul guvernului în furnizarea serviciului universal este foarte important pentru o tranziție corespunzătoare la e-guvernare 3.0. Verma [49] a realizat o revizuire bibliometrică cuprinzătoare a 353 de articole de cercetare publicate între 2010 și 2021 pentru a discerne performanța funcționarilor publici. Autorul a concluzionat că structurile de guvernare, împreună cu întreaga societate, devin mai inteligente prin utilizarea tehnologiilor inteligente. Cu toate acestea, citind textul, se poate admite că aceasta este o proiecție a speranțelor autorului pentru viitorul previzibil, dar nu există o indicație clară cu privire la momentul în care acest lucru se va întâmpla.

Un grup format din șapte specialiști în științe sociale și științe informatice de la McKinsey & Company a creat o diagramă în care au mapat cele mai promițătoare tehnologii pe baza aplicațiilor lor potențiale în domenii care ar putea fi benefice pentru societate. Ei s-au bazat pe un studiu realizat în 2018 și au ajuns la concluzia că cele mai valoroase tehnologii sunt deep learning, natural language processing, clasificarea imaginilor și videoclipurilor și detectarea obiectelor. Toate aceste tehnologii sunt legate de verificarea și validarea informațiilor [50].

3. Metodologie

Pentru prezentul studiu, oficialii din orașul Brașov, au fost de acord să furnizeze date anonimizate, care au cuprins 12.935 de petiții adresate municipalității în anul 2022 (1 ianuarie 2022–31 decembrie 2022) prin multiple canale de comunicare (e-mail, aplicații mobile, mesaje instantanee, platformă web și telefon) – Anexa A.

Fiecare dintre acestea a fost convertită folosind 118 indicatori, văzuți ca vectori, etichetați în 47 de clase care sunt, de asemenea, considerate layers. Anterior, responsabilitatea de a efectua această sarcină revenea angajaților primăriei, văzuți ca experți care se ocupau de petiții ca parte a sarcinilor lor zilnice. În timpul etichetării, experții au grupat, de asemenea, datele pe baza conținutului textual similar.

Ca date eșantion, pentru faza de inferență, au fost luate în considerare 1.295 de petiții. La finalul acestui proces, deci înainte de a începe analizele, eșantionul utilizat era format din 152.810 elemente.

În această etapă, autorul dorește să menționeze că au fost luați în considerare și alți factori de analiză: starea civilă (dacă este dezvăluită direct sau indirect de expeditor), platforma utilizată (mobil, laptop/PC), referințe la alte documente, cum ar fi legislația sau normele. Toate acestea sunt considerate informații suplimentare, dar sunt importante pentru construirea statisticilor.

Pe acest set de date, a fost efectuată o operațiune de curățare suplimentară pentru a anonimiza complet datele – toate petițiile conțineau fie nume (altul decât a petentului), adrese de e-mail, numere de telefon sau date similare care puteau lega conținutul de expeditor; prin urmare, un set complet de indicatori a fost eliminat, rezultând un număr total de 151.515 intrări valide. Autorul dorește să menționeze aici că setul de date primit pentru acest experiment a fost alcătuit din petiții la care răspunsurile au fost deja furnizate de angajații primăriei; prin urmare, acestea au fost considerate valide. Există mai multe limitări menționate într-o secțiune dedicată la finalul articolului.

Operațiunile de curățare au constat, de asemenea, în următoarele:

1. Tokenizare: împărțirea textului în cuvinte sau tokeni individuali pentru a permite procesarea ulterioară;
2. Eliminarea punctuației;
3. Corectarea greșelilor de scriere;
4. Eliminarea URL-urilor și a etichetelor HTML;
5. Eliminarea caracterelor speciale;
6. Eliminarea emoticoanelor;
7. Eliminarea cuvintelor ofensatoare și a limbajului neadecvat.

Pentru analiza propriu-zisă, a fost utilizat Google Colab [51] datorită accesului gratuit la un mediu de dezvoltare machine learning (ML) care permite scrierea și rularea codului Python, inclusiv a algoritmilor ML. Mai mult, platformele permit utilizarea modelelor pre-antrenate din cadrul popularelor framework-uri de învățare automată, cum ar fi TensorFlow și PyTorch. Pentru acest experiment, autorul a utilizat exclusiv TensorFlow ca platformă de dezvoltare, împreună cu software open-source ajustat, cum ar fi BERT [52], pentru analizele textului folosind tehnici de codificare bazată pe index și Bag of Words (BoW) [53, 54] alimentate cu texte din setul de date utilizat în acest experiment. Pentru datele tabelare (obținute după triajul primilor câțiva indicatori, cum ar fi vârsta, starea civilă și activismul), a fost utilizat TabNet [55]. Reprezentările vizuale pentru articol au fost reproduse cu ajutorul TensorFlow Playground [56].

4. Modelul AI propus

4.1. Lucrări conexe

În domeniul juridic, AI excelează în gestionarea sarcinilor repetitive și de rutină [57]. Una dintre cele mai vechi și notabile aplicații ale AI în domeniul juridic a fost în faza de documentare a unui proces, în special în clasificarea documentelor. Abordarea inițială a implicat căutarea de cuvinte cheie pentru a automatiza acest proces, dar aceasta avea limitări, deoarece o idee sau un concept poate fi exprimat în diverse moduri, iar anumite cuvinte cheie pot fi omise. În cele din urmă, s-au folosit algoritmi ML și procesare a limbajului natural (NLP); echipe de avocați au clasificat eșantioane de documente, iar apoi algoritmi au analizat modelele de cuvinte și combinații pentru a identifica ce documente răspundeau cererii [58]. Acest lucru a economisit o cantitate semnificativă de timp pentru solicitări viitoare. Cu toate acestea, rezultatele nu au fost o clasificare binară; în schimb, algoritmul a produs un scor de probabilitate ca un document să fie relevant [59]. Cele cu un scor de probabilitate ridicat sunt predate, în timp ce cele cu un scor scăzut sunt ignorate. Cele plasate între aceste limite necesită o revizuire umană.

Deoarece majoritatea petițiilor necesită input legislativ pentru răspunsuri, se poate folosi un model similar. Conform statisticilor făcute de Primăria Brașov, petițiile urmează teme comune care apar în diverse scenarii [60]. Având în vedere acest lucru, procesul de clasificare a documentelor este considerat de rutină – funcționarii publici creează un protocol pe care îl aplică în mod repetat. Totuși, automatizarea acestui proces este o sarcină îndelungată, deoarece informațiile analizate, fie că un document era sau nu relevant, sunt prezentate în format text. Fără o metodă prin care un computer să înțeleagă limbajul, aspectul de rutină al muncii nu ar putea fi realizat. Acum, că procesarea limbajului a avansat suficient pentru a permite acest lucru, procesul poate fi executat fără probleme.

