

UNIVERZITA PALACKÉHO V OLMOUCI

PEDAGOGICKÁ FAKULTA

Katedra technické a informační výchovy

Bakalářská práce

Jana Zemanová

Možnosti využití umělé inteligence a zpracování přirozeného jazyka ve vzdělávání

Olomouc 2023

vedoucí práce: Mgr. Lucie Bryndová

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně a uvedla jsem v ní veškerou literaturu a ostatní informační zdroje, které jsem použila.

V Olomouci dne 19. 6. 2023

Jana Zemanová

Poděkování

Děkuji tímto vedoucí mé bakalářské práce Mgr. Lucii Bryndové za vstřícnost, doporučení a konstruktivní zpětnou vazbu, které byly klíčové pro úspěšné dokončení této práce. Rovněž děkuji za cenné rady Mgr. Tomáši Dragonovi.

Jana Zemanová

Obsah

Úvod	6
1 Teoretická část – umělá inteligence	8
1.1 Vymezení pojmu	8
1.1.1 Silná a slabá umělá inteligence	9
1.2 Metody umělé inteligence	10
1.2.1 Strojové učení	10
1.2.2 Bayesovské sítě	11
1.2.3 Fuzzy logika	12
1.2.4 Umělé neuronové sítě	12
1.3 Zpracování přirozeného jazyka	15
2 Praktická část – analýza využití AI a NLP ve vzdělávání	17
2.1 Generování testových úloh	17
2.2 Bodování krátkých odpovědí	18
2.3 Formativní hodnocení	20
2.4 AI chatboti	23
2.5 Pedagogičtí agenti	24
2.6 Extrakce a souhrn textu	26
2.7 SWOT analýza	27
2.7.1 Silné stránky	27
2.7.2 Slabé stránky	28
2.7.3 Příležitosti	28
2.7.4 Hrozby	29
3 Jazykové modely jako nástroj pro studenty	30
3.1 Online překladače	30
3.2 AI chatboti	32
3.2.1 Zdroj informací	32
3.2.2 Korektura textu, formulace myšlenek	35
3.2.3 Generování celých odstavců →	37
4 Jazykové modely jako nástroj pro učitele	40
4.1 Tvorba příprav	40
4.2 Tvorba výukových materiálů	42
4.3 Tvorba testových otázek	45
Závěr	47

Seznam použitých zdrojů.....	48
Seznam obrázků.....	59

Úvod

Myšlenka umělé inteligence (AI) už desítky let fascinuje jak odborníky, tak i laickou veřejnost. Vytvoření obecné umělé inteligence, která by dokázala překonat své stvořitele, je stále ještě v nedohledné budoucnosti, pokud je vůbec něco takového možné. Přesto v posledních letech zažívá tento obor nebyvalé úspěchy a explozivní růst. Umělá inteligence se stává přirozenou součástí každodenních lidských životů a nachází uplatnění napříč obory.

Jednou z oblastí, ve které zavádění tohoto typu nových technologií představuje obrovský potenciál, je vzdělávání. V roce 2022 dosáhl trh s AI ve vzdělávání hodnoty 4 miliard USD a předpokládá se, že do roku 2032 vzroste na 30 miliard USD (Wadhvani a Loomba, 2023). AI je využívána např. v automatizaci hodnocení či v inteligentních výukových systémech, umožňuje individualizaci výuky a šetří čas učitelům.

Na konci roku 2022 AI prudce nabyla na popularitě v souvislosti s vývojem předtrénovaných jazykových modelů a jejich zpřístupněním veřejnosti v podobě inteligentních chatbotů, schopných generovat kvalitní texty. Tato skutečnost sice neměla vliv na volbu tématu této práce, protože dané téma bylo vybráno již o rok dříve, avšak potvrdila správnost výběru. Skutečnou motivací autorky práce byla její zkušenost, kdy v minulosti krátce studovala obor Umělá inteligence a zpracování přirozeného jazyka na Masarykově univerzitě. Studium sice z osobních důvodů ukončila předčasně a dále se v oboru nevzdělávala, přesto (anebo právě proto) při výběru tématu této závěrečné práce hrála klíčovou roli osobní touha zjistit, jak moc se v posledním desetiletí tento fascinující obor proměnil.

Přes nepopiratelnou aktuálnost, není v českém prostředí téma umělé inteligence ve vzdělávání často zpracováváno. Ucelený pohled na nedůležitější témata AI ve vzdělávání zpracoval ve své diplomové práci Vítězslav Rathouz (2017). Na něj tato práce částečně navazuje, přičemž se zaměřuje na popis aktuálního stavu výzkumu v oboru. Čerpáno bylo převážně ze zahraničních zdrojů. Tato práce tak přináší aktuální pohled na nové možnosti využití AI ve vzdělávání i do českého prostředí.

Vzhledem k tomu, jak široká jsou témata umělé inteligence ve vzdělávání, nesnaží se práce představit stav oboru uceleně, ale zaměří se pouze na jednu z nejvýznamnějších oblastí, a to zpracování přirozeného jazyka (NLP). Cílem práce je tedy analyzovat současné možnosti využití AI a NLP v oblasti vzdělávání. Dále budou otestovány a popsány možnosti využití generativní AI jako pomocného nástroje pro studenty a učitele.

Práce je rozdělena na dvě části, teoretickou část tvoří první kapitola a praktickou část tvoří druhá až čtvrtá kapitola. První kapitola přináší teoretický úvod do problematiky umělé inteligence, vymezuje samotný pojem a krátce představuje nejdůležitější metody využívané v AI. Druhá kapitola přináší samotnou analýzu současného stavu vyžití NLP ve vzdělávání. Kapitola je členěna dle jednotlivých podoblastí: generování testových úloh, bodování krátkých odpovědí, formativní hodnocení, AI chatboti, extrakce a souhrn textu a pedagogičtí agenti. Nakonec je aktuální stav oboru zhodnocen pomocí SWOT analýzy. Následující dvě kapitoly představí poznatky vzešlé z testování generativních AI chatbotů.

1 Teoretická část – umělá inteligence

1.1 Vymezení pojmu

Jako umělá inteligence (artificial intelligence, AI) jsou označovány člověkem vytvořené systémy, které vykazují známky inteligentního chování. Stejně se označuje i vědní obor zabývající se výzkumem a vývojem těchto systémů. Takové vymezení je ovšem příliš vágní vzhledem k tomu, že není zřejmé, co lze a co nelze označit za „inteligentní chování“. Ani samotný pojem inteligence nemá jednotnou definici.

Za jedno z nejjednodušších vymezení pojmu umělá inteligence se dá označit pojetí Richové, podle níž se AI zabývá strojovým řešením problémů, které v dané době zvládá lépe člověk (Mařík a kol., 1993). Toto pojetí nevymezuje předmět zkoumání absolutně, ale staví jej do přímé závislosti na současném stavu technického pokroku. To se může zdát jako slabina, ale ve skutečnosti to poměrně výstižně popisuje realitu. Jak totiž poznamenává Barták (2020), dříve složité problémy, jejichž řešení původně leželo v oblasti umělé inteligence, po svém zavedení do praxe zevšední, a jen málokdo je označí za umělou inteligenci. Příkladem mohou být algoritmy webových vyhledávačů nebo nástroje využívající rozpoznání přirozeného jazyka.

Často jsou zmiňovány různé parafráze Minského definice. Minský vidí umělou inteligenci jako vědu, která se zabývá vývojem umělých systémů, které jsou schopny řešit takové problémy, u nichž se předpokládá, že pro jejich řešení je třeba lidská inteligence (Barták, 2020; Mařík, 1993).

Mařík uvádí i explicitnější Kotkovu definici: „*Umělá inteligence je vlastnost člověkem uměle vytvořených systémů vyznačujících se schopností rozpoznávat předměty, jevy a situace, analyzovat vztahy mezi nimi a tak vytvářet vnitřní modely světa, ve kterých tyto systémy existují, a na tomto základě pak přijímat účelná rozhodnutí, za pomoci schopností předvídat důsledky těchto rozhodnutí a objevovat nové zákonitosti mezi různými modely a jejich skupinami.*“ (Kotek a kol., 1983 cit. podle Mařík a kol., 1993, s. 18)

Právě schopnost umělého systému vytvářet své vlastní vnitřní modely a na základě nich se rozhodovat, která je jádrem Kotkovy definice, je klíčová pro dílčí úlohy umělé inteligence jako jsou neuronové sítě či strojové učení, které budou dále v textu podrobněji rozebrány.

1.1.1 Silná a slabá umělá inteligence

Snaha rozlišit, zda je stroj možné považovat za inteligentní či nikoliv, provází obor umělé inteligence od jeho počátku. Je namístě zmínit známý a přes svoje stáří stále diskutovaný Turingův test z roku 1950. Na základě tohoto testu je za inteligentní možno považovat takový stroj, jehož odpovědi na člověkem zadané otázky jsou nerozlišitelné od odpovědí skutečného člověka.

Velmi silný argument, který poukazuje na nedostatečnost Turingova testu, je tzv. argument čínského pokoje, který představil už v roce 1980 filozof John Searle. Jedná se o myšlenkový experiment, který je možné shrnout asi takto: člověk dostane dvě velké várky čínského písma (kterému nerozumí) a soubor pravidel pro korelaci obou várek písma (v jazyce, kterému rozumí), následně onen člověk dostane další várku čínštiny („otázku“) spolu s dalšími jemu srozumitelnými instrukcemi, jak korelovat tyto znaky s předchozími dávkami písma a jak na základě této korelace vytvořit odpověď. Člověk je tak schopen odpovídat v čínštině, ačkoli nezná význam jediného čínského znaku. Stejně tak může i vhodně naprogramovaný stroj navenek inteligentně odpovídat na otázky, aniž by rozuměl jejich smyslu.

Searle (1980) na základě tohoto myšlenkového experimentu rozlišuje tzv. silnou a slabou umělou inteligenci. Silná umělá inteligence je taková, která nejen smysluplně odpovídá, ale obsahu také skutečně rozumí. Naproti tomu systém, který je založen pouze na transformaci dostupných informací bez znalosti jejich významu, označuje jako slabou umělou inteligenci.

V současné době jsou populární modely pro generování textu jako např. ChatGPT. Přestože by podobný inteligentní chatbot zřejmě mohl projít Turingovým testem, stále se jedná pouze o slabou umělou inteligenci bez schopnosti samostatně myslet nebo řídit inteligentní systémy.

Silnou nebo také obecnou umělou inteligenci (AGI – artificial general intelligence) můžeme vymezit jako systémy, které *„jsou schopny vyřešit libovolný problém, který fyzicky zvládne jejich podkladová architektura (hardware, na kterém běží).“* (Barták, 2020, s. 15) Takový teoretický systém by byl schopen se učit a sám sebe zdokonalovat způsobem, že by dokázal „překročit svůj stín“ – tedy vymanit se z rámce daného svým programem. Žádný takový systém ovšem v současné době neexistuje. Veškeré modely, které budou v této práci popisovány, spadají do kategorie slabé umělé inteligence. Také slabá umělá inteligence má často schopnost učit se a dosahovat tak poměrně inteligentních projevů. Rozdíl ovšem spočívá

v tom, že její působení se vždy zaměřuje pouze na konkrétní úzkou oblast, pro kterou byla naprogramována.

1.2 Metody umělé inteligence

Mezi základní vlastnosti umělé inteligence patří bezesporu schopnost učit se ze zkušeností a dat, přizpůsobovat se novým situacím a vylepšovat svůj výkon, dále schopnost řešit složité problémy reálného světa, které často vykazují vysokou neurčitost a nejistotu vstupních dat. I v rámci AI programů zaměřených na výuku je obvykle nutné vypořádat se s nepřesnými a neúplnými daty. Techniky pro zpracování neurčitosti se souhrnně označují pojmem *soft computing* (Hájek, 2000). V následujících podkapitolách budou krátce představeny některé nejzásadnější metody soft computingu.

1.2.1 Strojové učení

Strojové učení (machine learning) je jedním z nejdynamičtěji se rozvíjejících oborů v rámci umělé inteligence. Díky strojovému učení jsou počítače schopny rozpoznávat vzory, predikovat výsledky, zlepšovat se a přizpůsobovat se novým situacím na základě získaných zkušeností. V dnešní době si vývojáři systémů umělé inteligence uvědomují, že je mnohdy snazší natrénovat systém tím, že mu ukážeme příklady vstupů a jim odpovídajících výstupů, než se jej pokoušet ručně naprogramovat pro všechny možné vstupy (Jordan a Mitchell, 2015).

V klasickém programování je paradigma takové, že systému poskytneme vstupní data a instrukce (program), jak s těmito daty pracovat a jako výstup očekáváme odpovědi. Naproti tomu princip strojového učení je založen na tom, že do systému vložíme vstupní data a k nim očekávané výstupy. Systém v datech nalezne určitou statistickou strukturu, na základě které sám vytvoří pravidla umožňující automatizaci řešení. Tato pravidla pak lze aplikovat na nový soubor dat. Součástí tohoto procesu je zpětná vazba, která umožňuje průběžně upravovat způsob fungování algoritmu tak, aby se minimalizovala odchylka aktuálního výstupu a očekávaného výstupu (Chollet, 2019).

Výše popsaný způsob strojového učení se označuje jako *učení s učitelem* (supervised learning). Druhým způsobem je *učení bez učitele* (unsupervised learning). V tomto modelu má systém k dispozici pouze vstupní data bez provázanosti k očekávaným výstupům. Systém si tak sám vytváří vnitřní strukturu na základě podobnosti vstupních dat. Třetím paradigmatickým stojícím na pomezí učení s učitelem a učení bez učitele je *zpětnovazební učení*

(reinforcement learning). Systému zde nejsou poskytnuty očekávané výstupy, jako je tomu v prvním případě, ale pouze zpětná vazba, zda je akce správná či nikoliv (Pilát, nedatováno).

Pro strojové učení se využívá více metod např. rozhodovací stromy, bayesovské sítě, umělé neuronové sítě, fuzzy logika a genetické algoritmy, přičemž jednotlivé metody se v rámci konkrétních řešení mohou kombinovat. V následujících podkapitolách budou popsány ty metody, které se v rámci umělé inteligence ve vzdělávání v současné době nejvíce používají.

1.2.2 Bayesovské sítě

Bayesovské sítě mají široké spektrum využití ve strojovém učení a v různých aplikacích, jako jsou například predikce, analýza problému, dolování dat a rozhodování (Rod, 2018). V oblasti vzdělávání se používají např. k modelování a porozumění chování studentů, analýze výkonu studentů, hodnocení a k personalizaci v rámci inteligentních výukových systémů (Chanthiran a Mariappan, 2022). Obecně jsou bayesovské sítě schopny modelovat a reprezentovat procesy, ve kterých je důležité zohlednit nejistotu a vztahy mezi různými proměnnými, k čemuž využívají pravděpodobnostní programování.

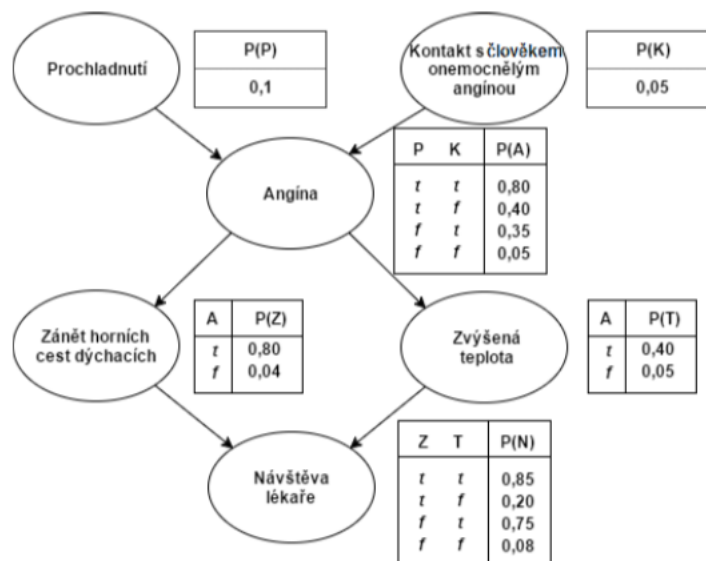
Základní myšlenka vychází z Bayesovy věty, kterou je možno nalézt ve více formulacích. Zde je uveden tvar z pohledu šancí:

$$\text{Aposteriorní poměr šancí} = \text{Apriorní poměr šancí} \times \text{Poměr věrohodností}$$

- *apriorní poměr šancí* – šance, že sledovaný jev nastane bez zohlednění dalších (nových) proměnných, tedy počáteční pravděpodobnost jevu
- *poměr věrohodností* – míra pravděpodobnosti, s jakou nová proměnná ovlivní apriorní šanci, vyjadřuje, jak silný vliv mají nová data na původní sledovaný jev
- *aposteriorní poměr šancí* – výsledný poměr šancí po zohlednění nových dat.

(Matula, 2020)

Jednoduchou aplikací výše uvedené věty můžeme sestavit algoritmus zvaný *Naivní Bayes*. Tento pravděpodobnostní model je využíván od počátků strojového učení, přibližně od 50. let, nicméně pro jednoduché klasifikování se používá dodnes (Chollet, 2019). Nevýhodou naivního Bayesova klasifikátoru je, že jednotlivé proměnné musí být na sobě nezávislé. Řešením je rozšíření jednoduchého pravděpodobnostního modelu do struktury acyklického orientovaného grafu – bayesovské sítě (Matula, 2020). Uzly grafu odpovídají jednotlivým náhodným veličinám a hrany grafu vyjadřují pravděpodobnostní závislost mezi veličinami.



Obr. 1: Příklad jednoduché bayesovské sítě

(Zdroj: Rathouz, 2017, s. 13)

1.2.3 Fuzzy logika

Zatímco představené bayesovské sítě využívaly pro predikci klasifikace pravděpodobnost, přičemž jednotlivé proměnné mohly nabývat pouze konkrétních hodnot (pravda – nepravda), v reálném světě často potřebujeme pracovat i s daty vykazujícími vysokou míru vágnosti a neurčitosti, tzn. nejsme schopni rozlišit, zda je něco pravda, či nikoliv. Jako příklad takové proměnné může být „znalost angličtiny“. Pro určitou úroveň dovednosti se jen těžko budeme moci rozhodnout, zda daného člověka zařadit do kategorie „ano“ či „ne“. Pro tyto případy, kdy je binární logické rozdělení příliš nepřesné, se využívá fuzzy logika, která umožňuje vyjádřit míru příslušnosti k určité kategorii (Bělohávek, 2017). Použití fuzzy logiky ve výukových programech tak umožňuje zahrnout do vzdělávacího procesu neurčité vlastnosti a chování studentů a zpřesňovat tak individualizaci vzdělávacího procesu.

