

Sinteză activității sub-proiect 1 : „Dezvoltarea experimentală a tehnologiilor emergente din domeniul sistemelor de recomandare (deep learning on big data) la nivelul rețelelor sociale online și studiul impactului acestora la nivelul utilizatorilor (AI Media)”, derulate în anul 2020

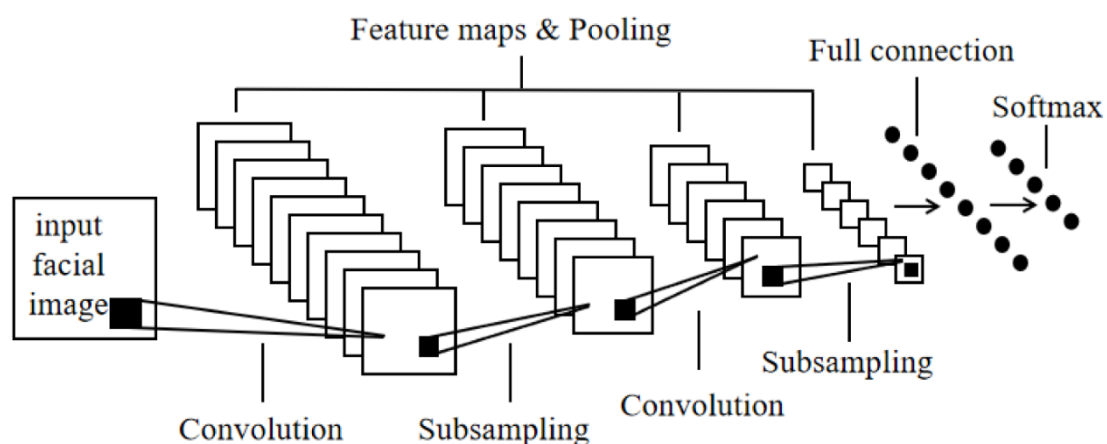
Activitatea 1-3-3: Dezvoltarea serviciului de analiză a sentimentelor (sentiment analysis) persoanelor care apar în fotografiile sau clipurile media ce conțin logo-ul unui anumit brand sau companii.

În cadrul acestei activități, am abordat detectarea emoțiilor din imaginile în care apar logo-urile de interes. Acest lucru presupune detectarea persoanelor din imaginile în care apar logo-urile, detectarea feței persoanelor și clasificarea acestora în unul dintre emoțiile de bază.

Pentru analiza sentimentelor, a fost folosit algoritmul Haar Cascade Classifier, bazat pe învățare automată în care o funcție în cascadă este antrenată dintr-o mulțime de imagini pozitive și negative, clasificând emoțiile în mai multe categorii:

- Emoții de bază (Basic Emotions - BEs) – fac referire la șase emoții umane de bază, adică fericirea, surpriza, tristețea, mânia, dezgustul și frica.
- Emoțiile compuse (Compound Emotions - CEs) – sunt combinații de două emoții de bază.
- Micro expresii (Micro Expressions - MEs) – reprezintă mișcări faciale mai spontane și mai subtile care apar involuntar.
- Unități de acțiune facială (Facial Action Units - AUs) – unități de acțiune facială codifică mișcările de bază ale individului sau grupurilor de mușchi.

O rețea neuronală convoluțională - CNN este adaptată direct în majoritatea abordărilor de detectare a sentimentelor bazate pe învățare profundă.



Structura unei rețele CNN în contextual recunoașterii emoțiilor

Pentru fiecare dintre imaginile și videoclipurile încărcate în aplicația AI Media, se aplică serviciul de analiză a sentimentelor.

Livrabil: *Studiu_1_3_3_analiza_sentiment_imagine*

Activitatea 1-3-4: Dezvoltarea serviciului suplimentar de recunoaștere a contextului (privind sentimentele și intențiile clienților) în care este utilizat numele unui brand sau produs în textul (comentarii, discuții, recenzii ș.a.) din cadrul rețelelor sociale online sau al blog-urilor și forum-urilor.

