STUDIA PAEDAGOGICA

Ročník 31, číslo 1, 2026
https://doi.org/10.5817/SP2026-1-6

ZAČÍNAJÍCÍ VÝZKUMNÍCI

UMĚLÁ INTELIGENCE JAKO PODPORA INDIVIDUALIZACE VÝUKY V ZÁKLADNÍM VZDĚLÁVÁNÍ (ISCED 1–2): SCOPING REVIEW

ARTIFICIAL INTELLIGENCE AS A SUPPORT FOR INSTRUCTIONAL INDIVIDUALIZATION IN PRIMARY AND LOWER SECONDARY EDUCATION (ISCED 1–2): A SCOPING REVIEW

Michal Hanzl[a], Martin Dosedla[a], Karel Picka[a]

[a] Pedagogická fakulta, Masarykova univerzita

ABSTRAKT

Cílem této scoping review je systematicky zmapovat, jak současné empirické studie popisují využití umělé inteligence (AI) k podpoře individualizace, personalizace a adaptivního učení na úrovni základního vzdělávání (ISCED 1–2) se zvláštním důrazem na generativní AI. Jedná se o scoping review zpracované v souladu s doporučeními PRISMA-ScR. Vyhledávání proběhlo v databázích Scopus, Web of Science, ERIC a IEEE Xplore, doplněných o Google Scholar a ruční dohledávání. Kritéria způsobilosti byla vymezena rámcem populace, konceptu a kontextu (PCC). Dva nezávislí hodnotitelé provedli screening 412 záznamů; do syntézy bylo zařazeno 11 studií. Napříč souborem studií se opakovaly tři mechanismy AI-podporované individualizace: průběžná diagnostika/monitorování, adaptivní úprava obsahu či postupu a přizpůsobená zpětná vazba (scaffolding). Studie vykazují převážně neutrální až pozitivní dopady na kognitivní výsledky a nezaznamenaly zhoršení výkonu vůči běžné výuce; afektivní a behaviorální výstupy jsou smíšené a metodologicky různorodé. Přínos generativní AI je podmíněn didaktickým zarámováním, aktivním vedením a supervizí učitele. Mezi identifikovaná rizika patří podvádění a faktické nepřesnosti výstupů, přičemž zjištění zároveň zdůrazňují potřebu jasných pravidel používání. Dosavadní poznatky vyznívají slibně, jsou však zatím neúplné. Klíčovou podmínkou smysluplného učení zůstává aktivní role učitele.

KLÍČOVÁ SLOVA

umělá inteligence; individualizace výuky; adaptivní učení; generativní umělá inteligence; základní vzdělávání

ABSTRACT

The aim of this scoping review is to systematically map how current empirical studies describe the use of artificial intelligence (AI) to support individualization, personalization, and adaptive learning in primary and lower secondary education (ISCED 1–2) with a particular focus on generative AI. Reported in accordance with PRISMA-ScR, we searched Scopus, Web of Science, ERIC, and IEEE Xplore, supplemented by Google Scholar and manual reference/citation tracking. Eligibility criteria were operationalized using the Population, Concept, and Context (PCC) framework. Two independent reviewers screened 412 records; 11 studies were included in the synthesis. Across the included studies, three recurring mechanisms of AI-supported individualization were identified: ongoing diagnosis/monitoring, adaptive adjustment of content or learning pathways, and tailored feedback and scaffolding. The included studies reported mostly neutral to positive effects on cognitive outcomes and did not document performance deterioration compared with usual instruction; affective and behavioral outcomes were mixed and methodologically heterogeneous. For generative AI, benefits were contingent on instructional framing, active teacher guidance, and ongoing supervision. Reported risks included cheating and factual inaccuracies in outputs, while the findings also highlighted the need for clear rules governing responsible use. Overall, evidence is promising but still incomplete, and meaningful learning remains critically dependent on the active role of the teacher.

KEYWORDS

artificial intelligence; instructional individualization; adaptive learning; generative artificial intelligence; primary and lower secondary education

KORESPONDUJÍCÍ AUTOR

Michal Hanzl, Pedagogická fakulta, Masarykova univerzita, Poříčí 7, 603 00 Brno
e-mail: 481198@muni.cz

Úvod

Základní vzdělávání (ISCED 1–2) čelí rostoucí poptávce po individualizaci výuky v reakci na diverzitu žákovských potřeb (Bartoňová & Vítková, 2019). Zatímco tradiční modely narážejí na kapacitní limity učitelů, nástroje umělé inteligence (AI) – včetně generativních modelů (LLM) – nabízejí možnost přizpůsobovat obsah i zpětnou vazbu ve větším měřítku (UNESCO, 2021).

Nástup generativní AI a nástrojů jako ChatGPT zintenzivnil diskuse o roli technologií ve škole: očekávání personalizace učení se střetávají s požadavky na didaktickou připravenost, etiku a regulaci (Kamalov et al., 2023; UNESCO, 2021). Empirické studie současně naznačují, že AI-podporované personalizované systémy mohou zlepšovat studijní výsledky, zejména u žáků, kteří v tradiční výuce zaostávají (Kamalov et al., 2023; Relmasira et al., 2023).

Využívání AI k individualizaci se v českém základním školství teprve rozvíjí a zůstává roztříštěné: zavádění je nerovnoměrné, převažují dílčí pokusy a chybí důkladné hodnocení dopadů na učení žáků (Kopecký et al., 2023;

NPI, 2024). Analýzy digitalizace školství zároveň poukazují na přetrvávající nejistotu učitelů ohledně přínosů a rizik AI (Hanzl et al., 2025; Kopecký et al., 2023).

Podobná situace platí i v širším evropském kontextu – ačkoli se o AI ve vzdělávání hodně hovoří, empirických studií z prostředí primárního a nižšího sekundárního vzdělávání je omezeně. V širším mezinárodním kontextu přehledové práce konzistentně uvádějí, že AI systémy mohou sloužit jak k automatizaci rutinních pedagogických činností, tak k podpoře individualizace prostřednictvím inteligentních tutorů, adaptivních systémů a rychlé zpětné vazby (Kamalov et al., 2023). Podobně Hardaker a Glenn (2025) syntetizují poznatky o využití AI pro personalizované učení a Hariyanto et al. (2025) se zaměřují na techniky AI v adaptivním vzdělávání. Tyto práce potvrzují rostoucí význam AI pro personalizaci a adaptivitu, avšak jejich záběr je širší než záběr této studie: nejsou primárně vymezeny prostředím základního vzdělávání ISCED 1–2, nekladou hlavní důraz na pedagogické mechanismy individualizace v běžné školní výuce a samostatně nepropojují otázku individualizace s rolí učitele, generativní AI a rozvojem AI gramotnosti žáků. Tato scoping review proto navazuje na existující zahraniční review, ale zužuje jejich obecnější závěry na empirickou evidenci z primárního a nižšího sekundárního vzdělávání a sleduje, jaké konkrétní mechanismy AI-podporované individualizace jsou v tomto kontextu doloženy.

Předkládaná studie si klade za cíl systematicky zmapovat dosavadní stav empirického poznání v oblasti využití umělé inteligence jako nástroje pro individualizaci, personalizaci a adaptivní výuku v prostředí základního vzdělávání (ISCED 1–2). Pozornost je věnována především identifikaci konkrétních způsobů a mechanismů, skrze které AI pedagogický proces individualizace podporuje, a také faktorům, jež úspěšnou integraci těchto technologií podmiňují, a to zejména s ohledem na efektivitu učebního procesu. Vzhledem k dynamickému vývoji technologií a rostoucím nárokům na digitální kompetence se práce zaměřuje rovněž na to, do jaké míry a jakým způsobem se individualizovaná výuka za podpory AI prolíná s paralelním rozvojem AI gramotnosti samotných žáků. Detailní vymezení výzkumného záměru, přesná formulace výzkumných otázek a kritéria systematického výběru literárních zdrojů jsou specificky rozpracovány v navazující metodologické části textu.

1 Konceptuální rámec a vymezení pojmů

Pochopení dopadů AI na individualizaci vyžaduje terminologicky odlišit pedagogický cíl (individualizace/personalizace učení) od technologických prostředků, které jej mohou podporovat (adaptivní systémy a generativní AI).

1.1 Umělá inteligence ve vzdělávání a generativní AI založená na velkých jazykových modelech: vymezení přístupu

Umělá inteligence ve vzdělávání (*AI in Education*, AIEd) je interdisciplinární oblast zaměřená na vývoj a využití AI technologií pro podporu učení a výuky (Tapalova & Zhiyenbayeva, 2022; Zafari et al., 2022). V této scoping review chápeme AIEd jako soubor nástrojů schopných analyzovat data o učení žáků a na jejich základě přizpůsobovat výukový obsah, poskytovat zpětnou vazbu nebo podporovat rozhodování učitelů. AIEd zahrnuje např. inteligentní doučovací systémy (Intelligent Tutoring Systems), adaptivní výukové platformy, systémy pro automatizované hodnocení a výukové chatboty. Podle Holmese a Tuomiho (2022) se aplikace AI ve vzdělávání soustřeďují zejména na: (a) individualizaci/adaptivní výuku, (b) automatizaci formativního i sumativního hodnocení, (c) sledování pokroku žáků a predikci výkonu a (d) podporu metakognice a autoregulace. Naše scoping review se primárně zaměřuje na první oblast, avšak v kontextu zmiňuje i související aplikace (např. AI podporující hodnocení či analytiku učení), protože s individualizací často úzce souvisejí.

Generativní AI založená na velkých jazykových modelech (LLM) představuje v rámci AIEd dynamický směr s potenciálem pro konverzační tutoring a adaptaci učebních materiálů. Dosavadní studie naznačují, že dobře navržené konverzační systémy mohou podporovat proces učení žáků i osvojování učiva, avšak účinek je výrazně podmíněn konkrétní podobou intervence a jejím pedagogickým zarámováním (Ahmad et al., 2021; Kamalov et al., 2023; Relmasira et al., 2023). Současně explicitně vymezujeme, že empirická evidence o dopadech generativních modelů na učení žáků, zejména na úrovni základní školy (dále ZŠ), je zatím omezená a závěry mají předběžný charakter. Na úrovni produktových oznámení a webových materiálů poskytovatelů se zároveň objevují režimy deklarovaně zaměřené na podporu učení (např. „Study mode“ a „Guided learning“) (Heymans, 2025; Meares, 2025; OpenAI, 2025). Tyto inovace však samy o sobě nepředstavují empirický důkaz účinnosti. Uvádíme je pouze jako indikátory technologického vývoje a podněty pro další výzkum (zejména na úrovni ZŠ).

1.2 Individualizace, personalizace a adaptivní učení: definice a operacionalizace

Pojmy individualizace, personalizace a adaptivní učení se v literatuře částečně překrývají; pro analytickou jednoznačnost je rozlišujeme následovně:

Individualizace výuky označuje přizpůsobování učiva, metod a tempa konkrétnímu žákovi s ohledem na jeho potřeby a možnosti; v důrazu na plánování a řízení výuky vychází primárně z role učitele (příp. systému), který upravuje podmínky učení pro jednotlivce (Maňák & Švec, 2003; Průcha et al., 2013; Zormanová, 2012).

Personalizace výuky je specifická forma individualizace, v níž je do utváření vzdělávací cesty aktivně zapojen žák (např. volbou témat, tempa či strategií řešení). Tímto krokem se posiluje autonomie a spoluzodpovědnost žáka; v tomto smyslu personalizace doplňuje individualizaci řízenou učitelem (Helus, 2015; Pane et al., 2014; Tomlinson, 2017).

Adaptivní učení označuje technologicky řízenou formu individualizace, v níž se výuka dynamicky přizpůsobuje na základě dat o výkonu žáka pomocí algoritmů v adaptivních výukových systémech (Capuano & Caballé, 2020; Kerr, 2016). Pro účely scoping review platí, že adaptivní systémy poskytují přizpůsobený obsah na základě průběžné diagnostiky, zatímco personalizace v širším smyslu může zahrnovat i volby a cíle žáka, které nejsou plně odvoditelné z výkonových dat.

