

DOI: <https://doi.org/10.54937/ssf.2026.25.2.114-125>

Inovativnost a postoje učitelů na 1. stupni ZŠ k využívání generativní umělé inteligence

Innovativeness and Attitudes of Primary School Teachers Towards the Adoption of Generative Artificial Intelligence

Petr Gonda, Martina Maněnová

Abstract

The rapid integration of Generative AI presents unique challenges for primary education. This study investigates the adoption patterns and attitudes of primary school teachers. A quantitative survey was conducted in the Hradec Králové Region, Czech Republic, with a final analyzed sample of 360 teachers (N=360). The instrument, based on Rogers' Diffusion of Innovations theory, categorized teachers and measured their experiences with and attitudes toward AI tools. Findings reveal a significant deviation from Rogers' model, with a high concentration in the 'Early Majority' (66.1%) and few 'Laggards' (5.8%). A strong positive correlation was found between completing AI-focused training and positive attitudes. Teachers primarily perceive AI as a productivity tool for their own preparation (e.g., ChatGPT, Canva), not as a tool directly for pupils. The data underscores an urgent need for targeted professional development to bridge the gap from viewing AI as a "teacher's tool" to its effective pedagogical integration.

Keywords: Artificial intelligence. Primary education. Teacher attitudes. Diffusion of innovations. Professional development. Generative AI.

Úvod

Umělá inteligence (AI) je rozsáhlý obor, který se zabývá studiem systémů známých jako inteligentní agenti, jak popisují Russell a Norvig (2021). Inteligentní agent je definován jako systém, který přijímá vjemy z prostředí a provádí akce s cílem dosáhnout nejlepšího nebo očekávaného výsledku. AI jako disciplína zahrnuje široké spektrum témat, od logiky a pravděpodobnosti po učení a uvažování. Klíčovým prvkem pro návrh kompetentních systémů je učení a schopnost agentů adaptovat se na změny v prostředí (Russell a Norvig, 2021). V kontextu vzdělávání představuje AI technologii s potenciálem transformace procesů, mimo jiné díky možnosti personalizovat učení (Kasneci a kol., 2023).

V posledních letech došlo k výraznému posunu paradigmatu s nástupem tzv. základních modelů (*foundation models*). Tento termín, navržený vědci ze Stanfordu (Bommasani a kol., 2021), odkazuje na modely trénované na rozsáhlých datech, které jsou posléze adaptovány na širokou škálu úloh (Miao a Holmes, 2023). Tento pokrok je umožněn rozvojem hlubokého učení (*deep learning*). Významným milníkem ve zpracování přirozeného jazyka se stalo zavedení architektury *Transformer*, kterou v roce 2017 představili Vaswani a kolektiv. Model *Transformer* je založen výhradně na mechanismu pozornosti – *attention* – a zcela se obejde bez tzv. rekurzivních nebo konvolučních vrstev. Tato architektonická změna zajistila lepší kvalitu a zároveň výrazně lepší paralelizovatelnost pro trénink (Vaswani a kol., 2017).

Na architektuře *Transformer* jsou postaveny Velké jazykové modely (*LLMs*), jako je například Generative Pre-trained Transformer – GPT. Tyto modely fungují primárně na principu podmíněné generace textu, kdy predikují následující slovo (token) na základě zadaného kontextu, což je základem pro interakci prostřednictvím výzev, tzv. promptů (Jurafsky a Martin, 2025). Vzhledem k rozsahu a univerzálnosti základních modelů (Bommasani a kol., 2021) se otevírají nové možnosti využití ve vzdělávání (Kasneci a kol., 2023):

- Zpracování přirozeného jazyka: *LLMs* dosáhly významných pokroků na mnoha lingvistických úlohách, včetně strojového překladu, sumarizace a generování textu (Kasneci a kol., 2023).
- Generování vizuálního a multimediálního obsahu: Generativní AI modely, které pracují s různými modalitami (včetně jazyka a vize), umožňují vytvářet obsah z intuitivních specifikací. Pokročilé multimodální modely, jako je GPT-4 (Miao a Holmes, 2023), jsou v promptech schopny akceptovat obrázky i text. Příklady vizuální syntézy, jako je model DALL-E, demonstrují generování vysoce kvalitních multimédií (Miao a Holmes, 2023).
- Adaptivní a personalizované systémy: *LLMs* mají potenciál zlepšit interakci s uživateli tím, že dokážou generovat kontextualizované a personalizované odpovědi (Kasneci a kol., 2023). AI může fungovat jako individuální kouč pro samostudium základních dovedností (Miao a Holmes, 2023). Tyto systémy mohou přizpůsobit výstup modelu na základě dat o žácích, jako je styl učení nebo předchozí znalosti (Kasneci et al., 2023).

