

SOUBORNÉ SDĚLENÍ

Umělá inteligence v zobrazovacích metodách

Artificial intelligence in imaging methods

Lukáš Lambert, Vojtěch Suchánek, Lukáš Mikšík, Jana Svítlová

Klinika zobrazovacích metod,
Fakultní nemocnice v Motole,
2. lékařská fakulta Univerzity
Karlovy, Praha

SOUHRN

Lambert L, Suchánek V, Mikšík L, Svítlová J. Umělá inteligence v zobrazovacích metodách

Rozvoj umělé inteligence (AI) přináší do zobrazovacích metod nové možnosti, které směřují k přesnější diagnostice, efektivnějšímu využití zdrojů a zlepšení komfortu pacienta. Ačkoli jsou koncepty AI známy již desítky let, teprve nedávné zrychlení vývoje výpočetních kapacit umožnilo jejich širší uplatnění v klinické praxi. Článek přináší přehled hlavních oblastí využití AI v pediatričké radiologii, kde limitující faktor často představuje dostupnost kvalitních trénovacích dat.

AI systémy se uplatňují v různých fázích radiologického procesu: od optimalizace objednávání a plánování vyšetření přes bezkontaktní biometrické řízení akvizice až po pokročilou rekonstrukci obrazu s nižší radiační zátěží či kratším časem vyšetření. V oblasti interpretace snímků napomáhá AI detekci patologií, kvantifikaci nálezů (např. stanovení skeletálního věku, antropometrických parametrů) a může přispět ke standardizaci a srozumitelnějšímu sdělení nálezu pacientovi.

Přestože AI není náhradou za erudovaného radiologa, její podpůrná role je v mnoha aspektech výhodná a neustále se rozšiřuje. Významné výzvy zůstávají v oblasti etiky, zodpovědnosti za interpretaci a ekonomické udržitelnosti.

Klíčová slova: umělá inteligence, zobrazovací metody, rentgen, výpočetní tomografie, magnetická rezonance, kontrastní látka

SUMMARY

Lambert L, Suchánek V, Mikšík L, Svítlová J. Artificial intelligence in imaging methods

Recent advances in artificial intelligence (AI) have introduced novel opportunities in diagnostic imaging, aiming to enhance diagnostic accuracy, optimize resource utilization, and improve patient comfort. While AI concepts have existed for decades, only recent improvements in computational power have enabled their widespread integration into clinical workflows. This article reviews key applications of AI in pediatric radiology—a field where the limited availability of high-quality annotated training data remains a major constraint.


AI technologies are being deployed across various stages of the imaging process: from optimizing examination requests and scheduling, through contactless biometric monitoring during acquisition, to advanced image reconstruction techniques that enable reduced radiation exposure and shorter scan times. In image interpretation, AI supports pathology detection, facilitates quantitative assessments (e.g., skeletal age estimation, anthropometric analysis), and aids in the standardization and clearer communication of findings to both clinicians and patients.

While AI cannot substitute the clinical expertise of trained radiologists, its complementary role is steadily expanding, offering substantial benefits across various aspects of imaging practice. Nonetheless, significant challenges remain—particularly in the domains of ethical governance, diagnostic accountability, and long-term economic sustainability.

Key words: artificial intelligence, pediatric radiology, X-ray, computed tomography, magnetic resonance imaging, contrast media

Korespondující autor:

prof. MUDr. Ing. Lukáš Lambert, Ph.D.
Klinika zobrazovacích metod FN Motol a 2. LF UK
V Úvalu 84
150 06 Praha 5
lukas.lambert@fnmotol.cz



Obr. 1: Schéma činností, kde lze v zobrazovacích metodách využít umělou inteligenci

ÚVOD

Umělá inteligence (AI) představuje koncept, který je známý již desítky let, nicméně v posledním období se dostává do popředí díky zlepšující se dostupnosti výpočetní síly pro složité komplexní operace. Hlavním omezením AI je, že umí jen to, co se naučí, a její kvalita závisí především na kvalitě, množství a spektru vstupních dat, která jsou v oblasti pediatrie hůře dostupná.⁽¹⁾

