

Raport 4

Proiect:

**SCAN-NEWS: Sistem inteligent pentru detecția și atenuarea răspândirii
dezinformării și știrilor false în rețelele sociale**

- Decembrie 2025 -

Director proiect: Conf. Habil. Dr. Ing. Elena-Simona APOSTOL

Proiectul SCAN-NEWS a fost motivat de nevoia stringentă de a contracara impactul negativ al știrilor false asupra coeziunii sociale și a procesului decizional. Obiectivul central de a dezvolta sisteme bazate pe Inteligență Artificială pentru (1) detectarea veridității știrilor, (2) analiza propagării informațiilor false în rețele sociale online, (3) imunizarea rețelelor, oprind astfel propagarea informațiilor malițioase de tip dezinformare, propagandă, etc.

Impactul proiectului se manifestă pe plan tehnologic, științific și cultural.

Pe plan tehnic și științific, au fost dezvoltate noi reprezentări vectoriale, care încapsulează contextul local (prin word embeddings și transformers), contextul global și informații de rețea și bazate pe grafuri de difuzie. Aceste reprezentări au contribuit la creșterea performanței modelelor de tip ansamblu propuse, atât pentru identificarea veridității informației, cât și pentru clasificarea tipurilor de dezinformare în cazul conținutului fals. De asemenea, activitatea de cercetare a cuprins și formularea și aplicarea unor strategii de imunizare a rețelelor sociale, realizând analiza proceselor de difuzie a informației pe grafuri dinamice de dimensiuni foarte mari, care modelează rețele sociale actuale cu milioane de utilizatori activi simultan.

Platformă SCAN-NEWS oferă utilizatorilor și o interfață grafică, prin care aceștia pot verifica veridicitatea informațiilor și pot identifica evenimente asociate fenomenelor de dezinformare. De asemenea, sistemul oferă o vizualizare structurată și clusterizată a subiectelor analizate, facilitând înțelegerea relațiilor dintre topic-uri și evidențierea tendințelor emergente din spațiul informațional. Astfel, prin facilitarea accesului la informații corecte și verificate, această platformă contribuie la impactul cultural, sprijinind publicul larg în filtrarea conținutului neveridic și în adoptarea unor decizii informate.

Prezentul raport oferă o analiză detaliată a activităților de cercetare și diseminare desfășurate în cadrul proiectului SCAN-NEWS în intervalul iulie – decembrie 2025. Documentul include, de asemenea, o sinteză a principalelor rezultate și realizări obținute pe parcursul întregului proiect.

1. Activități de cercetare

Proiectul SCAN-NEWS are ca prin focus analiza diferitelor tipuri de dezinformări prezente în mediul online și cu precădere în rețelele sociale, precum:

- Știri false (en. *fake news*): reprezintă informații false prezentate ca fiind adevărate
- Dezinformare parțială: constă în informații adevărate, dar prezentate într-un mod înșelător
- Satire și umor confundate cu realitatea: sunt știri sau postări satirice sau umoristice care sunt interpretate greșit ca fiind adevărate
- Conspirații: constă în teorii nefondate care explică evenimente sau fenomene complexe prin intermediul unor explicații simple, dar false
- Dezinformare neintenționată (en. *misinformation*): sunt informații incorecte, dar răspândite fără intenție de a înșela, ci din simplă neștiință sau eroare
- Dezinformare intenționată (en. *disinformation*): reprezintă răspândirea deliberată de informații false sau distorsionate cu scopul de a manipula sau înșela
- Etc.

Obiectivul principal al proiectului SCAN-NEWS se concentrează pe două direcții majore, cercetarea și dezvoltarea de:


- **[O₁]** noi modele de detecție de tip ansamblu care să integreze, pe lângă contextul cuvintelor extras cu soluții bazate pe Transformers, informații despre polaritatea și tematica știrilor, precum și graful de difuzie al știrii în rețelele sociale, pentru o detecție mai precisă;
- **[O₂]** noi strategii de imunizare a rețelelor sociale care au ca scop stoparea sau limitarea răspândirii online a informațiilor false, contribuind la un mediu digital mai sigur.