Implementace těchto technologií do primárního vzdělávání však není pouze otázkou dostupnosti hardwaru či softwaru, ale především otázkou připravenosti lidského faktoru. Jak trefně poznamenává Brdička (2024): „*Ten učitel, který nedokáže naučit víc než stroj, má být nahrazen a nahrazen bude.*“ Úspěšná difuze této inovace je tedy závislá na postojích a inovačním potenciálu samotných pedagogů.

Pro analýzu tohoto procesu byla v této studii využita Teorie difuze inovací Everetta M. Rogerse, která klasifikuje členy sociálního systému na základě míry jejich přístupu k osvojování novinek – od Inovátorů přes Časné

osvojitele až po Opozdilce (Círus, Maněnová, Škoda, 2019). Aplikace této typologie na české školství je nanejvýš aktuální, neboť výzkum Univerzity Palackého ukázal, že ačkoliv učitelé vnímají AI jako potenciální přínos, 87 % z nich v roce 2023 neabsolvovalo v této oblasti žádné vzdělávání (Kopecký a kol., 2023).

Cílem této studie bylo proto prozkoumat inovační profily a postoje učitelů 1. stupně základních škol k adopci generativní umělé inteligence. Studie si kladla za cíl nejen kategorizovat pedagogy dle Rogersovy teorie, ale také identifikovat úroveň jejich reálného využívání aplikací založených na principech generativní umělé inteligence ve výuce. Výzkum byl proto veden třemi dílčími cíli:

- Kategorizovat učitele 1. stupně ZŠ podle Rogersovy teorie osvojování inovací v kontextu využívání AI.
- Zmapovat úroveň jejich reálných zkušeností s aplikacemi využívajícími generativní AI.
- Analyzovat jejich postoje k využívání generativní umělé inteligence ve vzdělávání.

Metodologie

Pro dosažení stanovených cílů byl realizován kvantitativní výzkum formou dotazníkového šetření. Výzkumný design byl zvolen s cílem získat data od širokého vzorku respondentů a statisticky analyzovat vztahy mezi jejich inovativnostmi, postoji a demografickými proměnnými.

Výzkumný nástroj

Byl využit dotazník vlastní konstrukce, který metodologicky vycházel ze standardizovaného nástroje Kankaarinty přeloženého na přelomu 20. a 21. století Černochovou pro měření inovativnosti pedagogů (Círus, Maněnová, Škoda, 2019). Původní nástroj, zaměřený na obecné ICT, byl pro účely této studie strategicky adaptován specificky pro kontext umělé inteligence. Tato adaptace byla klíčová, neboť AI představuje specifickou podmnožinu technologií s unikátními implikacemi pro vzdělávání.

Výzkumný soubor

Výzkumný soubor tvořilo 367 učitelů 1. stupně základních škol v Královéhradeckém kraji v České republice. Soubor byl charakteristický výraznou dominancí žen (92,37 %). Věková struktura byla různorodá, přičemž nejpočetnější skupiny tvořili učitelé ve věku 43–48 let (18,80 %) a 55–60 let (17,71 %). Z hlediska délky praxe byla nejvíce zastoupena skupina pedagogů s praxí nad 32 let (21,78 %). Majoritní část respondentů (80,65 %) uvedla, že má přímou aprobaci pro učitelství na 1. stupni ZŠ.


Sběr a analýza dat

Sběr dat probíhal od listopadu 2024 do ledna 2025. Dotazníky byly distribuovány kombinovanou metodou – tištěnou formou na vybraných školách a v rámci prezenčních školení, a elektronicky (pomocí Microsoft Forms) prostřednictvím všech jednotlivě a jmenovitě oslovených ředitelů základních škol v celém Královéhradeckém kraji.

Získaná data byla transkribována a analyzována ve statistickém programu NCSS. Pro klíčový cíl (kategorizaci respondentů) byla uplatněna specifická analytická procedura. Pro každý z pěti klastrů tvrzení (viz výše) bylo vypočítáno průměrné skóre. Po kontrole a čištění dat bylo k dispozici pro analýzu a další zpracování celkem 360 dotazníků. Byla provedena deskriptivní statistika, korelační a faktorová analýza.