V tomto článku budou nastíněny hlavní směry, kam se AI v oblasti zobrazovacích metod v užším slova smyslu ubírá,


aby podpořila precizní diagnostiku, personalizovanou péči a efektivnější využití kapacity přístrojů (obráz. 1).^(2–4)

OBJEDNÁVÁNÍ A PLÁNOVÁNÍ VYŠETŘENÍ


Organizace objednávání pacientů je obtížným úkolem, který musí optimalizovat využití přístrojového času a lidského potenciálu při minimalizaci doby čekání na vyšetření. Toto hraje roli zejména u MR vyšetření. Z historických dat a aktuálních nemocničních dat lze systém naučit predikovat nároky na využití přístrojové kapacity, počítat s rizikem, že se pacient na vyšetření nedostaví, nebo sdružovat vyšetření, která vyžadují stejnou konfiguraci přístroje.⁽⁵⁾ Toto je však zatím ještě ve stadiu projektů a objednávání se děje zapisováním do objednávacích knih, tabulek nebo programů.

PLÁNOVÁNÍ ROZSAHU VYŠETŘENÍ

V klinickém provozu jsou k dispozici systémy, které jsou schopny samy rozpoznat anatomii lidského těla a naplánovat např. kolimaci a centraci paprsku při RTG hrudníku.⁽⁶⁾ Na CT umí rovněž detekovat anatomii a samostatně nastavit výšku vyšetřovacího stolu a rozsah plánovacího skenu, aby nedocházelo k přeskenování a navýšení radiační zátěže polohou pacienta mimo izocentrum.



Obr. 2: Srovnání obrazové kvality u přístroje Aquilion PRISM z dětské části nemocnice při standardní rekonstrukci (A, C, E) a s použitím deep-learning rekonstrukce (DLR), která potlačuje obrazový šum a zachovává ostrost obrazu (B, D, F). A, B – CT mozku s redukcí šumu a zvýrazněním kortiko-subkortikální diferenciace. C, D – CT kostí skalní u akutní mastoiditidy. E, F – CT jater.



Obr. 3: Srovnání obrazové kvality MR vyšetření bez použití (A, C) a při použití deep-learning reconstruction (DLR) (B, D). A, B – mozek – FLAIR. C, D – koleno – PD-FS.

BEZKONTAKTNÍ BIOMETRIE

Bezkontaktní biometrie se uplatňuje při hradlování vyšetření na podkladě dechu, kdy přístroj snímá bezkontaktním čidlem respirační pohyby a danou akvizici iniciuje v definované poloze hrudníku. Snímačem může být kamera nebo čidlo

ve vyšetřovacím stole s komplexním zpracováním získaného signálu, který ale není přímo měřenou veličinou (např. EKG nebo saturace).


REKONSTRUKCE OBRAZU

Velkým tématem CT zobrazování v posledních dvou dekáдах se stala otázka snižování radiační zátěže. Jednou z možností je vyšetřovat s menším napětím a proudem na rentgence a nekvalitní obraz dopočítat pomocí AI.⁽⁷⁾ AI rekonstrukci používáme ve FN Motol na dvou CT přístrojích, včetně toho, který je v dětské části nemocnice (obr. 2).


MR vyšetření jsou bez radiační zátěže, ale trvají dlouho. Přelomovou technologií, která se stává komerčně dostupnou teprve v posledních letech, je AI rekonstrukce.^(8–9) Umožňuje z výrazně podvzorkovaného prostoru dat (K-prostoru) rekonstruovat obraz, který je v řadě ohledů lepší než ten původní, vytvořený např. za dvojnásobný čas (obr. 3). Řada akvizic se tak dramaticky zrychluje. AI rekonstrukci na MR používáme ve FN Motol od letošního roku.