În cadrul acestui studiu, analiza sentimentelor a fost aplicată la nivel de cuvânt, la nivel de propoziție sau document sau la nivel de entitate sau aspect (Entity and Aspect or Feature Analysis). În timp ce analiza la nivel de document (Document Analysis) specifică dacă opinia exprimată este pozitivă sau negativă, analiza la nivel de entitate sau aspect specifică entitatea opiniei.

Alegerea caracteristicilor pentru clasificarea sentimentului este importantă pentru obținerea unei precizii cât mai bune. Exemple de caracteristici posibile pentru clasificarea sentimentului ar fi: Sentiment Lexicon, Reguli pentru opinii, Emoticon-uri, Frecvența și prezența termenilor, etc.

Testarea modelelor se face pe baza clasificării. Pentru clasificarea textului se folosește *transfer learning* (învățarea prin transfer) unde, în primă fază antrenarea se face pe un corpus mare. Apoi, se finalizează pe un corpus țintă. În cele din urmă, se instruește clasificatorul folosind exemple etichetate. În exemplul următor este ilustrat procesul de instruire.

În exemplul următor este ilustrat procesul de instruire.



Fig. 1 Clasificare text. Proces de instruire


Modelul nu necesită date etichetate pentru pregătirea prealabilă. Inițial este pre-instruit un model într-o manieră nesupravegheată, apoi este reglat pe un set de date specific domeniului. Astfel, clasificarea se face folosind mult mai puține date. Acest lucru este important, deoarece în practică nu există seturi de date mari care să fie etichetate. Modelul este combinația dintre arhitectura rețelei neuronale și setări specifice (*hyperparameter*).

Pentru implementare, a fost utilizată biblioteca FastText, lansată de echipa Facebook AI Research (FAIR) în 2016, care este bazată pe procesare CPU și utilizată pentru învățarea eficientă a reprezentărilor de cuvinte (încorporări de cuvinte) și clasificarea de text. Este scrisă în C și acceptă multiprocessing în timpul antrenării. Unul dintre obiectivele fastText este de a permite formarea modelelor fără a fi nevoie de un GPU. FastText permite atât antrenarea nesupravegheată cât și antrenarea nesupravegheată a reprezentărilor de cuvinte și pentru clasificarea de propoziții și este capabil să obțină performanțe foarte bune pentru reprezentările de cuvinte și clasificarea propozițiilor.

Pentru o eficiență bună pe seturi de date cu un număr foarte mare de categorii, se folosește un clasificator ierarhic în locul unei structuri plane, în care diferitele categorii sunt organizate într-un arbore (arbore binar în loc de lista).

Modelul BERT este un transformator bidirecțional antrenat pe sarcina de modelare a limbajului mascat (MLM) și sarcina de predicție a următoarei propoziției (NSP).

Arhitectura propusă pentru clasificarea sentimentelor cu granulație fină:



Clasificator de sentimente folosind modelul pre-instruit BERT

Pentru detecția de sentimente din text au fost identificate și testate două modele de rețele de deep learning care au prezentat în literatura studiată cele mai bune rezultate și anume: fastText și BERT. Au fost identificate seturi de date pentru detecția de sentimente din text dintre care au fost selectate Large Movie Review Dataset, Amazon Reviews for Sentiment Analysis și Amazon Earphones Reviews Kaggle. Aceste seturi sunt disponibile pentru cercetare și conțin atitudini și sentimente ale unor utilizatori clienți care au cumpărat anumite produse și servicii și care își exprimă opinia pe diverse rețele de socializare. Pe baza seturi selectate a fost construit un set propriu prin combinarea lor și prezentate într-un format unic, set folosit ulterior pentru instruirea rețelelor. Au rezultat modele de rețele pre-instruite cu o precizie de 88,10% pe fastText și 95,38% pe BERT.