Výsledky

Jak již bylo výše uvedeno, v rámci této studie jsou prezentovány výsledky kategorizace respondentů, která vychází z Rogersovy teorie difuze inovací v kontextu AI. Výsledné rozložení dat je uvedeno na grafu 1. Relativní četnosti jednotlivých kategorií jsou uvedeny v tabulce 1, tabulka 2 pak uvádí výchozí Rogersův teoretický model rozložení v jednotlivých kategoriích.



Graf 1: Rozložení respondentů podle kategorií

Tab. 1: Analýza dat ukazující odchylky od teoretického rozložení populace

Skupina	Absolutní četnost	Kumulativní absolutní četnost	Relativní četnost [%]	Kumulativní relativní četnost [%]
1	44	44	12,22	12,22
2	6	50	1,67	13,89
3	238	288	66,11	80,00
4	51	339	14,17	94,17
5	21	360	5,83	100,00

Tab. 2: Předpokládané rozložení populace dle Rogersova teoretického modelu

Inovátoři	Časní osvojitelé	Raná většina	Pozdní většina	Opozdilci
2,5 %	13,5 %	34 %	34 %	16 %

Nejvýraznější rozdíl byl zaznamenán u kategorie „Raná většina“, kam bylo zařazeno 66,11 % respondentů, zatímco Rogersův model předpokládá 34 %. Naopak, kategorie „Opozdilci“ byla zastoupena výrazně méně (5,83 %), než teorie uvádí (16,00 %). Podíl Inovátorů (12,22 %) byl vyšší než teoretický model (2,5 %), avšak kategorie Časných osvojitelů byla téměř absentující (1,67 % oproti 13,5 %).

Odchylka od Rogersova modelu si žádá interpretaci. Rogersova teorie byla formulována pro inovace, které se šíří postupně prostřednictvím sociálního vlivu. Nástup generativní AI, zejména ChatGPT na přelomu let 2022 a 2023, však nebyl postupnou adopcí, ale spíše náhlým a masivním vlivem, který vyústil v monopolizaci informačního prostředí (Dearing a Rogers, 1996 v Dearing, 2009). Je pravděpodobné, že tato náhlá a masivní expozice, působící jako silné posilující kontextuální podmínky, donutila pragmatickou Ranou většinu (*Early Majority*) k okamžité reakci a přeskočila tradiční, pomalejší fáze šíření vedené Inovátory a Časnými osvojiteli (Rogers, 2003 v Dearing, 2009). Učitelé proto nejednali ani tak z touhy po novosti, jako spíše z nutnosti adaptovat se na novou realitu a z vnímaného sociálního tlaku, což je primární motivací pro adopci u pozdnějších osvojitelů (Dearing, 2009).


Výsledky korelační analýzy

Analýza vztahu mezi délkou praxe (nezávislá proměnná) a zařazením do kategorie (závislá proměnná) ukázala, že mezi oběma proměnnými existuje statisticky významná, avšak velmi slabá pozitivní souvislost. Pearsonův korelační koeficient činí $r = 0,19$, což odpovídá slabému lineárnímu vztahu. Tento závěr potvrzuje i Spearmanův koeficient pořadové korelace, který dosáhl podobné hodnoty. Statistická významnost byla ovlivněna velikostí

souboru, avšak samotná síla efektu zůstává nízká. Prakticky to znamená, že jedinci s delší praxí bývají sice mírně častěji zařazováni do vyšších skupin, avšak tento trend je jen velmi slabý a má omezený praktický dopad.

Lineární regresní model, v němž byla kategorie predikována pomocí délky praxe, potvrdil nízkou vysvětlující schopnost prediktoru. Koeficient determinace činí $R^2 \approx 0,04$, což znamená, že délka praxe vysvětluje přibližně 4 % variability zařazení do skupiny. Přestože je sklon regresní přímky statisticky významný, jeho velikost je malá: s každým dalším rokem praxe se predikovaná hodnota skupiny zvyšuje pouze asi o 0,4 bodu. Tento efekt lze z hlediska aplikované praxe hodnotit jako málo výrazný.

