

Detekce Syntetického Textu:

Vývoj a Evaluace Nástroje DetekceGPT.cz pro Identifikaci Textů Generovaných Umělou Inteligencí

Kryštof Olík

Mgr. Filip Petroušek (supervizor)

krystof.olik@detekcegpt.cz

filip.petrousek@detekcegpt.cz

Ollsoft s.r.o.

IČO: 19336039, Příčná 1892/4, Nové Město (Praha 1), 110 00 Praha

Abstrakt

Tato studie se zaměřuje na vývoj a hodnocení nástroje DetekceGPT.cz, což je sofistikovaný systém pro detekci textu generovaného umělou inteligencí v pěti jazycích – češtině, slovenštině, angličtině, němčině a španělštině. S rychlým rozvojem technologií generování přirozeného jazyka je stále důležitější odlišovat texty generované lidmi od těch, které byly vytvořeny stroji. DetekceGPT.cz využívá pokročilé techniky strojového učení k identifikaci textů generovaných pomocí OpenAI ChatGPT. Provedli jsme rozsáhlé hodnocení nástroje na velké škále textů ve všech podporovaných jazycích. Naše výsledky ukazují, že DetekceGPT.cz může účinně a přesně identifikovat texty generované AI, což z něj činí robustní nástroj pro řešení této výzvy v různých jazycích a kontextech.

Úvod

Umělá inteligence (AI) a strojové učení jsou v dnešní době klíčovými technologiemi a nacházejí uplatnění v řadě aplikací, včetně generování přirozeného jazyka. Vysoce sofistikované LLMs (Large Language Models), jako jsou OpenAI's GPT-3, Google Bard, LLaMA a jejich následovníci, jsou schopné vytvářet texty, které jsou stále těžší rozlišit od těch psaných člověkem.¹ Tyto pokroky s sebou přinášejí značné příležitosti, ale zároveň také výzvy a rizika.

Syntetický text generovaný umělou inteligencí je problematický z mnoha důvodů. Ve školách může takový text ohrozit akademickou poctivost studentů, když se použije k plagiátorství nebo k vytvoření prací, které neodrážejí skutečné schopnosti a pochopení studenta.² Pro novináře a mediální organizace může syntetický text, který je těžko rozeznatelný od skutečného, vést k šíření falešných zpráv a dezinformací, což ohrožuje důvěryhodnost a integritu těchto institucí.³ A v kontextu organizací může nástup AI generovaných textů zpochybnit autentičnost komunikace a dokumentů.

Proto je nezbytné mít nástroje, které jsou schopné spolehlivě detekovat texty generované umělou inteligencí. V této práci představujeme nástroj DetekceGPT.cz, který byl vyvinutý s cílem identifikovat texty generované pomocí modelů GPT.

V následujících kapitolách podrobně popisujeme metodologii, kterou jsme použili při vývoji a testování DetekceGPT.cz, a předkládáme výsledky našeho rozsáhlého hodnocení tohoto nástroje. Naším cílem je poskytnout průkazné důkazy o efektivitě našeho nástroje při detekci syntetických textů a tím přispět k rozvoji robustních nástrojů pro boj proti potenciálním rizikům spojeným s AI generovanými texty.

¹ Peng, B., Li, C., He, P., Galley, M., & Gao, J. (2023). Instruction tuning with gpt-4. *arXiv preprint arXiv:2304.03277*.

² Dehouche, N. (2021). Plagiarism in the age of massive Generative Pre-trained Transformers (GPT-3). *Ethics in Science and Environmental Politics*, 21, 17-23.

³ Floridi, L., & Chiriatti, M. (2020). GPT-3: Its nature, scope, limits, and consequences. *Minds and Machines*, 30, 681-694.

Metodologie detekce

Vytvoření algoritmu pro nástroj DetekceGPT.cz bylo motivováno potřebou detekovat texty generované umělou inteligencí s vysokou přesností. Tento cíl vyžadoval vývoj robustního detekčního algoritmu, schopného zvládat nejen jednoduché, ale také složité texty, a zároveň pracovat v relativně krátkém čase.

