

Nové trendy v telemedicině a AI pro urology

MUDr. Martin Malý¹, MUDr. Alžběta Kantorová¹, doc. MUDr. David Zogala, Ph.D.²,
doc. MUDr. Otakar Čapoun, Ph.D., FEBU¹, prof. MUDr. Viktor Soukup, Ph.D., FEBU, MHA¹

¹Urologická klinika VFN a 1. LF UK, Praha

²Ústav nukleární medicíny VFN a 1. LF UK, Praha

Tento článek zpracovává téma nových trendů a technologií v urologii, a to konkrétně v oblasti telemedicíny a umělé inteligence. Nejprve stručně pojednává o přínosech telemedicíny a jak mění pohled na vztah mezi lékařem a pacientem. Podrobněji se pak text věnuje především umělé inteligenci, jež se v současnosti dostává do popředí zájmu laické i odborné veřejnosti. Její potenciál v urologii je testován v mnoha studiích, především se zaměřením na uroonkologii, v menší míře pak také v oblasti benigních urologických onemocnění. Článek se snaží identifikovat nejvýznamnější pokroky v této rychle se rozvíjející oblasti, a zároveň předkládá současné limity jejího zapojení do klinické praxe.

Klíčová slova: telemedicina, umělá inteligence, strojové učení, hluboké učení, robotická chirurgie, uroonkologie.

Emerging trends in telemedicine and artificial intelligence in urology

This article explores the emerging trends and technologies in urology, focusing on telemedicine and artificial intelligence. It provides a brief overview of the benefits of telemedicine and its impact on the patient-physician interactions. The article subsequently explores in detail the use of artificial intelligence, which is currently gaining considerable interest from both general public and medical professionals. Its potential in urology has been tested in a number of clinical studies, particularly in the field of uro-oncology and, to a lesser extent, in benign urological diseases. The aim of this article is to identify the key advances in this rapidly evolving field, while also highlighting the current limitations of its implementation into clinical practice.

Key words: telemedicine, artificial intelligence, machine learning, deep learning, robotic surgery, uro-oncology.

Úvod

V období pandemie covidu-19 se výrazněji do popředí zájmu lékařů dostává pojem telemedicina a s rozvojem online jednoduše dostupných velkých jazykových modelů (large language model – LLM, např. ChatGPT – generativní předtrénovaný transformátor, dostupný na tomto odkazu: <https://chatgpt.com>) také termín umělá inteligence (Artificial Intelligence – AI), i když jejich počátky sahají do minulého století. Obě témata se týkají i urologie, která jednoznačně patří mezi technologicky orientované medicínské obory. Cílem článku je přiblížit základy

telemedicíny a AI a jejich potenciální využití v urologii.

Telemedicina

Úvod

Dle Světové zdravotnické organizace (WHO) je telemedicina způsob poskytování individualizované zdravotní péče na dálku za využití moderních technologií, kde vzdálenost mezi poskytovatelem a příjemcem péče je rozhodujícím činitelem (1). Telemedicina v sobě může zahrnovat různé komunikační platformy, jako například e-mail nebo tele-

DECLARATIONS:

Declaration of originality:

The manuscript is original and has not been published or submitted elsewhere.

Ethics approval and consent to participate:

The authors attest that their study is in compliance with human studies committees and animal welfare regulations of the authors' institutions as well as with the Food and Drug Administration guidelines, including patient consent where appropriate. The authors also declare that their paper is in accordance with the World Medical Association Declaration of Helsinki on Ethical Principles for Medical Research Involving Human Subjects adopted by the 18th WMA General Assembly in Helsinki, Finland, in June 1964, with subsequent amendments, as well as with the ICMJE Recommendations for the Conduct, Reporting, Editing, and Publication of Scholarly Work in Medical Journals, updated in December 2018.

Conflict of interest and financial disclosures:

None.

Consent for publication:

None.

Author's contributions:

None.