Individualizaci používáme jako zastřešující koncept pro úpravy výuky „na míru" (učitel, technologie nebo jejich kombinace), **personalizaci** jako zdůraznění aktivní role žáka a **adaptivní učení** jako datově řízené přizpůsobování výuky v reálném čase. Pro úplnost doplňujeme i pojem **diferenciace výuky**, který pracuje s variantami výuky pro typologické skupiny žáků. V praxi se může s individualizací prolínat a tvořit součást inkluzivních strategií (Bartoňová & Vítková, 2019; Simonová et al., 2023).

1.3 Mechanismy individualizace prostřednictvím AI: diagnostika, adaptace, zpětná vazba

Systémy AI mohou umožnit individualizaci a personalizaci výuky novými způsoby ve větším měřítku, než je v běžných podmínkách dostupné pouze prostřednictvím učitele. Ve scoping review vycházíme ze tří opakujících se mechanismů: diagnostiky/monitorování, adaptace a přizpůsobené zpětné vazby.

Diagnostika a průběžné monitorování: AI analyzuje interakční data žáka (odpovědi, čas, chování) a průběžně odhaduje jeho aktuální úroveň znalostí a potřeb (student model) (Luckin et al., 2016). Oproti tradičním postupům může podpořit rychlejší pedagogickou reakci, je-li interpretace výstupů didakticky ukotvena (Kamalov et al., 2023).

Adaptace obsahu a průběhu výuky: Na základě diagnostiky mohou algoritmy upravovat obtížnost, tempo nebo formát učiva a nabízet diferencované aktivity (Ahmad et al., 2021). Tím vzniká individuálně přizpůsobený průběh učení, který umožňuje poskytovat podporu i ve větších třídách (Chen et al., 2020; Luckin et al., 2016).

Přizpůsobená zpětná vazba a nápověda: AI může poskytovat bezprostřední formativní reakce s ohledem na typ chyby a průběh učení. Díky zpracování přirozeného jazyka lze nabídnout vysvětlení a podpůrné vedení (*scaffolding*), které se funkčně přibližuje práci učitele (Huang et al., 2021; Chen et al., 2020; Kamalov et al., 2023).

Propojením těchto mechanismů může AI podporovat efektivitu učení, avšak nenahrazuje učitele; přínos závisí na tom, jak jsou výstupy smysluplně integrovány do výuky (Kamalov et al., 2023).

1.4 Role AI v základním vzdělávání: podpora učení vs. AI gramotnost

Zavádění AI do škol lze nahlížet ze dvou vzájemně se doplňujících hledisek: (a) AI jako nástroj podporující učení a (b) AI jako obsah výuky, tj. rozvoj AI gramotnosti (Park & Kwon, 2024).

V první roli je AI prostředkem pro podporu učení v předmětech a pro zvýšení míry individualizace (např. adaptivní procvičování, rychlá zpětná vazba, identifikace slabých míst) (Kamalov et al., 2023; Kim & Kwon, 2024). Zavádění však musí být rámováno principy inkluze a rovného přístupu, aby technologie nezvyšovala, ale naopak snižovala existující nerovnosti (UNESCO, 2021).

Ve druhé roli se AI stává obsahem vzdělávání: žáci se učí, co AI je, jak funguje a jak s ní kriticky a eticky zacházet (Yim & Su, 2025). AI gramotnost zahrnuje znalosti, dovednosti a postoje pro odpovědné působení ve světě ovlivněném AI včetně orientace v rizicích a etických dilematech (např. soukromí či zkreslení) (U.S. Department of Education, 2025; Langreo, 2025; Lai et al., 2023). Rámcová vodítka současně akcentují uvážlivé užívání AI, porozumění omezením systémů a etické aspekty (Rada Evropské unie, 2025; UNESCO, 2021).

Pro ZŠ z toho plyne potřeba obě role vyvažovat: využívat AI tam, kde podporuje učení, a současně rozvíjet AI gramotnost, aby žáci dokázali nástroje využívat uvážlivě; v obou rovinách zůstává klíčová moderující a hodnotící role učitele (Kim & Kwon, 2024; Khazanchi et al., 2024; Tang et al., 2025).

2 Cíle a metodologie scoping review

Tato kapitola popisuje metodologii scoping review zaměřené na využití umělé inteligence k podpoře individualizace výuky v základním vzdělávání (ISCED 1–2). Zvolený výzkumný design umožňuje systematicky zmapovat typy intervencí, uplatňované mechanismy a podobu dostupných empirických poznatků v metodologicky různorodé oblasti, a proto není cílem odhadovat jednotnou velikost efektu. Transparentnost postupu byla zajištěna prostřednictvím interního metodického protokolu vytvořeného před zahájením hlavních fází vyhledávání a selekce studií. Tento protokol vymezoval postup vyhledávání, kritéria selekce studií a základní rámec extrakce dat; nebyl však preregistrován ani veřejně publikován. Postup review je v rukopisu popsán v souladu s doporučeními PRISMA-ScR (Tricco et al., 2018). Vzhledem

k heterogenitě intervencí a výsledkových měřítek nebyla provedena meta-analýza. Zjištění byla syntetizována narativně a prezentována podle principů SWiM (*Synthesis Without Meta-analysis*; Campbell et al., 2020). Principy SWiM byly využity zejména k tomu, aby bylo zřejmé, podle jakých tematických okruhů byla zjištění seskupena, jak byly porovnávány směry a konzistence výsledků napříč studiemi a jak byla při interpretaci zohledněna metodologická heterogenita zahrnutých výzkumů.

2.1 Cíle, výzkumné otázky a rámec scoping review

Cílem této scoping review je systematicky zmapovat dosavadní empirické studie o využití AI pro individualizaci výuky na úrovni ZŠ (ISCED 1–2). Studie se zaměřuje na následující výzkumné otázky:

- VO1: Jakými způsoby umělá inteligence podporuje individualizaci výuky na úrovni ISCED 1–2?
- VO2: Jaké podmínky, překážky a podpůrné faktory jsou ve studiích uváděny v souvislosti se zaváděním AI pro individualizaci výuky?
- VO3: Jak a v jakém rozsahu se v zahrnutých studiích objevuje téma rozvoje AI gramotnosti žáků?

Primárním souborem studií jsou empirické studie realizované na úrovni ISCED 1–2. U hraničních případů mohou být v odůvodněných situacích zohledněny i studie z blízkých vzdělávacích kontextů, pokud je jejich výukový scénář a zkoumaný mechanismus věcně přenositelný do prostředí ZŠ (např. role učitele při práci žáků s generativní AI). Konceptuální a programové (policy) dokumenty jsou využívány výhradně pro vymezení pojmů a kontextualizaci, nikoli jako součást empirické syntézy výsledků. Vymezení otázek se promítlo do konstrukce vyhledávací strategie i do operacionalizace kritérií způsobilosti a schématu extrakce dat. Tomuto vymezení odpovídal rámec PCC: populaci/účastníky tvořili žáci na úrovni ISCED 1–2 a relevantní aktéři výukového scénáře, konceptem bylo využití AI k individualizaci, personalizaci a adaptivnímu učení a kontextem formální základní vzdělávání včetně hraničních scénářů věcně přenositelných do prostředí ZŠ (Aromataris et al., 2024; Peters et al., 2022).

2.2 Kritéria způsobilosti a vyloučení

Kritéria způsobilosti byla stanovena před zahájením screeningu a následně aplikována konzistentně ve všech fázích selekce. V souladu s metodologií Joanna Briggs Institute (JBI) pro scoping review byla operacionalizována rámcem PCC, který lépe odpovídá mapujícímu charakteru scoping review a umožňuje transparentně vymezit, koho se týká, jaký je jeho hlavní zkoumaný koncept a v jakém vzdělávacím kontextu jsou zdroje posuzovány (Aromataris et al., 2024; Peters et al., 2022).

Do empirického přehledu studií určeného pro extrakci dat a syntézu výsledků byly zařazeny studie, které splňovaly všechna následující kritéria:

- **P (populace/účastníci):** Hlavními účastníky byli žáci na úrovni základního vzdělávání a/nebo aktéři bezprostředně zapojení do AI-podporované individualizace na této úrovni, zejména učitelé.
- **C (koncept):** Studie se týkala využití AI přímo ve výuce nebo v procesu učení a tato role byla explicitně spojena s individualizací, personalizací nebo adaptivním učením; popis umožňoval identifikovat typ AI a způsob její integrace do výukového scénáře (např. adaptivní systém, inteligentní tutor, chatbot/LLM, robot, analytický nástroj) i alespoň jeden mechanismus relevantní k individualizaci (např. diagnostika/monitorování, adaptace obsahu či obtížnosti, přizpůsobená zpětná vazba, nápověda/scaffolding, doporučování úloh).
- **C (kontext):** Studie byla realizována v prostředí ISCED 1–2 (případně ekvivalentních ročnících či věku) a cílovou vzdělávací úroveň bylo možné jednoznačně určit; v odůvodněných hraničních případech mimo ISCED 1–2 mohla být studie zahrnuta pouze tehdy, pokud byl výukový scénář věcně přenositelný do kontextu ZŠ (tj. shoda aktéra práce s AI, organizační formy práce, typu úloh a míry pedagogického vedení).

Zařazeny byly pouze empirické studie, například randomizované kontrolované studie (RCT), kvaziexperimentální studie, výzkumy založené na designu (DBR), případové studie s empirickými daty a průřezové studie, které vedle shody s PCC poskytovaly data relevantní k výzkumným otázkám scoping review a měly jasně popsán vzdělávací scénář, vzorek, průběh využití AI a způsob vyhodnocení. Z hlediska typu dokumentu byly primárně zahrnuty recenzované časopisecké články a recenzované konferenční příspěvky; výjimečně také odborné zprávy či kapitoly, pokud obsahovaly empirická data a poskytovaly dostatečný metodický popis.

Z výběru byly vyloučeny studie, které nesplnily alespoň jednu z výše uvedených podmínek, zejména pokud: (a) nebyly realizovány na cílové úrovni ISCED 1–2 a současně nesplnily rozhodovací pravidlo přenositelnosti, (b) neobsahovaly jasný popis využití AI ve výuce nebo učení, (c) neprokazovaly přímou vazbu mezi AI a individualizací, personalizací či adaptivním učením, (d) neposkytovaly empirická data relevantní k výzkumným otázkám nebo byl jejich metodický popis nedostatečný pro posouzení způsobilosti nebo (e) šlo o duplicity či studie bez dostupného plného textu. Texty bez empirických dat (teoretické, konceptuální, názorové či programové dokumenty) nebyly součástí empirického souboru studií a sloužily pouze ke kontextualizaci pojmů.

2.3 Zdroje a postup identifikace studií

Za účelem pokrytí pedagogicky i technologicky orientované literatury bylo vyhledávání realizováno v databázích Scopus, Web of Science, ERIC a IEEE Xplore. Jako doplňkový zdroj byl využit Google Scholar a dále ruční dohledávání v referencích a citovanosti (revize referencí klíčových článků a revize citujících dokumentů). Dotazy byly iterativně optimalizovány tak, aby vracely relevantní výsledky napříč databázemi, vyhledávání bylo vedeno primárně v angličtině a doplňkově v češtině. Vyhledávací strategie byla odvozena z domén rámce PCC a kombinovala termíny pro populaci/účastníky, zkoumaný koncept a kontext základního vzdělávání (Aromataris et al., 2024; Peters et al., 2022). V databázích bylo identifikováno celkem 296 záznamů (ERIC: 36, Scopus: 76, Web of Science: 122, IEEE Xplore: 62); dalších 116 záznamů bylo dohledáno pomocí Google Scholar a ručního dohledávání v referencích a citovanosti.

Vyhledávací strategie byla operacionalizována jako databázově přizpůsobený soubor dotazů odvozený z rámce PCC. Jádro dotazů kombinovalo termíny pro umělou inteligenci (artificial intelligence, AI, případně generative AI/LLM), pro individualizaci a adaptivní/personalizované učení (individualization, personalization, adaptive learning) a pro cílový vzdělávací kontext (primary education, elementary education, lower secondary education, ISCED 1–2). Syntaxe byla v jednotlivých databázích upravována podle jejich rozhraní a indexačního jazyka. Všechny záznamy byly exportovány do společného úložiště; deduplikace a screening byly provedeny v aplikaci Rayyan (Ouzzani et al., 2016).

