

TECHNICKÁ UNIVERZITA V LIBERCI

KATEDRA GEOINFORMATIKY
A DIDAKTIKY INFORMATIKY FP

UMĚLÁ INTELLIGENCE V GEOGRAFICKÉM VZDĚLÁVÁNÍ

TEORIE A CVIČEBNICE
PRO UČITELE A UČITELKY
GEOGRAFIE

Jiří Šmída, Liberec 2026

studijní text pro kurz
Geoinformatika ve vzdělávání

Název: **Umělá inteligence v geografickém vzdělávání**

Vydání: **první**

Autor: **Jiří Šmída**

Rok vydání: **2026**

Určeno a doporučeno jako učební text pro kurzy KGD/PGIV a KGD/KGIV.

Metodická poznámka k postupu tvorby textu s podporou LLM AI

Tento studijní text vznikl ve spolupráci autora s asistentem založeným na velkém jazykovém modelu (Claude Opus, Anthropic). Spolupráce probíhala jako iterativní dialog v RAG režimu nad sadou odborných zdrojů, kurikulárních dokumentů a předchozích kapitol studijní opory. AI asistent plnil roli návrhovou a strukturující — generoval pracovní verze pasáží, navrhoval formulační varianty, identifikoval slabá místa argumentace a pomáhal s tvorbou souhrnů a tabulek.

Autor přistupoval ke všem návrhům AI kriticky a v souladu s principem transparentního a etického využívání generativní umělé inteligence v akademické práci: ověřoval faktografické údaje, primární i sekundární zdroje, terminologickou přesnost a soulad s teoretickými rámci geografického vzdělávání (RAP model, SPACIT, KRAAU, RVP ZV 2025). Strukturu, vyznění i didaktické těžiště textu autor cíleně přizpůsoboval vzdělávacím cílům kurzu ZGIV a odborné tradici oboru. Přes systematické ověřování nelze vyloučit, že některé sekundární odkazy nebo dílčí formulace nebyly v plném rozsahu prověřeny — generativní AI v této oblasti halucinuje, jak ostatně rozpracovává sama tato kapitola.

Tato poznámka je zároveň součástí didaktického záměru: kapitola věnovaná umělé inteligenci ve vzdělávání by ztrácela věrohodnost, kdyby svůj vlastní vznik nezveřejnila se stejnou mírou transparentnosti, jakou doporučuje studentům — budoucím učitelům — i jejich budoucím žákům. Autor plně odpovídá za výsledné znění, obsah a odbornou správnost publikace.

Poznámka k podmínkám užívání textu



Text je určen k osobnímu studijnímu využití studenty a studentkami. Citace, sdílení a úpravy textu jsou možné v rozsahu licence CC BY-NC-SA 4.0 a za podmínky respektování pravidel akademické integrity.

Obsah

Úvod a cíle tohoto studijního textu.....	7
1. Terminologické vymezení AI.....	9
Hierarchie pojmů: od umělé inteligence k velkým jazykovým modelům.....	9
Další druhy generativní AI a specializované platformy.....	10
Princip fungování velkých jazykových modelů.....	11
Kdy je LLM asistent vhodným nástrojem a kdy ne.....	12
Tři typy nasazení LLM asistenta — proč na tom záleží.....	13
Rychlé čtení podkapitoly 1.....	15
2. Promptování — základ úspěchu.....	16
Proč na promptu záleží víc než na nástroji.....	16
Tři komponenty dobrého promptu — kontext, úkol, cíl.....	16
Práce s přiloženým dokumentem — RAG v praxi.....	18
Iterace — promptování není střelba do terče.....	19
Vývoj jednoho promptu ve třech iteracích.....	20
Stejný prompt napříč nástroji.....	22
Rychlé čtení podkapitoly 2.....	23
3. AI ve vzdělávání.....	24
Proč tato podkapitola.....	24
Tři role AI ve vzdělávání.....	24
Empirická evidence — co o LLM asistentech víme z výzkumu.....	27
Kompetence pro práci s AI.....	31
Vrátíme se k otevřené otázce.....	32
Rychlé čtení podkapitoly 3.....	34
4. AI v geografickém vzdělávání.....	35
Proč si geografie zaslouží vlastní podkapitulu.....	35
Oblasti geografického vzdělávání s jasnou hodnotou AI.....	36
Oblasti, kde AI nestačí nebo škodí.....	37
LLM asistent a kurikulární práce.....	38
Specializované platformy nad LLM.....	40
Ekosystém specializovaných AI nástrojů.....	41
AI Lesson Plan Generators v českém prostředí.....	42
Didaktické rámce pro AI ve vzdělávání v ČR — iniciativa AI dětem.....	42
GeoAI v geografickém vzdělávání.....	44
Geografická specifika promptování.....	46
Pracovní scénář 1: knowledge cutoff a Hormuzský průliv.....	48
Pracovní scénář 2: sucho v české krajině.....	51
Rychlé čtení podkapitoly 4.....	53
5. Pokročilé techniky promptování.....	54
Co odlišuje pokročilé techniky od základů.....	54

Šest základních pokročilých technik.....	55
Tři další užitečné techniky.....	58
Dvě nadtechniky pro strukturování promptu.....	59
Pět komplexních ukázkových promptů — pro analýzu i testování.....	62
AI jako učitel promptování.....	69
Most k samostatnému procvičování.....	70
Rychlé čtení podkapitoly 5.....	72
6. Etika a epistemika.....	73
Etika, epistemika a geografické myšlení.....	73
Halucinace AI.....	74
Metoda SIFT a most ke geomédiím.....	76
Etické okruhy.....	78
Epistemické limity LLM pro geografické myšlení.....	83
Budoucí učitel geografie v AI kontextu.....	85
Rychlé čtení podkapitoly 6.....	87
Závěr.....	88
Klíčová sdělení kapitoly.....	90
Otázky pro samostudium.....	91
Pojmové otázky — zapamatování a porozumění.....	91
Analytické otázky — analýza a hodnocení.....	91
Reflexivní otázky — vlastní stanovisko.....	92
Úkoly pro samostatné procvičování.....	92
Krátké úkoly (do 30 minut).....	92
Středně náročné úkoly (1–3 hodiny).....	93
Projektové úkoly (5+ hodin).....	93
Tezaurus klíčových pojmů.....	95
Seznam zdrojů.....	98
Odborné publikace, oficiální dokumenty a koncepční rámce.....	98
Didaktické rámce a portály pro učitele.....	99
Nástroje zmiňované v textu.....	99
Specializované rešeršní nástroje.....	99

Geoinformatika ve vzdělávání | GIV 2026

Umělá inteligence v geografickém vzdělávání

Studijní text | Jiří Šmída | Liberec 2026

Úvod a cíle tohoto studijního textu

Představme si dvě odpovědi na stejnou otázku. Položíte asistentovi založenému na velkém jazykovém modelu jednoduchý dotaz: „*Jaká je rozloha Sahary?*“ První odpověď zní: „*Sahara je největší poušť světa a má rozlohu 3 miliony km².*“ Druhá odpověď zní: „*Sahara je největší horká poušť světa s rozlohou přibližně 9,2 milionu km².*“ Obě odpovědi jsou formulačně sebejisté, obě vypadají jako věrohodný geografický údaj. Jen jedna z nich je správná.

Nejde o problém technický. Jde o problém didaktický a epistemický. Obě odpovědi mohly skutečně přijít od stejného nástroje v různých momentech. Otázka, která stojí za touto kapitolou, není „*používat AI ve výuce, nebo ne*“ — odpověď na ni se v praxi rozhoduje sama tím, jak rychle se generativní AI šíří do životů žáků, učitelů i akademického prostředí. Otázka zní „*jak s ní pracovat tak, abychom rozeznali první odpověď od druhé — a abychom to naučili i své žáky*“.

Tato kapitola připraví budoucího učitele geografie na práci s generativní AI v profesní roli. Po jejím přečtení by měl student umět:

- vymezit pojem umělé inteligence, generativní AI a velkého jazykového modelu a vysvětlit principy jejich fungování studentovi nebo kolegovi v učitelském sboru;
- formulovat efektivní prompt pro práci s AI asistentem na konkrétním didaktickém úkolu z geografického vzdělávání;
- zařadit současné AI nástroje do teoretického rámce paradigmat AI ve vzdělávání a kriticky posoudit, kterému paradigmatu odpovídá konkrétní způsob jejich použití;
- interpretovat empirickou evidenci o vlivu AI na učení a vyvodit z ní didaktické implikace pro vlastní praxi;
- identifikovat oblasti geografického vzdělávání, kde AI nástroje přinášejí jasnou hodnotu, a oblasti, kde naopak nestačí nebo škodí;
- aplikovat metodu SIFT a další strategie ověřování na výstupy AI a vést k tomu i své budoucí žáky;
- promyslet etické a epistemické důsledky použití AI ve vzdělávání a formulovat vlastní pedagogické stanovisko.

Kapitola navazuje na předchozí texty této série, zejména na kapitolu o geomédiích a kritické gramotnosti. Výstupy generativní AI jsou v podstatě další generací geomédií — textovou vrstvou, která spoluvytváří představu o prostoru a o světě. Nástroje a kompetence, které student získal pro kritickou práci s mediálními výstupy o prostoru, na AI generované obsahy přímo navazují.

Text je členěn do šesti částí. Nejprve vymezíme pojmy a popíšeme, co generativní AI dělá a nedělá. Druhá část představí základy promptování — formulování zadání pro AI asistenta tak, aby dával užitečné odpovědi. Třetí část zavádí do teorie a empirie AI ve vzdělávání obecně, čtvrtá konkrétně do geografického vzdělávání. Pátá část rozvíjí pokročilé techniky promptování a obsahuje sadu komplexních ukázkových promptů, které slouží k analýze i k testování. Šestá část se věnuje etickým a epistemickým aspektům, které rámuji všechno předchozí.

Některé otázky v textu zůstanou otevřené záměrně — vědecký výzkum k nim ještě nedospěl k jednoznačné odpovědi a vlastní pedagogická pozice studenta se k nim teprve formuje. Nejvýznamnější z nich provází text od třetí části až do závěru: pokud generativní AI zlepšuje učební výkon mnohem víc než kritické a tvořivé myšlení, neposiluje to právě tu didaktickou logiku, která stojí v rozporu se vším, co tato série textů hájí?

S touto otázkou se vrátíme na seminář a v další praxi.

Práce se souhrny rychlého čtení. Každá podkapitola tohoto textu je zakončena krátkým souhrnem nazvaným *Rychlé čtení podkapitoly X*. Souhrn obsahuje hlavní teze, pojmy a vztahy v podkapitole — slouží jako mapa pro orientaci v probrané látce a jako referenční materiál, ke kterému se můžete kdykoli vrátit. Pro první čtení doporučujeme přečíst podkapitulu kompletně a souhrn použít až jako kontrolu porozumění. Pro pozdější opakování slouží souhrn jako nástroj pro rychlou rekapitulaci — místo čtení celé podkapitoly stačí projít její rychlé čtení a vyhledat detaily jen tam, kde si nejste jisti. První podkapitola textu navíc zavádí poměrně velké množství pojmů a zkratk; pokud při čtení ztratíte orientaci, na konci kapitoly najdete kromě rychlého čtení také tezaurus klíčových pojmů.

Poznámka k aktuálnosti textu. Generativní AI je obor, který se vyvíjí extrémně rychle. Konkrétní nástroje, jejich verze, ceníky i schopnosti se mění v řádu měsíců. Tento text byl napsán v dubnu 2026 a reflektuje stav generativní AI a AI nástrojů k tomuto datu. Principy, didaktické rámce a kritické perspektivy, o kterých je řeč, jsou stabilnější než konkrétní produkty — ale i tak je při čtení vhodné mít na paměti, že některé detaily se mohly mezi sepsáním a vaším čtením posunout. Když budete v textu narážet na konkrétní AI nástroj, berte ho jako příklad kategorie, ne jako doporučení konkrétního produktu.

1. Terminologické vymezení AI

Hierarchie pojmů: od umělé inteligence k velkým jazykovým modelům

Pojem **umělá inteligence** (artificial intelligence, AI) se ve veřejné diskuzi používá tak často a tak nejednoznačně, že je nutné nejprve vyjasnit, o čem konkrétně mluvíme. Umělá inteligence je nejširší zastřešující pojem označující obor informatiky, který se zabývá vývojem systémů schopných řešit úlohy běžně vyžadující lidskou inteligenci — rozpoznávání obrazu, porozumění řeči, hraní her, plánování, klasifikaci dat, predikci. Pod tuto hlavičku spadají velmi rozdílné technologie: pravidlové expertní systémy, klasické algoritmy strojového učení, neuronové sítě, hluboké učení i nejnovější generativní modely.

V kontextu vzdělávání mluvíme o samostatné aplikační oblasti — **AI ve vzdělávání** (artificial intelligence in education, AIEd). Tato oblast má historii sahající do devadesátých let dvacátého století. Po dlouhou dobu její nejvýraznější realizací byly inteligentní tutorské systémy (intelligent tutoring systems, ITS) — programy, které vedly žáka individuálně přizpůsobenou cestou předem připraveným kurikulem. Postupně k nim přibýly doporučovací systémy, nástroje pro automatické hodnocení, learning analytics a později chatboti.

Skutečně zlomová změna ale nastala až s nástupem **generativní AI** (generative AI, GenAI). Tato podmnožina umělé inteligence se neomezuje na klasifikaci nebo predikci na základě existujících dat, ale dokáže **generovat nový obsah** — text, obrazy, zvuk, video, kód. Generativní AI vznikla jako produkt několika souběžných pokroků: architektury neuronových sítí zvané transformer, dramatického nárůstu výpočetní kapacity a dostupnosti obrovských textových a obrazových datových sad pro trénování. Z generativní AI je pro učitele zdaleka nejvýznamnější jedna konkrétní kategorie nástrojů — **velké jazykové modely** (large language models, LLM). Velký jazykový model je generativní AI specializovaný na práci s přirozeným jazykem. Je trénován na enormním korpusu textu (korpus = rozsáhlá uspořádaná sbírka textů, na kterých byl model trénován; typicky knihy, články, weby, zdrojový kód) a po natrénování dokáže generovat text, který je gramaticky správný, kontextově relevantní a v mnoha případech věcně užitečný.

LLM se k uživateli typicky dostávají přes konkrétní produkty — **LLM asistenty** neboli AI chatboty. K dnešnímu dni patří mezi nejrozšířenější Claude od společnosti Anthropic, ChatGPT od OpenAI, Gemini od Google, Mistral od stejnojmenné francouzské společnosti, DeepSeek od čínské společnosti DeepSeek a další. Každý z těchto produktů má za sebou jiný velký jazykový model (případně rodinu modelů různých velikostí) a každý má své specifické silné stránky, ceník i podmínky použití. Pro praktickou práci učitele jsou rozdíly mezi nimi v mnoha úkolech méně

výrazné než to, co mají společného — všichni dnešní hlavní LLM asistenti zvládají generovat text v češtině, pracovat s přiloženými dokumenty, vyhledávat na webu (v některých konfiguracích) a vést delší konverzaci s pamětí na předchozí výměny.

V této kapitole používáme pojem **LLM asistent** jako obecný termín pro tuto kategorii nástrojů. Konkrétní produkty zmiňujeme jako příklady, ale principy, které popisujeme, platí napříč nástroji.

Další druhy generativní AI a specializované platformy

Velké jazykové modely a LLM asistenti tvoří jádro tématu této kapitoly, ale nejsou jediným druhem generativní AI, který se ve vzdělávání uplatňuje. Pro úplnost krátce vymezme čtyři další kategorie.

Generátory obrazu (DALL-E, Midjourney, Stable Diffusion, Flux a další) generují obrazy na základě textového popisu. V geografickém vzdělávání mají využití pro tvorbu ilustrací, schémat, konceptuálních map, vizualizací abstraktních pojmů. Mají ale i své limity — generátory neumí vytvářet kartograficky přesné mapy s lokalizovanými geografickými údaji a jejich výstupy je nutné posuzovat s podobnou kritickou distancí jako texty z LLM.

Multimodální AI asistenti kombinují práci s textem, obrazem, někdy i hlasem v jednom nástroji. Uživatel může ukázat fotografii krajiny a požádat o popis, zadat hlasovou otázku, dostat hlasovou odpověď. Většina dnešních hlavních LLM asistentů má v různé míře multimodální schopnosti zabudované přímo.

Specializované platformy postavené nad LLM. Zatímco LLM asistent typu Claude nebo ChatGPT je nástroj obecného použití, specializované platformy přidávají k jádrovému jazykovému modelu strukturu a funkce zaměřené na konkrétní typ úkolů. Nejzajímavější kategorií pro učitele jsou **platformy s RAG architekturou** (retrieval-augmented generation), které pracují primárně s dokumenty, jež do nich uživatel přiloží. Konkrétním příkladem je nástroj NotebookLM od Google, který se v průběhu roku 2025 stal jedním z nejvýraznějších didakticky orientovaných AI nástrojů. Příbuznou logiku mají i Claude Projects, vlastní GPTs v ChatGPT nebo Perplexity Spaces. Tato kategorie nástrojů má pro práci učitele jednu velkou výhodu, ke které se vrátíme v podkapitole 4: dramaticky snižuje riziko halucinací, protože nástroj odpovídá z konkrétních textů, které mu poskytneme, ne ze své obecné báze znalostí.

Specializované platformy pro tvorbu hodin a výukových materiálů — AI Lesson Plan Generators. Jsou to nástroje navržené přímo pro učitele, které nabízejí předpřipravené šablony pro generování hodin, pracovních listů, testů, diferenciovaných úkolů a žákovských zpráv. V mezinárodním kontextu k nejznámějším patří Magic School AI, Eduaide, Twee, Education Copilot. V českém prostředí jsou pro učitele zásadní iniciativy popsány v podkapitole 4.

GeoAI (geospatial AI) — aplikace umělé inteligence a strojového učení na prostorová data. Tato kategorie stojí mimo oblast LLM asistentů a tvoří kvalitativně odlišnou linii AI ve vzdělávání. Pod GeoAI patří automatická klasifikace dálkového průzkumu Země, segmentace satelitních a leteckých snímků, predikce povodní nebo lesních požárů, automatické rozpoznávání objektů v

krajině, AI rozšíření v geoinformačních systémech (ArcGIS Pro, QGIS), generování syntetických prostorových dat. Pro budoucího učitele geografie je důležité vědět, že AI v geografii zdaleka není jen LLM — vedle textových asistentů existuje celá oblast AI nástrojů pracujících přímo s prostorovými daty.

Až do nedávné minulosti vyžadovala práce s GeoAI specializované znalosti GIS a programování. To se rychle mění. V horizontu nejbližších let lze očekávat příchod laicky přívětivých aplikací, které zpřístupní vybrané GeoAI nástroje běžnému uživateli bez nutnosti instalace specializovaného GIS nebo psaní kódu. Pro středoškolské geografické vzdělávání to znamená, že GeoAI by se mělo stát součástí vzdělávacího obsahu na gymnáziu — a ne jen v rámci specializovaného kurzu geoinformatiky, ale jako součást obecné geografické digitální gramotnosti. Konkrétní didaktické scénáře a aktuální nástroje rozpracujeme v podkapitole 4.

Princip fungování velkých jazykových modelů

Pro práci s LLM asistentem není nutné znát detaily architektury transformer ani matematiku attention mechanismů. Důležité je rozumět **základnímu principu**, protože z něj vyplývá většina toho, co tyto nástroje umí a neumí.

LLM nepracuje se znalostmi tak, jak bychom si je představovali u encyklopedie nebo databáze. Neukládá si fakta v podobě záznamů, které by vyhledával. Místo toho LLM během trénování zpracoval obrovský objem textových dat a vytvořil si komplexní statistický model toho, **která slova obvykle následují po jakých jiných slovech v jakém kontextu**. Když mu uživatel položí otázku, model nehledá v paměti odpověď — predikuje slovo po slovu (přesněji řečeno token po tokenu, kde token je obvykle slovo nebo jeho část), který token má největší pravděpodobnost být dalším pokračováním v kontextu dotazu a předchozí části vlastní odpovědi. Tento proces se opakuje slovo za slovem, dokud model nedospěje k závěru, že odpověď je úplná.

Z tohoto principu plyne několik důležitých důsledků, které pomohou s LLM rozumně pracovat.

Jazyková plynulost není totéž co faktografická správnost. Model je trénovaný optimalizovat pravděpodobnost dobře znějícího textu, ne pravdivost obsahu. Často se obojí kryje, protože v trénovacích datech jsou převážně pravdivé výroky o světě. Ale když se model dostane do oblastí, kde má v datech mezery nebo rozporuplné informace, **vyplní mezeru pravděpodobnostně** — vytvoří větu, která zní stejně přesvědčivě jako věty pravdivé, ale obsahově může být úplně chybná. Tomuto jevu říkáme **halucinace** a vrátíme se k němu detailně v podkapitole 6.

Model nemá přístup k aktuálním datům. Trénování proběhlo k určitému datu — model má svůj **knowledge cutoff** (česky doslova „mezní datum znalosti“). Vše, co se ve světě stalo později, model neví — nebo si to konstruuje na základě obecných vzorců z trénovacích dat. Knowledge cutoff je pro učitele jeden z nejdůležitějších pojmů této kapitoly. Pokud učitel připravuje hodinu o aktuálním geopolitickém nebo environmentálním tématu — o probíhajícím konfliktu, nedávné přírodní katastrofě, nově vyhlášeném mezinárodním ujednání — a položí LLM asistentovi přímou otázku na specifika tohoto vývoje, dostane odpověď, která vypadá důvěryhodně, ale s velkou

pravděpodobností odráží stav světa k datu trénování modelu, ne dnešek. Konkrétní pracovní scénář pro takovou situaci rozpracujeme v podkapitole 4 na příkladu krize v Hormuzském průlivu. Některé LLM asistenty mají schopnost **vyhledávat na webu** během konverzace, čímž tento limit částečně obcházejí, ale i v takovém případě je nutné rozumět, **které informace pocházejí z webu a které z modelu samotného**. Knowledge cutoff konkrétního modelu obvykle uvádí jeho poskytovatel ve své dokumentaci; spolehlivý odhad lze získat i přímým dotazem modelu nebo testem na události, jejichž datum známe.

Model nemá vlastní zkušenost ani autentické porozumění. Nedokáže si představit místo, na kterém nikdy nebyl, neumí cítit emoce spojené s krajinou, nemá tělesnou paměť pohybu prostorem. Když popisuje fenomén místa nebo emocionální mapování, dělá to na základě toho, co o těchto pojmech četl v trénovacích datech — někdy elegantně, ale principiálně bez přístupu k tomu, co tyto pojmy ve skutečnosti znamenají.

Model není neutrální. Odráží to, na čem byl trénován. Většina velkých jazykových modelů je trénována převážně na anglickém textu, přičemž čeština a další menší jazyky tvoří relativně malou část korpusu. Podobně jsou různé světové kontexty zastoupeny velmi nerovnoměrně — americká a západoevropská realita je v datech mnohem hustěji než realita česká, africká nebo jihoamerická. Pro výuku regionální geografie a místopisu je toto omezení zásadní. K důsledkům se vrátíme v podkapitole 6.

Stejný dotaz nemusí dát stejnou odpověď. Generování je do určité míry stochastický proces — pro stejný prompt může model v různých momentech vygenerovat různé odpovědi. Tato variabilita je jeden z důvodů, proč při vážnější práci s LLM stojí za to **opakovat dotaz** nebo **porovnat odpovědi z různých nástrojů**.

Kdy je LLM asistent vhodným nástrojem a kdy ne

Z principu fungování LLM přímo vyplývá, **k jakým úkolům je tento nástroj vhodný a k jakým ne**. Pro učitele geografie jsou to dvě stejně důležité skupiny — vědět, kdy AI použít, je užitečné jen ve spojení s tím, kdy ji nepoužít.

LLM asistent je vhodným nástrojem pro úkoly, kde:

- uživatel generuje varianty textu (formulace zadání, alternativní vysvětlení pojmu, několik motivačních úvodů ke stejnému tématu);
- sumarizuje delší text do kratšího nebo naopak rozpracovává heslovitý nápad do souvislého textu;
- brainstormuje — potřebuje rychle dostat na stůl deset různých nápadů, ze kterých si vybere;
- strukturuje známý obsah do nové formy (převod osnovy do tabulky, restrukturalizace pracovního listu, převod textu do otázek);
- překládá mezi registry jazyka (přeformulování odborného textu pro žáky 6. ročníku, převod prezentace pro děti do textu pro rodiče);

- pracuje s konkrétním přiloženým dokumentem, kde ho zajímá analýza, sumarizace nebo extrakce informací z tohoto dokumentu;
- potřebuje zpětnou vazbu na svůj koncept, návrh nebo úvahu — LLM asistent dokáže nabídnout alternativní pohled, položit otázky, poukázat na slabá místa.

LLM asistent není vhodným nástrojem nebo vyžaduje zvýšenou opatrnost u úkolů, kde:

- uživatel potřebuje ověřená faktografická data (statistiky, místopisné údaje, rozlohy, nadmořské výšky, populace) — riziko halucinace je vysoké;
- pracuje s aktuálními informacemi, které se mohou rychle měnit (počasí, dnešní zprávy, čerstvá data o klimatu, probíhající události) — bez aktivního vyhledávání na webu nemá model přístup;
- pracuje s lokálně specifickými informacemi (regionální geografie konkrétní české oblasti, historie menších míst) — model má v této oblasti řidká data;
- chce vytvořit přesné mapy nebo pracovat s prostorovými daty (k tomu slouží GIS, ne LLM);
- potřebuje provést přesné matematické výpočty s mnoha kroky (LLM nejsou kalkulátor, byť některé novější verze mají vestavěné nástroje pro výpočty);
- jde o rozhodnutí s právními, etickými nebo profesními důsledky (hodnocení žáka, citlivé poradenství, posouzení integrace žáka se speciálními vzdělávacími potřebami) — výstup AI nemůže nést odpovědnost, kterou musí nést pedagog.

Toto rozlišení je první vrstvou kritické práce s LLM asistentem. Druhou vrstvou je metoda SIFT a další strategie ověřování, které rozpracujeme v podkapitole 6.

Tři typy nasazení LLM asistenta — proč na tom záleží

Stejný velký jazykový model může uživateli odpovídat ve třech velmi odlišných konfiguracích, které mají různé didaktické důsledky. Učitel, který chce s AI vědomě pracovat, potřebuje rozeznat, kterou konfiguraci právě používá.

Samostatný LLM asistent. Klasická konverzace s chatbotem. Model odpovídá z toho, co si pamatuje z trénování. Nemá přístup k aktuálním datům ani k externím dokumentům. Riziko halucinace je nejvyšší, protože model si v případě nedostatku dat odpověď konstruuje pravděpodobnostně. Vhodné pro generování textu, brainstorming, formulační práci.

LLM asistent s vyhledáváním na webu. Model kombinuje svůj vlastní výstup s aktivním vyhledáváním aktuálních informací na internetu. Má přístup k současným datům, dokáže citovat zdroje. Riziko halucinace je nižší, ale není nulové — model může chybně interpretovat nalezené informace nebo citovat zdroj, který ve skutečnosti něco jiného říká. Vhodné pro práci s aktuálním obsahem, ověřování faktů, řešerši.

LLM asistent v RAG konfiguraci. Model pracuje primárně s dokumenty, které mu uživatel přiloží. Když se zeptá na něco, co je v přiložených dokumentech, model odpoví na základě nich.

Když se zeptá na něco, co tam není, měl by ideálně přiznat, že odpověď nezná — i když i tady občas dochází k tomu, že model „vyplní mezeru“ obecnou znalostí. Příklady takových nástrojů: NotebookLM, Claude Projects, vlastní GPTs s knowledge base, ScioBot s nahranými vlastními materiály. Riziko halucinace v rámci přiložených zdrojů je výrazně nižší.

Pro učitele je RAG konfigurace zásadně užitečná. Představme si scénář, který se v praxi bude opakovat: učitel do RAG nástroje přiloží úplnou verzi revidovaného RVP ZV (PDF dokument o desítkách stran), strukturu vzdělávací oblasti Člověk a příroda nebo Člověk a jeho svět a případně i učebnici geografie pro daný ročník. Pak už může s nástrojem vést konverzaci přímo nad těmito dokumenty: „Vyhledej v RVP všechny formulace OVU pro 8. ročník, které se týkají povodní.“ — „Navrhni strukturu tematického bloku, který pokryje OVU GEO-9-3-04 a propojí ho s OVU CAS-9-2-02.“ — „Na základě přiložené učebnice vygeneruj pět testových otázek různé kognitivní náročnosti k tématu hospodářské zóny Evropy.“ Nástroj nepracuje s obecnou znalostí RVP nebo geografie — pracuje s konkrétním podkladem. Tím se výrazně snižuje riziko halucinace a zároveň poskytuje odpovědi přímo aplikovatelné na české kurikulární prostředí. Konkrétní pracovní postupy s RVP a dalšími kurikulárními dokumenty rozpracujeme v podkapitole 4.

V průběhu jedné konverzace lze mezi těmito konfiguracemi přecházet — někteří LLM asistenti umí v rámci jedné konverzace přepínat režim podle potřeby. Při osvojování práce s AI je užitečné si **vždy uvědomit, ve kterém režimu právě pracujeme**, protože tomu odpovídá i to, jak moc můžeme výstupu důvěřovat a jak ho musíme ověřovat.

Rychlé čtení podkapitoly 1

Tato podkapitola představila řadu pojmů. Pro orientaci shrneme nejdůležitější vztahy v podobě stručného přehledu.

Pojmy seřazené od nejširšího k nejužšímu:

- **AI (umělá inteligence)** — obor informatiky o systémech řešících úlohy vyžadující inteligenci.
- **AIEd (AI ve vzdělávání)** — aplikační oblast AI ve vzdělávání, historicky od 90. let (inteligentní tutorské systémy a další).
- **Generativní AI (GenAI)** — podmnožina AI generující nový obsah (text, obrazy, zvuk, kód).
- **LLM (velký jazykový model)** — generativní AI specializovaný na práci s přirozeným jazykem.
- **LLM asistent (AI chatbot)** — konkrétní produkt zpřístupňující LLM uživateli (Claude, ChatGPT, Gemini, Mistral, DeepSeek).

Další druhy GenAI a souvisejících nástrojů:

- **Generátory obrazu** (DALL-E, Midjourney, Stable Diffusion, Flux) — vizuální výstupy z textového zadání.
- **Multimodální asistenti** — kombinace textu, obrazu a hlasu v jednom nástroji.
- **RAG platformy** (NotebookLM, Claude Projects, GPTs) — práce s přiloženými dokumenty místo obecné báze.
- **AI Lesson Plan Generators** — Magic School AI, Eduaide, Twee, Education Copilot v zahraničí; ScioBot a iniciativa AI dětem v českém prostředí (rozpracováno v podkapitole 4).

GeoAI (geospatial AI) — aplikace AI na prostorová data, kvalitativně odlišná kategorie od LLM, s přicházející laickou dostupností.

Klíčový princip fungování LLM: model predikuje pravděpodobnost dalšího slova na základě kontextu — neukládá si fakta jako encyklopedie. Z toho plyne: jazyková plynulost neznamená faktografickou správnost; model může halucinovat; nemá přístup k aktuálním datům (pokud není připojen k webu); není neutrální.

Knowledge cutoff — datum, do kterého sahají znalosti modelu. Pro práci s aktuálními tématy je nutné používat režim s vyhledáváním na webu nebo RAG s aktuálními dokumenty.

Tři typy nasazení LLM asistenta podle úrovně rizika halucinace:

1. **Samostatný** — pouze trénovací data, vyšší riziko halucinací.
2. **S vyhledáváním na webu** — aktuální informace s citací zdrojů, nižší riziko halucinací.
3. **RAG (s přiloženými dokumenty)** — odpovídá z konkrétního obsahu, nejnižší riziko halucinací v rámci přiložených zdrojů.

Kdy LLM asistent využít a kdy ne: vhodný pro generování variant textu, brainstorming, sumarizaci, restrukturalizaci, překlad mezi registry, zpětnou vazbu, práci s přiloženým dokumentem; nevhodný nebo rizikový pro ověření faktografická data, aktuální informace bez webu, lokálně specifické údaje, přesné mapy a prostorová data, přesné výpočty, profesní rozhodnutí s odpovědností.

S tímto základním orientačním rámcem můžeme přejít ke podkapitole 2 — k tomu, jak s LLM asistentem prakticky pracovat.

