

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)

În cadrul Subproiectului 1, ce se focalizează asupra utilizării unor sisteme de analiză și recomandare complexe (deep learning), fost realizată Identificarea utilizatorilor potențiali și a așteptărilor acestora privind aplicația AI Media, a fost realizată o analiză a pieței privind soluțiile existente similare cu AI Media, a fost realizat un Ghid de bune practici pentru realizarea aplicației AI Media, folosind algoritmi de Machine Learning, care utilizează instrumente de recunoaștere a imaginilor și identificare a sentimentele provocate de postările din diferitele blocuri de conținut analizate, au fost realizate studii calitative și cantitative în rândul utilizatorilor potențiali ai aplicației AI Media, pentru a identifica așteptările privind capacitățile aplicației și a determina intenția de utilizare a sa și au fost formulate cerințele funcționale ale aplicației AI Media, fiind conceputa pentru a oferi următoarele servicii: identificarea logo-urilor din imagini și video; recunoașterea geolocației; contextul social în care e plasată pe o rețea socială o imagine și analiza sentimentelor.

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

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 supravegheată 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 listă).

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

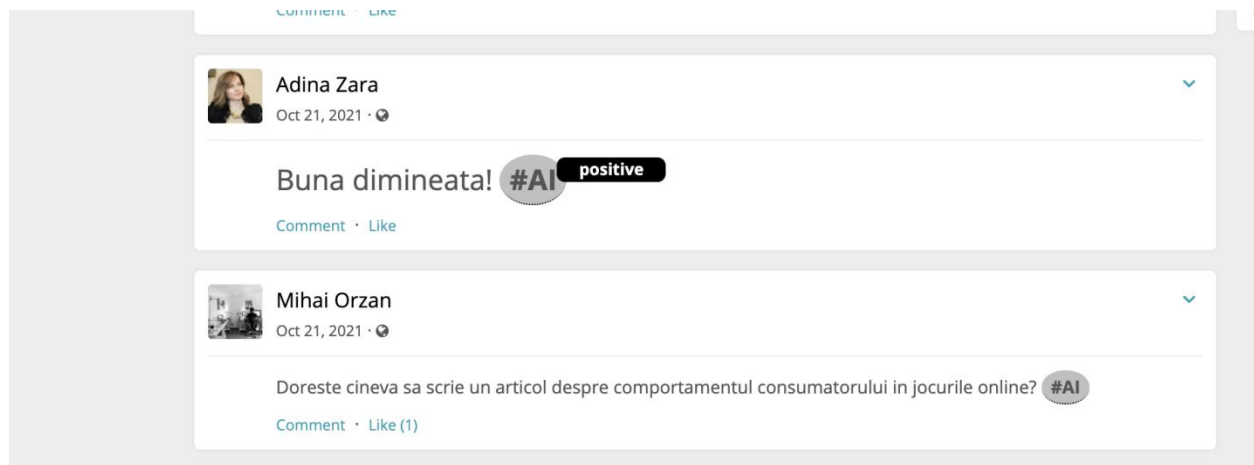
Pentru detecția de sentimente din text au fost identificate și testate două modele de rețele de deep learning care au prezentat în literatura studiată cele mai bune rezultate și anume: fastText și BERT. Au fost identificate seturi de date pentru detecția de sentimente din text dintre care au fost selectate 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.

În perioada de raportare a fost finalizată implementarea modului AI Media și integrarea acesteia în interfața comună FutureWeb și a fost completată structurarea ofertei de servicii de cercetare și tehnologice și prezentarea în platforma ERRIS cu studiul integrării serviciilor de tip deep learning în cadrul unei rețele sociale online. 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.



Sistemul de analiza a starii mesajului a fost implementat folosind un sistem mai complex, format astfel incat procesarea textelor sa fie facuta in coada, iar mesajulului procesat, pentru are exista si un rezultat sa i se ataseze o bulina cu text-ul #AI, care la mouse-over sa afiseze rezultatul procesarii.

Astfel, la o prima incarcare a unui mesaj nou, fie ele tiltu sau comentariu, script-ul in cauza transmite o cerere de procesare, continand hash-ul md5 al textului si textul in cauza, care va fi atasata intr-o coada de procesare. Un job automat ruleaza pe server la un interval de 5 minute, urmand sa

proceseze textele noi stocate in coada. Atunci cand procesarea a avut loc si mesajul a obtinut un rezultat al procesarii, atunci la verificarea ulterioara a codului hash aferent text-ului, doar rezultatul va fi returnat.