2.4 Proces výběru studií

Výběr studií proběhl třístupňovým screeningem (deduplikace, screening názvů/abstraktů, posouzení plných textů) v souladu s doporučeními PRISMA-ScR pro reportování scoping review (Tricco et al., 2018), přičemž počty záznamů v jednotlivých fázích identifikace, screeningu, posouzení způsobilosti a zařazení studií jsou znázorněny pomocí flow diagramu PRISMA 2020 (Page et al., 2021) (Obrázek 1). U hraničních případů mimo ISCED 1–2 bylo uplatněno předem stanovené rozhodovací pravidlo přenositelnosti výukového scénáře. Screening i posouzení plných textů prováděli dva nezávislí hodnotitelé. Před zahájením hlavní selekce byl realizován pilotní screening na podvzorku studií pro sjednocení interpretace kritérií. Neshody byly řešeny odbornou diskusí až do dosažení shody a rozhodnutí na úrovni plných textů byla zaznamenávána včetně důvodů vyloučení.

Z celkového počtu 412 identifikovaných studií bylo po screeningu a posouzení plných textů do finálního souboru zařazeno 11 studií. Při hodnocení způsobilosti plných textů (n = 22) byl nejčastějším důvodem vyloučení

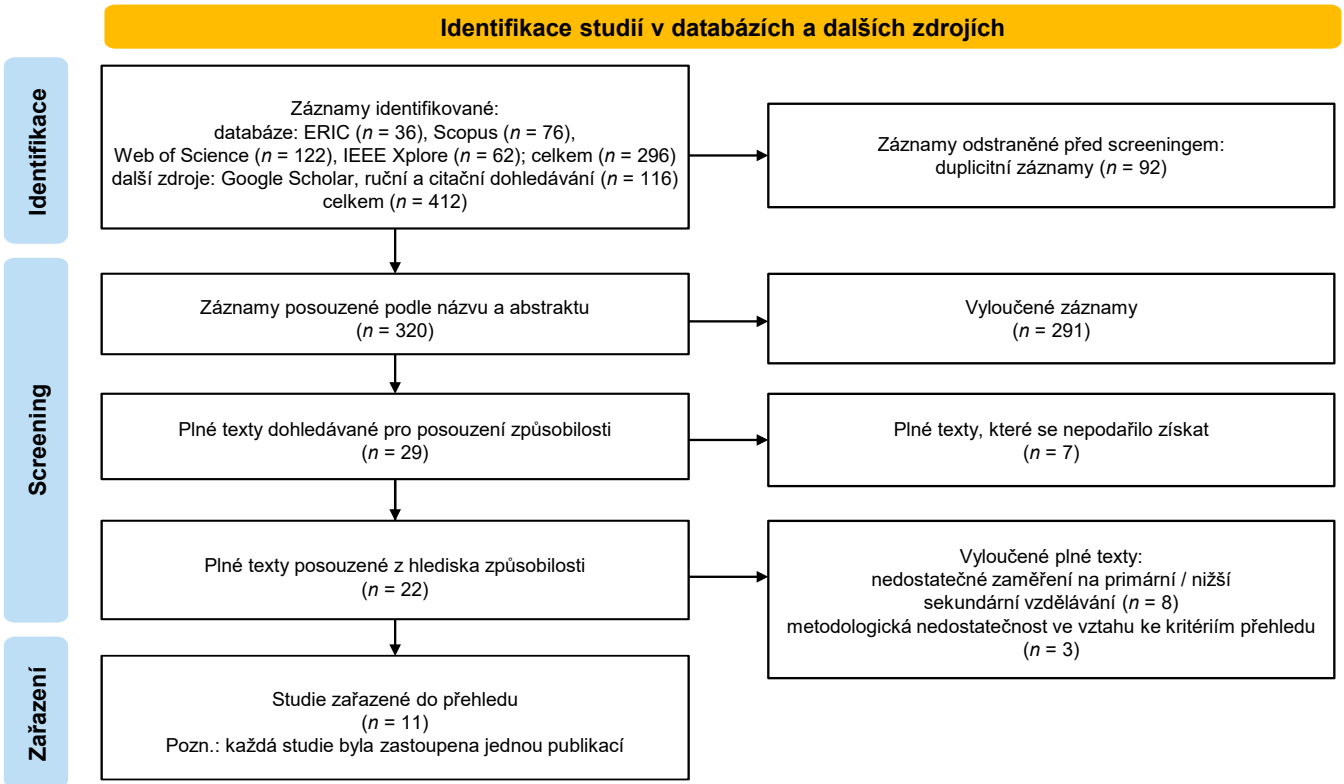

Obrázek 1

Flow diagram průběhu identifikace, screeningu, posouzení způsobilosti a zařazení studií, zpracovaný podle schématu PRISMA 2020 (Page et al., 2021) a reportovaný v kontextu PRISMA-ScR (Tricco et al., 2018)

nesoulad s cílovou úrovní ISCED 1–2 (n = 8). Druhým důvodem byly metodické nedostatky (n = 3), zejména nedostatečný popis výukového scénáře, AI nástroje nebo empirických údajů relevantních k výzkumným otázkám.

Nízký počet zahrnutých studií (n = 11) reflektuje přísná kritéria pro zařazení (zejména důraz na ISCED 1–2 a přímou vazbu na individualizaci) a současně potvrzuje, že navzdory mediálnímu zájmu o AIEd zůstává empirická evidence v prostředí základního školství omezená.

2.5 Extrakce dat

Z každé zařazené studie byly systematicky extrahovány údaje do předem připravené extrakční tabulky (*evidence inventory*; Tabulka 1), aby bylo možné jednotně zachytit charakteristiky studií a intervencí i výsledky relevantní k výzkumným otázkám scoping review. Struktura extrakce navazovala na výzkumné otázky, rámec PCC a metodologická doporučení pro scoping review (Aromataris et al., 2024; Peters et al., 2022). Zaznamenávány byly bibliografické údaje (APA 7, DOI), typ studie, kontext (země, ISCED, předmět a prostředí) a parametry výukového scénáře (organizační forma, typ úloh, míra autonomie žáka a role učitele), charakteristiky AI (typ a role nástroje), metodologické informace (metody a vzorek), měřené výstupy, hlavní zjištění a limity včetně možných rizik zkreslení.

Pokud některá proměnná nebyla ve studii explicitně uvedena, byl údaj v tabulce označen jako „nezjištěno“ a nebyl zahrnován do dílčích agregací vyžadujících danou informaci. Studie se zásadně chybějícími údaji (např. nejasně popsaná intervence nebo chybějící klíčové výsledkové měřítko) byly ponechány v souboru studií pro popis a kvalitativní interpretaci tam, kde to bylo možné, avšak nebyly využity v těch částech analýzy, pro něž byla chybějící informace nezbytná.

Vzhledem k rozsahu extrahovaných údajů je v hlavním textu rukopisu uvedena zkrácená verze přehledu důkazů (evidence inventory), zaměřená na klíčové charakteristiky studií a zjištění relevantní pro výzkumné otázky. Úplná verze je dostupná jako samostatná příloha/datový soubor.

Tabulka 1
Zkrácená souhrnná extrakční tabulka zahrnutých studií

ID	Studie (APA7)	Typ AI	AI nástroj / systém	Hlavní zjištění
S01	Song, X., Mak, J., & Chen, H. (2025). Teachers and learners' perceptions about implementation of AI tools in elementary mathematics classes. *Sage Open*, *15*(2), 1–14. https://doi.org/10.1177/21582440251334545	AI nástroje pro výuku matematiky (obecně „AI tools / AI-powered mathematics tools"	AI-powered mathematics tools	AI nástroje vedly k vyššímu zlepšení výkonu v experimentální skupině než v kontrolní skupině. Učitelé i žáci oceňovali individualizované materiály, okamžitou zpětnou vazbu a interaktivitu, zároveň se objevily technické a etické obavy.
S02	Khazanchi, R., Di Mitri, D., & Drachsler, H. (2024). The effect of AI-based systems on mathematics achievement in rural context: A quantitative study. *Journal of Computer Assisted Learning, 41*, e13098. https://doi.org/10.1111/jcal.13098	adaptivní výukový systém založený na AI (personalizované učební plány, přizpůsobení podle výkonu; diagnostika, kontrola pokroku, zvládnutí látky)	Edmentum Exact Path	Matematické skóre se zlepšilo ve všech skupinách, ale mezi skupinami nebyl významný rozdíl ve výkonu. Kontrolní výuka vedená učitelem vykázala vyšší afektivní zapojení; kognitivní zapojení se nelišilo.
S03	Tang, Q., Deng, W., Huang, Y., Wang, S., & Zhang, H. (2025). Can generative artificial intelligence be a good teaching assistant?—An empirical analysis based on generative AI-assisted teaching. *Journal of Computer Assisted Learning*, *41*(3), e70027. https://doi.org/10.1111/jcal.70027	Generativní AI (textový dialogový model / chatbot)	SparkDesk (iFlytek) – platforma generativní AI pro vzdělávací scénáře v Číně	GenAI zvýšila spokojenost s učením, ale nejlepší výsledky v zapojení i znalostech měla varianta s učitelským dohledem. Varianta s GenAI bez dohledu dosáhla v oblasti znalostí horších výsledků než tradiční výuka.

S04	Maaz, N., Mounsef, J., & Maalouf, N. (2025). CARE: Towards customized assistive robot-based education. *Frontiers in Robotics and AI*, *12*, 1474741. https://doi.org/10.3389/frobt.2025.1474741	Sociální asistenční robot (robotický tutor) + strojové učení pro adaptaci (klasifikace úrovně) + rozpoznávání emocí z obličeje (analýza mimiky)	Systém CARE na robotu Duet (Marses Robotic Solutions) + ROS2; rozpoznání tváře (OpenCV), analýza mimiky (CNN VGG13), klasifikace úrovně (XGBoost).	Skupina s personalizovaným robotem dosáhla vyššího post-diagnostického zlepšení než kontrolní skupina. Systém přesně predikoval úroveň žáků a pozorování naznačilo vyšší zapojení i zájem o matematiku.
S05	Jauhiainen, J. S., & Garagorry Guerra, A. G. (2024). Generative AI and ChatGPT in school children's education: Evidence from a school lesson. *Sustainability*, *15*(18), 14025. https://doi.org/10.3390/su151814025	Generativní AI / LLM (ChatGPT-3.5; zmiňováno i ChatGPT-4) + generování obrázků (Midjourney)	Digileac platform (test prostředí); ChatGPT-3.5 jako hlavní generativní nástroj; ChatGPT-4 použito pro adaptaci textu/otázek; Midjourney pro ilustrace	ChatGPT umožnil tvorbu diferencovaných/personalizovaných materiálů pro různé úrovně. Žáci vykazovali spíše pozitivní vnímané učení a radost z učení; výsledky zároveň naznačily vztah mezi učením, zájmem a pozitivním prožitkem..
S06	Liao, X., Zhang, X., Wang, Z., & Luo, H. (2024). Design and implementation of an AI-enabled visual report tool as formative assessment to promote learning achievement and self-regulated learning: An experimental study. *British Journal of Educational Technology*, *55*(3), 1253–1276. https://doi.org/10.1111/bjet.13424	AI pro formativní hodnocení: zpracování testových dat + kognitivní diagnostika + vizualizace	„AI-enabled visual report tool". Použité komponenty/techniky: kognitivně-diagnostický model NeuralCD, NLP + BM25 pro lokalizaci chyb, vizualizace přes PyEchart	Intervence vedla k rozdílnému průběhu změn výkonu mezi skupinami; obě skupiny se v čase zlepšily. Nejvýraznějším efektem byl růst self-efficacy; žáci zároveň vizuální přehled výsledků hodnotili pozitivně.
S07	Ravindiran, E., & Ramani, P. (2025). Revolutionizing primary education with AI: Advancing teaching and learning through smart technologies. *International Journal for Multidisciplinary Research*, *7*(2), 1–14. https://doi.org/10.36948/ijfmr.2025.v07i02.42369	„AI-powered tools" ve školách (kategorie nástrojů: ITS, adaptivní platformy, chatboty atd.)	Nejsou přesně určeny – ITS, chatbots, AI assistant atd…	AI skupina dosáhla výrazně vyšších hodnot v zapojení, retenci, výsledcích učení i snížení pracovní zátěže učitele. Kvalitativně byly zdůrazněny časová úspora, diferenciace a potřeba školení; u mladších žáků se objevily obtíže s autonomním používáním.