Cit. zkr: Urol. praxi. 2025;26(2):79-86
<https://doi.org/10.36290/uro.2025.041>
Článek přijat redakcí: 25. 2. 2025
Článek přijat k tisku: 1. 3. 2025

MUDr. Martin Malý
martin.maly@vfn.cz

fon, také způsoby komunikace cestou zasílání zpráv, volání, videohovory nebo streamování videa, dále ukládání dat, zobrazovací metody, videokonference a webináře, telemonitoring a telechirurgii (2, 3). Implementace těchto technologií však vyžaduje řešení problémů souvisejících s ochranou osobních údajů, úhradami a dalšími organizačními aspekty (4). Význam telemedicíny spočívá v redukci nadbytečných návštěv v nemocnici, a s tím spojených peněžních nákladů na provoz, v umožnění péče v odlehlých oblastech s omezenou dostupností specializované péče a ve snížení dopadu zdravotnictví na životní prostředí (3, 5). Obrázek 1 shrnuje i další výhody telemedicíny. Na důležitosti telemedicíny nabyla v období virové pandemie covidu-19 a právě tehdy také došlo k výraznému pokroku jejího zařazení ve zdravotnictví obecně (6). Klasickým příkladem telemedicíny využívaným v České republice je elektronický recept anebo internetový portál s možností online konzultací ulekare.cz (7, 8).


Vývoj telemedicíny

Počátky telemedicíny lze datovat do roku 1906, kdy vynálezce Willem Einthoven přenesl EKG signál pomocí telefonních kabelů na vzdálenost více než 1,5 kilometru (9). Dalšími významnými milníky ve vývoji telemedicíny byla první videokonzultace mezi psychiatrickou klinikou Nebraska Psychiatric Institute a Norfolk State Hospital v roce 1959, dále využití satelitních technologií v 70. letech 20. století, které propojily kliniku na Aljašce se vzdáleným centrem v Americe, v 90. letech 20. století došlo k zásadnímu rozvoji díky internetu a digitalizaci zdravotních záznamů, následovaly chytré telefony a mobilní aplikace (10, 11, 12). V neposlední řadě pokroky v telemedicině urychlila pandemie covidu-19, kdy došlo k nárůstu telemedicinských konzultací o stovky procent (13).

Telemedicína v urologii a telechirurgie

Telemedicína v urologii je úspěšně využívána například u pacientů s karcinomem prostaty (diagnostika a sledování po radikální terapii), hematurii, močovou inkontinencí či pánevním prolapsem (diagnostika, rehabilitace a sledování po operacích), u nekomplikované litiázy a močových infekcí (diagnostika

Obr. 1. Výhody telemedicíny – převzato z Symeonidis et al., 2023 (6)



a sledování). Mnoho dalších urologických onemocnění má potenciál být řešen „na dálku“, avšak zatím chybí studie, prokazující výhodu tohoto přístupu oproti fyzickým návštěvám pacienta u lékaře (5).

S vývojem miniinvazivní chirurgie, hlavně robotických systémů, došlo postupně k fyzickému oddálení operátora od pacienta. Právě robotická chirurgie společně s rychlým vývojem internetu, jeho zrychlením a stále se rozšiřujícím celosvětovým dosahem, stály u vzniku telechirurgie. Telechirurgie umožňuje chirurgovi interagovat s pacientem a provést kompletní výkon prostřednictvím telemanipulátoru (řídící jednotky) a robota umístěného u lůžka pacienta (výkonné jednotky) na obrovské vzdálenosti (14). Zcela první zdokumentovaná transatlantická teleoperace, roboticky asistovaná laparoskopická cholecystektomie, proběhla na pacientovi ve Štrasburku operátorem v New Yorku v roce 2001, avšak za pomoci fyzického dvoubodového spoje za cenu více jak 1 milion amerických dolarů (15). V urologii může být příkladem vůbec první takováto operace prezentovaná na konferenci Evropské urologické společnosti (EAU), ERUS24 (Konference Sekce robotické urologie EAU 2024), roboticky asistovaná resekce ledviny provedená prof. Bredou v Bordeaux (Francie) na pacientovi vzdáleném 8 264 kilometrů v Pekingu (Čína) za pomoci speciálního kabelu s latencí 132 ms (16). Tato nová disciplína má svá úskalí