2. Promptování — základ úspěchu

Proč na promptu záleží víc než na nástroji

Existuje rozšířený omyl, podle něhož je kvalita výstupu LLM asistenta dána především tím, který nástroj použijeme. V praxi je vztah opačný — **kvalita výstupu je především funkcí kvality vstupu**. Stejný nástroj poskytne dramaticky odlišné výsledky podle toho, jak je formulován prompt. Rozdíl mezi jednovětným dotazem a promyšleně strukturovaným zadáním bývá řádový.

Tato skutečnost má pro učitele dva důsledky. První je dobrá zpráva: dovednost formulovat kvalitní prompt je do značné míry přenositelná napříč nástroji. Učitel, který se naučí promptovat ve verzi nástroje A, většinu těchto dovedností přenesení i do nástroje B nebo C. Investice do promptové gramotnosti se neztratí s tím, jak konkrétní produkty stárnou. Druhým důsledkem je, že **zlepšování výstupu začíná u uživatele, ne u nástroje**. Když odpověď není použitelná, prvním krokem není hledat lepší AI asistent — prvním krokem je upravit prompt.

Pojem **prompt** označuje vstupní zadání, které uživatel formuluje pro AI asistenta. Může jít o jednu větu, ale i o několik odstavců strukturovaného zadání, případně o zadání doplněné o přiložený dokument nebo obrázek. V češtině se občas používá překlad „výzva“, ale v odborné komunitě se spíše ujímá ponechání anglického termínu prompt. V této kapitole používáme český termín „promptování“ pro samotnou činnost a „prompt“ pro konkrétní vstup.

Tři komponenty dobrého promptu — kontext, úkol, cíl

Promyšlený prompt obvykle obsahuje tři komponenty. Tyto komponenty nemusí být v promptu vždy explicitně oddělené — důležité je, aby tam **byly přítomné**. Pokud chybí, výstup se s vysokou pravděpodobností minul s tím, co uživatel skutečně potřeboval.

Kontext odpovídá na otázku „odkud mluvím a pro koho tvořím“. Sděluje modelu, kdo je uživatel, v jaké profesní situaci se nachází, pro koho je výstup určen, jaké jsou předchozí znalosti cílového adresáta, jaké jsou rámcové podmínky (kurikulum, metodika, instituce). Učitel geografie, který připravuje hodinu, má jiný kontext než student, který si píše seminární práci, a obojí se liší od překladatele, který upravuje turistický průvodce. Bez kontextu model „hádá“, komu odpovídá — a hádá podle nejpravděpodobnějšího uživatele ve svých trénovacích datech, což zpravidla není český učitel druhého stupně.

Úkol a parametry odpovídají na otázku „co konkrétně chci“. Definují typ výstupu (text, tabulka, otázka, plán hodiny), jeho rozsah (počet otázek, délka v minutách, počet odstavců), formát (souvislý text vs. odrážky, struktura nadpisů), styl (formální, hovorový, populárně-naučný), případně další omezení (jazyk, použité pojmy, naopak vyloučené pojmy). Úkol je tedy nejen *co*, ale i *jak* a *v jakém rozsahu*.

Cíl a kritéria úspěchu odpovídají na otázku „k čemu má výstup sloužit a podle čeho poznám, že je dobrý“. Tato komponenta je v promptech nejčastěji vynechávána a její doplnění obvykle přináší největší skok v kvalitě. Když model ví, že pracovní list má motivovat žáky 6. ročníku k samostatnému pozorování krajiny, generuje něco kvalitativně odlišného, než když ví jen, že má jít o pracovní list o krajině. Cíl řídí volbu obsahu, formy, jazykového registru i metodického přístupu.

V praxi se tyto tři komponenty často prolínají. Není podstatné, aby byly v promptu lineárně vypsané za sebou — důležité je, aby v něm všechny **byly**. V úvodních fázích osvojování si promptování pomáhá, když je uživatel zapisuje doslova jako tři oddělené části. Po několika desítkách promptů se tato struktura stane druhou přirozeností a uživatel ji formuluje implicitně.

Strukturování promptu — pomoc pro model i pro nás samé

Krátký prompt může být formulován jako jeden plynulý odstavce. Jakmile prompt přesáhne pět šest vět nebo začne obsahovat několik různorodých informací, vyplatí se ho **strukturovat** do jasně oddělených sekcí. Strukturovaný prompt má tři výhody: model lépe rozpozná, která část je co; uživatel sám si lépe ověří, že na nic nezapomněl; prompt se snadněji upravuje a opakovaně použije pro podobné úkoly.

Dva běžné způsoby strukturování:

Oddělení prázdnými řádky a krátkými popisky. Nejjednodušší forma. Před každou sekcí je popisek (Kontext, Úkol, Výstup), za ním obsah dané sekce, mezi sekcemi prázdný řádek. Funguje napříč všemi nástroji a je dobře čitelný i pro samotného uživatele.

Oddělení pomocí markdown nadpisů. Uživatel použije klasické markdown značky (## Kontext, ## Úkol). Někteří LLM asistenti to interpretují obzvlášť dobře, ale i ti, kteří markdown přímo nepodporují, ho čtou jako srozumitelný strukturní signál.

Volba formy je věcí osobní preference. Důležitější než konkrétní syntaxe je **fakt, že uživatel prompt strukturuje** a sekce explicitně odděluje. Příklad strukturovaného promptu pro typický učitelský úkol:

Kontext:

Jsem učitel geografie 2. stupně ZŠ. Připravuji hodinu pro 8. ročník, žáci mají základní znalosti o vodním koloběhu z předchozí hodiny.

Úkol:

Vytvoř pět testových otázek na téma povodně v ČR. Otázky mají pokrýt různé kognitivní úrovně podle Bloomovy taxonomie – od zapamatování po hodnocení.

Výstup:

- formát: otázky s otevřenou odpovědí, ne výběr z možností
- u každé otázky uveď, kterou kognitivní úroveň Bloomovy taxonomie testuje
- jazyk přiměřený 8. ročníku, ne odborný žargon
- celkem 5 otázek

Tento prompt obsahuje všechny tři komponenty (kontext, úkol, cíl/parametry) a navíc je strukturovaný do oddělených sekcí. Pro porovnání — uživatel by mohl totéž zformulovat i jako jednu větu „Vytvoř pět otázek o povodních pro osmáky.“ Rozdíl v kvalitě výstupu je dramatický.

Pro ještě sofistikovanější struktury — například promptu obsahujícího delší vnitřní text, ukázkové vzorky nebo více vrstev kontextu — existují další způsoby formálního značení sekcí. K nim se vrátíme v podkapitole 5 v rámci pokročilých technik promptování.

Práce s přiloženým dokumentem — RAG v praxi

V podkapitole 1 jsme zavedli pojem RAG (retrieval-augmented generation) jako třetí typ nasazení LLM asistenta — režim, kdy model pracuje primárně s dokumenty, které mu uživatel přiloží. RAG promptování má svá specifika a stojí za samostatnou pozornost, protože pro učitele otevírá kvalitativně odlišné možnosti práce s AI.

Když uživatel pracuje v RAG režimu (ať už v NotebookLM, Claude Projects, vlastních GPTs nebo jiném nástroji), strukturuje prompt obvykle ve dvou fázích. **Nejprve nahraje zdroje** — typicky PDF, DOCX nebo textový soubor s materiálem, nad kterým chce pracovat. To může být kapitola učebnice, odborný článek, zápis z porady, RVP ZV nebo jeho část, soubor metodických pokynů. Některé nástroje podporují i hromadné nahrání desítek dokumentů, čímž vzniká „znalostní báze“ pro daný projekt. **Teprve potom formuluje prompt**, který se na tyto zdroje odkazuje.

Specifický rys RAG promptování je, že **kontext** se z velké části přesouvá do přiložených dokumentů a samotný prompt se stává kratším. Místo aby uživatel modelu vysvětloval, co je RVP a jak je strukturováno, prostě RVP přiloží jako PDF a v promptu se na něj odkáže. Tím se prompt zaměřuje na úkol a cíl. Příklad:

V přiloženém dokumentu RVP ZV 2025 najdi všechny očekávané výstupy v oblasti Člověk a příroda, které se týkají vodního hospodářství a povodní.

Vypiš je v tabulce s těmito sloupci:

kód OVU, plné znění OVU, ročník, návrh mezipředmětového propojení.

Tento prompt předpokládá, že je v RAG nástroji nahrán dokument RVP ZV. Bez něj by stejný prompt v samostatném LLM asistentovi vrátil obecnou odpověď s vysokým rizikem halucinace. S přiloženým dokumentem dostává uživatel konkrétní, ověřitelnou tabulku, která vychází přímo z oficiálního textu — model „nemá kde halucinovat“.

Pro učitele to znamená novou kvalitu práce. Pomocí RAG režimu může vytvořit pracovní prostředí, ve kterém má průběžně k dispozici RVP ZV, vzdělávací oblasti svého aprobačního předmětu, používané učebnice a metodické dokumenty — a v něm vést konverzaci s AI asistentem o přípravě vlastní výuky. Konkrétní pracovní postupy v této kvalitativní rovině rozpracujeme v podkapitole 4.

Iterace — promptování není střelba do terče

Začínající uživatelé LLM asistenta často přistupují k promptování jako ke střelbě do terče: napíšu prompt, pošlu ho, dostanu odpověď, a pokud odpověď nesedí, prohlásím, že AI „neumí“ co jsem chtěl. Toto je **nejčastější příčina zklamání z práce s AI** — a zároveň dovednost, kterou je nejjednodušší změnit.

Označení **chatbot** v sobě obsahuje slovo „chat“ — anglicky **konverzace**. To není terminologická náhoda. Práce s LLM asistentem je svou povahou **konverzační** — série dotazů, odpovědí, upřesnění a reakcí, která postupně dovede obě strany k dohodě o tom, co vlastně potřebujeme. Užitečnou pomůckou pro pochopení tohoto rytmu je všední situace: když na ulici potkáme přítele a domlouváme si společnou schůzku na kávu, málokdy to vyřešíme jednou větou. Probíhá série výměn — „Co bys řekla na čtvrtek?“ — „Čtvrtek mi nesedí, co pátek?“ — „Pátek dobrý, kde?“ — „Třeba u nás v centru?“ — „Jo, v kolik?“ — než se obě strany rozejdou s bezpečným pocitem, že vědí, kdy, kde a proč se setkají. Promptování s LLM asistentem má často podobnou strukturu.

Tato analogie má své limity, ke kterým se vrátíme v podkapitole 6. Chatbot není přítel a konverzace s ním je technická, ne sociální — model nemá vlastní zájem, dlouhodobou paměť mimo aktuální chat ani vztah k uživateli. Pro pochopení iterativního rytmu je ale tato pomůcka funkční.

Promptování je **iterativní proces**. První odpověď model málokdy trefí přesně do toho, co uživatel potřebuje, protože uživatel sám v prvním promptu málokdy přesně formuluje, co potřebuje. Z toho vyplývá několik praktických principů:

První odpověď čteme jako diagnostiku, ne jako finální výstup. Zjišťujeme z ní, kde model dotaz pochopil dobře a kde ho pochopil jinak, než jsme zamýšleli. Tato informace je sama o sobě cenná — naznačuje, co v promptu chybělo.

Druhý prompt nepíšeme od nuly. V téže konverzaci pokračujeme upřesněním: „To je dobrý začátek, ale potřebuji...“ — nebo „Otázky 1 a 3 jsou v pořádku, ostatní přepiš tak, aby...“ — nebo „Zaměř se prosím víc na...“. Model si pamatuje předchozí výměny a postupně se přibližuje k tomu, co uživatel skutečně potřebuje.

Po dvou až třech iteracích se ptáme: vyplatí se pokračovat, nebo začít znovu? Pokud se odpovědi přibližují, pokračujeme. Pokud se vzdalují nebo stagnují, je často efektivnější otevřít novou konverzaci a napsat zlepšený prompt od začátku, využívající poznatky z neúspěšné iterace.

Iterace je didaktická hodnota. Učitel, který se naučí vést iterativní konverzaci s AI, se zároveň učí přesněji formulovat své vlastní pedagogické záměry. Tato dovednost má hodnotu i mimo práci s AI — pomáhá při tvorbě zadání pro žáky, formulaci učebních cílů i komunikaci s rodiči.

Vývoj jednoho promptu ve třech iteracích

Pro názornost ukážeme, jak se vyvíjí prompt učitele geografie, který chce vytvořit motivační úvod k hodině o suchu v české krajině. Postupně sledujeme tři iterace stejného úkolu.

První iterace — vágní prompt.

Napiš motivační úvod k hodině o suchu.

Tento prompt postrádá kontext (komu je úvod určen), parametry (jakou má mít formu, délku, styl) i cíl (co má úvod vyvolat u žáka). Model se pokusí odhadnout typický scénář a vrátí pravděpodobně obecný odstavec o tom, že sucho je závažný globální problém, s několika klimatickými statistikami. Učitel přečte odpověď a zjistí, že ji v takové podobě v hodině nepoužije — je příliš obecná, příliš odborná, není zaměřená na české prostředí, není navržena tak, aby zaujala konkrétní věkovou skupinu.

Druhá iterace — doplnění kontextu a parametrů.

Jsem učitel geografie 2. stupně ZŠ. Připravuji hodinu pro 8. ročník v Libereckém kraji o suchu v české krajině. Napiš motivační úvod do hodiny v rozsahu cca 200 slov. Měl by být psaný jazykem přiměřeným osmákovi a měl by se opírat o konkrétní situaci, kterou žáci mohou znát z vlastního okolí.

Druhá iterace doplňuje kontext (učitel, ročník, region) a parametry (rozsah, jazyk, opora o konkrétní situaci). Model nyní vrací výrazně konkrétnější odpověď — pravděpodobně začíná líčením vyschlého potoka nebo polabské krajiny v létě, jazykově se přibližuje žákovi 8. ročníku, je v doporučeném rozsahu. Kvalitativní skok oproti první iteraci je značný.

Co stále chybí? **Cíl** — co má úvod u žáka vyvolat. Učitel může chtít, aby úvod žáka motivoval k otázkám, k diskuzi, k osobnímu zaujetí, případně aby spojil sucho s konkrétním tématem hodiny (například s vodním hospodářstvím, půdou, zemědělstvím nebo klimatickou změnou). Bez vyjádření cíle model volí mezi těmito možnostmi sám.

Třetí iterace — doplnění cíle.

Jsem učitel geografie 2. stupně ZŠ. Připravuji hodinu pro 8. ročník v Libereckém kraji o suchu v české krajině. Napiš motivační úvod do hodiny v rozsahu cca 200 slov.

Cíl úvodu: vyvolat u žáků otázku, proč právě v posledních letech přibývá období sucha, i když se ČR nachází v mírném pásu. Úvod má naladit žáky na následnou diskuzi o vodním hospodářství v krajině a o tom, co může samospráva i jednotlivce dělat.

Forma: psaný jazyk přiměřený osmákovi, opora o konkrétní krajinu, kterou žáci znají z vlastního okolí. Ukončit otázkou, která přejde do následné diskuze.

Třetí iterace už obsahuje všechny tři komponenty. Model nyní vrací úvod, který je nejen jazykově a obsahově vhodný, ale je **funkčně navržený** pro konkrétní pedagogický záměr — končí otevřenou otázkou, naviguje žáky směrem k tématům, která má hodina pokrýt, a propojuje sucho s aktivním rolí samosprávy a jednotlivce.

Tato třetí verze je výsledkem zhruba dvou minut formulační práce. Investice se vrátila ve formě výstupu, který je v hodině přímo použitelný — místo obecného textu, který by učitel musel kompletně přepisovat. **Toto je rozdíl mezi promptováním a „zadáváním otázek do AI“.**

Co dál po třetí iteraci? Učitel dostane od modelu motivační úvod, který je ve své první podobě v hodině použitelný. Tím ale práce s konverzací nemusí končit. Konverzační logika LLM asistenta otevírá řadu přirozených pokračování. Učitel může požádat o variantu pro slabšího žáka:

Skvělé. Teď mi prosím připrav stejný úvod v jednodušší jazykové verzi — pro žáka, který má slabší čtenářskou gramotnost. Zachovej stejný cíl a stejnou závěrečnou otázku.

Nebo o převedení úvodu do podoby použitelné v pracovním listu:

Doplň prosím k úvodu krátký pracovní list:
tři úvodní otázky pro žáky, na které mohou odpovědět ve dvojicích před začátkem hodiny.
Otázky mají vést k otevřené diskuzi, ne k jednoznačné odpovědi.

Případně o test, zda úvod funguje pro odlišný kontext:

Pokud bych stejnou hodinu učil v jihočeském regionu (například okolí Třeboně, kde je vodohospodářský kontext jiný), jak bys upravil/a úvod, aby byl pro žáky stejně blízký? Zachovej délku a strukturu.

Každý takový dotaz pokračuje v téže konverzaci a využívá toho, že model si pamatuje vše, co bylo řečeno dříve. **Z původního dvouminutového promptu se tak postupně stává funkční sada didaktických materiálů**, kterou by ručně vytvořit zabralo násobně víc času. To je hlavní praktický důsledek toho, že chatbot je *chat* — konverzace, která plodí výstupy, jak postupuje.

Stejný prompt napříč nástroji

Jeden ze základních principů této kapitoly zní: **principy promptování jsou univerzální napříč LLM asistenty**. Stejný prompt, který jsme rozvíjeli v předchozí ukázce, lze zkopírovat do Claude, ChatGPT, Gemini i dalších nástrojů a získat z nich srovnatelně použitelné výstupy. Konkrétní formulace odpovědi se mezi nástroji liší — různí asistenti mají různý „styl psaní“, různě silné stránky v některých typech úkolů, různý vztah k českému jazyku — ale fundamentální logika promptu funguje napříč.

Tento poznatek má praktický důsledek pro studenta učitelství: **investice do promptové gramotnosti není investicí do konkrétního produktu**. Když se osvojí formulace promptů s třemi komponentami, strukturováním a iterativním přístupem, dovednost přetrvá, i když se konkrétní nástroje za pět let radikálně promění. Stejně tak má smysl si **zvyknout na jeden nástroj jako na hlavní pracovní prostředí** — důvěrná znalost konkrétního produktu (jeho specifik, silných stránek, omezení, ceníku) má svou hodnotu — ale nezavírat se před ostatními. Pro některé úkoly bude jeden nástroj zřetelně silnější než druhý a stojí za to si toho být vědom.

Rychlé čtení podkapitoly 2

Tato podkapitola představila promptování jako základní dovednost práce s LLM asistentem. Pro orientaci shrneme klíčová pravidla.

Hlavní teze: kvalita výstupu je především funkcí kvality vstupu. Investice do promptování se vrací v podobě výrazně lepších výsledků a je přenositelná napříč nástroji.

Tři komponenty dobrého promptu:

1. **Kontext** — kdo jsem, pro koho tvořím, v jaké situaci.
2. **Úkol a parametry** — co konkrétně chci, v jakém rozsahu, formátu, stylu.
3. **Cíl a kritéria úspěchu** — k čemu má výstup sloužit, podle čeho poznám, že je dobrý.

Komponenta cíle je nejčastěji vynechávána a její doplnění obvykle přináší největší skok v kvalitě.

Strukturování promptu: delší prompty rozdělit do sekcí oddělených prázdnými řádky a popisky (Kontext, Úkol, Výstup). Pomáhá modelu i samotnému uživateli při kontrole úplnosti zadání.

RAG promptování: v režimu s přiloženými dokumenty (NotebookLM, Claude Projects, ScioBot s nahranými materiály) se kontext z velké části přesouvá do dokumentů a prompt se zaměřuje na úkol a cíl. Pro učitele to otevírá kvalitativně novou rovinu práce — například konverzaci nad RVP ZV nebo používanou učebnicí.

Iterace je normou, ne známkou neúspěchu:

- první odpověď čteme jako diagnostiku, ne jako finální výstup
- druhý prompt nepíšeme od nuly — pokračujeme v téže konverzaci upřesněním
- po dvou až třech iteracích posoudíme, zda se přibližujeme nebo stagnujeme
- konverzace pokračuje přirozenými pokračováními (varianty, pracovní listy, jiný kontext)

Univerzálnost napříč nástroji: principy promptování fungují v Claude, ChatGPT, Gemini i dalších asistentech. Investice do promptové gramotnosti není investicí do konkrétního produktu.

Nejčastější chyba začátečníků: zacházet s LLM asistentem jako se „střelbou do terče“. Promptování je konverzace, ne dotaz s jednou odpovědí.

V této podkapitole jsme krátce zmínili, že chatbot není přítel — je to nástroj, jehož konverzační podobu nelze zaměňovat se sociálním vztahem. Toto pozorování otevírá širší a ve veřejné diskuzi často kladenou otázku: **Může AI nahradit lidského učitele?** Odpověď se rodí z porozumění tomu, jakou roli AI ve vzdělávání hraje, k čemu je kvalifikovaná, a kde leží její principiální limity. Právě tomu se věnuje následující podkapitola — představuje teoretický rámec pro reflexi rolí AI ve vzdělávání a empirickou evidenci o jejím vlivu na učení. Otázka po nahraditelnosti učitele bude tematickým obloukem celé podkapitoly 3 a vrátí se k ní i podkapitola 6, kde rozpracujeme epistemické limity AI.

3. AI ve vzdělávání

Proč tato podkapitola

Předchozí podkapitoly představily AI jako technologii a ukázaly, jak s ní prakticky pracovat. To je nutné předpolí, ale samo o sobě nestačí. Učitel, který umí promptovat, ale nerozumí, **v jaké roli** AI při výuce vystupuje a **jaký dopad** na učení má, riskuje, že nasadí silný nástroj nepromyšleně. Tato podkapitola přidává druhou vrstvu kompetence — orientační rámec pro reflexi rolí AI ve vzdělávání a empirickou evidenci o jejím vlivu na učení.

Podkapitola pracuje se třemi opěrnými studiemi. Nejde o tvrzení, že tyto studie jsou nejlepší nebo nejvýznamnější dostupné — jsou to **vybrané práce**, které dobře reprezentují tři roviny současného odborného diskurzu o AI ve vzdělávání: rovinu teoretického rámce (Ouyang a Jiao, 2021), rovinu empirické evidence (Wang a Fan, 2025) a rovinu kompetenčního modelování (Sanusi a kolektiv, 2022). Pro hlubší orientaci v tématu doporučujeme studentům prostudovat i další zdroje — výběr je uveden v seznamu doporučené literatury na konci kapitoly.

V průběhu podkapitoly se vrátíme k otázce, kterou jsme otevřeli na konci podkapitoly 2: **Může AI nahradit lidského učitele?** Odpověď, ke které dojdeme, není ano nebo ne. Spočívá v rozpoznání toho, **co AI dělá dobře, co dělá hůře a co principiálně nemůže dělat vůbec** — a v didaktickém umění tyto roviny od sebe rozlišit.

Tři role AI ve vzdělávání

Ouyang a Jiao (2021) systematizují tři odlišné role, kterými AI může vstupovat do učebního procesu. Označují je jako tři paradigmata AI ve vzdělávání — termín paradigma zde znamená propojení teoretického základu, role AI a role žáka v daném pedagogickém uspořádání. Tři role představují jak historický vývoj AI ve vzdělávání, tak typologii, která stále popisuje různé způsoby nasazení AI v dnešní praxi. Pro učitele jsou tyto role **diagnostickým rámcem** — pomáhají rozpoznat, ve které z nich AI v konkrétní hodině vystupuje.

První role: AI řídí, žák přijímá (*AI-directed, learner-as-recipient*)

V této roli AI **řídí** učební proces: reprezentuje znalosti, předepisuje pořadí výukových kroků, hodnotí odpovědi jako správné nebo špatné, posouvá žáka po předem dané trase. Žák je v roli

příjemce — reaguje na předem nastavené sekvence úkolů, jeho individuální potřeby, zájmy a cíle nejsou systémově zohledňovány. Teoretickým základem je behaviorismus.

Modernější příklad této logiky představují adaptivní cvičebné platformy, kde algoritmus žákovi předkládá další úlohu na základě úspěšnosti předchozí. Žák se po systému pohybuje, ale nevolí si trasu, neformuluje si vlastní cíle, nediskutuje s nástrojem o smyslu úkolu.

Hlavní limit první role spočívá v tom, že AI funguje jako „černá skříňka“. Žák nemá vhléd do toho, **proč** mu systém předkládá právě tuto úlohu, **podle čeho** posuzuje úspěch, **kam** ho cesta vede. Tato neprůhlednost je přijatelná pro dobře definované problémy s jednoznačnou správnou odpovědí, ale stává se problematickou v okamžiku, kdy se učení dotýká **otevřených otázek**, hodnotových soudů, kontextové interpretace.

V geografickém vzdělávání je tato role vhodná například pro procvičování místopisu — adaptivní aplikace, ve které žák opakovaně určuje polohu států, řek a pohoří, dává okamžitou zpětnou vazbu o správnosti. Naopak nevhodná je pro výuku témat jako prostorové nerovnosti, klimatická spravedlnost nebo územní konflikty, kde neexistuje jediná správná odpověď a kde je interpretační rámec sám o sobě předmětem reflexe.

Druhá role: AI a žák spolupracují (*AI-supported, learner-as-collaborator*)

V této roli AI opouští direktivní řízení a stává se **podpůrným nástrojem**. Sbírá data o průběhu žákova učení, adaptivně upravuje model toho, co žák ví a v čem tápe, nabízí cesty hlouběji nebo jinam. Žák je v roli **spolupracovníka** — komunikuje s AI, klade otázky typu „proč?“ a „co kdyby?“, spolurozhoduje o směru učení. Učení je aktivní a kontextuální. Teoretickým základem je kognitivní a sociální konstruktivismus.

Současní LLM asistenti využívají v režimu otevřeného dialogu — kdy žák zadává otázky podle vlastního zájmu, AI vysvětluje, žák reformuluje, AI nabízí alternativu — odpovídají do značné míry této roli. Hlavním limitem je nedostatečná kontinuita interakce: komunikace mezi žákem a AI je zpravidla úsekovitá, ne průběžná. AI zatím nedokáže udržet dlouhodobý kontext žákova vývoje, jeho cíle, jeho příběh.

V geografickém vzdělávání je tato role vhodná například pro práci se starými mapami, kdy žák s AI diskutuje o tom, co konkrétní mapa zobrazuje, co opomíjí, jaký byl politický kontext jejího vzniku. AI zde funguje jako partner pro hlubší pochopení mapy jako geomédia. Méně vhodná je pro výuku, kde má žák provést samostatný terénní výzkum — AI nemůže nahradit autentickou zkušenost s místem, na které žák musí dojít, pozorovat ho a popsat.

Třetí role: AI zmocňuje, žák vede (*AI-empowered, learner-as-leader*)

V této roli AI žáka **zmocňuje**: poskytuje mu transparentní, interpretovatelnou podporu, respektuje jeho hodnoty a cíle, rozšiřuje jeho lidské poznávání, místo aby ho nahrazovala. Žák je v roli **lídra** vlastního učení — rozhoduje, reflektuje, informuje AI o svých záměrech. Zároveň nese odpovědnost za rizika automatizovaných rozhodnutí: zda výstupu AI věřit, jak ho ověřit, jak ho použít. Žák je tedy schopen **vlastního jednání a iniciativy** (anglicky agency, v české didaktice

také aktérství žáka, jak tento pojem rozpracovává Spilková). Teoretickým základem je konektivismus a teorie komplexních adaptivních systémů.

Klíčovým konceptem této role je **rozšířená inteligence** (augmented intelligence) — pojetí AI jako nástroje, který lidské myšlení doplňuje a rozšiřuje, ale konečné rozhodnutí ponechává člověku. AI nabízí podklad, analyzuje, navrhuje varianty; člověk vyhodnocuje, vybírá, nese odpovědnost.

Ouyang a Jiao (2021) zdůrazňují, že tato role je **vývojový trend** — žádoucí směr AI ve vzdělávání, který je v praxi zatím velmi málo naplněný. Současní LLM asistenti mají potenciál pohnout vzdělávání směrem k této roli, ale sami o sobě k tomu nestačí. Klíčem je **didaktické zarámování** — způsob, jakým učitel s nástrojem zachází.

V geografickém vzdělávání je tato role vhodná například pro projektovou práci, ve které žák zkoumá konkrétní lokální problém (úbytek vody v krajině, dopad nové dálnice, změna využití zemědělské půdy) a AI mu pomáhá strukturovat poznatky, generovat hypotézy, hledat protiargumenty. Žák zůstává autorem výzkumu i jeho závěrů. Méně vhodná je tato role tam, kde žákům zatím chybí základní dovednosti samostatné práce — bez nich se „lídrovství“ mění v rezignaci na vedení a žák začíná AI nekriticky následovat, čímž padá do první role.

Srovnání rolí

Pro orientaci uvádíme srovnání tří rolí v přehledné podobě.

	PRVNÍ ROLE	DRUHÁ ROLE	TŘETÍ ROLE
Role AI	ředitel procesu	podpora, spoluhráč	nástroj rozšířené inteligence
Role žáka	příjemce služby	spolupracovník	lídr vlastního učení
Teoretický základ	behaviorismus	konstruktivismus	konektivismus, komplexita
Typické úlohy v geografickém vzdělávání	procvičování místopisu	práce se starými mapami, řízený dialog nad učivem	projektová práce nad lokálním problémem

Posun mezi rolemi není lineárním nahrazením — role se nevylučují. V praxi je často kombinujeme: tentýž nástroj může v jedné situaci fungovat v první roli a v jiné v třetí, podle toho, **jak ho učitel a žák používají**.

Toto pozorování je pro pochopení LLM asistentů zásadní.

Kde stojí dnešní LLM asistenti?

LLM asistent — Claude, ChatGPT, Gemini — sám o sobě **do žádné z rolí nepatří**. Rozhoduje způsob jeho použití. Tentýž nástroj může v praxi fungovat ve všech třech rolích:

- jako **první role**, když žák použije nástroj k vygenerování hotového testu nebo referátu, který nekriticky odevzdá;
- jako **druhá role**, když žák použije nástroj jako pomocníka při řešení úkolu, který sám aktivně vede a s nástrojem diskutuje;
- jako **třetí role**, když nástroj slouží jako partner reflexe — pomáhá žákovi formulovat vlastní učební cíle, zpochybňovat vlastní řešení, posuzovat kvalitu vlastní práce.

Tato pluralita rolí je důsledkem toho, že LLM asistent je **obecně použitelný nástroj**, ne specializovaný systém s jednou pedagogickou logikou. Stejně jako papír a tužka mohou být nástrojem direktivního diktátu i otevřené tvůrčí práce, LLM asistent přijímá podobu, kterou mu dá uživatelská praxe.

Otázka, kterou tato pluralita otevírá, je velmi konkrétní: **kteřá z těchto rolí dnes ve školní praxi dominuje — a která by měla?** Empirická evidence, kterou rozpracujeme v následující podsekci, naznačuje znepokojivou odpověď.

Empirická evidence — co o LLM asistentech víme z výzkumu

Wang a Fan (2025) publikovali rozsáhlou metaanalýzu 51 experimentálních a kvazi-experimentálních studií, které zkoumaly vliv LLM asistentů (především ChatGPT) na učení žáků a studentů. Studie pokrývají období od listopadu 2022 do února 2025 a zahrnují celkem 72 nezávislých efektů.

Co je to metaanalýza? Metaanalýza je výzkumná metoda, která statisticky kombinuje výsledky řady původních studií zkoumajících podobnou otázku. Místo toho, aby autoři provedli vlastní experiment, sesbírají všechny dostupné kvalitní studie k tématu a spočítají z nich souhrnný efekt. Výhodou je, že syntéza desítek studií dává spolehlivější odpověď než jakákoliv jednotlivá studie sama o sobě. Limitem je, že metaanalýza je vždy závislá na kvalitě a srovnatelnosti původních studií. Pro budoucího učitele jsou výsledky této metaanalýzy první spolehlivou kvantitativní orientací v terénu, kde do té doby panovala spíš anekdotická diskuze.

Krátká poznámka k aplikovatelnosti: studie sice zkoumá specificky **ChatGPT**, ale závěry interpretujeme **jako platné pro kategorii LLM asistentů obecně**. Jde o drobné rozšíření platnosti — konkrétní efekty v jiných nástrojích se mohou číselně lišit, ale principiální vzorce (co se zlepšuje víc, co míň, jaké faktory hrají roli) lze přenášet napříč. Kde to bude pro výklad důležité, uvedeme to explicitně.