S08	Deveci Topal, A., Dilek Eren, C., & Kolburan Geçer, A. (2021). Chatbot application in a 5th grade science course. *Education and Information Technologies*, *26*, 6241–6265. https://doi.org/10.1007/s10639-021-10627-8	AI chatbot (NLP; dialogový systém)	Chatbot postavený na Google Dialogflow + nasazení přes Telegram; název aplikace „Fenbotum (My sciencebot)"; doplněno o videa/simulace z webu	Mezi skupinami nebyl ve výkonu statisticky významný rozdíl, v experimentální skupině však mezi pretestem a posttestem došlo k významnému zlepšení. Žáci hodnotili chatbot jako užitečný a zábavný; slabinou byly opožděné či nekonzistentní odpovědi.
S09	Chen, C.-H., & Chang, C.-L. (2024). Effectiveness of AI-assisted game-based learning on science learning outcomes, intrinsic motivation, cognitive load, and learning behavior. *Education and Information Technologies*, *29*, 18621–18642. https://doi.org/10.1007/s10639-024-12553-x	GenAI/LLM (ChatGPT) + AI asistence ve hře; hra má i prvky adaptace/ scaffoldingu	Digitální hra Summon of Magicrystal + integrovaný ChatGPT (GPT-3.5-turbo API)	GameGPT s příklady vedl po kontrole pretestu k vyšším výsledkům než hra bez GPT. Varianty GPT zvýšily vnímanou kompetenci a snížily kognitivní zátěž; příklady podporovaly relevantnější dotazování a systematičtější řešení.
S10	Kosmas, P., Nisiforou, E. A., Kounnapi, E., Sophocleous, S., & Theophanous, G. (2025). Integrating artificial intelligence in literacy lessons for elementary classrooms: A co-design approach. *Education Technology Research and Development*, *73*, 2589–2615. https://doi.org/10.1007/s11423-025-10492-z	Převážně generativní AI pro text (ChatGPT, Gemini) + generativní nástroje pro obraz/video	ChatGPT, Gemini (text); Copilot, Ideogram, Muse.ai (obraz); VideoGen, Fliki, Invideo AI (video)	Co-design AI aktivit posílil u učitelů spolupráci, pocit vlastnictví a profesní rozvoj, zároveň však ukázal potřebu lepší přípravy a AI tréninku. Žáci vykazovali vysoký zájem, ale naráželi na technické problémy a obtíže při používání nástroje.
S11	Feng, Y., & Wang, X. (2023). A comparative study on the development of Chinese and English abilities of Chinese primary school students through two bilingual reading modes: Human-AI robot interaction and paper books. *Frontiers in Psychology, 14*, 1200675. https://doi.org/10.3389/fpsyg.2023.1200675	Edukační AI robot (human–AI robot interaction) s interaktivními funkcemi (touchscreen/hlas, překlad, čtení nahlas, skórování a korekce výslovnosti	Edukační AI robot + audio elektronická obrázková kniha + čtení založené na hře s postavami	AI-robotický režim čtení překonal papírové knihy v motivaci, porozumění, samostatném učení, výslovnosti i testových výsledcích. Efekt byl připisován zejména režimu čtení, materiálům a nástrojům; akceptace žáků, rodičů i učitelů byla vysoká.

2.6 Analytický postup a syntéza

Analýza kombinovala deskriptivní mapování souboru studií a tematickou narativní syntézu. V první fázi byly studie shrnuty pomocí proměnných z extrakční tabulky (viz kap. 2.5) pro popis struktury souboru studií (např. typ AI nástroje, design studie, délka a forma intervence). Ve druhé fázi proběhla tematická syntéza založená na kódovacím rámci odvozeném z výzkumných otázek, konceptuálního rámce a dimenzí PCC, který byl průběžně zpřesňován. Kódovací rámec zahrnoval populaci/účastníky, zkoumaný koncept, kontext výukového scénáře a průřezovou oblast rizik a opatření k jejich zmírnění. Vzhledem k heterogenitě intervencí a výsledkových měřítek byla zvolena narativní syntéza bez metaanalýzy, přičemž prezentace výsledků vycházela z principů Synthesis Without Meta-analysis (SWiM; Campbell et al., 2020).

2.7 Posouzení kvality a síly evidence

Kvalita jednotlivých studií byla posuzována jako podpůrný krok pro interpretaci výsledků, nikoli jako dodatečný filtr pro vyřazování již zařazených zdrojů. U každé studie byly zhodnoceny klíčové metodické aspekty ovlivňující důvěryhodnost závěrů: popis intervence a výukového scénáře, adekvátnost výběru vzorku, vhodnost a popis měření, způsob vyhodnocení dat a úplnost reportování výsledků včetně limitací. Výstupy posouzení byly zaznamenány v extrakční tabulce a využity při syntéze tak, že interpretace zjištění byla vážena podle metodické přesvědčivosti podkladových studií. Síla a omezení evidence byla následně shrnuta narativně s ohledem na robustnost designů, konzistenci zjištění a míru přímé relevance k individualizaci výuky na úrovni ISCED 1–2.

Pro kritické hodnocení randomizovaných, kvaziexperimentálních a kvalitativních studií byly podle typu designu použity odpovídající kontrolní seznamy JBI (Aromataris et al., 2024). Jednotlivé položky byly posuzovány samostatně a závěry z hodnocení byly shrnuty deskriptivně pro účely interpretace síly evidence; hodnocení nesloužilo k vyloučení studií.

3 Výsledky

Tato kapitola prezentuje výsledky scoping review a navazuje na metodologický postup popsaný v kapitole 2. Výsledky vycházejí z finálního souboru zahrnutých studií ($n = 11$) a jsou uspořádány tak, aby odpovídaly výzkumným otázkám.

3.1 Přehled zahrnutých studií

Finální soubor studií je geograficky i metodologicky heterogenní, což odráží ranou a stále se formující fázi využívání AI v primárním a nižším sekundárním vzdělávání v letech 2021–2025. Zahrnuté studie se soustředí na úroveň

ISCED 1–2 (častěji na nižší sekundární stupeň) a tematicky pokrývají zejména matematiku s využitím adaptivních systémů. Zastoupeny jsou však i přírodovědné předměty, jazyková gramotnost, dějepis a informatika. Rozptyl naznačuje, že individualizační potenciál AI je v dostupné evidenci zkoumán napříč kurikulem, nikoli pouze v technologicky orientovaných předmětech. Zatímco adaptivní systémy v matematice a přírodovědných předmětech vykazují v analyzovaných studiích relativně stabilní kognitivní přínosy, generativní AI se v souboru studií objevuje spíše jako flexibilní nástroj pro adaptaci a tvorbu diferencovaných učebních materiálů. Její skutečný účinek na učení však podle dostupných poznatků zásadně závisí na kvalitě didaktického začlenění do výuky a míře aktivního vedení učitele (Khazanchi et al., 2024; Maaz et al., 2025; Song et al., 2025; Tang et al., 2025).

3.2 Typy studií a výzkumné designy

Metodologicky jde o heterogenní soubor studií kombinující experimentální a kvaziexperimentální intervence s kvalitativními a smíšenými designy. Převládají kontrolované intervenční studie realizované v běžných školních podmínkách – od randomizovaného experimentu s více podmínkami (Chen & Chang, 2024) po kvaziexperimenty ověřující účinnost adaptivních systémů a GenAI-asistované výuky (Khazanchi et al., 2024; Tang et al., 2025). Soubor studií dále zahrnuje smíšeně-metodologické mapování implementace a percepcí (Song et al., 2025) a návrhově orientované přístupy typu co-design / případová studie, kde učitelé s výzkumníky společně vytvářejí a pilotně ověřují AI-integrované lekce (Jauhiainen & Garagorry Guerra, 2024; Kosmas et al., 2025). V menší míře se objevují i komparativní studie různých výukových režimů, např. porovnání čtení s AI robotem a práce s tištěnými materiály (Feng & Wang, 2023).

Podpůrné kritické hodnocení tuto heterogenitu potvrzuje: metodicky přesvědčivější oporu poskytují zejména kontrolované intervenční studie s jasně popsaným výukovým scénářem a měřením výkonu, zatímco část pilotních, co-designových a kvalitativně orientovaných studií přináší spíše kontextové poznatky o proveditelnosti, percepcích aktérů a didaktickém ukotvení využití AI. Tomu odpovídá i opatrnost při interpretaci síly evidence v následujících podkapitolách.

Intervence se liší délkou (od jednorázových lekcí po vícetýdenní a delší implementace) i intenzitou začlenění AI (od cíleného obohacení konkrétní aktivity po pravidelné používání v běžné výuce) (Feng & Wang, 2023; Jauhiainen & Garagorry Guerra, 2024; Liao et al., 2024; Tang et al., 2025). AI je využívána jak prostřednictvím softwarových nástrojů, například adaptivních systémů, chatbotů a velkých jazykových modelů, tak ve fyzické podobě robotického tutora. To ukazuje, že výzkum v primárním a nižším sekundárním vzdělávání stále ověřuje různé role AI a scénáře jejího využití.

3.3 Role AI ve vzdělávání na úrovni ZŠ

Zahrnuté studie ukazují dvě komplementární role AI v základním vzdělávání: (1) AI jako didaktický nástroj podporující učení v různých předmětech prostřednictvím adaptace a interaktivní podpory a (2) AI jako obsah výuky zaměřený na rozvoj AI gramotnosti. V souboru studií převažují intervence v první roli, zatímco druhá role je zastoupena omezeně a ve studiích se objevuje spíše jako doprovodný cíl či rámování (Deveci Topal et al., 2021; Feng & Wang, 2023; Khazanchi et al., 2024).

AI jako obsah výuky je reprezentována zejména návrhově orientovanými pilotními studiemi: Kosmas et al. (2025) popisují spolupráci učitelů a výzkumníků při tvorbě lekcí pro primární vzdělávání, v nichž AI podporuje práci s textem (např. generováním obrazových podnětů) a je doprovázena reflexí toho, co o AI žáci vědí a jak ji mohou smysluplně využít.

Obě role se mohou prolínat: v uruguayské studii žáci pracovali s materiály upravenými pomocí generativní AI (GenAI, ChatGPT, DALL·E), což současně podpořilo učení v dějepisu a umožnilo prakticky reflektovat možnosti a limity těchto nástrojů (Jauhiainen & Garagorry Guerra, 2024). Autoři upozorňují, že atraktivita aktivity není automatickým efektem technologie, ale výsledkem didaktického strukturování a vedení práce s AI. V souladu se zjištěními Tang et al. (2025) se přínosy GenAI pravděpodobněji projeví, je-li její využití ve třídě rámováno učitelem a směřuje k aktivnímu zpracování učiva a kritickému ověřování výstupů. Evidence k výuce AI gramotnosti na ZŠ zůstává omezená a opírá se převážně o ojedinělé pilotní studie a koncepční či doporučující dokumenty (UNESCO, 2021).

3.4 Mechanismy individualizace

Napříč souborem studií se individualizační podpora AI nejčastěji realizuje jako propojená „učební smyčka" tří funkcí: (1) průběžná diagnostika/monitorování, (2) adaptivní úprava obsahu nebo postupu a (3) přizpůsobená zpětná vazba a nápověda (*scaffolding*). Většina intervencí tyto složky kombinuje, a proto jen výjimečně umožňuje odděleně posoudit přínos jednotlivých mechanismů.