Důležitým požadavkem byla také podpora více jazyků. Tento aspekt je klíčový pro široké využití nástroje, protože AI generované texty nejsou omezeny pouze na jediný jazyk. Proto byl náš algoritmus navržen a trénován tak, aby byl schopen efektivně detekovat AI generované texty v různých jazycích

Algoritmus

Základem nástroje DetekceGPT.cz je sofistikovaný algoritmus strojového učení, který byl trénován na rozsáhlém korpusu dat obsahujících jak texty psané člověkem, tak texty generované AI. Tato trénovací data byla pečlivě vybrána a anotována tak, aby algoritmus měl co nejlepší možnost se naučit rozlišovat mezi těmito dvěma typy textů.

Využíváme princip učení s učitelem, kdy model učíme na základě předem označených příkladů. Model se učí na základě vektorových příznaků, které jsou extrahovány z trénovacích textů a které se snaží zachytit klíčové rozdíly mezi texty napsanými člověkem a texty generovanými AI.⁴

DetekceGPT.cz používá konvoluční neuronové sítě (CNN), jež jsou účinné při analýze sekvenčních dat jako je text. CNN jsou schopné učit se a identifikovat důležité vzorce v textu, které mohou být indikátory toho, zda byl text generován člověkem nebo AI.⁵ Vedle toho nástroj využívá i metodu transfer

⁴ Duzhin, F., & Gustafsson, A. (2018). Machine learning-based app for self-evaluation of teacher-specific instructional style and tools. *Education Sciences*, 8(1), 7.

⁵ Wang, S., Huang, M., & Deng, Z. (2018, July). Densely connected CNN with multi-scale feature attention for text classification. In *IJCAI* (Vol. 18, pp. 4468-4474).

learningu, což umožňuje aplikovat znalosti získané při tréninku na jednom datasetu na jiný dataset. Tento přístup významně zvyšuje efektivitu a přesnost našeho nástroje, obzvláště v podpoře více jazyků.⁶

V procesu analýzy textu DetekceGPT.cz nejen využívá trénovaný model pro klasifikaci, ale také se zaměřuje na několik klíčových aspektů textu, které mohou naznačovat, že byl generován AI. Jedním z nich je "perplexity" textu - míra, jak moc je text předvídatelný. Jelikož modely AI, jako je GPT, jsou trénovány na základě většinově předvídatelných vzorců v textu, mohou generovat texty s nižší perplexity než průměrný člověk.⁷

Dále se algoritmus zaměřuje na styl psaní a klasické struktury či slovní spojení, které jsou typické pro texty generované Large Language Modely (LLM). Takové struktury a spojení mohou být pro člověka obtížné rozpoznat, ale pro náš algoritmus jsou klíčové při detekci AI generovaného textu.

To je důvod, proč DetekceGPT.cz používá kombinaci strojového učení a lingvistické analýzy k dosažení co nejvyšší úrovně přesnosti při identifikaci textů generovaných AI.

Nástroj DetekceGPT.cz sám serializuje text do potřebného vektorového formátu, vyčte si informace a následně použije CNN ke klasifikaci textu. Náš algoritmus je navržen tak, aby upřednostňoval detekci false negatives nad false positives, aby nebyl zbytečně poškozen žádný člověk.

Popis datasetů

Pro trénování a testování nástroje DetekceGPT.cz byly využity rozmanité datasety pokrývající širokou škálu textových stylů a struktur. Tímto způsobem bylo zajištěno, že náš model je schopen detekovat texty generované umělou inteligencí napříč různými typy textů.

⁶ Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.

⁷ Miaschi, A., Brunato, D., Dell'Orletta, F., & Venturi, G. (2021, June). What makes my model perplexed? a linguistic investigation on neural language models perplexity. In *Proceedings of Deep Learning Inside Out (DeeLIO): The 2nd Workshop on Knowledge Extraction and Integration for Deep Learning Architectures* (pp. 40-47).