Diagrama GANTT a proiectului																					
WP	Luna	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
WP1	Activități de management																				
S1.1	Management administrativ				D1a					D1b						D1c					D1d
S1.2	Management tehnic										D1e						D1f				
WP2	Analiza cerințelor și soluțiilor similare existente																				
S2.1	Analiza critică a soluțiilor existente				D2a																
S2.2	Cerințe funcționale și non-funcționale					D2b															
S2.5	Cerințe tehnologice																				
WP3	Colectarea și adnotarea datelor																				
S3.1	Analiza seturilor de date disponibile online					D3a															
S3.2	Colectarea de noi date din mediile sociale								D3b												
S3.3	Preprocesare și extragerea caracteristicilor									D3c	M3a										
WP4	Proiectarea și implementarea sistemului																				
S4.1	Proiectarea arhitecturii																				
S4.2	Implementarea algoritmilor de Învățare Automată													D4a							
S4.3	Scierea codului modulelor arhitecturii																D4b				
S4.4	Integrarea modulelor																	D4c	M4a		
S4.5	Proiectarea interfeței cu utilizatorii																	D4d			
WP5	Evaluare și validare																				
S5.1	Definirea scenariilor de test															D5a					
S5.2	Testare experimentală a modulelor și sistemului															D5b	D5c	D5d			
S5.3	Optimizări ale sistemului																		D5e	M5a	
WP6	Diseminare și exploatare																				
S6.1	Diseminarea rezultatelor								D6a							D6b		D6c		D6d	
S6.2	Exploatare sistem																				M6b

Figură 1. Diagrama GANTT

Principalele activități de cercetare desfășurate în Etapa 4 a proiectului SCAN-NEWS s-au încadrat în pachetele de lucru **WP4. Proiectarea și implementarea sistemului**, **WP5. Evaluare și validare** și **WP6. Diseminare și exploatare**, conform cu calendarul de activități (detaliat în *Figură 1. Diagrama GANTT*). Sinteza acțiunilor derulate în aceste pachete de lucru este prezentată în continuare.

- **(WP4) Nouă arhitectură de analiză a sentimentelor:** În cadrul aceste acțiuni s-a propus o nouă arhitectură de tip ansamblu pentru analiza sentimentelor pe aspecte. Spre deosebire de soluția inițială propusă în proiect (Raportul 2), care furniza doar polaritatea generală a textului, noul model aduce o granularitate mai mare și informații contextuale mai detaliate pentru îmbunătățirea modulului de detecție a dezinformării.
- **(WP4) Algoritmi de detecție bazați pe Modele Lingvistice Mari (LLM-uri):** În cadrul aceste acțiuni s-au propus modele de detecție bazate pe versiuni fine-tuned de LLMs. Ca modele de bază s-a plecat de la arhitectura Transformer ALBERT și familia de modele lingvistice LLaMa. Pentru seturile de date multilingve s-a folosit o variantă fine-tuned de XLM-RoBERTa.
- **(WP4) Optimizarea algoritmului de imunizare:** În cadrul aceste acțiuni s-a propus o modalitate de optimizare a algoritmului de imunizare descris în Raportul 1. Rezultatele finale a fost trimise spre a fi publicate.
- **(WP5) Evaluare și validare:** În această etapă au fost definite mai multe scenarii de test pentru evaluarea modulelor implementate până la acest moment. O mare parte din rezultate au fost deja diseminate la diferite conferințe și jurnale.
- **(WP6) Diseminarea și exploatare:** În această etapă, au fost publicate (1) 1 articol de jurnal cotate ISI Q1 în *Informatică și Inteligență Artificială* și (2) 5 articole de conferință (mai multe detalii în *Secțiunea 2. Activități de publicare*)



Figură 2. Arhitectura generală SCAN-NEWS

Arhitectura soluției finale este ilustrată în *Figură 2. Arhitectura generală SCAN-NEWS*. La momentul finalizării raportului 3, toate modulele beneficiau deja de activități de proiectare, implementare și testare. În cadrul raportului 4, accentul a fost pus pe introducerea de îmbunătățiri și pe evaluarea unor noi direcții bazate pe modele de tip ansamblu și pe Modele Lingvistice Mari (LLM-uri).

În secțiunile următoare sunt prezentate detalii privind implementarea și rezultatele obținute pentru aceste module. Precizăm că prezentul raport, la fel ca și cele anterioare, include exclusiv rezultate deja publicate.