Mai mult, dacă sunt implementate sistemele NLP dezvoltate recent, precum AI generativ, cum ar fi ChatGPT [61, 62], răspunsul la petiții după clasificarea corespunzătoare a documentelor legale, așa cum s-a menționat mai sus, va deveni o simplă rutină compare and comply [9].

4.2. Input layer

Inițial, folosind algoritmi Authority and Hubs Distribution [46], sistemul a evaluat gradul de asociere dintre cuvintele găsite în liniile de subiect ale tuturor petițiilor pentru a clasifica cererile cetățenilor. Aceasta a implicat punctarea legăturii conexiunilor dintre cuvinte.

Așa cum se arată în Figura 1, cuvintele din liniile de subiect (59 de noduri, sau cuvinte unice dintr-un total de 66 și 44 de legături între noduri) sunt interconectate (cu cât sunt mai închise legăturile și punctele, cu atât conexiunea este mai puternică), fără cuvinte izolate. Cu toate acestea, conexiunile dintre ele sunt încă slabe în acest moment, dar ajută la clasificarea corpusului textual principal.




Fig. 1. Analiza și vizualizarea cuvintelor cheie așa cum sunt regăsite acestea în linia de subiect a petițiilor – prima sarcină de clasificare.

Source: autorul

4.3. Layer-ele ascunse

Problema în acest moment este că sistemul nu știe nimic despre conținutul unei petiții sau al mesajelor de pe Facebook, așa că există o nevoie puternică de a-l traduce într-o formă pe care calculatorul o poate înțelege, și aceasta este un vector de caracteristici. O modalitate posibilă de a efectua această traducere este de a întreba experții (funcționarii publici) despre conținut și de a concatena răspunsurile într-un vector binar; aceasta este ceea ce experții în AI numesc supervised learning. Etichetarea conținutului poate fi realizată pentru fiecare petiție din setul de antrenament [63, 64, 65]. De fapt, nu este nevoie să se aloce resurse pentru activitățile de etichetare; sistemul poate pur și simplu să observe acțiunile umane și poate analiza modelele de cuvinte și combinații pentru a eticheta corect fiecare petiție.

Manipularea vectorilor și etichetelor ajută la traducerea problemei într-o formă geometrică. Dacă fiecare dintre acești vectori este reprezentat ca un punct în spațiu și dacă există o etichetă corespunzătoare acestor puncte, atunci sistemul poate învăța din date.

În Figura 2, există utilizatori ai sistemului care au trimis o petiție către primărie (set de antrenament). În partea de jos, se pot vedea petițiile (setate ca un vector de importanță) care ar putea fi tratate cu ușurință de municipalitate, în timp ce în partea de sus, există o problemă importantă care trebuie luată în considerare rapid.




Fig. 2. Model generic de predicției a importanței (văzută ca un vector) unui topic precum cît de active este cetățeanul în folosirea sistemului de petiționare.

Source: autorul

4.4. Modelul de antrenament

Figura 3 oferă o reprezentare vizuală a modelului de antrenament. Modelul este elastic; acesta oferă posibilitatea de a fi ajustat de către administratori, permițându-le să adauge mai multe layere și vectori.




Fig. 3. Modelul de antrenament (simplificat), reprezentare vizuală cu ajutorul Google TensorFlow

Source: github.com [56] – accessed on 19 March 2023

Layer-ele reprezintă un grup de elemente interconectate care, atunci când sunt calculate împreună, ajută modelul să funcționeze mai bine. Acestea sunt bazate pe caracteristici văzute ca vectori și considerate importante de administratorii sistemului, cum ar fi limbajul

(de exemplu, utilizarea de cuvinte neadecvate sau jignitoare), motivul (de exemplu, disfuncționalități deja cunoscute ale diferitelor sisteme din oraș: alimentare cu energie electrică, furnizarea apei potabile), factorii geografici (de exemplu, zone care se confruntă cu aceeași problemă, cum ar fi gropile din asfalt și diferiți cetățeni continuă să trimită mesaje despre acestea), activitățile (de exemplu, muzică de la un festival din apropiere) și gradul de încredere al utilizatorului (pe baza postărilor anterioare ale acestuia pe paginile oficiale de social media ale primăriei/petiții/mesaje, folosind instrumente de sentiment analysis). Cu alte cuvinte, conexiunea dintre vectori este realizată prin măsurarea legăturilor dintre aceștia (așa cum se vede în Figura 1).

Odată ce modelul este antrenat și compilat, sistemul atribuie un scor fiecărei petiții și efectuează acțiuni specifice pe baza unui prag prestabilit.

Când sistemul întâlnește texte provocatoare (de exemplu, întrebări adresate de cetățeni care necesită soluții complexe pe care sistemul nu le-a întâlnit anterior), software-ul generează mai multe răspunsuri, fiecare cu o probabilitate corespunzătoare care indică cât de sigur este sistemul de corectitudinea răspunsului (de exemplu, 0.92, 0.84, 0.76 – cunoscute sub denumirea de „valori de încredere”). Administratorii sistemului vor stabili un prag sau o valoare limită care servește drept ghid pentru a decide ce răspunsuri poate gestiona mașina. Mai exact, dacă probabilitatea unui răspuns dat depășește pragul (de exemplu, 0.90), atunci mașina poate să răspundă automat. Cu toate acestea, dacă valoarea scade sub prag, întrebarea trebuie adresată unui operator uman.

În general, primăria are identitățile cetățenilor care se adresează prin petiționare, cunoscând astfel locurile în care aceștia locuiesc. Prin urmare, înțelege problemele cu care se confruntă și despre ce anume ar putea depune plângeri. Apoi, poate folosi aceste informații pentru a genera o listă de profiluri aparținând persoanelor care petiționează frecvent (un număr mare de reclamanți tind să-și repete acțiunile, chiar dacă primesc un răspuns pozitiv din partea primăriei). În plus, primăria poate folosi informațiile publice despre utilizatorii activi de pe pagina oficială de Facebook. Coroborând aceste informații cu predicțiile de sentiment analysis, sistemul poate fi mai eficient și mai eficace în atribuirea scorurilor, pe baza cărora poate considera anumite acțiuni.