Vizuální analýza dat prostřednictvím scatterplotu s regresní přímkou (Graf 2) ukazuje, že hodnoty závislé proměnné jsou vzhledem k délce praxe značně rozptýlené a regresní přímku sledují pouze velmi volně. To odpovídá nízké hodnotě R^2 . Reziduální graf poté neodhalil systematické vzorce či nelineární struktury, což naznačuje, že lineární model je formálně použitelný. Výrazná variabilita reziduí však ukazuje, že proměnná délka praxe není silným prediktorem kategorického zařazení.



Graf 2: Scatterplot s regresní přímkou

Celkově lze konstatovat, že délka praxe je sice statisticky významně asociována s vyšším zařazením do skupiny, avšak tento vztah má velmi malou sílu. Pro praktickou predikci či hlubší porozumění determinaci jednotlivých skupin by bylo vhodné zahrnout další relevantní proměnné, které se na výsledném zařazení podílejí pravděpodobně podstatně větší měrou.

Výsledky faktorové analýzy


Faktorová analýza byla provedena s cílem identifikovat latentní struktury mezi 25 položkami rozdělenými do pěti tematických okruhů (K1–K5). Analýza byla realizována na souboru 360 respondentů. Nejprve byla ověřena vhodnost dat pro faktorové zpracování. Bartlettův test sféricity byl statisticky významný ($\chi^2(300) = 3088,31$; $p < .001$), což indikuje, že korelační matice se významně liší od identity a položky mezi sebou vykazují dostatečnou míru interkorelace. Nízká hodnota determinantu korelační matice ($\text{Log}(\text{Det}|\mathbf{R}|) = -8,83$) dále potvrzuje přítomnost silnějších vzájemných vztahů mezi proměnnými a podporuje použitelnost faktorové analýzy.

Hodnoty communalit se pohybovaly v rozsahu 0,22–0,65, což znamená, že extrahované faktory vysvětlují přiměřenou část variance jednotlivých položek. Nejvyšší communalities byly pozorovány u položek K1_3 (0,62), K5_1 (0,60) a K5_4 (0,65), což ukazuje na jejich silné zakotvení ve společné faktorové struktuře. Naopak nižší hodnoty communalit byly identifikovány u položek K3_5, K4_3 nebo K4_2, jejichž společná variance s ostatními položkami je omezenější. Tyto položky jsou sice do struktury zahrnuty, ale přispívají relativně menší měrou.

Uvnitř jednotlivých skupin položek se objevují převážně středně silné pozitivní korelace ($r \approx .30-.55$), což ukazuje na dobrou vnitřní konzistenci škál. Nejvyšší korelace byly pozorovány v rámci škály K1 a K5, kde položky vykazují silné vztahy a pravděpodobně reprezentují dobře definované latentní konstrukty.

Naopak korelace mezi různými okruhy (např. K1 \times K4 nebo K2 \times K5) jsou převážně slabé nebo záporné. To ukazuje, že jednotlivé škály reprezentují odlišné dimenze a měří různé aspekty sledovaného fenoménu. Struktura dat tak nevytváří nežádoucí redundanci a je vhodná pro vícerozměrné modelování.

Na základě kritéria vlastního čísla ($\lambda > 1$) byly extrahovány celkem tři až pět faktorů (v závislosti na metodě a rotaci), přičemž hlavní interpretace se opírá o pětifaktorové řešení, které poskytuje nejjasnější teoretické ukotvení a je podpořeno i Scree plotem (Graf 3).



Graf 3: Porovnání Scree plotů (suťových grafů)

Faktor 1 je tvořen především položkami z první škály (K1_1 až K1_5), které vykazují silná pozitivní zatížení. Tento faktor lze interpretovat jako primární dimenzi prvního tematického okruhu, vykazující velmi dobrou soudržnost a silnou vazbu na latentní konstrukty.

Druhý faktor je tvořen převážně položkami K2_1 až K2_5, částečně doplněnými položkami K4. Tento faktor reprezentuje druhou oblast měřeného konstruktů, která se významně odlišuje od prvního faktoru, ale vykazuje dobrou vnitřní strukturu.

Faktor 3 je charakteristický výraznými zápornými korelacemi u položek K3. To ukazuje, že se jedná o samostatnou dimenzi, která je orientována opačně vůči ostatním faktorům. Tato inverzní orientace je typická u škál, které měří opačný typ charakteristiky nebo alternativní aspekt sledovaného jevu.

Čtvrtý faktor byl tvořen zejména položkami K4_1 až K4_5. Tyto položky vykazují střední hodnoty communalit a směřují k samostatné interpretaci, přestože některé přesahy mezi faktory naznačují částečnou vícefaktorovou strukturu.