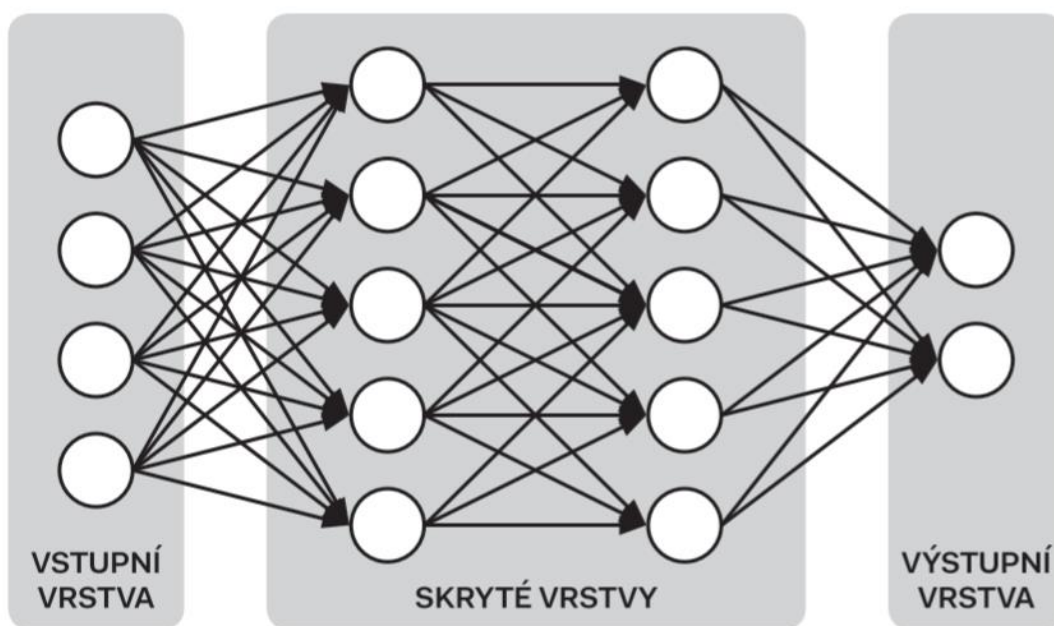
1.2.4 Umělé neuronové sítě

Zcela klíčovým nástrojem umělé inteligence a strojového učení jsou umělé neuronové sítě (artificial neural networks, ANN), jejichž koncept stojí na snaze napodobit fungování lidského mozku, kde velké množství nervových buněk zpracovává signály a předává je mezi sebou. Stejně tak umělé neuronové sítě jsou sítě navzájem propojených matematických

modelů neuronů. Tyto sítě jsou velmi efektivní např. v rozpoznávání vzorů, klasifikaci a strojovém učení.

Teoretický model neuronové sítě byl objeven a zkoušen již v padesátých letech minulého století, bohužel tehdejší možnosti výpočetní techniky neumožňovaly jeho využití a také v důsledku kritického postoje tehdejší kapacity v oboru Marvina L. Minskeho tento model na dlouhá léta zmizel ze zájmu vědců (Barták, 2020). Velkého návratu se dočkaly až v 80. letech, kdy byl objeven *algoritmus zpětného šíření*, který je zásadní pro zpětnou vazbu ve výše popsaném procesu učení s učitelem. První praktickou aplikací pak byl v roce 1989 program umožňující rozpoznání ručně psaných číslic, později využitý v poštovních službách (Chollet, 2019).

Jak již bylo zmíněno, základním stavebním prvkem neuronových sítí jsou neurony, které jsou vzájemně propojeny a schopny si předávat a upravovat signál. Struktura tak tvoří „orientovaný graf s dynamicky ohodnocenými vrcholy a hranami“ (Křivan, 2021, s. 5). Rozlišujeme *vstupní vrstvu* neuronů, která přijímá hodnoty zvnějšku, *skryté vrstvy*, a *výstupní vrstvu*, jejíž hodnoty jsou výstupem celé sítě. Každý neuron může mít několik vstupů vedoucích signál z předchozího neuronu (nebo přímo z vnějšího zdroje), přičemž každý vstup je ohodnocen vahou. Neuron vstupní hodnoty vynásobené vahou sečte, součet upraví předem definovanou funkcí a konečný výsledek pošle na výstup, který může vést do několika neuronů v následující vrstvě (Durčák, 2017).



Obr. 2: Znárodnění jednoduché neuronové sítě se dvěma skrytými vrstvami

(Zdroj: Barták, 2020, s. 35)

Větší úspěchy v aplikaci neuronových sítí, a tudíž i zájem odborné veřejnosti o tento model strojového učení je záležitostí až posledních zhruba deseti let. Jak uvádí Chollet (2019), zlomovým rokem, po kterém se na tuto oblast umělé inteligence zaměřila do té doby relativně nízká pozornost vědců, byl rok 2012, kdy model založený na neuronové síti jednoznačně zvítězil v soutěži klasifikace rozsáhlých obrazů ImageNet nad modely založenými na klasických přístupech. O tři roky později pak hluboká neuronová síť dosáhla v soutěži výsledku 96,4 %, což bylo považováno za kompletní vyřešení úlohy. Po těchto úspěších v oblasti počítačového vidění začalo *hluboké učení* (deep learning) přirozeně nacházet uplatnění i v dalších oblastech jako např. v oblasti zpracování přirozeného jazyka. Odtud je jen krůček k využití pro různé problémy umělé inteligence ve vzdělávání.

Deep learning

V předchozím odstavci byly uvedeny pojmy hluboká neuronová síť a hluboké učení a také byl naznačen jejich naprosto zásadní význam v současném vývoji umělé inteligence a strojového učení. I když je deep learning podmnožinou strojového učení, resp. neuronových sítí, v posledních letech je označován za samostatnou disciplínu, která přináší nové zajímavé možnosti, ale také se potýká s problémy, které u mělkých neuronových sítí nevznikají.

Přidávání dalších skrytých vrstev neuronů umožňuje stále větší abstrakci a generalizaci a intuitivně vede k efektivnějšímu procesu učení a inteligentnějšímu a přesnějšímu chování neuronové sítě. Přesto přidání dalších vrstev není tak snadné, jak by se na první pohled mohlo zdát. Pomineme-li problém výkonu výpočetní techniky, který jistě zejména v minulosti hrál významnou roli, ukázalo se jako náročný úkol samotné trénování sítě. Výše bylo naznačeno, jak se šíří signál mezi neurony ve směru dopředu. Také bylo zmíněno, že pro trénování sítě je zásadní zpětný signál, umožňující upravovat váhy jednotlivých spojení a zlepšovat tím fungování sítě (algoritmus zpětného šíření). Právě tento proces zpětné vazby se ukázal u hlubokých sítí jako problematický, protože jednotlivé vrstvy se neučí stejně rychle. Tento fakt se označuje jako *problém mizejícího gradientu*¹, kdy se první vrstvy sítě učí výrazně pomaleji než ty poslední, dokonce se mohou v učení téměř „zaseknout“. To v praxi vede k tomu, že se s přidáním nových vrstev může efektivita sítě snížit. Existuje několik technik na minimalizaci tohoto problému. Přesto při sestavování sítě mající za cíl řešení konkrétní úlohy hraje klíčovou roli nalezení optimální vnitřní architektury sítě (Nielsen, 2015).

¹ Kromě problému mizejícího gradientu se můžeme setkat i s opačným jevem, označovaným jako *problém explodujícího gradientu*. V takovém případě se naopak rychleji učí vrstvy první oproti vrstvám posledním.

V současné době je běžné využití hlubokých sítí s několika desítkami vrstev neuronů, nicméně experimentuje se i se sítěmi o hloubce tisíc vrstev (Li, 2021). Další stinnou stránkou je, že se neuronové sítě chovají do jisté míry jako černá skříňka, tzn. nedokážou zdůvodnit, proč došly k danému výsledku. Následkem toho je extrémně obtížné vysvětlit a opravit chyby, kterých se dopouštějí (Barták, 2020). Snaha vyřešit nebo snížit tento nedostatek, a naopak zvýšit transparentnost a tím i důvěru uživatelů vedla v posledních několika letech k rozvoji nové disciplíny *vysvětlitelné umělé inteligence* (explainable artificial intelligence, XAI). Velký přínos nepochybně představuje i její využití ve vzdělávání. Schopnost AI vysvětlit své chování může vést k zvýšení důvěry zúčastněných stran, vědomému rozhodování studentů, zda se budou doporučeními umělé inteligence řídit, k podpoře dialogu mezi učiteli a studenty a v neposlední řadě i ke zvýšení AI gramotnosti (Khosravi a kol., 2022).

1.3 Zpracování přirozeného jazyka

Už od počátků umělé inteligence tu byla snaha vytvořit systémy, které budou schopny myslet a komunikovat podobně jako lidé. I v první kapitole zmiňovaný Turingův test jasně ukazuje, že právě schopnost komunikace na lidské úrovni byla od počátků oboru vnímaná jako zcela klíčová. Právě proto se *zpracování přirozeného jazyka* (natural language processing, NLP) řadí mezi nejstarší disciplíny umělé inteligence. Jak je z názvu patrné, obor zpracování přirozeného jazyka se zabývá všemi problémy, které souvisí s počítačovým zpracováním lidské řeči. K jejich řešení je využíváno poznatků zejména z informatiky, lingvistiky a matematiky (Centrum zpracování přirozeného jazyka, 2023).

Je pochopitelné, že se v průběhu let měnily konkrétní výzvy a zaměření vědců. Za zmínku stojí konverzační program ELIZA z šedesátých let minulého století. Jeho princip spočíval v tom, že opakoval věty napsané uživatelem a na základě klíčových slov vybíral vhodnou otázku a simuloval tak roli psychoterapeuta. Přestože je jeho fungování z dnešního pohledu úsměvně jednoduché a rozhodně nelze označit za inteligentní, ve své době představoval průlom, protože nebylo na první pohled rozlišitelné, zda člověk komunikuje se strojem nebo s jiným člověkem. Okolo roku 2010 pak bylo jednou z velkých výzev NLP rozpoznávání řeči, tedy automatický zápis mluveného slova, a s ním spojený vývoj virtuálních asistentů. Další oblastí NLP, která za poslední dekádu zaznamenala prudký rozvoj, je strojový překlad. Současné překladače sice stále nedosahují kvalit lidských překladatelů, zvláště pokud jde o složitější a nejednoznačné věty, pro běžné texty s jednoduchou strukturou však poskytují

vcelku vysoce kvalitní překlad. V posledních letech pak zaznamenaly úspěch modely zaměřené na generování textu.

Jazykové modely jsou v současnosti nejvýznamnějšími nástroji pro zpracování přirozeného jazyka včetně generování textu. Fungování těchto modelů je založeno na predikci následujícího slova na základě kontextu. Model má tedy za úkol předpovědět, jaké slovo by mělo následovat ve sledu již vygenerovaných slov. I když to může být teoreticky cokoliv, existují slova, která jsou v daném kontextu pravděpodobnější než jiná. Aby vytvořená posloupnost slov byla smysluplná, je zapotřebí kvalitního jazykového modelu (Materna, 2019). K jeho vytvoření se v současné době využívají hluboké neuronové sítě a strojové učení. Přičemž se dá zjednodušeně říct, že čím větší je trénovací dataset, tím kvalitnější texty je model schopen generovat. Jako příklad takových modelů může být uveden model BERT od společnosti Google nebo GPT od společnosti OpenAI.

Přístupy NLP založené na transformátorech typu BERT nebo GPT-3 jsou dnes standardem. Jejich výhodou je, že jsou předtrénované na masivních datech a lze je relativně snadno doladit na konkrétní úlohu. To je zvláště výhodné ve školství, protože zatímco předtrénované modely jsou trénované na jazykově správných textech, odpovědi psané žáky bývají často hovorové s mělkou slovní zásobou, obsahují chyby a zkratky (Cochran, 2022).

Zpracování přirozeného jazyka je samozřejmě neodmyslitelnou součástí mnoha problémů AIED. Zcela klíčovou roli hraje při počítačem podporované výuce jazyků, ale zasahuje i do mnoha dalších témat. Příkladem využití NLP může být automatické generování zpětné vazby, hodnocení psaných odpovědí studentů, komunikace inteligentních pedagogických agentů, extrakce hlavních myšlenek z dlouhých textů, generování souvislých textů na základě vyhledávání informací, automatizovaná tvorba testových otázek a další.

Generativní AI tak může v procesu vzdělávání hrát různé role. V roli tutora může poskytovat doplňující materiál, generovat příklady, shrnovat učební obsah nebo poskytovat hodnocení. V roli studenta vypracovávat úkoly na základě požadavků studentů nebo pracovat jako člen týmu v rámci metod kooperativního učení. Využití se dále nabízí v podobě experta v oboru poskytováním rad a odpovědí na konkrétní otázky. Může též sloužit jako pomocný nástroj shromažďování a analyzování dat či korekturou textu (Hwang, 2023).

2 Praktická část – analýza využití AI a NLP ve vzdělávání

Umělá inteligence ve vzdělávání (Artificial intelligence in education, AIED) je vědní disciplína, která kombinuje poznatky z řady oborů, zejména umělé inteligence, pedagogiky, psychologie či kognitivní vědy, za účelem využití techniky ke zlepšení procesů vzdělávání (Rathouz, 2017). Umělá inteligence i její využití ve vzdělávání, stejně tak jako AI gramotnost získaly v posledních letech zvýšenou pozornost, včetně pozornosti komerčních společností (Holmes a Tuomi, 2022).

Hlavním cílem práce je analyzovat současné možnosti využití umělé inteligence a zpracování přirozeného jazyka v oblasti vzdělávání. Za tímto účelem byla provedena rešerše více než 40 zahraničních zdrojů převážně z let 2021 až 2023. Na základě toho byla identifikována a analyzována klíčová témata současného výzkumu související se zpracováním přirozeného jazyka v oblasti vzdělávání, a sice: generování testových úloh, bodování krátkých odpovědí, formativní hodnocení, AI chatboti, pedagogičtí agenti a extrakce a souhrn textu. Na závěr kapitoly byla provedena SWOT analýza, ve které byly identifikovány silné a slabé stránky současného využití AI a NLP ve vzdělávání a také příležitosti a hrozby, které tato oblast přináší a na které bude třeba reagovat.

2.1 Generování testových úloh

Jedním z aktuálně řešených problémů je generování testových úloh a jejich hodnocení. Jazykové modely jsou čím dál tím lepší v generování jakýchkoliv textů, a tedy i otázek, přesto dělají chyby. V tak důležité oblasti, jakou je hodnocení vzdělávání, je ovšem důležité, aby vygenerované úlohy měly vysokou kvalitu a aby byly relevantní k hodnocenému obsahu (Wang a kol., 2022).

Dalším požadavkem často je, aby testové otázky odpovídaly konkrétním cílům, které učitel stanovil na základě Bloomovy taxonomie. Mnoho používaných metod generuje otázky faktické a mělké, zatímco generování otázek respektujících Bloomovu taxonomii očekávaného výstupu zůstává stále náročným problémem. Jednou z hlavních výzev tedy je, aby vygenerované otázky podporovaly kritické myšlení nebo orientaci studentů v rámci širšího kontextu. Wijanarko a kol. (2021) nicméně představili model generování otázek založený na klíčové frázi, který vykazuje velmi slibnou úroveň, pokud jde o srozumitelnost a provázanost s očekávanou úrovní Bloomovy taxonomie.

K automatickému vytváření testových úloh se využívá např. kontextualizované generování otázek, tedy generování takových otázek, na něž lze nalézt odpověď v daném odstavci. Vstupně-výstupní struktura těchto modelů může vypadat tak, že na vstup vložíme kontext a očekávanou odpověď a systém vygeneruje otázku. Jiné nastavení spočívá v tom, že vstup obsahuje kontext a cíl a výstupem je otázka spolu s odpovědí. Tento přístup umožňuje generovat více relevantních otázek. Zásadní roli hraje délka kontextu a otázky. Ukazuje se, že příliš krátký kontext vede k nízké rozmanitosti otázek, naproti tomu příliš dlouhý kontext může model zmást a vést k irelevantním výstupům (Wang a kol., 2022).

Zajímavým a velmi užitečným úkolem je generování kvalitních uzavřených otázek s více možnostmi. Vzhledem k oblíbenosti tohoto typu testů a zároveň značné těžkopádnosti jejich ručního sestavování, je v posledních letech populární jejich automatické generování, přičemž se objevují přístupy založené čistě na strojovém učení i přístupy zahrnující sémantiku. Zajímavou úlohou pro budoucí výzkum je generování vhodných distraktorů, tedy nesprávných možností (Kumar a kol., 2023).

Vývoj se pochopitelně nesoustředí jen na generování otázek v oborech s převahou znalostního charakteru ale i v oborech založených na dovednostech, jako je např. matematika nebo programování. Při výuce programování je např. užitečná schopnost modelu generovat otázky, které mohou sloužit jako nápověda poskytující studentům pomoc při snaze porozumět kódu. Vytváření takových otázek lidmi je velmi nákladné a ukazuje se, že umělé systémy v dnešní době dokážou generovat gramaticky, věcně i pedagogicky správné otázky tohoto typu (Tamang a kol., 2022).

Výuková prostředí mohou být obohacena i o možnost generování hádanek. Přestože učení za pomoci hádanek a rébusů je pro studenty motivující a zajímavé, není na tuto úlohu zaměřena pozornost, a většina prací o generování hádanek je mimo kontext vzdělávání (Parasa a kol., 2022). Řešení problémů tohoto typu zřejmě nebude hlavním tématem zpracování přirozeného jazyka ve vzdělávání, přesto další vývoj skrývá potenciál v podobě zpestření výukových systémů zajímavějšími a pro žáky lákavějšími úlohami, které jim pomohou pochopit látku do větší hloubky.

2.2 Bodování krátkých odpovědí

Oblastí, která skrývá velký potenciál pro zapojení AI je automatické hodnocení testů a studentských prací. Dnes je naprostým standardem strojové vyhodnocování uzavřených testových úloh s více možnostmi. Uzavřené otázky však nejsou vždy adekvátním nástrojem

pro diagnostiku studentových znalostí a dovedností. Je zřejmé, že jen těžko testují vyšší stupně kognitivních operací jako např. analýza či kritické myšlení ani neumožňují studentovi originální či kreativní pojetí úkolu. Navíc nedávají učitelům úplnou informaci o tom, zda došlo ke skutečnému osvojení látky, protože student někdy může vybrat správnou odpověď i na základě nepřesné úvahy či pouhým vyřazením evidentně špatných možností. Naproti tomu otevřené otázky lépe ukazují dosaženou úroveň znalostí, nicméně jejich hodnocení je zvláště při velkém počtu studentů časově náročné. Do popředí zájmu se tak dostal i vývoj modelů zaměřených na automatizované bodování a hodnocení otevřených krátkých odpovědí a dlouhých textů studentů. Užitek přitom nepřináší jen vyučujícím, ale i studentům, kteří díky tomu mohou zpětnou vazbu získat okamžitě.

Přístupy založené na hlubokém učení v posledních letech výrazně zlepšily výkon automatických bodovacích systémů, přesto zatím není možné vyloučit chyby. V prostředí oficiálního hodnocení vzdělávání je však obvykle vyžadováno spolehlivé a vysoce kvalitní hodnocení. Proto se v současné době používají automatické bodovací systémy spíše jen jako referenční nástroj na detekci chyb pro lidského hodnotitele. Dokud nebude vývoj tak daleko, abychom se mohli na tyto systémy plně spolehnout, může být řešením minimalizujícím náklady koncept „human-in-the-loop“, který automaticky oboduje pouze vysoce spolehlivé odpovědi a ty méně spolehlivé převede na lidského hodnotitele (Funayama, 2022).

Tendence ke zvýšené chybovosti modelů je pozorovatelná zejména v kontextu matematiky. Děje se tak, protože většina tradičních technik zpracování přirozeného jazyka nebyla navržena pro kontext, ve kterém se objevují nejazykové znaky a výrazy. Baral a kol. (2022) pro překlenutí tohoto problému navrhli model Math Term Frequency, který po spojení s dříve vyvinutými modely pro hodnocení představuje slibnou metodu pro zmírnění chybovosti modelu v kontextu obsahujícím matematické symboly.