i výhody. Mezi výhody patří možnost zajistit kvalitní chirurgické vzdělávání (telementoring a teleproktoring) a možnost poskytovat pokročilou péči v odlehlých oblastech s nedostatečnou zdravotní péčí či v případě přírodních či jiných katastrof (17). Na druhou stranu nedostatek osobního kontaktu mezi pacientem a chirurgem může být problematický v případech zanedbání lékařské péče. Telechirurgie se může odehrávat v rámci více států, a tak mohou vznikat komplikované soudní spory. Další otázkou je, kdo by byl zodpovědný za chyby způsobené zpožděním přenosu či selháním zařízení. Budeme-li chtít telechirurgii implementovat do běžné praxe, je zásadní zajištění dostatečně rychlého a spolehlivého kabelového spojení či bezdrátové datové sítě (15). Na závěr je důležité zmínit, že se stále jedná o experimentální a drahou metodu zatím využívající především optická vlákna a na její zařazení do doporučených postupů si budeme muset ještě počkat (18).

Umělá inteligence

Úvod

Definovat termín umělá inteligence není jednoduché, ale jednou z nejčastěji užívaných definic je tato: AI označuje výpočetní schopnost stroje napodobovat a vykonávat lidské kognitivní úkoly (19). Organizace pro hospodářskou spolupráci a rozvoj (OECD)

Obr. 2. AI spadá do oblasti datové vědy a zahrnuje klasické programování a ML. ML obsahuje množství modelů a metod, včetně DL a ANN – převzato z Choi et al., 2020 (27)



definuje AI takto: Systém AI je strojový systém, který dokáže pro danou sadu člověkem stanovených cílů vytvářet předpovědi, doporučení nebo rozhodnutí ovlivňující reálné či virtuální prostředí. Různé systémy AI se liší úrovní autonomie a adaptability (20). AI je velmi široký pojem, který zahrnuje různé přístupy, jak ukazuje obrázek 2. Pro uvedení tématu do širšího kontextu, AI patří do oboru tzv. data science, česky datová věda, což je interdisciplinární obor zabývající se velkými objemy dat z různých zdrojů za účelem extrakce relevantních informací pro podporu rozhodování s tím, že jedním z hlavních cílů datové vědy je predikce výsledků s ohledem na znalosti v příslušné doméně zájmu (21). V běžné praxi se občas termíny související s AI používají nepřesně a zaměňují se mezi sebou, proto je vhodné je rozlišovat. Pro medicínu je zejména důležité tzv. strojové učení (Machine Learning – ML), jež se může vyskytovat v několika formách. Jednou z nich je hluboké učení (Deep Learning – DL), které se v současnosti nejčastěji realizuje pomocí umělých neuronových sítí (Artificial Neural Networks – ANN) (19).


Princip, jakým AI (v nejčastěji používaném režimu) pracuje, není jednoduché vysvětlit. Ve zkratce však jde o programovací přístup, kdy systém nemá předem zabudované pevné rozhodovací pravidlo typu „pokud nastane A, udělej B“. Místo toho se potřebná pravidla učí z dat – tento proces učení probíhá prostřednictvím tzv. tréninku neuronové sítě, která se skládá z velkého počtu menších jednotek (tzv. „neuronů“). Každý takový „neuron“ sám o sobě na nejzákladnější úrovni reaguje převážně binárně (tj. ano/ne). Síla umělých neuronových sítí tkví především

v obrovském počtu neuronů, v jejich vzájemném propojení a ve struktuře jednotlivých vrstev, což umožňuje složitější zpracování dat. Aby síť správně fungovala, je nutné ji nejprve vytrénovat na velkém množství vhodných dat. Například u zpracování obrazů se jí předkládají snímky spolu se správným řešením (tzv. supervize člověkem), které jí ukazují, co má rozpoznat. Neuronová síť zpočátku nastavuje váhy a propojení mezi neurony téměř náhodně. Po každém vyhodnocení síť dostane zpětnou vazbu, jak dobře objekt na snímku identifikovala. Na základě této informace pak postupně optimalizuje zapojení i nastavení neuronů a vrstev tak, aby se co nejvíce blížila správné odpovědi. Tyto tréninkové procesy mohou být velmi časově i výpočetně náročné, což je důvod, proč se pro jejich realizaci často využívají specializované výkonné počítače nebo tzv. cloudová řešení (19, 22). AI modely můžeme dělit na diskriminativní (přiřazují označení k datům) či generativní (vytváří nová data, např. podle slovního zadání vytvoří jiný text, obraz či video). V medicíně se AI uplatňuje nejčastěji při zpracování přirozeného jazyka (Natural Language Processing – NLP) a vizuálních dat (Computer Vision – CV) jako radiologické, patologické či endoskopické snímky. Možné je systémy trénovat na analýzu a interpretaci prakticky čehokoliv, co lze nějakým způsobem počítači elektronicky zviditelnit, digitalizovat (např. zvukový signál – fonendoskop, elektrický signál – EKG) (19).