Livrabil: *Studiu_1_3_4_analiza_sentiment_text*

Activitatea 1-3-5: Dezvoltarea serviciului suplimentar de recunoaștere a produselor fizice ale unei companii prin analiza conținutului imaginilor platformelor eCommerce

Selectarea fotografiilor adecvate pentru produse și campaniile de marketing ce conțin produse este extrem de semnificativă pentru promovarea platformei eCommerce. Anul acesta Google a lansat "Google feed for merchants", funcție ce permite vizualizarea produselor sub bara de căutare. Folosirea eficientă a imaginilor de produs în campaniile de marketing poate reprezenta un diferențiator strategic semnificativ.

Imaginile sunt foarte diverse și adesea conțin scene complexe cu mai multe obiecte (8,4 per imagine în medie). Am utilizat adnotări de etichete la nivel de imagine, casete de delimitare a obiectelor, segmentări de obiecte, relații vizuale, narațiuni localizate și multe altele.

Am folosit rețeaua RetinaNet, bazată pe casete care au fost introduse o dată cu Faster RCNN și au fost utilizate de algoritmi dezvoltați. Anterior acestei metode, se utiliza algoritmul de căutare selectivă, însă, obiectele pot avea dimensiuni diferite. Această metodă este utilă pentru generarea propunerilor de regiuni cu formă variabilă. În tabelul de mai jos se pot observa rezultatele obținute.


Clasa	Număr imagini	Număr imagini	Precizie
-------	---------------	---------------	----------

	antrenare	evaluare	
Tin can	500	31	84 %
Mobile phone	500	98	82,7 %
Printer	210	19	95%


Am considerat oportună includerea de imagini detectate cu rețelele instruite cu titlul de exemplificare:



Exemple detecție de obiecte din clasa Mobile phone



Exemple detecție de obiecte din clasa Tin Can



Exemple detecție de obiecte din clasa Printer

Limitele acestei analize sunt datorate timpului îndelungat de antrenare algoritmului înainte de-a fi folosit, și etichetarea manuală a produselor. Pentru a reduce acest timp poate fi utilizat un serviciu în cloud ce folosește antrenare pe GPU sau TPU.

Livrabil: *Studu_1_3_5_recunoastere_produce_image*

Activitatea 1-4-1: Integrarea aplicației la nivelul proiectului și ajustarea aplicației AI Media prin contribuția directă a membrilor consorțiului de cercetare și a utilizatorilor aplicației

Au fost identificate 3 modalități de integrare, care au fost testate alternativ de echipa de cercetare.

Prima modalitate implică *servicii web REST*. Integrarea subproiectului AI Media cu aplicația unitară la nivel de proiect se poate face prin servicii web REST. La nivelul aplicației AI Media au fost dezvoltate o serie de servicii REST prin intermediul cărora alte aplicații se pot interconecta cu aplicația AI Media. Pe baza acestor servicii web se pot apela funcțiile implementate la nivelul subproiectului AI Media.

A doua modalitate implică realizarea unui *link către aplicația existentă*. În cadrul subproiectului AI Media a fost dezvoltată o interfață web, pentru a facilita operarea și testarea serviciilor web REST dezvoltate. Această interfață ar putea fi folosită ca atare. Pentru accesarea interfeței web, în aplicația unitară care face integrarea tuturor subproiectelor, se poate rezerva un link ce va avea ca referință interfața web a subproiectului AI Media.

Cea de-a treia modalitate – conectarea la *Iframe*, presupune ca interfața dezvoltată în cadrul subproiectului AI Media ar putea fi folosită ca atare, integrarea cu aplicația unitară putând fi făcută prin folosirea unui *iframe*. Mai exact, în cadrul aplicației unitare, într-una dintre pagini este folosit un *iframe* în care va rula aplicația AI Media. Transparent aplicația pare a fi rulată direct de pe serverul aplicației unitare, în fapt aplicația AI Media este doar integrată într-o pagină a acesteia.