Jak číst velikost efektu

Wang a Fan používají standardizovanou míru velikosti účinku **Hedges's g**. Pro učitele, který se s touto mírou nesetkává každý den, postačí jednoduchý interpretační rámec (Sawilowsky, 2009):

HODNOTA G	INTERPRETACE
0,0 – 0,2	velmi malý efekt
0,2 – 0,5	malý efekt
0,5 – 0,8	střední efekt
0,8 – 1,2	velký efekt
1,2 – 2,0	velmi velký efekt

Velikost efektu g neříká nic o **statistické významnosti** výsledku — všechny zde uváděné efekty jsou statisticky významné. Říká, **jak moc** se experimentální skupina lišila od kontrolní v praktickém smyslu.

Tři klíčové efekty

Metaanalýza měřila vliv LLM asistentů ve třech oblastech: učební výkon (typicky výsledky testů a hodnocení), učební vnímání (motivace, sebedůvěra, postoj k učení) a myšlení vyššího řádu (kritické myšlení, tvořivost, schopnost analýzy). Výsledky:

OBLAST	HEDGES'S G	INTERPRETACE
Učební výkon	0,867	velký efekt
Učební vnímání	0,456	střední efekt
Myšlení vyššího řádu	0,457	střední efekt

První čtení těchto čísel vypadá optimisticky. LLM asistenti **opravdu zlepšují učení** — a to ve všech třech oblastech statisticky významně. Druhé, pozornější čtení odhalí znepokojivou disproporci, která dala této kapitole její otevřenou otázku.

Paradox výkonu a myšlení vyššího řádu

Efekt LLM asistentů na učební výkon ($g = 0,867$) je **téměř dvakrát větší** než efekt na myšlení vyššího řádu ($g = 0,457$). Co je nejvíc vidět — testy, známky, hodnocení — zlepšuje AI nejvíc. Co je pro geografii a humanitní obory **klíčové** — kritická analýza, tvořivost, schopnost autonomního úsudku — zlepšuje výrazně méně.

Wang a Fan tuto disproporci vysvětlují technickou povahou LLM. Velký jazykový model dokáže strukturovaně a srozumitelně předat látku, vysvětlit pojmy, poskytnout odpovědi na učební úkoly — to vede k rychlému zvýšení výkonu. Zároveň se ale model opírá o trénovací data a

pravděpodobnostní predikce, což omezuje jeho kapacitu pro skutečně **kritickou analýzu** a tvořivá řešení nových problémů. Nepřesnosti v generovaném obsahu mohou kritické myšlení žáka dokonce **brzdit**, protože vytvářejí falešný pocit jistoty.

Z tohoto pozorování plyne pro učitele **klíčový didaktický důsledek**: LLM asistent **bez pedagogického zarámování** snadno propadá do první role — zvyšuje výkon, ale utlumuje myšlení. Pro třetí roli — pro takové použití AI, kdy žák zůstává lídrem vlastního učení — je nutná **vědomá didaktická práce**. Ta zahrnuje například:

- explicitní zarámování úkolu Bloomovou taxonomií (pohnout žáka k vyšším kognitivním úrovním analýzy, hodnocení, tvorby);
- požadavek, aby žák **zhodnotil** výstup AI, ne ho jen převzal;
- konfrontaci výstupů z různých AI nástrojů, která vyvolává kritické posouzení;
- propojení AI s aktivitami, které AI nemůže nahradit (terénní práce, interview, vlastní pozorování).

K této didaktické práci se vrátíme v podkapitole 4 a v podkapitole 6.

Které faktory zesilují nebo oslabují efekt

Metaanalýza neidentifikovala jen tři hlavní efekty, ale i řadu **moderátorů** — proměnných, které významně ovlivňují, jak silně AI působí. Pro učitele jsou tři z nich obzvláště poučné.

Typ kurzu významně moderuje efekt na výkon. Nejsilnější efekt LLM asistentů byl pozorován u kurzů zaměřených na rozvoj **dovedností** ($g = 0,874$). Jazyky a psaní následují ($g = 0,531$). Naopak nejmenší efekt byl pozorován u **STEM kurzů** ($g = 0,311$). Geografie do STEM patří, ale jen částečně — je to **hybridní disciplína se syntetizujícím charakterem**. Sdílí s STEM obory metodologické rysy (práce s daty, modelování, technologie, prostorové analýzy), ale zároveň STEM přesahuje důrazem na **interpretaci, kontext a komplexitu prostorových vztahů**, kterými má blíž k humanitním vědám. Empirické zjištění Wang a Fan o STEM oborech proto pro geografii **není přesnou predikcí**. Reálný efekt v geografickém vzdělávání pravděpodobně leží mezi STEM efektem ($g = 0,311$) a vyššími hodnotami zjištěnými u jazykově orientovaných kurzů. Pro učitele to znamená, že **STEM evidence je pro geografii orientačním vodítkem, ne přesným číslem**.

Model výuky moderuje efekt ještě silněji. Nejvyšší efekt byl pozorován v **problémové výuce** (problem-based learning, $g = 1,113$) — tedy v didaktickém uspořádání, kdy žák řeší autentický otevřený problém a AI mu pomáhá. To dává geograficky orientovanému učiteli silnou indicii: **kombinace problémově orientované výuky s LLM asistentem** je podle evidence nejnadějnější cesta. Naproti tomu projektová výuka, ve které žáci dlouhodobě pracují na komplexních projektech, vykazuje nízký efekt ($g = 0,239$) — autoři interpretují tento výsledek tak, že komplexnost projektů přesahuje kapacitu LLM asistenta, který umí pomoci s dílčími úkoly, ale ne s integrací celku.

Doba intervence moderuje efekt jednou z nejpřekvapivějších věcí v metaanalýze:

DOBA INTERVENCE	G
do 1 týdne	0,332
1–4 týdny	0,428
4–8 týdnů	0,999
nad 8 týdnů	0,531

Optimum efektu je při intervenci v délce **4 až 8 týdnů**. Krátké intervence (do týdne) přinášejí malý efekt — žáci se teprve učí promptovat, ještě nemají vybudovaný rytmus. Dlouhé intervence (nad 8 týdnů) **přinášejí pokles efektu** — autoři interpretují tento jev jako důsledek **nadměrné závislosti** na nástroji. Žáci, kteří s AI pracují příliš dlouho, přestávají rozvíjet vlastní dovednosti, které AI dělá za ně.

Tato čísla mají pro učitele jasnou didaktickou implikaci: LLM asistent **není „naučte se jednou, používejte navždy“ nástroj**. Je to nástroj pro cílené, časově ohraničené období. Po čtyřech až osmi týdnech intenzivního používání má smysl zařadit alternativu, vrátit se k nástrojům bez AI nebo aspoň přesměrovat AI do jiné role.

Kterou roli v AI nasadit

Posledním zkoumaným moderátorem je **role**, ve které AI funguje. Wang a Fan rozlišují tři hlavní role:

ROLE AI	G (MYŠLENÍ VYŠŠÍHO ŘÁDU)
Inteligentní tutor	0,945
Inteligentní nástroj	0,480
Inteligentní partner	0,399

Nejsilnější efekt na myšlení vyššího řádu nastává tehdy, když AI funguje jako **inteligentní tutor** — tedy když poskytuje žákovi strukturovanou individuální zpětnou vazbu, vede ho, hodnotí, navrhuje další kroky. To je didakticky náročnější použití než „inteligentní nástroj“, kdy AI jen vyhledává nebo sumarizuje, a vyžaduje **kvalitní prompty**, které samotnou roli tutora vytvoří.

Pro učitele to znamená, že kvalita didaktického dopadu AI úzce souvisí s tím, **jak je AI v hodině zarámovaná**. Stejný nástroj použitý jako „rychlý zdroj informací“ vyvolá menší efekt než tentýž nástroj nasazený jako „individuální tutor s konkrétním učebním cílem“. Návrat k základnímu poznatku z podkapitoly 2: kvalita výstupu je především funkcí kvality vstupu.

Kompetence pro práci s AI

Kompetenční rámec, který představíme, vychází z práce Sanusi a kolektivu (2022). Jeho jádro tvoří typologie pěti vzájemně propojených kompetencí pro AI gramotnost. V této podkapitole rámec **adaptujeme pro českou učitelskou přípravu** — primárně jako kompetence budoucího učitele, sekundárně jako kompetence, které učitel rozvíjí u žáků.

Pro mezinárodní kontext je relevantní přiřadit k Sanusimu i kompetenční rámce vydávané UNESCO. Pro učitele je k dispozici samostatný *AI Competency Framework for Teachers* (Miao & Cukurova, 2024), který strukturuje kompetenci do pěti aspektů (human-centred mindset, etika AI, základy a aplikace AI, AI v pedagogice, AI pro vlastní profesní rozvoj) ve třech úrovních progrese (osvojit, prohloubit, tvořit). UNESCO současně publikovalo paralelní rámec pro žáky (Miao & Shiohira, 2024). V této podkapitole pracujeme primárně s rámcem Sanusi a kolektivu, který je strukturně jednodušší a pro úvod do tématu vhodnější; oba UNESCO rámce doporučujeme studentům prostudovat samostatně jako rozšiřující materiál. Strukturně se rámce navzájem neopírají o sebe, ale doplňují — pro praxi učitele přinášejí všechny tři vzájemně kompatibilní pohledy.

Pět kompetencí pro práci s AI:

KOMPETENCE	PRO UČITELE ZNAMENÁ	PRO ŽÁKA ZNAMENÁ
Kognitivní	analyzovat výstupy AI, posuzovat jejich kvalitu, rozpoznat halucinaci, kontextualizovat informace	porozumět tomu, co AI předkládá, srovnávat to s tím, co už ví
Dovednostní	logicky strukturovat prompt, rozpoznat platnost argumentu, kriticky číst	obojí ve věkově přiměřené míře
Samostatné učení	osvojit si práci s novými nástroji bez návodu, iterativně se zlepšovat, vzdělávat se	umět samostatně formulovat dotaz a kriticky přijmout odpověď
Týmová práce	sdílet dobrou praxi a prompty s kolegy, učit se ze zkušeností druhých	spolupracovat se spolužáky při práci s AI, srovnávat výstupy, diskutovat
Spolupráce s nástrojem	kvalifikovaně použít LLM asistent, ale i rozeznat, kdy ho nepoužít	vědět, k čemu AI slouží a kde její pomoc nestačí

Pět kompetencí spolu interaguje. Kognitivní kompetence funguje jako základ — ovlivňuje rozvoj všech ostatních. Spolupráce s nástrojem a týmová práce mají největší přímý vliv na samotné používání AI v praxi. To je samo o sobě didakticky zajímavé pozorování: **AI gramotnost není primárně technická dovednost, ale dovednost spolupráce** — s nástrojem i s druhými lidmi.

Pro učitele má rámec dvě funkce. Za prvé je to **mapa vlastní kompetenční přípravy**: učitel může kriticky reflektovat, ve které z pěti kompetencí je silný a kterou potřebuje rozvíjet. Za druhé je to **mapa pro rozvoj žáků**: stejných pět kompetencí se týká i jeho žáků — s tím rozdílem, že učitel je v roli toho, kdo žákovo osvojení těchto kompetencí promyšleně organizuje. Vědomí,

že se učitel a žák pohybují v témže kompetenčním rámci, jen v různých rolích, je důležitým východiskem pro autentické učitelství v éře AI.

Most k modelu RAP

Kompetenční rámec se zaměřuje na **kognitivní a dovednostní** rovinu. Pro geografické vzdělávání s emancipační orientací — tak, jak ho rozpracovává tato série textů — je nutné připojit **třetí rovinu**: rovinu reflexivně-občanskou. Tu nabízí model RAP (Jekel a kolektiv, 2025), který jsme představili v kapitole o geomédiích.

KROK MODELU RAP	APLIKACE NA PRÁCI S AI
Reflexe	Co AI produkuje? Proč právě tento výstup? Z jakých dat čerpá?
Argumentace	Jak s výstupem nakládat? Jaké argumenty mluví pro jeho použití, jaké proti?
Participace	Jak výstup AI a získané poznatky využít pro sociální prostor — sdílet je s kolegy a žáky, přispět jimi do veřejné diskuze, posílit kolektivní pedagogickou kompetenci?

Třetí krok modelu RAP je v kontextu AI ve vzdělávání obzvlášť důležitý. Participace tu neznámá jen použití AI pro vlastní účel. Znamená i **sdílení získaných poznatků dál** — s kolegy v učitelském sboru, s žáky při výuce, ve veřejné diskuzi o AI ve vzdělávání. Učitel, který kvalifikovaně pracuje s AI a sdílí vlastní zkušenost s úspěchy i neúspěchy, posiluje kolektivní pedagogickou kompetenci v širším společenství. Bez této participativní dimenze by AI gramotnost zůstala individuální dovedností, místo aby se stala součástí společné profesní kultury.

Spojení kompetenčního rámce s modelem RAP je didaktickým ukotvením, ze kterého vychází podkapitoly 4 a 6.

Vrátíme se k otevřené otázce

Otevřeli jsme tuto podkapitolu otázkou: **Může AI nahradit lidského učitele?** Co na ni říkají tři probrané studie?

Odpověď v rolích. V první roli — kde jde o předávání hotových odpovědí a hodnocení správnosti — část funkcí učitele AI **technicky zvládá**. Adaptivní cvičebné systémy doplňují učitele v této roli už dnes. Ve druhé a třetí roli — kde jde o spolupráci, vedení, rozvoj žákovy iniciativy a kritického myšlení — se AI dostává k principiálním limitům. Může roli učitele **doplnit**, ale ne nahradit.

Odpověď v evidenci. Wang a Fan ukázali, že LLM asistenti nejsilněji zvyšují **výkon** a nejslaběji **myšlení vyššího řádu**. To znamená, že tam, kde se geografické vzdělávání odehrává nejhluběji

— v kritickém myšlení, kontextové interpretaci, rozvoji geografického citění — je dopad AI nejmenší. Tato práce zůstává primárně prací učitele.

Odpověď v kompetenci. Sanusi a kolektiv ukázali, že AI gramotnost je především dovednost **spolupráce s nástrojem** a s druhými lidmi, ne dovednost technická. Učit žáky **spolupracovat s AI** dokáže jen ten, kdo to sám umí — a kdo si umí v dané chvíli **odložit AI stranou** a nahradit ji jinou pedagogickou metodou. Tato meta-kompetence je principiálně lidská.

Souhrnná odpověď: **AI nemůže nahradit lidského učitele, ale mění jeho roli.** Učitel přestává být primárně zdrojem informací (v této roli ho AI částečně doplňuje) a stává se průvodcem, který žákovi pomáhá rozumět tomu, **jak s AI pracovat, kdy s ní nepracovat, a jak její výstupy zařadit do vlastního myšlení o světě.** Tato role je principiálně lidská a její důležitost s nástupem AI **roste**, ne klesá.

V podkapitole 4 přejdeme od obecného AI ve vzdělávání ke konkrétnímu AI v geografickém vzdělávání. Probereme oblasti, kde AI v geografii přináší jasnou hodnotu, oblasti, kde naopak nestačí, specifika promptování pro geografické úkoly a roli specializovaných platforem (NotebookLM, ScioBot, GeoAI). V podkapitole 6 se pak vrátíme k epistemickým otázkám a k etickým aspektům, které jsme dnes jen otevřeli.

Rychlé čtení podkapitoly 3

Hlavní teze: AI ve vzdělávání nemá jednu pevnou roli. Jakou roli AI hraje, závisí na **didaktickém zarámování** — na tom, jak ji učitel a žák používají.

Tři role AI ve vzdělávání (Ouyang a Jiao, 2021):

1. **AI řídí, žák přijímá** (*AI-directed, learner-as-recipient*) — behaviorismus. Vhodné pro procvičování místopisu; nevhodné pro otevřené otázky.
2. **AI a žák spolupracují** (*AI-supported, learner-as-collaborator*) — konstruktivismus. Vhodné pro práci se starými mapami; nevhodné pro autentický terénní výzkum.
3. **AI zmocňuje, žák vede** (*AI-empowered, learner-as-leader*) — konektivismus, rozšířená inteligence. Vhodné pro projektovou práci; vyžaduje vybudované samostatné dovednosti žáka.

LLM asistenti sami o sobě do žádné z rolí nepatří — rozhoduje způsob jejich použití.

Empirická evidence (Wang a Fan, 2025): metaanalýza 51 studií. Tři klíčové efekty:

- pro učební výkon zjištěno $g = 0,867$ (velký efekt)
- pro učební vnímání zjištěno $g = 0,456$ (střední efekt)
- pro myšlení vyššího řádu zjištěno $g = 0,457$ (také střední efekt).

Paradox: efekt na výkon je téměř dvakrát větší než na myšlení vyššího řádu. Bez pedagogického zarámování AI propadá do první role.

Klíčové moderátory efektu:

- **Typ kurzu** — STEM ($g = 0,311$); pro geografii orientační, ne přesné, kvůli hybridní povaze oboru.
- **Model výuky** — nejvyšší efekt v problémové výuce ($g = 1,113$), nízký v projektové ($g = 0,239$).
- **Doba intervence** — optimum 4–8 týdnů ($g = 0,999$), pak pokles kvůli nadměrné závislosti.
- **Role AI** — inteligentní tutor má nejsilnější efekt na myšlení vyššího řádu ($g = 0,945$).

Pět kompetencí pro práci s AI (adaptováno podle Sanusi a kolektivu, 2022): (1) kognitivní kompetence, (2) dovednostní kompetence, (3) samostatné učení, (4) týmová práce, (5) spolupráce s nástrojem.

Rámec se uplatňuje primárně jako **mapa kompetenční přípravy učitele**, sekundárně jako **mapa pro rozvoj žáků**. Jako rozšíření doporučujeme UNESCO kompetenční rámce — pro učitele Miao & Cukurova (2024), pro žáky Miao & Shiohira (2024). Most k modelu RAP (Jekel a kolektiv, 2025): reflexe, argumentace, participace ve vztahu k AI výstupům — s důrazem na sdílení zkušeností v profesním společenství.

Odpověď na otázku „Může AI nahradit učitele?“: Nemůže, ale mění jeho roli. Učitel přestává být primárně zdrojem informací a stává se **průvodcem** kritickou prací s AI a vším, co AI nedokáže — terénním pozorováním, autentickou zkušeností, hodnotovou reflexí. Tato role s nástupem AI **roste na důležitosti**.

4. AI v geografickém vzdělávání

Proč si geografie zaslouží vlastní podkapitulu

Předchozí podkapitola představila AI ve vzdělávání obecně. Většina poznatků platí napříč obory — paradigmatický rámec, paradox výkonu vs. myšlení vyššího řádu, význam didaktického zarámování, kompetenční rámec. Existuje ale několik specifík, kvůli kterým geografie potřebuje vlastní zarámování. Tato podkapitola tato specifika rozpracovává.

První specifikum je **fakticko-prostorové**. Zeměpisné údaje patří k oblastem, kde LLM asistenti **nejčastěji halucinují**. Místopis, rozlohy, nadmořské výšky, počty obyvatel měst, historické hranice států, datace přírodních jevů — to vše jsou údaje, které model neukládá jako přesná data, ale rekonstruuje je z trénovacích dat. Důsledek: učitel geografie pracuje s nástrojem, který v jeho oborové oblasti **dělá víc chyb než v některých jiných oblastech**. Tato realita musí být součástí každého didaktického rozhodnutí.

Druhé specifikum je **lokální**. Český místopis a regionální geografie jsou v trénovacích datech LLM zastoupeny **výrazně méně** než realie americké, britské nebo německé. Model „ví“ víc o New Yorku než o Liberci, víc o Mississippi než o Jizeře. Pro výuku regionální geografie ČR a evropského kontextu blízkého žákům to znamená, že LLM asistenti pracují **s nedostatkem kvalitních dat**, a riziko halucinace narůstá. Naopak při výuce o globálních fenoménech (klimatická změna, světové oceány, hospodářské zóny rozvinutého světa) je situace lepší.

Třetí specifikum je **hybridní povaha disciplíny**, o které jsme mluvili v podkapitole 3 ve vztahu k STEM efektu. Geografie sdílí s STEM obory metodologické rysy (práce s daty, modelování, prostorové analýzy, technologické nástroje), ale zároveň STEM přesahuje důrazem na interpretaci, kontext a komplexitu prostorových vztahů. Pro AI v geografickém vzdělávání to znamená, že efekt LLM asistentů pravděpodobně leží **mezi STEM póly** (kde je efekt nejmenší) a humanitními póly (kde je efekt větší).

Čtvrté specifikum je **propojení textu a prostoru**. Geografie pracuje s textem (popis krajiny, regionální charakteristika, didaktický výklad) i s prostorovými daty (mapy, satelitní snímky, GIS analýzy). LLM asistenti zvládají první rovinu, ale **principiálně ne druhou**. To otevírá zajímavý didaktický prostor: AI v geografii není jen LLM asistent, ale i celá kategorie **GeoAI** — aplikace strojového učení na prostorová data. Této kategorii věnujeme samostatnou podsekcí.

Oblasti geografického vzdělávání s jasnou hodnotou AI

Z předchozí podkapitoly víme, že LLM asistent je **vhodný pro generování variant textu, sumarizaci, restrukturalizaci, brainstorming a práci s přiloženým dokumentem**. V geografickém vzdělávání má tato obecná typologie konkrétní podoby, ve kterých AI přináší jasnou hodnotu pro učitele.

Příprava textových materiálů. Pracovní listy, zadání úloh, motivační úvody, otázky pro reflexi, testové otázky různé kognitivní náročnosti — to vše jsou úkoly, kde LLM asistent nahrazuje rutinní formulační práci, kterou by učitel jinak dělal ručně. Hodina o povodňové prevenci ve Středočeském kraji potřebuje pět testových otázek od zapamatování po hodnocení? Dvouminutový promyšlený prompt vrátí hrubý materiál, který učitel za další tři minuty dotáhne do použitelné podoby. Časový zisk oproti ručnímu psaní je řádový.

Brainstorming didaktických aktivit. Učitel připravuje hodinu o vztahu krajiny a klimatu a hledá motivační aktivitu na úvod. Místo aby prošel pět didaktických příruček, položí LLM asistentovi otázku: „Navrhni pět různých motivačních aktivit pro úvod hodiny o vztahu krajiny a klimatu v 8. ročníku. Aktivity by měly trvat maximálně 10 minut, používat běžně dostupné materiály a propojit téma s vlastní zkušeností žáků.“ Odpověď neslouží jako finální plán, ale jako **šíře možností** — z pěti návrhů si učitel vybere ten, který nejlépe sedí jeho třídě, kontextu, vlastního stylu.

Diferenciace obsahu pro různé úrovně žáků. LLM asistent je výborný pomocník pro tvorbu variant téhož materiálu — pro slabší čtenáře, pro nadané žáky, pro žáky s odlišným mateřským jazykem. Učitel připraví základní text o vodním hospodářství; požádá AI, aby z něj vytvořila zjednodušenou verzi pro slabšího čtenáře a rozšířenou verzi pro nadaného žáka. Tři verze téhož materiálu vznikají v čase potřebném pro vytvoření jedné.

Generování scénářů pro rolové hry. Geografické vzdělávání s emancipačním přesahem (aktivní občanství, prostorové nerovnosti, územní konflikty) často využívá rolových her, ve kterých žáci zastávají různé zainteresované strany. AI dokáže vygenerovat **profily rolí** s argumenty, motivacemi a hodnotovými východisky pro každou ze stran. Územní spor o výstavbu nové dálnice v Libereckém kraji může mít deset žakovských rolí — starosta dotčené obce, místní zemědělec, ekologický aktivista, krajský radní, projektový inženýr, dopravní expert. AI poskytne hrubý materiál, učitel ho upraví tak, aby seděl na konkrétní region a vzdělávací cíl.

Sumarizace odborných textů do jazyka přístupného žákovi. Učitel narazí na zajímavý odborný článek o desertifikaci nebo o klimatické migraci. Článek je pro 8. ročník nečitelný, ale jeho jádro by žáci měli znát. LLM asistent dokáže článek sumarizovat do několika odstavců přiměřených věkové úrovni — s tím, že učitel výsledek **kontroluje** proti originálu, aby se zachovala přesnost.

Prvotní rešerše literatury a zdrojů. Při přípravě nového tematického bloku potřebuje učitel rychlou orientaci v dostupné literatuře. AI s vyhledáváním na webu nebo specializované rešeršní nástroje (Consensus, Scite — k nim se vrátíme) dokáží navrhnout výchozí body, které učitel dál sám prozkoumá.

Zpětná vazba na vlastní materiály. Učitel napíše návrh pracovního listu a požádá AI o kritické zhodnocení: „Identifikuj v tomto pracovním listu nejasné formulace, příliš obtížné nebo naopak

triviální úlohy a místa, kde chybí návaznost mezi částmi." AI funguje jako první čtenář, který poskytuje strukturovanou kritiku.

Společným rysem všech těchto úloh je, že **AI je nástrojem, který šetří učitelovi čas** a zároveň nabízí **širší variant**, kterou by učitel sám obtížně generoval. AI ale **nenahrazuje učitelův odborný úsudek** — ten zůstává v každém kroku potřebný pro výběr, korekci, kontextualizaci.

Oblasti, kde AI nestačí nebo škodí

Stejně důležité jako vědět, kde AI pomáhá, je vědět, kde **nepomáhá nebo aktivně škodí**. Tyto oblasti jsou v geografickém vzdělávání specifické a stojí za pojmenování.

Faktografické údaje, zejména místopisné a statistické. Rozloha Sahary, počet obyvatel Liberce, nadmořská výška Sněžky, datace stavby přehrad, hranice biogeografických oblastí — to vše jsou údaje, kde LLM asistent **má vysokou pravděpodobnost halucinace**. Pravidlo: faktografické údaje vždy ověřit z primárního zdroje. Pokud je učitel potřebuje pro test nebo pracovní list, **nevěřit AI**.

Aktuální data. Současná teplota, dnešní stav povodí, aktuální politická situace v regionu, čerstvé statistiky obyvatelstva — bez aktivního vyhledávání na webu nemá model přístup. Pokud učitel potřebuje aktuální data, musí použít LLM asistenta v režimu s vyhledáváním a stejně si **ověřit citované zdroje**.

Lokálně specifické informace. Historie konkrétní české obce, místní pojmenování krajinných prvků, lokální specifika hospodářství — model má pro tato témata řídká data. Pokud učitel potřebuje informace o konkrétní lokalitě, lepší cestou je **vlastní místní řešerše** (obecní úřad, místní muzeum, regionální literatura) doplněná případně AI jako sekundárním zdrojem.

Přesné mapy a prostorová data. LLM asistent **nedokáže vytvořit kartograficky přesnou mapu**. Generátory obrazu vytvářejí mapy, které vypadají jako mapy, ale jejich geografická přesnost je nulová — pojmenování měst nesedí, hranice jsou imaginární, měřítko nedává smysl. Pro mapovou tvorbu slouží GIS, ne AI.

Přesné výpočty. LLM nejsou kalkulátor. Sčítání rozloh okresů, výpočet průměrných srážek za období, statistické zpracování dat — k tomu jsou nástroje vhodnější. Někteří novější LLM asistenti mají vestavěný kalkulační nástroj, který přesnost zlepšuje, ale i pak je dobré výsledky **kontrolovat**.

Profesní rozhodnutí s odpovědností. Hodnocení žáka, rozhodnutí o jeho integraci, volba speciálního přístupu pro žáka se SVP — to jsou rozhodnutí, která **musí činit pedagog**, ne AI. AI může pomoci s formulováním zprávy, ale **odpovědnost a substantivní obsah** patří k učiteli.

Autentické místní zkušenosti. Geografie je obor, který se učí z mapy, ale i z **chodidel** — z procházky krajinou, z pozorování řeky, z návštěvy fabriky. AI nemůže nahradit **terénní práci, autentické setkání s místem, rozhovor s pamětníkem**. Pokud učitel připravuje výuku tématu,

kde je autentická zkušenost klíčová, AI je nanejvýš pomocníkem pro přípravu, ne nahrazením toho, co se musí zažít.

LLM asistent a kurikulární práce

Jeden z nejhodnotnějších způsobů využití LLM asistenta v učitelské práci je **práce nad kurikulárními dokumenty**. RVP ZV 2025 ve své revidované podobě, jeho oblasti, OVU, klíčové kompetence — to vše jsou rozsáhlé texty, ve kterých se učitel pohybuje při každém plánování výuky. AI v RAG režimu zde otevírá kvalitativně novou rovinu.

Vzpomeňme z podkapitoly 1 a 2 na **RAG konfiguraci** — režim, kdy LLM asistent pracuje primárně s dokumenty, které mu uživatel přiloží. Pro práci s revidovaným RVP doporučujeme následující strukturovaný postup.

Krok 1: Připravit sadu výchozích dokumentů. Z webu MŠMT a NPI ČR stáhnout nejméně tyto dokumenty:

- Úplný text revidovaného RVP ZV 2025 (PDF, kompletní dokument)
- Strukturu vzdělávací oblasti, ve které se učitel pohybuje (Člověk a příroda pro 2. stupeň, Člověk a jeho svět pro 1. stupeň)
- Metodické doporučení k revidovanému RVP (pokud je k dispozici)
- Charakteristiku klíčových kompetencí pro daný stupeň vzdělávání

Volitelně doplnit:

- Aktuální používanou učebnici geografie (pokud máte digitální verzi)
- Vlastní školní vzdělávací program (ŠVP) konkrétní školy, pokud učitel působí na konkrétní škole
- Případové studie a metodiky NPI relevantní pro plánovanou tematiku

Krok 2: Volba RAG nástroje a nahrání zdrojů. Pro českého učitele jsou nejvhodnější:

- **NotebookLM** — nejširší didaktické funkce (Audio Overview, Mind mapy, časová osa), kvalitní práce s češtinou
- **Claude Projects** — kvalitní porozumění komplexním textům, dobré pro hluboké analytické úlohy
- **ChatGPT s vlastní knowledge base** — flexibilní, ale vyžaduje placený tarif
- **ScioBot s nahranými materiály** — výhodou je zařamování v české didaktické tradici

Nahrát všechny dokumenty z kroku 1 jako jednu znalostní bázi.

Krok 3: Ověřit, že nástroj dokumenty „přečte“ celé. Před vlastní prací položit kontrolní otázku, která vyžaduje znalost konkrétní pasáže z dokumentu. Například: „*Z přiloženého RVP cituj přesně formulaci OVU GEO-9-3-04. Uveď, na které straně dokumentu se nachází.*“ Pokud nástroj vrátí

přesnou citaci, je dokument zpracovaný správně. Pokud ne (citace je vágní, model si vymýšlí kód, neumí najít stranu), dokument se nenahrál celý — nutno rozdělit nebo nahrát znovu.

Krok 4: Strukturovaná konverzace nad RVP. Po ověření, že dokumenty jsou správně načteny, lze vést konverzaci typu:

„Vyhledej v přiloženém RVP všechny očekávané výstupy ve vzdělávací oblasti Člověk a příroda, které se týkají vodního hospodářství. Vypiš je v tabulce s těmito sloupci: kód OVU, plné znění OVU, ročník, návrh mezipředmětového propojení s další oblastí RVP.“

„Na základě přiložené struktury vzdělávací oblasti navrhni tematický blok ‚Sucho v české krajině‘ pro 8. ročník. Blok by měl pokrývat OVU, které najdeš relevantní, měl by trvat 4 vyučovací hodiny a měl by být uspořádán podle didaktického rámce E-U-R (evokace — uvědomění si významu — reflexe).“

„Z přiložené učebnice vyber pasáž, která se nejvíc týká povodňové prevence. Ke každé větě této pasáže přiřaď klíčový pojem, který bych měl s žáky aktivně procvičit. Navrh, kterým způsobem využití GenAI (z 10 způsobů iniciativy AI dětem) by k procvičení každého pojmu byl nejvhodnější.“

„Najdi v RVP všechny formulace, kde se objevuje pojem ‚udržitelnost‘. Z kontextu odhadni, co tímto pojmem RVP rozumí. Navrhni mi, jak ho operacionalizovat v hodině geografie pro 9. ročník — uveď tři konkrétní pozorovatelné projevy chování žáka, ze kterých poznám, že tuto klíčovou kompetenci rozvíjí.“

Krok 5: Iterace a kritické čtení výstupů. Stejně jako při běžném promptování (podkapitola 2), i u RAG práce s RVP platí, že **první odpověď čteme jako diagnostiku, ne jako finální výstup**. Učitel ověřuje, zda nástroj skutečně cituje z přiloženého RVP, zda nezaměnil OVU kódy, zda neopomenul relevantní pasáže. U citovaných pasáží je vhodné si **odkliknout zpět do zdroje** (RAG nástroje typicky umožňují přejít přímo na citovanou pasáž v dokumentu).