1. **Common Crawl dataset** posloužil jako primární zdroj tréninkových dat. Tento rozsáhlý archiv webových stránek obsahuje mnoho typů textů napsaných lidskými autory a poskytli nám tak reprezentativní vzorek textů generovaných člověkem.⁸
2. **Datasets z Hugging Face** byly využity k získání textů generovaných AI. Specificky jsme použili následující datasey:
 - a. **XWikis Corpus**: Tento dataset nabízí texty v různých jazykových párech a směrech pro cross-lingual a multi-lingual abstraktivní sumarizaci dokumentů. Poskytovaný text umožňuje modelu DetekceGPT.cz rozumět a naučit se variace v textu generované překladem nebo sumarizací napříč různými jazyky.⁹
 - b. **MERLIN corpus**: Jedná se o psaný korpus pro češtinu, němčinu a španělštinu, který byl navržen tak, aby ilustroval společný evropský referenční rámec pro jazyky (CEFR) s autentickými daty od žáků. Korpus obsahuje texty vytvořené žáky v rámci standardizovaných jazykových certifikátů, které pokrývají úroveň CEFR od A1 do C1. Tato rozmanitost poskytuje modelu možnost naučit se detekovat AI generovaný text v různých úrovních zdatnosti jazyka.¹⁰
 - c. **MC4**: Tento dataset je multijazyčná obrovská, očištěná verze Common Crawl's web crawl korpusu. Založeno na datasetu Common Crawl: "<https://commoncrawl.org>". Tato verze byla připravena společností AllenAI a je hostována na této adrese: <https://huggingface.co/datasets/allenai/c4>. K dispozici

⁸ Common crawl. (n.d.). <https://commoncrawl.org/>

⁹ XWikis, <https://huggingface.co/datasets/GEM/xwikis> , Perez-Beltrachini, L., & Lapata, M. (2021). *Models and Datasets for Cross-Lingual Summarisation. Proceedings of The 2021 Conference on Empirical Methods in Natural Language Processing*. Punta Cana, Dominican Republic.

¹⁰ MERLIN corpus, <https://huggingface.co/datasets/aseifert/merlin>, Seifert, A. (n.d.). *ASEIFERT/Merlin · Datasets at hugging face*.

je 108 jazyků, což modelu umožňuje se naučit a porozumět textům generovaným v různých jazycích.¹¹

3. **Vlastní scrapovaná data:** Tato data byla získána prostřednictvím vlastního scrapingu a zahrnovala texty z širokého spektra online zdrojů. Cílem bylo získat realistický obrázek o jazykové rozmanitosti a strukturách textu, které jsou běžně používány v různých kontextech a jazycích. Zdroje zahrnovaly:
 - a. **Vzdělávací weby:** Tyto stránky poskytly bohatý zdroj textu na různých úrovních obtížnosti a na různá témata, od základního vzdělávání po pokročilé akademické texty.
 - b. **Online diskusní fóra pro studenty:** Texty z těchto fór zahrnovaly širokou škálu jazykových stylů a poskytovaly realistický obrázek o tom, jak lidé komunikují v online prostředí.
 - c. **Stránky s pracovními nabídkami:** Tyto stránky poskytly příklady formálního a profesionálního jazyka, který se liší od jazyka používaného v běžné komunikaci nebo akademických textech. Dále poskytli příklady motivačních dopisů a životopisů, což dále utvrdilo model v detekování profesních textů.
 - d. **Akademické časopisy:** Tyto časopisy poskytly příklady vysoko specializovaného a technického jazyka v různých oborech.
4. **Partnerství se školami:** V rámci vývoje nástroje DetekceGPT.cz bylo také vytvořeno partnerství se dvěma školami - jednou základní a jedním gymnáziem. Tyto školy poskytly texty, které byly odevzdávány jejich studenty během období pandemie COVID-19, kdy se většina výuky a domácích úkolů odehrávala online. Tyto texty byly anonymizovány a

¹¹ MC4, <https://huggingface.co/datasets/mc4>, Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., ... Liu, P. J. (2019). *Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer*. arXiv E-Prints. Retrieved from <http://arxiv.org/abs/1910.10683>

použity jako tréninková data pro náš model. Byly cenným zdrojem autentických studentských textů a poskytly nám možnost naučit model rozpoznat různé styly a úrovně psaní, které jsou typické pro studentské práce.