Analiza și Detectia Veridicității Informațiilor postate în Mediile Sociale

În această secțiune vom prezenta pe scurt stadiul de dezvoltare anterior Raportului 4, iar ulterior vom detalia activitățile realizate în cadrul Raportului 4 pentru următoarele componente: *Sub-modulul de Analiză a Sentimentelor* și *Modulul de Analiză și Detectie*.

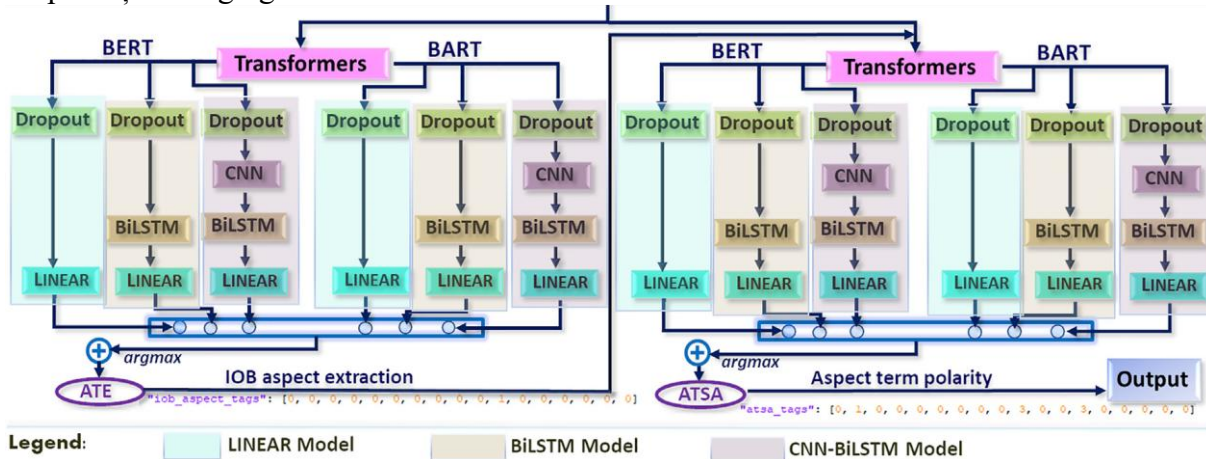
Sub-Modulul Analiza a Sentimentelor

În cadrul proiectului SCAN-NEWS am cercetat cum tehnicile de analiză a sentimentelor pot îmbunătăți procesul de detectare a diferitelor tipuri de dezinformare, inclusiv a știrilor false, sau propagandei distribuite pe rețelele sociale. Prin evaluarea tonului și a poziționării emoționale din conținut, pot fi identificate tipare care semnaleză potențiale manipulări sau distorsiuni ale informației. Astfel, postările care exprimă emoții foarte pozitive sau foarte negative, în special atunci când nu sunt susținute de argumente sau dovezi solide, pot constitui indicii privind prezența dezinformării sau a propagandei. Neconcordanțele dintre sentimentul exprimat și realitatea faptică pot sugera intenția de a induce în eroare, fiind frecvente în conținuturile manipulative de tip propagandă. De asemenea, analiza sentimentelor poate contribui la clasificarea tipurilor de dezinformare, oferind indicii suplimentare în detectarea conținuturilor alarmiste (de exemplu, pentru detectia panicării publicului), mesajelor polarizante, discursurilor manipulative, unde tonul emoțional este folosit intenționat pentru a amplifica impactul mesajului fals.

Pentru sub-modulul de Analiză a Sentimentelor, obiectivul a fost dezvoltarea unor modele capabile să extragă atât polaritatea la nivel de conținut, cât și poziționarea autorului față de informațiile discutate. Prima soluție, un model de tip ansamblu, a fost prezentată în detaliu în cadrul Raportului 2, sub denumirea EDSA-Ensemble (Event Detection Sentiment Analysis Ensemble). EDSA folosește și un algoritm de extragere a subiectelor (componenta ED - Event Detection) ce ajută la depistarea topic-urilor de interes și la identificarea grupurilor sau indivizilor vizați de discursul dezinformant. Odată ce un eveniment/topic este detectat, ansamblul EDSA aplică Analiza Sentimentului (prin componenta SA-Sentiment Analysis) pentru a determina polaritatea generală a evenimentului (impact pozitiv sau negativ asupra rețelei). Un sentiment agregat puternic negativ (sau polarizat) este un indicator cheie al conținutului problematic (discurs de ură sau dezinformare cu intenție malițioasă).