Klíčový rozdíl oproti práci se samostatným LLM asistentem: model **odpovídá z přiloženého textu, ne z obecné znalosti RVP**. Tím se výrazně snižuje riziko halucinace a odpovědi jsou přímo aplikovatelné na české kurikulární prostředí. Učitel přestává AI ptát „co je v RVP“ — a začíná s ní vést konverzaci nad tím, jak RVP **operacionalizovat ve vlastní praxi**.

Praktická poznámka: RVP ZV 2025 v plné podobě je rozsáhlý dokument o stovkách stran. Některé RAG nástroje mají omezení velikosti přiložených souborů. Pokud nástroj přiložení celého dokumentu odmítne nebo s ním pracuje pomalu, lze ho rozdělit — například přiložit jen vzdělávací oblast Člověk a příroda samostatně, nebo její konkrétní část (regionální geografie, fyzická geografie, společenská geografie). NotebookLM a Claude Projects zvládají rozsáhlé dokumenty nejlépe.

Specializované platformy nad LLM

V podkapitole 1 jsme zavedli pojem RAG platforem jako kategorie nástrojů, které pracují primárně s přiloženými dokumenty. Pro učitele geografie je obzvlášť hodnotná jedna z nich — **NotebookLM** od Google. Není to jediný nástroj této kategorie a princip funguje i v Claude Projects, vlastních GPTs, Perplexity Spaces nebo ScioBotu s nahranými materiály. NotebookLM ale zaslouží podrobnější rozpracování, protože jeho **didaktické funkce** přesahují běžnou RAG práci s dokumenty a otevírají kvalitativně nové možnosti.

NotebookLM funguje jako **digitální zápisník propojený s LLM**. Uživatel do něj nahraje sadu zdrojů (PDF, DOCX, weby, YouTube videa, audio nahrávky) a nástroj vytvoří „znalostní bázi“, se kterou pak lze pracovat různými způsoby:

- **Diskuze nad zdroji** — klasická RAG konverzace, model odpovídá výhradně na základě nahraných materiálů a u každé odpovědi cituje konkrétní pasáž zdroje.
- **Briefing dokument** — automatické shrnutí všech nahraných zdrojů do jednoho přehledového textu.
- **Studijní průvodce** — generování učebního materiálu s otázkami a klíčovými pojmy.
- **Časová osa** — extrakce událostí a dat z nahraných zdrojů a jejich uspořádání chronologicky.
- **Mind mapa** — vizualizace pojmů a vztahů z nahraných zdrojů.
- **Audio Overview** — generování audio přehledu, ve kterém dva AI moderátoři diskutují obsah nahraných zdrojů. Tento výstup je v originále anglický, ale podporuje řadu dalších jazyků včetně češtiny.
- **Video Overview** — generování video prezentace na základě nahraných zdrojů.

Pro učitele geografie se otevírají konkrétní didaktické scénáře:

Příprava regionální studie. Učitel připravuje blok o regionální geografii Skandinávie. Nahrá do NotebookLM tři odborné články, dvě kapitoly z atlasu a aktuální zprávu o klimatické změně v Arktidě. Nad touto sadou pak vede konverzaci pro vlastní přípravu, generuje testové otázky, vytváří studijní průvodce pro žáky.

Audio výstup pro žáky. Tatáž sada zdrojů poslouží pro generování Audio Overview — patnáctiminutové diskuze dvou moderátorů o regionální geografii Skandinávie. Žáci ji mohou poslouchat při cestě do školy, při sportu, při ručních pracích. Audio formát zpřístupňuje obsah žákům, kteří hůř čtou nebo si lépe pamatují slyšené.

Práce se starými mapami. Učitel nahrá do NotebookLM staré mapy regionu (Müllerova mapa Čech, mapa třetího vojenského mapování, Klaudyánovu mapu) a doplní je odbornými texty o jejich historickém kontextu. Žáci pak nad touto sadou vedou konverzaci, ptají se na detaily, srovnávají různé mapové reprezentace téhož území v různých dobách. AI funguje jako průvodce mapovou historií regionu.

Projektová podpora. Žáci pracují na projektu o místních prostorových nerovnostech. Nahrají do NotebookLM data z ČSÚ, regionální studie, mediální texty o tématu. Nástroj jim pomáhá orientovat se v rozsáhlém materiálu, hledat souvislosti, formulovat hypotézy.

Klíčová výhoda RAG platform zůstává — riziko halucinace je v rámci nahaných zdrojů výrazně nižší než u samostatného LLM asistenta. Model **nemá kde halucinovat**, protože odpovídá z konkrétního textu, na který se odkazuje. Tato vlastnost dělá z RAG platform nejdidakticky nejbezpečnější nasazení LLM asistenta pro práci s ověřenými zdroji.

Ekosystém specializovaných AI nástrojů

V podkapitole 1 jsme zmínili, že vedle obecných LLM asistentů existují **specializované AI nástroje**, které mají v určitých úkolech zřetelnou výhodu. Pro pokročilou práci učitele geografie stojí za to vědět, **kdy stojí za to specializovat** a kdy postačí obecný nástroj.

Specializované rešeršní nástroje pro vědeckou literaturu — Consensus, Scite, Elicit a další — jsou postaveny nad databázemi vědeckých publikací (Semantic Scholar, OpenAlex, PubMed) a vrací výsledky s **explicitními citacemi a hodnocením vědecké váhy**. Pro učitele, který připravuje kvalifikační práci, hledá oporu pro didaktické rozhodnutí v aktuální evidenci nebo chce ukotvit obsah hodiny v současné odborné diskuzi, jsou cenným doplňkem. Příklad: učitel připravuje hodinu o klimatické migraci a chce vědět, co o tématu říká současná odborná literatura. Obecný LLM asistent dá obecnou odpověď s rizikem halucinace; Consensus nebo Scite vrátí konkrétní studie s odkazy a strukturovaným shrnutím.

RAG platformy pro syntézu z přiložených zdrojů — NotebookLM, Claude Projects, vlastní GPTs — jsme rozpracovali výše. Hodí se pro práci s konkrétní sadou ověřených zdrojů.

Obecní LLM asistenti — Claude, ChatGPT, Gemini — jsou nejvšestrannější. Hodí se pro brainstorming, formulační práci, editaci textu, generování variant.

Optimální workflow pro náročnější přípravu (například při tvorbě nové tematické přípravy nebo kvalifikační práce) může vypadat takto:

1. **Vyhledat odbornou literaturu** specializovaným rešeršním nástrojem (Consensus, Scite). Stáhnout open-access články.
2. **Přiložit články do RAG platformy** (NotebookLM). Vést s nimi konverzaci, generovat shrnutí, identifikovat klíčové pojmy.
3. **Diskutovat výsledky s obecným LLM asistentem** (Claude, ChatGPT). Brainstorming didaktického zarámování, formulace pracovních listů, kreativní přesah.

Tento workflow využívá **silných stránek každého nástroje**. Specializovaný rešeršní nástroj má přístup k odborné literatuře, který obecný LLM nemá. RAG platforma garantuje, že se odpovědi opírají o konkrétní zdroje. Obecný LLM nabízí formulační a kreativní svobodu.

Důležitá poznámka: i jediný silný obecný LLM asistent dnes do určité míry tuto roli zvládne sám. Claude, ChatGPT i Gemini umí v některých konfiguracích vyhledávat na webu, číst přiložené dokumenty, vést dlouhou konverzaci. Specializace nástrojů **není povinná** — je to **kvalifikované rozhodnutí**, které učitel činí podle náročnosti úkolu, dostupnosti nástrojů a vlastní zkušenosti.

Pro běžnou denní práci vystačí obecný LLM asistent. Pro hluboce ukotvenou přípravu, kvalifikační práci nebo systematickou řešerši odborné literatury se vyplatí specializovaný workflow. **Didaktická citlivost rozpoznat, kdy stojí za to specializovat**, je sama o sobě součástí AI gramotnosti učitele.

AI Lesson Plan Generators v českém prostředí

V podkapitole 1 jsme zmínili kategorii **AI Lesson Plan Generators** — specializovaných platforem pro tvorbu hodin a výukových materiálů. V českém prostředí je nejrozšířenějším zástupcem této kategorie **ScioBot** (sciobot.cz) od společnosti Scio. Využívá ho přes 70 tisíc pedagogů a 3 400 škol v České republice.

ScioBot generuje strukturované přípravy hodin podle metody E-U-R (evokace — uvědomění si významu — reflexe), tvoří pracovní listy a tisknutelné materiály, podporuje nahrávání vlastních materiálů jako podkladu pro generování (RAG princip). Výhodou je **zarámování v české didaktické tradici**, znalost RVP ZV a přizpůsobení českému jazykovému prostředí.

Z mezinárodních AI Lesson Plan Generators stojí za zmínku Magic School AI, Eduaide, Twee a Education Copilot. Mají širší funkční záběr a často pokročilejší integraci s dalšími nástroji, ale výstupy v češtině jsou méně kvalitní a neznají specifika českého kurikula.

Pro běžnou denní práci učitele geografie je ScioBot dostatečným a často nejvhodnějším řešením v této kategorii. Mezinárodní nástroje má smysl prozkoumat, pokud učitel připravuje obsah v angličtině nebo potřebuje specifické funkce, které český nástroj zatím nenabízí.

Didaktické rámce pro AI ve vzdělávání v ČR — iniciativa AI dětem

Pro systematické zavádění AI do vlastní pedagogické praxe nestačí znát nástroje — je potřeba **didaktický rámec**, který odpovídá na otázku, **k čemu** AI ve výuce vlastně používat a **jak** to dělat smysluplně. V českém prostředí takový rámec systematicky vyvíjí **iniciativa AI dětem** vedená Evou Nečasovou. Jde o neziskovou organizaci, která vznikla jako odpověď na potřebu profesionálního zarámování AI ve školství a působí v úzké spolupráci s **Národním pedagogickým institutem ČR**.

Pro budoucího učitele geografie je orientace v této iniciativě (dostupné na chatveskole.cz) **klíčovou součástí učitelské přípravy**. Mezi nejhodnotnější výstupy patří:

Rámec „4 kroky ke smysluplnému učení s AI“ — ucelený metodický postup pro pedagogy, kteří začínají s AI ve výuce systematicky pracovat. Publikováno ve spolupráci s NPI ČR na portálu rvp.cz.

10 způsobů využití generativní AI ve výuce. Tento rámec je pro učitele obzvlášť praktický, protože pojmenovává **didakticky odlišné způsoby**, kterými lze AI nasadit. Není to seznam nástrojů, ale **typologie pedagogických scénářů**:

ZPŮSOB	Co ROZVÍJÍ
Otázky na míru	hlubší porozumění tématu, aktivní přemýšlení
Obsahová struktura	logická stavba výstupu, prioritizace informací
Brainstorming	divergentní myšlení, různé úhly pohledu
Plánování	organizace vlastní práce, realistické cíle
Vylepšení výstupu	kritické hodnocení, jazyková kultura
Zpětná vazba	sebereflexe, práce s kritérii hodnocení
Argumentace	argumentační dovednosti, kritické myšlení
Role experta	komunikace s odborníkem, kladení otázek
Inovace	tvůrčí přístup, vývoj nástrojů
Reflexe přínosu	metakognice, vědomé využití technologie

Pro učitele geografie tato typologie znamená, že **konkrétní hodina s AI** se nemusí omezit na „nechat žáky vygenerovat text“. Stejně téma — například klimatickou změnu — lze v AI zarámovat deseti odlišnými didaktickými způsoby, z nichž každý rozvíjí jiné kompetence. Volba způsobu je didaktickým rozhodnutím, které učitel činí podle vzdělávacího cíle.

Rámec vychází z **AI Assessment Scale** Leona Furze a je doplněn o důležité doporučení: GenAI nasazovat především u **starších žáků**, kteří jsou dostatečně zralí na to, aby dokázali samostatně posoudit, zda jim AI v učení skutečně pomáhá. Toto doporučení vychází mj. z výzkumu o riziku **kognitivního dluhu** při nadměrném využívání AI.

Metodika využití chatbotů ve formativním hodnocení. Samostatně rozpracovaná oblast s vlastními prompty pro tvorbu kritérií hodnocení, formulaci výukových cílů, individualizaci, sebehodnocení žáků a generování slovní zpětné vazby. Pro učitele, který chce AI využít k úspoře času ve formativním hodnocení (jedna z časově nejnáročnějších učitelských úloh), je tato metodika přímo aplikovatelná.

Databáze AI asistentů kategorizovaná do pěti oblastí: AI asistenti pro hodnocení, oborová AI asistenti, asistenti pro řízení školy, AI akcelerátor (rámec ADKAR pro řízení změny), AI asistenti pro různé pedagogické úkoly (Plánovač výuky, Učitelský mentor, Didaktický rádce, Asistent pro rozvoj myšlení a další). V kategorii oborových asistentů najde učitel geografie například „Asistent Poznej svět: Zeměpisný kvíz“.

Strategie zavedení AI ve školách. Pro budoucího učitele, který se brzy stane součástí pedagogického sboru, je hodnotnou orientací rámec ADKAR (Awareness — Desire — Knowledge — Ability — Reinforcement) aplikovaný na zavádění AI ve škole jako celku. Učitel,

který přichází do sboru, který s AI teprve začíná, dokáže díky tomuto rámci kvalifikovaně přispět k systémové změně, ne jen k vlastní praxi.

Doporučení pro využívání AI na ZŠ, SŠ a VŠ. Tři samostatně rozpracovaná doporučení s odlišnostmi podle stupně vzdělávání. Pro budoucího učitele 2. stupně ZŠ a SŠ je toto referenční materiál pro každodenní práci.

Společným rysem výstupů iniciativy AI dětem je **didaktická preciznost**: pojmenování pedagogických cílů, propojení s ověřenými didaktickými rámci (AI Assessment Scale, ADKAR), respekt k českému kurikulárnímu prostředí, srozumitelný jazyk pro učitele bez specializovaného technického vzdělání. Zveřejněné prompty a AI asistenti jsou navrženi tak, aby fungovali napříč hlavními LLM asistenty — investice učitele do studia těchto materiálů se neztrácí změnou nástroje.

Pro učitele, kteří plánují systematicky rozvíjet AI gramotnost u svých žáků, je doplňkovým referenčním materiálem také *AI Competency Framework for Students* (Miao & Shiohira, 2024) vydaný UNESCO. Definuje čtyři kompetenční aspekty žáka (human-centred mindset, etika AI, AI techniky a aplikace, návrh AI systémů) ve třech úrovních (porozumět, aplikovat, tvořit) a poskytuje strukturovaný plán toho, co u žáků postupně rozvíjet.

Doporučení pro budoucího učitele geografie: chatveskole.cz prostudovat jako **referenční materiál pro pedagogickou práci s AI** ještě před začátkem vlastního učitelského působení. Iniciativa publikuje materiály pravidelně, takže obsah je vhodné sledovat průběžně. Pro orientaci v geografickém kontextu pak zveřejněné rámce a prompty samostatně adaptovat — typologie 10 způsobů využití i metodika formativního hodnocení jsou převoditelné na geografické úlohy bez větších úprav.

GeoAI v geografickém vzdělávání

GeoAI (geospatial AI, geoprostorová umělá inteligence) označuje **průsečík umělé inteligence s tradiční prostorovou analýzou**. Není to další stupeň v hierarchii nad strojovým učením nebo hlubokým učením, ale specifická aplikace AI metod na **geoprostorová data, geografickou vědu a geoinformační technologie**. Definice společnosti Esri, která je v současnosti hlavním globálním dodavatelem GeoAI nástrojů, zní: „*GeoAI je aplikace umělé inteligence kombinovaná s geoprostorovými daty, vědou a technologií za účelem urychlení reálného porozumění obchodním příležitostí, environmentálním dopadům a provozním rizikům*“ (Esri, 2025).

Co GeoAI dělá

Zatímco běžná AI může pracovat s jakýmkoliv daty, GeoAI se specificky zaměřuje na **prostorový rozměr**. Hlavní oblasti aplikace:

Extrakce prvků z map a snímků. Automatická detekce objektů v reálném čase — palmy, budovy, silniční trhliny, lodě, auta na parkovišti, hnízda v lese. Strojové učení rozpoznává objekty ze satelitních a leteckých snímků s přesností, která dříve vyžadovala ruční práci kartografa.

Práce s prostorovým kontextem. GeoAI dokáže analyzovat nejen obrázky, ale i vektorová a tabulková geodata, případně **nestrukturovaný text** (například geolokalizované příspěvky ze sociálních sítí), který nese prostorovou informaci.

Prediktivní analýza v prostoru. Předpovídání nehod, povodní, lesních požárů, šíření znečištění; hledání vzorců a shluků v geografických datech; modelování dopadů urbanizace, klimatické změny, epidemii.

Klasifikace krajinného pokryvu a změn v čase. Automatické vyhodnocení toho, jak se krajina mění (odlesnění, urbanizace, zemědělské cykly), na základě časových řad satelitních snímků.

Předtrénované modely a zpřístupnění GeoAI

Klíčová skutečnost pro budoucího učitele geografie: GeoAI se v posledních letech **stalo dramaticky přístupnější**. V ekosystému ArcGIS jsou dnes k dispozici **předtrénované modely** (ready-to-use), které uživatelům umožňují provádět pokročilé GeoAI analýzy (například detekci budov nebo lodí ze satelitních snímků) **bez nutnosti psát kód nebo trénovat vlastní systém**. Stačí vybrat model z katalogu, načíst data a spustit analýzu (Esri, 2025).

Tento posun znamená, že GeoAI přestává být doménou specializovaných odborníků na strojové učení a stává se **dostupným nástrojem** pro učitele, studenty a širší geografickou komunitu. Zároveň je nutné udržet kritickou perspektivu: studie „*Geospatial Artificial Intelligence (GeoAI) Is Widening the Digital Divide*“ (Annals of the American Association of Geographers, 2025) upozorňuje, že rozšíření GeoAI prohlubuje digitální rozdělení — koncentruje moc u těch, kdo mají přístup k datům, výpočetní kapacitě a kompetenci kriticky pracovat s GeoAI výstupy. **Široké zavedení GeoAI gramotnosti** ve vzdělávání je proto nejen technická, ale i etická nutnost.

Proč by GeoAI mělo zaznít na gymnáziu

Donedávna byla GeoAI doménou specializovaných GIS kurzů na vysokých školách a profesionálních pracovištích. Tato situace se v horizontu nejbližších let dramaticky promění. Přibývá laicky přívětivých webových aplikací, předtrénovaných modelů, integrovaných nástrojů v ArcGIS Online. Pro budoucího učitele geografie to znamená, že v horizontu nejbližších dvou let bude reálné zařadit **vlastní práci žáků s GeoAI nástroji** přímo do gymnaziální výuky — ne jen práci s hotovými výstupy, ale aktivní využití GeoAI pro vlastní analytické úlohy.

Jako orientační tipy didaktických scénářů, které **v horizontu jednoho až dvou let** budou na gymnáziu reálně proveditelné s rostoucí dostupností nástrojů:

- **Detekce změn v zástavbě s předtrénovaným modelem** — žáci v ArcGIS Online vyberou území zájmu (rodný region) a aplikují předtrénovaný model na detekci budov v satelitních snímcích z různých let. Výstupem je vlastní analýza růstu zástavby, kterou v hodině diskutují.

- **Klasifikace krajinného pokryvu pomocí GeoAI nástroje** — žáci nezávisle na učiteli klasifikují satelitní snímky vlastního území do kategorií (les, pole, zástavba, voda) pomocí předtrénovaného modelu a porovnávají výsledek s referenční mapou.
- **Detekce objektů z dronových snímků** — projektová úloha, kdy žáci zpracovávají vlastní dronové snímky z lokální exkurze (počet stromů v sadu, počet aut na parkovišti, identifikace nelegálních skládek) pomocí GeoAI modelu.

Pro běžné didaktické scénáře, které v textu zmiňujeme jako příklady (sledování změn krajinného pokryvu, analýza povodňového rizika, monitoring sucha přes vegetační indexy, práce se starými mapami v digitální podobě), **dnes GeoAI nástroje žáci přímo nepoužívají** — pracují s **hotovými výstupy** prostorových analýz nebo využívají standardní GIS metody (překryvná analýza, vizuální interpretace mapy). To je legitimní a hodnotné, ale je důležité tyto úlohy didakticky nezaměňovat za „práci s GeoAI“. Skutečná GeoAI gramotnost na gymnáziu se teprve formuje a stane se realitou v horizontu nejbližších let.

Vztah GeoAI a LLM asistentů — komplementarita

GeoAI a LLM asistenti se v geografii nevylučují, ale **doplňují**. LLM asistent generuje text **o prostorových jevech**, GeoAI pracuje **se samými prostorovými daty**.

V didaktickém scénáři se obě kategorie přirozeně potkávají: žáci analyzují prostorová data v GIS s GeoAI nástroji (například identifikují místa, kde sucho nejvíce ohrožuje zemědělství, pomocí předtrénovaného modelu na vegetační indexy). Výsledky pak interpretují ve formě eseje, ve které jim s formulací pomáhá LLM asistent — ten rozumí textu o suchu, ale neumí provést prostorovou analýzu. Žáci se učí **kvalifikovaně kombinovat oba typy nástrojů** podle toho, k čemu se hodí.

Pro budoucího učitele geografie tato komplementarita znamená, že **AI gramotnost v geografii má dva pilíře**: práci s textovými LLM asistenty (obsah této kapitoly) a práci s GeoAI v GIS prostředí (specializovaný kurz geoinformatiky). Žádný z pilířů nestačí sám.

Geografická specifika promptování

V podkapitole 2 jsme představili tři komponenty dobrého promptu — kontext, úkol, cíl. V geografickém vzdělávání mají tyto komponenty některá specifika, která stojí za pojmenování.

Kontextu se v geografii vyplácí investovat víc než jinde. Důvodem je riziko halucinace u geografických údajů. Čím konkrétnější je kontext, tím méně prostoru má model pro pravděpodobnostní vyplňování mezer. Místo „*napiš pracovní list o povodních*“ formulovat „*napiš pracovní list o povodních pro 8. ročník v Libereckém kraji s důrazem na lokální situaci v Pojizeří*“ — model dostává jasnější ukotvení a méně halucinuje.

Lokální specifika je třeba jmenovat explicitně. Pokud učitel chce, aby se ve výstupu objevila česká specifika, musí o ně **explicitně požádat**. Bez explicitního pokynu model defaultně tihne k

obecnému (často americkému nebo západoevropskému) kontextu, protože v něm má víc trénovacích dat. Formulace typu „*uveď konkrétní příklady z Česka*“, „*přizpůsob obsah českému kurikulárnímu prostředí (RVP ZV)*“, „*vyhni se anglosaským reáliím a místo nich použij česká*“ dramaticky zvyšují kvalitu odpovědi.

Číselné údaje vždy explicitně zpochybnit. Při geografických dotazech, které obsahují kvantitativní údaje (rozlohy, počty obyvatel, nadmořské výšky, klimatické statistiky), zařadit do promptu instrukci typu „*u každého číselného údaje uveď, jak vysoká je tvoje míra jistoty, a doporuč zdroj pro ověření*“. Model je tak nucen reflektovat svou nejistotu místo aby halucinoval s jistotou.

Pro aktuální data vždy režim s vyhledáváním nebo RAG. O knowledge cutoff jsme mluvili v podkapitole 1. V geografii je toto specifikum obzvlášť důležité — politická situace, klimatická data, demografie, územní správa se mění průběžně. Pro každý dotaz o aktuálním stavu zapnout vyhledávání nebo přiložit aktuální dokument.

Pro lokální informace zapojit lidský zdroj. I s nejlepším promptem nedokáže LLM asistent nahradit místní expertizu — informace od pamětníka, archivu obecního úřadu, regionálního muzea, regionální literatury. Pokud učitel připravuje obsah o konkrétním místě, AI použít jako sekundární zdroj a primární opřít o lokální zdroje.

Promptovat v češtině, ale být připraven na občasné zhoršení kvality. LLM asistenti dnes pracují s češtinou výrazně lépe než před dvěma lety, ale kvalita stále občas kolísá. Pokud v češtině dostáváme nekvalitní výstup, vyzkoušet stejný prompt v angličtině — někdy je výstup výrazně lepší a stačí ho do češtiny přeložit (LLM asistenti tento překlad zvládají dobře).

Pracovní scénář 1: knowledge cutoff a Hormuzský průliv

Slíbený scénář z podkapitoly 1. Ukazuje, jak nesprávné chápání knowledge cutoff může učitele dovést k fatální chybě a jak proti tomu didakticky postupovat.

Situace

Učitel geografie na gymnáziu připravuje hodinu o globálních dopravních koridorech. Jako aktuální případ chce probrat **napětí v Hormuzském průlivu** v kontextu izraelsko-americko-iránského konfliktu (březen–květen 2026), který v posledních měsících eskaluje. Hodina má za týden a učitel sahá po LLM asistentovi pro rychlou orientaci v aktuálním vývoji.

Nesprávný postup

Učitel otevře LLM asistenta a položí mu přímou otázku:

„Vysvětli mi aktuální situaci v Hormuzském průlivu — kdo aktuálně útočí, jak reaguje světový trh s ropou, jaké jsou nejnovější diplomatické iniciativy.“

Co se stane? Model — **bez aktivního vyhledávání na webu** — odpoví. Odpověď bude formulačně sebejistá, faktograficky strukturovaná, bude obsahovat data, jména aktérů, čísla. Učitel ji přečte a získá dojem, že je informován.

Problém: odpověď reflektuje stav světa **k datu trénování modelu**. Pokud k eskalaci došlo nedávno, model o ní nemusí vědět vůbec — a místo toho rekonstruuje obecný vzorec „napětí v Hormuzu“ z trénovacích dat. Mohl uvést konflikt **z jiné doby** jako „aktuální“, chybně přiřadit jména aktérů, vymyslet diplomatickou iniciativu, která neproběhla. Učitel přijde do třídy s informacemi, které jsou v lepším případě zastaralé, v horším smyšlené. Před třídou pak buď ztrapní sebe, nebo — což je horší — předá žákům dezinformace.

Správný postup

Postup má čtyři fáze, každá s jiným typem nasazení AI.

Fáze 1: Použití AI pro doplnění kontextu. Pro části tématu, které **se v čase nemění**, je LLM asistent výborným pomocníkem. Učitel se může zeptat:

„Vysvětli mi, co je Hormuzský průliv z geografického a strategického hlediska. Proč je v angličtině označován jako chokepoint? Jaké další chokepointy ve světovém oceánu existují a jaký je jejich strategický význam?“

Tyto informace jsou stabilní — geografické rysy průlivu, jeho hloubka, šířka, objem dopravované ropy, koncept chokepointu, světové analogie (Suezský průplav, Panamský průplav, Bospor, Malacký průliv). Model je z trénovacích dat zná dobře a riziko halucinace je nízké.

Fáze 2: Pro aktuální vývoj použít AI s vyhledáváním na webu. Pro otázky o aktuálním stavu otevřít LLM asistenta v režimu s aktivním vyhledáváním (ChatGPT s web search, Claude s web search, Perplexity). Formulovat:

„Vyhledej aktuální zprávy o situaci v Hormuzském průlivu v kontextu izraelsko-americko-iránského konfliktu. Sumarizuj, co se stalo v posledních dvou týdnech. U každého tvrzení uveď zdroj a datum publikace.“

Model vyhledá aktuální zprávy, citoval je s odkazy. Učitel pak **klikne na citované zdroje** a ověří, že skutečně říkají to, co model tvrdí. Tím se snižuje riziko, že model špatně interpretuje nalezené informace.

Fáze 3: Pro hloubkové studium konkrétních aspektů použít RAG. Pokud učitel chce do hodiny zařadit konkrétní studii nebo analytický článek, stáhnout PDF do RAG nástroje (NotebookLM, Claude Projects) a vést konverzaci nad konkrétním textem. Například:

„V přiloženém článku z Center for Strategic and International Studies o Hormuzském průlivu vyhledej argumenty pro a proti tezi, že Írán by průliv skutečně dokázal zablokovat na delší dobu. Porovnej tyto argumenty s těmi, které uvádí přiložený článek z Council on Foreign Relations.“

Model pracuje s konkrétními ověřenými zdroji, ne s obecnou znalostí.

Fáze 4: Vytvoření učební pomůcky pomocí ArcGIS StoryMaps a RAG. Pro praktické využití ve výuce učitel vytvoří **interaktivní učební pomůcku** v prostředí **ArcGIS StoryMaps**. Platforma StoryMaps má pro geografické vzdělávání mimořádný potenciál — umožňuje vytvářet **učební pomůcky** (svého druhu mapové učebnice pro jednotlivou hodinu), ve kterých se prolínají stručný text, interaktivní mapy, fotografie a multimediální obsah. Aktivita pro žáky pak typicky zabere 10–20 minut samostatné práce v hodině.

Pro tvorbu obsahu StoryMaps učitel využije **RAG nástroj NotebookLM** s nahranými zdroji z předchozích fází (články z CSIS a CFR, geografické a strategické pozadí, aktuální zpravodajství s ověřenými odkazy). Konkrétní prompt:

„Z přiložených zdrojů navrhni scénář krátké mapové narativní aplikace v ArcGIS StoryMaps na téma ‚Hormuzský průliv jako globální chokepoint‘ pro žáky 1. ročníku gymnázia. Aplikace má trvat přibližně 15 minut samostatné práce. Navrhni: - úvodní motivační scénu (text + návrh na obsah mapy); - 3–4 textových sekcí (každá do 80 slov, označ klíčová slova tučně); - 1 mapovou sekci (s popisem, co má zobrazovat mapa); - 1–3 fotografie (s tipy na zdroj z internetu, případně navrhni prompt pro generování obrázku či infografiky generativním AI nástrojem — například Gemini, ChatGPT s DALL-E, Midjourney); - 3–5 otázek nebo úloh pro žáky, které vyřeší s pomocí aplikace — odpovědi nebo argumenty najdou v textu nebo na mapách; - návrh na závěrečnou reflektivní otázku.“

Text formuluj přiměřeně 16letému žákovi gymnázia, vyhni se odbornému žargonu a respektuj limity čtenářské gramotnosti.“

NotebookLM vrátí strukturovaný scénář, který učitel přenesení do prostředí ArcGIS StoryMaps, doplní o konkrétní mapové vrstvy (ArcGIS Online disponuje rozsáhlou globální geodatabází) a

fotografie. Pro doplnění lze požádat o **pracovní list pro tisk**, do kterého žáci zaznamenají odpovědi na otázky a vlastní reflexi:

„K předchozí mapové aplikaci připrav pracovní list pro tisk (formát A4, jednostránkový), do kterého žáci zaznamenají: - odpovědi na otázky z aplikace; - vlastní formulaci toho, proč je Hormuzský průliv strategicky významný (max. 3 věty); - vlastní názor: jaká rizika by pro Evropu znamenalo dlouhodobé přerušení dopravy přes Hormuz?“

Síla tohoto postupu spočívá v možnosti **rychlé adaptace pro různé pedagogické kontexty**. S pomocí AI lze stejnou základní strukturu StoryMap, otázek i pracovního listu během několika minut upravit pro jiný ročník (například 9. třída ZŠ s jednodušším jazykem a širší motivační scénou) nebo pro žáky se specifickými vzdělávacími potřebami (zkrácený rozsah textu, vizuálně podpořené úlohy, alternativní formy záznamu). To, co by ručně vyžadovalo opakovanou přípravu, AI zvládne v rámci téže konverzace s několika dalšími prompty.

Co tento postup demonstruje: spojení **dvou kvalitativně odlišných nástrojů** — RAG platformy NotebookLM pro generování obsahu a ArcGIS StoryMaps pro interaktivní didaktickou prezentaci. Vznikne učební materiál, který by ručně vyžadoval několik hodin přípravy. Učitel si zachovává plnou kontrolu nad odbornou kvalitou (kontroluje výstupy z NotebookLM proti zdrojům) i nad didaktickou strukturou (rozhoduje o pedagogických cílech aplikace).

Pro budoucího učitele geografie je důležité vědět, že ArcGIS StoryMaps má pro tvorbu krátkých učebních pomůcek **systematický potenciál** — nejde o jednorázové použití pro Hormuz, ale o **typovou kombinaci nástrojů**, kterou lze opakovaně využít pro různá geografická témata.

Didaktická lekce

Tento scénář ilustruje princip, který platí napříč geografickým vzděláváním: **různé typy informací vyžadují různé typy nasazení AI**. Stabilní obecné informace (co je chokepoint) — samostatný LLM asistent stačí. Aktuální vývoj — režim s vyhledáváním. Hluboká analýza konkrétního zdroje — RAG s přiloženým dokumentem. Didaktická pomůcka pro výuku — kombinace RAG (NotebookLM) a specializované platformy (ArcGIS StoryMaps).