5. **AI texty:** Ke získání textů generovaných umělou inteligencí jsme využili čtyři populární jazykové modely jako jsou GPT-3.5, Google BARD, LLaMA a GPT-4. Na základě lidsky psaných textů získaných z předešlých datasetů jsme vytvořili syntetické alternativy generované umělou inteligencí, což naučilo neuronovou síť, jak vypadá text od jazykového modelu.

Soubor dat, který byl použit pro vývoj algoritmu DetekceGPT.cz, byl velmi rozmanitý, co se týče jazyka a typu textu. Ačkoli dominantní část dat představovala čeština, algoritmus byl také trénován na textech v dalších jazycích, mezi které patřila například angličtina, slovenština, němčina či španělština. To umožňuje našemu detekčnímu nástroji operovat efektivně napříč různými jazyky. Navíc, díky předem zmíněné metodě transfer learningu bylo možné model vytrénovat s širokou kompatibilitou na několik jazyků.¹²

Co se týče rozdělení dat, byla věnována zvláštní pozornost tomu, aby bylo zajištěno, že nedojde k jevu „overfitting“.¹³ K tomu byla data rozdělena do tří oddělených skupin: tréninková, validační a testovací. Tréninková data tvořila 70% celkového souboru dat a byla použita pro primární trénink modelu. Následně byla využita validační data, která tvořila 15% celkového souboru, aby se ověřila účinnost a robustnost modelu. Zbývajících 15% dat bylo použito jako testovací sada pro finální ověření účinnosti modelu. Tímto způsobem bylo dosaženo vyváženého rozdělení dat, které přispělo k vysoce efektivnímu a robustnímu modelu.

¹² Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.

¹³ Ying, X. (2019, February). An overview of overfitting and its solutions. In *Journal of physics: Conference series* (Vol. 1168, p. 022022). IOP Publishing.

Evaluace přesnosti nástroje

Pro hodnocení efektivity nástroje DetekceGPT.cz jsme provedli rozsáhlé testování na širokém spektru textů. Tato textová data zahrnovala mnoho různých typů dokumentů a textů od esejí na různá témata, příběhů, lyrických básní, prezentací, diplomových prací, seminárních prací a vědeckých článků až po motivační dopisy a e-mailové zprávy. Tato různorodost v nás zajistila, že náš nástroj je schopný detekovat texty generované umělou inteligencí v mnoha různých kontextech a stylových registrech.

Naše evaluace se zaměřila na přesnost detekce - procentuální poměr správně identifikovaných textů. Testovací data byla rozdělena na dvě kategorie - texty psané lidskými autory a texty generované AI.

Výsledky evaluace ukázaly, že DetekceGPT.cz je vysoce účinný v detekci AI generovaných textů. I když se někdy stalo, že některé texty generované AI nebyly správně identifikovány, většina textů byla detekována správně. Je důležité poznamenat, že u textů psaných lidskými autory byla úroveň přesnosti mimořádně vysoká - téměř všechny texty byly správně identifikovány jako lidské.

Jediná oblast, kde jsme narazili na problémy, byla detekce některých článků z Wikipedie. Tyto texty byly v některých případech nesprávně identifikovány jako generované umělou inteligencí. Může to být dáno tím, že styl psaní na Wikipedii je často velmi strukturovaný a formální, což může připomínat texty generované AI. Pracujeme na zlepšení našeho algoritmu tak, aby dokázal lépe rozlišovat mezi těmito specifickými typy textů.

Výsledky evaluace přesnosti nástroje DetekceGPT.cz

Typ textu	Správně detekované AI Texty (z 1000)	Správně detekované lidské Texty (z 500)	Úroveň přesnosti AI detekce (%)	Úroveň přesnosti lidské detekce (%)
Eseje	943	496	94.3	99.2
Příběhy	886	498	88.6	99.6
Lyrické básně	896	483	89.6	96.6
Diplomové práce	925	500	92.5	100
Vědecké články	932	456	93.2	91.2
Motivační dopisy	965	500	96.5	100
E-Mailové zprávy	913	494	91.3	98.8
Encyklopedie	743	398	74.3	79.6

Při vyhodnocování našeho nástroje jsme každému typu textu přiřadili 1000 unikátních vzorků generovaných umělou inteligencí (dohromady 8000 vzorků) a 500 vzorků napsaných lidmi (dohromady 4000). Co se týče identifikace textů vytvořených umělou inteligencí, klasifikovali jsme je jako úspěch, pokud náš nástroj určil, že je více než 50% pravděpodobnost, že byl text generován AI. Na druhé straně, lidsky psané texty jsme považovali za správně identifikované, pokud nástroj určil, že je méně než 50% pravděpodobnost, že byly generovány umělou inteligencí. Je vhodné podotknout, že všechny texty, kromě lyrických básní, byly delší než 1000 znaků, což je pro přesnou detekci potřebné.