În Raportul 4, ne-am concentrat pe un model de tip ansamblu superior celui prezentat în Raportul 2 ce poate analiza în profunzime discursul dezinformant prin faptul că oferă o granularitate mult mai mare a analizei, concentrându-se pe aspecte specifice ale textului. Soluția propusă poartă numele de ATESA-BÆRT. ATESA-BÆRT este un model eterogen de tip ansamblu pentru Aspect-Based Sentiment Analysis (ABSA), alcătuit din 12 configurații distincte care îmbină transformare pre-antrenate și mai apoi fine-tunate de noi (i.e., BERT și BART) cu modele neuronale clasice (i.e., Linear, BiLSTM, CNN-BiLSTM). Soluția împarte problema ABSA în două sub-task-uri: (1) Aspect Term Extraction (ATE) - extragerea

termenilor/aspectelor din text, folosind etichetare IOB; și (2) Aspect Term Sentiment Analysis (ATSA) – clasificarea polarității fiecărui aspect, i.e., negativ, neutru, pozitiv. Arhitectura generală a ansamblului este prezentată în Figura 3. Fiecare ramură a sistemului (ATE și ATSA) cuprinde șase modele, iar predicția finală este realizată printr-o strategie argmax asupra ieșirilor agregate.



Figură 3. Arhitectura soluției de analiză a sentimentelor bazată pe Aspect

ATESA-BÆRT a depășit d.p.d.v. a acurateții toate modelele din state-of-the-art cu care am făcut comparația (ex. DeBERTa, BERTAsp+SCAPT, RGAT-BERT, SA-BERT-XGBoost). Pentru aceste comparații am folosit seturi de date clasice orientate spre review-uri comerciale. Atât ramura ATE cât și ramura ATSA au obținut acuratețe de aproximativ 99% pe experimentele noastre. În urma comparării timpilor de execuție, am concluzionat că modelul BERT fine-tunat de noi este preferabil modelului BART din perspectiva costurilor computaționale, însă combinația în ansamblu oferă robustețe sporită.

Rețelele sociale conțin scriere informală, greșeli, ironii, termeni multi-cuvânt ad-hoc, etc. Prin combinația Linear + BiLSTM + CNN-BiLSTM și prin contextualizarea dublă (BERT + BART), ATESA-BÆRT reușește să gestioneze mai eficient textul informal și zgomotos din rețelele sociale. Pentru detectarea dezinformării, aceasta înseamnă mai puține fals-negative în prezența textelor scrise neîngrijit, detecție cu un grad mare de fiabilitate a sentimentelor chiar când autorii folosesc strategii de evitare (ex. ironii, formulări confuze).

În cadrul arhitecturii SCAN-NEWS, ieșirea obținută din ansamblul ATESA-BÆRT a fost utilizată ca encodare vectorială de aspect-sentiment și dat ca input pentru clasificatorul final de dezinformare. Discursurile de dezinformare și manipuloare pot amplifica emoții extreme sau inconsecvente. Soluția propusă, ATESA-BÆRT, furnizează modului de detecție informații despre polaritate granulară pe aspect, de asemenea poate permite identificarea contradicțiilor dintre aspecte (ex. un mesaj laudă un element și denigrează altul în mod artificial pentru a induce confuzie), identifică pattern-uri de emoții neobișnuit de intense, detectează polarizări artificiale între aspecte ale aceluiași subiect, și poate surprinde “framing emoțional” manipulator. Rezultatele prezentate în această secțiune au fost publicate în jurnalul Elsevier *Knowledge-Based Systems*, cu un factor de impact de 7.6.