Učitel, který tento princip ovládá, dělá kvalifikovaná didaktická rozhodnutí. Učitel, který přistupuje ke všem dotazům přes samostatného LLM asistenta, riskuje katastrofickou chybu. **Diagnostická schopnost rozpoznat, jaký typ AI nasazení daná otázka vyžaduje, je sama o sobě klíčovou kompetencí učitele.**

Pracovní scénář 2: sucho v české krajině

Druhý pracovní scénář ukazuje cestu od prvního promptu k hotovému materiálu. Je úmyslně **běžný** — ne dramatický geopolitický kontext jako Hormuz, ale typická příprava hodiny, jakou učitel dělá pravidelně.

Situace

Učitelka geografie na 2. stupni ZŠ připravuje hodinu o suchu v české krajině pro 8. ročník v Libereckém kraji. Na hodinu má 45 minut, jako součást širšího bloku o vodě v krajině. Cíl hodiny: žáci **vysvětlí** vlastními slovy, proč v Česku přibývají období sucha, i když se země nachází v mírném pásu (úroveň: porozumění), a **navrhnou** alespoň dvě konkrétní opatření na úrovni samosprávy a jednotlivce, kterými lze sucho v krajině zmírnit (úroveň: tvorba).

Krok 1: Motivační úvod

Učitelka začne tam, kde jsme v podkapitole 2 skončili — třetí iterace promptu pro motivační úvod. Výstup již používá; v této podkapitole rozšiřujeme práci o další kroky.

Krok 2: Rozšíření o pracovní list

Z téže konverzace učitelka pokračuje:

„Skvělé. Teď k motivačnímu úvodu připrav krátký pracovní list pro práci ve dvojicích. Pracovní list obsahuje: - 3 úvodní otázky pro diskuzi ve dvojicích (otevřené, ne na jednoznačnou odpověď) - jeden krátký informační text (max. 200 slov) o současném stavu sucha v Česku - 3 otázky k textu (různé kognitivní úrovně podle Bloomovy taxonomie) - jeden úkol pro výstup ze dvojice — krátký nápad na opatření, které by žáci s rodiči mohli realizovat doma

Jazyk přiměřený 8. ročníku.“

Model vrací strukturovaný pracovní list. Učitelka ho **kontroluje proti faktům** — zejména informační text — a opravuje, co je nepřesné. Modelu nedůvěřuje na slovo; čísla o suchu si ověřuje na webu ČHMÚ a VÚV TGM.

Krok 3: Diferenciace pro slabšího žáka

Ve třídě je žák s diagnostikovanou dyslexií. Učitelka pokračuje:

„V téže struktuře připrav variantu pro žáka se sníženou čtenářskou gramotností. Zkrať informační text na 100 slov, použij krátké věty, vyhni se odborným pojmům, které nejsou nezbytné. Zachovej cíl pracovního listu.“

Druhá verze pracovního listu vzniká za další minutu.

Krok 4: Variace pro jihočeský kontext

Učitelka mimochodem chce vědět, jestli by hodinu mohla použít i kolegyně z Jihočeského kraje, se kterou pravidelně sdílí přípravy:

„Pokud bych stejnou hodinu chtěla použít v jihočeském regionu (například okolí Třeboně, kde je vodohospodářský kontext jiný — rybniční soustava, vědomá retenční voda v krajině), jak bys upravil/a obsah pracovního listu? Vypiš jen ty pasáže, které je třeba přepsat.“

Model identifikuje pasáže o lokálním kontextu (zmínky o krajině severních Čech, které jsou v Pojizeří relevantní) a navrhne nové znění pro Třeboňsko.

Krok 5: Kontrolní otázky

Učitelka chce hodinu uzavřít kontrolními otázkami, které by žáci řešili samostatně. Žádá v souladu s Bloomovou taxonomií kognitivních cílů:

„Vytvoř 5 kontrolních otázek pro žáky, které by řešili individuálně v posledních 5 minutách hodiny. Otázky pokrývají: - 2 otázky na zapamatování klíčových pojmů z hodiny - 2 otázky na porozumění (vlastními slovy vysvětlit příčinu sucha) - 1 otázka na aplikaci (žák navrhne 1 vlastní opatření) - u každé otázky uveď klíč k řešení pro učitele.“

Z původního dvouminutového promptu se postupně stala **funkční sada didaktických materiálů** pro celou hodinu: motivační úvod, pracovní list ve dvou variantách (běžná + diferencovaná), regionální variace pro jiný kraj, kontrolní otázky s klíčem. Reálný čas přípravy: kolem 25 minut konverzace s AI plus následných 15 minut kontroly faktů a dopracování. Bez AI by tato příprava trvala přibližně 3 hodiny.

Co tento scénář ukazuje

Tři klíčové poznatky:

Hodnota AI je v rozšiřování, ne v nahrazování. Učitelka zachovává plnou kontrolu nad obsahem, didaktickými cíli, regionálním ukotvením. AI dělá rutinní formulační práci, ke které by jinak ručně psala. Výsledek je její, ne AI.

Iterativní konverzace je klíčová. Pět navazujících promptů v jedné konverzaci dává kvalitativně lepší výsledek než pět samostatných promptů od začátku. Model si pamatuje předchozí výměny a každé další zadání staví na předchozím.

Kontrola faktů zůstává prací učitele. AI neumožňuje vyhnout se ověřování — naopak ho **vyžaduje**, protože faktografické chyby by jinak prošly do hodiny. Investice 15 minut do kontroly proti webu ČHMÚ a VÚV TGM je nutnou součástí postupu.

Rychlé čtení podkapitoly 4

Hlavní teze: AI v geografickém vzdělávání má svá specifika — fakticko-prostorové (vysoké riziko halucinace u geografických údajů), lokální (řidká data o českém prostředí), oborové (geografie jako hybridní disciplína), typové (text vs. prostorová data).

Vhodné použití AI: příprava textových materiálů, brainstorming, diferenciacce, generování scénářů, sumarizace, prvotní rešerše, zpětná vazba na vlastní materiály.

Nevhodné nebo rizikové použití: faktografické a místopisné údaje, aktuální data bez vyhledávání, lokálně specifické informace, přesné mapy, přesné výpočty, profesní rozhodnutí s odpovědností, autentická místní zkušenost.

Práce s revidovaným RVP v RAG režimu (5 kroků): připravit dokumenty → zvolit RAG nástroj → ověřit, že nástroj „přečetl“ celé → strukturovaná konverzace → iterace a kritické čtení.

Specializované platformy nad LLM: NotebookLM (s nadstavbovými funkcemi — Audio Overview, Mind mapy), Claude Projects, vlastní GPTs, ScioBot. Klíčová výhoda: výrazně nižší riziko halucinace v rámci nahraných zdrojů.

Ekosystém AI nástrojů: specializované rešeršní nástroje (Consensus, Scite) → RAG platformy pro syntézu → obecní LLM asistenti pro brainstorming a editaci. Pro běžnou denní práci stačí obecný LLM.

AI Lesson Plan Generators v ČR: ScioBot (sciobot.cz) jako nejrozšířenější český nástroj s metodou E-U-R.

Iniciativa AI dětem (Eva Nečasová, chatveskole.cz): rámec „4 kroky ke smysluplnému učení s AI“, **10 způsobů využití GenAI ve výuce**, metodika formativního hodnocení, databáze AI asistentů, doporučení pro ZŠ/SŠ a VŠ. Klíčový **referenční materiál** pro budoucího učitele. Doplnkově UNESCO *AI Competency Framework for Students* (Miao & Shiohira, 2024) jako globální rámec pro rozvoj žákovských kompetencí.

GeoAI: průsečík AI s prostorovou analýzou. Předtrénované modely v ArcGIS dramaticky zvyšují dostupnost. V horizontu jednoho až dvou let očekávané rozšíření vlastní práce žáků s GeoAI na gymnáziu (detekce změn v zástavbě, klasifikace krajinného pokryvu, analýza dronových snímků). **Vztah s LLM asistenty: komplementarita** — text vs. prostorová data.

Geografická specifika promptování: investovat víc do kontextu, explicitně jmenovat lokální specifika, zpochybnit číselné údaje, pro aktuální data režim s vyhledáváním nebo RAG, pro lokální informace zapojit lidský zdroj.

Pracovní scénář Hormuzský průliv ilustruje, že **různé typy informací vyžadují různé typy nasazení AI** — stabilní obecné informace → samostatný LLM, aktuální vývoj → režim s vyhledáváním, hloubková analýza → RAG, didaktická pomůcka → kombinace RAG (NotebookLM) + ArcGIS StoryMaps.

Pracovní scénář sucho v české krajině ukazuje cestu od prvního promptu k hotovému materiálu pro hodinu — pět navazujících promptů v jedné konverzaci generuje motivační úvod, pracovní list ve dvou variantách, regionální variace, kontrolní otázky s klíčem v souladu s Bloomovou taxonomií. Klíčové: **AI rozšiřuje, nikoli nahrazuje učitele; kontrola faktů zůstává prací učitele.**

V podkapitole 5 přejdeme k pokročilým technikám promptování. V podkapitole 6 se vrátíme k etickým a epistemickým aspektům — halucinace, ověřování (SIFT), ekologická stopa, akademická integrita, kulturně-jazykové zkreslení.

5. Pokročilé techniky promptování

Co odlišuje pokročilé techniky od základů

V podkapitole 2 jste se naučili základ promptování — tři komponenty (kontext, úkol, cíl), strukturování, iteraci, RAG práci s přiloženými dokumenty. To je dostatečné pro většinu úkolů, se kterými se učitel geografie setká v každodenní praxi. Pokročilé techniky, které představuje tato podkapitola, otevírají **další kvalitativní rovinu**: situace, kdy potřebujete od LLM asistenta odpověď, která je hlubší, kreativnější, kritičtější nebo přesněji odpovídá specifickému didaktickému záměru.

Pokročilé techniky se od základů odlišují třemi rysy. **Za prvé**, vědomě **využívají toho, jak LLM zpracovává prompt** — například toho, že explicitně zadaný řetěz uvažování vede k jiným výsledkům než přímý dotaz. **Za druhé**, často **kombinují několik prvků** v jednom promptu (například role + příklady + krok za krokem), čímž dosahují kvalitativně jiných výsledků. **Za třetí, vyžadují cvičení a iteraci** — málokterý učitel zvládne pokročilé techniky napoprvé. Investice do jejich osvojení se ale vrátí ve formě výrazně kvalitnějších výstupů u náročných úkolů.

Praktická poznámka před čtením této podkapitoly. Otevřete si nyní svůj oblíbený LLM asistent (Claude, ChatGPT, Gemini, Mistral, ScioBot nebo jiný) v sousedním okně prohlížeče. Většinu příkladů, které v této podkapitole najdete, můžete přímo zkopírovat a otestovat ve své AI. Pasivní čtení o pokročilých technikách promptování má omezenou hodnotu — skutečné porozumění přichází ve chvíli, kdy techniku sami vyzkoušíte na konkrétním úkolu a srovnáte výstupy s vlastním očekáváním. **Investice do aktivního čtení této podkapitoly se vyplátí.**

Než přejdeme k jednotlivým technikám, dvě obecná upozornění.

Trend reasoning modelů. V současnosti probíhá výrazný posun ve vývoji LLM směrem k modelům s **vestavěným uvažováním** (reasoning, extended thinking) — modely typu o1, o3 od OpenAI, Claude s režimem extended thinking, Gemini s reasoning módem, DeepSeek R1. Tyto modely mají v sobě integrován mechanismus, který před vlastní odpovědí provádí **vnitřní řetěz uvažování** — model se sám sebe ptá, plánuje řešení, kontroluje předpoklady. Pro uživatele to znamená, že **některé pokročilé techniky** (zejména klasický Chain-of-Thought, kdy explicitně žádáme „postupuj krok za krokem“) **se u reasoning modelů stávají nadbytečnými** nebo dokonce kontraproduktivními (model uvažuje sám a explicitní instrukce k uvažování ho jen zdržuje). Pokud pracujete s reasoning modelem, sledujte v dokumentaci nástroje doporučení, které techniky nepoužívat.

Pokročilé techniky nejsou nutné pro každý prompt. Pokud učitel ke každému dotazu o povodních zformuluje šestiřádkový prompt s rolí, příklady, krok za krokem instrukcemi a meta-kognitivní reflexí, výsledek bude **horší**, než kdyby zformuloval jednoduchý strukturovaný prompt s třemi komponentami. Pokročilé techniky jsou nástroje pro **náročné úkoly** — komplexní přípravy, projektová zadání, analýzu mediálních výstupů, hluboké zpětné vazby. Pro běžnou rutinu zůstávají základy z podkapitoly 2 dostatečné.

S tímto rámcem přistupme k jednotlivým technikám.

Šest základních pokročilých technik

1. Role-based prompting

Princip. Modelu zadáte konkrétní **rolí, ze které má odpovídat**. Místo neutrálního stavu „LLM asistent“ model přijímá perspektivu konkrétní expertní role — učitele, didaktika, geografa, historika, kritika, žáka. Role řídí výběr slovníku, hloubku zpracování, hierarchii hodnot, rétorický rejstřík.

Krátký příklad.

„Vystupuj jako zkušený didaktik geografie s 20letou praxí na druhém stupni ZŠ. Posuď, zda následující pracovní list vede žáky k myšlení vyššího řádu, nebo zůstává na úrovni faktografického zapamatování. Při hodnocení pracuj s revidovanou Bloomovou taxonomií. [pracovní list]“

Kdy použít. Role-based prompting je obzvlášť silný, když potřebujete **odbornou nebo expertní perspektivu** — kritickou recenzi materiálu, zhodnocení návrhu, simulaci dialogu s žákem. Méně se hodí pro úkoly, kde je odbornost nadbytečná (jednoduchá tvorba textu, formulační úpravy).

2. Chain-of-thought

Princip. Modelu **explicitně řeknete, ať postupuje krok za krokem** a každý krok zdůvodní. Tím se aktivuje sekvenční zpracování úkolu, které u některých úloh vede k výrazně přesnějším výsledkům — model sám zachytí mezikroky, které by jinak přeskočil. Technika je obzvlášť silná pro úlohy s logickým, matematickým nebo analytickým charakterem.

Krátký příklad.

„Postupuj krok za krokem: (1) Identifikuj v přiloženém textu o suchu všechna tvrzení o příčinách. (2) Pro každé tvrzení posuď, zda jde o příčinu přírodní, společenskou nebo kombinovanou. (3) U každého tvrzení uveď, na jaké klíčové kompetenci RVP ZV by se na tomto základě dalo stavět ve výuce.“

Kdy použít. Pro úlohy s analytickým charakterem, kde záleží na sekvenci úvah. Méně užitečné u kreativních úloh (brainstorming, generování variant), kde naopak chceme rychlou produkci a ne metodickou analýzu. **Pozor na reasoning modely** — u nich může být explicitní Chain-of-Thought nadbytečné a zbytečně zpomalující.

3. Few-shot prompting

Princip. Model dostane **několik konkrétních příkladů** požadovaného formátu odpovědi a poté se po něm chce pokračovat ve stejném vzoru. Few-shot znamená „několik příkladů“ (typicky 2 až 5). Pokud zadáte jen jeden příklad, jde o **one-shot prompting**. Pokud žádný, jde o **zero-shot** — to je běžný způsob, kterým většina uživatelů s LLM komunikuje.

Few-shot je cenný v situacích, kdy je obtížné přesně popsat slovy formát požadovaného výstupu, ale snadno se ukáže na příkladu.

Krátký příklad.

„Generuj otázky k diskusi pro hodinu o globálních problémech. Sleduj formát z následujících příkladů:

Příklad 1: Téma: Migrace. Otázka: Jaký rozdíl je mezi pohybem člověka, který emigruje za prací, a člověka, který opouští zemi kvůli válce? Které z těchto pohybů zachycují mediální výstupy o ‚migrační krizi‘?

Příklad 2: Téma: Plastový odpad v oceánech. Otázka: Pokud denně vyhazujeme plastovou láhev, jaká je pravděpodobnost, že její část skončí v oceánu? Co určuje, zda plast doputuje k pobřeží Indického oceánu, nebo zůstane na české skládce?

Příklad 3: Téma: Dezertifikace. Otázka: Sahara se rozšiřuje. Co to znamená pro lidi, kteří žijí na okraji pouště? Co s tím Evropská unie může udělat — a co je realisticky ochotná dělat?

Pokračuj ve stejném formátu pro tato témata: ztráta biodiverzity, městská zástavba na úrodné půdě, voda jako mezinárodní zdroj konfliktu.“

Kdy použít. Pro úkoly, kde má výstup **specifický formát**, který je obtížné zachytit pravidly, ale snadno na příkladu. Few-shot je obzvlášť silný pro generování série materiálů ve stejném stylu (testové otázky, motivační úvody, stručné popisy regionů).

4. Reframing

Princip. Pokud model na první formulaci úkolu reaguje neuspokojivě, **přeformulujete úkol z jiné perspektivy nebo jiným přístupem**. Reframing není pouhé „zopakování trochu jinak“ — je to vědomá změna **rámu myšlení**, kterou modelu dáváte. Místo „popiš mi povodně v Česku“ zformulujete „představ si, že jsi novinář, který připravuje reportáž o povodních pro mladé čtenáře. Jaké tři otázky bys jako první zadal expertovi?“. Stejně téma, dramaticky odlišný výstup.

Krátký příklad.

Původní prompt: „Vysvětli pojem ekologický otisk.“

Reframing: „Žák 8. třídy slyší pojem ekologický otisk poprvé a chce vědět, proč ho zajímá. Vysvětli mu to v rozhovoru, ve kterém se ptá a ty mu odpovídáš. Žákovy otázky musí znít jako otázky 14letého kluka.“

Kdy použít. Když první výstup působí ploše, obecně, akademicky, nezáživně. Reframing je silný nástroj pro **revitalizaci úkolu**, který se zdál triviální.

5. Step-by-step decomposition

Princip. Velký komplexní úkol **rozdělíte na menší podúkoly** a model je řeší postupně. Liší se od Chain-of-Thought tím, že **dekompozici provádí uživatel**, ne model. Step-by-step decomposition je obvykle součástí strukturovaného promptu, ne instrukce „postupuj krok za krokem“.

Krátký příklad.

„Připrav strukturu projektové práce pro žáky 9. ročníku na téma „Voda v krajině naší obce“. Rozděl práci do těchto fází:

1. Motivační úvod a vyvolání zájmu (cca 1 vyučovací hodina) 2. Sběr informací — práce s mapami, návštěva obecního úřadu, rozhovor s pamětníkem (1 týden mimo vyučování) 3. Analýza získaných informací (1 hodina) 4. Tvorba výstupu — krátká prezentace nebo plakát (2 hodiny) 5. Sdílení s ostatními žáky a reflexe (1 hodina)

Pro každou fázi navrhní: konkrétní cíl, role žáků, role učitele, doporučené nástroje (včetně AI, kde se hodí), předpokládané výstupy, kritéria hodnocení.“

Kdy použít. Pro **velké komplexní úkoly**, kde model snadno přeskóčí důležité prvky. Step-by-step decomposition zaručuje, že model neopomine žádnou z fází.

6. Meta-cognitive prompting

Princip. Po vygenerování odpovědi model požádáte, aby **sám reflektoval kvalitu vlastní odpovědi** a vylepšil ji. Tato sebereflexe často odhalí chyby, které by samotná odpověď nezachytila — chybějící perspektivy, neodůvodněná zjednodušení, slabě podložená tvrzení.

Krátký příklad.

Po vygenerované odpovědi: „Než tvou odpověď přijmu, projdi ji ještě jednou. Co bys ty sám/a opravil/a nebo přepracoval/a, kdybys měl/a odpovídat znovu? Které pasáže jsou nejslabší? Které tvrzení v odpovědi je nejméně podložené a měl/a bys ho zpochybnit?“

Kdy použít. Když potřebujete **kvalitnější výstup pro důležitý didaktický kontext** — finální verze pracovního listu, kritická recenze materiálu, příprava na hodinu, ke které se nemůžete v průběhu vrátit. Meta-cognitive prompting funguje jako automatická druhá redakce.

Tři další užitečné techniky

7. Prompt chaining

Princip. Místo jednoho velkého promptu zadáte **řetěz menších promptů**, kde výstup jednoho slouží jako vstup dalšího. Každý článek řetězu má jasný úkol a model nemusí uvažovat o celém workflow najednou. Prompt chaining je v praxi často přirozeným pokračováním iterativní konverzace, ale můžeme ho i **vědomě plánovat předem**.

Krátký příklad. Místo „*napiš pracovní list o povodňové prevenci*“ (jeden velký prompt) jdete řetězem:

1. „*Vygeneruj 10 možných témat hodiny o povodňové prevenci pro 8. ročník.*“
2. „*Z těchto 10 témat vyber tři, která nejvíc rozvíjejí myšlení vyššího řádu. Zdůvodni výběr.*“
3. „*K vybraným třem tématům navrhni strukturu hodiny.*“
4. „*Pro téma, které jsi označil/a jako nejlepší, vytvoř pracovní list.*“

Kdy použít. Pro **složitě úkoly s několika fázemi**, kde každá fáze ovlivňuje další. Prompt chaining dává učiteli kontrolu — můžete v kterémkoli článku řetězu zasáhnout, upravit směr, vrátit se zpět.

8. Negative prompting / constraint specification

Princip. Explicitně specifikujete, **co model NEMÁ dělat**. Toto se zdá triviální, ale je to nedoceňovaná technika. LLM má tendenci sklouzávat k typickým vzorcům (Bloomova taxonomie všude, ke každému tématu odkazy na Wikipedii, zakončení odstavce řečnickou otázkou). Pokud chcete jinou strukturu, **musíte typický vzorec explicitně zakázat**.

Krátký příklad.

„Připrav pracovní list o vodním hospodářství. Omezení: - NEPOUŽÍVEJ Bloomovu taxonomii ani její terminologii - NEZAHNRNUJ odkazy na Wikipedii - NEKONČI úkoly řečnickou otázkou - NEPOUŽÍVEJ frázi je důležité si uvědomit, že' - NEDÁVEJ na konec povinný ‚závěr a shrnutí‘“

Kdy použít. Když máte **konkrétní představu, jak výstup nemá vypadat**. Negative prompting je obzvláště cenný pro učitele, kteří už dobře vědí, jaké formulace jsou pro jejich třídu nepoužitelné.

9. Error injection

Princip. Modelu **záměrně zadáte text s chybou** a požádáte ho, aby chybu našel a vysvětlil. Tato technika má dvojí didaktickou hodnotu. **Pro učitele:** rychlá kontrola, zda model dokáže rozeznat běžné nesrovnalosti (užitečné při testování, jak důvěryhodný model je). **Pro žáky:** vynikající výuková aktivita — žáci dostanou text, ve kterém je chyba, a mají s pomocí AI najít a popsat ji. Učí se kritickému čtení i kritické práci s AI současně.

Krátký příklad pro výuku.

„V následujícím textu o klimatu je úmyslně skryta jedna faktografická chyba. Najdi ji, vysvětli, proč je to chyba, a navrhní správné znění:

„Sahara je největší poušť světa s rozlohou přibližně 9 milionů km². Jihovýchodně od ní leží oblast Sahel, která tvoří přechod mezi pouštěmi a vlhkými tropy. Sahel se v posledních desetiletích rozšiřuje severním směrem, protože dezertifikace v Saharě tlačí pouštní oblast jižněji.“

(Chyba: směr šíření Sahelu — pouštní oblast se rozšiřuje jižně do Sahelu, ne naopak.)

Kdy použít. Jako učební aktivitu se žáky pro nácvik kritického čtení. Také jako **diagnostiku spolehlivosti modelu** — pokud model chybu nenajde, je to varovný signál, jak důvěryhodné jsou jeho další odpovědi v dané oblasti.

Dvě nadtechniky pro strukturování promptu

10. XML tagy pro pokročilé strukturování

V podkapitole 2 jste se naučili strukturovat prompt prázdnými řádky a popisky sekcí (*Kontext*, *Úkol*, *Výstup*). Tato forma je dostatečná pro většinu úkolů. Pro **složitě prompty** s vnitřními vrstvami (například prompt obsahující ukázkové texty, doplňující kontextové informace, složitá specifikace formátu) se ale vyplatí ostřejší forma — **XML tagy**.

XML tag uzavírá konkrétní část promptu mezi otevírací a uzavírací značku, čímž modelu dává jednoznačný signál o tom, kde sekce začíná a končí. Použití je inspirováno doporučeními pro Claude, ale dobře funguje i v ostatních nástrojích.

Krátký příklad.

```
<role>
Jsi zkušený didaktik geografie s praxí na druhém stupni ZŠ.
</role>

<úkol>
Posuď přiložený pracovní list a navrhní úpravy.
</úkol>

<pracovní_list>
PRACOVNÍ LIST: Vodní hospodářství v krajině Pro 8. ročník ZŠ

Úloha 1: Co je to retence vody v krajině? Napiš vlastními slovy.
```

Úloha 2: Vyjmenuj 3 přírodní prvky a 3 lidské zásahy, které ovlivňují, kolik vody krajina zadrží.

Úloha 3: Najdi v okolí své obce jedno místo, kde je voda v krajině zadržena (rybník, mokřad, les), a jedno místo, kde voda z krajiny rychle odtéká (zpevněné plochy, narovnaný potok). Stručně popiš obě místa.

Úloha 4: Navrhni jedno opatření, které by v okolí tvé obce zlepšilo retenci vody.

<výstup>

Pro každý zjištěný problém v pracovním listu uveď:

- konkrétní úlohu, které se týká
- důvod, proč je to problém
- konkrétní úpravu, kterou navrhuješ

Posuď zejména:

- zda jsou úlohy jasně formulované
- zda kognitivní náročnost úloh stoupá od první k poslední
- zda jsou úlohy realisticky řešitelné v rámci jedné vyučovací hodiny

</výstup>

Kdy použít. Pro **složené prompty s vnitřní strukturou**, kde běžné oddělení prázdnými řádky není dostatečné. Také pro **opakovaně používané promptové šablony** — XML tagy umožňují snadnou výměnu obsahu jednotlivých sekcí, aniž by se rozbila celková struktura.

11. Kombinace technik

Pokročilé techniky jsou v praxi **málokdy používány samostatně**. Většina silných promptů kombinuje **tři až pět technik najednou**. Typická kombinace pro náročný úkol:

- **role-based prompting** (zadání odborné perspektivy)
- **few-shot prompting** (několik vzorových příkladů formátu)
- **step-by-step decomposition** (rozdělení úkolu na fáze)
- **negative prompting** (specifikace toho, co model NEMÁ dělat)
- **meta-cognitive prompting** (závěrečná sebereflexe modelu)

Toto skládání je nejhodnotnější dovedností pokročilého promptování. Učí se cvičením — uživatel postupně sleduje, **které kombinace v jaké situaci fungují**, a buduje si vlastní repertoár.

V další části této podkapitoly si tuto kombinaci ukážeme na pěti komplexních promptech pro typické geografické úkoly. Každý prompt je zároveň **ukázkou pro analýzu** (kde můžete identifikovat použité techniky) a **ukázkou pro testování** (kde můžete prompt zkopírovat do svého LLM asistenta a pozorovat výstup).

Orientační přehled — kdy jakou techniku použít

Pro praktickou orientaci uvádíme přehled toho, jaké techniky jsou pro typické učitelské úkoly nejvhodnější. Tabulka není vyčerpávající a slouží jako vodítko, ne jako pravidlo.

ÚKOL	HLAVNÍ TECHNIKY	DOPLŇKOVÉ TECHNIKY
Formulační variace, brainstorming	reframing, few-shot	(techniky obvykle nejsou potřeba)
Rozsáhlá příprava hodiny	role-based, step-by-step decomposition, negative prompting	meta-cognitive, prompt chaining
Tvorba sady testových otázek	few-shot, role-based	step-by-step (pro různé kognitivní úrovně)
Kritická recenze materiálu	role-based, meta-cognitive	chain-of-thought
Analýza dat, mediálních výstupů	chain-of-thought, role-based	step-by-step decomposition
Komplexní projektová zadání	step-by-step decomposition, role-based	prompt chaining, XML tagy
Adaptace pro různé úrovně žáků	reframing, few-shot	(často součást iterace)
Diagnostika spolehlivosti modelu	error injection	meta-cognitive
Výuková aktivita s AI pro žáky	error injection, role-based	reframing

Některé techniky jsou **univerzálně užitečné** napříč úkoly (role-based, meta-cognitive), jiné mají **specifický rozsah použití** (few-shot pro formátované série, error injection pro diagnostiku a výuku). S praxí získáte intuici, která kombinace pro váš konkrétní úkol nejlépe funguje.

V druhé části této podkapitoly, která následuje, ukážeme **pět komplexních ukázkových promptů** — pro analýzu i pro testování. Každý prompt je navržený tak, aby v něm bylo možné rozpoznat několik z představených technik a aby ho bylo možné okamžitě zkopírovat a zkusit ve vlastním LLM asistentovi.

Pět komplexních ukázkových promptů — pro analýzu i testování

V této části podkapitoly najdete pět komplexních promptů pro typické úkoly učitele geografie. Každý prompt je navržený tak, aby kombinoval několik z dříve představených technik a aby byl přímo použitelný — můžete ho zkopírovat do svého LLM asistenta a otestovat. U každého promptu najdete dvě části:

- **Analýza promptu** — které techniky jsou v něm použité a proč jsou v této kombinaci vhodné.
- **Návrh varianty pro testování** — jak prompt upravit pro vlastní situaci, ročník nebo region.

Doporučujeme **postupovat aktivně**: prompt zkopírovat, otestovat, přechíst odpovědi LLM asistenta, porovnat s vlastním očekáváním, a teprve pak číst analytický komentář. Tato sekvence — pokus, vlastní reflexe, teoretická analýza — odpovídá principům aktivního učení a vede k hlubšímu osvojení technik.

Prompt 1: Příprava hodiny o povodňové prevenci pro konkrétní region

```
<role>
Jsi zkušený didaktik geografie s 15letou praxí na druhém stupni ZŠ. Specializuješ se
na výuku fyzické geografie ČR a problematiku vody v krajině.
</role>

<situace>
Jsem učitel geografie, připravuji vyučovací hodinu o povodňové prevenci pro 8.
ročník. Hodina trvá 45 minut. Žáci pocházejí z Liberce a okolí, mají osobní zkušenost
s povodněmi v Pojizeří v posledních letech. Ve třídě je jeden žák s diagnostikovanou
dyslexií, dva žáci s odlišným mateřským jazykem (vietnamština, ukrajinština).
</situace>

<úkol>
Navrhni strukturu této vyučovací hodiny. Postupuj v následujících krocích:

1. Formuluj jeden hlavní vzdělávací cíl hodiny v souladu s revidovanou Bloomovou
taxonomií – cíl má být formulován aktivním slovesem a odkazovat ke konkrétní
pozorovatelné činnosti žáka.

2. Navrhni minutovou strukturu hodiny (motivační úvod, hlavní obsahová část, závěr).
Pro každou část uveď konkrétní aktivitu žáků a roli učitele.

3. K hlavní obsahové části navrhni dvě klíčové otázky, které mají vést žáky k myšlení
vyššího řádu (analýza, hodnocení, tvorba), ne pouze k zapamatování faktů.

4. Pro žáka s dyslexií a pro žáky s odlišným mateřským jazykem navrhni konkrétní
diferenciační opatření, které lze v hodině realizovat.
</úkol>

<omezení>
- NEPOUŽÍVEJ obecná témata typu "globální povodňová rizika" – vždy ukotvit v Pojizeří
nebo přílehlém regionu.
- NEZAHRNUTÍ úlohy, které vyžadují přesné faktografické údaje o konkrétních
povodňových událostech (riziko halucinace).
```

- NEKONČI hodinu pasivním shrnutím učitele – závěr má aktivně zapojit žáky.
</omezení>

<reflexe>

Po vygenerování návrhu projdi jeho výsledek ještě jednou a zhodnoť:

- Které části návrhu jsou nejslabší?
 - Kde mohou nastat praktické problémy v reálné hodině?
 - Co bys ty sám v navrženém schématu přepracoval, kdybys měl odpovídat znovu?
- </reflexe>

Analýza promptu. Kombinace pěti technik:

- **Role-based prompting** — odborná perspektiva didaktika geografie (15 let praxe, specializace na vodu v krajině) řídí slovník a hloubku odpovědi.
- **Step-by-step decomposition** — explicitní rozdělení úkolu do čtyř kroků zaručuje, že model neopomine žádnou klíčovou fázi přípravy.
- **Negative prompting** — sekce *omezení* explicitně zakazuje typické vzorce, které by snížily kvalitu odpovědi (obecnost, halucinace, pasivní závěr).
- **Meta-cognitive prompting** — sekce *reflexe* nutí model k závěrečnému kritickému přehodnocení vlastního výstupu.
- **XML tagy** — přehledné oddělení pěti vrstev promptu (role, situace, úkol, omezení, reflexe).