În cadrul folderului rezultatelor acestei activități, se regăsesc:

- descrierea serviciilor AIMedia REST (fișierul *aimedia-api-docs.json* ce poate fi vizualizat în site-ul <https://editor.swagger.io/>)
- oferirea unei descrieri a modului de integrare a serviciilor AIMedia REST în aplicația FutureWeb - *futureweb_aimedia_integrare_servicii_rest_v1.txt*
- serviciile web REST, care se pot accesa de către utilizatori la adresa web: <https://195.34.77.2:12184/ro.ugal.futureweb.aimedia/api/v4>

Livrabil: 1.4.1. Integrarea aplicației

Activitatea 1-4-2: Promovarea aplicației AI Media în rândul potențialilor utilizatori

În acest scop, a fost planificat în perioada 4.05.2020 – 18.06.2020 un webinar dedicat promovării online a aplicației AI Media în rândul potențialilor utilizatori. A fost realizat un landing page <https://aimedia.thecon.ro/> care a fost promovat de membrii echipei, a fost gestionat procesul legat de înregistrările participanților și au fost pregătite prezentări ale managerului de proiect la nivelul partenerului – Universitatea Dunărea de Jos din Galați – Prof. univ. dr. Adrian Micu, respectiv ale doi membri din echipa de cercetare: Prof. univ. dr. Alexandru Căpățînă și dr. Dan Munteanu. În data de 19.06.2020 a avut loc webinarul, la care au participat aproape de 30 de persoane interesate de implementarea aplicației AI Media. Conținutul webinarului a fost înregistrat integral, pe platforma Zom, și este disponibil pe Youtube: <https://www.youtube.com/watch?v=ORsbKDa6gI&feature=youtu.be>

Am preferat varianta unui webinar în locul unui workshop datorită condițiilor speciale impuse de pandemia COVID-19.

Livrabile: prezentări webinar, capturi de imagini

Activitatea 1-4-3: Realizarea unui Ghid de utilizare și implementare a aplicației AI Media

Prin dezvoltarea aplicației AI Media se dorește adresarea directă a factorilor care determina succesul în campaniile din social media. În același timp, aceasta aplicație poate fi utilizată și ca sistem de monitorizare și analize statistice, de exemplu pentru a urmări dacă brandul sau produsele vizate au fost plasate în conformitate cu cerințele producătorului în campanii de social media. Analizarea unui eșantion considerabil poate duce la identificarea unor influenceri a căror rol poate fi extins, acționând ca ambasadori de produs în cadrul unor campanii ce vizează direct o audiență target-ată. Folosirea algoritmilor de deep learning pentru a identifica sentimentele acestor influenceri în diferitele paragrafe de conținut pe care aplicația AI Media le analizează și luând în calcul multitudinea de date legate de context social, locație geografică, analiza sentimentului va fi posibilă prin realizarea unor analize cantitative pornind de la resurse de conținut calitativ, utilizând cu preponderență algoritmi de inteligență artificială. În contextul impactului social media asupra brandurilor, o analiză privind cercetarea de marketing a unui produs folosind rețele neuronale este necesară.

Aplicația AI Media este o unealtă pentru analize de marketing ale unor brand-uri/companii pe rețele sociale. Oferă posibilitatea de import a postărilor, comentariile, imaginilor și clipurilor video dintr-o rețea socială aleasă pentru cercetare.

În cadrul ghidului au fost prezentate în extenso cele 5 servicii ale platformei AI Media (Serviciul de recunoașterea logo-urilor, Serviciul de recunoaștere a locației geografice, Serviciul de recunoaștere a contextului social, Serviciul de analiză a sentimentelor și Serviciul de recunoaștere a produselor fizice ale unei companii), precum și print-screen-uri din interfața de utilizare a aplicației.

Livrabil: 1.4.3. Ghid utilizare AI Media

Activitatea 1-5-1: Diseminarea pe scara largă a rezultatelor proiectului (prin workshop-uri și conferințe științifice, oferte de marketing și realizarea de articole în publicații de larg interes la nivelul comunității locale și la nivel național)

În anul 2020, membrii echipei de cercetare au realizat și publicat 5 articole cu acknowledgement proiect FutureWeb:

1. Micu A., Geru M., Micu A.E., Capatina A., Avram C., Rusu R., 2020, Empirical Insights on Cloud Services for Machine Learning Applications, Annals of Dunarea de Jos din Galati. Fascicle I. Economics and Applied Informatics, no. 2/2020, pp. 85-90, ISSN 1584-0409

http://www.eia.feaa.ugal.ro/images/eia/2020_2/Micu_Geru_Micu_Capatina_Avram_Rusu.pdf