V druhé polovině 20. století proniká AI v rámci výzkumu do nejrůznějších oborů

medicíny. V medicíně má AI velmi široký potenciál. Mohli bychom ji využívat v rámci personalizované diagnostiky a terapie, analýzy radiologických a patologických snímků (radiomika a patomika), genomiky, monitorace pacientů, podpory klinického rozhodování, optimalizace pracovního provozu a efektivity, vzdělávání a v neposlední řadě ve vědeckém výzkumu, například při vývoji léků či při analýze velkého množství dat (23, 24). Zapojení AI do medicínské praxe je nevyhnutelné, otázkou zůstává jeho míra. Vývoj je velmi rychlý, investiční podpora v korporátním, akademickém i státním sektoru výrazná. Zatím převládá názor, že AI technologie budou lékaři sloužit jako asistent s cílem zrychlení a zefektivnění procesu práce a minimalizovat rutinní činnosti. Samozřejmě má i AI ve zdravotnictví své limity, především etické, právní a v rozložení odpovědnosti za použití AI nástrojů, jak ilustruje obrázek 3 (25). Fungování AI systému v současné době není předvídatelné a vysvětlitelné, proto se objevuje volání po tzv. „explainable AI“. Zapomínat bychom neměli ani na kvalifikační proces lékařů. Dovednosti vznikají opakováním často velmi jednotvárných činností. U odborníka tak vzniká rutina, jistota a schopnost fungovat rychleji, efektivněji a vypořádat se pak i se složitějšími případy. Delegací rutinních činností na automatické systémy se tento tréninkový podnět oslabí a zároveň se stáváme na přístrojové technice závislími. Zde však není zásadní rozdíl oproti dalším odvětvím lidské činnosti, ve kterých se používají pokročilé technologie (26).

Obr. 3. Současné limity AI v medicíně – převzato z Liu et al., 2023 (28)



V rámci urologie existuje mnoho studií testujících využití AI jak u benigních, tak u maligních onemocnění, a také v pediatrické urologii, která však není předmětem tohoto článku. Množství publikací na téma AI v urologii v posledních letech stoupá, jak je znázorněno na grafu 1, který zobrazuje počet publikací dle roku vydání v databázi PubMed při zadání termínu „AI in urology“. V popředí zájmu v současné době stojí uroonkologie, nejvíce pak nádory prostaty, poté močového měchýře a ledvin. Z benigních urologických onemocnění je nejčastěji studované využití v oblasti urolitiázy, méně pak u benigní hyperplazie prostaty, inkontinence či transplantace ledvin (19, 22).

Uroonkologie


Prostata

Lokalizovaný karcinom prostaty

AI má potenciál ve zlepšení diagnostiky (radiodiagnostika a patologie), iniciační stratifikace rizika a predikce odpovědi na léčbu u lokalizovaného karcinomu prostaty (KP).