Este interesant de menționat aici așa-numitul paradox Jevons [66, 67, 68], care afirmă că îmbunătățirile în eficiență și tehnologie corelate cu reducerea costurilor, care inițial duc la o scădere a utilizării resurselor, pot duce la o creștere generală a consumului agregat. Ca rezultat, autorul prezice că ușurința crescută de utilizare și viteza sistemului pot duce la o cerere mai mare, compensând orice câștiguri de eficiență și punând o presiune mai mare asupra resurselor administrative. Acest lucru se datorează în principal faptului că ușurința de utilizare a sistemului, corelată cu viteza cu care aplicațiile răspund/rezolvă problema, va încuraja o utilizare mai mare, ceea ce va conduce la o creștere a cererii care poate compensa economiile realizate din creșterea eficienței. Acest paradox subliniază nevoia unei abordări holistice a gestionării resurselor, care să țină cont nu doar de câștigurile de eficiență, ci și de comportamentul și reacțiile cetățenilor la aceste câștiguri.

4.5. Output layer

Gestionarea problemelor asociate reintroducerii în sistem a răspunsurilor date de acestapoate fi dificilă, dar având în vedere că robustetea unui sistem de petiții nu ar trebui să fie la fel de solidă ca cea a unui sistem financiar (de exemplu, în cazul detectării fraudei), un astfel de sistem va reduce în mod cert presiunea asupra funcționarilor publici atunci când se ocupă de un volum mare de petiții, acționând astfel:

1. Ia o acțiune moderată – backlog, trimițând petiția spre investigare umană, în timp ce ajută la extragerea informațiilor relevante din cadrul legislativ pentru a sprijini funcționarul public în oferirea unui răspuns precis la plângere;
2. Ia o acțiune fermă, acționând în locul oamenilor (independent), generând narațiuni și furnizând toate informațiile necesare cetățeanului. De asemenea, ar putea angaja un dialog activ folosind capacități avansate NLP (precum GPT [69]) dacă este necesar;
3. Acțiune pasivă. În acest scenariu, sistemul AI ar putea răspunde într-un mod blând, folosind limbaj și fraze menite să dezamorseze orice potențială discuție cu un cetățean confrunțat.

În oricare dintre cazurile de mai sus, funcționarii publici vor primi un sprijin semnificativ din partea unui astfel de sistem, în timp ce cetățenii vor căpăta o încredere mai mare în administrația locală, știind că oficialii sunt activi în rezolvarea problemelor lor. Dacă adunăm toate opțiunile de mai sus, putem vedea eficiența sistemului. Mai mult, roboții software pot fi utilizați pentru a aduna informații despre percepțiile publicului asupra diverselor acțiuni ale oficialilor sau ale diferitelor agenții și, pe baza analizei sentimentelor, pot studia starea de spirit a publicului și pot oferi feedback municipalității pentru a-și îmbunătăți serviciile [70, 71, 72, 73].

Pentru o mai bună înțelegere, Figura 4 oferă o reprezentare vizuală a modelului. În lumea reală, totuși, datele ar putea să nu fie la fel de bine echilibrate ca în rezultatul prezentat.




Fig. 4. Modelul final (simplificat), reprezentare vizuală cu ajutorul Google TensorFlow
Source: github.com [56] – accessed on 19 March 2023

Legendă:

- X1 și X2 sunt de văzut, în sensul prezentei lucrări, ca intrări de date, precum X1 din petiții și X2 din mesaje postate pe pagina oficială de Facebook a instituției.
- Data curation se referă la procesul de curățare a datelor de intrare (așa cum este menționat în Secțiunea 3) pentru a fi utilizate în model, făcându-l relevant și fiabil. În acest experiment, autorul a înlocuit cuvintele abreviate cu semnificația lor, transformându-le în vectori (forma numerică) prin tehnici de Index-Based Encoding și Bag of Words (BoW) [53, 54].
- Rezultatele investigației umane, care sunt considerate „acțiune blândă”, vor fi reintroduse în sistem după faza de ieșire. Acest feedback are ca scop reajustarea vectorilor pentru a îmbunătăți acuratețea pentru următoarea intrare.

5. Rezultate

Pentru a testa modelul, autorul a preluat date reale din unul dintre orașele mari din România, Brașov, așa cum este descris în secțiunea „Metodologie”, și le-a introdus în sistem.

Un set complet de conexiuni (realizate pe 10% din textele complete din setul de antrenament, la faza de inferență) poate fi observat în Figura 5.

Tabelul 1. Eșantion al setului de date utilizat pentru antrenament.

ID	Articol	Valoare	Observații/Detalii
I1	Gen*	0/1/2	0—necunoscut/1—bărbat/2—femeie
I2	Grupă de vârstă**	0 la 6	0—necunoscut/6 > 70
I3	Dacă este în numele unei firme	0/1	0—necunoscut/1—nu/2—da
I41	Geografic 1***	0 la 88	Împărțit în 8 subgrupuri majore, fiecare împărțit în 8 subgrupuri (0 pentru nedeazăluit)
I42	Geografic 2	0/1/2	0—necunoscut/1—locuiește la bloc/2—locuiește la casă (cu grădină)
I5	Tipul petiției	0/1/2/3/4/5	0—necunoscut/1—cerere/2—plângere/3—referință/4—audiență/5—propunere
I6	Atașament	0/1	Nu/Da
I7	Subiectul petiției	0 la 9	Pe baza cuvintelor scrise în câmpul Subiect (diferit de I3); 0 pentru necunoscut
I81	Activ****	0/1/2	0—prima/1—a doua/2—multiple
I82	Activ pe pagina oficială de social media	0/1/2	0—prima/1—a doua/2—multiple
I91	Conținut 1	0/1	Dacă se referă la vecini (persoane specifice)
I92	Conținut 2	0/1	Dacă se referă la cartier
I101	Conținut 2	0/1/2	0—nu/1—dacă se referă la parcare/2—dacă se referă la parcare în legătură cu I82
I11	Conținut 3	0/1	0—nu/1—dacă se referă la facilitățile proprii

*extras din Prenume (în limba română, marea majoritate a Prenumelor care se termină cu „a” aparțin femeilor); **dacă direct (menționându-l în text simplu) sau indirect (menționând că este student sau o persoană pensionară, etc.) dezvăluite de expeditor; ***pe baza adresei; ****dacă persoana a trimis mai mult de o petiție; Source: autorul.

Tabelul 2. Matricea de corelație; rezultate pe eșantionul din Tabelul 1.