Modulul de Analiză și Detecție

În raportul precedent am arătat cum metodele tradiționale bazate doar pe analiza conținutului textual sunt insuficiente. Știrile false se propagă prin rețele sociale, iar informațiile despre modul de răspândire (redat în graful de difuzie) și comportamentul utilizatorilor sunt importante pentru a determina veridicitatea cât și tipul de dezinformare, unde este cazul. Soluția propusă de noi a fost GETAE, o arhitectură AI de tip ansamblu care integrează două tipuri de informații: (1) informația de conținut (caracteristicile extrase direct din textul știrii), (2) informația de graf/propagare (caracteristicile extrase din structura și dinamica rețelei sociale). Aceasta permite modelului să înțeleagă dacă un text, deși pare inofensiv la prima vedere, este asociat cu un tipar de difuzie specific știrilor false (propagare rapidă, rețele închise, etc.). Ansamblu folosește mai multe tipuri de rețele neuronale adânci (ex. Convolutional Neural Networks-CNN, Recurrent Neural Networks-RNN/LSTM/GRU). Aceste rețele sunt antrenate folosind un nou tip de Transformer-based embedding ce combina informațiile de conținut și cele de propagare, denumit de noi *Propagation-Enhanced Content Embedding*. Predicțiile obținute de la fiecare model din ansamblu sunt combinate printr-o metodă de vot ponderat.

Activitățile din ultima parte a proiectului au presupus și testarea și fine-tunarea unor noi modele pentru ansamblul de detecție, modele bazate pe arhitectura Transformer de tip LLM (Model Lingvistic Mare).

O primă soluție de îmbunătățire a modului de detecție din cadrul platformei SCAN-NEWS a avut la bază arhitectura de tip Transformer ALBERT (A Lite BERT). Modelul propus folosește o versiune fine-tuned de noi a lui ALBERT și l-am numit VERIT-ALBERT. Arhitectura VERIT-ALBERT include și modulul Weight Learner (Figura 4) care ajustează dinamic hiperparametrii (ex. learning rate-ul) și este folosit pentru optimizarea procesului de antrenare și prevenirea supraînvațării. Prin folosirea acestui mecanism se pot reduce costurile computaționale și se accelerează convergența, mai ales în contextul seturilor de date dezechilibrate.

Pentru fine-tuning, s-a folosit o strategie mixtă care combină transfer learning, frozen encoder și optimizarea dinamică a hiperparametrilor. Arhitectura ALBERT pre-antrenată a fost păstrată în mare parte înghețată, adică straturile transformatorului nu au fost modificate în timpul antrenării. Au rămas antrenabile doar straturile noi, adăugate pentru sarcina de clasificare de știri false.



Figură 4. Arhitectura VERIT-ALBERT

Modelul a fost fine-tunat cu doua seturi de date LIAR și ISOT. Strategie de fine-tuning a diferit pentru fiecare dataset.

Pentru setul de date LIAR, datorită dezechilibrului la nivel de clase, s-a fost folosit undersampling și grid search pe hiperparametri (Tabel 1). Astfel s-au identificat configurații care minimizează overfitting-ul.

Step	Training Loss	Validation Loss	Accuracy	F1-Score	Precision	Recall	Accuracy Label False	Accuracy Label True
100	0.697900	0.709045	0.530938	0.487493	0.608075	0.530938	0.256781	0.868597
200	0.701600	0.672267	0.577844	0.491135	0.601480	0.577844	0.938517	0.133630
300	0.692400	0.725074	0.533932	0.517572	0.571239	0.533932	0.356239	0.752784
400	0.670000	0.648858	0.631737	0.612705	0.634880	0.631737	0.822785	0.396437
500	0.693300	0.708954	0.497006	0.394113	0.662281	0.497006	0.113924	0.968820
600	0.671600	0.655458	0.632735	0.595177	0.655540	0.632735	0.895118	0.309577
700	0.687000	0.638660	0.641717	0.617173	0.652782	0.641717	0.858951	0.374165
800	0.657400	0.637755	0.637725	0.632721	0.635007	0.637725	0.739602	0.512249
900	0.635800	0.651164	0.647705	0.641017	0.645851	0.647705	0.764919	0.503341
1000	0.651000	0.633196	0.653693	0.640721	0.656358	0.653693	0.815552	0.454343
1100	0.626800	0.634108	0.641717	0.628297	0.642814	0.641717	0.804702	0.440980
1200	0.629700	0.630788	0.634731	0.634400	0.634151	0.634731	0.676311	0.583519
1300	0.600700	0.626623	0.644711	0.642213	0.642459	0.644711	0.719711	0.552339
1400	0.600800	0.623506	0.650699	0.646329	0.648441	0.650699	0.746835	0.532294
1500	0.597400	0.624640	0.655689	0.648939	0.654399	0.655689	0.773960	0.510022

