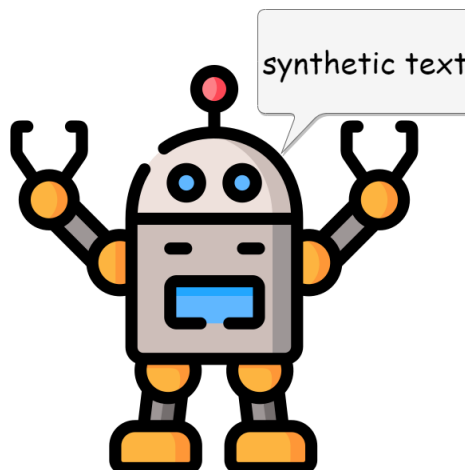




Katedra Systemów Multimedialnych

Zespół projektowy: 41@KSMM'2022pb AI Tech	1. Jan Tobolewski - kierownik 2. Karol Baran 3. Natalia Rucińska
Opiekun:	dr hab. inż. Piotr Szczuko
Klient:	Piotr Szczuko (Konsorcjum AI Tech - Akademia innowacyjnych zastosowań technologii cyfrowych)
Data zakończenia:	20.01.2023
Słowa kluczowe:	Generowanie tekstu, Uczenie głębokie, Splotowe sieci neuronowe



TEMAT PROJEKTU:

Klasyfikator naturalności stylu tekstu - autentyczny czy syntetyczny.

CELE I ZAKRES PROJEKTU:

Celem projektu jest stworzenie algorytmu wyróżniającego styl tekstu napisanego przez człowieka od tekstów wygenerowanych przez algorytmy generujące.

1. Przygotowanie zbioru danych tekstów naturalnych.
2. Wygenerowanie tekstów syntetycznych.
3. Douczenie modelu do generowania tekstów z tematyki medycznej.
4. Wybór i opracowanie modelu głębokiego klasyfikatora wyróżniającego styl tekstu.
5. Ewaluacja modelu, sprawdzenie skuteczności.
6. Porównanie osiągniętych wyników ze skutecznością rozróżniania stylu tekstu przez ankietowanych.

OSIĄGNIĘTE REZULTATY:

1. Zbiór tekstów naturalnych na bazie na artykułów [Harvard Health Publishing](#)
2. Zbiór tekstów syntetycznych podając algorytmowi znak zachęty (jedno zdanie z tekstu naturalnego).
3. Generator douczony do zdefiniowanego zadania – generowanie tekstów z tematyki medycznej.
4. Model grafowej splotowej sieci neuronowej klasyfikującej teksty pomiędzy dwie klasy – teksty naturalne, teksty syntetyczne.
5. Poszukiwanie najlepszego rozwiązania. Zaprezentowany model uznano za optymalny.
6. Przeprowadzenie ankiety oraz analiza wyników.

CECHY CHARAKTERYSTYCZNE ROZWIĄZANIA, KIERUNKI DALSZYCH PRAC:

Cechy charakterystyczne:

1. Dokładność na poziomie 80-90% jest wynikiem zadowalającym. Wyniki są znacznie lepsze niż uzyskane przez osoby ankietowane.
2. Zastosowanie grafowych sieci neuronowych.
3. Stosunkowo krótki czas uczenia i wnioskowania.
4. Uniwersalność metodyki umożliwia wykorzystanie z dowolnym modelem generującym tekst.


Kierunki dalszych prac:

1. Analiza innych struktur grafów. Sprawdzenie skuteczności klasyfikacji z zastosowaniem połączeń semantycznych między tokenami.
2. Ankieta skierowana dla respondentów silnie związanych z branżą medyczną.
3. Sprawdzenie skuteczności klasyfikacji dla języków fleksyjnych (np. język polski).



Katedra Systemów Multimedialnych

Project team: 41@KSMM'2022pb AI Tech	1. Jan Tobolewski - leader 2. Karol Baran 3. Natalia Rucińska
Supervisor:	dr hab. inż. Piotr Szczuko
Client:	Piotr Szczuko (Konsorcjum AI Tech - Akademia innowacyjnych zastosowań technologii cyfrowych)
Date:	20.01.2023
Key words:	Text classification, Deep learning, Graph Neural Networks



PROJECT TITLE:

A classifier of naturalness of text style - authentic or synthetic

OBJECTIVES AND SCOPE:

The goal of the research project is to prepare an algorithm to distinguish the style of human-written text from texts generated by generating algorithms.

1. Preparation a new dataset of natural texts.
2. Generation of synthetic texts.
3. Fine-tune text generator which would be better suited for medical texts specificity.
4. Selection and development of a classifier, based on deep learning, to distinguish text style.
5. Model evaluation, checking metrics accuracy.
6. Comparison of the results obtained with the effectiveness of distinguishing text style by the respondents.

RESULTS:

1. Natural text dataset based on [Harvard Health Publishing](#) articles.
2. Synthetic dataset, created form a line of prompt (one sentence from the natural text).
3. Fine-tuned generator for defined task – generating texts from medical domain.
4. Model of graph convolutional neural network classifying texts between two classes – natural and synthetic.
5. Results analysis and selection of the best result. The presented model was evaluated as optimal.
6. A survey was carried out, results analyzed.

MAIN FEATURES, FUTURE WORKS:

Features:

1. The model's accuracy of 80-90% is a satisfying score. These results are better than those obtained by survey respondents.
2. Utilization of graph neural networks.
3. The relatively short training and inference times.
4. Universal methodology that can be adapted to be used with any generating model.

Directions for further work:

1. Analyze other graph structures, and possibility of using semantic connections between tokens.
2. Conduct a survey targeted for people with strong association to the medical field.
5. Testing classification for inflected languages, e.g. Polish.