I když není u automatických hodnocících systémů možné zcela eliminovat chyby, četné studie ukazují, že jejich spolehlivost je obecně plně srovnatelná s lidskými opravami. Ostatně ani lidské hodnocení ze své podstaty není nikdy plně objektivní.² Problém nasazení automatického hodnocení do praxe se tak může přesouvat spíše k otázce důvěry učitelů v tyto systémy. Walter (2022) ve své studii ukazuje, že ke zvýšení důvěry učitelů v automatické bodování otevřených otázek přispívá, pokud systém kromě souhrnného skóre také extrahuje klíčová slova související s úkoly. V takovém případě je důvěra učitelů poměrně vysoká.

² Kromě jednoznačných chyb způsobených např. nepozorností učitele zasahuje do hodnocení mnoho dalších vlivů. Může to být pověst žáka, aktuální rozpoložení a osobnost učitele, nebo třeba efekt řady a kontrastu, kdy např. po několika vynikajících výkonech bude i průměrný výkon hodnocen jako podprůměrný. Zdroj.: pf.ujep.cz/obecna-didaktika/pdf/Hodnoceni.pdf

Žádný z účastníků studie přitom automatickým systémům nedůvěřoval zcela, což je dle Waltera ve skutečnosti pozitivním zjištěním, protože ukazuje na odpovědné používání digitálních technologií učiteli.

Jak bylo zmíněno výše, modely na hodnocení otevřených odpovědí se zatím ve vzdělávání reálně příliš často nepoužívají. Jako důvod byla zmíněna jejich možná chybovost, nicméně před jejich skutečným nasazením je třeba se vypořádat i s problémem rozpoznávání rukopisu, protože většina testů je psána ručně v klasickém vzdělávacím prostředí. Oka a kol. (2022) na konferenci AIED 2022 představili systém pro plně automatizované bodování ručně psaných krátkých odpovědí na otevřené otázky. Plně automatizovaný znamená, že využívá rozpoznávání ručně psaných znaků a eliminuje potřebu zpracování dat lidmi, jako je např. přidávání anotací. Experiment využívající data z testu na japonskou univerzitu ukázal, že systém byl schopen s vysokou přesností určovat skóre na rozsáhlých datech ze skutečného vzdělávacího prostředí.

Využití automatického bodování krátkých odpovědí se pochopitelně neomezuje pouze na testování. Jeho využití se nabízí i v rámci podpůrných vzdělávacích aplikací. Jednou z možných aplikací je systém na podporu čtení s porozuměním. Ten na základě obodování krátké odpovědi vyhodnotí dosaženou žákovu úroveň a následně doporučí další texty pro čtení, které jsou na úrovni obtížnosti vždy jen o něco málo převyšující aktuální schopnosti žáka. Tento přístup vede k postupnému a individualizovanému procesu zvyšování dané kompetence (Liu, 2022).

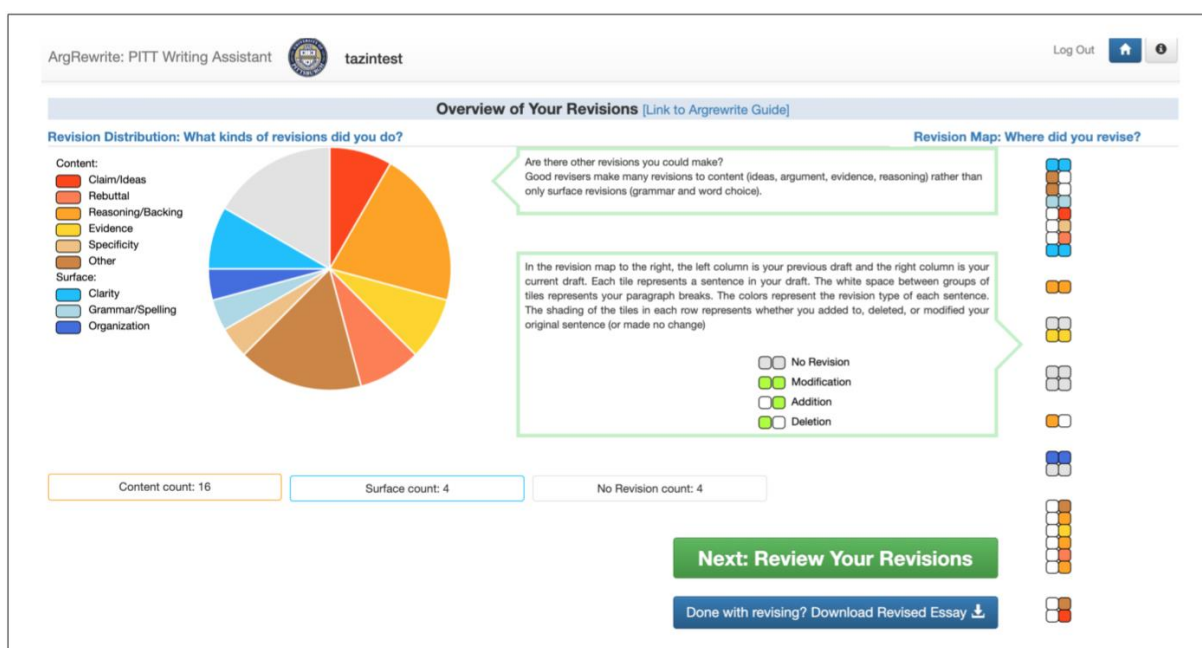
2.3 Formativní hodnocení

Předchozí příklady automatického hodnocení zahrnovaly pouze případy, kdy bylo hodnocení vyjádřeno pomocí určitého skóre. Takové hodnocení se sice ve vzdělávání využívá velmi často, nicméně poskytuje studentovi jen minimální zpětnou vazbu. Naproti tomu formativní hodnocení poskytuje žákovi oporu v podobě informací, které mu mohou pomoci zlepšit svůj výkon. Pro studenta je tedy formativní hodnocení neocenitelným přínosem. Jednou z největších překážek častějšímu poskytování komplexní zpětné vazby je její časová náročnost pro učitele. Systémy, které by tento proces uměly automatizovat, by tak byly učitelům bezesporu velkou oporou.

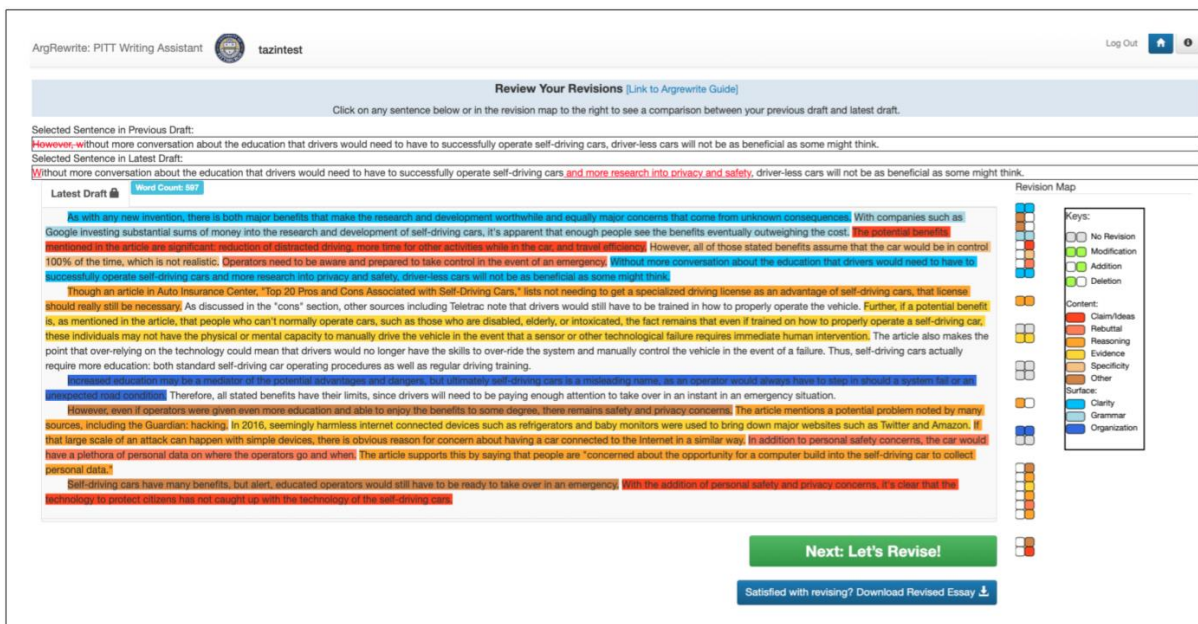
Systémy automatického hodnocení psaní poskytují studentům formativní zpětnou vazbu, jak opravit či zlepšit své písemné práce. Nástroj PyrEval+CR je zaměřený na poskytování formativní zpětné vazby na vědecké eseje studentů středních škol. Systém

rozpoznává myšlenky v eseji a srovnává jejich důležitost v učebních osnovách (Singh, 2022). Ve spolupráci s učiteli byly vytvořeny osnovy přírodních věd a následně byl PyrEval+CR testován na stovkách skutečných středoškolských prací. Ukázalo se, že automatické hodnocení odpovídá hodnocení sestaveným v laboratoři. Software přináší přínos v podobě okamžité zpětné vazby studentům a také v podobě souhrnné zprávy o tématech a myšlenkách v hodnocených esejích celé třídy. Učitel tak má k dispozici rychlou zpětnou vazbu, jak studenti chápou zadané téma (Chuprinski, 2022).

Jiným nástrojem poskytujícím automatické formativní hodnocení psaní je ArgRewrite. Tento systém se snaží pomoci studentům nejen s konkrétním úkolem, ale také u nich podporovat rozvoj kompetence samostatně revidovat svoji písemnou práci. Za tímto účelem vytváří a v grafické podobě předkládá studentům analýzu jejich dosavadních oprav eseje (viz Obr. 3 a Obr. 4). Korpus ArgRewrite V.2 je možné využít k vývoji různých aplikací včetně např. predikce, zda daná část textu obsahuje konkrétní nebo obecnou informaci (Litman a kol., 2022; Kashefi a kol., 2022).

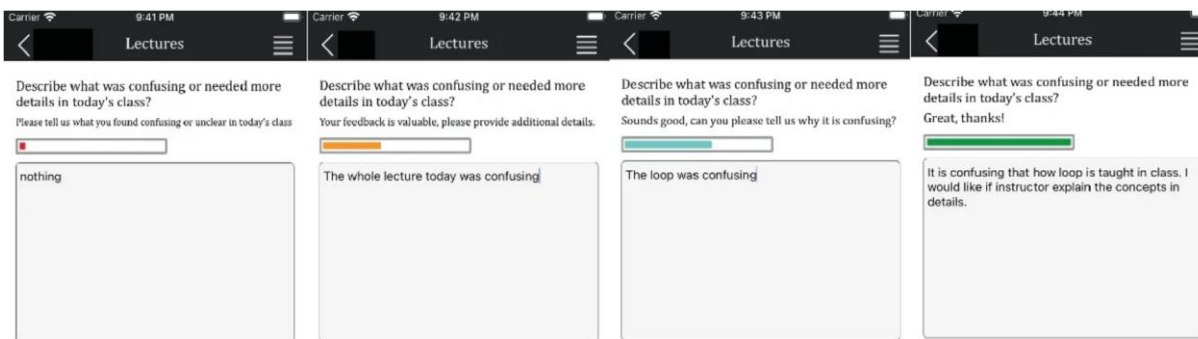


Obr. 3: Celkový přehled provedených revizí v ArgRewrite
(zdroj: <http://argrewrite.cs.pitt.edu/files/ArgrewriteGuide.pdf>)



Obr. 4: Rozhraní ArgRewrite umožňuje sledovat a porovnávat provedené opravy textu na úrovni vět (zdroj: <http://argrewrite.cs.pitt.edu/files/ArgrewriteGuide.pdf>)

Formativní zpětná vazba rozvíjí i dovednost psaní reflexí. Dokládají to výsledky experimentu, jak automatická zpětná vazba zlepšuje kvalitu odeslaných evaluací přednášek a jak ovlivňuje ochotu studentů je psát. Byla vytvořena mobilní aplikace CourseMIRROR, ve které mohou studenti psát evaluace na absolvované přednášky. V průběhu psaní je jim v reálném čase poskytována automatická zpětná vazba na kvalitu jejich reflexe (viz Obr. 5). Experiment ukazuje, že zatímco studenti, kteří psali evaluace bez automatické zpětné vazby, měli tendenci ke konci semestru psát méně kvalitní či žádné hodnocení, u studentů s podporou automatické zpětné vazby se naopak kvalita odeslaných hodnocení v průběhu semestru zvyšovala (Magooda a kol., 2022).



Obr. 5: Automatická zpětná vazba v průběhu psaní evaluace v aplikaci CourseMIRROR (Zdroj: Magooda a kol., 2022)

Pro podporu výuky matematiky existuje bezplatný online nástroj ASSISTments, který poskytuje studentům okamžité formativní hodnocení a učitelům zprávy o tom, jak si jejich studenti při plnění úkolu vedli, a instruktážní návrhy. Dle studie Gillespie a kol. (2022) učitelé využívali informace z ASSISTments ohledně plnění domácích úkolů žáky k zefektivnění následné výuky a k vyšší individualizaci v rámci třídy. Přínos automatického formativního hodnocení a souhrnných zpráv učitelům je tak nesporný.

2.4 AI chatboti

Masové zpřístupnění generativních jazykových AI modelů představují inteligentní chatboti, kteří jsou schopni komunikovat s uživatelem lidským způsobem. V listopadu 2022 zpřístupnila společnost OpenAI veřejnosti konverzačního agenta ChatGPT postaveného na modelu GPT-3.5³, který je schopen dle instrukcí generovat velice kvalitní texty téměř nerozeznatelné od textů psaných člověkem (OpenAI, 2022). V reakci na to přišlo mnoho velkých i malých společností s konkurenčními chatboty jako např. YouBot společnosti YOU.com, BARD společnosti Google nebo chatovací vyhledávač Bing společnosti Microsoft, do kterého je integrován model GPT.

Vzhledem k všestrannosti AI chatbotů a relativní kvalitě jejich výstupů se nabízí široké pole možností pro jejich využití ve vzdělávacím procesu. Učitelé je mohou využít přímo ve výuce např. jako konverzačního partnera nebo partnera pro jazykové hry, nabízí se využití v podobě tvorby materiálů, ukázek, povídek a jiných textů pro výuku, nebo si již existující materiály mohou nechat upravit a získat tak individualizované varianty (Jeon a Lee, 2023). Dále mohou posloužit jako generátor nápadů pro výuku, včetně konkrétních výukových metod nebo rychlý vyhledávač informací. Podobně je mohou použít i žáci v rámci domácí přípravy. V tomto smyslu je výborným nástrojem chatbot Bing, dostupný v prohlížeči Microsoft Edge, který generuje odpovědi na základě procházení webu, díky čemuž pracuje s aktuálními informacemi a nabízí odkazy na relevantní zdroje.

Schopnost generovat vysoce kvalitní texty se ale nepojí jen s výhodami. Snadná dostupnost a fakt, že generované texty jsou prakticky nerozeznatelné od práce skutečného člověka, přináší riziko zneužití ve formě plagiátorství. Rozeznat, zda je autorem člověk, přitom spolehlivě nedokáže ani člověk, ani umělá inteligence. Sharples to ukazuje na vysoce citovaném článku z roku 2010, ve kterém AI model paradoxně nacházel prvky uměle

³ V březnu 2023 byl veřejnosti zpřístupněn prémiový chatbot ChatGPT Plus postavený na novějším jazykovém modelu GPT-4.

generovaného textu, a dále poznamenává: „*Spíše, než abychom se pokoušeli o další trapná srovnání, poznamenáváme, že jakýkoli dostatečně výkonný program, který by určil, zda je článek napsán člověkem nebo strojem, by mohl být často přechytračen stejně výkonným AI generátorem textu v marných závodech ve výpočetním zbrojení.*“ (Sharples, 2022; vlastní překlad) Ani kdybychom vyvinuli systém schopný rozlišit, kdo je autorem, v konečném důsledku bychom si tím nepomohli.

Abychom se vyhnuli riziku plagiátorství u žáků a studentů, bude nutné upravit přístup k zadávaným úkolům. Jednou z možností je zadávat kontextualizované či reflexivní písemné úkoly, práce zahrnující hodnocení složitých problémů reálného světa, praktické úkoly či projekty buď výzkumného charakteru, nebo vyžadující originální řešení. Tedy zadávat takové úkoly, které AI vůbec nedokáže vytvořit, nebo jen s velkými obtížemi. Jinou, případně doplňkovou strategií v boji proti podvodům využívajícím AI je zavedení přísných opatření např. omezení písemných prací na prostředí hlídané učebny. Poslední a velice důležitou cestou je vytrvalé zvyšování etického povědomí a vedení studentů k zodpovědnému využívání technologií (Jeon a Lee, 2023; Kooli, 2023; Sharples, 2022).

Zadávaní úkolů, které si kladou za cíl rozvíjení kritického myšlení a vyžadují kreativitu a promyšlení informací namísto pouhého opakování faktů, také lépe odpovídá cílům, jak jsou definovány v RVP ZV⁴. Obecné cíle základního vzdělávání jsou v ČR zaměřeny na získání klíčových kompetencí (Rámcový vzdělávací program pro základní vzdělávání, 2021). Skutečný stav českého školství však ne vždy odpovídá těmto principům a zejména didaktická plochost ve výuce často vede k velmi nízkému rozvoji klíčových kompetencí u žáků (Čapek, 2015).

2.5 Pedagogičtí agenti

Inteligentní pedagogičtí agenti jsou technologie z oblasti AIED využívající poznatků zpracování přirozeného jazyka. Jedná se o softwarové komponenty v inteligentních výukových systémech (intelligent tutoring system, ITS), což jsou komplexní doučovací platformy využívající AI ke komplexnímu řízení procesu učení zahrnující poskytování personalizované a adaptivní vzdělávací podpory studentům. Hlavním cílem pedagogických agentů je napodobovat roli učitele tím, že komunikují s uživatelem a prostřednictvím dialogu mu poskytují veškerou studijní podporu. Podobně jako učitel mohou studentovi klást otázky, dávat úlohy k procvičení či řešení problémů, dávat rady a vysvětlení, odpovídat na studentovy

⁴ Rámcový vzdělávací program pro základní vzdělávání – závazný dokument určující rámec vzdělávání na ZŠ

otázky apod., vyučování je tak vystavěno okolo aktivního dialogu (Kochmar a kol., 2022). Agenti mohou mít různé grafické zpracování, nicméně v současné době se stále více využívají ztělesnění agenti, u nichž je kladen důraz na realistický vzhled. Takoví agenti pak mohou komunikovat i pomocí gest, která mohou být buď ručně naprogramovaná, nebo využívat AI pro automatické vytváření gest, což poskytuje větší prostor pro personalizaci (Sinha a Malhotra, 2022).