Tabel 1. Metrice de antrenare (setul de date LIAR), după Grid Search

LIAR este compus din afirmații scurte și clasele sunt debalansate, acest lucru impactând metricele de performanță. Acuratețea finală a modelului propus de noi pentru acest set de date, deși relativ mică (65%) a fost semnificativ mai mare decât alte modele cu care am comparat sau decât modelul ALBERT standard (56%). Scorurile F1-score și precizia au fost în creștere odată cu avansarea antrenării. O problemă a fost distribuția etichetelor, spre exemplu enunțurile *True*, fiind mai scurte, au fost clasificate corect cu dificultate mai mare. Modelul tinde să supraînvețe după 3–4 epoci, motiv pentru care a fost aleasă o configurație redusă de epoci și un mecanism de optimizare atent reglat. În final, s-a demonstrat o stabilitate rezonabilă prin aplicarea stratified K-folds, deși setul de date rămâne problematic pentru toate modelele analizate.

În cazul setului de date ISOT, modelul a fost antrenat pe un număr mic de epoci, obținându-se rezultate bune și datorită lungimii mai mari a articolelor din acest set de date (Tabel 2).

Step	Training Loss	Validation Loss	Accuracy	F1-Score	Precision	Recall	Accuracy Label False	Accuracy Label True
100	0.981800	0.224849	0.964376	0.964378	0.964445	0.964376	0.959350	0.969584
200	0.841800	0.195508	0.968743	0.968744	0.968766	0.968743	0.966125	0.971455
300	0.755000	0.176542	0.973339	0.973341	0.973402	0.973339	0.968383	0.978474
400	0.692000	0.161241	0.975178	0.975180	0.975222	0.975178	0.971093	0.979410
500	0.650500	0.148202	0.977017	0.977017	0.977019	0.977017	0.976513	0.977539
600	0.604900	0.141377	0.978396	0.978397	0.978449	0.978396	0.973803	0.983154
700	0.611800	0.134659	0.980234	0.980235	0.980257	0.980234	0.977416	0.983154
800	0.559900	0.130406	0.981154	0.981154	0.981165	0.981154	0.979223	0.983154
900	0.531900	0.129065	0.981384	0.981384	0.981403	0.981384	0.978771	0.984090

Tabel 2. Metrice de antrenare (setul de date ISOT)

Deoarece acest set de date conține articole lungi și clase echilibrate a permis modelelor testate să obțină acuratețe mult mai bună. Modelul propus de noi a avut o acuratețe finală de 98%, fiind cea mai ridicată dintre toate modelele testate.

În acest caz, modulul Weight Learner accelerează convergența și îmbunătățește vizibil rezultatele, mai ales pentru rata de învățare de $4e-5$, care oferă cea mai bună performanță pe toate metricile. Modelul converge rapid (100–300 de pași), fără semne de supra-antrenare.

Rezultatele prezentate în această secțiune au fost publicate într-un articol de conferință.

O altă soluție de clasificare propusă în cadrul acestei etape a fost pentru date multilinguale și e bazată pe un ansamblu de tip Mixture of Transformers (MoT), care maximizează performanța prin valorificarea modelelor lingvistice adaptate fiecărei sarcini (task) și limbi. Cele două sarcini de detecție definite pentru această soluție sunt (1) detecția veridicității știrilor (clasificare binară), și (2) detecția tipului de știre falsă (dezinformare, propagandă, satiră, mit urban, etc.) Arhitectura integrează un ansamblu eterogen de modele Transformer, incluzând variante general-purpose, task-specific și multilingve. O caracteristică cheie pentru proiectul SCAN-NEWS este mecanismul de language-aware routing care, în funcție pe limba textului combină predicțiile celor mai bune modele English-only și multilingve prin strategii de ponderare, cum ar fi Dominant-75% (predicția modelelor English-only au o pondere de 75%, pentru restul de 25% se consideră modelele multilingve). Arhitectura a fost antrenată și pe date obținute în cadrul unei competiții construite pentru detecția sexismului.