Tyto výsledky ukazují, že náš nástroj je vysoce účinný a spolehlivý při detekci textů generovaných AI ve srovnání s texty psanými lidmi. Zároveň poukazují na oblasti, kde je možné dosáhnout dalších zlepšení.

Další důležitou součástí našeho testování bylo ověření schopnosti nástroje DetekceGPT.cz identifikovat texty generované různými jazykovými modely. Pro tento účel jsme zařadili do testovací sady texty vygenerované čtyřmi populárními AI modely - GPT-3.5, BARD, LLaMA a GPT-4.

Výsledky testů na textech generovaných modely GPT-3.5, BARD a LLaMA ukázaly, že náš nástroj je schopen s přesností identifikovat texty těchto modelů jako AI generované.

V případě textů generovaných nejnovějším modelem, GPT-4, byla úroveň přesnosti výrazně nižší. Náš nástroj správně identifikoval 64 % textů generovaných GPT-4 jako AI generované. Tato mírně nižší úroveň přesnosti je pravděpodobně způsobena pokročilejšími technikami generování textu používanými v modelu GPT-4, které umožňují tomuto modelu vytvářet texty ještě blíže stylu lidského psaní.

Následující tabulka představuje podrobnější přehled výsledků testování na AI generovaných textech:

Podrobný přehled výsledků přesnosti detekce napříč různými large language modely

Model umělé inteligence	Počet testovaných textů	Správně identifikované texty	Úroveň přesnosti (%)
GPT-3.5 Turbo (ChatGPT)	3500	3358	95.9
Google BARD	2000	1773	88.65
LLaMA	2000	1729	86.45
GPT-4	500	343	68.6

Tyto výsledky jasně ukazují, že náš nástroj je schopen efektivně detekovat texty generované umělou inteligencí napříč různými modely. Přesto jsme identifikovali oblasti, kde může dojít k dalším vylepšením, konkrétně v detekci textů generovaných pokročilými modely jako je GPT-4. Práce na zlepšení těchto aspektů našeho nástroje je v současné době v plném proudu.

Jedním z dalších klíčových cílů našeho testování bylo zhodnotit efektivitu našeho nástroje DetekceGPT.cz v detekci AI generovaných textů v různých jazycích. Pro tento účel jsme provedli rozsáhlé testování na datové sadě obsahující 7000 AI generovaných textů a 3500 lidsky psaných textů v pěti jazycích: čeština, slovenština, angličtina, španělština a němčina. Datová sada byla shodná s tou z první tabulky, ale pouze bez textů Encyklopedie.

Hlavní náplní této fáze evaluace bylo ověření, zda je náš nástroj schopen správně identifikovat AI generované texty a lidsky psané texty bez ohledu na jazyk, ve kterém jsou napsány. Tento aspekt je obzvláště důležitý v kontextu Evropy, kde je často nutné pracovat s texty v různých jazycích.

Podrobný přehled výsledků přesnosti detekce napříč různými jazyky

Jazyk	Správně detekované AI Texty / počet textů	Správně detekované lidské Texty / počet	Úroveň přesnosti AI detekce (%)	Úroveň přesnosti lidské detekce (%)
Čeština	1935/2000	982/1000	96.75	98.2
Angličtina	1912/2000	983/1000	95.6	98.3
Slovenština	950/1000	496/500	95	99.2
Španělština	806/1000	482/500	80.6	96.4
Němčina	857/1000	484/500	85.7	96.8

Dle získaných výsledků je patrné, že nástroj DetekceGPT.cz exceluje v detekci AI generovaných textů, zejména v češtině a angličtině, kde dosahuje přesnosti detekce AI textů 96,75 %, resp. 95,6 %. I přes solidní výsledky v slovenštině (95 %) lze zaznamenat mírný pokles v přesnosti detekce u španělštiny a němčiny na 80,6 %, resp. 85,7 %. Když se zaměříme na lidsky psané texty, nástroj konzistentně detekuje přes 96 % textů správně napříč všemi jazyky. Tato data jasně demonstrují, že nástroj je silným nástrojem pro detekci AI generovaných textů.