Pedagogičtí agenti mohou studentům poskytovat pomoc na úrovni kognitivní a metakognitivní podpory tím, že jim pomáhají zaměřit se na kritické znaky, umožňují podílet se na řízení času a reflexe vlastního pokroku nebo jim pomáhají vybírat efektivní strategie samoregulovaného učení (Dever a kol., 2022; Sinha a Malhotra, 2022). Dále podporují motivaci studentů, pomáhají jim zvládat emoce a navozují vztahovou podporu (Sinha a Malhotra, 2022). Zejména při navazování určitého vztahu mezi studentem a agentem, jehož cílem je motivace studenta k učení, je zásadní také styl jazyka. Ukazuje se, že neformální styl konverzace má u většiny studentů pozitivní vliv na jejich výsledky (Li, Cheng, Wang a Graeser, 2022).

Z novějších konverzačních systémů je možno zmínit ScratchThAI zaměřeného na výuku informatického myšlení skrze blokový programovací jazyk Scratch. Žáci mohou ScratChatbota žádat o rady, vysvětlení, mohou procvičovat pomocí navrhovaných cvičení, dostávají automatizované hodnocení apod. Při výuce algoritmického myšlení v běžné třídě se musí učitel potýkat s velkou různorodostí, co se týče schopností studentů. Ne vždy má dost prostoru pro individuální práci s jednotlivci. Díky personalizovanému přístupu ScratchThAI jsou výsledky žáků ve třídách, kde učitel využívá tento systém, lepší než při tradiční výuce (Katchapakirin a kol., 2022).

V roce 2019 byl spuštěn Korbit, ITS založený na dialogu (Kochmar a kol., 2022). Poskytuje interaktivní personalizovanou výuku témat souvisejících s datovou vědou, strojovým učením a umělou inteligencí. Jedná se o online platformu kombinující různé metody výuky, jako je projektové učení, přednášková videa, sokratovské metody nebo aktivity na řešení problémů. Inteligentní agent využívá zpětnovazební učení k automatickému přidělování aktivit studentům, přičemž je sám schopen se učit jak z historických dat, tak i online. Díky tomu je předpoklad, že se bude dále zlepšovat, jak bude přibývat přihlášených studentů (Belfer a kol., 2022). Korbit je také schopen automaticky generovat personalizovanou zpětnou vazbu, rady a vysvětlení a další pedagogické intervence, k čemuž využívá různé zdroje dat včetně Wikipedie. Výběr pedagogické intervence je přitom určen na

základě profilu studenta a jeho schopností, čímž je zajištěna vysoká míra personalizace (Kochmar a kol. 2022).

Příkladem ztělesněného agenta je např. agentka Patti v systému pro výuku anglického jazyka. Patti dává pokyny hlasem, při čemž pohybuje rty, ukazuje na obsah na obrazovce a také přikyvuje nebo se naopak tváří zmateně v průběhu plnění cvičení studentem. Experiment ukázal, že přítomnost agenta ve výukovém systému měla pozitivní vliv na průběh učení i na dosažené výsledky (Carlotto a Jaques, 2016).

2.6 Extrakce a souhrn textu

Problematika extrakcí a souhrnů textů se liší od předchozích aplikací tím, že vyžaduje zpracování často velice dlouhých textů, v rámci kterých je nutné identifikovat klíčové myšlenky a tyto zpracovat do krátkého souhrnu. Použití klasických jazykových modelů jako BERT může být v některých případech pro tak dlouhé texty limitující, protože s délkou textu roste složitost jejich mechanismu pozornosti kvadraticky. Z tohoto důvodu může být vhodné tyto koncepty stavět na modelech přímo určených pro dlouhé texty, jako je např. Longformer, jehož složitost je lineární (Beltagy a kol, 2020).

Metody souhrnů dlouhých textů se v rámci vzdělávání využívá např. pro automatizované hodnocení studentských souhrnů. Sumarizace textu je jednou z efektivních metod výuky čtení s porozuměním. Jejich hodnocení je přitom pro učitele časově náročné. Nástroje schopné automaticky extrahovat ze zadaného textu hlavní myšlenky, vyhodnotit jejich zahrnutí do studentem napsaného výtahu a tento obodovat, však mají nejen potenciál zefektivnit práci učitelů, ale také v případě použití studentem mu pomoci zlepšit dovednost psaní souhrnů (Botarleanu a kol., 2021). Souhrny jsou přitom hodnoceny z hlediska různých kritérií, např. skutečnost, zda se podařilo zachytit hlavní myšlenku, do jaké míry byly zachyceny důležité detaily, soudržnost textu, vhodnost parafrází, přiměřenost délky souhrnu a další znaky. K tomu je možné přistupovat dvěma způsoby. Jednodušší způsob předpokládá vytrénování několika neuronových sítí, kdy každá je zaměřena na zhodnocení textu z hlediska jednoho kritéria. Druhý způsob je založen na holistické analýze textu, hodnotí tedy všechna zadaná kritéria současně, čímž se více přibližuje lidskému způsobu hodnocení. Výhodou druhého přístupu je zejména nižší výpočetní náročnost (Botarleanu a kol., 2022).

Extrakce a souhrn dlouhých textů se však nemusí zaměřovat pouze na studenty a učitele, ale je možné je využít i pro ředitele a organizátory kurzů. Například poskytovatelé masivních otevřených online kurzů (MOOC) potřebují pro zlepšení kurzů přečíst a analyzovat

recenze účastníků, kterých však může být i několik tisíc. Takový proces je pro lidi zdlouhavý a neefektivní. Dřívější automatizované metody založené na výběru dle klíčových slov mohou být přitom nepřesné a nepřehledné, protože rozdělí podobné názory vyjádřené jinými slovy. Tento problém řeší jemnozrnný přístup k extrakci klíčových myšlenek, což je metoda extrakce klíčových slov z textu, která se snaží identifikovat významově podobné fráze a slova. Automatický extraktor klíčových myšlenek, který z velkého množství komentářů seskupí důležité myšlenky, aniž by se spoléhal na doslovnost, má potenciál ušetřit mnoho času a nákladů (Xiao a kol., 2022). Uplatnění přitom může najít nejen u poskytovatelů MOOC, jak bylo uvedeno výše, ale např. také u ředitelů škol či učitelů v rámci statistické analýzy dotazníkového šetření (Esmaeilzadeh a kol., 2022).

2.7 SWOT analýza

2.7.1 Silné stránky

Programy umělé inteligence schopné zpracovávat přirozený jazyk poskytují oporu všem účastníkům vzdělávacího procesu v podobě automatizace činností, které dříve musely být prováděny ručně. Patří mezi ně zejména tvorba otázek pro testování, bodování a hodnocení prací studentů včetně poskytování formativní zpětné vazby či extrakce klíčových myšlenek z dotazníků. Automatizace těchto činností snižuje pracovní vyčerpání pedagogických pracovníků a v důsledku učitelům uvolňuje ruce pro jiné důležité činnosti, jako jsou individualizované metody, přípravu projektů a mnoho dalších. Kromě toho bezprostřednost automatických hodnocení přináší benefit v podobě možné okamžité pedagogické intervence. To vše má pozitivní vliv na efektivitu výuky.

Všeobecná dostupnost AI chatbotů představuje doslova revoluci ve využívání modelů zpracování přirozeného jazyka. Dnes se tak nabízí velice široká škála způsobů, jakými je možno chatboty použít. Studentům pomáhají ve vyhledávání informací, při vypracování úkolů či jako doučovací agenti. Učitelům umožňují zlepšit výuku pomocí návrhů výukových metod pro konkrétní hodinu či vytvořením a úpravou výukových textů a materiálů dle instrukcí. Pomoc při psaní akademických prací v podobě návrhů na frázování, tón a styl mohou využít i výzkumníci (Kooli, 2023). Celkově je tedy možné označit AI chatboty za univerzální nástroje pro podporu práce s textem.

Posledním kladem, který zde bude uveden, je, že studenti obecně pozitivně vnímají testové otázky a materiály generované umělou inteligencí. Většina studentů se také ráda učí

za pomoci digitálních technologií, což je velice důležité, protože bez toho by zavádění systémů AI do vzdělávání postrádalo smysl (Van Campenhout a kol., 2022).

2.7.2 Slabé stránky

Zřejmě největší slabinou modelů pro automatické generování textu je jejich chybovost. U chatbotů jako je ChatGPT si to může každý vyzkoušet sám. Problém je to však i u modelů specializovaných na hodnocení či generování otázek. Chyby mohou být věcné, gramatické i třeba to, že otázka vůbec není otázkou (Wang a kol. 2022). Systémy v současné době také jen s obtížemi zvládají generování otázek ověřujících zvládnutí učiva na vyšší úrovni myšlení (Wijanarko a kol., 2021). Generativní jazykové modely nemají schopnost reflektovat vytvořený text, nemohou tak zkontrolovat přesnost ani slušnost – jsou ve své podstatě nemyslicí a amorální (Sharples, 2022). To je další důvod, proč není možné jimi vytvořené materiály použít bez předchozí kontroly.

Další slabou stránkou bránící masivnějšímu využití potenciálu, který jazykové modely ve vzdělávání nabízí, je nízká dostupnost specializovaného SW pro automatické hodnocení a tvorbu otázek, který dosahuje lepších výsledků. Učitelé mají celkově spíše nízkou důvěru v systémy automatického hodnocení (Walter, 2022), a pokud SW pro tyto účely nebude dostatečně kvalitní a dostupný, těžko můžeme očekávat v tomto směru zlepšení. Pokud jde o relativně nízké využití ITS, zde je jedním z hlavních problémů nákladný proces tvorby pedagogických intervencí, zejména pokud jsou tvořeny na základě ručně sestavovaných pravidel a expertních návrhů (Kochmar a kol., 2022).

2.7.3 Příležitosti

Rozšíření a vývoj nových specializovaných nástrojů na zpracování přirozeného jazyka, například nástrojů na hodnocení či automatickou tvorbu otázek, bude mít významný dopad na snížení pracovní zátěže pedagogů. To zcela přirozeně povede ke zkvalitnění výuky, protože pokud se učitelé nebudou muset zdržovat rutinními či administrativními činnostmi, budou mít více času na přípravu výuky, mohou do výuky častěji zařazovat různé aktivizační metody, badatelsky orientovanou výuku, problémové a projektové učení a další metody, které jsou sice obecně efektivní z pohledu rozvíjení kompetencí žáka, ale často bývají náročné na přípravu. Učitelům by v tomto smyslu zcela jistě pomohlo také vyvinutí nástrojů, schopných výrazně snížit jejich administrativní zátěž. Odlehčení rutinní práce pedagogů může mít rovněž pozitivní vliv na jejich well-being a předcházení syndromu vyhoření, což v konečném

důsledku povede opět ke zkvalitnění výuky. Zajímavou výzvou zpracování přirozeného jazyka je také umět odhalovat některé kognitivní stavy jako např. frustrace. Díky tomu by mohly systémy na tyto stavy reagovat a poskytovat studentům afektivní podporu (Albornoz-De Luise a kol., 2022).

Nutnost čelit hrozbě plagiátorství za pomoci AI chatbotů může vést k posunu zadávaných úkolů od zadání na pouhou replikaci faktů směrem k tvorbě originálního, inovativního či praktického obsahu. Takový posun je zcela v souladu s moderním pojetím výuky a představuje pro studenty příležitost k rozvoji vyšších stupňů myšlení. Rozšíření AI chatbotů tak může v konečném důsledku přispět k modernizaci školství.

2.7.4 Hrozby

Schopnost chatbotů generovat vysoce kvalitní texty s sebou přirozeně přináší riziko zneužití takových textů. Ve školství zcela nepochybně budou přibývat situace, kdy si student nechá vypracovat školní úkol umělou inteligencí a tuto práci bude vydávat za svou. Pravdou je, že tento problém, kdy student vydává za svoji práci, kterou sám nenapsal, existuje už dlouho. S nějakou formou vypracování práce na zakázku má dle různých šetření zkušenost mezi 8 a 20 procenty studentů (Mach, Foltýnek a kol., 2021). Vypracování úkolu chatbotem s sebou nese jen minimální či zcela nulové náklady, práce je přitom hotová okamžitě. To významně zvyšuje příležitost k podvádění. Hrozbu, že se taková praxe stane normou není možné ignorovat a je třeba zavést adekvátní opatření včetně změn zadání či podpory etické výchovy.

Nevhodné či nadměrné používání nástrojů na generování odpovědí s sebou přitom nenese pouze hrozbu etického charakteru. Přílišné spoléhání na tyto technologie může vést k povrchnímu pochopení látky a bránit rozvoji kompetencí (Kooli, 2023). Proto pokud nebudou ve školství plošně a v praxi zavedeny vhodné metody, existuje riziko, že dostupnost generativních modelů nepovede ke zkvalitnění procesu vzdělávání, ale k pravému opaku.

Hrozbu související s častým používáním automatizovaného hodnocení odpovědí představuje i neschopnost umělých systémů vidět za danou práci konkrétního člověka. Jistě jsou situace, kdy je na místě maximálně objektivní hodnocení, na druhou stranu studenti jsou lidé s jedinečnými osobnostmi a různými příběhy. Proto není vždy špatně, pokud učitel vidí za odpovědí konkrétního žáka a svoje hodnocení určitým způsobem individualizuje. Přílišná uniformita automatického hodnocení může odosobnit tuto část vzdělávacího procesu.

3 Jazykové modely jako nástroj pro studenty

V průběhu psaní této bakalářské práce byly testovány možnosti, jak využít AI jako pomocný nástroj při psaní školní práce. Konkrétně byly využity online překladače pro překlad zahraničních článků a AI chatboti pro rychlé vyhledání informací, vysvětlení a překlad anglických pojmů a generování návrhů na formulaci myšlenek, vyzkoušeno bylo také generování celých odstavců. V této kapitole budou popsány zkušenosti a postřehy z tohoto testování.

3.1 Online překladače

Pro účely této práce bylo čerpáno převážně z anglických elektronických zdrojů. Z toho důvodu bylo shledáno jako účelné využívat pro rychlou orientaci v textu a přibližný překlad článků překladače Google Translate (integrováný v prohlížeči Google Chrome), Microsoft Translate (integrováný v prohlížeči Microsoft Edge) nebo DeepL (je možné nainstalovat jako rozšíření do Google Chrome). Právě překladače integrované v prohlížeči poskytují komfort tím, že přeloží celou webovou stránku na dvě kliknutí. Tyto funkce ostatně nejsou žádnou novinkou a dá se předpokládat, že je studenti běžně využívají.

Je známo, že strojový překlad běžného nepříliš náročného či specifického textu bývá na relativně vysoké úrovni. Jedním z dílčích cílů práce bylo otestovat možnosti využití jazykových modelů studenty. S tím souvisí i otázka, jakým způsobem si umělá inteligence poradí s překladem odborného textu. Ukázalo se, že překlad je dostatečně kvalitní, aby umožňoval pochopení odborného textu zejména pro člověka, který již má alespoň základní povědomí o daném oboru. Přesto v žádném případě nelze tvrdit, že je strojový překlad zcela přesný, naopak vykazoval zejména níže popsané problémy.

První problém se týkal překladu odborných pojmů, které někdy v textu zůstaly v anglické podobě. V případě, že byl termín přeložen, šlo obvykle o doslovný překlad, a to včetně těch pojmů, které mají v češtině jiný ustálený ekvivalent, a nebo těch, které se v českých textech obvykle nepřekládají. V rámci jednoho textu se často vyskytoval stejný termín v přeložené i nepřeložené variantě.

Druhým problémem, který v některých případech ztěžoval pochopení významu textu, byla nevhodná volba slov, špatná syntaxe a další nedostatky. Jedním z faktorů je zřejmě i kvalita originálního textu. Pokud se totiž v přeloženém textu nacházelo větší množství těchto chyb, obvykle se jednalo o článek autorů, kteří nejsou rodilí mluvčí.

Jednotlivé překladače se navíc v kvalitě překladu lišily. Je to ilustrováno na následujícím krátkém úryvku z konferenčního příspěvku o automatizovaném hodnocení krátkých odpovědí u zkušebních testů na japonskou univerzitu (Oka a kol., 2022):

Originální text: *Automated short-answer scoring (SAS) techniques for English language have undergone technical improvements. Since the proposal of SAS that uses deep learning, its (SAS) performance has improved. Particularly, SAS was devised using a massive transformer-based language model. The demand of SAS is immeasurable and is not limited to new tests. Therefore, recent studies on SAS for practical purposes in Japan use data from actual mock examinations.*

Překlad Google Translate: *Techniky automatického skórování krátkých odpovědí (SAS) pro anglický jazyk prošly technickými vylepšeními. Od návrhu SAS, který využívá hluboké učení, se jeho výkon (SAS) zlepšil. Konkrétně SAS byl navržen pomocí masivního jazykového modelu založeného na transformátoru. Poptávka po SAS je neměřitelná a neomezuje se pouze na nové testy. Nedávné studie o SAS pro praktické účely v Japonsku proto používají data ze skutečných simulovaných vyšetření.*

Překlad Microsoft Translate: *Techniky SAS (Automated Short-Answer Scoring) pro anglický jazyk prošly technickým vylepšením. Od návrhu SAS, který využívá hluboké učení, se jeho výkon (SAS) zlepšil. Konkrétně SAS byl navržen pomocí masivního jazykového modelu založeného na transformátorech. Poptávka po SAS je nezměřitelná a neomezuje se pouze na nové testy. Proto nedávné studie o SAS pro praktické účely v Japonsku používají údaje ze skutečných zkoušek nanečisto.*

Překlad DeepL: *Techniky automatizovaného bodování krátkých odpovědí (SAS) v anglickém jazyce prošly technickým zdokonalením. Od doby, kdy byl navržen SAS využívající hluboké učení, se jeho výkonnost (SAS) zlepšila. Zejména SAS byl navržen s využitím modelu jazyka založeného na masivním transformátoru. Nároky na SAS jsou nezměrné a neomezují se pouze na nové testy. Proto se v nedávných studiích o SAS pro praktické účely v Japonsku používají data ze skutečných zkušebních testů.*

Překlad LINDAT: *Techniky automatizovaného bodování krátkých odpovědí (SAS) pro anglický jazyk prošly technickým zlepšením. Od návrhu SAS, který využívá hlubokého učení, se jeho (SAS) výkonnost zlepšila. Zvláště SAS byl navržen s využitím masivního modelu jazyka založeného na transformátorech. Poptávka SAS je nezměrná a neomezuje se pouze na nové testy. Proto nedávné studie o SAS pro praktické účely v Japonsku používají údaje ze skutečných modelových zkoušek.*

Potvrdilo se, že překladač od Googlu není v dnešní době tou nejlepší volbou. V této ukázce nesprávně použil výrazy „skórování“, „neměřitelná“ a „simulovaná vyšetření“, zatímco ostatní překladače si s těmito slovy poradily lépe. Naopak DeepL špatně formuloval větu: „...modelu jazyka založeného na masivním transformátoru.“ Nejlepší překlad tohoto textu vytvořil Microsoft Translate, přestože vůbec nepřeložil výraz „Automated Short-Answer Scoring“. U úryvku byl zahrnut pro srovnání ještě český překladač LINDAT, vyvinutý na Matematicko-fyzikální fakultě Univerzity Karlovy (Kořarko, Variš a Popel, 2019), jehož překlad se ukázal také na uspokojivé úrovni.