ZVÝŠENÍ PŘESNOSTI DETEKCE PATOLOGICKÝCH ZMĚN

Ani radiologové nejsou neomylní. Přesnost detekce patologických změn se odhaduje na 98 % v normálním provozu a je nižší v pohotovostním režimu. Detekční systémy založené na AI umožňují označit místa, která se jeví patologická nebo odlišná od normy. V dětské radiologii hovoříme především o skiografii skeletu a hrudníku.^(10–12) U skiografie hrudníku je nutné si uvědomit, že detekční systémy fungují až od určitého věku (uvedeno výrobcem – např. Gleamer od 15 let pro skiografii hrudníku a od 2 let pro skiografii kostí) a detekují pouze určitý počet patologií (např. pneumonie, pneumothorax, ložiskový stín, pleurální tekutina), ale jiné ne (městnání, plicní edém, skeletální deformity...), protože na ně



Obr 4: Pleurální tekutina oboustranně (A) a pravostranný pneumothorax (B) detekované pomocí AI



Obr 5: Falešně pozitivní nálezy na RTG snímku nohy (A), ruky (B), lokte (C)

nebyly natrénovány (obr. 4). U skiografie dětského skeletu narážíme na častou falešnou pozitivitu v místě epifyzárních růstových štěrbin a dále u nepřesných projekcí, kterým se u traumatických pacientů nevyhne z důvodu bolestivosti (obr. 5). Naopak je důležité konstatovat, že AI systémy zvládají i detekci diskretních fraktur dětského věku (obr. 6). Použití AI u radiologů zvyšuje záchyt fraktur o jednotky procent. Místa označená systémem nejsou nálezem, ale nápodobou.


KVANTIFIKACE NÁLEZŮ

Automatická kvantifikace měření zmenšuje interobservační variabilitu a snižuje náročnost interpretace snímků.⁽¹³⁾ V dětské radiologii je vzorovým příkladem hodnocení


kostního věku ze snímku ruky a zápěstí. Bone expert udává interobservační variabilitu 4,1 měsíce, Gleamer 5,8 měsíce v porovnání s experty (8,6 měsíce) dle metodiky Greulich and Pyle. Automatická kvantifikace kostního věku ve FN Motol je používána v komerčním režimu (obr. 7).

Antropometrie je další oblastí, kde může AI urychlit a standardizovat měření.⁽¹⁴⁾ V současné době testujeme řešení od Gleamer AI, které umožňuje měřit řadu parametrů, jako je Cobbův úhel, valgozitu a délku dolní končetiny, valgozitu haluxů, intermetatarzální úhel, inklinaci kosti patní, úhel nožní klenby, pelvimetrické hodnoty (inklinace, incidence, úhel stříšky acetabula, osifikace hřebene lopaty kosti kyčelní dle Rissera) a další (obr. 8).

Pro segmentaci objemu anatomických struktur a tkání z CT a MR vyšetření a detekci patologických nálezů byla vyvinuta řada nástrojů, které jsou dostupné jak komerčně, tak



Obr. 6: Označení fraktury a nitrokloubní tekutiny u supra-kondylické fraktury humeru (A), označení abrupce nehtové drsnatiny a zároveň falešně pozitivní nález v místě růstové štěrbin (B, C)




Obr. 7: Automatické hodnocení skeletálního věku ze skiagrafického snímku zápěstí a ruky pomocí aplikace BoneExpert

i ve formě volně šiřitelných balíčků, které ale postrádají certifikaci zdravotnického prostředku. U CT vyšetření uvedme klinické nástroje pro detekci plicních uzlů, mozkové ischemie a krvácení a v rámci výzkumu pak nástroje pro segmentaci jednotlivých orgánů, viscerálního a podkožního tuku a svalové tkáně. U MR vyšetření se uplatňuje kvantifikace především u MR mozku při segmentaci mozkových kompartmentů a struktur s volumetrií a kvantifikací tkáňových charakteristik v rámci výzkumu.⁽¹⁵⁾