	I1	I2	I3	I4 *	I5	I6	I7	I8 *	I9 *	I10 *	I11	I12
I1	1.0000	-0.0955	0.0354	0.0838	-0.0127	0.1109	0.0129	-0.0492	0.4208	0.3429	0.4265	[...]
I2	-0.0955	1.0000	0.0697	-0.3778	-0.2118	-0.0464	-0.0506	0.0533	-0.0357	-0.1504	-0.0788	[...]
I3	0.0354	0.0697	1.0000	-0.0231	-0.0205	-0.0147	-0.0167	-0.0876	0.0235	0.0896	0.0111	[...]
I4 *	0.0838	-0.3778	-0.0231	1.0000	0.1147	0.0146	0.0097	0.0130	0.0466	0.0844	-0.0051	[...]
I5	-0.0127	-0.2118	-0.0205	0.1147	1.0000	-0.0443	0.0345	-0.0245	-0.0287	0.0512	0.0208	[...]
I6	0.1109	-0.0464	-0.0147	0.0146	-0.0443	1.0000	-0.0062	-0.0025	0.1103	0.1226	0.1061	[...]
I7	0.0129	-0.0506	-0.0167	0.0097	0.0345	-0.0062	1.0000	-0.0803	0.0919	-0.0316	0.0499	[...]
I8 *	-0.0492	0.0533	-0.0876	0.0130	-0.0245	-0.0025	-0.0803	1.0000	-0.0220	-0.0073	-0.0710	[...]
I9 *	0.4208	-0.0357	0.0235	0.0466	-0.0287	0.1103	0.0919	-0.0220	1.0000	0.2737	0.4082	[...]
I10 *	0.3429	-0.1504	0.0896	0.0844	0.0512	0.1226	-0.0316	-0.0073	0.2737	1.0000	0.2322	[...]
I11	0.4265	-0.0788	0.0111	-0.0051	0.0208	0.1061	0.0499	-0.0710	0.4082	0.2322	1.0000	[...]
I12	[...]	[...]	[...]	[...]	[...]	[...]	[...]	[...]	[...]	[...]	[...]	1.0000

*exemplele pentru I8, I9, I10 și alți indicatori compuși transformați în vectori unici: „Este prezent un anumit cuvânt, cum ar fi „lucru”, în context?” - Detectare. „Ce tip de „lucru” este „lucru”?” - Clasificare. „Cum ar putea fi clasificat sau reclasificat „lucrul”?” - Segmentare. Source: autorul.

Scorurile oferite de mașină nu sunt importante pentru acest articol. Cu toate acestea, pe baza setului complet de valori, sistemul poate înțelege conexiunile dintre vectori și poate decide ce să facă cu petiția, așa cum este explicat în Secțiunea 4.5. Valoarea reală a unui astfel de sistem se bazează pe viteza cu care poate efectua triajul petițiilor primite și pe acuratețea acestuia, așa cum va fi prezentat mai jos. Fără aceasta, rata de așteptare data de raportul dintre toate petițiile și cele care așteaptă analiză umană, ar putea mări capacitatea Dispeceratului Tehnic Integrat al orașului Brașov, văzut aici ca un „gatekeeper”. De exemplu, un adnotator uman lucrează 8 ore pe zi, iar o singură adnotare durează 5 minute; un sistem tradițional este capabil să gestioneze aproximativ 100 de intrări pe zi, aceasta fiind capacitatea sistemului. Se poate efectua calculul și se poate observa că, în cazul Brașovului, sistemul actual, tradițional, depășește nevoile (1).

$$12.935/251 \text{ de zile lucrătoare pe an în } 2022 \times 5 \text{ min} \approx 4 \text{ h } 20 \text{ min/zi} \quad (1)$$

Totuși, în cazul în care urmează să extindem sistemul pentru a acoperi orașe mai mari (de exemplu, București, care este de opt ori mai mare decât Brașov) sau întreaga țară pentru anumite agenții guvernamentale centrale, situația ar fi diferită. Mai mult, în cazurile de dezastre naturale în care pot apărea creșteri neașteptate a mesajelor deoarece oamenii raportează cu promptitudine situația. În plus, ținând cont de timpul necesar procesării informațiilor și răspunderii la acestea, este ușor de imaginat beneficiile substanțiale ale unui astfel de sistem. Deși numărul input-urilor poate fi imprevizibil, mașina este, fără îndoială, capabilă să funcționeze într-un ritm mai rapid decât oamenii și, cu o pregătire adecvată, poate obține o precizie mai mare. În plus, mașinile nu se bazează pe anumite ore de lucru, zile lucrătoare etc.



(a)

(b)

Fig. 5. Analiza și vizualizarea cuvintelor cheie așa cum se găsesc în corpusul principal a 130 de petiții. Pentru a oferi cititorilor o înțelegere a complexității, este prezentat acest eșantion de 130 de texte ($\approx 10\%$ din setul de instruire). Ar fi fost imposibil să se utilizeze setul de date complet pentru reprezentarea vizuală, deoarece numărul excesiv de conexiuni ar fi făcut figura de neînțeles: (a) complexitatea eșantionului văzută de mașină; (b) Un exemplu de legături a unui singur cuvânt (în acest caz s-a ales „transport”) în context în alte petiții.

Source: autorul

În imaginea de mai sus, în Figura 5, se poate observa densitatea culorii, care arată legătura realizată de sistem cu cuvintele care sunt prezente în alte petiții. Cu alte cuvinte, sistemul este capabil să „înțeleagă” textul într-un mod mai mult sau mai puțin similar cu cel al oamenilor.

După ce au fost calculate legăturile, mașina are de obicei capacitatea de a evalua petițiile, deși cu un anumit grad de inexactitate, așa cum se arată în Figura 6 de mai jos, și de a decide acțiunea. De exemplu, dacă o plângere se referă la sistemul de alimentare cu apă potabilă într-un cartier al orașului, petiția poate conține cuvinte precum „apă”, „țeavă”, „drum” și altele din această categorie, dar este puțin probabil să aibă „furturi”, „animale sălbatice”, „semafoare”. Când apar aceste situații, totuși, sistemul va transmite textul unui operator uman, observându-i comportamentul și (re)ajustând modelul. În plus, operatorii umani pot ajuta mașina cu aceste ajustări pentru o mai bună predicție viitoare.




Fig. 6. Modele de predicție utilizate experimental pentru acest articol.

Graficul prezentat în Figura 6 arată rezultatele testării a șase modele distincte de predicție. Modelul Gradient Boosted Tree s-a dovedit a fi cel mai precis, cu o eroare relativă de 7,84%, dar a avut și o eficiență moderată, fiind nevoie de aproximativ 16 secunde pentru a procesa textul și a determina cursul său de acțiune. În comparație, alte modele, cum ar fi Decision Tree, care au fost mai rapide, necesitând doar 2 secunde, dar au avut o rată de eroare mai mare de 12,32%.

Autorul dorește să clarifice că intenția nu a fost măsurarea ratei de eroare a experților primăriei, care poate fi mai mică decât oricare dintre modelele testate în studiu. Cu toate acestea, rezultatele au susținut ipoteza că viteza mașinii ar putea fi un avantaj și, cu o pregătire adecvată, precizia acestor modele s-ar putea îmbunătăți.