Obecně se dá konstatovat, že je kvalita strojového překladu odborných textů dostatečná zejména pro účely rychlého orientačního překladu. Není však možné takový překlad nekriticky přijímat, naopak je někdy nutno vybrané pasáže srovnat s originálním zněním. Např. překlad výrazu „*combined human-computer tutoring systems*“ se pohyboval od „*kombinované systémy doučování mezi člověkem a počítačem*“ až po „*kombinované systémy doučování člověka a počítače*“. Přesnost a odbornost tedy může být zajištěna pouze lidským překladatelem. Přes zmíněné nedostatky představují překladače užitečný nástroj zejména pro studenty, kteří chtějí čerpat ze zahraničních zdrojů, a neovládají přitom daný jazyk na dostatečně vysoké úrovni, aby pro ně bylo čtení v originále komfortní.

3.2 AI chatboti

3.2.1 Zdroj informací

Schopnosti současných AI chatbotů vybízí k jejich použití jako rychlého zdroje informací. V průběhu psaní této práce byli chatboti několikrát využiti jako nástroj pro rychlé povrchní obeznámení se s dílčím tématem, pro překlad a vysvětlení neznámých pojmů a pro vyhledání dalších informací. Využití chatbotů pro tyto účely představuje benefit ve formě úspory času, protože není nutné procházet různé odkazy a informace je k dispozici ihned.

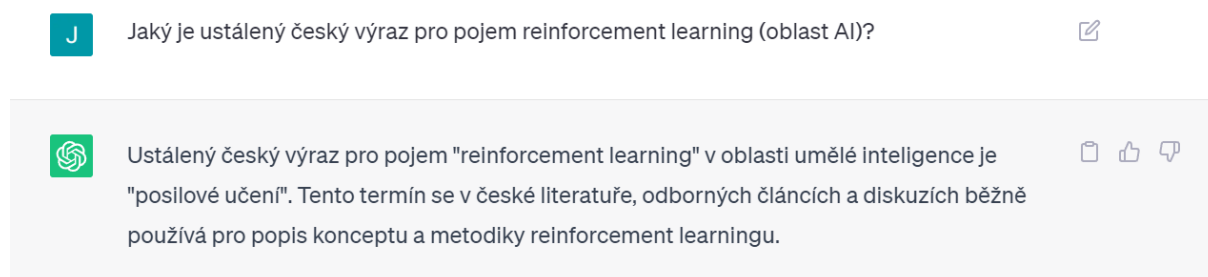
Zejména pokud jde o rychlé vysvětlení neznámých pojmů, ukázaly se generativní modely jako efektivní nástroj. Vysvětlení byla relativně správná, shrnující důležité informace. Navíc často není nutné pro pochopení studovaného textu rozumět konkrétnímu pojmu hlouběji.

Větší potíže nastávaly, pokud byl AI chatbot požádán, aby napsal český ekvivalent anglického pojmu. Někdy byly jeho odpovědi správné, jindy si vymýšlel a za český ekvivalent vydával svůj vlastní překlad. Zřetelně je to vidět např. na pojmu reinforcement learning, pro který se v české literatuře používá výraz zpětnovazební učení (zřídka též

posilované učení a učení posilováním). Na tomto pojmu bylo otestováno několik chatbotů, přičemž každý dostal stejnou otázku několikrát (vždy do nového chatu). Odpovědi testovaných chatbotů ChatGPT-3.5 (viz Obr. 6) a Deeply (viz Obr. 7) byly vždy chybné. YouBot v době testování zpočátku několikrát odpovídal chybně, jako český ekvivalent pojmu uvedl např. výrazy „zpevňování učení“ či „posilování učení“. V jednom případě však překvapil správným pojmem (viz Obr. 8), překlad navíc podložil zdroji (žádný z uvedených zdrojů se však nepodařilo dohledat). Nejlépe si vedl chatovací vyhledávač Bing, který ve stylu „vyvážený“ odpověděl pokaždé správně (viz. Obr. 9).

Podobně náhodné výsledky generovali chatboti pro dotazy na překlad jiných odborných pojmů. Např. pro pojem data mining, jehož správný český ekvivalent je vytěžování dat (Kučerová, 2003), případně se v české literatuře používá dolování dat či dolování z dat, generovala AI nejčastěji „těžba dat“ a „dolování dat“, výjimečně také „vytěžování dat“, „analýza dat“, „analytika dat“ či „sběr dat“.

Na tomto problému je krásně vidět, že jazykové modely jsou pouze nemyslicí generátory slov. Textům ve skutečnosti nerozumí a pouze odhadují vhodný sled slov na základě datasetu, na kterém byly trénovány. Pro účely překladu odborných pojmů jsou naprosto nevhodné. Jistota, s jakou nesprávné informace předkládají, přitom může působit matoucím dojmem.



Obr. 6: ChatGPT-3.5 uvedl nepoužívaný překlad „posilové učení“

(Zdroj: vlastní screenshot)



Jaký je ustálený český výraz pro pojem reinforcement learning (oblast AI)?



Ustálený český výraz pro pojem "reinforcement learning" je "učení s posilováním".

Obr. 7: Deeply také uvedl nepoužívaný výraz "učení s posilováním"

(Zdroj: vlastní screenshot)

Jaký je ustálený český výraz pro reinforcement learning (oblast AI)?

V ustáleném českém jazyce se pro "reinforcement learning" často používá termín "zpětnovazební učení". Tento výraz se vyskytuje například v následujících zdrojích:

- "Úvod do zpětnovazebního učení" (článek na stránkách Katedry kybernetiky na ČVUT)
- "Reinforcement learning z pohledu teorie informace" (článek na stránkách MatfyzPress)
- "Moderní kognitivní věda a strojové učení" (knihovna MUNI, kde je výraz "zpětnovazební učení" použit v jednom z článků).



Obr. 8: YouBot uvedl správný pojem, vícekrát však odpověděl nesprávně

(Zdroj: vlastní screenshot)

The screenshot shows a Bing search interface. At the top, a blue search bar contains the query "Jaký je ustálený český výraz pro 'reinforcement learning' (oblast AI)?". Below the search bar, there are two green checkmarks indicating successful search and generation. The main content area displays the answer: "Ustálený český výraz pro 'reinforcement learning' je **zpětnovazební učení**¹. Tento termín se používá v českém prostředí v oblasti umělé inteligence." Below the answer, there is a question "Můžu Vám s něčím dalším pomoci?". At the bottom, there are three blue links for "Další informace": "1. slovník.seznam.cz", "2. příručka.ujc.cas.cz", and "3. cs.wikipedia.org". On the right side, it says "1 z(e) 20" with a green dot.

Obr. 9: Bing odpovídal nejpřesněji

(Zdroj: vlastní screenshot)

Generativní modely se ukázaly jako užitečný nástroj také v případě vyhledávání doplňkových či konkrétních informací, jejichž vyhledávání pomocí tradičních vyhledávačů by

mohlo být časově náročné. Takto zjištěné informace je pochopitelně nutné ověřit. V tomto ohledu má výhodnou funkci vyhledávač Bing, který ke svým tvrzením nabízí i zdroje, ze kterých čerpal, informace je tak možné rychle ověřit. Několikrát se stalo, že poskytnutý zdroj ve skutečnosti neobsahoval vygenerovanou informaci. Na druhou stranu občas odkazoval na zajímavý zdroj, který se ukázal jako dále využitelný.

3.2.2 Korektura textu, formulace myšlenek


Někdy se stává, že student má povědomí o tom, co by chtěl vyjádřit, nicméně nezvládá formulovat myšlenky tak, aby dosáhl požadované akademické úrovně výsledného textu. V takových případech mohou být užiteční AI chatboti, kteří poskytnou návrhy na korekci textu. Stačí nahrubo zaznamenat myšlenky bez dodržování odpovídajícího akademického stylu a požádat jazykový model, aby navrhl korekturu podle daných požadavků. Například tento odstavec byl použit pro otestování možností automatické AI korektury.


Předchozí odstavec je výsledkem korektury vytvořené ChatGPT-3.5. Na základě požadavků byl autorský stylisticky nevhodný text přeformulován do této výsledné podoby. Myšlenky zůstaly stejné, pouze výsledný ráz více odpovídal akademickému stylu psaní. Model si bez problémů poradil i s přepsáním věty psané původně v první osobě do trpného rodu. U nevhodné formulace byly dále požadovány úpravy, dokud nebyl výsledek v očekávané kvalitě (viz Obr. 10).


Kromě korektury je model schopen jednotlivé myšlenky i samostatně složit do souvislého textu, viz následující odstavec.


Při psaní školních prací se ukazuje, že jazykové modely představují užitečný nástroj pro korekci textu. Tyto modely jsou schopny provádět efektivní úpravy a navrhovat vhodné formulace myšlenek, které dokážou sestavit do souvislého textu. Výhodou používání těchto modelů je, že si udržují požadovanou akademickou úroveň, což přispívá k vyšší kvalitě napsaných prací. Korektury AI rovněž šetří čas studentům, neboť jim pomáhají v případech, kdy se student ocitá v nejistotě ohledně formulace svých myšlenek. Nicméně, je důležité si být vědom nevýhod častého používání těchto nástrojů, jako je snížení rozvoje komunikativní kompetence u studenta.


Předchozí odstavec je zcela formulován jazykovým modelem ChatGPT-3.5. Jednotlivé myšlenky, ze kterých má být text sestaven, byly v dotazu formulovány bodově. Chatbot je sám přeformuloval a seskládal do uceleného textu (viz Obr. 11). Pochopitelně by bylo možné instrukcemi dále výstup upravovat tak, aby přesněji odpovídal autorově představě.


 Následující odstavec je součástí mé bakalářské práce. Navrhni korekturu textu, aby lépe odpovídal akademické úrovni psaní. Práce je psána v trpném rodě.
"Někdy se stává, že student ví, co chce napsat, ovšem myšlenky se mu nedaří formulovat tak, aby měl výsledný text požadovanou úroveň. K tomu mohou pomoci AI chatboti tím, že navrhnou korekturu textu. Stačí zapsat myšlenky přibližně, bez patřičné akademické kultury a požádat jazykový model, aby navrhl korekturu dle požadavků. Například tento odstavec jsem využila pro otestování možnosti této automatické AI korektury."


 Někdy se stává, že student má vědomost, co by chtěl vyjádřit, nicméně nezvládá formulovat myšlenky tak, aby dosáhl požadované akademické úrovně výsledného textu. V takových případech mohou být užiteční AI chatboti, kteří poskytnou návrhy na korekci textu. Stačí nhrubo zaznamenat myšlenky bez dodržování odpovídajícího akademického stylu a požádat jazykový model, aby navrhl korekturu podle daných požadavků. Například tento odstavec byl použit pro otestování možnosti automatické AI korektury.


 Nahraď prosím slovo "vědomost" vhodnějším výrazem.

 Někdy se stává, že student disponuje znalostmi, co by chtěl vyjádřit, nicméně nezvládá formulovat myšlenky tak, aby dosáhl požadované akademické úrovně výsledného textu.

 Přeformuluj část věty: "student disponuje znalostmi, co by chtěl vyjádřit"


 Někdy se stává, že student má povědomí o tom, co by chtěl vyjádřit.





 Tato formulace se mi líbí. Nahraď ji prosím v původně vytvořené korektuře.

 Někdy se stává, že student má povědomí o tom, co by chtěl vyjádřit, nicméně nezvládá formulovat myšlenky tak, aby dosáhl požadované akademické úrovně výsledného textu. V takových případech mohou být užiteční AI chatboti, kteří poskytnou návrhy na korekci textu. Stačí nhrubo zaznamenat myšlenky bez dodržování odpovídajícího akademického stylu a požádat jazykový model, aby navrhl korekturu podle daných požadavků. Například tento odstavec byl použit pro otestování možnosti automatické AI korektury.

Obr. 10: Korektura textu navržená modelem ChatGPT-3.5

(Zdroj: vlastní screenshot)

J Vytvoř odstavec do bakalářské práce psané v trpném rodě, který bude obsahovat následující  myšlenky (poskládej jednotlivé myšlenky do souvislého textu, který má patřičnou akademickou úroveň):
Jazykové modely zvládají dobré korektury textu
mohou samostatně navrhnout formulaci myšlenek a složit je do souvislého textu
Modely dokážou udržet požadovanou akademickou úroveň
Korektury AI šetří čas studentům při psaní školních prací
Mohou pomoci tam, kde si student neví s formulací rady
Nevýhodou častého používání může být nízké rozvíjení komunikativní kompetence u studenta

 Při psaní školních prací se ukazuje, že jazykové modely představují užitečný nástroj pro korekci textu. Tyto modely jsou schopny provádět efektivní úpravy a navrhnout vhodné formulace myšlenek, které dokážou sestavit do souvislého textu. Výhodou používání těchto modelů je, že si udržují požadovanou akademickou úroveň, což přispívá k vyšší kvalitě napsaných prací. Korektury AI rovněž šetří čas studentům, neboť jim pomáhají v případech, kdy se student ocitá v nejistotě ohledně formulace svých myšlenek. Nicméně, je důležité si být vědom nevýhod častého používání těchto nástrojů, jako je snížení rozvoje komunikativní kompetence u studenta.   

Obr. 11: ChatGPT-3.5 vytvořil z jednotlivých myšlenek souvislý text

(Zdroj: vlastní screenshot)

V druhém případě chatbot sám skládá myšlenky, dává je vzájemně do souvislosti, někdy mírně posouvá jejich význam a případně doplňuje tvrzení, která v původním zadání nebyla (v ukázce jde o část věty: „*což přispívá k vyšší kvalitě napsaných prací*“), čímž se spolupodílí na výsledném textu. Z tohoto důvodu autorka této práce považuje zmíněný způsob využívání jazykových modelů bez uvedení této skutečnosti za jednání na hraně etiky. Na druhou stranu mezi situacemi, kdy by měla být umělá inteligence považována za spoluautora (a tedy být řádně ocitována) a kdy ne, nemusí vést zcela jasná hranice. Záleží na formulaci dotazu i na tom, jak se následně pracuje s vygenerovaným textem. Rozhodujícím kritériem pro to, zda uvádět spolupráci s chatbotem na konkrétním úryvku by tak mohlo být např. to, zda jsou v konečné formulaci textu ryze myšlenky autora, či zda na úrovni myšlenek přispěla i umělá inteligence. Urban (2023) uvádí současná stanoviska vybraných vysokých škol k této problematice, která se pohybují na škále od úplného zákazu až po velmi vstřícné přístupy k použití AI jako podpůrného nástroje. O tom, jak se k této problematice postavit, se jistě povedou ještě dlouhé diskuze.

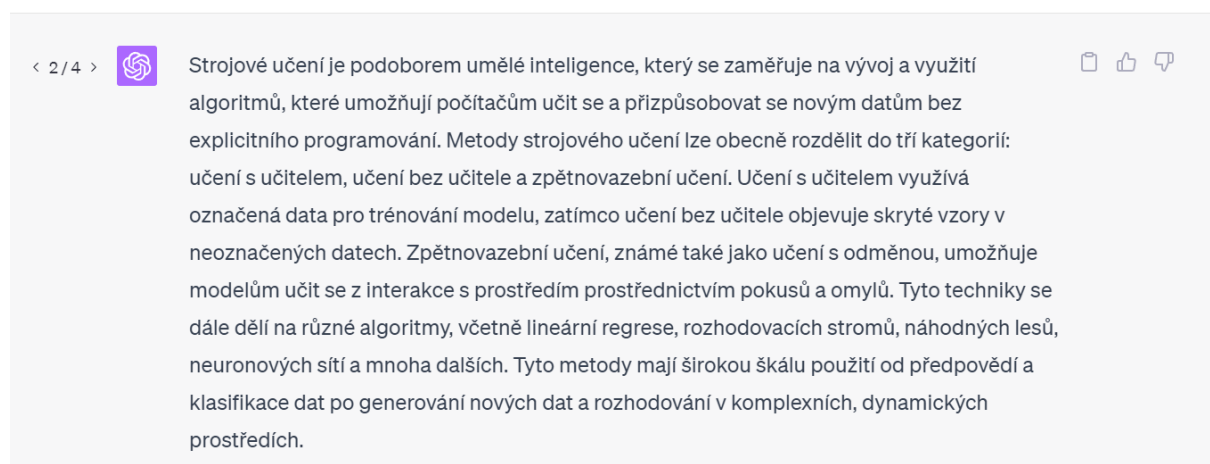
3.2.3 Generování celých odstavců

Riziko plagiátorství související s kvalitou současných AI generátorů textu bylo rozebíráno už v kapitole 2. Použití uměle generovaných textů v jakékoliv školní práci je bez

řádného ocitování podvodem. Pokud jde o angličtinu, Sharples (2022) uvádí schopnost ChatGPT napsat akademický článek. Tato podkapitola se snaží odpovědět na otázku, zda je nerozpoznatelný autor i v případě odborných textů v českém jazyce. Vyzkoušeno bylo generování textu na teoretická témata popisného charakteru (např. metody strojového učení, neuronové sítě, zpracování přirozeného jazyka) i na témata složitější (např. porovnání oblastí využití bayesovských a neuronových sítí).

Obecně se dá říct, že se kvalita jednotlivých výstupů značně lišila. V některých případech model na zadané téma vytvořil text obsahující výrazné nedostatky, takže by bylo možné odhadnout, že se jedná o automaticky generovaný text (viz Obr. 13). Častěji ovšem předložil práci na velmi dobré úrovni, jen s drobnými nepřesnostmi či prakticky bez chyb (viz Obr. 12). Ani v případě odborného textu v češtině tak nelze s jistotou rozeznat, zda je autorem člověk či stroj.

J Vygeneruj jeden odstavec popisující metody strojového učení.



Obr. 12: Jeden z lepších výstupů generování odborného textu. ChatGPT-4 se zde nedopustil výraznějších chyb.

Pro názvy metod použil ustálené české termíny (jen výraz „učení s odměnou“ se nepoužívá).

(Zdroj: vlastní screenshot)



Metody strojového učení jsou souborem algoritmů a technik, které umožňují počítačovým systémům automaticky se učit a zlepšovat své výkony na základě zkušeností a dat. Existuje několik hlavních metod strojového učení, které se používají v různých oblastech, jako je rozpoznávání obrazů, přirozeného jazyka, analýza dat a mnoho dalších. Zde jsou některé z těchto metod:



1. **Supervizované učení:** Tato metoda vyžaduje označená trénovací data, ve kterých jsou vstupy spojené s odpovídajícími výstupy. Algoritmy strojového učení se snaží naučit se mapovat vstupní data na správné výstupy na základě tohoto označeného trénovacího souboru.
2. **Nenadzorované učení:** Na rozdíl od supervizovaného učení tato metoda se učí bez označených dat. Algoritmy strojového učení se snaží najít strukturu nebo vzory v neoznačených datech. Nenadzorované učení se často používá pro shlukování dat, redukci dimenzionality a generativní modelování.
3. **Zpětnovazební učení:** Tato metoda umožňuje strojovému systému učit se prostřednictvím interakce s prostředím a obdržení zpětné vazby na základě jeho akcí. Systém se snaží maximalizovat odměnu nebo minimalizovat chybu na základě zpětné vazby, kterou obdrží.
4. **Posílené učení:** Tato metoda je často používána pro učení strojů, aby dosahovaly rozhodnutí a řídily akce v dynamickém prostředí. Algoritmy posíleného učení se učí pomocí strategií, které maximalizují kumulativní odměnu za správná rozhodnutí v interakci se zvoleným prostředím.
5. **Přenos učení:** Tato metoda se zaměřuje na přenos znalostí nebo dovedností z jedné úlohy nebo domény na jinou úlohu nebo doménu. Místo učení od nuly může stroj využít již naučené znalosti, aby urychlil učení nebo zlepšil výkon v novém prostředí.
6. **Hlubkové učení:** Tato metoda je založena na umělých neuronových sítích s více vrstvami, které se nazývají hluboké neuronové sítě. Hlubkové učení umožňuje modelům extrahovat stále abstraktnější a významnější reprezentace dat, což umožňuje řešení složitých úkolů, jako je rozpoznávání obrazů a překlad přirozeného jazyka.