Položky K5 vykazují nejvyšší soudržnost a tvoří velmi stabilní faktor s výraznými zatíženími. To ukazuje, že tato škála představuje nejednoznačnější a nejvýrazněji oddělenou latentní dimenzi v celé analýze.

Výsledná struktura faktorů je dobře interpretovatelná a odpovídá teoretickému rozdělení položek do pěti oblastí. Každý faktor přímo navazuje na jednu tematickou škálu, přičemž drobné přesahy mezi skupinami K2 a K4 jsou z psychometrického hlediska běžné a nepředstavují problém. Faktorová řešení napříč oběma dokumenty jsou stabilní a navzájem konzistentní.

Výsledky faktorové analýzy poskytly jasné důkazy o tom, že použitý soubor položek lze vhodně popsat pomocí vícerozměrné latentní struktury. Pět extrahovaných faktorů odpovídá předpokládanému teoretickému členění škál a vykazuje dobrou vnitřní konzistenci i odlišnost. To, že jednotlivé skupiny položek (K1–K5) tvoří výrazně oddělené faktory, naznačuje, že měří odlišné aspekty sledovaných psychologických či behaviorálních jevů a nekonflují mezi sebou. Tento výsledek podporují také vnitroskupinové korelace, které byly převážně středně silné, což je žádoucí v případě, kdy položky mají reflektovat podobný konstrukt.

Některé položky však vykazovaly nižší communalities (např. K3_5, K4_3), což ukazuje, že se do faktorové struktury zapojují jen omezenou měrou. Z psychometrického hlediska to může naznačovat buď problematickou formulaci těchto položek, nebo jejich slabší relevanci vůči měřenému konstrukt. Přestože tyto položky nebyly natolik slabé, aby narušovaly celkovou strukturu, může být vhodné jejich obsah zvážit v budoucích úpravách nástroje – například je přeformulovat, nahradit nebo doplnit dalšími položkami zachycujícími stejný fenomén.

Diskuse korelační a regresní analýzy

Korelační a regresní analýzy doplnily zjištění faktorové analýzy a umožnily posoudit vztah mezi praktickou zkušeností respondentů a jejich zařazením do jednotlivých skupin. Ačkoli výsledky ukázaly statisticky významný vztah mezi délkou praxe a zařazením do Skupiny, šlo o vztah velmi slabý ($r \approx 0,19$). Tento efekt se projevil také v regresním modelu, kde délka praxe vysvětlila pouze přibližně 4 % variability skupinového zařazení ($R^2 \approx 0,04$). Statistická významnost je v tomto případě důsledkem relativně velkého počtu respondentů, nikoli síly efektu.

Z praktického hlediska výsledky naznačují, že délka praxe sice může hrát určitý dílčí roli v tom, do jaké skupiny je jednotlivec zařazen, avšak její vliv je minimální. Větší část variability je pravděpodobně způsobena jinými faktory, které nebyly v tomto modelu zahrnuty – například typem odbornosti, úrovní vzdělání, kvalitou výkonu nebo specifickými kompetencemi. To odpovídá i obecným poznatkům z oblasti profesního růstu, kde délka praxe sice může predikovat určité aspekty zařazení, avšak není dostatečně silným samotným prediktorem.

Kombinace faktorové a korelační analýzy ukazuje na důležitou skutečnost: zatímco individuální položky dotazníku tvoří jasnou a dobře identifikovatelnou faktorovou strukturu, jejich vztah k vnějším proměnným (jako je délka praxe) je slabý. To je v psychometrii poměrně běžné; vnitřní konstrukce nástroje může být robustní, aniž by jednotlivé škály silně asociovaly s jedním specifickým vnějším kritériem. Faktory tedy pravděpodobně měří nuance, které nejsou přímo závislé na délce praxe, ale reflektují komplexnější psychologické nebo profesní charakteristiky.

Celkově lze říci, že výsledky podporují validitu a stabilitu měřicího nástroje, zatímco související prediktivní vztahy poukazují na potřebu širšího modelu zahrnujícího více prediktorů. Tato kombinace je zcela běžná a poukazuje na to, že faktorová analýza a korelace odpovídají na odlišné typy výzkumných otázek – zatímco jedna se zaměřuje na vnitřní strukturu konstruktů, ta druhá se týká jeho vztahu k externím proměnným.