6. Discuții

Avansarea tehnologiei a permis AI-ului să facă progrese remarcabile în gestionarea aspectelor critice ale funcțiilor compare & comply. Funcționarii din administrația publică trebuie să examineze o cantitate mare de date, majoritatea fiind legislație și norme interne, pentru a putea evita complicații juridice neprevăzute [74]. Aceasta este încă o problemă destul de dificilă pentru a fi rezolvată de mașini, deoarece anumite concepte pot fi formulate în moduri diferite. Totuși, sistemul nu încearcă să înlocuiască oamenii, ci să-i ajute să performeze mai bine; prin urmare, criticile care vizează greșelile sistemelor AI, cunoscute sub numele de „exemple adversariale”, nu trebuie privite ca erori, ci ca funcționalități [75]. Rolul automatizării este de a facilita sarcinile, permițând software-ului să scaneze documentele legislative, să înțeleagă sensul lor, să le compare cu cererile cetățenilor și să determine ce documente trebuie menționate în răspuns, economisind astfel timp și efort considerabile.

Metodologia utilizată, așa cum este descrisă în articol, ar putea fi adaptată pentru a rezolva probleme de sentiment analysis asociate cu e-petițiile, în funcție de accesul la un lexicon al limbii române care să includă termeni pozitivi și negativi (echipe de experți lucrează în

prezent la construirea acestuia [76, 77]). Identificarea celor mai extremi termeni pozitivi și negativi va permite clasificarea intrărilor „evidente”, iar abordarea self-supervised learning (SSL) va gestiona ulterior restul intrărilor prin referirea încrucișată cu aceste exemple.

6.1. Limitări

Eficiența sistemului a fost menționată, dar, desigur că aceasta este o problemă puternic dezbătută, deoarece mașinile nu reprezintă un panaceu. Sistemul este departe de a fi perfect. Cu toate acestea, dacă există rareori un caz de fals pozitiv sau fals negativ, așa cum se vede în Figura 4, sistemul poate solicita informații suplimentare de la cetățean sau poate transmite petiția unui operator uman. Este esențial ca oamenii să fie implicați în sistemele AI pentru a asigura responsabilitatea și acuratețea; cu alte cuvinte, este nevoie de precauție.

Mai mult, într-un mediu real, sistemul poate prezenta un comportament neașteptat; pot apărea bias-uri care ar putea compromite rezultatul, ducând la procese în instanță. Pentru a evita acest lucru, este important să identificăm și să abordăm potențialul bias pentru a asigura corectitudinea și utilizarea etică a sistemului. Acesta poate apărea dintr-o varietate de surse, cum ar fi datele de antrenament dezechilibrate, limitările algoritmilor, etc. Eșecul în abordarea acestor bias-uri poate duce la discriminarea anumitor grupuri de oameni sau la predicții inexacte care duc la rezultate slabe, ceea ce poate avea consecințe serioase, inclusiv acțiuni legale, așa cum s-a menționat anterior. Pentru a atenua riscul apariției bias-ului, este important să se stabilească bune practici pentru etichetarea datelor de către experți și preprocesarea acestora de către administratori, împreună cu monitorizarea continuă și evaluarea performanței sistemului. Acest lucru poate include tehnici precum augmentarea datelor, interpretabilitatea modelului și măsuri de echitate, precum și implicarea unor actori diverși în proiectarea și implementarea sistemului.

6.2. Noi orizonturi de cercetare

În cazul analizei petițiilor, sistemul ar trebui să fie antrenat pe un corp mare de date textuale, care ar trebui etichetat cu metadate relevante, cum ar fi tipul de problemă, urgența, sentiment analysis și multe altele. Prin analiza tiparelor din date, sistemul poate învăța să identifice teme și subiecte comune și să facă conexiuni între cuvinte și expresii înrudite. Acest lucru permite sistemului să clasifice corect noi petiții și să le prioritizeze pe baza nivelului lor de urgență și importanță.

Mai mult, într-o platformă de e-petiții îmbunătățită cu AI, API-ul GPT (Interfață de Programare a Aplicațiilor) ar putea fi integrat ca un chatbot inteligent pentru a oferi suport personalizat și eficient utilizatorilor. Noul GPT-4o, ca model lingvistic de mari dimensiuni (Generative Pre-trained Transformer), are capacitatea de a înțelege și răspunde la întrebări în limbaj natural, ceea ce îl face un candidat ideal pentru gestionarea în timp real a cererilor utilizatorilor.

Ca idee pentru lucrări viitoare, integrarea GPT-4o în sistemul de petiții poate fi îmbunătățită prin încorporarea unor tehnici avansate de machine learning. Acest lucru poate îmbunătăți acuratețea și relevanța răspunsurilor oferite de GPT-4o, permițându-i să învețe din feedback-ul utilizatorilor și să se adapteze la nevoile acestora în schimbare.

În plus, autorul dorește să menționeze că, în etapa actuală, sistemul dezvoltat împreună cu prezentul articol nu are o interfață grafică, fiind în mare parte o abordare algoritmică a unei probleme AI – un proof of concept. Cu toate acestea, scopul acestei lucrări nu este promovarea acestui sistem în particular, ci dezvoltarea unor aplicații capabile să ajute funcționarii publici, instituțiile și, în final, cetățenii.

Aplicarea tehnicilor de transfer learning și de self-supervised learning ar fi deosebit de avantajoasă în implementarea unui astfel de sistem, care ar putea fi utilizat de alte entități din administrația publică, inclusiv muzee și alte instituții care servesc direct cetățenii. Cu date de intrare consistente, ar fi fezabil să se modifice layer-ul de ieșire pentru a înțelege mai bine nevoile cetățenilor fără a fi nevoie de a porni de la zero.

Deși aspectul financiar poate să nu fie imediat evident în managementul public, utilizarea tehnologiilor avansate are potențialul de a genera beneficii tangibile, cum ar fi creșterea încrederii și angajamentului cetățenilor.

6.3. Implicații teoretice, practice și politice

Implicațiile teoretice sugerează că modelul dezvoltat în acest studiu ar putea fi adaptat pentru a rezolva probleme de sentiment analysis asociate cu e-petițiile. Mai mult, implicațiile practice arată că AI are capacitatea de a asista funcționarii din administrația publică în gestionarea volumelor mari de date, economisind timp și efort considerabile. Prin scanarea documentelor legislative, înțelegerea semnificației acestora, compararea lor cu cerințele cetățenilor și determinarea documentelor de referință în răspuns, AI poate diminua volumul de muncă al funcționarilor publici prin procesarea rapidă și precisă a unor cantități mari de text 24/7.