Tyto metody představují jen některé z hlavních přístupů v oblasti strojového učení a jejich kombinace a rozšíření se neustále rozvíjejí, aby umožnily počítačovým systémům se adaptovat a učit se z různých druhů dat a úkolů.

Obr. 13: Nejhorší výstup generování odborného textu – ChatGPT-3.5 se dopustil zásadních chyb. V prvním odstavci chybí slovo „zpracování“ (přirozeného jazyka), pojem „nenadzorované učení“ neexistuje (jedná se o „učení bez učitele“), „4. posílené učení“ také neexistuje (popis odpovídá zpětnovazebnímu učení, označovanému někdy jako posilované učení), „Přenos učení“ a „Hlubkové učení“ (správně hluboké učení) jsou konkrétní metody/modely a nemohou být uvedeny jako další možnosti vedle základních metod učení s učitelem, učení bez učitele a zpětnovazebního učení.

(Zdroj: vlastní screenshot)

4 Jazykové modely jako nástroj pro učitele

Druhým dílčím cílem této práce bylo otestovat možnosti využití AI chatbotů jako nástroje pro učitele při přípravě na výuku. Existuje velmi pestrá paleta způsobů, jak využít AI přímo ve výuce nebo při přípravě na výuku⁵. V následujících podkapitolách bude popsána možnost tvorby celých příprav, tvorba materiálů a testových otázek.

4.1 Tvorba příprav

Učitelé mohou ChatGPT využít pro tvorbu celých příprav na výuku. Stačí napsat požadavky na konkrétní výukovou jednotku a jazykový model dokáže vygenerovat kompletní přípravu. Samozřejmě je možné zadat dotaz obecně, např. jen téma a věk žáků, nicméně čím více informací je modelu poskytnuto, tím lepší a přesnější bude výsledek. Je tak vhodné specifikovat časovou dotaci, vybavení učebny, počet dětí, požadavky na použité metody, předchozí znalosti a zkušenosti žáků, cíle hodiny a další očekávání či specifika dané třídy (viz Obr. 14).

Ze všech testovaných chatbotů (ChatGPT-3.5, ChatGPT-4, YouBot) se nejvíce osvědčil ChatGPT-4, který tuto komplexnější úlohu zvládal nejlépe. Předchozí model GPT měl problém sestavit průběh hodiny tak, aby součet času jednotlivých aktivit odpovídal stanovenému celkovému času výukové jednotky. ChatGPT-4 tento problém zvládal dobře.

Kromě vytvoření celé přípravy na výukovou jednotku je možné chatbota využít pro generování nápadů na aktivity do výuky, bez zasazování do konkrétního rámce hodiny (viz Obr. 15). Je dobré v dotazu specifikovat, o jaké aktivity má učitel zájem, včetně např. přídavných jmen typu zajímavý, zábavný, netradiční apod.

Chatbot pochopitelně není pedagogem, proto přirozeně může navrhopvat (a také navrhuje) aktivity, které neodpovídají dané věkové skupině, nezohledňují některé požadavky či trpí dalšími nedostatky, např. nereálným časovým odhadem. Je však na učiteli, jak bude s vygenerovaným obsahem dál pracovat, opět může být užitečné dotaz dále zpřesňovat a doplňovat, nebo si nechat některou navrženou aktivitu detailněji popsat. Celkově je však možno shrnout tento způsob využití jako užitečný, protože může přinést zajímavé nápady, které by třeba učitele nenapadly.

⁵ Zajímavé tipy jsou např. v Průvodci ChatGPT pro učitele: <https://aidetem.cz/dwnld/Pruvodce-ChatGPT-pro-ucitele.pdf>

- J** Jsem učitelka informatiky na ZŠ. Vytvoř přípravu na zajímavou či zábavnou výuku v 9. třídě na téma Umělá Intelligence kolem nás. Navrhni vhodné cíle. Zohleď následující požadavky: Výuková jednotka má 45 minut. Ve třídě je 14 dětí. Budou použity alespoň 3 různé metody, z toho žádná nebude výklad.



Název hodiny: Umělá Intelligence kolem nás



Cíle hodiny:

1. Studenti rozpoznají a identifikují příklady umělé inteligence ve své každodenní realitě.
2. Studenti porozumí základním konceptům a principům umělé inteligence.
3. Studenti zhodnotí dopad umělé inteligence na společnost a životní prostředí.

Struktura hodiny a metody:

1. **Diskuze na základě obrázků (10 minut)**
 - Vytiskněte obrázky nebo piktogramy různých předmětů a technologií, které využívají umělou inteligenci (např. mobilní telefony, samořízená auta, doporučovací algoritmy na internetu, hlasové asistentky jako Alexa, Google Home atd.).
 - Dejte studentům několik minut na to, aby prohlédli obrázky a diskutovali ve dvojicích, které z nich podle nich využívají umělou inteligenci.
 - Sbírejte názory a závěry třídy a diskutujte o nich.
2. **Skupinová práce s případovou studií (20 minut)**
 - Rozdělte třídu do skupin po 3-4 studentech. Každé skupině dejte případovou studii jedné technologie založené na umělé inteligenci (např. samořízená auta, doporučovací algoritmy, hlasové asistenty).
 - Úkolem skupin je prozkoumat, jak daná technologie funguje, jak využívá umělou inteligenci a jaký může mít dopad na společnost a životní prostředí.
 - Po skupinové práci se všechny skupiny sejdou a prezentují své zjištění třídě.
3. **Kreativní činnost: Návrh vlastní AI (10 minut)**
 - Po diskusích a prezentacích studentů je nechte, aby pracovali individuálně a navrhli vlastní technologii založenou na umělé inteligenci. Jak by tato technologie fungovala? Jaký by měla dopad na společnost a životní prostředí?
 - Umožněte studentům prezentovat své návrhy, pokud na to zbývá čas.
4. **Závěrečná diskuse a reflexe (5 minut)**
 - Závěrečná diskuse o tom, co se dnes naučili a jaké dopady může mít umělá inteligence na naši společnost a životní prostředí.
 - Reflektujte a shrňte hlavní body hodiny.

Potřebné materiály:

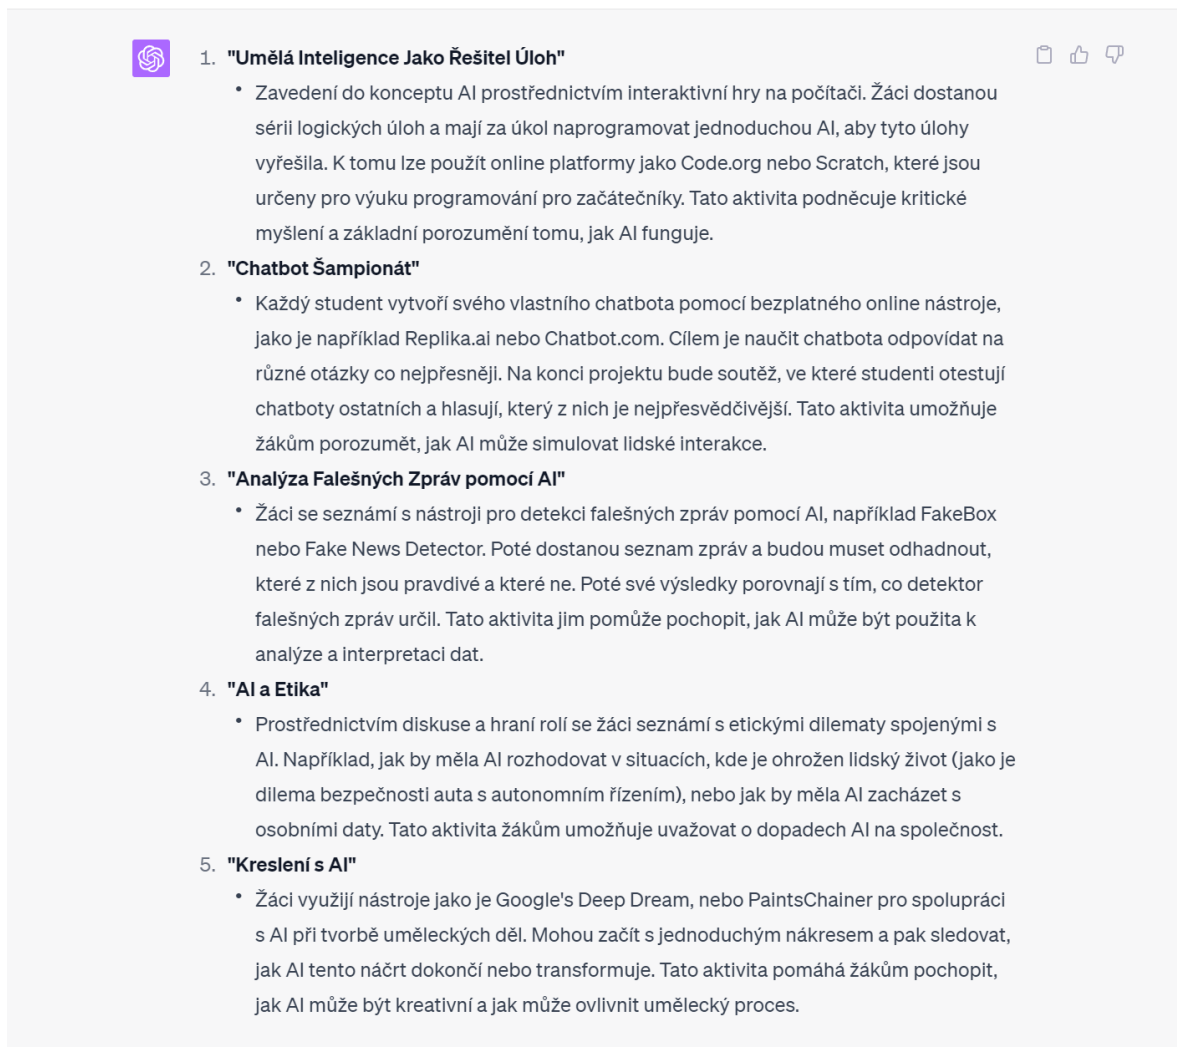
- Obrázky nebo piktogramy technologií využívajících umělou inteligenci
- Případové studie technologií využívajících umělou inteligenci
- Papír a tužky pro návrhy vlastních technologií založených na umělé inteligenci

Důležité poznámky:

- Ujistěte se, že studenti respektují názory ostatních během diskusí.
- Udržujte pozitivní a podporující atmosféru, když studenti prezentují své návrhy.
- Vždy je dobré mít v záloze další materiály a aktivity, pokud by některé části hodiny proběhly rychleji než očekáváno.

*Obr. 14: Příprava na výuku vygenerovaná ChatGPT-4
(Zdroj: vlastní screenshot)*

J Napiš 5 různých nejlépe zajímavých či netradičních aktivit do výuky, zaměřených na rozvoj AI gramotnosti. U žáků se nepředpokládají žádné předchozí znalosti ani zkušenosti s AI. Jedná se o skupinu 15 žáků, věk 14-15 let, dostupné vybavení učebny: počítače s přístupem k internetu, interaktivní tabule.



The screenshot shows a list of five activities generated by ChatGPT-4. Each activity is numbered and has a brief description. The activities are: 1. "Umělá Inteligence Jako Řešitel Úloh", 2. "Chatbot Šampionát", 3. "Analýza Falešných Zpráv pomocí AI", 4. "AI a Etika", and 5. "Kreslení s AI".

- "Umělá Inteligence Jako Řešitel Úloh"**
 - Zavedení do konceptu AI prostřednictvím interaktivní hry na počítači. Žáci dostanou sérii logických úloh a mají za úkol naprogramovat jednoduchou AI, aby tyto úlohy vyřešila. K tomu lze použít online platformy jako Code.org nebo Scratch, které jsou určeny pro výuku programování pro začátečníky. Tato aktivita podněcuje kritické myšlení a základní porozumění tomu, jak AI funguje.
- "Chatbot Šampionát"**
 - Každý student vytvoří svého vlastního chatbota pomocí bezplatného online nástroje, jako je například Replika.ai nebo Chatbot.com. Cílem je naučit chatbota odpovídat na různé otázky co nejpřesněji. Na konci projektu bude soutěž, ve které studenti otestují chatboty ostatních a hlasují, který z nich je nejpřesvědčivější. Tato aktivita umožňuje žákům porozumět, jak AI může simulovat lidské interakce.
- "Analýza Falešných Zpráv pomocí AI"**
 - Žáci se seznámí s nástroji pro detekci falešných zpráv pomocí AI, například FakeBox nebo Fake News Detector. Poté dostanou seznam zpráv a budou muset odhadnout, které z nich jsou pravdivé a které ne. Poté své výsledky porovnájí s tím, co detektor falešných zpráv určil. Tato aktivita jim pomůže pochopit, jak AI může být použita k analýze a interpretaci dat.
- "AI a Etika"**
 - Prostřednictvím diskuse a hraní rolí se žáci seznámí s etickými dilematy spojenými s AI. Například, jak by měla AI rozhodovat v situacích, kde je ohrožen lidský život (jako je dilema bezpečnosti auta s autonomním řízením), nebo jak by měla AI zacházet s osobními daty. Tato aktivita žákům umožňuje uvažovat o dopadech AI na společnost.
- "Kreslení s AI"**
 - Žáci využijí nástroje jako je Google's Deep Dream, nebo PaintsChainer pro spolupráci s AI při tvorbě uměleckých děl. Mohou začít s jednoduchým nákresem a pak sledovat, jak AI tento náčrt dokončí nebo transformuje. Tato aktivita pomáhá žákům pochopit, jak AI může být kreativní a jak může ovlivnit umělecký proces.

Obr. 15: Návrhy na aktivity vygenerované ChatGPT-4.

Mohou následovat dotazy na podrobnější popsání jednotlivých aktivit.

(Zdroj: vlastní screenshot)

4.2 Tvorba výukových materiálů

Dalším způsobem, jak může AI ulehčit práci učitelům, je tvorba výukových materiálů. Bylo otestováno generování pracovních listů a výukových textů pomocí ChatGPT-3.5 a ChatGPT-4. Oba modely dokázaly uspokojivě vytvořit pracovní listy (viz Obr. 16) i další texty (viz Obr. 17), které je možno využít ve výuce. Pochopitelně i tyto automaticky vytvořené texty je nutné kontrolovat, protože mohou obsahovat chyby, nicméně i přes tuto skutečnost mají potenciál ušetřit mnoho času.

J

Vytvoř pracovní list na téma "Umělá inteligence kolem nás" pro žáky 9. třídy ZŠ. Žáci nemají žádné předchozí znalosti ani dovednosti ohledně AI. V průběhu vypracování pracovního listu mají přístup k Internetu.



Pracovní list: Umělá inteligence kolem nás



Úvod:

Vítejte na pracovním listu na téma "Umělá inteligence kolem nás". Na tomto listu se dozvíte základní informace o umělé inteligenci (AI), jak ovlivňuje naše každodenní životy a jaké jsou její výhody a nevýhody. Při vypracování tohoto listu si můžete vyhledávat další informace na internetu.

1. Co je umělá inteligence?

- Vyhledejte definici umělé inteligence a zapište ji do vlastních slov.
- Jaké jsou hlavní cíle umělé inteligence?

2. Příklady umělé inteligence v každodenním životě:

- Vyhledejte příklady použití umělé inteligence v každodenním životě (například v chytrých telefonech, asistentech, sociálních médiích, zpracování obrazu apod.).
- Popište alespoň tři příklady a stručně vysvětlete, jak umělá inteligence v těchto případech funguje.

3. Výhody a nevýhody umělé inteligence:

- Seznamte se s výhodami a nevýhodami používání umělé inteligence.
- Sestavte tabulku, ve které vypíšete alespoň tři výhody a tři nevýhody umělé inteligence. K výhodám a nevýhodám přidejte stručné vysvětlení.

4. Etické otázky a umělá inteligence:

- Jaké etické otázky se vztahují k používání umělé inteligence?
- Vyberte si jednu etickou otázku spojenou s umělou inteligencí a stručně ji popište. Poté vypište své osobní stanovisko k této otázce a zdůvodněte ho.

5. Budoucnost umělé inteligence:

- Jak si myslíte, že se bude umělá inteligence vyvíjet v budoucnosti?
- Vyhledejte informace o nejnovějších trendech v oblasti umělé inteligence a zapište si nějaké zajímavé poznatky.

Závěr:

Na tomto pracovním listu jste se dozvěděli základní informace o umělé inteligenci a jak ovlivňuje naše životy. Doufáme, že jste si rozšířili své znalosti o této zajímavé technologii. Pokud máte nějaké další otázky, můžete se na ně obrátit učitel nebo vyhledat další informace na internetu.

Obr. 16: Pracovní list vygenerovaný pomocí ChatGPT-3.5

(Zdroj: vlastní screenshot)

J

Napiš případovou studii některé technologie založené na umělé inteligenci, tak aby byla srozumitelná žákům 9. třídy ZŠ.



< 2 / 2 >



Případová studie: Použití AI v dopravě - samořídící auta



Úvod:

Samořídící auta jsou jedním z nejdůležitějších technologických vývojů poslední doby. Tato vozidla využívají umělou inteligenci (AI), aby byla schopna řídit sama, bez potřeby lidského řidiče.

Jak to funguje?

Umělá inteligence v samořídících autech funguje pomocí kombinace různých technologií, jako jsou senzory (např. lidar, radar a kamery), které shromažďují data o okolním prostředí. Tato data jsou pak zpracována algoritmy AI, které rozhodují o tom, jak by mělo auto reagovat na různé situace, například když je před ním překážka, nebo když je potřeba zastavit na červenou.

Případová studie: Uber a samořídící auta

Uber, mezinárodní společnost nabízející služby sdílení jízdy, začala testovat samořídící auta v roce 2016 v americkém městě Pittsburgh. Cílem bylo zjistit, zda by mohla být tato technologie použita k zefektivnění a zbezpečení jejich služeb.

Během testování bylo samořídící auto Uberu schopno bezpečně navigovat po ulicích města, detekovat a reagovat na jiná vozidla, chodce a překážky. Avšak i přes tyto úspěchy, došlo i k několika problémům. V jednom případě auto Uberu způsobilo nehodu, protože nebylo schopno rozpoznat chodce, který nečekaně vstoupil na silnici.

Důsledky a učení:

Tento případ ukázal, že ačkoli samořídící auta mají obrovský potenciál pro zlepšení bezpečnosti a efektivity dopravy, stále existují výzvy, které je třeba překonat. Uber musel investovat do vývoje a vylepšení svých algoritmů pro detekci a reakci na neočekávané situace.

Závěr:

Umělá inteligence má obrovský potenciál pro přeměnu mnoha oblastí našeho života, včetně dopravy. Ale jako s každou novou technologií, je důležité pečlivě ji testovat a vylepšovat, aby byla co nejbezpečnější a nejefektivnější. Uberova zkušenost s samořídícími auty je příkladem toho, jak může průkopnická práce s AI vést k významným pokrokům, ale také ukázat na důležitost ostražitosti a kontinuálního vývoje.