V rámci radiodiagnostiky se studuje potenciální využití DL/CV u magnetické rezonance (MR) prostaty jako samostatné diagnostické metody bez biopsie prostaty (BP) za pomoci autosegmentace a detekce ložisek KP, zlepšení identifikace pacientů k BP a snížení variability čtení histologických preparátů různými lékaři či hodnocení Gleasonova skóre (GS) přímo ze snímků (29). Zajímavá je studie Cai et al., kde testovali DL model proti radiologům bez zjištění rozdílu v detekci klinicky signifikantního KP (30). Mezinárodní komparativní studie PI-CAI z roku 2024 porovnávala DL model proti 62 radiologům v hodnocení MR prostaty pomocí PI-RADS 2.1 v detekci klinicky signifikantního KP. Zjistili vyšší přesnost DL modelu oproti radiologům, s plochou pod křivkou (area under curve – AUC) 0,91 pro model, respektive 0,86 pro radiology (31). Několik modelů je již schváleno Americkým úřadem pro kontrolu potravin a léčiv (Food and Drug Administration – FDA) jako například Quantib®, který splňuje i požadavky evropského nařízení o zdravotnických prostředcích 2017/745. Tento produkt má především za cíl pomáhat méně zkušeným radiologům (32).

Graf 1. Počet publikací podle roku na téma AI v urologii v databázi PubMed



Patologové testují využití DL modelů s pomocí virtuálních preparátů (whole slide image – WSI) v detekci KP, ke stanovení GS a v identifikaci kribriiformních struktur. Modely na přítomnost či nepřítomnost KP v bioptických vzorcích obecně dosahují velké přesnosti s AUC nad 0,90 (29). Prvním nástrojem povoleným FDA v patologii KP se stal Paige Prostate. Jedná se o DL model s použitím CNN, který má za úkol asistovat patologovi v detekci, gradingu a kvantifikaci KP v bioptických vzorcích. Tento nástroj zkracuje dobu čtení vzorků, snižuje potřebu použití imunohistochemie a vyhledání druhého názoru a zároveň zachovává stejnou přesnost diagnostiky v porovnání se samotnými patologi (33).

Pro další péči o pacienta s nově diagnostikovaným lokalizovaným KP je důležitá stratifikace rizika. U nás využívané klasifikace (např. dle EAU) jsou převážně založené na stratifikaci rizika dle d'Amica/NCCN (National Comprehensive Cancer Network) z 90. let 20. století kombinující GS, hladinu prostatického specifického antigenu (PSA) a per rektum vyšetření (DRE). Tyto klasifikace opakovaně prokázaly nedostatečnou prognostickou přesnost (29, 34, 35). V roce 2024 zahrnul NCCN do svých doporučení využití nástroje Artera AI Prostate Test, což je multimodální AI model s učením s vlastním dohledem kombinující klinická data a histopatologické snímky z biopsie prostaty, k rozdělení pacientů s nově diagnostikovaným KP dle rizika 10letého vývoje vzdálených metastáz. Dle studie Esteva et al. model v porovnání s rizikovými skupinami dle NCCN prokázal vyšší AUC o 9,2 až 14,2 % v predikci vzdálených