KOMUNIKACE A STANDARDIZACE NÁLEZU

Popis je nedílnou součástí radiologického výkonu. Cílem popisu je zřetelně komunikovat klinicky významné nálezy v kontextu klinických informací o pacientovi. Velké jazykové modely (large language models, LLM) umožňují zpracování vstupních dat na základě pravděpodobnosti pokračování textového řetězce.⁽¹⁶⁾ Dostává se nám tak do ruky nástroj, který má potenciál extrahovat z nálezů zásadní informace a v koncizní podobě je komunikovat klinikům



Obr. 8: Automatické měření délky dolních končetin (A), Cobbova úhlu (B), sklonu pánve (C) a dalších parametrů z modality EOS



Obr. 9: Vysvětlení nálezů na CT dětskému pacientovi ve věku 3, 5 a 11 let, jak jej navrhuje ChatGPT-4o.

a ve zjednodušené podobě i pacientům včetně výkladu toho, co pro daného pacienta představují (obráz. 9).

REDUKCE KONTRASTNÍ LÁTKY

Byť kontrastní látky pro CT a MR mají vynikající bezpečnostní profil, minimalizace podávaného objemu je žádoucí jak z pohledu pacienta, zdravotnického zařízení, tak i zátěže životního prostředí. V současné době jsou vyvíjeny algoritmy pro CT a MR, které umožňují podání zlomkového množství kontrastní látky a dopočítání obrazu tak, jako by byl objem standardní.⁽¹⁷⁾ Pro MR by mohly být pro komerční využití již v následujícím roce.

ETICKÉ OTÁZKY

S rostoucím využitím AI se objevují otázky ohledně odpovědnosti za falešně pozitivní a negativní nálezy, které zůstávají čistě na bedrech radiologa, byť některé systémy vykazují statisticky vyšší přesnost pro vybrané nálezy. Práce radiologa je velmi komplexní a kromě provedení a hodnocení vyšetření zahrnuje i syntézu informací z předchozích vyšetření, klinických a paraklinických informací, návrh dalšího postupu a komunikaci v rámci interdisciplinárních týmů.

NÁKLADOVÁ EFEKTIVITA

Ekonomika umělé inteligence v zobrazovacích metodách ve zdravotnictví spojuje náklady, jejich návratnost z pohledu zdravotnického zařízení, plátce, pacienta a celkově společnosti.⁽¹⁸⁾ Do nákladů na vývoj AI systémů je nutné započítat i náklady na certifikaci zdravotnického prostředku. Problémem je i pořizování AI, které je často nutné řešit formou subscripcie, nikoliv přímého nákupu s jednorázovým nákladem.

Nákladovou efektivitu AI lze kalkulovat z následujících faktorů. Urychlení vyšetření a zlepšení dostupnosti přístroje vede k možnosti provést více vyšetření a hrazené péče (například u MR). Urychlení diagnostiky vede k tomu, že radiolog zastane více práce za určený čas. Zvýšení senzitivity vyšetření pomáhá k včasné diagnostice a menšímu počtu nároků ze strany pacientů při nepopsání určité patologie. Menší množství kontrastní látky přímo vede ke snížení materiálových nákladů na vyšetření.

Výsledky pro blaho pacienta lze spatřovat v omezení doby strávené v čekárně, kratším pobytu v tunelu MR, menším zatížením organismu kontrastní látkou, srozumitelnějším výstupu vyšetření.