Obr. 17: Případová studie vytvořená modelem ChatGPT-4

(Zdroj: vlastní screenshot)

Generované pracovní listy byly vždy logicky uspořádané, obsahovaly krátký úvod a závěr. V úvodu byly někdy uvedeny jednoduché instrukce, přestože to dotaz explicitně nepožadoval. Položky byly většinou více zaměřeny na vyhledání faktických informací, popis či vysvětlení, někdy obsahovaly i úlohy na vyšší kognitivní operace jako např. srovnání apod. Tyto znaky je ovšem možné snadno korigovat pomocí lepší konkretizace dotazu.

Generované výukové texty byly také většinou dobře použitelné, výjimečně obsahovaly chyby či nepřesnosti. Výhodou je, že jazykový model je schopen text formulovat v zadaném stylu a formě. Byl tak schopen např. velmi jednoduchým a čtivým způsobem vysvětlit problematiku metod strojového učení (dotaz obsahoval požadavek, že má text působit, jako by ho psal 15letý žák), vytvořit fiktivní diskuzi nebo případovou studii. Opět se osvědčilo dotazy co nejvíce specifikovat. Nicméně ne vždy výsledek definovaným charakteristikám odpovídal. Např. zadaný rozsah textu ChatGPT-3.5 někdy ignoroval, novější model však tento problém zvládal dobře.

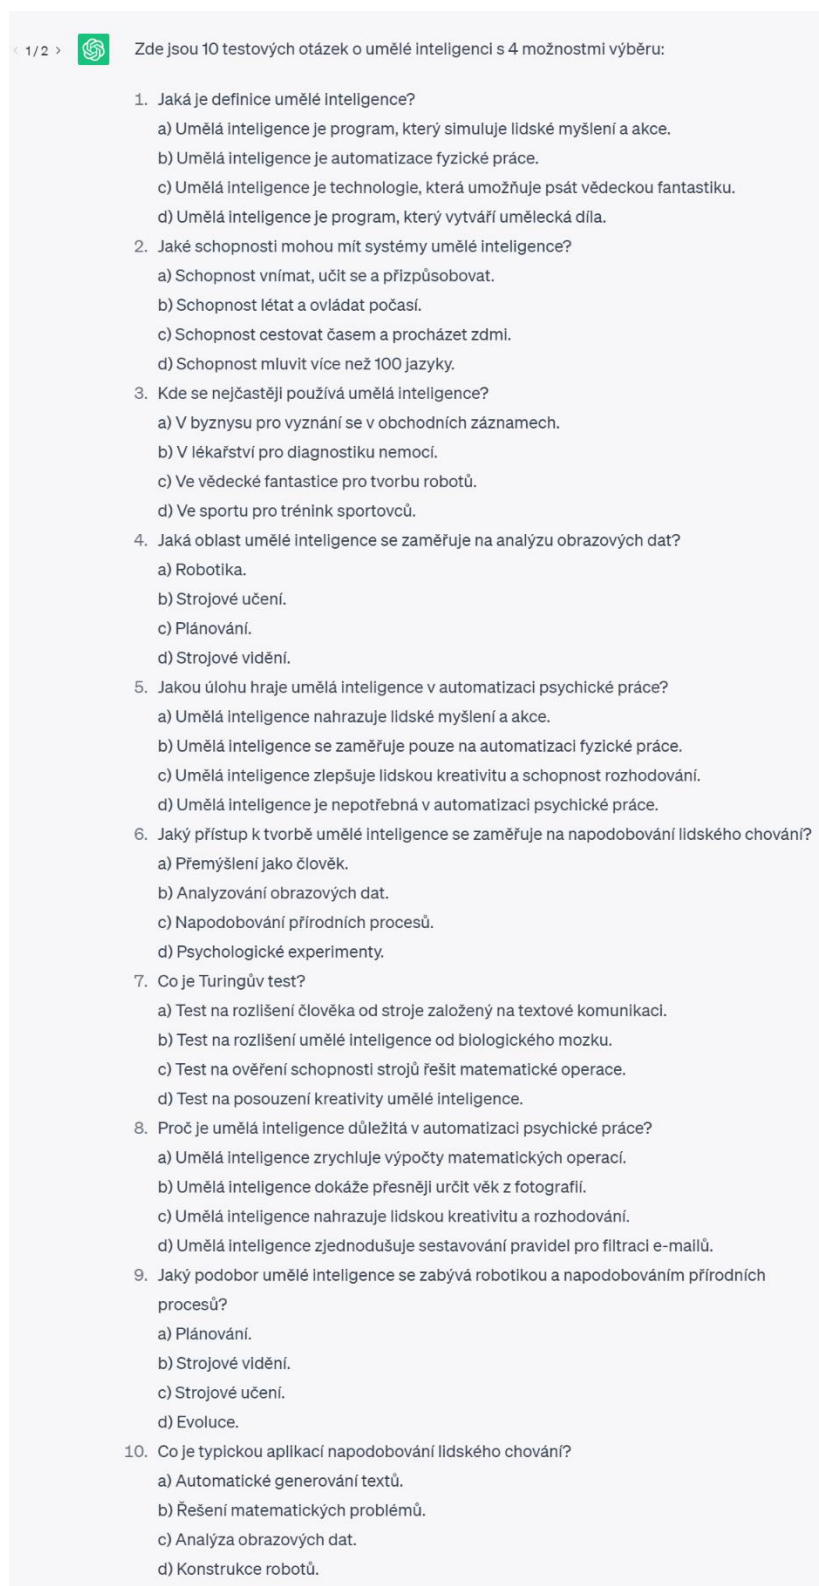
4.3 Tvorba testových otázek


Jak bylo rozebráno v kapitole 2.1, tvorba testových otázek je další činností, jejíž automatizace může učitelům významně pomoci. Byla otestována tvorba uzavřených testových otázek pomocí AI chatbotů na základě vloženého kontextu. Ukázalo se však, že model nebyl schopen vytvořit kvalitní sadu otázek. Největší problém byl s generováním vhodných distraktorů. Stávalo se například, že otázka měla ve skutečnosti 2 správné odpovědi, nebo byly možnosti zavádějící či nepřesné. Tvorba uzavřených testových otázek pomocí ChatGPT je tedy možná, ovšem vyžaduje následnou editaci učitelem.

Obr. 18 ukazuje generované otázky chatbotem ChatGPT-3.5 na dotaz: „Vytvoř 10 různě obtížných testových otázek se 4 možnostmi výběru s jednou správnou odpovědí, vycházejících z následujícího textu o umělé inteligenci: [byl vložen text o umělé inteligenci z webu AI dětem, dostupný z: <https://aidetem.cz/obecny-uvod-do-umele-inteligence/co-to-vlastne-je-ai/>]“.

V uvedené ukázce (viz Obr. 18) je příkladem zavádějícího distraktoru například možnost 5a), odpověď je totiž obecná a lze říci, že v určitých záležitostech skutečně může AI nahrazovat lidské myšlení a akce. Příkladem úplně špatně položené otázky včetně odpovědí je otázka č. 9, která zřejmě vychází z této věty zdrojového textu: „*Mezi další významné podobory umělé inteligence patří například **plánování** nebo **robotika**, které řeší úlohy napodobováním přírodních procesů, jako je evoluce nebo chování živočichů.*“ (Cahlík

a Jindra, 2022) Vytvořená otázka však nedává smysl a vůbec neodpovídá myšlence zdrojového textu. Na druhou stranu otázka č. 7 je příkladem dobře vygenerované otázky.



< 1/2 >  Zde jsou 10 testových otázek o umělé inteligenci s 4 možnostmi výběru:

1. Jaká je definice umělé inteligence?
 - a) Umělá inteligence je program, který simuluje lidské myšlení a akce.
 - b) Umělá inteligence je automatizace fyzické práce.
 - c) Umělá inteligence je technologie, která umožňuje psát vědeckou fantastiku.
 - d) Umělá inteligence je program, který vytváří umělecká díla.
2. Jaké schopnosti mohou mít systémy umělé inteligence?
 - a) Schopnost vnímat, učit se a přizpůsobovat.
 - b) Schopnost létat a ovládat počasí.
 - c) Schopnost cestovat časem a procházet zdi.
 - d) Schopnost mluvit více než 100 jazyky.
3. Kde se nejčastěji používá umělá inteligence?
 - a) V byznysu pro vyznání se v obchodních záznamech.
 - b) V lékařství pro diagnostiku nemocí.
 - c) Ve vědecké fantastice pro tvorbu robotů.
 - d) Ve sportu pro trénink sportovců.
4. Jaká oblast umělé inteligence se zaměřuje na analýzu obrazových dat?
 - a) Robotika.
 - b) Strojové učení.
 - c) Plánování.
 - d) Strojové vidění.
5. Jakou úlohu hraje umělá inteligence v automatizaci psychické práce?
 - a) Umělá inteligence nahrazuje lidské myšlení a akce.
 - b) Umělá inteligence se zaměřuje pouze na automatizaci fyzické práce.
 - c) Umělá inteligence zlepšuje lidskou kreativitu a schopnost rozhodování.
 - d) Umělá inteligence je nepotřebná v automatizaci psychické práce.
6. Jaký přístup k tvorbě umělé inteligence se zaměřuje na napodobování lidského chování?
 - a) Přemýšlení jako člověk.
 - b) Analyzování obrazových dat.
 - c) Napodobování přírodních procesů.
 - d) Psychologické experimenty.
7. Co je Turingův test?
 - a) Test na rozlišení člověka od stroje založený na textové komunikaci.
 - b) Test na rozlišení umělé inteligence od biologického mozku.
 - c) Test na ověření schopnosti strojů řešit matematické operace.
 - d) Test na posouzení kreativity umělé inteligence.
8. Proč je umělá inteligence důležitá v automatizaci psychické práce?
 - a) Umělá inteligence zrychluje výpočty matematických operací.
 - b) Umělá inteligence dokáže přesněji určit věk z fotografií.
 - c) Umělá inteligence nahrazuje lidskou kreativitu a rozhodování.
 - d) Umělá inteligence zjednodušuje sestavování pravidel pro filtraci e-mailů.
9. Jaký podobor umělé inteligence se zabývá robotikou a napodobováním přírodních procesů?
 - a) Plánování.
 - b) Strojové vidění.
 - c) Strojové učení.
 - d) Evoluce.
10. Co je typickou aplikací napodobování lidského chování?
 - a) Automatické generování textů.
 - b) Řešení matematických problémů.
 - c) Analýza obrazových dat.
 - d) Konstrukce robotů.

*Obr. 18: Uzavřený test generovaný pomocí ChatGPT-3.5
správné možnosti dle chatbota: 1a, 2a, 3b, 4d, 5c, 6a, 7a, 8c, 9a, 10a
(Zdroj: vlastní screenshot)*

Závěr

Umělá inteligence a zpracování přirozeného jazyka zažily v posledních letech významný pokrok napříč obory, vzdělávání nevyjímaje. Aktuálnost tématu této práce potvrdil i rozruch okolo nových AI chatbotů, k jejichž používání pro vzdělávací účely se v nejrůznějším smyslu vyjadřuje velká část vysokých škol i jednotlivé známé osobnosti na poli pedagogiky či informatiky. Některé postoje jsou optimistické, inspirativní a jiné pro změnu plné pochybností a obav. Díky tomuto dění je v posledních měsících umělá inteligence velmi diskutovaným tématem, pokud jde o moderní technologie a vzdělávání, a může se stát doslova spouštěčem revoluce ve školství.

Umělá inteligence a zpracování přirozeného jazyka mají nicméně ve vzdělávání více možností využití, než co nabízí chatboti typu ChatGPT. Jsou jimi pedagogičtí agenti poskytující adaptabilní personalizovaný přístup v inteligentních výukových systémech, programy poskytující komplexní formativní hodnocení psaných textů, software pro tvorbu testových otázek nebo bodování odpovědí studentů v otevřených testech.

Cíl práce, tedy analyzovat současné možnosti využití umělé inteligence a zpracování přirozeného jazyka ve vzdělávání, byl dosažen skrze analýzu zahraniční literatury, při jejímž výběru byl kladen velký důraz na aktuálnost. Pomocí SWOT analýzy byly posouzeny silné a slabé stránky, příležitosti a hrozby celé zkoumané oblasti AI a NLP ve vzdělávání. Práce tím přinesla do českého prostředí ucelený pohled na aktuální stav výzkumu a aplikací AI a NLP pro vzdělávací účely.

Stanovené dílčí cíle byly naplněny systematickým otestováním vybraných způsobů využití AI chatbotů typu ChatGPT při přípravě učitelů a studentů. Ukázalo se, že generativní modely dnes mohou dobře sloužit pro orientační překlad a jako rychlý zdroj informací, také je možné je účinně použít pro různé korektury textu, lze s nimi poměrně efektivně vytvářet a upravovat textové výukové materiály a přípravy do výuky. Přestože se u těchto výstupů objevovaly chyby, a není tak možné výstupy použít bez následné kontroly, míra chybovosti byla dostatečně nízká, aby umožnila výrazné zefektivnění práce oproti ručnímu sestavování. Pouze v případě generování uzavřených testových otázek vykazovaly výstupy vysokou chybovost a přínosy použití současných modelů pro tyto účely jsou tak diskutabilní. Výsledky testování včetně poznatků z jeho průběhu byly v práci popsány a doplněny screenshoty konverzací s chatboty. Práce tak může zároveň posloužit jako metodika pro učitele a studenty, jak si pomocí tohoto AI nástroje zefektivnit práci. Generovanou podporu výuky zatím nebyl prostor otestovat ve třídě, nicméně autorka zamýšlí její otestování v následujícím roce.

Seznam použitých zdrojů

Literatura

ALBORNOZ-DE LUISE, Romina Soledad, Miguel AREVALILLO-HERRÁEZ a David ARNAU. Using Open Source Technologies and Generalizable Procedures in Conversational and Affective Intelligent Tutoring Systems. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium* [online]. Cham: Springer International Publishing, 2022, 2022-07-26, s. 53-58 [cit. 2023-05-19]. Lecture Notes in Computer Science. ISBN 978-3-031-11646-9. Dostupné z: https://doi.org/10.1007/978-3-031-11647-6_9

BARAL, Sami, Karthik SEETHARAMAN, Anthony F. BOTELHO, Anzhuo WANG, George HEINEMAN a Neil T. HEFFERNAN. Enhancing Auto-scoring of Student Open Responses in the Presence of Mathematical Terms and Expressions. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 685-690 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_68

BARTÁK, Roman. *Co je nového v umělé inteligenci*. Praha: Nová beseda, 2020. ISBN 978-80-88383-13-0 (e-kniha; pdf).

BELFER, Robert, Ekaterina KOCHMAR a Iulian Vlad SERBAN. Raising Student Completion Rates with Adaptive Curriculum and Contextual Bandits. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 724-730 [cit. 2023-05-18]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_74

BELTAGY Iz, Matthew E. PETERS a Arman COHAN. *Longformer: The Long-Document Transformer* [online]. 2020 [cit. 2023-06-08]. Dostupné z: <https://doi.org/10.48550/arXiv.2004.05150>

BOTARLEANU, Robert-Mihai, Mihai DASCALU, Laura K. ALLEN, Scott Andrew CROSSLEY a Danielle S. MCNAMARA. Automated Summary Scoring with ReaderBench. In: CRISTEA, Alexandra I. a Christos TROUSSAS, ed. *Intelligent Tutoring Systems* [online]. Cham: Springer International Publishing, 2021, 2021-07-09, s. 321-332 [cit. 2023-06-08]. Lecture Notes in Computer Science. ISBN 978-3-030-80420-6. Dostupné z: https://doi.org/10.1007/978-3-030-80421-3_35

BOTARLEANU, Robert-Mihai, Mihai DASCALU, Laura K. ALLEN, Scott Andrew CROSSLEY a Danielle S. MCNAMARA. Multitask Summary Scoring with Longformers. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 756-761 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_79

CARLOTTO, Talvany a Patricia A. JAQUES. The effects of animated pedagogical agents in an English-as-a-foreign-language learning environment. *International Journal of Human-Computer Studies* [online]. 2016, 95, 15-26 [cit. 2023-05-31]. ISSN 10715819. Dostupné z: <https://doi.org/10.1016/j.ijhcs.2016.06.001>

COCHRAN, Keith, Clayton COHN, Nicole HUTCHINS, Gautam BISWAS a Peter HASTINGS. Improving Automated Evaluation of Formative Assessments with Text Data Augmentation. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 390-401 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_32

ČAPEK, Robert. *Moderní didaktika*. Praha: Grada Publishing, 2015, reprint 2022. ISBN 978-80-247-3450-7.

DEVER, Daryn A., Nathan A. SONNENFELD, Megan D. WIEDBUSCH a Roger AZEVEDO. Pedagogical Agent Support and Its Relationship to Learners' Self-regulated Learning Strategy Use with an Intelligent Tutoring System. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-

27, s. 332-343 [cit. 2023-05-18]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_27

ESMAEILZADEH, Soheil, Brian WILLIAMS, Davood SHAMSI a Onar VIKINGSTAD. Providing Insights for Open-Response Surveys via End-to-End Context-Aware Clustering. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 526-532 [cit. 2023-05-16]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_44

FUNAYAMA, Hiroaki, Tasuku SATO, Yuichiroh MATSUBAYASHI, Tomoya MIZUMOTO, Jun SUZUKI a Kentaro INUI. Balancing Cost and Quality: An Exploration of Human-in-the-Loop Frameworks for Automated Short Answer Scoring. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 465-476 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_35

GILLESPIE, Jamie, Kevin WINN, Malinda FABER a Jessica HUNT. Implementation of a Mathematics Formative Assessment Online Tool Before and During Remote Learning. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium* [online]. Cham: Springer International Publishing, 2022, 2022-07-26, s. 168-173 [cit. 2023-05-15]. Lecture Notes in Computer Science. ISBN 978-3-031-11646-9. Dostupné z: https://doi.org/10.1007/978-3-031-11647-6_29

HÁJEK, Petr. Soft computing. *Vesmír* [online]. 2000, 79(12) [cit. 2023-06-19]. Dostupné z: <https://vesmir.cz/cz/casopis/archiv-casopisu/2000/cislo-12/soft-computing.html>

HOLMES, Wayne a Ilkka TUOMI. State of the Art and Practice in AI in Education. *European Journal of Education* [online]. 2022, 57(4), 542-570 [cit. 2023-05-17]. ISSN 01418211. Dostupné z: <http://dx.doi.org/10.1111/ejed.12533>

HWANG, Gwo-jen a Nian-shing CHEN. Editorial Position Paper: Exploring the Potential of Generative Artificial Intelligence in Education. *Journal of Educational Technology* [online]. 2023, 26(2), 1-18 [cit. 2023-05-09]. ISSN 11763647. Dostupné z:

[https://doi.org/10.30191/ETS.202304_26\(2\).0014](https://doi.org/10.30191/ETS.202304_26(2).0014)

CHANTHIRAN, Maran a Punithavili MARIAPPAN. Bayesian Network Approach in Educational Application Development: A Systematic Literature Review and Bibliometric Meta-Analysis. *International Journal of Artificial Intelligence* [online]. 2022, 9, 8-16 [cit. 2023-05-17]. ISSN 26863251. Dostupné z: <https://doi.org/10.36079/lamintang.ijai-0901.348>

CHOLLET, François. *Deep learning v jazyku Python* [online]. Praha: Grada, 2019. ISBN 978-80-247-3100-1. Dostupné z: <https://www.bookport.cz/kniha/deep-learning-v-jazyku-python-6045>

JEON, Jaeho a Seongyong LEE. Large language models in education: A focus on the complementary relationship between human teachers and ChatGPT. *Education and Information Technologies: The Official Journal of the IFIP Technical Committee on Education* [online]. 2023, 1-20 [cit. 2023-05-09]. ISSN 13602357. Dostupné z:

<https://doi.org/10.1007/s10639-023-11834-1>

JORDAN, M. I. a T. M. MITCHELL. Machine learning: Trends, perspectives, and prospects. *Science* [online]. 2015, 349(6245), 255-260 [cit. 2023-05-04]. ISSN 00368075.