Aceste rezultate au fost publicate într-un articol de conferință ISI.

Un alt model propus și testat pentru partea de detecția a avut la bază familia de Modele Lingvistice Mari LLaMA2. În construirea acestui model, am aplicat o abordare multi-task, în care modelul este antrenat simultan pe mai multe tipuri de date etichetate, acoperind categorii precum cyberbullying, extremism, amenințări, incitare și propagandă. Soluția propusă este capabilă să distingă nuanțe semantice complexe și să ofere clasificări coerente indiferent de tipul de conținut analizat. Evaluările experimentale demonstrează că această depășește performanța modelelor de referință în toate categoriile testate, obținând rezultate superioare în metrici precum acuratețe, F1-score și interpretabilitate. Modelul prezintă o generalizare excelentă, menținând performanțe mari atât pe seturi de date curate, cât și pe seturi zgomotoase și puternic dezechilibrate. Pe model s-a aplicat și analiză de tip ablation pentru a se vedea contribuția fiecărui modul arhitectural, iar testele cross-dataset arată că soluția propusă de noi reușește să transfere competențe între tipuri diferite de conținut dăunător (ex. dezinformare, propagandă, instigare la ură), reducând necesitatea fine-tuning-ului per-dataset.

Aceste rezultate au fost publicate într-un articol de conferință ISI.

2. Activități de publicare

În cadrul proiectului SCAN-NEWS au fost publicate, cu afiliere AOSR, un număr de 14 articole științifice. Dintre acestea, șase sunt articole de jurnal indexate ISI și clasificate Q1 conform Journal Citation Reports (JCR) pe 2023 respectiv 2024.

Din totalul celor 14 publicații, șase articole au fost raportate în decembrie 2025, iar restul au fost incluse în raportările anterioare: în prima parte a anului 2025 (Raportul 3) și în primul an al proiectului (Raportele 1 și 2).

Lista publicațiilor pentru proiectul SCAN-NEWS este redată mai jos.

Publicații raportate în Decembrie 2025

- **Elena-Simona Apostol**, Alin-Georgian Pisciă, Ciprian-Octavian Truică. *ATESA-BART: A heterogeneous ensemble learning model for Aspect-Based Sentiment Analysis*. Knowledge-Based Systems, 326:1-13(113987), ISSN 0950-7051, Septembrie 2025. DOI: [10.1016/j.knosys.2025.113987](https://doi.org/10.1016/j.knosys.2025.113987) (Jurnal cotate ISI Q1 în Computer Science și Inteligență Artificială, F.I. = 7.6 conform JCR 2024)
- Ciprian-Octavian Truică, **Elena-Simona Apostol**, Alexandru-Gabriel Ilie, Adrian Paschke. *HarmLLaMA: Harmful Language Detection with Large Language Models*. International Conference on Intelligent Computer Communication and Processing (ICCP 2025), Octombrie 2025
- Daria-Elena Burghilea, Ciprian-Octavian Truică, **Elena-Simona Apostol**. *VERIT-ALBERT: A Finetuned LLM Approach for Verifying Information Credibility*. RoEduNet Conference Networking in Education and Research, Septembrie 2025. DOI: [10.1109/RoEduNet68395.2025.11208267](https://doi.org/10.1109/RoEduNet68395.2025.11208267)
- Alexandru Petrescu, Ciprian-Octavian Truică, **Elena-Simona Apostol**. *Language-based Mixture of Transformers for Sexism Identification in Social Networks*, Conference and Labs of the Evaluation Forum (CLEF 2025), p. 142-155, Septembrie 2025. DOI: [10.1007/978-3-032-04354-2_10](https://doi.org/10.1007/978-3-032-04354-2_10)
- Alexandru Petrescu, **Elena-Simona Apostol**, Ciprian-Octavian Truică. *Awakened at EXIST2025: Adaptive Mixture of Transformers*, Working Notes of the Conference and Labs of the Evaluation Forum (CLEF 2025), p. 2112-2118, Septembrie 2025
- Maria-Diana Cotelin, Ciprian-Octavian Truică, **Elena-Simona Apostol**. *NetGuardAI at EXIST2025: Sexism Detection using mDeBERTa*, Working Notes of the Conference and Labs of the Evaluation Forum (CLEF 2025), p. 1897-1905, Septembrie 2025