Limity výzkumu a kontext

Je nezbytné interpretovat výsledky v kontextu limitů této studie. Výzkumný vzorek byl omezen na jeden z krajů České republiky a byl založen na dobrovolné účasti respondentů, což omezuje plnou zobecnitelnost závěrů na celou populaci učitelů 1. stupně v ČR. Dynamický vývoj AI zároveň znamená, že zjištění odrážejí situaci v době sběru dat. Regresní model zahrnoval pouze jedinou nezávislou proměnnou – délku praxe. Toto zjednodušení umožnilo základní analýzu vztahu, avšak významně omezuje jeho interpretaci, protože zařazení do skupiny může být podmíněno mnoha dalšími faktory (např. kvalifikací, typem pracovní pozice, odbornými dovednostmi, výsledky hodnocení výkonu). Studie tedy nepostihuje komplexnost reálných rozhodovacích procesů.

Velikost vzorku umožnila detekovat i velmi slabé korelace jako statisticky významné. Vztah mezi délkou praxe a skupinou byl sice statisticky signifikantní, ale z hlediska praktického uplatnění má nízkou sílu. Výsledky je proto třeba interpretovat obezřetně a nevyvozovat z nich závěry, které přesahují jejich skutečný efekt.

Přesto jsou výsledky relevantní. Zasazují se do kontextu předchozích výzkumů, jako například Círus (2017), který při zkoumání adopce ICT rovněž identifikoval odchylku od Rogersova modelu směrem k vyšší míře inovativnosti u pedagogů. Tato studie naznačuje, že v kontextu AI je tato tendence učitelů k adaptaci ještě výraznější.

Závěr

Cílem této práce bylo ověřit strukturu, kvalitu a praktickou využitelnost měřicího nástroje prostřednictvím faktorové analýzy a následně prozkoumat vztah mezi délkou praxe a zařazením do jednotlivých skupin respondentů pomocí korelační a regresní analýzy. Výsledky faktorové analýzy jednoznačně potvrdily existenci stabilní pětifaktorové struktury, která je teoreticky v souladu s koncepcí měřeného jevu. Položky jednotlivých škál tvoří soudržné a dobře interpretovatelné faktory, přičemž vnitroskupinové korelace naznačují adekvátní konzistenci daných konstrukcí. Komunalitní hodnoty byly ve většině případů ve středních až vyšších pásmech, což svědčí o kvalitním zapojení položek do latentní struktury.

Korelační a regresní analýza přinesly doplňující pohled na vztah mezi praxí a zařazením do skupin. Ačkoli byl tento vztah statisticky významný, jeho síla byla velmi nízká ($r \approx 0,19$; $R^2 \approx 0,04$). Délka praxe tedy představuje

pouze minoritní faktor ovlivňující zařazení, což naznačuje, že jde o komplexní proces, který je formován širší škálou proměnných, než zahrnoval použitý statistický model. Závěrem lze konstatovat, že měřicí nástroj vykazuje dobré psychometrické vlastnosti, stabilní faktorovou strukturu a potenciál pro praktické použití, zatímco predikce zařazení na základě délky praxe je omezená a vyžaduje další proměnné pro plnohodnotné vysvětlení.

Výsledky práce mají několik praktických dopadů, které mohou být užitečné pro organizace, odborné instituce či vedoucí pracovníky, kteří pracují s hodnocením kompetencí nebo profesního zařazení:

- **Validita nástroje pro diagnostické a evaluační účely**

Stabilní pětifaktorová struktura potvrzuje, že dotazník lze bezpečně používat pro diagnostiku jednotlivých oblastí, které faktory reprezentují. Každý z identifikovaných faktorů zachycuje odlišnou dimenzi sledovaného fenoménu, což umožňuje cílené hodnocení specifických kompetencí nebo charakteristik.

- **Potřeba komplexnějších rozhodovacích modelů**

Slabý vztah mezi délkou praxe a zařazením do skupiny ukazuje, že rozhodování založené pouze na počtu let praxe je nedostatečné. Praxe má omezený predikční význam a měla by být doplněna dalšími ukazateli, jako jsou kvalita výkonu, odborné certifikace, úroveň samostatnosti, typ vzdělání, interpersonální dovednosti. Z praxe tedy vyplývá potřeba vícefaktorového přístupu namísto spoléhání se na jediný faktický údaj.