Role učitele (zejména u GenAI) se ukazuje jako průřezová podmínka účinku. Tang et al. (2025) naznačují, že samotná dostupnost ChatGPT bez aktivního vedení nezaručuje lepší výsledky, zatímco při učitelském dohledu roste jak znalostní zisk, tak zapojení žáků. GenAI se tak v souboru studií jeví spíše jako nástroj, který zesiluje kvalitu výuky tehdy, když učitel nastaví cíle, pravidla práce a způsoby ověřování výstupů (Tang et al., 2025).

Diagnostika a monitorování: Systémy průběžně sbírají procesní data o práci žáka (např. správnost, čas, postup) a odvozují z nich indikátory zvládnutí a potřeby podpory; tyto informace mohou být dostupné i učiteli. Např. Edmentum Exact Path propojuje diagnostické posouzení s přehledy o zvládnutí a postupu žáků (Khazanchi et al., 2024).

Adaptivní přizpůsobení obsahu a postupu: Na diagnostiku navazuje úprava obtížnosti, tempa, sekvence aktivit nebo míry podpory tak, aby odpovídala aktuální úrovni žáka. V některých scénářích byla generativní AI využita k rychlé přípravě více úrovní vysvětlení a úloh pro různorodé potřeby žáků v jedné třídě (Jauhiainen & Garagorry Guerra, 2024).

Přizpůsobená zpětná vazba a vedení: AI poskytuje formativní reakce „krok po kroku" (vyhodnocení odpovědi, nápověda, doplňující vysvětlení), v některých řešeních i dialogicky. Ve výukové hře s podporou ChatGPT mohli žáci získávat doplňující příklady a vysvětlení během řešení, což autoři spojují s lepšími výsledky a nižší kognitivní zátěží (Chen & Chang, 2024).

3.5 Dopady na žáky: kognitivní výsledky (výkon, znalosti, učení)

Analyzované studie uvádějí kognitivní efekty v rozmezí od neutrálních po pozitivní, přičemž studie s kontrolní podmínkou neprokázaly zhoršení výkonu. Pozitivní výsledky se objevují v různých předmětech i typech AI podpory. V experimentu s game-based učením ve fyzice žáci v AI podmínkách (zejména při podpoře ChatGPT prostřednict-vím příkladů) dosahovali lepších výsledků a uváděli nižší kognitivní zátěž (Chen & Chang, 2024). V přírodovědě byl pozitivní dopad popisován také při využití AI chatbota v 5. ročníku (Deveci Topal et al., 2021). V jazykové oblasti se u programu bilingvního čtení s edukačním robotem objevily příznivější výsledky než při práci s tištěnými materiály (Feng & Wang, 2023). Součástí souboru studií jsou i intervence s robotickým tutorem, v nichž autoři porovnávají vzdělávací výsledky s kontrolní výukou bez této podpory (Maaz et al., 2025).

Současně se objevují studie bez jednoznačného meziskupinového efektu: v rurálním kontextu USA se zlepšily obě skupiny (AI i kontrolní skupina), takže rozdíl mezi nimi nebyl ve všech analýzách průkazný (Khazanchi et al., 2024). Zjištění tak podporují interpretaci, že přínos AI je podmíněn výchozí úrovní výuky, délkou a intenzitou intervence a kvalitou implementace. U generativní AI se navíc opakovaně ukazuje, že přínos není „automatickým" efektem technologie, ale souvisí s didaktickým rámováním, pravidly práce a učitelským dohledem (Jauhiainen & Garagorry Guerra, 2024; Tang et al., 2025).

3.6 Dopady na žáky: afektivní a behaviorální výsledky

Některé studie sledovaly také afektivní a behaviorální ukazatele (zájem o učení, motivaci, vnímanou kompetenci, zapojení do aktivit a aspekty autonomie/autoregulace). Napříč souborem studií se rýsuje spíše příznivý obraz krátkodobých žákovských reakcí na AI-podporované aktivity, avšak efekty nejsou univerzální a bývají zachyceny různorodými přístupy, často prostřednictvím sebeposouzení žáků.

AI-podporované aktivity jsou žáky často hodnoceny jako atraktivní. V lekci, kde generativní AI sloužila k úpravě výukových materiálů, uváděli žáci vysokou míru obliby této formy práce. Pozitivní hodnocení souviselo zejména se zájmem o téma, vnímanou čitelností materiálů a užitečností ilustrací (Jauhiainen & Garagorry Guerra, 2024). V kontrolovaném experimentu s game-based učením byla dostupnost podpory ChatGPT spojena s vyšší vnímanou kompetencí a zájmem o učení a současně s nižší subjektivně vnímanou zátěží (Chen & Chang, 2024). V dlouhodoběji vedeném programu bilingvního čtení žáci v robotické variantě vykazovali příznivější čtenářské návyky a vyšší motivaci ke čtení (Feng & Wang, 2023). V návrhově orientovaných studiích se zároveň ukazuje, že pozitivní zkušenost žáků souvisí s tím, zda je práce s AI zasazena do konkrétní pedagogické činnosti a doprovázena reflexí (Kosmas et al., 2025).

U behaviorálních ukazatelů (zejména u zapojení žáků) se ale ukazuje výrazná závislost na implementaci: samotná přítomnost ChatGPT aktivitu žáků automaticky nezvyšuje a klíčovou proměnnou je učitelský dohled (nastavení pravidel, průběžné usměrňování, práce s ověřováním výstupů), který může zapojení i výsledky učení posilovat (Tang et al., 2025). Některé práce dále naznačují možné přínosy v oblasti autonomie a autoregulace při využití formativní podpory s vizualizovanými výstupy pro sebehodnocení a současně snížení negativních emocí spojených s evaluací (Liao et al., 2024). Celkově je však tato část evidence méně konsolidovaná: indikátory se liší, měření bývá krátkodobé a často založené na sebehodnocení.

3.7 Implementace a akceptace: učitelé, žáci, organizační podmínky

Zavádění AI do výuky na úrovni ISCED 1–2 se v souboru studií jeví jako změna didaktické praxe, podmíněná připraveností učitelů, dostupností infrastruktury a organizačním rámcem školy (Kosmas et al., 2025; Ravindiran & Ramani, 2025; Song et al., 2025). Opakujícím se závěrem je význam „pedagogického zarámování“ AI: schopnosti převést nástroj do smysluplné výukové aktivity, nastavit pravidla práce a průběžně korigovat využití AI tak, aby podporovalo učení, nikoli nahrazovalo klíčové učební činnosti žáka (Kosmas et al., 2025; Tang et al., 2025). U generativní AI je tato podmíněnost obzvlášť zřetelná: přínosy se objevují zejména tehdy, když je práce s výstupy didakticky vedena k porozumění, ověřování a aktivnímu zpracování učiva (Jauhiainen & Garagorry Guerra, 2024; Tang et al., 2025).

Materiální a organizační podmínky se zvýrazňují zejména ve studiích z kontextů s omezenými zdroji nebo u technologicky náročnějších řešení (adaptivní platformy, robotický tutor), kde proveditelnost a škálovatelnost závisí na dostupnosti zařízení, konektivitě a zajištění podpory pro zavedení postupu do každodenní výuky (Khazanchi et al., 2024; Maaz et al., 2025;

Ravindiran & Ramani, 2025). Akceptace žáků bývá vyšší, je-li AI srozumitelně ukotvena v úlohách a poskytuje zjevnou podporu řešení. Současně však atraktivita nástroje sama o sobě nevypovídá o kvalitě učení (Chen & Chang, 2024; Jauhiainen & Garagorry Guerra, 2024).

3.8 Rizika a mitigace reportované ve studiích

Zařazené studie vedle přínosů konzistentně zmiňují rizika, zpravidla preventivně: ochranu dat a soukromí, spolehlivost a ověřitelnost výstupů (zejména u generativní AI), rizika nadměrného spoléhání na AI včetně dopadů na akademickou integritu, férovost, možné zkreslení a technickou robustnost některých řešení (Kosmas et al., 2025; Song et al., 2025). Rizika jsou jen výjimečně dokumentována jako konkrétní incidenty během realizace intervence; častěji jsou rámována jako podmínka odpovědné implementace.

Mitigační strategie se v souboru studií opakují ve čtyřech liniích: (a) institucionálně ukotvená pravidla práce s daty, vymezení odpovědností a dohled nad tím, jak jsou data sbírána a využívána (Kosmas et al., 2025; Ravindiran & Ramani, 2025), (b) učitelská supervize a průběžná kontrola toho, jak se AI podpora ve třídě uplatňuje, včetně korekcí nevhodného či nerovnoměrného využití (Liao et al., 2024; Ravindiran & Ramani, 2025), (c) scénářové či doménové vymezení použití nástroje (např. úzce vymezený chatbot, předem připravené scénáře a typy úloh), které omezuje nekontrolovanou interakci a usnadňuje kontrolu věcné správnosti (Deveci Topal et al., 2021; Tang et al., 2025), (d) odborná kontrola a úprava materiálů vytvořených pomocí AI před jejich použitím ve třídě, která snižuje riziko faktických nepřesností a nevhodnosti obsahu vzhledem k věku žáků (Chen & Chang, 2024; Jauhiainen & Garagorry Guerra, 2024). U nástrojů, které vyhodnocují chování a emoční projevy žáků, autoři upozorňují, že přesnost výsledků závisí na prostředí a průběhu vzájemného působení žáka s nástrojem. Při posuzování účinků je proto nutné jasně popsat technologická omezení těchto nástrojů (Feng & Wang, 2023; Maaz et al., 2025). Napříč studiemi se rizika jeví jako zvládnutelná za předpokladu, že jsou předem ošetřena v návrhu intervence a následně systematicky monitorována.

Zahrnuté studie naznačují, že u generativní AI je mitigace rizik těsně spojena s didaktickým vymezením úloh a s průběžnou kontrolou práce s výstupy. Místo spoléhání na technickou detekci automaticky generovaného textu se ve studiích jako vhodný směr objevují zadání vyžadující kritické posouzení výstupu AI, zdůvodnění postupu řešení a transparentní přiznání použití nástroje. Tento závěr je však třeba chápat jako mapované implementační opatření, nikoli jako empiricky ověřený účinek na rozvoj vyšších kognitivních dovedností nebo akademické integrity.

3.9 Shrnutí síly evidence a identifikace mezer ve výzkumu

Syntéza 11 zahrnutých studií (2021–2025) ukazuje, že evidence o využití AI pro individualizaci výuky na úrovni ISCED 1–2 je metodologicky i obsahově heterogenní. Soubor studií kombinuje kontrolované intervence, krátké pilotáže i návrhově/implementačně orientované práce a liší se délkou intervencí, výukovými scénáři i volbou indikátorů výsledků (Kosmas et al., 2025; Ravindiran & Ramani, 2025; Song et al., 2025). Sílu evidence je proto třeba interpretovat diferencovaně – podle typu nástroje, mechanismu podpory a didaktického zarámování.

Nejpřesvědčivější část zjištění se vztahuje ke kognitivním výstupům, u nichž studie obvykle uvádějí neutrální až pozitivní účinky a žádná z prací neprokázala zhoršení výkonu oproti srovnávací podmínce. Pozitivní nálezy se objevují ve scénářích se strukturovanou podporou učení (např. příklady, nápověda, průběžná zpětná vazba) a/nebo adaptací podle výkonu (Deveci Topal et al., 2021; Feng & Wang, 2023; Chen & Chang, 2024; Maaz et al., 2025). Současně se ale vyskytují studie bez jednoznačného meziskupinového efektu, což naznačuje citlivost výsledků na kontext, délku a kvalitu implementace (Khazanchi et al., 2024).

Z hlediska mechanismů individualizace se napříč studiemi opakuje „učební smyčka" diagnostika/monitorování – adaptace – přizpůsobená zpětná vazba (Chen & Chang, 2024; Khazanchi et al., 2024). Pro interpretaci je podstatné, že tyto složky bývají ve studiích kombinovány do jednoho intervenčního „balíku", a proto je jen výjimečně možné odděleně posoudit přínos jednotlivých komponent.