Návrh varianty pro testování. Adaptujte prompt pro vlastní region a ročník. Nahradte Liberec a Pojizeří svou lokalitou (například Jihočeský kraj, Třeboňsko), upravte ročník (například 6. nebo 9.), případně téma (sucho v krajině, voda v urbanizovaných oblastech). Po obdržení odpovědi zkuste prompt zkopírovat do druhého LLM asistenta (například Claude → ChatGPT) a porovnejte výstupy. Pozorujte, ve kterých částech jsou nástroje srovnatelné a ve kterých se výrazně liší.

Prompt 2: Tvorba sady testových otázek k regionální geografii Evropy

<role>

Jsi zkušený autor učebnic geografie pro 2. stupeň ZŠ a tvůrce testových materiálů. Tvé otázky jsou známe tím, že rovnoměrně pokrývají různé kognitivní úrovně Bloomovy taxonomie a vyhýbají se jednoduchému zapamatování faktů.

</role>

<úkol>

Vytvoř sadu 10 testových otázek pro žáky 8. ročníku k tématu "Hospodářské zóny Evropy" (průmyslové oblasti, zemědělské regiony, turistická centra, suroviny). Sleduj formát následujících příkladů a zachovej stejný styl i kvalitu:

PŘÍKLAD 1 (úroveň: porozumění)

Otázka: Vlastními slovy vysvětli, proč se těžký průmysl v Evropě tradičně koncentroval do oblasti Porúří v Německu. Které dva přírodní faktory hrály v této koncentraci klíčovou roli?

Klíč pro učitele: blízkost ložisek černého uhlí a železné rudy; říční doprava (Rýn).
Hodnocení: 2 body za uvedení obou faktorů, 1 bod za jeden.

PŘÍKLAD 2 (úroveň: aplikace)

Otázka: Představ si, že máš rozhodnout o umístění nového logistického centra v Evropě. Které tři geografické faktory bys při výběru lokality posuzoval/a jako nejdůležitější? Pro každý faktor uveď, proč je důležitý.

Klíč pro učitele: dopravní napojení (silnice, železnice, přístavy); vzdálenost k cílovým trhům; dostupnost pracovní síly. Možné jsou i jiné relevantní odpovědi (cena pozemků, daňové podmínky), pokud žák zdůvodní.

PŘÍKLAD 3 (úroveň: analýza)

Otázka: Středomořské zemědělství se výrazně liší od zemědělství severoevropského. Identifikuj tři hlavní rozdíly a u každého rozdílu uveď, zda jeho příčina je převážně přírodní, převážně společenská, nebo kombinovaná.

Klíč pro učitele: typické plodiny (vín, olivy, citrusy vs. obiloviny, brambory) – kombinace přírodních a společenských faktorů; způsob zavlažování (intenzivní vs. méně potřebné) – převážně přírodní (klíma); velikost farem – převážně společenská (historický vývoj vlastnictví).

Pokračuj ve stejném formátu – vytvoř dalších

10 otázek, které pokryjí kognitivní úrovně:

- 2x zapamatování (s klíčem)
- 2x porozumění (s klíčem)
- 2x aplikace (s klíčem)
- 2x analýza (s klíčem)
- 1x hodnocení (s klíčem a tipem na vedení diskuze)
- 1x tvorba (s klíčem a popisem očekávaného výstupu)

</úkol>

<omezení>

- Nepoužívej otázky typu "Vyjmenuj 5 zemí v jihovýchodní Evropě" – to je čisté zapamatování bez geografického porozumění.
- Vyhýbej se přesným statistickým údajům (přesný počet obyvatel, přesný HDP) – riziko halucinace.
- Vyhýbej se klišé typu "v dnešní globalizované době" nebo "v rámci udržitelného rozvoje".

</omezení>

Analýza promptu. Kombinace tří hlavních technik:

- **Few-shot prompting** — tři detailní ukázkové příklady (s klíčem pro učitele a hodnocením) modelu jasně ukazují požadovaný formát. Bez těchto příkladů by model vrátil otázky generického stylu, který se podobá učebnicím, ale neodpovídá pedagogickému záměru.
- **Role-based prompting** — odborná role autora učebnic řídí kvalitu a styl otázek.
- **Negative prompting** — sekce *omezení* explicitně zakazuje typické nekvalitní vzorce (otázky na pouhé zapamatování, halucinační statistiky, klišé).

Spojení few-shot prompting s explicitním požadavkem na kognitivní úroveň Bloomovy taxonomie zaručuje **kvalitativní rovnoměrnost sady** — model neudělá deset otázek na zapamatování, jen proto, že jsou snazší k vygenerování.

Návrh varianty pro testování. Adaptujte prompt pro jiné regionální téma (Asie, Afrika, Severní Amerika) nebo pro jiný ročník (6. ročník — fyzická geografie světadílů; 9. ročník — Česká

republika v evropském kontextu). Můžete také experimentovat se změnou počtu příkladů — odeberte druhý příklad a zkuste, jak few-shot funguje při dvou ukázkách místo tří. Pozorujte, jak se kvalita výstupu mění.

Prompt 3: Návrh projektové práce o místních prostorových nerovnostech

<role>

Jsi didaktik geografie specializující se na badatelsky orientované učení a projektovou výuku. Pracoval/a jsi v České republice s žáky i s učiteli a rozumíš realitě českých škol.

</role>

<úkol>

Navrhni komplexní projektovou práci pro žáky 9. ročníku ZŠ na téma "Prostorové nerovnosti v naší obci a okolí". Projekt bude trvat 4 týdny (přibližně 8 vyučovacích hodin + samostatná práce mimo školu).

Postupuj v následujících krocích:

KROK 1: Vymezení tématu pro žáky.

Naformuluj, jak žákům představit pojem "prostorové nerovnosti" tak, aby byl srozumitelný a osobně relevantní. Uveď konkrétní úvodní otázky, které u žáků vyvolají zájem o téma.

KROK 2: Strukturace projektu do fází.

Rozděl projekt do 5 fází (úvod a motivace, sběr informací, analýza dat, tvorba výstupu, sdílení a reflexe). Pro každou fázi uveď:

- časový rozsah
- konkrétní aktivity žáků
- roli učitele
- doporučené nástroje (včetně AI tam, kde se hodí, a poznámky, kdy AI není vhodná)
- konkrétní výstup fáze

KROK 3: Návrh konkrétních badatelských otázek.

Připrav 5 možných badatelských otázek, mezi kterými žáci (ve dvojicích nebo trojicích) vyberou. Otázky musí být:

- realisticky řešitelné v rámci 4 týdnů
- místně ukotvené (ne globální)
- otevřené (více než jedna správná odpověď)
- propojené s životní zkušeností žáků

KROK 4: Návrh kritérií hodnocení.

Vypiš 5–7 kritérií pro hodnocení projektu. Pro každé kritérium uveď tři úrovně dosažení (začínající – pokročilý – výborný) s konkrétními pozorovatelnými projevy.

KROK 5: Identifikace rizik a tipů pro učitele.

Uveď 3–5 typických problémů, které mohou v tomto projektu nastat (nezájem části žáků, nerovnoměrné zapojení ve dvojicích, citlivost tématu pro některé rodiny atd.), a navrhni konkrétní strategie, jak s nimi učitel může pracovat.

</úkol>

<omezení>

- NEPOUŽÍVEJ obecné fráze typu "rozvoj klíčových kompetencí" bez konkrétního pojmenování, kterou kompetenci a jak.

- NEZAVRHUJ žakovskou perspektivu – žáci nejsou pasivní příjemci, ale spolutvůrci projektu.
 - NEPŘEDPOKLÁDEJ ideální podmínky (nadšená rodina, spolupracující obecní úřad, vstřícné vedení školy) – naopak, nech v návrhu prostor pro to, že některé žáky bude třeba motivovat.
 </omezení>

<reflexe>

Po vygenerování návrhu projdi jeho výsledek ještě jednou a zhodnoť:

- Pro kterou fázi projektu je AI nejvíc užitečná a pro kterou naopak není vhodná?
- Které části návrhu vyžadují největší přípravu ze strany učitele?
- Jaká rizika může projekt mít pro žáky ze sociálně znevýhodněných rodin (téma prostorových nerovností se jich může osobně dotknout)?

</reflexe>

Analýza promptu. Tento prompt je nejkomplexnější ze všech pěti — kombinuje **šest technik**:

- **Role-based prompting** s velmi specifickou rolí (badatelsky orientované učení v českém kontextu).
- **Step-by-step decomposition** s pěti explicitními kroky.
- **Negative prompting** v sekci *omezení*.
- **Meta-cognitive prompting** v závěrečné sekci *reflexe* s konkrétními kritickými otázkami.
- **XML tagy** pro strukturování pěti vrstev promptu.
- **Implicitní constraint specification** — požadavek na konkrétní pozorovatelné projevy v hodnocení (vede model k přesnějším formulacím).

Seberefektivní část (KROK 5) navíc obsahuje **přemýšlení o sociální citlivosti tématu** — to je didakticky cenné, protože model je nucen reflektovat etické důsledky vlastního návrhu.

Návrh varianty pro testování. Změňte téma projektu (například "Voda v krajině naší obce", "Mobilita a doprava v naší obci", "Klima a krajina v posledních 50 letech v našem regionu"), upravte ročník (například 8. ročník nebo 1. ročník gymnázia s rozšířenějším pojetím) nebo časový rozsah (kratší dvoutýdenní mini-projekt vs. dlouhodobý semestrální projekt). Pozorujte, jak se mění obtížnost úkolů a charakter doporučených aktivit.

Prompt 4: Analýza mediálního výstupu o klimatu

<role>

Jsi mediální analytik specializující se na vědeckou komunikaci a kritickou analýzu mediálních textů o environmentálních tématech. Současně máš didaktickou perspektivu – přemýšlíš o tom, jak s mediálními texty pracovat ve výuce geografie na druhém stupni ZŠ a na gymnáziu.

</role>

<úkol>

Postupuj krok za krokem:

KROK 1: Pečlivě si přečti přiložený text o klimatu (článek z online média).

KROK 2: Identifikuj v textu:

- centrální tezi nebo tvrzení
- klíčové údaje a statistiky (s uvedením, zda je v textu jejich zdroj)
- citované experty nebo organizace
- emocionální nebo hodnotové formulace
- konkrétní fakta vs. interpretace
- nejasné formulace nebo argumentační skoky

KROK 3: Posud věrohodnost textu podle metody

SIFT (Stop, Investigate, Find better coverage, Trace claims):

- Kdo je autor a vydavatel?
- Jaké jiné zdroje téma pokrývají a jak se jejich podání liší?
- Jsou centrální údaje v textu dohledatelné v primárních zdrojích?

KROK 4: Navrhni pět didaktických otázek, kterými by učitel mohl s žáky tento text analyzovat ve výuce. Otázky musí směřovat ke kritické práci s mediálním textem, ne pouze k jeho převyprávění.

KROK 5: Navrhni jednu praktickou aktivitu (15–20 minut), ve které by žáci s tímto textem v hodině pracovali.

</úkol>

<text_k_analyze>

[ZDE VLOŽTE TEXT MEDIÁLNÍHO VÝSTUPU, KTERÝ CHCETE ANALYZOVAT – například článek z iDnes, Aktuality.cz, Seznam Zprávy o teplotních rekordech, povodních, suchu, klimatické politice. Doporučená délka: 500–1500 slov.]

</text_k_analyze>

<omezení>

- NEPRESUMUJ politickou pozici textu – analyzuj text takový, jaký je, a doložené tvrzení od interpretace vždy odděluj.
- NESNIŽUJ kvalitu textu obecně – mediální texty mají svou roli a za některými slabinami stojí redakční omezení (rozsah, čas, cílová skupina), ne nekompetence autora.
- NEZAMĚŇUJ pojem "kritická analýza" za "negativní hodnocení". Kritická analýza identifikuje silné i slabé stránky textu.

</omezení>

Analýza promptu. Kombinace čtyř technik:

- **Role-based prompting** s dvojitou rolí (mediální analytik + didaktik) — vede k vyvážené analýze.
- **Chain-of-thought** v explicitních krocích analýzy.
- **Step-by-step decomposition** s pěti kroky včetně metodiky SIFT.
- **Negative prompting** v sekci *omezení*, které zabraňuje typickým chybám analýzy mediálních textů.

Tento prompt současně **napojuje na podkapitolu 6** (kde rozpracujeme metodu SIFT systematicky) a **na kapitolu o geomédiích a kritické gramotnosti** v této studijní opoře. Pro studenta je to ukázka toho, jak pokročilé promptování slouží **kritické pedagogické práci**, ne pouze formulační výkonnosti.

Návrh varianty pro testování. Vyberte si konkrétní článek z české mediální produkce o klimatickém tématu (sucho v ČR, povodně, energetická transformace, klimatická politika EU), vložte ho do sekce *text_k_analyze* a otestujte. Zkuste prompt aplikovat na **dva texty s odlišnou redakční kvalitou** (například článek z odborného webu vs. článek z bulvárního média) a porovnejte, jak se analytické výstupy liší. Můžete prompt také obrátit a požádat AI, aby **sama vygenerovala mediální text** o klimatu s úmyslnými problémy, který pak budete v hodině s žáky analyzovat.

Prompt 5: Simulace expertní role pro hloubkový rozhovor

```
<role>
Vystupuj jako Karel Novák, hypotetický odborník na vodohospodářství v české krajině s 30letou praxí. Pracoval jsi v Povodí Labe, později ve Výzkumném ústavu vodohospodářském T. G. Masaryka. Specializuješ se na otázky retence vody v krajině a obnovy mokřadů. Při komunikaci udržuj odbornou úroveň, ale zároveň věcnost a srozumitelnost – odpovídáš laickému tazateli, ne kolegovi z oboru.
</role>

<úkol>
Připravuji s žáky 9. ročníku projekt o vodě v krajině. Než s nimi začneme pracovat na konkrétních úkolech, chci si sám/sama prohloubit odborný kontext. Veď se mnou rozhovor – budeš odpovídat na mé otázky a já se budu postupně ptát na různé aspekty problematiky.

Pravidla našeho rozhovoru:
1. Odpovídáš stručně (2–4 věty na otázku, pokud explicitně nepožádám o delší výklad).
2. Pokud si nejsi jistý odpovědí (například pokud jde o konkrétní statistický údaj nebo aktuální informaci), explicitně to řekneš ("v této otázce si nejsem jistý" nebo "k tomuto údaji bych potřeboval ověřit aktuální zdroj").
3. Pokud je otázka mimo tvou specializaci (například ekonomické nebo politické otázky), odkážeš mě na vhodnější zdroj.
4. Pokud považuješ otázku za špatně formulovanou nebo nejednoznačnou, požádáš mě o upřesnění.

Začni stručným představením toho, kdo jsi a v čem ti můžu nejvíc užitečně pomoci. Pak budu pokládat své otázky.
</úkol>
```

Analýza promptu. Tento prompt používá **role-based prompting** v jeho nejsilnější variantě – vytváří **personu** s konkrétní odbornou specializací, kariérní historií a osobnostními rysy. Persona je hypotetická (model nepředstírá reálnou osobu), ale dostatečně konkrétní, aby vedla model k odpovědím v určitém stylu.

Klíčem k efektivnosti tohoto promptu jsou **čtyři pravidla rozhovoru**, která nastavují **omezení** chování modelu:

- pravidlo stručnosti zabraňuje typické chybě LLM (rozsáhlé monology);
- pravidlo přiznání nejistoty (constraint specification) **strukturálně snižuje halucinace** – model je nucen explicitně přiznat, kde si není jistý, místo aby si vymýšlel sebejistou odpověď;
- pravidlo o specializaci omezuje rozsah toho, na co model odpovídá;

- pravidlo o nejednoznačnosti otázek **otáčí dynamiku konverzace** — model se aktivně doptává, místo aby pasivně odpovídal.

Tento prompt je **nástroj pro vlastní přípravu učitele**, ne primárně pro žáky. Učitel získá strukturovaný rozhovor s "odborníkem", ze kterého si může odnést otázky, perspektivy a pochopení tématu, které mu pomůže lépe vést projekt s žáky.

Návrh varianty pro testování. Vytvořte vlastní personu pro téma, na kterém aktuálně pracujete:

- Eva Hlavatá, klimatoložka specializující se na klimatickou změnu ve střední Evropě
- Jan Procházka, urbanista zabývající se brownfieldy a regenerací postindustriálních krajín
- Marie Svobodová, kartografka specializující se na staré mapy českého území

Vedte rozhovor a sledujte, jak persona ovlivňuje styl a obsah odpovědí. Stejnou personu můžete vyzkoušet ve dvou různých LLM asistentech a porovnat, který nástroj personu udržuje konzistentněji v průběhu rozhovoru.

AI jako učitel promptování

Tato podkapitola představila vybrané pokročilé techniky promptování. Zdaleka nejde o vyčerpávající přehled — v praxi promptování existuje desítky dalších technik, kombinací a přístupů, a celý obor se rychle vyvíjí. Pokud chcete v promptování pokračovat za rámec této podkapitoly, máte k dispozici **rekursivní pomoc: AI samo dokáže být dobrým učitelem promptování**.

Konkrétní způsoby, jak LLM asistenta použít k vlastnímu rozvoji v promptování:

„Vystupuj jako zkušený lektor promptování pro učitele. Vysvětli mi techniku ‚meta-cognitive prompting‘ — co je její princip, kdy ji použít, jaké jsou typické chyby. Uveď tři krátké příklady promptů, ve kterých se tato technika uplatňuje. Příklady ukazuj na úkolech z geografického vzdělávání.“

„Pokouším se napsat prompt pro tvorbu pracovního listu o povodňové prevenci pro 8. ročník. Můj současný prompt zní: [vložit svůj prompt]. Posuď, jaké techniky promptování v něm jsou již použité a které by ho ještě mohly vylepšit. Pro každou doporučenou techniku uveď, jak konkrétně by ji bylo možné do mého promptu zapracovat.“

„Připravil/a jsem následující prompt: [vložit svůj prompt]. Identifikuj v něm slabá místa — pasáže, které jsou nejasné, redundantní, mohou vést k nežádoucímu výstupu, nebo postrádají nějakou důležitou komponentu. Doporuč konkrétní úpravy.“

Tento přístup má dva limity, které je dobré mít na paměti. **Za první**, AI o promptování odpovídá s **proměnlivou kvalitou**. Jde o oblast, kde se doporučení rychle mění, různé modely fungují odlišně a v trénovacích datech existují i protichůdné rady. Pro důležitá rozhodnutí je vhodné doporučení z AI **ověřit v jiném zdroji** — v dokumentaci nástroje, na chatveskole.cz, v odborné literatuře. **Za druhé**, AI nedokáže nahradit cvičení. Nejvhodnějším zdrojem rozvoje v

promptování zůstává **vlastní opakovaná praxe** — pravidelné používání AI pro reálné úkoly, sledování, co funguje a co ne, postupné budování vlastního repertoáru technik.

AI jako učitel promptování má proto smysl jako **doplňěk vlastní praxe**, ne jako její náhrada. Pro budoucího učitele geografie je vhodné si tuto rekursivní možnost uvědomit a využít ji ve chvílích, kdy narazíte na konkrétní problém ve vlastním promptování — k systematickému rozvoji se ale neomezit pouze na ni.

Most k samostatnému procvičování

Tato podkapitola dosáhla teoreticky-praktického vrcholu — pokročilé techniky promptování jsou nejhlubší vrstvou kompetence, kterou v celé kapitole představujeme. Přesto, jak jsme zdůraznili na začátku, **pokročilé techniky nejsou cílem samy o sobě**. Jejich smyslem je umožnit učiteli efektivnější didaktickou práci v geografickém vzdělávání — práci, která je v souladu s cíli geografického vzdělávání rozpracovanými v této celé sérii textů.

Skutečné osvojení pokročilého promptování přichází **pouze prostřednictvím vlastní praxe**. Žádný studijní text nemůže nahradit vlastní cvičení — opakované formulování promptů, sledování výstupů, srovnávání nástrojů, reflexi vlastních úspěchů i neúspěchů. Pro budoucího učitele geografie je proto klíčové, **aby pokročilé techniky pravidelně používal v reálné přípravě výuky**, a ne aby je studoval pouze teoreticky.

Pro samostatné procvičování doporučujeme:

1. **Otestovat alespoň dva ze pěti komplexních promptů** v této podkapitole ve dvou různých LLM asistentech a porovnat výstupy.
2. **Adaptovat jeden prompt** pro téma vlastní budoucí hodiny — vlastní region, ročník, konkrétní obsahový blok.
3. **Vyzkoušet RAG práci s RVP ZV** podle pětikrokového postupu z předchozí podkapitoly.
4. **Prostudovat alespoň tři materiály** z chatveskole.cz (například „10 způsobů využití GenAI ve výuce“, metodiku formativního hodnocení, doporučení pro ZŠ a SŠ) a převzít z nich konkrétní prompty pro adaptaci na geografické úkoly.
5. **Postupně budovat vlastní repertoár promptů** — pro typické situace v učitelské práci si sestavovat osobní knihovnu osvědčených šablon, které lze opakovaně používat a postupně zlepšovat.

Pokud studujete tento text v rámci akademického kurzu, dává smysl výše uvedené propojit s praktickou částí výuky a s konzultacemi se spolužáky a vyučujícími. Pokud studujete samostatně, nahradte tuto kolektivní rovinu vlastní reflexí, sdílením s kolegy v učitelském sboru, případně účastí na profesionálních online komunitách (Facebook skupina iniciativy AI dětem, LinkedIn skupiny pro učitele).

Podkapitola 6, která následuje, uzavírá tematický oblouk celé studijní opory — věnuje se etickým a epistemickým aspektům práce s AI. Pokročilé techniky promptování, které jste se

naučili v této podkapitole, dávají plný smysl jen v rámci kritické a eticky reflektované praxe. Bez tohoto rámce by byly jen souborem efektivnostních triků; v rámci kritické perspektivy se z nich stávají didaktické nástroje s jasným pedagogickým směrem.

Rychlé čtení podkapitoly 5

Hlavní teze: Pokročilé techniky promptování umožňují kvalitativně lepší výsledky u náročných úkolů. Jsou doplňkem základů z podkapitoly 2, ne jejich náhradou — pro běžnou rutinu zůstávají základy dostatečné.

Devět technik pokročilého promptování + dvě nadtechniky pro strukturování:

1. **Role-based prompting:** Modelu zadáte konkrétní expertní roli
2. **Chain-of-thought:** Explicitně žádáte uvažování krok za krokem
3. **Few-shot prompting:** Poskytnete několik vzorových příkladů formátu
4. **Reframing:** Přeformulujete úkol z jiné perspektivy
5. **Step-by-step decomposition:** Rozdělíte úkol na menší podúkoly
6. **Meta-cognitive prompting:** Necháte model reflektovat vlastní výstup
7. **Prompt chaining:** Řetězíte více promptů s návazností výstupů
8. **Negative prompting:** Specifikujete, co model NEMÁ dělat
9. **Error injection:** Záměrně vložená chyba pro testování / výuku
10. **XML tagy** pro složité prompty s vnitřní strukturou
11. **Kombinace technik** — silné prompty obvykle kombinují 3–5 technik najednou.

Důležitá kvalifikace — reasoning modely: novější modely s vestavěným uvažováním (o1, o3, Claude s extended thinking, Gemini reasoning, DeepSeek R1) některé techniky činí nadbytečnými, zejména klasický Chain-of-Thought.

Pět komplexních ukázkových promptů demonstruje kombinace technik na typických úkolech učitele geografie:

1. Příprava hodiny o povodňové prevenci (role + step-by-step + negative + meta-cognitive + XML).
2. Tvorba sady testových otázek (few-shot + role + negative).
3. Návrh projektové práce o místních prostorových nerovnostech (kombinace 6 technik — nejkomplexnější).
4. Analýza mediálního výstupu o klimatu (role + chain-of-thought + step-by-step + negative).
5. Simulace expertní role pro hloubkový rozhovor (role-based v nejsilnější variantě + constraint specification).

Každý prompt je **přímo kopírovatelný** a navržen pro testování ve vlastním LLM asistentovi.

AI jako učitel promptování: AI samo lze použít k vlastnímu rozvoji v promptování (vysvětlování technik, analýza vlastních promptů, návrhy zlepšení). Použít s **dvojí kontrolou** (ověřit doporučení v jiném zdroji) a jako **doplňěk vlastní praxe**, ne její náhradu.

Nejhodnotnější dovednost pokročilého promptování není znalost jednotlivých technik, ale schopnost **kombinovat několik technik** do silného promptu pro konkrétní situaci. Tato dovednost se učí cvičením — pravidelným testováním, sledováním výsledků, postupným budováním vlastního repertoáru.

6. Etika a epistemika

Etika, epistemika a geografické myšlení

Předchozí podkapitoly představily AI jako technologii, jako nástroj, jako didaktického partnera, jako objekt teoretické reflexe. Tato závěrečná podkapitola otevírá vrstvu, která rámuje vše předchozí — **etické a epistemické otázky**, které vyplývají z práce s LLM asistenty ve vzdělávání. Bez této vrstvy by byl text návodem k efektivnímu používání nástroje. S ní se stává textem o **odpovědné pedagogické praxi**.

Pojem **etika** je v kontextu vzdělávání známý — týká se otázek správného a nesprávného jednání, hodnotových voleb, odpovědnosti pedagoga vůči žákům, kolegům, společnosti a profesi. Pro práci s AI je etika klíčová především v oblastech **ochrany osobních údajů žáků, akademické integrity, technologické rovnosti a kulturní citlivosti**.

Pojem **epistemika** (nebo epistemologie) je méně známý a stojí za vymezení. Epistemika je nauka o **poznání** — o tom, **jak víme to, co víme**, jaké jsou zdroje a meze našeho poznání, podle čeho rozeznáváme pravdivé tvrzení od chybného, ověřené poznání od domněnky. Pro učitele geografie je epistemika přímo relevantní, protože **geografie je obor, který pracuje s rozmanitými zdroji poznání** — empirickými daty (terénní pozorování, satelitní snímky, statistiky), teoretickými modely (klimatické modely, modely populační dynamiky), narativy (mediální texty, lokální paměť, regionální literatura), mapovými reprezentacemi (geomédií). Každý z těchto zdrojů má **odlišnou epistemickou váhu** — jiný způsob, jakým k poznání přispívá, a jiné meze platnosti.

Geografické myšlení je v podstatě **integrační epistemická praxe**: učí žáka rozeznat, který typ zdroje k jakému typu poznání přispívá, kde jsou jeho meze, jak různé zdroje kombinovat. Pro tuto integrační práci je epistemická reflexe — schopnost ptát se „*odkud to vím a jak spolehlivé to je*“ — naprosto klíčová.

S nástupem LLM asistentů přibývá nový typ zdroje poznání. Výstupy AI **nejsou ani empirickým pozorováním, ani teoretickým modelem, ani mediálním narativem v klasickém smyslu**. Jsou to **pravděpodobnostní rekonstrukce** vytvořené z rozsáhlého korpusu jiných textů. Tato kvalitativně nová epistemická povaha vyžaduje vlastní reflexi — co LLM výstup vlastně **je z hlediska poznání**? Jak ho integrovat se zbytkem epistemického repertoáru geografie? Které z geografického myšlení LLM dokáže rozšířit a které principiálně ne?

Tato podkapitola na tyto otázky odpovídá. Začneme **konkrétním problémem halucinací**, postoupíme přes **metodu kritického ověřování** k **etickým okruhům**, dojdeme k **principiálním limitům** AI pro geografické myšlení a uzavřeme syntézou pozice učitele geografie v éře AI.

Halucinace AI

V podkapitole 1 jsme krátce zavedli pojem halucinace jako pravděpodobnostní vyplnění mezery v trénovacích datech. Nyní rozpracujeme tento jev hlouběji a v didakticky relevantní šíři.

Co je halucinace

Halucinace je termín, kterým se v oboru AI označuje situace, kdy LLM asistent vygeneruje **fakticky nepravdivý výstup, formulovaný se stejnou jazykovou jistotou jako výstup pravdivý**. Halucinace není chyba v technickém smyslu — model „nedělá něco špatně“. Halucinace je **přímý důsledek toho, jak LLM funguje**. Model je trénován optimalizovat pravděpodobnost dobře znějícího textu, ne pravdivost obsahu. Když se dostane do oblasti, kde má v datech mezery, **vyplní mezeru pravděpodobnostně** — vytvoří větu, která **by zněla věrohodně**, kdyby byla pravdivá.

Z této povahy halucinace plynou tři důležité didaktické implikace:

- **Halucinaci nelze vykořenit zlepšením modelu.** S každou novou generací LLM se halucinace snižuje, ale nikdy nezmizí úplně. Jde o vlastnost paradigmatu, ne o chybu konkrétní implementace.
- **Halucinace je nejhůře rozeznatelná tam, kde uživatel téma nezná.** Pokud učitel téma dobře ovládá, halucinaci typicky rozezná; pokud se ptá na něco nového, je v ní bezbranný.
- **Některé typy obsahu jsou k halucinacím náchylnější než jiné.** Zde je geografická specifika obzvlášť důležitá.

Kde LLM nejčastěji halucinuje v geografických tématech

Z principu fungování modelu plyne, že riziko halucinace stoupá v oblastech, kde **má řídká data** nebo **rozporuplná data**. V geografii to znamená:

Konkrétní číselné údaje (rozlohy, nadmořské výšky, počty obyvatel, přesné statistické hodnoty). Model si je nepamatuje jako pevná data, ale rekonstruuje je z trénovacího textu. Často se stane, že se trefí do správného řádu, ale konkrétní číslo si vymyslí nebo posune.

Lokálně specifické informace o malých regionech. Pro Prahu nebo Berlín má model obstojná data; pro Bitov nad Dyjí nebo malou obec v Krkonoších může mít data minimální. Halucinace v lokálních otázkách jsou obzvlášť časté a obzvlášť nebezpečné, protože **učitel je nemusí rozpoznat** — zná rámcový kontext, ne každý detail.

Historické datace přírodních a společenských jevů. Kdy byla postavena konkrétní přehrada, kdy proběhla konkrétní povodeň, kdy se obec stala městem — to vše jsou údaje, kde model halucinuje s vysokou pravděpodobností.

Hraniční pojmosloví (regionální názvy, místní pojmenování krajinných prvků, dialektismy). Model může uvést pojem, který v dané oblasti nikdo nepoužívá, nebo si vymyslet český překlad pojmu, který v češtině nemá ustálený ekvivalent.

Chyby v logice uzavřených testových položek. Tato kategorie halucinací je pro učitele obzvlášť zálučná, protože nejde o faktografickou chybu, ale o **chybu v pedagogické konstrukci**. Pokud učitel zadá AI úkol typu „vytvoř pět uzavřených testových otázek s výběrem ze čtyř odpovědí, kde žák vybírá jednu správnou“ nebo „vytvoř otázky, kde žák vybírá jednu nesprávnou odpověď“, model často vytvoří položky, kde:

- **více než jedna nabízená odpověď je za určitých okolností správná** (například otázka „Která řeka pramení v Krkonoších?“ s odpověďmi Labe, Úpa, Mumlava, Vltava — z geografického hlediska jsou tři z těchto čtyř odpovědí správné)
- **správná odpověď je formulována nejednoznačně** a žák ji legitimně může chápat jako nesprávnou (například nepřesné vymezení regionu, vágní statistický údaj)
- **distraktory (nesprávné odpovědi) jsou nedostatečně odlišené od správné odpovědi** — model vygeneruje čtyři odpovědi, které jsou si tak podobné, že žák těžko rozeznává mezi nimi
- **klíč přiřazený k odpovědím obsahuje chybu** — model uvede jako správnou odpověď tu, která je ve skutečnosti nesprávná

Tento typ halucinace **nelze odhalit pouhým fact-checkingem** — vyžaduje **pedagogickou kontrolu testové konstrukce** ze strany učitele před použitím testu ve výuce. Praktické doporučení: **každou uzavřenou testovou položku vygenerovanou AI projít z perspektivy žáka** a zeptat se, zda by žák mohl legitimně vybrat jinou odpověď, než kterou model označuje za správnou. Pokud ano, položku přepracovat. Toto pravidlo platí obzvlášť pro situace, kde test slouží k sumativnímu hodnocení (závěrečná známka, písemná práce) — tam jsou důsledky chyby v testové položce pro žáka přímo měřitelné.