- **Využití výsledků při plánování profesního rozvoje**

Identifikované faktory mohou sloužit jako vodítko pro tvorbu vzdělávacích programů, plánů profesního růstu či školení. Zaměření na oblasti, které vycházejí jako samostatné latentní dimenze, umožňuje cílenější intervence a podporu v konkrétních kompetencích.

- **Doporučení pro úpravu či další vývoj nástroje**

Některé položky s nižšími communalitami by mohly být přeformulovány nebo doplněny novými, aby lépe zachycovaly zamýšlený konstrukt. To může zvýšit přesnost měření a posílit psychometrické vlastnosti dotazníku v budoucích šetřeních.

- **Podpora evidence-based rozhodování**

Výsledky poskytují statisticky podložený základ pro to, aby rozhodovací procesy v organizacích nebyly intuitivní, ale aby vycházely z validních dat a ověřených konstrukcí. Správné využití měřicího nástroje tak může přispět k efektivnějšímu a spravedlivějšímu hodnocení pracovníků.

Bibliografie

- Bommasani, R.; D. A. Hudson; E. Adeli; R. Altman; S. Arora a kol. (2021). *On the Opportunities and Risks of Foundation Models*. Online. 2021. arXiv. Dostupné z: <https://doi.org/10.48550/arXiv.2108.07258>

- Brdička, B. (2024). *Pedagogika nejistoty v éře AI*. Online. Praha: Národní pedagogický institut ČR, 2024. [citováno 2025-11-12]. Dostupné z: <https://digitalizace.rvp.cz/files/pedagogika-nejistoty-v-ere-ai-11.pdf>
- Dearing, J. W. (2009). *Applying Diffusion of Innovation Theory to Intervention Development*. *Research on Social Work Practice*. Online. 19(5), 503–518. Dostupné z: <https://doi.org/10.1177/1049731509335569>
- Kasneci, E.; K. Sessler; S. Küchemann; M. Bannert; D. Dementieva a kol. (2023). *ChatGPT for good? On opportunities and challenges of large language models for education*. *Learning and Individual Differences*. Online. 103, 102274. Dostupné z: <https://doi.org/10.1016/j.lindif.2023.102274>
- Círus, L. (2017). *Vliv učitele na formování digitální gramotnosti žáků 1. stupně základní školy*. Hradec Králové. Disertační práce. Univerzita Hradec Králové. Pedagogická fakulta.
- Círus, L.; M. Maněnová a J. Škoda. (2019). *Teachers' attitudes towards ICT and their reflection in the pupils' digital literacy*. Ústí nad Labem: Educa PF UJEP. ISBN 978-80-7561-191-8.
- Kopecký, K.; R. Sztokowski; D. Voráč; V. Krejčí a P. Dobešová. (2023). *České školy a umělá inteligence*. Online. Olomouc: Pedagogická fakulta Univerzity Palackého v Olomouci, 2023. [citováno 2025-11-12]. Dostupné z: [researchgate.net/publication/374133351_Ceske_skoly_a_umela_inteligence_-_vyzkumna_zprava](https://www.researchgate.net/publication/374133351_Ceske_skoly_a_umela_inteligence_-_vyzkumna_zprava)
- Miao, F. a W. Holmes. (2023). *Guidance for generative AI in education and research*. Online. 2023. UNESCO. Dostupné z: <https://doi.org/10.54675/EWZM9535>
- Russell, S. J. a P. Norvig. (2021). *Artificial intelligence: a modern approach*. Fourth edition. Pearson. ISBN 978-0-13-461099-3.
- Vaswani, A.; N. Shazeer; N. Parmar; J. Uszkoreit; L. Jones; A. N. Gomez; L. Kaiser a I. Polosukhin. (2017). *Attention Is All You Need*. Online. 2017. arXiv. Dostupné z: <https://doi.org/10.48550/arXiv.1706.03762>

Mgr. Petr Gonda

Ústav primární, preprimární a speciální pedagogiky
Univerzita Hradec Králové, Pedagogická fakulta, Česká republika
Rokitanského 62, 500 03, Hradec Králové, Česká republika
petr.gonda@uhk.cz

Doc. PaedDr. Martina Maněnová, PhD.

Ústav primární, preprimární a speciální pedagogiky
Univerzita Hradec Králové, Pedagogická fakulta
Rokitanského 62, 500 03, Hradec Králové, Česká republika
martina.manenova@uhk.cz