U afektivních a behaviorálních výstupů (zájem, motivace, vnímaná kompetence, zapojení, autonomie/autoregulace) se rýsuje spíše příznivý obraz krátkodobých reakcí, avšak evidence je méně ucelená: indikátory se liší, měření bývá krátkodobé a často založené na sebehodnocení (Chen & Chang, 2024; Jauhiainen & Garagorry Guerra, 2024). Některé studie naznačují přínosy pro čtenářské návyky a motivaci (Feng & Wang, 2023) či pro autoregulaci v návaznosti na formativní podporu a sebereflexi (Liao et al., 2024), současně však ukazují, že tyto přínosy jsou do značné míry podmíněny způsobem implementace a pedagogickým vedením (Chen & Chang, 2024; Jauhiainen & Garagorry Guerra, 2024; Tang et al., 2025).

Při syntéze je nutné rozlišovat mezi povahou evidence u zavedených adaptivních systémů a u nastupující generativní AI. Zatímco inteligentní doučovací systémy (zejména v matematice) vykazují v souboru studií robustnější kvantitativní data s měřitelnými kognitivními zisky, evidence pro GenAI na úrovni ISCED 1–2 zůstává zatím převážně kvalitativního a exploračního charakteru. Studie v této oblasti (např. Jauhiainen & Garagorry Guerra, 2024; Kosmas et al., 2025) se soustředí primárně na design výukových scénářů, pilotní ověřování proveditelnosti a analýzu percepcí aktérů.

Tento stav odráží ranou fázi zavádění generativní AI do primárního a nižšího sekundárního vzdělávání, kdy se výzkum zaměřuje především na didaktické ukotvení a bezpečnost nástrojů, nikoli na rozsáhlé ověřování jejich příčinných dopadů na výsledky učení.

Generativní AI je v souboru studií zastoupena omezeně, přesto se v dostupných studiích stabilně ukazuje, že její přínos není „automatickým" efektem technologie. Pravděpodobněji se projeví tehdy, když je role nástroje didakticky vymezena a práce s výstupy je vedena k porozumění, ověřování a aktivnímu zpracování učiva (Chen & Chang, 2024; Jauhiainen & Garagorry Guerra, 2024; Tang et al., 2025).

Mezery se nejvíce rýsují ve dvou oblastech. Zaprvé, AI gramotnost je ve studiích často přítomna jen jako rámování nebo doprovodná reflexe; explicitní výukové programy a standardizované měření AI-kompetencí na ISCED 1–2 jsou zastoupeny omezeně (Kosmas et al., 2025). Zadruhé, implementační evidence je převážně popisná: zdůrazňuje význam organizačního rámce školy, infrastruktury a didaktické připravenosti učitelů, ale jen omezeně umožňuje srovnat účinnost různých modelů zavádění a jejich škálovatelnost, zejména u náročnějších řešení (Khazanchi et al., 2024; Maaz et al., 2025; Ravindiran & Ramani, 2025; Song et al., 2025).

V oblasti rizik studie poukazují na několik opakujících se témat, zejména na ochranu dat a soukromí, spolehlivost výstupů, akademickou integritu a technickou spolehlivost. Způsoby zmírňování těchto rizik jsou však většinou formulovány jako obecné principy a doporučené postupy, nikoli jako intervence empiricky ověřené napříč školami (Deveci Topal et al., 2021; Kosmas et al., 2025; Ravindiran & Ramani, 2025; Tang et al., 2025). Tyto limity a implikace dále rozvíjí diskuse.

4 Diskuse

V této kapitole diskutujeme hlavní zjištění scoping review o využití AI pro individualizaci výuky na úrovni primárního a nižšího sekundárního vzdělávání (ISCED 1–2). Diskuse navazuje na výsledky (kap. 3) a zasazuje je do rámce výzkumných otázek VO1–VO3.

4.1 Shrnutí a interpretace hlavních zjištění vůči VO1–VO3

V návaznosti na výsledky se ukazuje, že AI se na úrovni ISCED 1–2 uplatňuje napříč předměty zejména jako nástroj podporující adaptaci učiva, průběžnou zpětnou vazbu a cílenou nápovědu. Přínosy však závisí na didaktickém ukotvení intervence a na způsobu, jakým učitel práci s AI strukturuje a řídí.

VO1 (podoby a mechanismy AI pro individualizaci): Ve vztahu k VO1 bylo identifikováno široké spektrum aplikací – od adaptivních platforem

a doučovacích systémů přes konverzační agenty podporující čtenářství či přírodovědné učení až po generativní AI využitou pro přípravu diferencovaných materiálů (Jauhiainen & Garagorry Guerra, 2024). Interpretace napříč studiemi naznačuje, že individualizace je nejčastěji realizována kombinací tří navzájem provázaných funkcí: (a) průběžné diagnostiky/monitorování, (b) adaptace obsahu nebo míry podpory a (c) okamžité zpětné vazby a nápovědy (Chen et al., 2020; Kamalov et al., 2023). Rovněž však platí, že v reálné praxi se AI uplatňuje spíše jako doplňující opora učitele než jako samostatná náhrada pedagogického vedení.

VO2 (faktory podmiňující úspěšné zavedení): Ve vztahu k VO2 výsledky ukazují, že úspěšná implementace AI je podmíněna kombinací faktorů na úrovni školy i učitele. Na makroúrovni vystupuje dostupnost infrastruktury (zařízení, konektivita) a otázka rovného přístupu. Tam, kde jsou tyto podmínky oslabené, roste riziko, že AI inovace budou selektivně dostupné pouze části škol nebo žáků (Khazanchi et al., 2024; UNESCO, 2021). Na úrovni učitele se jako zásadní jeví profesní připravenost: bez metodické podpory a praktických příkladů zůstává AI pro řadu pedagogů obtížně uchopitelná a využití se omezuje na dílčí, často experimentální pokusy (Zormanová & Vavříková, 2025). Postoje učitelů nejsou apriorně odmítavé; převažuje opatrný zájem a potřeba konkrétních vodítek, jak AI zapojit, aby podporovala cíle výuky a nevytvářela nové problémy v hodnocení či akademické integritě (NPI, 2024; Zormanová & Vavříková, 2025). Významným facilitátorem je rovněž institucionální podpora – tam, kde vedení školy vytváří podmínky pro pilotování (čas, sdílení praxe, jasná pravidla), je zavádění AI realističtější a udržitelnější (Hanzl et al., 2025; Ravindiran & Ramani, 2025).

VO3 (individualizace s AI a rozvoj AI gramotnosti): Ve vztahu k VO3 se ukazuje, že rozvoj AI gramotnosti je v souboru studií přítomen spíše okrajově a často implicitně. Řada studií pracuje s AI jako nástrojem podpory učení, aniž by systematicky rozvíjela porozumění principům AI, jejím limitům a pravidlům bezpečného užívání. Tam, kde se prvky AI gramotnosti objevují, mají typicky podobu doprovodné reflexe práce s nástrojem (např. ověřování výstupů, práce s chybovostí a transparentní přiznání využití AI), nikoli uceleného kurikulárního programu (Jauhiainen & Garagorry Guerra, 2024). Tato disproporce naznačuje, že školní praxe bude pravděpodobně nejprve využívat AI „pro výkon“ (rychlá podpora učení), zatímco AI gramotnost bude vyžadovat cílenější metodické vedení a integraci do kurikula, aby se minimalizovala rizika nesprávného používání. Tento deficit v literatuře otevírá prostor pro český výzkum, který by se měl zaměřit na to, jak „učení s AI” (individualizace) přirozeně transformovat v „učení o AI” (gramotnost) v rámci běžných předmětů.

4.2 Mechanismy individualizace a role učitele

Mechanismy individualizace s podporou AI identifikované ve výsledcích se ve studiích obvykle objevují jako jeden celek propojující diagnostiku, adaptaci a přizpůsobenou zpětnou vazbu, takže je obtížné určit účinek jednotlivých složek (Kamalov et al., 2023). Pro praxi je proto klíčové vnímat účinnost jako výsledek výukového designu a míry učitelské supervize, nikoli jako vlastnost nástroje samotného. Účinnost AI-podporované individualizace se v praxi jeví jako závislá na tom, zda učitel vymezuje cíle a pravidla práce s nástrojem, interpretuje data a cíleně zasahuje do výuky a zároveň záměrně rozvíjí vyšší kognitivní dovednosti tak, aby bránil pasivnímu „outsourcování" práce na AI (Luckin et al., 2016; Tang et al., 2025). Zvláště u generativní AI platí, že samotná dostupnost nástroje automaticky nezaručuje vyšší aktivitu ani lepší výsledky. Klíčová je míra didaktického řízení a průběžného dohledu učitele (Tang et al., 2025).

Vedle výkonových ukazatelů je třeba při interpretaci zachovat i vazbu na afektivní a behaviorální indikátory mapované ve výsledcích. Ty jsou v zahrnutých studiích zachyceny heterogenně a často krátkodobě, proto je nelze použít k silnému závěru o širších psychosociálních dopadech AI. Podporují však opatrný závěr, že AI má ve škole fungovat jako doplňující vrstva podpory, nikoli jako náhrada učitelské práce a pedagogické interakce.

4.3 Dopady na učení a motivaci: přínosy vs. smíšené výsledky a možné vysvětlení heterogenity

Zahrnuté studie naznačují, že AI-podporovaná individualizace může být spojena s neutrálními až pozitivními kognitivními výsledky, zejména ve scénářích se strukturovanou zpětnou vazbou, nápovědou nebo adaptací podle výkonu žáka. V žádné ze zahrnutých studií nebylo nasazení AI spojeno se zhoršením výkonu žáků, současně však nelze z dostupné evidence odvozovat obecný účinek AI napříč předměty a kontexty. Při výuce založené na digitální hře s podporou ChatGPT zaznamenali Chen a Chang (2024) vyšší úspěšnost ve fyzice ve skupině s asistencí chatbota než ve skupině bez podpory AI. V jiných studiích se ale rozdíly mezi AI a kontrolní skupinou neprojevily statisticky významně (Khazanchi et al., 2024; Tang et al., 2025). Smíšené výsledky proto podporují opatrnou interpretaci, že přínos AI závisí na výchozí úrovni výuky, délce intervence, kvalitě implementace a míře pedagogického vedení.

Vedle kognitivních výsledků ovlivňuje AI ve výuce také motivaci a postoje žáků. Většina intervencí uvádí vyšší zájem a zaujetí žáků při využití interaktivních AI prvků; žáci často hodnotí učení s AI jako zábavnější a méně stresující (Jauhiainen & Garagorry Guerra, 2024). Pozitivní vliv bývá spojován s okamžitou zpětnou vazbou a přiměřenou úrovní výzev. Současně je však nutné udržet rovnováhu, aby AI nenahrazovala klíčovou žákovskou

činnost a neoslabovala samostatné myšlení či tvořivost (Kopecký et al., 2023; Zormanová & Vavříková, 2025).

4.4 Zavádění GenAI: překážky, podpora a rizika

Zavádění AI do školní praxe je komplexní změna, která zahrnuje technické, organizační i etické otázky. V této části vycházíme primárně ze syntézy zahrnutých studií v hlavním empirickém souboru studií. Avšak u implementačních bariér a školních pravidel záměrně doplňujeme argumentaci o české kontextové zdroje mimo soubor studií (zejm. národní šetření a metodické zprávy), které lépe zachycují aktuální situaci a obavy aktérů v prostředí ČR (Hanzl et al., 2025; Kopecký et al., 2023; NPI, 2024; Zormanová & Vavříková, 2025). Napříč zdroji se jako opakující překážky ukazují omezené technické zázemí (zařízení, konektivita) a potřeba cíleného profesního rozvoje učitelů (Hanzl et al., 2025; Kopecký et al., 2023; NPI, 2024; Zormanová & Vavříková, 2025). U generativní AI výrazně vystupují obavy z „outsourcování" práce na AI a z věcných nepřesností výstupů, což posiluje důraz na didaktické řízení a ověřování informací (Hanzl et al., 2025; Kopecký et al., 2023; Zormanová & Vavříková, 2025).