Citace literatury, autorů, organizací. Toto je častější v akademickém kontextu, ale i učitel geografie může narazit. Model dokáže vygenerovat zdánlivě plnohodnotnou citaci (autor, rok, název článku, časopis, strany), která **neexistuje**. Halucinace citací je obzvlášť problematická pro studentské práce a odborné texty učitele.

Co halucinace znamenají pro učitele

Závěr je didakticky jednoduchý a pedagogicky náročný současně: **každý faktografický údaj z LLM asistenta je nutné ověřit**, pokud má být použit v kontextu, kde na pravdivosti záleží — pracovní list, test, výuka, citace. Toto ověření není formalitou; je to **základní povinnost pedagoga**, který výstup AI předává dál žákům.

Praktická pravidla pro práci s halucinacemi:

- **Pro faktografické otázky používat AI v režimu s vyhledáváním nebo RAG**, ne samostatný režim.

- **U každého konkrétního čísla, datace, jména, citace si ověřit primární zdroj.** Kategoricky to platí pro vše, co půjde do hodiny nebo do textu.
- **Pokud nelze ověřit, raději údaj vypustit** než ho předat dál nezkontrolovaný.
- **Učit žáky, že AI halucinuje** — ne jako kuriozitu, ale jako součást základní digitální gramotnosti.

K poslednímu bodu se v této podkapitole vrátíme — schopnost rozeznat halucinaci je jednou z klíčových kompetencí, kterou AI gramotný učitel rozvíjí u žáků.

Metoda SIFT a most ke geomédiím

Halucinace je důvod, proč potřebujeme **systematický nástroj kritického ověřování** výstupů AI. V mediální výchově a v digitální gramotnosti se v posledním desetiletí ustanovil rámec, který tuto potřebu pokrývá obecně — **metoda SIFT** Mike Caulfielda (2017). Pro učitele geografie má SIFT zvláštní hodnotu, protože přirozeně navazuje na **kritickou práci s geomédií**, kterou jste si osvojili v předchozí kapitole této studijní opory.

Čtyři kroky SIFT

Caulfieldova metoda se skládá ze čtyř kroků, jejichž anglické začátky tvoří akronym SIFT (česky „prosévát“):

S — Stop. Před tím, než přijmete tvrzení nebo informaci, zastavte se. Nepoužívejte ji impulzivně. Tato první fáze je metakognitivní — připomenutí sama sobě, že je třeba ověřovat. V kontextu AI to znamená: než zkopírujete výstup LLM asistenta do pracovního listu, **zastavte se**.

I — Investigate the source. Prozkoumejte zdroj. Pro klasický mediální obsah to znamená zjistit, kdo ho publikoval, jaká je jeho autorita, jaké zájmy zastupuje. **Pro AI výstup** to znamená zeptat se: *odkud model toto tvrdí?* Často odpověď zní „z trénovacích dat“ — což je epistemicky netransparentní zdroj. Pokud LLM asistent pracuje v režimu s vyhledáváním nebo v RAG, kontrolujte **konkrétní citované zdroje**, ne obecné formulace.

F — Find better coverage. Najděte lepší pokrytí tématu. Hledejte, jak téma popisují **jiné, ověřitelné zdroje** — odborná literatura, oficiální statistiky, primární data. Pro geografická témata to znamená: pro otázky o ČR konzultovat ČSÚ, ČHMÚ, VÚV TGM, pro otázky o EU statistiky Eurostatu, pro klimatická data IPCC zprávy. Ověření v primárním zdroji **přepisuje** výstup AI, ne ho potvrzuje — pokud najdete rozpor, věří se primárnímu zdroji.

T — Trace claims. Vystopujte tvrzení k jeho původu. Pokud LLM asistent uvádí konkrétní statistiku, přírodní fakt, historickou událost, najděte **původní zdroj toho tvrzení**. Často to vede k překvapivému zjištění: tvrzení existuje, ale v jiné podobě, než AI uvádí; nebo neexistuje vůbec a model ho zkonstruoval.

Když LLM asistent pracuje v režimu s vyhledáváním na webu (ChatGPT s web search, Claude s web search, Perplexity, Gemini), aplikace SIFT se v jednom rozhodujícím ohledu **mění**. Místo dohledávání zdrojů je úkolem **ověřit citované zdroje**. Model říká, odkud tvrzení přebírá; vy klikáte na odkazy a kontrolujete, zda zdroj **skutečně říká to**, co AI tvrdí. Tato kontrola není formalitou — je to běžné, že model **nepřesně interpretuje** nalezený zdroj, vykládá ho mimo kontext nebo si do něj přidává tvrzení, která tam nejsou.

Pro geografického učitele to v praxi znamená: u každé citace prokliknout odkaz, **přečíst původní text** (alespoň stručně) a ověřit, zda formulace AI sedí. Pokud ne, výstup opravit — buď úpravou formulace, nebo vyhledáním alternativního zdroje.

Most ke geomédiím

Pozorný čtenář si uvědomil, že kroky SIFT se nápadně podobají **kritické práci s geomédií**, kterou jste si osvojili v předcházející kapitole o geomédiích. Tato podobnost není náhodná. Caulfieldova metoda byla původně formulována pro **kritickou mediální gramotnost** — schopnost kriticky pracovat s informacemi z mediálního prostředí. Geomédiá jsou specifický typ mediálního obsahu, který nese **prostorovou informaci** o světě — mapy, geografické vizualizace, reportáže o územích, satelitní snímky v médiích. Kritická práce s geomédií je **specifickou aplikací kritické mediální gramotnosti** na prostorové sdělení.

LLM asistent generuje **textovou vrstvu o prostoru**. Jeho výstupy o geografických tématech (popis krajiny, regionální charakteristika, výklad geografického jevu) jsou **další generací geomédií** — médiem, které spoluvytváří představu o světě a o prostoru. Stejná pravidla, která jste zavedli pro kritickou práci s geomédií v předchozí kapitole, **se přímo vztahují i na výstupy AI**:

- Kdo (co) toto sdělení vytvořilo? (*LLM asistent — model trénovaný na korpusu textů*)
- Z jaké pozice mluví? (*z trénovacích dat, ovlivněn jazykovým a kulturním zastoupením v korpusu*)
- Co zobrazuje a co naopak neukazuje? (*co model „ví“ vs. kde má mezery*)
- Jaký mocenský nebo zájmový rámec za sdělením stojí? (*společnost, která model trénovala — její komerční zájmy, kulturní pozadí, ideologická východiska*)
- Jak se sdělení vztahuje k jiným zdrojům? (*srovnání s primárními daty, odbornou literaturou, mediální produkcí*)

Pro učitele geografie z toho plyne integrující závěr: **AI gramotnost není novou vrstvou kompetence vedle kritické geomediální gramotnosti — je její současnou aplikací**. Učitel, který ovládá kritickou práci s geomédií, je **principiálně připraven** kriticky pracovat i s výstupy LLM asistentů. Stačí stávající dovednosti aplikovat na nový typ mediálního obsahu, ne se učit zcela nové pojmy.

Tento poznatek je didakticky cenný hned dvakrát. **Za první**, dává učiteli ujištění, že se neocitl v zcela neznámém terénu — disponuje již velkou částí potřebných kompetencí. **Za druhé**, nabízí

cestu pro výuku se žáky: kritická práce s AI se nemusí vyučovat jako samostatné téma, ale **jako rozšíření mediální a geomediální gramotnosti**, kterou žáci již rozvíjejí.

Etické okruhy

Z dosavadního výkladu vyplývá, že práce s AI vyžaduje kritickou pozornost k pravdivostnímu obsahu výstupů. To je epistemická rovina. Vedle ní existuje **etická rovina** — okruh otázek, které se týkají **správnosti jednání** učitele, žáků a širšího vzdělávacího systému ve vztahu k AI. V této podkapitole rozpracujeme šest etických okruhů, které učitel geografie potřebuje promyslet a se kterými v praxi pracovat.

Pro hlubší orientaci v globální debatě o etice AI ve vzdělávání je relevantním zdrojem zpráva UNESCO (2025) *AI and the Future of Education: Disruptions, Dilemmas and Directions*. Šest etických okruhů, které rozpracujeme níže, je v souladu se širší debatou, kterou tato zpráva mapuje, a budoucímu učiteli geografie doporučujeme s ní pracovat jako s referenčním rámcem pro vlastní pedagogickou pozici.

Ochrana osobních údajů

Při běžné práci s LLM asistenty učitelé často **nevědomky předávají citlivé údaje** o žácích, kolezích, žákovských rodinách. Konkrétní rizika:

- nahrání žákovské práce do AI s plným jménem žáka v textu
- žádost o radu při hodnocení konkrétního žáka s uvedením jména, diagnózy, rodinné situace
- vložení e-mailu od rodiče s plným jménem do AI pro pomoc s formulací odpovědi
- nahrání zápisu z porady s plnými jmény účastníků a obsahem diskuze

Většina běžných LLM asistentů ukládá vstupy uživatele **buď pro ladění modelu, nebo pro analytické účely**. I když dnešní hlavní nástroje deklarují, že vstupy nejsou používány k trénování (zvláště v placených tarifech a podnikových verzích), **technická infrastruktura tato data zpracovává**, ukládá je v logu a může je v omezené podobě uchovávat.

Pro učitele to znamená dvě praktická pravidla:

- **Anonymizovat všechny vstupy** předtím, než je vložíte do AI. Místo „Pavel Novák, 8. ročník, dyslexie“ formulujte „žák 8. ročníku s diagnostikovanou dyslexií“.
- **Necitovat doslovně texty rodičů ani kolegů**, pokud obsahují identifikační údaje. Pokud potřebujete pomoc s formulací odpovědi, parafrázuje situaci anonymně.

Pro práci s GDPR ve školách doporučujeme učitelům prostudovat metodiky NPI ČR a interní směrnice školy. Pokud škola ještě nemá vlastní pravidla pro práci s AI, je to **téma, které učitel může otevřít** — návrh školního pravidla může být součástí jeho profesního přínosu pedagogickému sboru.

Akademická integrita

Akademická integrita (poctivost při studiu a tvůrčí práci — neopisování, řádné citování zdrojů, vlastní autorství práce, transparentnost o pomoci a zdrojích, kterými student pracoval) byla v éře AI postavena před zásadní výzvou. Dosud se akademická integrita opírala o **rozeznatelnost cizí práce** — opisy z internetu šly dohledat plagiátorskými detektory, citace z knih byly zjevné. **AI generovaný text** je z principu **nedohledatelný klasickými plagiátorskými detektory** — neexistuje původní zdroj, který by se dal porovnat.

Tato zdánlivá nezachytitelnost má ale **důležité kvalifikace**. AI generovaný text je **rozpoznatelný stylisticky a jazykově** — má charakteristické rétorické vzorce, typické formulační obraty, určitou strukturní pravidelnost, kterou zkušený čtenář často odhalí. Detekční nástroje pro AI text existují a postupně se zlepšují, ale jejich spolehlivost zůstává proměnlivá. Pro učitele to znamená, že **lidská pozornost vůči stylu** je v hodnocení žákovských textů důležitější než kdy dříve.

Druhou důležitou kvalifikací je **rozdíl mezi pomocí s formou a pomocí s autorstvím**. Pokud student použije AI k **jazykové úpravě nebo k překladu textu, jehož myšlenky, struktura, námětový rámec, závěry, výsledky a doporučení jsou jeho vlastní**, jde o legitimní použití nástroje — analogicky jako korektor, redaktor nebo překladatel. **Plagiátorství vzniká tehdy, když si student přivlastní myšlenky, strukturu a závěry, které neformuloval sám**. Toto rozlišení je klíčové pro budoucího učitele, který formuluje pravidla pro žáky: **autorství myšlenky** je předmět ochrany, **forma jejího vyjádření** může být kolaborativní s nástrojem.

Kvalifikace předchozího odstavce vede k didakticky důležitému závěru: **klasický typ zadání se v éře AI epistemicky vyčerpává**. Zadání jako „*napiš esej o suchu v české krajině*“ nebo „*zpracuj referát o klimatické změně*“ nedává učiteli **podklad, ze kterého by mohl posoudit, kdo a jak text vytvořil**. Žák může text napsat sám; může ho napsat AI; může vzniknout v různě kombinované spolupráci. Z výsledné práce **to nelze poznat** — a pokud učitel hodnotí jen výsledný text, nehodnotí žákovu učení, ale **schopnost dodat výstup**.

Proměna zadání směrem k formám, které **prokazují autorství, kvalitu učení a porozumění**, je proto jednou z klíčových didaktických úkolů budoucího učitele geografie. Konkrétní směry této proměny:

- **Zadání s povinnou autentickou složkou** — terénní pozorování, fotografie z konkrétního místa, rozhovor s pamětníkem, vlastní mapa, naskicovaný profil krajiny. AI nemůže za žáka navštívit místo ani provést rozhovor.
- **Zadání s povinnou ústní složkou** — žák musí o své práci hovořit, odpovídat na otázky, vysvětlovat své postupy. Pokud práci nepsal sám, ústní složka rychle odhalí mezery.
- **Zadání s viditelnými stopami procesu** — žák odevzdává nejen finální výstup, ale i postupné verze, poznámky, otázky kladené v průběhu práce. Učitel hodnotí proces, ne jen produkt.
- **Zadání s explicitním zapojením AI** — žák AI použije, ale dokumentuje, **co přesně AI poskytla**, jak s tím dál pracoval, kde s AI nesouhlasil. Hodnotí se reflexivní práce, ne autorství textu.

- **Zadání ukotvená v lokálním kontextu** — práce s konkrétním místem, konkrétní obcí, konkrétní řekou, kde generická AI odpověď nestačí, protože žádá lokální specifika, která model nezná.
- **Zadání kombinující více médií** — kombinace textu, mapy, vlastní fotografie, ústní prezentace. Komplexní výstup je obtížnější simulovat AI než jednoduchý text.

Tato proměna zadání není reakcí pouze na AI — je to **dlouhodobý didaktický posun**, který se s nástupem AI urychluje. Geografické vzdělávání má v této proměně přirozenou výhodu: tradice **terénní práce, místní orientace a autentické zkušenosti s prostorem** je přesně tím typem pedagogické praxe, ke kterému se vzdělávání obecně směřuje. Učitel geografie, který tuto tradici aktivně rozvíjí, **už dnes formuluje zadání**, která jsou v éře AI nadále smysluplná. Pro budoucího učitele je tato kontinuita silným zdrojem důvěry — geografická pedagogika není v krizi způsobené AI, ale v transformaci, ve které má **přirozeně dobrou výchozí pozici**.

Pro budoucího učitele geografie z toho plynou tři praktické otázky:

1. **Jak formulovat pravidla pro žáky.** Otázka „*Mohou žáci používat AI na domácí úkol?*“ nemá univerzální odpověď. Záleží na cíli úkolu. Pokud je cílem ověřit, **zda žák umí napsat text** (jazyková kompetence), AI je nepřipustná. Pokud je cílem ověřit, **zda žák rozumí tématu**, AI je legitimní pomocník — pokud žák transparentně uvede, co a jak ji použil. Učitel by měl explicitně formulovat **pravidla pro každý typ úkolu** a tato pravidla s žáky probrat.
2. **Jak rozlišit úkoly, kde AI smí a kde ne.** Užitečné kritérium: pokud lze úkol smysluplně vyřešit jediným promptem do AI, je úkol nevhodně formulovaný a žák by měl mít možnost AI použít s transparentním uvedením. Naopak úkoly, které vyžadují **autentickou žakovu zkušenost** (terénní pozorování, rozhovor s pamětníkem, vlastní fotografie z exkurze, reflexe vlastního prožívání místa), zůstávají **AI-imunní** — žák je AI nemůže smysluplně obejít, i kdyby chtěl.
3. **Jak nastavit transparentnost.** Pokud žáci AI smí použít, **měli by uvést, jak ji použili** — jakou otázku položili, co AI poskytla, jak s odpovědí pracovali. Tato dokumentace má dvojí hodnotu: pro učitele jako podklad pro hodnocení, pro žáka jako **trénink reflexivní práce s nástrojem**. Iniciativa AI dětem na chatveskole.cz tento princip rozpracovává v doporučeních pro ZŠ a SŠ; pro budoucího učitele je vhodné s nimi pracovat.

Atrofie dovedností

Pokud AI píše za žáka, **žák se neučí psát**. Pokud AI plánuje za učitele, **učitel se neučí plánovat**. Tento princip — **atrofie dovedností v důsledku přenesení činnosti na nástroj** — není novou otázkou (debata o kalkulačkách v matematice, o GPS navigaci, o autokorekci pravopisu), ale s nástupem LLM asistentů dostává **novou intenzitu**. Současné AI nepřebírá jen dílčí mechanické úkony, ale **kognitivní procesy vyššího řádu** — formulování myšlenky, strukturování argumentace, kreativní syntézu, kritickou analýzu.

Pro geografické vzdělávání je atrofie dovedností obzvlášť relevantní v několika oblastech:

1. **Pisatelská kompetence.** Schopnost samostatně formulovat myšlenku v souvislém textu je jednou z klíčových kompetencí, kterou škola rozvíjí. Pokud žák při všech delších textech používá AI, **tato kompetence neroste**. Pro učitele geografie to znamená, že některé úkoly (popisy regionů, eseje o geografických tématech, reflexivní texty) musí zůstat **AI-mimo zónou** — aby pisatelská kompetence měla prostor se rozvíjet.
2. **Kritické čtení faktografického textu.** Pokud žák žádá AI o sumarizaci místo aby text sám četl, **schopnost samostatného čtení odborné literatury slábne**. Pro budoucího učitele to znamená, že při práci s odbornými články by měl žáky vést k vlastní četbě a teprve sekundárně případně použít AI pro rekapitulaci nebo doplnění.
3. **Pedagogická improvizace.** U učitele samotného je rizikem nadměrné spoléhání na AI při přípravě hodin. Pokud učitel **každou hodinu** připravuje s AI, jeho samostatná pedagogická invence se postupně oslabuje. AI je doplněk, ne náhrada didaktického myšlení.

Klíčem k prevenci atrofie je **vědomá střídavost** — AI pro některé úkoly, samostatná práce pro jiné. Doba intervence z metaanalýzy Wang a Fan (4–8 týdnů jako optimum) je v této souvislosti silným empirickým podkladem: **trvalé používání AI snižuje její efekt**, protože uživatelé ztrácejí samostatné dovednosti, které by AI měla rozšiřovat, ne nahrazovat.

Zároveň je třeba zdůraznit, že **opačný extrém — AI úplně se vyhýbat — není pro budoucího učitele řešením**. Kompetentní učitel v éře AI **musí AI sám aktivně používat**. Jen na základě **vlastní opakované zkušenosti** s nástrojem si učitel vybuduje schopnost rozeznat, **kde AI pomáhá a kde škodí, kdy její výstup věřit a kdy ne, jaká pravidla pro žáky formulovat**. Tato schopnost je formou **metakognice zaměřené na digitální svět** — uvědomělé reflexe vlastních procesů při práci s digitálními nástroji.

Bez aktivní vlastní praxe učitel zůstává v pozici teoretika, který předává žákům abstraktní pravidla bez zakotvení ve zkušenosti. Žáci toto rozdělení rychle rozeznají a pravidla nepřijmou jako věrohodná. Naopak učitel, který **AI pravidelně používá, reflektuje vlastní úspěchy a chyby, učí se z chyb svých i cizích, sleduje vývoj nástrojů a sdílí zkušenost s kolegy**, vytváří **kvalitní pedagogickou pozici**, která žákům něco říká i bez explicitních pravidel — modeluje **vědomé používání nástroje**, ze kterého si žáci odvodí vlastní zdravé hranice.

Aktivní a systematická vlastní zkušenost s AI je proto **základní podmínkou** pro rozvoj profesní kompetence v této oblasti. Není to volitelný doplněk profesní přípravy učitele geografie — je to **její nedělitelná součást**.

Ekologická stopa

Provoz LLM asistentů má **významné energetické náklady**. Trénování velkých modelů spotřebovává obrovské množství elektriny; každý prompt vyžaduje energii pro odpověď; chlazení datacenter zatěžuje vodní zdroje. Konkrétní čísla se rychle mění s vývojem technologií, ale řád zůstává: **práce s LLM asistentem není ekologicky neutrální**.

Pro učitele geografie — oboru, který se aktivně zabývá klimatickou změnou a environmentálními dopady lidských aktivit — má tento okruh zvláštní symbolickou váhu. Není konzistentní vyučovat o snížení uhlíkové stopy a současně používat AI bez ohledu na její vlastní stopu.

To **neznamená vyhýbat se AI z ekologických důvodů**. Znamená to **uvážlivé používání**:

- nepoužívat AI na úkoly, které lze efektivně vyřešit jinak (jednoduché vyhledávání, krátké odpovědi)
- nepoužívat opakovaně stejné prompty, když si výstup můžete uložit
- pro velké úkoly volit jeden komplexní prompt místo desítek malých
- u žáků pěstovat **stejnou uvážlivost** — AI jako nástroj pro náročné úkoly, ne pro běžné dotazy

Argumentace v tomto okruhu je didakticky cenná i pro výuku se žáky. AI lze postavit do **stejně perspektivy jako jiné technologie s ekologickou stopou** (auta, klimatizace, mezinárodní letecká doprava) — uvědomělé používání místo úplné odmítnutí, kvalitativní změna místo asketické zdrženlivosti.

Technologická nerovnost

LLM asistenti mají placené i bezplatné tarify. Placené verze typicky nabízejí lepší modely, vyšší limity použití, kvalitnější vyhledávání, přístup k pokročilým funkcím (RAG, vlastní asistenty, multimodální vstupy). **Žáci ze sociálně různě situovaných rodin mají k těmto nástrojům různý přístup.**

Pro učitele to znamená dvě praktická rizika. **Za prvé**, pokud učitel zadá úkol, který smysluplně vyžaduje pokročilé funkce AI (například RAG s přiloženým PDF), žáci, jejichž rodina nemá placený tarif, jsou znevýhodněni. **Za druhé**, i u bezplatných tarifů hraje roli **digitální vybavení rodiny** — žáci s vlastním počítačem doma mají jiné podmínky než žáci, kteří mohou pracovat jen ve školní počítačové učebně.

Praktická pravidla:

- **úkoly s povinným použitím AI** zadávat tak, aby je bylo možné splnit i v bezplatném tarifu hlavních nástrojů
- **rozsah práce s AI** plánovat s vědomím, že žáci mohou narazit na denní limity bezplatných verzí
- **pro náročnější úkoly** zajistit alternativní cestu — školní účet, společná práce v hodině, individuální podpora
- **diskutovat se žáky** otázku technologické nerovnosti otevřeně, ne ji přehlížet

Pro budoucího učitele je tato otázka součástí širší pedagogické citlivosti k sociálnímu složení třídy. Stejně jako učitel přemýšlí o tom, zda všichni žáci mají rovný přístup k učebnicím nebo k pomůckám, musí přemýšlet o rovném přístupu k digitálním nástrojům.

LLM asistenti jsou trénováni na **rozsáhlých textových korpusech**, ve kterých jsou různé jazyky, kultury a regiony zastoupeny **velmi nerovnoměrně**. Anglicky psané texty tvoří dominantní část většiny korpusů. České texty mají v korpusu řádově menší zastoupení. Některé jazyky a kultury (jihoamerické, africké, středoasijské) jsou zastoupeny minimálně.

Tato nerovnoměrnost se promítá do výstupů. Model **rozumí lépe tématům, kde má víc dat**, a **zkresleně nebo s mezerami** popisuje témata, kde má dat málo. Pro výuku regionální geografie z toho plyne několik konkrétních dopadů:

Asymetrie hloubky. Pokud se učitel ptá na detaily geografie New Yorku, dostane bohatý a strukturovaný popis. Pokud se ptá na geografii Tomska nebo Maputo, dostane výrazně méně informací — a riziko halucinace je výrazně vyšší.

Defaultní perspektiva. Pokud učitel nezadá žádný kulturní kontext, model **defaultně uvažuje z anglosaské perspektivy**. Příklady, analogie, hodnotové soudy — vše vychází z dominantního kulturního pozadí trénovacích dat. Pro učitele geografie, který chce prezentovat **plurálu perspektiv** (například při výuce o globální nerovnosti, kulturních konfliktech, historických událostech), je nutné explicitně žádat o **alternativní perspektivu**.

Český kontext jako menšina. Pro výuku regionální geografie ČR je toto omezení obzvlášť relevantní. Model českou krajinu zná **jako menšinový případ globálního korpusu**. Pro detailní výuku českého místopisu je AI nedostatečným zdrojem a musí být doplněna českou odbornou literaturou, mapovými portály (mapy.cz, geoportál ČÚZK) a primárními statistickými zdroji.

Praktická pravidla pro práci s tímto zkreslením:

- pro výuku českého místopisu a regionální geografie ČR **používat AI s vědomím jejích limitů** a doplňovat ji o český zdrojový materiál
- pro výuku světových regionů **explicitně žádat plurál perspektiv** v promptech („*uved', jak na tento problém pohlíží různí aktéři z různých kulturních pozic*")
- pro výuku **kontroverzních historických událostí** (kolonialismus, válečné konflikty, územní spory) ověřovat AI výstupy o různé národní perspektivy
- **se žáky tematizovat kulturní pozici AI** jako součást mediální gramotnosti — model „někoho zastupuje" v tom, co a jak říká

Epistemické limity LLM pro geografické myšlení

Etické okruhy se týkají **toho, jak s AI správně jednat**. Nyní se vracíme do epistemické roviny, kterou jsme otevřeli na začátku této podkapitoly: **co AI principiálně nemůže nahradit v geografickém myšlení**. Jde o limity, které nejsou důsledkem současného stavu technologie a které nezmizí s lepšími modely. Jsou důsledkem toho, **co LLM principiálně je** — a co geografické poznání **principiálně potřebuje**.

LLM nemá vlastní zkušenost s prostorem

Model nezná pocit, jaké je stoupání kopcem. Nezná chuť vzduchu po dešti v lese. Nezná vůni přístavu, hluk centra města, ticho horské louky. Nezná tělesnou paměť pohybu krajinou. **Vše, co o těchto věcech model říká, vychází z toho, co o nich napsali jiní lidé.**

Pro geografické vzdělávání, které se v této sérii textů opírá o **fenomenologii místa** (Tuan, Relph), **terénní geografii** a **autentickou žákovou zkušenost s prostorem**, je tento limit zásadní. AI dokáže o místě **mluvit**, ale nemůže ho **prožít**. A geografické porozumění, které stojí na **autentickém setkání s krajinou**, je mimo dosah jakéhokoli LLM asistenta — současného i budoucího.

Pro budoucího učitele to znamená, že **terénní složka výuky** — exkurze, terénní pozorování, místní orientace — **získává s nástupem AI ještě vyšší didaktickou hodnotu**, ne nižší. Je to oblast, kde AI nemůže učitele zastoupit, a kde se proto autentická pedagogická práce odehrává v čisté podobě.

LLM nepracuje s pojmovou strukturou prostoru

Model pracuje se **vzorci v textu**, ne s **pojmovou strukturou** v geografickém smyslu. Když mluví o povodňové prevenci, nedělá to z pochopení vodního cyklu, ale z toho, co o povodňové prevenci říkají texty. Často to vede ke smysluplným odpovědím — v jednoduchých případech se vzorce v textu kryjí s pojmovou strukturou — ale v komplexních případech model odhalí svou jazykovou (ne pojmovou) povahu. **Když je třeba pojem „přeformulovat ze základu“**, AI to neumí. Pracuje s tím, co o pojmu už bylo řečeno.

Pro výuku geografického myšlení (jak ho rozpracovává podkapitola 2 této série) to znamená, že **rozvoj pojmové struktury** — schopnost žáka vlastními slovy vysvětlit pojem, vidět vztahy mezi pojmy, restrukturovat pojmovou síť při setkání s novou informací — je **prací učitele**, ne AI.

LLM nemůže nahradit autentickou participaci

V kapitole o geomédiích jsme rozpracovali model RAP — Reflexe, Argumentace, **Participace**. Participativní rovina geografického vzdělávání předpokládá, že žák (nebo učitel) **vstupuje do reálného sociálního prostoru** s vlastní pozicí, pohledem, akcí. Píše dopis na obecní úřad, účastní se veřejné diskuze, navrhne místní projekt, sdílí poznatky s komunitou.

LLM asistent může tuto participaci **podpořit** — pomoci formulovat dopis, najít argumenty pro veřejnou diskuzi, navrhnout strukturu projektu. **Nemůže ji ale provést**. Model nikam nevstoupí. Žádný hlas v reálné diskuzi nezvedne. Žádný dopis nepošle s vlastním jménem.

Pro geografii s aktivně-občanským přesahem (aktivní občanství, prostorové nerovnosti) to znamená, že **autentická participace zůstává oblastí, kde se geografické vzdělávání odehrává v plné podobě bez možnosti AI substituce**.

Budoucí učitel geografie v AI kontextu

Z dosavadního výkladu plyne syntetický obraz **role budoucího učitele geografie v éře AI**. Tento obraz uzavírá nejen tuto podkapitolu, ale celou kapitolu — vrací se k otázce „Může AI nahradit učitele?“ otevřené v podkapitole 3 a poskytuje na ni odpověď, která integruje vše, čím jsme prošli.

Učitel geografie v éře AI je průvodce, ne zdroj informací. Funkce „nositele faktografického poznání“ se z učitele přesouvá k AI a k digitálním databázím. Funkce **průvodce kritickou prací s informacemi**, kdo umí žákům ukázat, **jak rozeznat kvalitní informaci od halucinace, jak ověřovat zdroje, jak zařadit AI výstup do plurálního pojmového rámce**, naopak **roste na důležitosti**.

Učitel geografie v éře AI je pedagog autentické zkušenosti. AI nedokáže nahradit terénní pozorování, autentické setkání s místem, fenomenologickou rovinu geografického vzdělávání. Tyto oblasti jsou **chráněné prostory pedagogické práce**, kde se geografické myšlení rozvíjí v čisté podobě.

Učitel geografie v éře AI je nositel autentického pedagogického vztahu. Vzdělávací proces není jen předávání informací; je to **vztahová praxe**, ve které učitel a žák spolu sdílejí čas, prostor, pozornost, odpovědnost. AI dokáže **napodobit** některé povrchové projevy tohoto vztahu — generuje empatické formulace, vytváří personalizované odpovědi, projevuje zájem o uživatele. **Tuto napodobeninu je třeba brát vážně** — funguje subjektivně a v některých situacích má svůj didaktický význam (například při samostatném studiu, kdy student potřebuje strukturovanou zpětnou vazbu).

Současně ale platí, že simulovaná empatie nestojí na žité zkušenosti, není zakotvena ve společném prostoru, nenese odpovědnost za druhého, není přítomná v reálném čase. Skutečný pedagogický vztah — **přítomnost učitele s žákem v jedné místnosti, sdílená paměť společných hodin, dlouhodobý kontakt, vzájemný respekt, závazek odpovědnosti za žákův růst** — je oblastí, kde AI principiálně nemůže učitele nahradit. Žák, který má **autentický pedagogický vztah** s učitelem, má něco kvalitativně jiného než žák, který má jen přístup k LLM asistentovi. Tento rozdíl je nepřevoditelný a nezávisí na technické úrovni AI — bude platit i v budoucnu, kdy budou modely výrazně dokonalejší než dnes.

Učitel geografie v éře AI je etický a epistemický referenční bod. Žáci se ocitají ve světě, kde AI je všudypřítomný nástroj — a kde **kritická a eticky reflektovaná práce s ní** je klíčovou kompetencí budoucnosti. Učitel, který tuto kritickou a etickou práci umí sám a předává ji žákům, plní jednu z nejdůležitějších společenských rolí současné školy.

Učitel geografie v éře AI je participativní pedagog. Aktivní občanství, prostorové nerovnosti, klimatická spravedlnost — to jsou oblasti, kde se geografické vzdělávání transformuje **z předávání faktů na podporu autentické sociální participace**. AI tyto procesy podporuje, ale nesubstituuje. Učitel, který chápe rozdíl, používá AI jako pomocníka pro participativní pedagogiku, ne jako jejího nahradníka.

Závěrečná teze, kterou si **odnesete z této kapitoly do vlastní praxe**: AI nezmenšuje význam učitele. **Mění to, čím je učitel důležitý** — a v této změně otevírá pro pedagogiku nové prostory hodnoty, kterých si dosud možná nebylo plně vědomí. Být učitelem geografie v éře AI **znamená být víc, ne méně**, než byl učitel před nástupem těchto technologií. Být víc kritickým, autentickým, etickým, participativním, **a zachovávat autentický pedagogický vztah s žákem jako nepřevoditelný základ**. AI tu pomáhá, ale ne zastoupí.