În concluzie, acest studiu demonstrează că AI poate asista eficient funcționarii din administrația publică în gestionarea unor volume mari de date, identificând în același timp bias-ul și asigurând utilizarea etică a sistemului. În plus, AI are potențialul de a genera beneficii tangibile, cum ar fi creșterea încrederii și angajamentului cetățenilor, și poate fi aplicat și în alte entități din administrația publică.

7. Concluzii

Autorul a realizat acest experiment pentru a explora elementele computaționale implicate în contextul învățării operării cu intrări de tip text. Concluziile sugerează că aceste modele pot, teoretic, fi implementate și pot executa empiric o gamă largă de acțiuni, în funcție de capacitatea modelului și de zgomotul din setul de date, văzut aici ca secvențe de text neclare în interiorul petițiilor. Mai mult, s-a demonstrat că modelele AI pot reduce volumul de muncă al funcționarilor publici prin procesarea unor cantități mari de text cu mare viteză și precizie, șapte zile pe săptămână, 24 de ore pe zi. În timp ce experimentul s-a concentrat pe funcții liniare, cu relativ puține straturi și indicatori, văzuți aici ca vectori, metodologia poate fi extinsă la multe alte probleme de machine learning care implică clase de funcții mai bogate. De exemplu, poate fi aplicată unei rețele care efectuează un calcul neliniar a caracteristicilor în layer-ele sale inițiale.

De asemenea, această abordare experimentală poate fi utilizată pentru a studia exemple pe scară mai mare de învățare contextuală, cum ar fi modelele lingvistice, și pentru a determina dacă comportamentele acestora pot fi explicate prin algoritmi de machine learning interpretabili. Deși mai este mult de lucru, rezultatele oferă dovezi inițiale că ceea ce astăzi este văzut ca un mod online, dar asincron, de a trata cererile cetățenilor, în viitor, s-ar putea să nu fie la fel de dificil pe cât pare și poate fi pus în practică folosind instrumente ML standard. Mai mult, soluțiile oferite de instrumentele de inteligență artificială vor ajuta la crearea unei comunicări mai bune cu administrația publică și la găsirea unor soluții mai bune la problemele cetățenilor. Implementarea tehnicilor NLP în procesele administrației publice este doar unul dintre primii pași în era e-guvernării 3.0.

Anexa A

Table 3. Categoriile petițiilor*

ID	Item	Active	Resolved	Total
1	Afișaj/comerț neautorizat	-	34	34
2	Îmbunătățiri rutiere	244	1250	1494
3	Animale în spațiul public	2	58	60
4	Deteriorarea rețelelor de utilități	312	1653	1965
5	Cereri de informații	9	2520	2529
6	Construcții/lucrări neautorizate	-	160	160
7	Eliminarea deșeurilor	2	107	109
8	Distrugerea domeniului public	6	58	64
9	Fântâni	-	6	6
10	Iluminat public	3	851	854
11	Investiții	10	5	15
12	Marcaje rutiere	-	18	18
13	Parcări ilegale	5	882	887
14	Parcări publice/rezidențiale	5	159	164
15	Permise de trecere liberă	-	16	16
16	Probleme de mediu	-	77	77
17	Salubritate	6	1443	1449
18	Semnalizare rutieră	2	970	972
19	Servicii electronice/Portal web	12	18	30
20	Reclamații servicii administrative	9	4	13
21	Situații de urgență	-	28	28
22	Transport public	43	142	185
23	Transport taxi	-	4	4
24	Tulburări publice	2	356	358
25	Vehicule abandonate	1	318	319
26	Zero plastic în zonele verzi	-	8	8
27	Zone verzi/mobilier urban	12	1790	1802
Total		685**	12935	13620

* Dispecerat Tehnic Integrat – raportul general de activitate pentru perioada 01.01.2022-31.12.2022;

** 685 cereri au fost înregistrate la sfârșitul lunii decembrie. În cea mai mare parte, acestea abordau probleme care au provenit din locația la mare altitudine a Brașovului, care provoacă ninsori masive în timpul iernii.

Table 4. Originea petițiilor*

ID	Item	Total
1	Email	968
2	Smart phone	8074
3	Instant message	2
4	Web platform	1463
5	Phone	3113
	Total	13620

* Dispecerat Tehnic Integrat – raportul general de activitate pentru perioada 01.01.2022-31.12.2022;

References

- [1] C. Vrabie, *Elemente de E-Guvernare [Elements of e-government]*, Bucharest: Pro Universitaria, 2016.
- [2] G. Porumbescu, C. Vrabie, J. Ahn and T. Im, "Factors Influencing the Success of Participatory E-Government Applications in Romania and South Korea," *The Korean Journal of Policy Studies*, vol. 27, no. 1, pp. 1-21, 2012.
- [3] European Commission, "eGovernment and digital public services," European Commission, 17 06 2022. [Online]. Available: <https://digital-strategy.ec.europa.eu/en/policies/egovernment>. [Accessed 23 04 2023].
- [4] Nikola Vlahovic and Tomislav Vracic, *An Overview of E-Government 3.0 Implementation*, IGI Global, 2015.
- [5] C. N. Jun and Chung Joo Chung, "Big data analysis of local government 3.0: Focusing on Gyeongsangbuk-do in Korea," *Technological Forecasting and Social Change*, vol. 110, pp. 3-12, 2016.
- [6] S. Terzi, K. Votis, D. Tzovaras, I. Stamelos and K. Cooper, "Blockchain 3.0 Smart Contracts in E-Government 3.0 Applications".
- [7] European Commission, "Public Administration and Governance in the EU," European Commission, 01 2023. [Online]. Available: https://reform-support.ec.europa.eu/system/files/2023-01/DG%20REFORM%20Newsletter02_january2023.pdf. [Accessed 23 04 2023].
- [8] J. D. Twizeyimana and A. Andersson, "The public value of E-Government – A literature review," *Government Information Quarterly*, vol. 36, no. 2, pp. 167-178, 2019.
- [9] C. Vrabie, "Artificial Intelligence Promises to Public Organizations and Smart Cities," in *Digital Transformation*, Springer International Publishing, 2022, pp. 3-14.
- [10] C. Vrabie, "Digital Governance (in Romanian Municipalities) and Its Relation with the IT Education– A Longitudinal Assessment of Municipal Web Sites in Romania," in *Public Administration in Times of Crisis*, NISPAcee PRESS, 2011, pp. 237-269.
- [11] C. Vrabie, "Artificial Intelligence Promises to Public Organizations and Smart Cities.," *Digital Transformation. Lecture Notes in Business Information Processing*, vol. 465, 8 12 2022.
- [12] C. Vrabie, "E-Government 3.0: An AI Model to Use for Enhanced Local Democracies," *Sustainability*, 2023.
- [13] C. Vrabie, "E-Guvernarea in municipiile Romaniei (2010)," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 1, 2010.
- [14] C. Vrabie, "E-gov 2012. Analiza orizontala a Web site-urilor primariilor municipiilor din Romania," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 2, 2012.
- [15] C. Vrabie, "E-Guvernarea în municipiile Romaniei (2014) Analiza orizontala a Web site-urilor primariilor municipiilor din Romania," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 3, 2014.
- [16] C. Vrabie, "E-guvernarea in municipiile Romaniei. Best cases.," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 4, 2015.