Dostupné z: <https://www.jstor.org/stable/24748571>

KASHEFI, Omid, Tazin AFRIN, Meghan DALE, Christopher OLSHEFSKI, Amanda GODLEY, Diane LITMAN a Rebecca HWA. ArgRewrite V.2: an annotated argumentative revisions corpus. *Language Resources and Evaluation* [online]. 2022, 56(3), 881-915 [cit. 2023-05-15]. ISSN 1574-020X. Dostupné z: <https://doi.org/10.1007/s10579-021-09567-z>

KATCHAPAKIRIN, Kantinee, Chutiporn ANUTARIYA a Thepchai SUPNITHI.

ScratchThAI: A conversation-based learning support framework for computational thinking development. *Education and Information Technologies* [online]. 2022, 27(6), 8533-8560 [cit. 2023-05-31]. ISSN 1360-2357. Dostupné z: <https://doi.org/10.1007/s10639-021-10870-z>

KHOSRAVI, Hassan a kol. Explainable Artificial Intelligence in education. *Computers and Education: Artificial Intelligence* [online]. 2022, 3. ISSN 2666-920X. Dostupné z:

<https://doi.org/10.1016/j.caeai.2022.100074>

KOCHMAR, Ekaterina, Dung Do VU, Robert BELFER, Varun GUPTA, Iulian Vlad SERBAN a Joelle PINEAU. Automated Data-Driven Generation of Personalized Pedagogical Interventions in Intelligent Tutoring Systems. *International Journal of Artificial Intelligence in Education* [online]. 2022, 32(2), 323-349 [cit. 2023-05-22]. ISSN 1560-4292. Dostupné z: <https://doi.org/10.1007/s40593-021-00267-x>

KOOLI, Chokri. Chatbots in Education and Research: A Critical Examination of Ethical Implications and Solutions. *Sustainability (2071-1050)* [online]. 2023, 15(7), 5614-5628 [cit. 2023-05-09]. ISSN 20711050. Dostupné z: <https://doi.org/10.3390/su15075614>

KŘIVAN, Miloš. Umělé neuronové sítě [online]. Praha: Oeconomica, 2021 [cit. 2023-05-05]. ISBN 978-80-245-2420-7. Dostupné z: <https://oeconomica.vse.cz/publikace/umele-neuronove-site-pripravujeme/>

KUMAR, P. Archana, Ashalatha NAYAK, Manjula S. K a kol. A Novel Framework for the Generation of Multiple Choice Question Stems Using Semantic and Machine-Learning Techniques. *International Journal of Artificial Intelligence in Education* [online]. 2023. <https://doi.org/10.1007/s40593-023-00333-6>

LI, Guohao, Matthias MÜLLER, Bernard GHANEM a Vladlen KOLTUN. Training Graph Neural Networks with 1000 Layers. *ArXiv* [online]. 2021 [cit. 2023-05-06]. Dostupné z: <https://doi.org/10.48550/arXiv.2106.07476>

LI, Haiying, Fanshuo CHENG, Grace WANG a Art GRAESER. The Impact of Conversational Agents' Language on Self-efficacy and Summary Writing. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 553-559 [cit. 2023-05-18]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_48

LITMAN, Diane, Tazin AFRIN, Omid KASHEFI, Christopher OLSHEFSKI, Amanda GODLEY a Rebecca HWA. An Automated Writing Evaluation System for Supporting Self-monitored Revising. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 581-587 [cit. 2023-05-12]. Lecture

Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z:

https://doi.org/10.1007/978-3-031-11644-5_52

LIU, Ming-Chi, Wei-Yang LIN a Chia-Ling TSAI. Computer-Aided Response-to-Intervention for Reading Comprehension Based on Recommender System. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 512-518 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_42

MAGOODA, Ahmed, Diane LITMAN, Ahmed ASHRAF a Muhsin MENEKSE. Improving the Quality of Students' Written Reflections Using Natural Language Processing: Model Design and Classroom Evaluation. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 519-525 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_43

MACH, Jan, Tomáš FOLTÝNEK a kol. *Jak předcházet psaní prací na zakázku* [online]. Praha: Univerzita Karlova, 2021 [cit. 2023-05-17]. Dostupné z: <https://dspace.cuni.cz/bitstream/handle/20.500.11956/172130/9788024651224.pdf>

MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. (1). Praha: Academia, 1993. ISBN 80-200-0496-3.

NIELSEN, Michael. *Neural networks and deep learning* [online]. Determination Press, 2015 [cit. 2023-05-05]. ISBN neuvedeno. Dostupné z: <http://neuralnetworksanddeeplearning.com/index.html>

OKA, Haruki, Hung Tuan NGUYEN, Cuong Tuan NGUYEN, Masaki NAKAGAWA a Tsunenori ISHIOKA. Fully Automated Short Answer Scoring of the Trial Tests for Common Entrance Examinations for Japanese University. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 180-192 [cit. 2023-05-13]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_15

PARASA, S. Niharika, Chaitali DIWAN, Srinath SRINIVASA. Automatické generování hádanek pro výukové zdroje. In: RODRIGO, M. Maria, Noburu MATSUDA, Alexandra I. CRISTEA (a kol.). *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium. AIED 2022* [online]. Springer, Cham, 2022, 343–347 [cit. 2023-05-08]. Dostupné z: https://doi.org/10.1007/978-3-031-11647-6_66

Rámcový vzdělávací program pro základní vzdělávání [online]. Praha: MŠMT, 2021 [cit. 2023-05-17]. Dostupné z: <https://www.edu.cz/rvp-ramcove-vzdelavaci-programy/ramcovy-vzdelavacici-program-pro-zakladni-vzdelavani-rvp-zv/>

SEARLE, John R. Minds, brains, and programs. *Behavioral and Brain Sciences*. 1980, **3**, [417-424]. [DOI: 10.1017/S0140525X00005756]. [ISSN 0140-525x]. Dostupné také z: <https://web.archive.org/web/20071210043312/http://members.aol.com/NeoNoetics/MindsBrainsPrograms.html>

SHARPLES, Mike. Automated Essay Writing: An AIED Opinion. *International Journal of Artificial Intelligence in Education: Official Journal of the International AIED Society* [online]. 2022, 1-8 [cit. 2023-05-09]. ISSN 15604292. Dostupné z: <https://doi.org/10.1007/s40593-022-00300-7>

SINGH, Purushartha, Rebecca J. PASSONNEAU, Mohammad WASIH, Xuesong CANG, ChanMin KIM a Sadhana PUNTAMBEKAR. Automated Support to Scaffold Students' Written Explanations in Science. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 660-665 [cit. 2023-05-13]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_64

SINGH, Purushartha, Rebecca J. PASSONNEAU, Mohammad WASIH, Xuesong CANG, ChanMin KIM a Sadhana PUNTAMBEKAR. Automated Support to Scaffold Students' Written Explanations in Science. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 660-665 [cit. 2023-05-13]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_64

SINHA, Tanmay a Shivam MALHOTRA. Embodied Agents to Scaffold Data Science Education. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium* [online]. Cham: Springer International Publishing, 2022, 2022-07-26, s. 150-155 [cit. 2023-05-30]. Lecture Notes in Computer Science. ISBN 978-3-031-11646-9. Dostupné z: https://doi.org/10.1007/978-3-031-11647-6_26

TAMANG, J. Lasang, Rabin BANJADE, Jeevan CHAPAGAIN a kol. Automatic Question Generation for Scaffolding Self-explanations for Code Comprehension. In: RODRIGO, M. Maria, Noburu MATSUDA, Alexandra I. CRISTEA a kol. *Artificial Intelligence in Education. AIED 2022* [online]. Springer, Cham, 2022 [cit. 2023-05-08]. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_77

VAN CAMPENHOUT, Rachel, Martha HUBERTZ a Benny G. JOHNSON. Evaluating AI-Generated Questions: A Mixed-Methods Analysis Using Question Data and Student Perceptions. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 344-353 [cit. 2023-05-16]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_28

WALTER, Candy. Increasing Teachers' Trust in Automatic Text Assessment Through Named-Entity Recognition. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium* [online]. Cham: Springer International Publishing, 2022, 2022-07-26, s. 191-194 [cit. 2023-05-12]. Lecture Notes in Computer Science. ISBN 978-3-031-11646-9. Dostupné z: https://doi.org/10.1007/978-3-031-11647-6_32

WANG, Zichao, Jakob VALDEZ, Debsihla BASU MALLICK a Richard G. BARANIUK. Towards Human-Like Educational Question Generation with Large Language Models. In: RODRIGO, M. Maria, Noburu MATSUDA, Alexandra I. CRISTEA (a kol.) *Artificial Intelligence in Education. AIED 2022* [online]. Springer, Cham, 2022 [cit. 2023-05-08]. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_13

WIJANARKO, Bambang Dwi, Yaya HERYADI, Hapnes TOBA a Widodo BUDIHARTO. Question generation model based on key-phrase, context-free grammar, and Bloom's taxonomy. *Education and Information Technologies: The Official Journal of the IFIP Technical Committee on Education* [online]. 2021, 26(2), 2207-2223 [cit. 2023-05-11]. ISSN 13602357. Dostupné z: <https://doi.org/10.1007/s10639-020-10356-4>

XIAO, Chenghao, Lei SHI, Alexandra CRISTEA, Zhaoxing LI a Ziqi PAN. Fine-grained Main Ideas Extraction and Clustering of Online Course Reviews. In: RODRIGO, Maria Mercedes, Noburu MATSUDA, Alexandra I. CRISTEA a Vania DIMITROVA, ed. *Artificial Intelligence in Education* [online]. Cham: Springer International Publishing, 2022, 2022-07-27, s. 294-306 [cit. 2023-05-16]. Lecture Notes in Computer Science. ISBN 978-3-031-11643-8. Dostupné z: https://doi.org/10.1007/978-3-031-11644-5_24

Elektronické zdroje

BĚLOHLÁVEK, Radim. Fuzzy logika umožňuje řešit praktické problémy, je blízká lidskému uvažování. Martina Šaradínová. In: *Univerzita Palackého v Olomouci* [online]. Olomouc: Univerzita Palackého v Olomouci, 14. října 2017 [cit. 2023-06-19]. Dostupné z: <https://www.upol.cz/nc/zpravy/zprava/clanek/fuzzy-logika-umoznuje-resit-prakticke-problemy-je-blizka-lidskemu-uvazovani/>

CAHLÍK Vojtěch a Vojtěch JINDRA. Co to vlastně je umělá inteligence. In: *AI dětem* [online]. AI dětem, září 2022 [cit. 2023-06-08]. Dostupné z: <https://aidetem.cz/obecnny-uvod-do-umele-intelligence/co-to-vlastne-je-ai/>

CENTRUM ZPRACOVÁNÍ PŘIROZENÉHO JAZYKA. *NLP* [online]. Brno: Centrum zpracování přirozeného jazyka, FI MUNI, 2023 [cit. 2023-05-10]. Dostupné z: <https://nlp.fi.muni.cz/cs/ZpracovaniPrirozenehoJazyka>

DURČÁK, Pavel. Neuronové sítě a princip jejich fungování. In: *NaPočítači.cz* [online]. Praha: Verlag Dashöfer, 8. září 2017 [cit. 2023-05-05]. Dostupné z: <https://www.napocitaci.cz/33/neuronove-site-a-princip-jejich-fungovani-uniqueidgOkE4NvrWuNY54vrLeM670eFNQh552VdDDulZX7UDBY/>

CHUPRINSKI, Mariah. Natural language processing software evaluates middle school science essays. In: *PennState* [online]. Pennsylvania State University, 11. října 2022 [cit.

2023-05-10]. Dostupné z: <https://www.psu.edu/news/engineering/story/natural-language-processing-software-evaluates-middle-school-science-essays/>

KOŠARKO, Ondřej, Dušan VARIŠ a Martin POPEL. *LINDAT Translation service*, LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University, 2019.

Dostupné z: <http://hdl.handle.net/11234/1-2922>

KUČEROVÁ, Helena. Vytěžování dat. In: *KTD: Česká terminologická databáze knihovnictví a informační vědy (TDKIV)* [online]. Praha: Národní knihovna ČR, 2003 [cit. 2023-05-26]. Dostupné z:

https://aleph.nkp.cz/F/?func=direct&doc_number=000000088&local_base=KTD

MATERNA, Jiří. Nebezpečná umělá inteligence od OpenAI. In: *Machine Learning Guru* [online]. Jiří Materna, 17. února 2019 [cit. 2023-05-10]. Dostupné z:

<http://www.mlgyuru.com/cs/dangerous-artificial-intelligence-by-openai/>

MATULA, Dominik. Bayesovské sítě: Jak postavit funkční síť na zelené louce. In: *Profinit* [online]. Praha: Profinit EU, 15. dubna 2020 [cit. 2023-05-04]. Dostupné z:

<https://profinit.eu/blog/bayesovske-site-jak-postavit-funkcni-sit-na-zelene-louce/>

OPENAI. Představujeme ChatGPT. In: *OpenAI* [online]. OpenAI, 30. listopadu 2022 [cit. 2023-05-10]. Dostupné z: <https://openai.com/blog/chatgpt>

PILÁT, Martin. Zpětnovazební učení. In: *Martin Pilát* [online]. Praha: Martin Pilát [cit. 2023-06-19]. Dostupné z: <https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/zpetnovazebni-uceni>

URBAN, Petr. ChatGPT jako nástroj k podvádění. České univerzity se v přístupu k AI rozcházejí. In: *e15* [online]. Praha: CZECH NEWS CENTER, 7. května 2023 [cit. 2023-05-26]. Dostupné z: <https://www.e15.cz/byznys/technologie-a-media/chatgpt-jako-nastroj-k-podvadeni-ceske-univerzity-se-v-pristupu-k-ai-rozchazeji-1398046>

WADHWANI, Preeti a Smriti LOOMBA. Artificial Intelligence (AI) in Education Market size to exceed \$30 bn by 2032. In: *Global Market Insights* [online]. Selbyville: Global Market Insights Inc., 2. února 2023 [cit. 2023-06-06]. Dostupné z:

<https://www.gminsights.com/pressrelease/artificial-intelligence-ai-in-education-market>

Kvalifikační práce

RATHOUZ, Vítězslav. *Vybrané kapitoly z umělé inteligence ve vzdělávání* [online]. Brno, 2017 [cit. 2023-05-05]. Dostupné z: <https://theses.cz/id/dsgwf7/>. Diplomová práce. Masarykova univerzita, Filozofická fakulta. Vedoucí práce RNDr. Michal Černý.

ROD, Martin. *Application of Bayesian Networks to Data Mining* [online]. Praha, 2018 [cit. 2023-05-17]. Dostupné z: https://insis.vse.cz/zp/portal_zp.pl?podrobnosti_zp=65580. Diplomová práce. Vysoká škola ekonomická v Praze, Fakulta managementu. Vedoucí práce prof. Radim Jiroušek, DrSc.

Seznam obrázků

Obr. 1: Příklad jednoduché bayesovské sítě.....	12
Obr. 2: Znárodnění jednoduché neuronové sítě se dvěma skrytými vrstvami.....	13
Obr. 3: Celkový přehled provedených revizí v ArgRewrite.....	21
Obr. 4: Rozhraní ArgRewrite umožňuje sledovat a porovnávat provedené opravy textu.....	22
Obr. 5: Automatická zpětná vazba v průběhu psaní evaluace v aplikaci CourseMIRROR	22
Obr. 6: ChatGPT-3.5 uvedl nepoužívaný překlad „posilové učení“	33
Obr. 7: Deeply také uvedl nepoužívaný výraz "učení s posilováním"	34
Obr. 8: YouBot uvedl správný pojem, vícekrát však odpověděl nesprávně.....	34
Obr. 9: Bing odpovídal nejpřesněji	34
Obr. 10: Korektura textu navržená modelem ChatGPT-3.5.....	36
Obr. 11: ChatGPT-3.5 vytvořil z jednotlivých myšlenek souvislý text	37
Obr. 12: Jeden z lepších výstupů generování odborného textu.	38
Obr. 13: Nejhorší výstup generování odborného textu – ChatGPT-3.5.....	39
Obr. 14: Příprava na výuku vygenerovaná ChatGPT-4.....	41
Obr. 15: Návrhy na aktivity vygenerované ChatGPT-4.....	42
Obr. 16: Pracovní list vygenerovaný pomocí ChatGPT-3.5	43
Obr. 17: Případová studie vytvořená modelem ChatGPT-4.....	44
Obr. 18: Uzavřený test generovaný pomocí ChatGPT-3.5.....	46

Anotace

Jméno a příjmení:	Jana Zemanová
Katedra:	Katedra technické a informační výchovy
Vedoucí práce:	Mgr. Lucie Bryndová
Rok obhajoby:	2023

Název práce:	Možnosti využití umělé inteligence a zpracování přirozeného jazyka ve vzdělávání
Název v angličtině:	Possibilities of using artificial intelligence and natural language processing in education
Anotace práce:	Tato bakalářská práce se zaměřuje na možnosti využití umělé inteligence (AI) a zpracování přirozeného jazyka (NLP) ve vzdělávání. Teoretická část představuje problematiku umělé inteligence. V praktické části byly na základě aktuálních zahraničních zdrojů analyzovány současné možnosti využití AI a NLP ve vzdělávání a pomocí SWOT analýzy zhodnoceny z pohledu silných a slabých stránek, příležitostí a hrozeb. Dále byly otestovány a popsány možnosti využití generativních AI chatbotů typu ChatGPT jako pomocného nástroje pro studenty a učitele. Práce tak přináší aktuální pohled na danou problematiku a zároveň může sloužit jako metodika pro studenty a učitele.
Klíčová slova:	Umělá inteligence, zpracování přirozeného jazyka, vzdělávání, jazykové modely, ChatGPT, bodování krátkých odpovědí, automatické formativní hodnocení, pedagogičtí agenti, automatické generování otázek
Anotace v angličtině:	This bachelor thesis focuses on the potential use of artificial intelligence (AI) and natural language processing (NLP) in education. The theoretical part introduces the concept of artificial intelligence. In the practical part, the current possibilities of using AI and NLP in education were analyzed based on recent foreign sources and evaluated in terms of strengths, weaknesses, opportunities and threats using SWOT analysis. Additionally, the possibilities of using generative AI chatbots like ChatGPT as an assistive tool for students and teachers were tested and described. The paper thus provides an up-to-date perspective on the subject and can also serve as a methodology for students and teachers.

Klíčová slova v angličtině:	Artificial intelligence, natural language processing, education, language models, ChatGPT, short answer scoring, automatic formative assessment, pedagogical agents, automatic question generation
Přílohy vázané v práci:	
Rozsah práce:	59 stran
Jazyk práce:	čeština