Rychlé čtení podkapitoly 6

Hlavní teze: Práce s AI vyžaduje současnou pozornost k **epistemické rovině** (jak víme to, co AI tvrdí — pravdivostní obsah, halucinace, kritické ověřování) a k **etické rovině** (jak s AI správně jednat — ochrana údajů, integrita práce, nerovnost, kulturní zkreslení, ekologická stopa).

Halucinace jsou principiální vlastnost LLM, ne chyba. Šest typických typů v geografii: konkrétní čísla, lokálně specifické informace, datace, hraniční pojmosloví, **chyby v logice uzavřených testových položek**, citace literatury. Pro každý faktografický údaj použitý ve výuce platí **povinnost ověření**.

Metoda SIFT (Caulfield, 2017) jako čtyři kroky kritického ověřování: Stop (zastavit se), Investigate (prozkoumat zdroj), Find better coverage (najít lepší pokrytí), Trace claims (vystopovat tvrzení). U LLM s vyhledáváním se SIFT mění z dohledávání na ověřování citovaných zdrojů.

Most ke geomédiím: AI gramotnost není zcela novou kompetencí, ale **současnou aplikací kritické geomediální gramotnosti** na nový typ mediálního obsahu. Učitel, který ovládá kritickou práci s geomédií, je principiálně připraven kriticky pracovat i s AI výstupy.

Šest etických okruhů (rámec konzistentní s UNESCO 2025):

1. **Ochrana osobních údajů** — anonymizovat všechny vstupy, necitovat doslovně texty s identifikačními údaji.
2. **Akademická integrita** — nová pravidla pro éru AI; rozlišovat **autorství myšlenky** (předmět ochrany) od **formy vyjádření** (může být kolaborativní s AI); **proměna zadání** směrem k autentickým, ústním, lokálně ukotveným formám, které prokazují autorství.
3. **Atrofie dovedností** — vědomá střídavost mezi prací s AI a samostatnou prací; doba intervence 4–8 týdnů jako empirické optimum. **Aktivní vlastní zkušenost s AI** je zároveň základní podmínkou kompetence učitele — bez ní zůstává teoretikem bez zakotvení v praxi.
4. **Ekologická stopa** — uvážlivé používání AI; konzistence s tématy klimatické změny ve výuce.
5. **Technologická nerovnost** — úkoly proveditelné v bezplatných tarifech; alternativní cesty pro náročnější aktivity.
6. **Kulturní a jazykové zkreslení** — explicitně žádat plurál perspektiv; pro český místopis doplňovat AI o český zdrojový materiál.

Tři epistemické limity LLM pro geografické myšlení:

1. LLM nemá vlastní zkušenost s prostorem (terénní výuka jako nezastupitelná oblast).
2. LLM nepracuje s pojmovou strukturou prostoru (rozvoj pojmové sítě je práce učitele).
3. LLM nemůže nahradit autentickou participaci (model RAP — Reflexe, Argumentace, Participace).

Syntéza role učitele geografie v éře AI: AI nezmenšuje význam učitele. Mění to, čím je učitel důležitý. Učitel se stává **průvodcem kritické práce, pedagogem autentické zkušenosti, nositelem autentického pedagogického vztahu, etickým a epistemickým referenčním bodem, participativním pedagogem**. Být učitelem v éře AI znamená být víc, ne méně.

V závěru kapitoly se vracíme k otevřené otázce, kterou tento text provází od podkapitoly 3 — pokud LLM zlepšují výkon mnohem víc než myšlení vyššího řádu, neposiluje to právě paradigma, kterému chceme uniknout?

Závěr

Tato kapitola z kurzu Geoinformatika ve vzdělávání vyučovaném na Technické univerzitě v Liberci (v odborné gesci Katedry geoinformatiky a didaktiky informatiky) vás provedla šesti rovinami práce s umělou inteligencí v geografickém vzdělávání — od terminologie a principů fungování LLM, přes praktické základy promptování, teoretický rámec AI ve vzdělávání a empirickou evidenci, k aplikaci na geografické vzdělávání, pokročilým technikám promptování, a etickým a epistemickým aspektům. V průběhu textu jsme některé otázky **záměrně neuzavřeli** — protože vědecký výzkum k nim ještě nedospěl k jednoznačné odpovědi a vaše vlastní pedagogická pozice se k nim teprve formuje.

Nejvýznamnější z otevřených otázek nás provázela od podkapitoly 3 až do závěru: **pokud generativní AI zlepšuje učební výkon mnohem víc než kritické a tvořivé myšlení ($g = 0,867$ vs. $g = 0,457$), neposiluje to právě tu didaktickou logiku, která stojí v rozporu se vším, co tato série textů hájí — pojetí geografie jako oboru kritické prostorové gramotnosti, badatelského myšlení a aktivního občanství?**

Odpověď, kterou kapitola umožňuje formulovat, je dvojí.

Empiricky je riziko reálné. Bez vědomé didaktické práce LLM asistenti skutečně tíhnou k výkonové optimalizaci na úkor hloubkového myšlení. Nezáleží na nástroji — záleží na **didaktickém zarámování**, ve kterém je nástroj nasazen. Stejný LLM asistent může v jedné hodině posilovat první roli AI (žák jako pasivní příjemce hotových odpovědí) a v jiné hodině třetí roli (žák jako lídr vlastního učení). Pedagogická volba tohoto zarámování zůstává **na učiteli**.

Strukturálně je odpověď náročnější. Pokud se vzdělávací systém jako celek bude řídit primárně viditelnými výkonovými ukazateli — známkami, výsledky testů, srovnatelnými výstupy — AI tento směr přirozeně posílí, protože v něm má největší efekt. Pokud naopak vzdělávací systém uchová a rozvine **kvalitativní ukazatele učení** — kritické myšlení, tvořivost, autentickou zkušenost, schopnost participace — AI se stane nástrojem, který tyto kvalitativní procesy podpoří. **Tato volba není individuální. Je to kolektivní rozhodnutí o tom, co vzdělávání má dělat.**

V této kolektivní rozpravě je hlas učitele geografie cenný. Geografie disponuje pedagogickou tradicí, ve které **autentická zkušenost s prostorem, místní orientace a kritická práce s reprezentacemi světa** mají dlouhodobé místo. To je tradice, která se s nástupem AI **nestává zastaralou**, ale naopak **zdrojem, ze kterého lze čerpat odpověď** na otázky, na které jiné obory teprve hledají odpověď. Učitel geografie, který svou tradici aktivně rozvíjí a propojuje ji s informovanou prací s AI, je **přínosem nejen pro vlastní žáky, ale pro celou pedagogickou komunitu**.

Být učitelem geografie v éře umělé inteligence znamená stát na **dvou nohách současně** — jedna noha v pedagogické tradici, která ví, co je **autentická zkušenost a kritické myšlení**, druhá noha v současných nástrojích, které tuto tradici **nemusí ohrožovat**, pokud je s nimi zacházeno vědomě. Tento dvojnohý stoj není pohodlný. Je to ale stoj, ze kterého geografické vzdělávání má **nejlepší výhled** — víc než kdy dříve.

Otevřená otázka, se kterou jste začali tuto kapitolu, vás bude provázet i nadále. **Nemůže být uzavřena**, protože odpověď na ni se rodí v praxi — v každé konkrétní hodině, v každém konkrétním rozhodnutí, v každém konkrétním vztahu se žákem. Studijní text vám k této praxi poskytl pojmový rámec, empirickou orientaci, praktické nástroje a kritickou reflexi. **Vlastní odpověď zformulujete sami ve své pedagogické budoucnosti.**

Klíčová sdělení kapitoly

Pro pevnou orientaci v textu shrnujeme deset klíčových sdělení, která tvoří tematické jádro kapitoly.

1. **Kvalita výstupu je především funkcí kvality vstupu.** Investice do promptové gramotnosti se vrací ve výrazně lepších výsledcích a je přenositelná napříč nástroji. Naučit se promptovat znamená osvojit si **dovednost, která neztrácí hodnotu** s tím, jak se konkrétní produkty mění.
2. **LLM asistent v geografii halucinuje častěji než v některých jiných oblastech.** Místopis, statistiky, lokální informace, datace, citace — to vše jsou typy obsahu, kde model rekonstruuje data pravděpodobnostně a kde **každý faktografický údaj je nutné ověřit** před použitím ve výuce.
3. **Tři typy nasazení LLM asistenta** (samostatný / s vyhledáváním / RAG) se výrazně liší rizikem halucinace. **Schopnost rozpoznat, jaký typ AI nasazení daná situace vyžaduje, je sama o sobě klíčovou kompetencí učitele.** Pro práci s aktuálními tématy a kurikulárními dokumenty je RAG režim zásadní.
4. **AI nemá pevnou pedagogickou roli — rozhoduje didaktické zarámování.** Tentýž nástroj může v jedné hodině posilovat pasivní příjem hotových odpovědí, v jiné aktivní spolupráci, v třetí samostatné vedení vlastního učení. Tato volba je **na učiteli**.
5. **Empirická evidence ukazuje znepokojivý paradox.** LLM asistenti nejsilněji zvyšují výkon ($g = 0,867$) a nejslaběji myšlení vyššího řádu ($g = 0,457$). Bez vědomé didaktické práce AI tihne k posílení paradigmatu, kterému kritická pedagogika chce uniknout. **Vědomé pedagogické zarámování je proto klíčové.**
6. **Geografie se s AI nestává zastaralou — ale transformuje se.** Tradice terénní práce, místní orientace a autentické zkušenosti s prostorem jsou přesně ty oblasti pedagogické práce, **kde AI principiálně nemůže učitele nahradit.** Geografie má v této transformaci dobrou výchozí pozici.
7. **Pokročilé techniky promptování umožňují kvalitativně lepší výsledky** u náročných úkolů. Nejhodnotnější dovedností je **kombinace několika technik** v jednom promptu pro konkrétní situaci. Tato dovednost se osvojuje **vlastní praxí**, ne pasivním čtením teorie.
8. **AI gramotnost je současnou aplikací kritické geomediální gramotnosti** na nový typ mediálního obsahu. Učitel, který ovládá kritickou práci s geomédií (kapitola o geomédiích v této studijní opoře), je principiálně připraven pracovat i s výstupy AI. Stávající dovednosti se aplikují, ne se učí znovu.
9. **Aktivní vlastní zkušenost učitele s AI je nedělitelnou součástí jeho profesní přípravy.** Bez systematické vlastní praxe nemůže učitel formulovat věrohodná pravidla pro žáky, rozeznávat halucinace, kriticky posuzovat výstupy. AI nelze zvládnout teoreticky — je to dovednost zakotvená ve zkušenosti.
10. **AI nezmenšuje význam učitele — mění to, čím je učitel důležitý.** Učitel přestává být primárně zdrojem informací a stává se **průvodcem kritické práce, pedagogem autentické zkušenosti, nositelem autentického pedagogického vztahu, etickým a epistemickým referenčním bodem, participativním pedagogem.** Být učitelem geografie v éře AI znamená **být víc, ne méně.**

Otázky pro samostudium

Otázky jsou rozdělené do tří kategorií podle typu kognitivní práce, kterou vyžadují. Doporučujeme projít otázky všech tří kategorií — každá rozvíjí jiný typ porozumění textu.

Pojmové otázky — zapamatování a porozumění

1. Vlastními slovy vysvětlíte rozdíl mezi pojmy AI, AIEd, GenAI a LLM asistent. Uveďte u každého pojmu konkrétní příklad.
2. Co znamená pojem **knowledge cutoff** a proč je pro učitele geografie důležitý? Popište alespoň tři situace, kdy je nutné při práci s LLM asistentem brát knowledge cutoff výslovně v úvahu.
3. Vysvětlíte princip RAG (retrieval-augmented generation) a uveďte tři konkrétní příklady, kdy by ho učitel geografie využil v přípravě výuky.
4. Pojmenujte tři role AI ve vzdělávání podle Ouyang a Jiao (2021). Pro každou roli uveďte: teoretický základ, roli AI, roli žáka, příklad geografického úkolu.

Analytické otázky — analýza a hodnocení

5. Vysvětlíte paradox mezi efektem AI na učební výkon ($g = 0,867$) a na myšlení vyššího řádu ($g = 0,457$). Posudte, jak by tento paradox měl ovlivnit konkrétní rozhodnutí učitele geografie při plánování hodiny — uveďte tři praktické důsledky pro vlastní praxi.
6. Analyzujte, ve kterých oblastech geografického vzdělávání má LLM asistent jasnou hodnotu, a kde naopak nestačí nebo škodí. Pro každou oblast uveďte zdůvodnění opřené o vlastnosti LLM popsané v podkapitole 1.
7. Posudte rozdíl mezi **plagiátorstvím** v klasickém smyslu a **legitimním použitím AI** pro jazykové úpravy textu. Kde leží etická hranice a jak ji jako budoucí učitel formulujete pro vlastní žáky?

Reflexivní otázky — vlastní stanovisko

8. Otevřená otázka kapitoly zní: pokud LLM asistenti zvyšují výkon mnohem víc než myšlení vyššího řádu, neposiluje to právě paradigma, kterému kritická pedagogika chce uniknout? Formulujte vlastní stanovisko k této otázce — ne jako akademický výklad, ale jako pedagogickou pozici, ze které budete vyučovat.

9. Reflektujte vlastní vztah k AI jako k pomocníkovi ve vlastním studiu. Které úkoly studujete s AI a které úmyslně bez ní? Z jakých důvodů? Změnilo by se vaše rozhodování po přečtení této kapitoly?

10. Promyslete, jak budete formulovat **pravidla pro používání AI ve své budoucí třídě**. Jaká pravidla zavedete pro různé typy úkolů (faktografické otázky, eseje, projekty, terénní práci)? Jak budete pravidla komunikovat žákům a jejich rodičům?

Úkoly pro samostatné procvičování

Úkoly jsou rozdělené do tří kategorií podle náročnosti a časové investice. Pro získání plné kompetence z této kapitoly doporučujeme zpracovat alespoň jeden úkol z každé kategorie.

Krátké úkoly (do 30 minut)

1. Test halucinací. Položte dvěma různým LLM asistentům (například Claude a ChatGPT) tři geograficky-faktografické otázky o vašem rodném kraji (rozloha okresu, počet obyvatel okresního města k roku 2024, nadmořská výška lokálního vrcholu). Odpovědi porovnejte s primárním zdrojem (ČSÚ, mapový portál). Zaznamenejte: kolik odpovědí bylo přesných, kolik nepřesných, kolik halucinačních. Uvedte krátkou reflexi (5–10 vět) o tom, co z toho plyne pro vaši budoucí praxi.

2. Iterativní zpřesnění promptu. Zformulujte vágní prompt na téma vlastního výběru z geografického vzdělávání (například „*napiš pracovní list o klimatu*“). Otestujte ho v LLM asistentovi. Pak prompt postupně zpřesněte ve **třech iteracích** — doplňte kontext, parametry, cíl. Po každé iteraci zaznamenejte výstup a porovnejte kvalitu odpovědi. V krátké reflexi popište, co konkrétně se v každé iteraci zlepšilo.

3. Analýza ukázkového promptu. Vyberte si jeden ze pěti komplexních ukázkových promptů z podkapitoly 5. Identifikujte v něm všechny použité pokročilé techniky promptování. Pro každou techniku popište, jakou funkci v promptu plní a co by se stalo, kdyby ji uživatel z promptu vypustil.

Středně náročné úkoly (1–3 hodiny)

4. RAG práce s RVP ZV. Stáhněte si revidované RVP ZV (PDF z webu MŠMT). Nahrajte ho do RAG nástroje (NotebookLM, Claude Projects, ScioBot s vlastními materiály). Postupujte podle pětikrokového postupu z podkapitoly 4. Vygenerujte tabulku všech očekávaných výstupů ve vzdělávací oblasti Člověk a příroda, které se týkají vodního hospodářství. Tabulku zkontrolujte proti původnímu RVP — zaznamenejte všechny nepřesnosti, které jste odhalili. Reflektujte, do jaké míry by RAG nástroj reálně urychlil vaši kurikulární práci.

5. Vlastní pracovní list pomocí pokročilých technik. Vytvořte pracovní list pro vlastní budoucí hodinu (téma a ročník dle vlastního výběru) s pomocí LLM asistenta. Použijte **alespoň tři pokročilé techniky promptování** z podkapitoly 5. Po vygenerování výstupu pracovní list zkritizujte (jako učitel hodnotící cizí materiál) a navrhnete úpravy. Konečnou verzi pracovního listu odevzdejte spolu s krátkou reflexí (jaké techniky jste použili, jak fungovaly, co byste příště udělali jinak).

6. Analýza mediálního výstupu o klimatu. Vyberte si konkrétní článek z české mediální produkce o klimatickém tématu (sucho v ČR, povodně, energetická transformace, klimatická politika). Aplikujte na něj prompt č. 4 z podkapitoly 5 (analýza mediálního výstupu) ve dvou různých LLM asistentech. Porovnejte výstupy — kde se shodují, kde se liší, který nástroj poskytl hlubší analýzu. Reflektujte, co z toho plyne pro vaši budoucí výuku kritické práce s mediálními texty.

7. Vlastní persona experta. Vytvořte vlastní personu odborníka pro téma, na kterém aktuálně pracujete (klimatolog, urbanista, kartograf, geomorfolog...). Vedte s personou strukturovaný rozhovor o pěti až deseti otázkách pro vlastní odbornou orientaci. Z odpovědí vyfiltrujte: které informace jste prověřili a potvrdili v primárních zdrojích, které byly halucinací, které byly užitečné jako navedení k dalšímu studiu. Persona je nástroj — popište, ke které části vlastní přípravy vám pomohla nejvíc.

Projektové úkoly (5+ hodin)

8. Návrh tematického bloku s integrací AI. Navrhnete tematický blok pro 8. nebo 9. ročník (4–6 vyučovacích hodin) na téma vlastního výběru. Pro každou hodinu specifikujte: cíl, strukturu, materiály, úkoly pro žáky, **rozhodnutí o roli AI** (kde je AI vhodná, kde nikoli, kde je zapojení AI na žákovi a kde na učiteli). Návrh připravte v takové úrovni, aby ho mohl bezprostředně realizovat jiný učitel. K návrhu připojte krátký komentář o tom, jak jste rozhodovali o nasazení AI v jednotlivých hodinách.

9. Praktická studie s ArcGIS StoryMaps. Postupem popsáním v podkapitole 4 (Hormuz, Fáze 4) vytvořte vlastní učební pomůcku v ArcGIS StoryMaps na téma geografického zájmu pro žáky vámi zvoleného ročníku. Pro generování obsahu použijte NotebookLM s nahranými relevantními zdroji. Hotovou aplikaci doplňte o tisknutelný pracovní list pro žáky. Aplikaci otestujte alespoň s

jedním člověkem (kolegou, spolužákem, žákem) a zaznamenejte zpětnou vazbu. Výstupem je hotová aplikace + reflexivní zpráva (1–2 strany) o procesu tvorby a získané zpětné vazbě.

10. Vlastní pravidla pro AI ve třídě. Zformulujte vlastní strukturovaný dokument „*Pravidla pro používání AI v hodinách geografie*“ určený pro třídu, kterou budete jako budoucí učitel vést. Dokument by měl pokrývat: definice toho, co je AI; obecná pravidla pro různé typy úkolů; pravidla pro různé žákovské situace (domácí příprava, hodina, projekty); pravidla pro práci s halucinacemi; pravidla pro práci s lokálními a citlivými údaji; etické principy; postup pro neshody mezi učitelem a žákem o použití AI. Dokument formulujte v jazyce přiměřeném žákům 8.–9. ročníku. Připojte krátký metodický komentář pro další učitele, který vysvětlí, proč jste konkrétní pravidla zvolili.

Tezaurus klíčových pojmů

Tezaurus shrnuje klíčové pojmy z této kapitoly v abecedním uspořádání. Pro každý pojem uvádíme stručné vymezení a podkapitolu, ve které byl rozpracován hlouběji.

AI Lesson Plan Generator. Specializovaná platforma navržená pro generování didaktických materiálů (přípravy hodin, pracovní listy, testy) přímo pro učitele. V českém prostředí zástupcem ScioBot. (Podkapitola 4.)

AI ve vzdělávání (AIED, artificial intelligence in education). Aplikační oblast umělé inteligence ve vzdělávacím prostředí, s historií od 90. let 20. století. Zahrnuje inteligentní tutorské systémy, doporučovací systémy, learning analytics, AI chatboty. (Podkapitola 1.)

Akademická integrita. Poctivost při studiu a tvůrčí práci — neopisování, řádné citování zdrojů, vlastní autorství práce, transparentnost o pomoci a zdrojích. V éře AI rozšířená o rozlišení mezi autorstvím myšlenky (předmět ochrany) a formou vyjádření (může být kolaborativní s AI). (Podkapitola 6.)

Atrofie dovedností. Oslabení dovednosti v důsledku jejího přenesení na nástroj. V kontextu AI ohrožuje pisatelskou kompetenci, kritické čtení odborných textů, pedagogickou improvizaci. Prevencí je vědomá střídavost mezi prací s AI a samostatnou prací. (Podkapitola 6.)

Bloomova taxonomie kognitivních cílů. Šestiúrovňový rámec pro klasifikaci učebních cílů (zapamatování, porozumění, aplikace, analýza, hodnocení, tvorba). V LLM promptování slouží jako návod pro zadávání úkolů různé kognitivní náročnosti. (Podkapitola 4 a 5.)

Few-shot prompting. Pokročilá technika promptování, kdy uživatel poskytne v promptu několik (typicky 2–5) ukázkových příkladů formátu odpovědi. Liší se od one-shot (jeden příklad) a zero-shot (žádné příklady). (Podkapitola 5.)

Generativní AI (GenAI). Podmnožina umělé inteligence, která dokáže generovat nový obsah (text, obrazy, zvuk, video, kód). Zahrnuje LLM, generátory obrazu, multimodální asistenty. (Podkapitola 1.)

GeoAI (geospatial AI, geoprostorová umělá inteligence). Průsečík umělé inteligence s tradiční prostorovou analýzou. Zahrnuje extrakci prvků z map a snímků, predikci přírodních jevů, klasifikaci krajinného pokryvu. Kvalitativně odlišná kategorie od LLM. (Podkapitola 1 a 4.)

Halucinace AI. Situace, kdy LLM asistent vygeneruje fakticky nepravdivý výstup, formulovaný se stejnou jazykovou jistotou jako výstup pravdivý. Není chyba, ale principiální vlastnost LLM. V geografii obzvlášť častá u faktografických údajů, lokálních informací, datací, citací, uzavřených testových položek. (Podkapitola 1 a 6.)

Hedges's g. Standardizovaná míra velikosti účinku používaná v metaanalýzách. Interpretační rámec: 0,2 malý, 0,5 střední, 0,8 velký, 1,2 velmi velký efekt. (Podkapitola 3.)

Iniciativa AI dětem. Česká nezisková iniciativa vedená Evou Nečasovou, která systematicky vyvíjí didaktické rámce pro práci s AI ve vzdělávání. Web chatveskole.cz. (Podkapitola 4.)

Knowledge cutoff. Datum, do kterého sahají znalosti modelu (poslední datum trénování). Pro práci s aktuálními tématy je nutné používat režim s vyhledáváním na webu nebo RAG s aktuálními dokumenty. (Podkapitola 1 a 4.)

Korpus. Rozsáhlá uspořádaná sbírka textů, na kterých byl model trénován. Většina LLM má anglicky převažující korpus s nerovnoměrným zastoupením různých jazyků a kultur. (Podkapitola 1 a 6.)

LLM (large language model, velký jazykový model). Generativní AI specializovaný na práci s přirozeným jazykem. Trénován na velkém objemu textu, dokáže generovat gramaticky správný a kontextově relevantní text. (Podkapitola 1.)

LLM asistent (AI chatbot). Konkrétní produkt zpřístupňující LLM uživateli prostřednictvím konverzačního rozhraní. Příklady: Claude, ChatGPT, Gemini, Mistral, DeepSeek. (Podkapitola 1.)

Metaanalýza. Výzkumná metoda, která statisticky kombinuje výsledky řady původních studií zkoumajících podobnou otázku. Poskytuje souhrnný efekt s vyšší spolehlivostí než jednotlivá studie. (Podkapitola 3.)

NotebookLM. RAG platforma od společnosti Google s nadstavbovými funkcemi (Audio Overview, Mind mapy, briefing dokument, časová osa). Pro učitele cenná díky nízkému riziku halucinace v rámci nahraných zdrojů. (Podkapitola 1 a 4.)

Persona prompting. Varianta role-based prompting, kdy uživatel modeluje konkrétní fiktivní expertní postavu s biografickými detaily. Silná technika pro hloubkové rozhovory s odborníkem. (Podkapitola 5.)

Prompt. Vstupní zadání, které uživatel formuluje pro AI asistenta. Tři komponenty kvalitního promptu: kontext, úkol a parametry, cíl a kritéria úspěchu. (Podkapitola 2.)

Prompt chaining. Pokročilá technika, kdy uživatel zadá řetěz menších promptů, ve kterém výstup jednoho slouží jako vstup dalšího. Vhodné pro komplexní úkoly s více fázemi. (Podkapitola 5.)

RAG (retrieval-augmented generation). Konfigurace LLM asistenta, ve které model pracuje primárně s dokumenty přiloženými uživatelem. Výrazně snižuje riziko halucinace v rámci nahraných zdrojů. Příklady nástrojů: NotebookLM, Claude Projects, vlastní GPTs, ScioBot s vlastními materiály. (Podkapitola 1, 2 a 4.)

Reasoning model. Novější generace LLM s vestavěným mechanismem vnitřního uvažování (extended thinking). Příklady: OpenAI o1 a o3, Claude s režimem extended thinking, Gemini s reasoning módem, DeepSeek R1. U těchto modelů je některé klasické techniky promptování nadbytečné. (Podkapitola 5.)

Role-based prompting. Pokročilá technika, kdy uživatel zadá modelu konkrétní expertní roli, ze které má odpovídat. (Podkapitola 5.)

ScioBot. Český AI Lesson Plan Generator od společnosti Scio (sciobot.cz). Generuje strukturované přípravy hodin metodou E-U-R, podporuje nahrávání vlastních materiálů (RAG princip). (Podkapitola 4.)

SIFT. Metoda kritického ověřování informací podle Mike Caulfielda (2017): Stop, Investigate the source, Find better coverage, Trace claims. Aplikovatelná na výstupy AI jako rozšíření kritické geomediální gramotnosti. (Podkapitola 6.)

Token. Základní jednotka, se kterou LLM pracuje při zpracování textu — typicky slovo nebo jeho část. Model predikuje další token na základě pravděpodobnosti v kontextu. (Podkapitola 1.)

UNESCO AI Competency Framework for Students. Mezinárodní kompetenční rámec pro žáky vydaný UNESCO (Miao & Shiohira, 2024). Definuje čtyři kompetenční aspekty (human-centred mindset, etika AI, AI techniky a aplikace, návrh AI systémů) ve třech úrovních (porozumět, aplikovat, tvořit). Použitelný jako globální referenční materiál pro učitele plánující systematický rozvoj AI gramotnosti u žáků. (Podkapitola 4.)

UNESCO AI Competency Framework for Teachers. Mezinárodní kompetenční rámec pro učitele vydaný UNESCO (Miao & Cukurova, 2024). Strukturuje kompetenci do pěti aspektů (human-centred mindset, etika AI, základy a aplikace AI, AI v pedagogice, AI pro vlastní profesní rozvoj) ve třech úrovních progresu (osvojit, prohloubit, tvořit). Komplementární k rámci Sanusi a kolektivu (2022). (Podkapitola 3.)

XML tagy v promptu. Pokročilá technika strukturování promptu pomocí značek typu `<role>...</role>`, `<úkol>...</úkol>`, `<výstup>...</výstup>`. Vhodné pro složité prompty s vnitřní strukturou. (Podkapitola 5.)

Seznam zdrojů

Seznam zahrnuje zdroje použité v této kapitole — odborné publikace, oficiální dokumenty, didaktické rámce a webové portály. Zdroje jsou rozděleny podle typu pro snazší orientaci.

Odborné publikace, oficiální dokumenty a koncepční rámce

Caulfield, M. (2017). *Web Literacy for Student Fact-Checkers*. Pressbooks. Dostupné z: <https://webliteracy.pressbooks.com/>

Esri (2025). *What Is GeoAI?* Esri. Dostupné z: <https://www.esri.com/en-us/capabilities/geoai/overview>

Jekel, T., Gryl, I., & Schulze, U. (2025). Reflexion, Argumentation und Partizipation: Modell für emancipative Geomedien-Bildung. *Journal of Geography and Education*. (Podle citace v kapitole o geomédiích této studijní opory.)

Miao, F., & Cukurova, M. (2024). *AI Competency Framework for Teachers*. UNESCO. <https://doi.org/10.54675/ZJTE2084>

Miao, F., & Shiohira, K. (2024). *AI Competency Framework for Students*. UNESCO. <https://doi.org/10.54675/JKJB9835>

MŠMT (2025). *Rámcový vzdělávací program pro základní vzdělávání* (revidovaná verze). Ministerstvo školství, mládeže a tělovýchovy ČR. Dostupné z: <https://www.edu.cz/>

NPI ČR. *Metodická doporučení k revidovanému RVP ZV*. Národní pedagogický institut České republiky. Dostupné z: <https://www.npi.cz/>

Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education: The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020.

Sanusi, I. T., Olaleye, S. A., Agbo, F. J., & Chiu, T. K. F. (2022). The role of learners' competencies in artificial intelligence education. *Computers and Education: Artificial Intelligence*, 3, 100098.

Sawilowsky, S. S. (2009). New effect size rules of thumb. *Journal of Modern Applied Statistical Methods*, 8(2), 597–599.

UNESCO (2025). *AI and the Future of Education: Disruptions, Dilemmas and Directions*. UNESCO. <https://doi.org/10.54675/KECK1261>

Wang, J., & Fan, W. (2025). The effect of ChatGPT on students' learning performance, learning perception, and higher-order thinking: A meta-analysis. *Humanities and Social Sciences Communications*.

„Geospatial Artificial Intelligence (GeoAI) Is Widening the Digital Divide“ (2025). *Annals of the American Association of Geographers*, 115(9), 2017–2029.

Didaktické rámce a portály pro učitele

Iniciativa AI dětem, z. s. *Chatboti ve škole* — komplexní portál pro učitele s metodikami, doporučeními a databází promptů. Dostupné z: <https://chatveskole.cz/>

Iniciativa AI dětem & NPI ČR. *4 kroky ke smysluplnému učení s AI*. Dostupné z: <https://digitalizace.rvp.cz/clanky/4-kroky-ke-smysluplnemu-uceni-s-ai>

Iniciativa AI dětem & NPI ČR. *10 způsobů využití generativní AI ve výuce na ZŠ a SŠ*. Dostupné z: <https://digitalizace.rvp.cz/clanky/10-zpusobu-vyuziti-generativni-ai-ve-vyuce-na-zs-a-ss>

Furze, L. *AI Assessment Scale*. Dostupné z: <https://aiassessmentscale.com/>

Nástroje zmiňované v textu

Anthropic. *Claude*. Dostupné z: <https://claude.ai/>

OpenAI. *ChatGPT*. Dostupné z: <https://chatgpt.com/>

Google. *Gemini*. Dostupné z: <https://gemini.google.com/>

Google. *NotebookLM*. Dostupné z: <https://notebooklm.google.com/>

Mistral AI. *Le Chat*. Dostupné z: <https://chat.mistral.ai/>

DeepSeek. *DeepSeek*. Dostupné z: <https://chat.deepseek.com/>

Perplexity AI. *Perplexity*. Dostupné z: <https://www.perplexity.ai/>

Scio. *ScioBot*. Dostupné z: <https://sciobot.cz/>

Esri. *ArcGIS StoryMaps*. Dostupné z: <https://storymaps.arcgis.com/>

Esri. *ArcGIS Online*. Dostupné z: <https://www.arcgis.com/>

Magic School AI. *AI nástroje pro učitele*. Dostupné z: <https://www.magicschool.ai/>

Specializované rešeršní nástroje

Consensus. *AI Search Engine for Research*. Dostupné z: <https://consensus.app/>

Scite.AI. *AI for Researchers*. Dostupné z: <https://scite.ai/>

Elicit. *Research Assistant*. Dostupné z: <https://elicit.com/>