- [17] C. Vrabie, "Analiza orizontala a Web site-urilor primariilor oraselor din Romania," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 5, 2016.
- [18] C. Vrabie, "Studiu de impact "E-guvernarea în municipiile României". Analiza orizontala a Web site-urilor primăriilor municipiilor din România," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 6, 2020.
- [19] C. Vrabie, "Analiza orizontala a Web site-urilor primăriilor municipiilor din România," *Impact Studies on E-Government and Smart Cities (ISEGOV)*, vol. 7, 2024.
- [20] I. Hashem, R. Usmani, M. Almutairi, A. Ibrahim, A. Zakari, F. Alotaibi, S. Alhashmi and H. Chiroma, "Urban Computing for Sustainable Smart Cities: Recent Advances, Taxonomy, and Open Research Challenges.," *Sustainability* , vol. 15, no. 5, 2023.
- [21] C. Bonnell, "In business we trust. People trust businesses more than governments, nonprofits, media: survey," Associated Press, 16 01 2023. [Online]. Available: <https://eu.usatoday.com/story/money/2023/01/16/trust-business-more-than-government-nonprofits-media-survey/11062453002/>. [Accessed 23 04 2023].
- [22] N. Vangelov, "Ambient Advertising in Metaverse Smart Cities," *SCRD Journal*, vol. 7, no. 1, pp. 43-55, 2023.
- [23] D. C. Iancu and M. Ungureanu, "Depoliticizing the Civil Service: a critical review of the public administration reform in Romania," *Research in social change*, vol. 2, no. 2, pp. 63-106, 2010.
- [24] D. C. Iancu, "European compliance and politicization of public administration in Romania," *Innovative Issues and Approaches in Social Sciences*, vol. 6, no. 1, pp. 103-117, 2013.
- [25] B. Hamrouni, A. Bourouis, A. Korichi and M. Brahmi, "Explainable Ontology-Based Intelligent Decision Support System for Business Model Design and Sustainability," *Sustainability* , vol. 13, no. 17, 2021.
- [26] Y.-C. Chen, M. Ahn and Y.-F. Wang, "Artificial Intelligence and Public Values: Value Impacts and Governance in the Public Sector," *Sustainability* , vol. 15, no. 6, 2023.
- [27] C. v. 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*, vol. 39, no. 3, 2022.
- [28] J. Reis, P. E. Santo and N. Melão, "Artificial Intelligence in Government Services: A systematic literature review," *Springer Nature*, pp. 241-252, 2019.
- [29] Thakhathi V. G. and Langa R. D., "The role of smart cities to promote smart governance in municipalities," *SCRD Journal*, vol. 6, no. 2, pp. 9-22, 2022.
- [30] KPMG, "Manage the effects of Robotic Process Automation to enable a future-proof workforce," KPMG Advisory, 2019.
- [31] J. Sánchez, J. Rodríguez and H. Espitia, "Review of Artificial Intelligence Applied in Decision-Making Processes in Agricultural Public Policy," *Processes* , vol. 8, no. 11, 2020.
- [32] C. Schachtner, "Smart government in local adoption – Authorities in strategic change through AI," *SCRD Journal*, vol. 5, no. 3, pp. 53-62, 2021.
- [33] J. Etscheid, "Artificial Intelligence in Public Administration," in *Electronic Government. EGOV 2019. Lecture Notes in Computer Science*, Springer, 2019.
- [34] D. Kolkman, "The usefulness of algorithmic models in policy making," *Government Information Quarterly*, vol. 37, no. 3, 2020.
- [35] M. Ibtissem , B. Mohsen and B. Jaleleddine , "Quantitative relationship between corruption and development of the Tunisian stock market," *Public and Municipal Finance*, vol. 7, no. 2, pp. 39-47, 2018.
- [36] A. Munshi, A. Mehra and A. Choudhury, "LexRank Algorithm: Application in Emails and Comparative Analysis," *International Journal of New Technology and Research (IJNTR)*, vol. 7, no. 5, pp. 34-38, 2021.