Zjištění o významu učitelské supervize a didaktického řízení, která dominují zahraničnímu souboru studií, přímo korespondují s potřebami identifikovanými v českém prostředí. Právě absence konkrétních metodických vodítek v ČR znamená, že analyzovaná empirická evidence může sloužit jako nezbytný základ pro tvorbu lokálních výukových scénářů. Ty by měly učitelům pomoci překonat nejistotu z integrace AI tím, že jasně vymezí momenty, kdy AI podporuje učení a kdy naopak vede k pasivnímu přebírání výsledků.

Za klíčové opatření k omezování těchto rizik se napříč zdroji jeví jasná pravidla používání AI a průběžná pedagogická supervize. Školy by měly explicitně vymezit, kdy je využití AI ve výuce přijatelné, jak má být přiznáno a jaké formy práce jsou naopak nepřípustné, a tato pravidla srozumitelně komunikovat žákům i rodičům (NPI, 2024; Rada Evropské unie, 2025). Reakcí bývá didaktická úprava úloh a hodnocení směrem k zadáním, kde je klíčová osobní zkušenost žáka, práce s vlastními daty nebo obhajoba postupu. Tomu odpovídá i doporučení vést se žáky průběžný dialog o etice, akademické integritě a ověřování výstupů (Zormanová & Vavříková, 2025). Dokumenty vzdělávací politiky současně dokládají, že odpovědnému zavádění AI do škol je věnována stále větší pozornost také na úrovni národních a nadnárodních institucí (Rada Evropské unie, 2025; U.S. Department of Education, 2025).

Vedle bariér jsou patrné i faktory, které adopci usnadňují. Část učitelů má o smysluplné využití AI zájem, ale často postrádá prakticky orientovaná školení, ukázkové lekce a sdílené materiály přenositelné do vlastní výuky

(NPI, 2024; Zormanová & Vavříková, 2025). Podpůrně působí i vedení školy, pokud vytváří prostor pro pilotování, sdílení zkušeností a zajistí základní technické podmínky (Hanzl et al., 2025). Na systémové úrovni je důležité, aby zavádění AI nezvyšovalo nerovnosti a kombinovalo infrastrukturu, profesní rozvoj a opatření pro rovný přístup (Ravindiran & Ramani, 2025; UNESCO, 2021).

Zahrnuté studie ukazují, že individualizace není automatickým důsledkem pouhé přítomnosti technologie ve třídě. Pro český kontext z toho plyne opatrná implikace: technická infrastruktura a konektivita samy o sobě nestačí; účelné zavádění AI vyžaduje současně metodickou podporu učitelů, jasná školní pravidla a prostor pro pedagogicky vedené pilotování.

4.5 Omezení scoping review a doporučení pro výzkum a praxi

Empirické poznatky o využití AI pro individualizaci na úrovni ISCED 1–2 zatím vycházejí z malého počtu studií (n = 11), které jsou metodologicky i obsahově různorodé. Další limitací je absence veřejně dostupného či preregistrovaného protokolu. Ačkoli byl před zahájením screeningu vytvořen interní metodický protokol vyhledávání, selekce studií a extrakce dat, nebyl zveřejněn v žádném registru ani repozitáři. Tato skutečnost částečně omezuje možnost nezávislého ověření původně zamýšleného postupu. Hlavní metodologické kroky jsou však v rukopisu popsány tak, aby bylo možné posoudit transparentnost vyhledávání, selekce, extrakce dat a syntézy. S ohledem na heterogenitu intervencí a výsledkových měřítek byla syntéza vedena narativně bez metaanalýzy, což omezuje možnosti zobecnění. Řada studií má charakter kratších pilotních intervencí a poskytuje jen částečný vhled do dlouhodobých dopadů.

Hlavním omezením je relativně nízký počet zařazených studií. Tento stav je však přímým důsledkem striktní aplikace kritérií způsobilosti vymezených rámcem PCC a požadavkem na explicitní vazbu mezi AI a individualizací výuky v kontextu ISCED 1–2. Při výběru byla vědomě upřednostněna metodická kvalita a věcná relevance před kvantitou heterogenních studií, které často postrádají robustní evaluační data nebo dostatečně popsaný výukový scénář. Většina identifikovaných, leč vyřazených záznamů trpěla buď metodickými nedostatky v popisu intervence, nebo absencí empirických dat relevantních k výzkumným otázkám. Výsledný soubor studií tak sice neaspiruje na vyčerpávající mapování celého technologického trhu, ale poskytuje metodicky podloženou bázi pro analýzu reálných didaktických účinků AI v prostředí ISCED 1–2.

Rychlý vývoj AI zvyšuje riziko rychlé zastaralosti poznatků, zejména v oblasti generativní AI, a nelze vyloučit ani publikační zkreslení. V diskusi byly pro kontextualizaci využity i národní mapovací a metodické zdroje a vybrané politickostrategické dokumenty. Nelze z nich však odvozovat kau-

zální závěry o dopadech na učení (NPI, 2024; Rada Evropské unie, 2025; U.S. Department of Education, 2025). Z uvedených omezení plyne potřeba posunout výzkum od pilotních demonstrací k robustnějším a kontextově citlivým evaluacím.

Závěr

Tato scoping review zmapovala empirickou evidenci k využití umělé inteligence pro individualizaci výuky na úrovni základního vzdělávání (ISCED 1–2) v globálním kontextu se zřetelem k implikacím pro evropské a české prostředí. Na základě narativní syntézy 11 studií publikovaných v letech 2021–2025 lze konstatovat, že dosavadní zjištění vyznívají převážně pozitivně. Množství a přesvědčivost dostupných důkazů se však liší podle typu nástroje, vzdělávací oblasti a výzkumného designu. Nejkonzistentněji se přínosy AI ukazují ve scénářích, kde technologie podporuje průběžnou diagnostiku výkonu, adaptaci obtížnosti a tempa a okamžitou formativní zpětnou vazbu. Klíčovou podmínkou účinnosti přitom zůstává didaktické zarámování a aktivní role učitele. Současně platí, že využívání generativní AI a rozvoj AI gramotnosti v primárním a nižším sekundárním vzdělávání jsou zatím podloženy omezeným počtem studií, často krátkodobých a exploračních. Závěry v těchto oblastech proto mají předběžný charakter.

Odpověď na hlavní otázku: stav evidence o AI pro individualizaci na ZŠ
Dostupná empirická evidence naznačuje, že AI může v prostředí ZŠ podporovat individualizaci výuky zejména prostřednictvím tří propojených mechanismů: (1) průběžné diagnostiky učení a chybovosti, (2) adaptace obsahu či trajektorie učení (obtížnost, tempo, typ podpory) a (3) přizpůsobené zpětné vazby a nápovědy poskytované bezprostředně. Soubor studií zároveň ukazuje potenciál škálovat individuální podporu v situacích, kde běžná výuka naráží na časové a kapacitní limity, avšak síla tohoto závěru se mezi typy nástrojů a výukovými scénáři liší. Na úrovni ISCED 1–2 proto nelze AI chápat jako autonomní řešení individualizace, ale spíše jako nástroj, jehož přínos závisí na kvalitě pedagogického scénáře, jasném nastavení cílů a aktivní roli učitele. Bez tohoto didaktického ukotvení zůstává její přínos nejistý a obtížně zobecnitelný.

Co je nejlépe podložené a co zůstává předběžné
Nejlépe podložená část evidence se vztahuje k adaptivním systémům a inteligentním tutorům zejména v matematice a vybraných přírodovědných a technických předmětech, kde se častěji objevují experimentální či kvaziexperimentální designy a opakovaně se ukazují neutrální až pozitivní do-

pady na výkon. Relativně konzistentní je rovněž zjištění, že okamžitá zpětná vazba a cílené nápovědy představují klíčový mechanismus, jímž se individualizace prostřednictvím AI promítá do učebních výsledků.

Předběžnější charakter má evidence ve třech rovinách. Zaprvé, afektivní a behaviorální dopady (motivace, zapojení, autonomie, autoregulace) jsou často popisovány pozitivně, avšak bývají měřeny heterogenně, spíše krátkodobě a převážně sebehodnocením. Zadruhé, využívání generativní AI v primárním a nižším sekundárním vzdělávání je doloženo menším počtem studií a jeho účinky do značné míry závisejí na úrovni pedagogického vedení. GenAI se jeví jako užitečná tehdy, když je její role didakticky omezena a strukturována tak, aby podporovala porozumění, nikoli nahrazovala žákovu kognitivní práci. Zatřetí, rozvoj AI gramotnosti na ZŠ zůstává empiricky podložen jen omezeně a dosavadní práce mají převážně pilotní či designově orientovaný charakter.

Implikace pro praxi

Pro pedagogickou praxi se jako nejbezpečnější vstupní krok jeví dobře ohraničené scénáře: adaptivní procvičování, formativní zpětná vazba a diferencované nápovědy. V těchto případech lze jasně vymezit cíle učení, sledovat pokrok a současně omezit riziko nežádoucích efektů. Funkční se jeví uspořádání, v němž AI podporuje „mikroúroveň" žákovských činností, zatímco učitel řídí „makroúroveň" výuky: cíle, zadání, společnou reflexi a ověřování porozumění. U generativní AI je na místě řízené zavádění založené na učitelem ověřených materiálech, strukturovaných úlohách, zdůvodňování postupu a průběžném ověřování tvrzení. Součástí implementace má být nastavení školních pravidel používání AI a systematická metodická podpora učitelů zejména v didaktické a etické rovině.

Prioritní směry dalšího výzkumu

Mapování mezer ukazuje čtyři priority pro další výzkum na úrovni ISCED 1–2: (1) longitudinální evaluační studie v běžných školních podmínkách ověřující udržitelnost efektů, (2) systematické testování podmínek účinnosti, zejména role učitele, míry pedagogického vedení a charakteru učebních úloh, (3) výzkum generativní AI ve scénářích relevantních pro ZŠ se zaměřením na efektivitu didaktického redesignu úloh a jeho dopad na porozumění, metakognici a akademickou integritu žáků a (4) empirické ověřování rozvoje AI gramotnosti včetně věkově přiměřených konceptů, účinných postupů a provázání „učení s AI" a „učení o AI" napříč předměty.

Celkově scoping review podporuje závěr, že AI má na úrovni základního vzdělávání reálný potenciál posilovat individualizaci výuky, avšak pouze při odpovědné integraci, v níž učitel zajišťuje pedagogické vedení a činí klíčová didaktická rozhodnutí. Nesystematická adopce bez didaktického ukotvení

pravděpodobně nepřinese stabilní přínosy, zatímco promyšlené scénáře s jasnými cíli, pravidly a průběžným pedagogickým vedením představují realistickou cestu k její smysluplné integraci. Pro výzkum to znamená posun od pilotních demonstrací k robustním a kontextově citlivým evaluacím, které lépe určí, kdy a pro koho AI individualizaci podporuje a za jakých podmínek.

Využití nástrojů AI

Autoři deklarují, že využili AI nástroje (ChatGPT) výhradně pro drobné stylistické úpravy a překlad abstraktu. Současně uvádějí, že využili AI nástroje (např. Elicit, Scite, Google Scholar Labs, ResearchRabbit) k tvorbě výzkumných podnětů, přičemž výstupy byly autorsky ověřeny.

Poděkování

Autoři děkují prof. PhDr. Tomáši Janíkovi, Ph.D., M.Ed. za odborné vedení, cenné rady a první recenzi. Dále děkuji doc. Mgr. et Mgr. Kateřině Vlčkové, Ph.D. za konzultace a doporučení k vymezení tématu a interpretaci zjištění. Poděkování patří také Masarykově univerzitě za institucionální zázemí.

Literatura

Ahmad, S. F., Rahmat, M. K., Mubarik, M. S., Alam, M. M., & Hyder, S. I. (2021). Artificial intelligence and its role in education. *Sustainability, 13*(22), 12902. https://doi.org/10.3390/su132212902

Aromataris, E., Lockwood, C., Porritt, K., Pilla, B., & Jordan, Z. (Eds.). (2024). *JBI manual for evidence synthesis*. JBI. https://doi.org/10.46658/JBIMES-24-01

Bartoňová, M., & Vítková, M. (2019). *Inkluzivní pedagogika*. Slezská univerzita v Opavě, Fakulta veřejných politik v Opavě.