Publicații raportate în Iunie 2025

- **Elena-Simona Apostol**, Ciprian-Octavian Truică, Mariana Damova, Purificação Silvano, Giedre Valunaite Oleškevičienė, Chaya Liebeskind, Dimitar Trajanov, Anna Baczkowska, Emma Angela Montecchiari, Christian Chiarcos. *Multiword Discourse Markers Across Languages: A Linguistic and Computational Perspective*, International Journal of Applied Linguistics, Wiley, ISSN 0802-6106, Aceptat spre publicare în Aprilie 2025. DOI: [10.1111/ijal.12755](https://doi.org/10.1111/ijal.12755) (Jurnal cotate ISI Q1 în Lingvistică, F.I. = 1.7 conform JCR 2024)

- Ciprian-Octavian Truică, **Elena-Simona Apostol**, Marius Marogel, Adrian Paschke. *GETAE: Graph Information Enhanced Deep Neural NeTwork Ensemble*. Expert Systems with Applications, vol. 275, ISSN 0957-4174, Mai 2025, DOI: [10.1016/j.eswa.2025.126984](https://doi.org/10.1016/j.eswa.2025.126984) (Jurnal cotatec ISI Q1 în Computer Science și Inteligență Artificială, F.I. = 7.5 conform JCR 2024)

Publicații raportate în Decembrie 2024

- Alexandru Petrescu, Ciprian-Octavian Truică, **Elena-Simona Apostol**, Adrian Paschke. *EDSA-Ensemble: an Event Detection Sentiment Analysis Ensemble Architecture*. IEEE Transactions on Affective Computing, 16(2): 555-572, ISSN: 1949-3045, April 2025, *Disponibil online: August 2024*, Publicat: Aprilie 2025, DOI: [10.1109/TAFFC.2024.3434355](https://doi.org/10.1109/TAFFC.2024.3434355) (Jurnal cotatec ISI Q1, F.I. = 9.6 conform JCR 2023)
- **Elena-Simona Apostol**, Ciprian-Octavian Truică, Adrian Paschke. *ContCommRTD: A Distributed Content-based Misinformation-aware Community Detection System for Real-Time Disaster Reporting*. Transactions on Knowledge and Data Engineering Journal, November 2024. DOI: [10.1109/TKDE.2024.3417232](https://doi.org/10.1109/TKDE.2024.3417232) (Jurnal cotatec ISI Q1, F.I. = 8.9 conform JCR 2023)
- Ciprian-Octavian Truică, Ana-Teodora Constantinescu, **Elena-Simona Apostol**. *StopHC: A Harmful Content Detection and Mitigation Architecture for Social Media Platforms*. IEEE International Conference on Intelligent Computer Communication and Processing (ICCP 2024), Octombrie 2024 (Conferință ISI cotatec Național în CORE)

Publicații raportate în Iulie 2024

- **Elena-Simona Apostol**, Özgür Coban, Ciprian-Octavian Truică. *CONTAIN: A community-based algorithm for network immunization*. Engineering Science and Technology, an International Journal. Elsevier. 55:1-10(101728), ISSN 2215-0986, Iulie 2024. DOI: [10.1016/j.jestch.2024.101728](https://doi.org/10.1016/j.jestch.2024.101728) (Jurnal cotatec ISI Q1, F.I. = 5.1 conform JCR 2023)
- **Elena-Simona Apostol**, Adrian-Cosmin Cojocaru, Ciprian-Octavian Truică. *Large-Scale Graphs Community Detection using Spark GraphFrames*. The 23rd International Symposium on Parallel and Distributed Computing (ISPDC 2024). Iulie 2024 (Conferință ISI cotatec C în CORE)
- Alexandru Petrescu, Ciprian-Octavian Truică, **Elena-Simona Apostol**. *Language-based Mixture of Transformers for EXIST2024*. Conference and Labs of the Evaluation Forum (CLEF2024). Publicată în Lecture Notes in Computer Science (LNCS). Septembrie 2024 (Conferință ISI)

Data: 04.12.2025

Semnătură director,
Conf. Dr. Ing. Habil. Apostol Elena-Simona