- [37] M. Zalwert, "LexRank algorithm explained: a step-by-step tutorial with examples," 5 5 2021. [Online]. Available: <https://maciejzalwert.medium.com/lexrank-algorithm-explained-a-step-by-step-tutorial-with-examples-3d3aa0297c57>. [Accessed 25 3 2023].
- [38] Hans Jochen Scholl and Manuel Pedro Rodríguez Bolívar, "Regulation as both enabler of technology use and global competitive tool: The Gibraltar case," *Government Information Quarterly*, vol. 36, no. 3, 2019.
- [39] C. Vrabie and E. Dumitrascu, Smart cities: de la idee la implementare, sau, despre cum tehnologia poate da strălucire mediului urban, Bucharest: Universul Academic, 2018.
- [40] T. TIMAN, A. F. V. VEENSTRA and G. BODEA, "Artificial Intelligence and public services," European Parliament, 2021.
- [41] H. Wu, Z. Wang, F. Qing and S. Li, "Reinforced Transformer with Cross-Lingual Distillation for Cross-Lingual Aspect Sentiment Classification," *Electronics*, vol. 10, 2021.
- [42] H. Mehr, "Artificial Intelligence for Citizen Services and Government," Harvard Ash Center, 8 2017. [Online]. Available: https://ash.harvard.edu/files/ash/files/artificial_intelligence_for_citizen_services.pdf. [Accessed 18 3 2023].
- [43] A. Reshi, F. Rustam, W. Aljedaani, S. Shafi, A. Alhossan, Z. Alrabiah, A. Ahmad, H. Alsuwailam, T. Almangour, M. Alshammari, E. Lee and I. Ashraf, "COVID-19 Vaccination-Related Sentiments Analysis: A Case Study Using Worldwide Twitter Dataset," *Healthcare*, vol. 10, no. 3, 2022.
- [44] A. Alabrah, H. Alawadh, O. Okon, T. Meraj and H. Rauf, "Gulf Countries' Citizens' Acceptance of COVID-19 Vaccines—A Machine Learning Approach," *Mathematics*, vol. 10, no. 3, 2022.
- [45] S. Zschirnt, "Justice for All in the Americas? A Quantitative Analysis of Admissibility Decisions in the Inter-American Human Rights System," *Laws*, vol. 10, no. 3, 2021.
- [46] J. M. Kleinberg, "Authoritative Sources in a Hyperlinked Environment," *Journal of the ACM*, vol. 46, no. 5, p. 604–632, 1999.
- [47] J. Hreňo, P. Bednár, K. Furdík and T. Sabol, "Integration of Government Services using Semantic Technologies.," *J. Theor. Appl. Electron. Commer. Res.*, vol. 6, no. 1, 2011.
- [48] D. Piaggese, "Hyper Connectivity as a Tool for the Development of the Majority," *International Journal of Hyperconnectivity and the Internet of Things*, 2021.
- [49] S. Verma, "Sentiment analysis of public services for smart society: Literature review and future research directions," *Government Information Quarterly*, vol. 39, no. 3, 2022.
- [50] M. Chui, M. Harrysson, J. Manyika, R. Roberts, R. Chung, P. Nel and A. v. Heteren, "Applying artificial intelligence for social good," McKinsey Global Institute, 28 11 2018. [Online]. Available: <https://www.mckinsey.com/featured-insights/artificial-intelligence/applying-artificial-intelligence-for-social-good>. [Accessed 09 04 2023].
- [51] Google, "Google Colaboratory," [Online]. Available: <https://colab.research.google.com/#scrollTo=-gE-Ez1qtyIA>. [Accessed 25 2 2023].
- [52] Google Research, "BERT," 2020.
- [53] R. Silipo and K. Melcher, "Text Encoding: A Review," towardsdatascience, 21 11 2019. [Online]. Available: <https://towardsdatascience.com/text-encoding-a-review-7c929514cccf#:~:text=Index%2DBased%20Encoding,that%20maps%20words%20to%20indexes..> [Accessed 08 04 2023].
- [54] J. Kameni, F. Flambeau, N. Tsopze and M. Tchuente, "Explainable Deep Neural Network for Skills Prediction from Resumes," 12 2021. [Online]. Available: https://www.researchgate.net/publication/357375852_Explainable_Deep_Neural_Network_for_Skills_Prediction_from_Resumes?channel=doi&linkId=61cb04a1b8305f7c4b074a9b&showFulltext=true. [Accessed 08 04 2023].
- [55] DreamQuark, "TabNet : Attentive Interpretable Tabular Learning," Paris, 2019.
- [56] Tensor Flow, "Deep playground," Tensor Flow, [Online]. Available: <https://github.com/tensorflow/playground>. [Accessed 19 3 2023].

- [57] E. Brynjolfsson and A. McAfee, "The business of artificial intelligence," *Harvard Business Review*, vol. 95, no. 1, pp. 53-62, 2017.
- [58] T. H. Davenport and R. Ronanki, "Artificial intelligence for the real world," *Harvard Business Review*, vol. 96, no. 1, pp. 108-116, 2018.
- [59] M. Schrage, "The key to winning with AI: Improve your workflow—not your algorithm," *MIT Sloan Management Review*, vol. 59, no. 4, pp. 1-9, 2018.
- [60] Smar-EDU Hub, "'Accelerating innovation' Smart Cities International Conference (SCIC), 10th Edition, 2022," 8 12 2022. [Online]. Available: <https://www.smart-edu-hub.eu/about-scic10/conference-program10>. [Accessed 18 3 2023].
- [61] OpenAI, "Introducing ChatGPT," OpenAI, 11 2022. [Online]. Available: <https://openai.com/blog/chatgpt>. [Accessed 18 3 2023].
- [62] I. Sutskever, Interviewee, *Fireside Chat with Ilya Sutskever and Jensen Huang: AI Today and Vision of the Future*. [Interview]. 22 3 2023.
- [63] E. Akyürek, D. Schuurmans, J. Andreas, T. Ma and D. Zhou, "What learning algorithm is in-context learning? Investigations with linear models," *arXiv*, 2022.
- [64] C. Vrabie, "Education – A Key Concept for E-Administration," *Procedia - Social and Behavioral Sciences*, vol. 186, pp. 371-375, 2015.
- [65] A.-M. Tirziu and C. Vrabie, "NET Generation. Thinking outside the box by using online learning methods," *MPRA*, 2016.
- [66] B. Alcott, "Jevons' paradox," *Ecological Economics*, vol. 54, no. 1, pp. 9-21, 2005.
- [67] S. Sorrell, "Jevons' Paradox revisited: The evidence for backfire from improved energy efficiency," *Energy Policy*, vol. 37, no. 4, pp. 1456-1469, 2009.
- [68] L. Fich, S. Viola and N. Bentsen, "Jevons Paradox: Sustainable Development Goals and Energy Rebound in Complex Economic Systems.," *Energies*, vol. 15, no. 16, 2022.
- [69] OpenAI, "GPT-4 is OpenAI's most advanced system, producing safer and more useful responses," OpenAI, 14 03 2023. [Online]. Available: <https://openai.com/product/gpt-4>. [Accessed 23 04 2023].
- [70] B. Barnhart, "The importance of social media sentiment analysis (and how to conduct it)," Sprout Social, 27 3 2019. [Online]. Available: <https://sproutsocial.com/insights/social-media-sentiment-analysis/>. [Accessed 6 5 2022].
- [71] V. Dabhade, "Conducting Social Media Sentiment Analysis: A Working Example," Express Analytics, 24 5 2021. [Online]. Available: <https://www.expressanalytics.com/blog/social-media-sentiment-analysis/>. [Accessed 6 5 2022].
- [72] K. Jindal and R. Aron, "A systematic study of sentiment analysis for social media data," *Materials Today: Proceedings*, 2021.
- [73] A. Tirziu and C. Vrabie, "Living Labs – Instruments of Social Innovation in Rural Areas," *Proceedings of the Central and Eastern European e|Dem and e|Gov (CEEeGov) Days*, 2017.
- [74] 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.
- [75] A. Ilyas, S. Santurkar, D. Tsipras, L. Engstrom, B. Tran and A. Madry, "Adversarial Examples Are Not Bugs, They Are Features," in *33rd Conference on Neural Information Processing Systems*, Vancouver, 2019.
- [76] D. Neagu, A. Rus, M. Grec, M. Boroianu, N. Bogdan and A. Gal, "Towards Sentiment Analysis for Romanian Twitter Content," *Algorithms*, vol. 15, no. 10, 2022.
- [77] Ș. Cioban, "Cross-Domain Sentiment Analysis of the Natural Romanian Language," in *Digital Economy. Emerging Technologies and Business Innovation*, Springer Link, 2021, pp. 172-180.