ZÁVĚR

Umělá inteligence v zobrazovacích metodách představuje významný technologický posun, a to i u pediatrických

pacientů. Umožňuje rychlejší, přesnější diagnostiku s menší zátěží pro pacienta a má potenciál celkově přispět ke zlepšení péče o dětské pacienty. Přestože AI není náhradou za zkušeného radiologa, její role jako pomocného nástroje

s nápovědou je nezpochybnitelná a bude nadále růst. Otázkou zůstává nákladová efektivita, která by měla být ospravedlnitelná buď přímou návratností investice, nebo zlepšením péče a komfortu pacienta. |

LITERATURA

1. Hua SB, Heller N, He P, et al. Lack of children in public medical imaging data points to growing age bias in biomedical AI. medRxiv 2025.06.06.2532891.
2. Dillman JR, Somasundaram E, Brady SL, et al. Current and emerging artificial intelligence applications for pediatric abdominal imaging. *Pediatr Radiol* 2022; 52(11): 2139–2148.
3. Otjen JP, Moore MM, Romberg EK, et al. The current and future roles of artificial intelligence in pediatric radiology. *Pediatr Radiol* 2022; 52(11): 2065–2073.
4. Hull NC, Frush DP, Chu WC, et al. Pediatric Imaging 2040. *Radiology* 2025; 315(2): e250378.
5. Valenzuela-Núñez C, Latorre-Núñez G, Troncoso-Espinosa F. Smart medical appointment scheduling: Optimization, machine learning, and overbooking to enhance resource utilization. *IEEE Access* 2024; 12: 7551–7562.
6. Rasche A, Brader P, Borggreffe J, et al. Impact of intelligent virtual and AI-based automated collimation functionalities on the efficiency of radiographic acquisitions. *Radiography*. 2024;30(4):1073–9.
7. Zhang F, Peng L, Zhang G, et al. Artificial intelligence iterative reconstruction for dose reduction in pediatric chest CT: a clinical assessment via below 3 years patients with congenital heart disease. *J Thorac Imag* 2025; 40(4): e0827.
8. Choi JW, Cho YJ, Lee SB, et al. Accelerated brain magnetic resonance imaging with deep learning reconstruction: a comparative study on image quality in pediatric neuroimaging. *Pediatr Radiol* 2025; 1–2. doi: 10.1007/s00247-025-06314-2
9. Pocepcova V, Zellner M, Callaghan F, et al. Deep learning-based denoising image reconstruction of body magnetic resonance imaging in children. *Pediatr Radiol* 2025; 55(6): 1235–1244.
10. Ashworth E, Allan E, Pauling C, et al. Artificial intelligence (AI) in radiological paediatric fracture assessment: An updated systematic review. *Eur Radiol* 2025. doi: 10.1007/s00330-025-11449-9
11. Guermazi A, Tannoury C, Kompel AJ, et al. Improving radiographic fracture recognition performance and efficiency using artificial intelligence. *Radiology* 2022; 302(3): 627–636.
12. Monti CB, Bianchi LM, Rizzetto F, et al. Diagnostic performance of an artificial intelligence model for the detection of pneumothorax at chest X-ray. *Clin Imaging* 2025; 117: 110355.
13. Nguyen T, Hermann AL, Ventre J, et al. High performance for bone age estimation with an artificial intelligence solution. *Diagn Interv Imaging* 2023; 104(7–8): 330–336.
14. Lassalle L, Regnard NE, Ventre J, et al. Automated weight-bearing foot measurements using an artificial intelligence-based software. *Skeletal Radiol* 2025; 54(2): 229–41.
15. Phan TV, Sima DM, Beelen C. et al. Evaluation of methods for volumetric analysis of pediatric brain data: The Childmetrix pipeline versus adult-based approaches. *Neuroimage Clin* 2018; 19: 734–744.
16. Bhayana R. Chatbots and large language models in radiology: a practical primer for clinical and research applications. *Radiology* 2024; 310(1): e232756.
17. Ahmadzade M, Morón FE, Shastri R, et al. AI-assisted post contrast brain MRI: eighty percent reduction in contrast dose. *Academic Radiology* 2024. doi: 10.1016/j.acra.2024.10.026
18. Khanna NN, Maindarkar MA, Viswanathan V, et al. Economics of artificial intelligence in healthcare: diagnosis vs. treatment. *Healthcare (Basel)* 2022; 10(12): 2493.