<https://dbh.nsd.uib.no/publiseringskanaler/erihplus/periodical/info?id=493270>

https://www.aeaweb.org/econlit/journal_list.php

2. Capatina, A., Kachour, M., Lichy, J., Micu, A., Micu, A. E., & Codignola, F. (2020). Matching the future capabilities of an artificial intelligence-based software for social media marketing with potential users' expectations. Technological Forecasting and Social Change, 151, 119794.

<https://www.sciencedirect.com/science/article/abs/pii/S0040162519310613>

https://apps.webofknowledge.com/full_record.do?product=WOS&search_mode=GeneralSearch&qid=3&SID=C4YQm3CbWU1rMvZkgU7&page=1&doc=1

3. Enache M.C., 2020, AI for Advertising, Annals of Dunarea de Jos din Galati. Fascicle I. Economics and Applied Informatics, no. 1/2020, pp. 28-32, ISSN 1584-0409
http://www.eia.feaa.ugal.ro/images/eia/2020_1/Cristina_Enache_1.pdf
<https://dbh.nsd.uib.no/publiseringskanaler/erihplus/periodical/info?id=493270>
https://www.aeaweb.org/econlit/journal_list.php
4. Enache M.C., 2020, Sentiment Analysis in Tourism, Annals of Dunarea de Jos din Galati. Fascicle I. Economics and Applied Informatics, no. 1/2020, pp. 81-85, ISSN 1584-0409
http://www.eia.feaa.ugal.ro/images/eia/2020_1/Cristina_Enache_2.pdf
<https://dbh.nsd.uib.no/publiseringskanaler/erihplus/periodical/info?id=493270>
https://www.aeaweb.org/econlit/journal_list.php
5. Munteanu D., Munteanu N. (2020). Sentiment Analysis Based on Deep Learning Techniques Applied to Children in Logical Games from Nonformal Education eLearning sustainment for never-ending learning, Proceedings of the 16th International Scientific Conference "eLearning and Software for Education" Bucharest, April 23-24, 2020, Volume 1, DOI: 10.12753/2066-026X-20-007, Pages: 57-65, Publisher: Carol I National Defence University Publishing House
<https://proceedings.elseconference.eu/index.php?r=site/index&year=2020&index=papers&vol=35&paper=45bbd04c72d2864a66d90a96b38c3649>

Livrabile/Indicatori de realizare:

4 studii (servicii de cercetare) - 4 studii realizate – Rapoarte 1.3.3, 1.3.4, 1.3.5 și diseminarea rezultatelor către firme în cadrul webinarului

1 baza de date - baza de date fw_senti_text_dataset (Baza de date poate fi descarcata de la adresa <https://195.34.77.2:12183/> Baza de date (set de date) cu texte denumita fw_senti_text_dataset descrisa in studiul Studiu_1_3_4_analiza_sentiment_text.docx in capitolul 7.4 Setul de date Future Web. Datele au fost extrase din setul de date 3 seturi IMDb movie review (50.000 reviews), Reviews for Sentiment Analysis - Amazon] (4.000.000 reviews si 100.000 de reviews) și Earphones Reviews (14.337 reviews). Toate textele (recenziile si sentimentele respective) au fost stocate în fișiere CSV care contin campurile: 'sentiment', 'text', 'negative', 'neutral', 'positive', 'set'.)

1 documentatie de integrare a modului AI Media la nivelul rețelei sociale online FutureWeb – Raport 1.4.1

1 stagiul de formare tanar cercetător – 1 mobilitate cec de tip B pentru tineri cercetători – în derulare la ASE București, perioada 21.09.2020 – 7.10.2020 – Rusu Robert

5 articole in publicatii de larg interes la nivelul comunitatii locale/nationale – 1 articol ISI în revista Technological Forecasting and Social Change, IF 5,846, Q1 zona roșie;