Závěr

V rámci naší práce jsme se zaměřili na problematiku detekce textů generovaných umělou inteligencí. Hlavním přínosem naší práce je vývoj a evaluace nástroje DetekceGPT.cz, který se ukázal jako vysoce efektivní nástroj pro identifikaci AI generovaných textů.

Naše práce přinesla důležité poznatky týkající se významu a možností detekce AI generovaných textů. Přehled existujících prací nám umožnil srovnání s jinými metodami a způsoby detekce.

V rámci metodologie jsme se podrobně zaměřili na popis našeho nástroje DetekceGPT.cz, jeho technologií a postupů, které využívá pro detekci AI generovaných textů. Dále jsme se zaměřili na popis datasetů, které jsme využili pro trénink a testování našeho nástroje.

Výsledky a analýza evaluace našeho nástroje ukázaly, jak efektivně DetekceGPT.cz funguje ve všech testovaných textových variantách a poskytly nám ucelený pohled na silné a slabé stránky našeho řešení. Důkladná analýza výsledků nám také umožnila identifikovat možnosti pro další výzkum a vylepšení.

Naše práce přináší nové možnosti pro detekci AI generovaných textů a otevírá dveře pro další výzkum v této oblasti. Ukázala, že detekce AI generovaných textů je realizovatelná a efektivní, což je důležité v kontextu rostoucího využití umělé inteligence v oblasti tvorby textů.

Reference

- Peng, B., Li, C., He, P., Galley, M., & Gao, J. (2023). Instruction tuning with gpt-4. *arXiv preprint arXiv:2304.03277*.
- Dehouche, N. (2021). Plagiarism in the age of massive Generative Pre-trained Transformers (GPT-3). *Ethics in Science and Environmental Politics*, 21, 17-23.
- Floridi, L., & Chiriatti, M. (2020). GPT-3: Its nature, scope, limits, and consequences. *Minds and Machines*, 30, 681-694.
- Duzhin, F., & Gustafsson, A. (2018). Machine learning-based app for self-evaluation of teacher-specific instructional style and tools. *Education Sciences*, 8(1), 7.
- Wang, S., Huang, M., & Deng, Z. (2018, July). Densely connected CNN with multi-scale feature attention for text classification. In *IJCAI* (Vol. 18, pp. 4468-4474).
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.
- Miaschi, A., Brunato, D., Dell'Orletta, F., & Venturi, G. (2021, June). What makes my model perplexed? a linguistic investigation on neural language models perplexity. In *Proceedings of Deep Learning Inside Out (DeeLIO): The 2nd Workshop on Knowledge Extraction and Integration for Deep Learning Architectures* (pp. 40-47).
- Common crawl. (n.d.). <https://commoncrawl.org/>
- XWikis, <https://huggingface.co/datasets/GEM/xwikis> , Perez-Beltrachini, L., & Lapata, M. (2021). *Models and Datasets for Cross-Lingual Summarisation. Proceedings of The 2021 Conference on Empirical Methods in Natural Language Processing*. Punta Cana, Dominican Republic.
- MERLIN corpus, <https://huggingface.co/datasets/aseifert/merlin>, Seifert, A. (n.d.). *ASEIFERT/Merlin · Datasets at hugging face*.
- MC4, <https://huggingface.co/datasets/mc4>, Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., ... Liu, P. J. (2019). *Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer*. arXiv E-Prints. Retrieved from <http://arxiv.org/abs/1910.10683>
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.
- Ying, X. (2019, February). An overview of overfitting and its solutions. In *Journal of physics: Conference series* (Vol. 1168, p. 022022). IOP Publishing.