Campbell, M., McKenzie, J. E., Sowden, A., Katikireddi, S. V., Brennan, S. E., Ellis, S., Hartmann-Boyce, J., Ryan, R., Shepperd, S., Thomas, J., Welch, V., & Thomson, H. (2020). Synthesis without meta-analysis (SWiM) in systematic reviews: Reporting guideline. *BMJ, 368*, l6890. https://doi.org/10.1136/bmj.l6890

Capuano, N., & Caballé, S. (2020). Adaptive learning technologies. *AI Magazine, 41*(2), 96–98. https://doi.org/10.1609/aimag.v41i2.5317

Chen, C.-H., & Chang, C.-L. (2024). Effectiveness of AI-assisted game-based learning on science learning outcomes, intrinsic motivation, cognitive load, and learning behavior. *Education and Information Technologies, 29*(14), 18621–18642. https://doi.org/10.1007/s10639-024-12553-x

Chen, L., Chen, P., & Lin, Z. (2020). Artificial intelligence in education: A review. *IEEE Access, 8*, 75264–75278. https://doi.org/10.1109/ACCESS.2020.2988510

Deveci Topal, A., Dilek Eren, C., & Kolburan Geçer, A. (2021). Chatbot application in a 5th grade science course. *Education and Information Technologies, 26*(5), 6241–6265. https://doi.org/10.1007/s10639-021-10627-8

Feng, Y., & Wang, X. (2023). A comparative study on the development of Chinese and English abilities of Chinese primary school students through two bilingual reading modes: Human-AI robot interaction and paper books. *Frontiers in Psychology, 14*, Article 1200675. https://doi.org/10.3389/fpsyg.2023.1200675

Hanzl, M., Dosedla, M., Novotná, P., & Harsányi, T. (2025). Attitudes and experiences of primary and secondary school teachers and students of teacher training programmes with generative artificial intelligence in education. *2025 International Conference on Emerging eLearning Technologies and Applications (ICETA)*, 215–222. https://doi.org/10.1109/ICETA67772.2025.11280241

Hardaker, G., & Glenn, L. E. (2025). Artificial intelligence for personalized learning: A systematic literature review. *International Journal of Information and Learning Technology, 42*(1), 1–14. https://doi.org/10.1108/IJILT-07-2024-0160

Hariyanto, Kristianingsih, F. X. D., & Maharani, R. (2025). Artificial intelligence in adaptive education: A systematic review of techniques for personalized learning. *Discover Education, 4*(1). https://doi.org/10.1007/s44217-025-00908-6

Helus, Z. (2015). *Sociální psychologie pro pedagogy* (2., přeprac. a dopl. vyd.). Grada.

Heymans, M. (2025). *Guided learning in Gemini: From answers to understanding*. Google. https://blog.google/outreach-initiatives/education/guided-learning/

Holmes, W., & Tuomi, I. (2022). State of the art and practice in AI in education. *European Journal of Education, 57*(4), 542–570. https://doi.org/10.1111/ejed.12533

Huang, J., Saleh, S., & Liu, Y. (2021). A review on artificial intelligence in education. *Academic Journal of Interdisciplinary Studies, 10*(3), 206–217. https://doi.org/10.36941/AJIS-2021-0077

Jauhiainen, J. S., & Garagorry Guerra, A. (2024). Generative AI and education: Dynamic personalization of pupils' school learning material with ChatGPT. *Frontiers in Education, 9*, Article 1288723. https://doi.org/10.3389/feduc.2024.1288723

Kamalov, F., Santandreu Calonge, D., & Gurrib, I. (2023). New era of artificial intelligence in education: Towards a sustainable multifaceted revolution. *Sustainability, 15*(16), 12451. https://doi.org/10.3390/su151612451

Kerr, P. (2016). *Personalization of language learning through adaptive technology: Part of the Cambridge Papers in ELT series*. Cambridge University Press. https://www.cambridge.org/elt/blog/wp-content/uploads/2017/06/CambridgePapersinELT_AdaptiveLearning.pdf

Khazanchi, R., Di Mitri, D., & Drachsler, H. (2024). The effect of AI-based systems on mathematics achievement in rural context: A quantitative study. *Journal of Computer Assisted Learning, 41*(1). https://doi.org/10.1111/jcal.13098

Kim, K., & Kwon, K. (2024). Tangible computing tools in AI education: Approach to improve elementary students' knowledge, perception, and behavioral intention towards AI. *Education and Information Technologies, 29*(13), 16125–16156. https://doi.org/10.1007/s10639-024-12497-2

Kopecký, K., Szotkowski, R., Voráč, D., Krejčí, V., & Dobešová, P. (2023). *České školy a umělá inteligence – výzkumná zpráva*. Pedagogická fakulta Univerzity Palackého v Olomouci.

Kosmas, P., Nisiforou, E. A., Kounnapi, E., Sophocleous, S., & Theophanous, G. (2025). Integrating artificial intelligence in literacy lessons for elementary classrooms: A co-design approach. *Educational Technology Research and Development, 73*(4), 2589–2615. https://doi.org/10.1007/s11423-025-10492-z

Lai, T., Xie, C., Ruan, M., Wang, Z., Lu, H., & Fu, S. (2023). Influence of artificial intelligence in education on adolescents' social adaptability: The mediatory role of social support. *PLOS One, 18*(3), e0283170. https://doi.org/10.1371/journal.pone.0283170

Langreo, L. (2025). *It's not magic: How these schools are teaching AI literacy*. *Education Week*. https://www.edweek.org/technology/its-not-magic-how-these-schools-are-teaching-ai-literacy/2025/10

Liao, X., Zhang, X., Wang, Z., & Luo, H. (2024). Design and implementation of an AI-enabled visual report tool as formative assessment to promote learning achievement and self-regulated learning: An experimental study. *British Journal of Educational Technology, 55*(3), 1253–1276. https://doi.org/10.1111/bjet.13424

Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. (2016). *Intelligence unleashed: An argument for AI in education*. Pearson.

Maaz, N., Mounsef, J., & Maalouf, N. (2025). CARE: Towards customized assistive robot-based education. *Frontiers in Robotics and AI, 12*, Article 1474741. https://doi.org/10.3389/frobt.2025.1474741

Maňák, J., & Švec, V. (2003). *Výukové metody*. Paido.

Meares, J. (2025). *How Gemini's Guided Learning can help you study more effectively*. Google. https://blog.google/products/gemini/guided-learning-google-gemini/

NPI. (2024). *Připravenost škol na rozvoj digitálních kompetencí*. Digitalizace RVP. https://digitalizace.rvp.cz/files/vedeni-sos-final-1.pdf

OpenAI. (2025). *Představujeme studijní režim*. https://openai.com/cs-CZ/index/chatgpt-study-mode/

Ouzzani, M., Hammady, H., Fedorowicz, Z., & Elmagarmid, A. (2016). Rayyan—A web and mobile app for systematic reviews. *Systematic Reviews, 5*(1), Article 210. https://doi.org/10.1186/s13643-016-0384-4

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ, 372*, n71. https://doi.org/10.1136/bmj.n71

Pane, J. F., Griffin, B. A., McCaffrey, D. F., & Karam, R. (2014). Effectiveness of Cognitive Tutor Algebra I at scale. *Educational Evaluation and Policy Analysis, 36*(2), 127–144. https://doi.org/10.3102/0162373713507480

Park, W., & Kwon, H. (2024). Implementing artificial intelligence education for middle school technology education in Republic of Korea. *International Journal of Technology and Design Education, 34*(1), 109–135. https://doi.org/10.1007/s10798-023-09812-2

Peters, M. D. J., Godfrey, C., McInerney, P., Khalil, H., Larsen, P., Marnie, C., Pollock, D., Tricco, A. C., & Munn, Z. (2022). Best practice guidance and reporting items for the development of scoping review protocols. *JBI Evidence Synthesis, 20*(4), 953–968. https://doi.org/10.11124/JBIES-21-00242

Průcha, J., Walterová, E., & Mareš, J. (2013). *Pedagogický slovník* (7., aktualiz. a rozš. vyd.). Portál.

Rada Evropské unie. (2025). *Akt o umělé inteligenci*. Rada Evropské unie. https://www.consilium.europa.eu/cs/policies/artificial-intelligence/

Ravindiran, E., & Ramani, P. (2025). Revolutionizing primary education with AI: Advancing teaching and learning through smart technologies. *International Journal for Multidisciplinary Research, 7*(2). https://doi.org/10.36948/IJFMR.2025.V07I02.42369

Relmasira, S. C., Lai, Y. C., & Donaldson, J. P. (2023). Fostering AI literacy in elementary science, technology, engineering, art, and mathematics (STEAM) education in the age of generative AI. *Sustainability, 15*(18), 13595. https://doi.org/10.3390/su151813595

Simonová, J., Greger, D., Straková, J., Šťastný, V., Bílá, A., Novotná, K., Navrátilová, J., Potužníková, E., Brožová, K., & Dvořák, D. (2023). *Podoby diferenciace na základních školách: Zpráva z výzkumu*. Pedagogická fakulta Univerzity Karlovy.

Song, X., Mak, J., & Chen, H. (2025). Teachers' and learners' perceptions about implementation of AI tools in elementary mathematics classes. *SAGE Open, 15*(2). https://doi.org/10.1177/21582440251334545

Tang, Q., Deng, W., Huang, Y., Wang, S., & Zhang, H. (2025). Can generative artificial intelligence be a good teaching assistant? An empirical analysis based on generative AI-assisted teaching. *Journal of Computer Assisted Learning, 41*(3). https://doi.org/10.1111/jcal.70027

Tapalova, O., & Zhiyenbayeva, N. (2022). Artificial intelligence in education: AIEd for personalised learning pathways. *Electronic Journal of e-Learning, 20*(5), 639–653. https://doi.org/10.34190/EJEL.20.5.2597

Tomlinson, C. A. (2017). *How to differentiate instruction in academically diverse classrooms* (3rd ed.). ASCD. https://files.ascd.org/staticfiles/ascd/pdf/siteASCD/publications/books/HowtoDifferentiateInstructioninAcademicallyDiverseClassrooms-3rdEd.pdf

Tricco, A. C., Lillie, E., Zarin, W., O'Brien, K. K., Colquhoun, H., Levac, D., Moher, D., Peters, M. D. J., Horsley, T., Weeks, L., Hempel, S., Akl, E. A., Chang, C., McGowan, J., Stewart, L., Hartling, L., Aldcroft, A., Wilson, M. G., Garritty, C., ... Straus, S. E. (2018). PRISMA extension for scoping reviews (PRISMA-ScR): Checklist and explanation. *Annals of Internal Medicine, 169*(7), 467–473. https://doi.org/10.7326/M18-0850

UNESCO. (2021). *Artificial intelligence in education*. https://www.unesco.org/en/digital-education/artificial-intelligence

U.S. Department of Education. (2025). *Proposed priority and definitions—Secretary's supplemental priority and definitions on advancing artificial intelligence in education*. *Federal Register, 90*. https://www.federalregister.gov/d/2025-13650

Yim, I. H. Y., & Su, J. (2025). Artificial intelligence (AI) learning tools in K–12 education: A scoping review. *Journal of Computers in Education*. *12*, 93–131. https://doi.org/10.1007/s40692-023-00304-9

Zafari, M., Bazargani, J. S., Sadeghi-Niaraki, A., & Choi, S.-M. (2022). Artificial intelligence applications in K–12 education: A systematic literature review. *IEEE Access, 10*, 61905–61921. https://doi.org/10.1109/ACCESS.2022.3179356

Zormanová, L. (2012). *Výukové metody v pedagogice: Tradiční a inovativní metody, transmisivní a konstruktivistické pojetí výuky, klasifikace výukových metod: S praktickými ukázkami*. Grada.

Zormanová, L., & Vavříková, H. (2025). Attitudes of Czech and Polish teachers towards the use of artificial intelligence in schools. *International Journal of Research in E-Learning*, *11*(1). 1–23. https://doi.org/10.31261/IJREL.2025.11.1.02