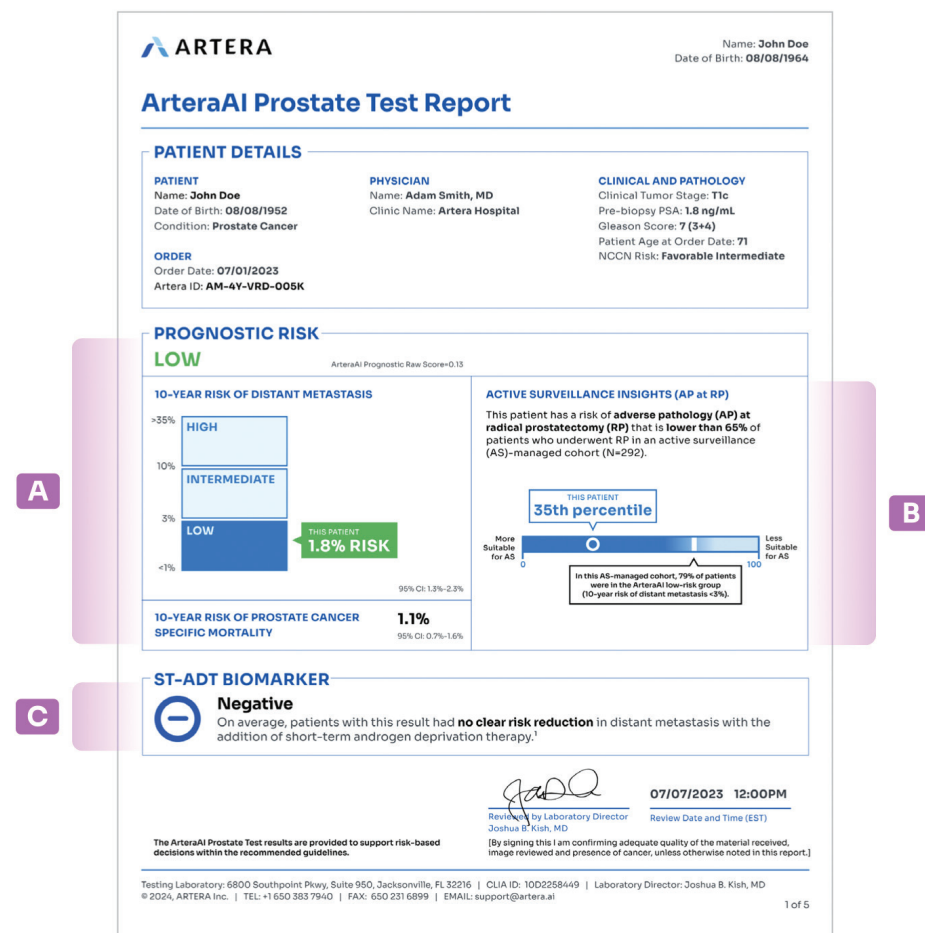
metastáz v 5 a 10 letech, biochemickém selhání v 5 a 10 letech, 10letém přežití specifickým pro KP a celkovém přežití (36). Mimo to Artera AI souběžně identifikuje pacienty, kteří by pravděpodobně benefitovali z krátkodobé androgen deprivace terapie v kombinaci s radioterapií u středně rizikového KP (37). Příklad výstupu Artera AI je uvedený na obrázku 4.

Díky velkému množství dat (automatické metriky výkonnosti), které sbírá světově nepoužívanější robotický systém Da Vinci v celém průběhu roboticky asistované radikální prostatektomie, bylo možné vytvořit ML algoritmus k hodnocení a predikci operační dovednosti na základě pooperační délky hospitalizace a DL algoritmus k predikci pooperační kontinence, obojí s cílem lepší objektivizace expertízy chirurgů v porovnání s klasickými statistickými metodami (38, 39).

Biochemická rekurence

V rámci BCR byl testován ML model k rozdělení pacientů s nízkou a vysoce rizikovou BCR dle pravděpodobnosti vyvinutí metastatického postižení do pěti let, který byl však vytvořen na základě retrospektivních dat z klasického stagingu pomocí CT břicha a malé pánve a scintigrafie kostí. Chybí však významné studie za použití moderních stagingových metod, jako je například PSMA PET/CT (29, 40). K vývoji nových DL modelů na predikci doby do BCR s pomocí virtuálních patologických snímků vybízí i tzv. LEOPARD (LEarning biO-chemical Prostate cAncer Recurrence from histopathology sliDes) Challenge. V rámci této veřejné soutěže je k dispozici 508 kvalitních WSI po radikální prostatektomii k natrénování modelu a další snímky k validaci (41).

Obr. 4. Příklad výstupu Artera AI při stratifikaci pacienta s nově diagnostikovaným KP do rizikových skupin; A (prognostické riziko), B (porovnání s pacienty ve stejné rizikové skupin), C (doporučení stran ADT) – převzato z: <https://artera.ai/wp-content/uploads/FINAL-General-Bifold-Brochure-Digital-V3.pdf>



Metastatický či pokročilý karcinom prostaty

V rámci metastatického či pokročilého KP je AI obecně testována méně, některé snahy můžeme najít v oblasti diagnostiky metastáz, stanovení prognózy pacientů, v selekci správné léčby a v identifikaci a predikci kastrací rezistence. Využití CV v diagnostice metastáz na PSMA PET/CT je zatím relativně limitované vzhledem k malému množství kvalitních dat, variabilitě PSMA exprese a nejasným anatomickým hranicím lézí (29). Dynamický vývoj však lze předpokládat. Terapie metastatického KP je velmi rychle se vyvíjející oblast s novými druhy léčby a kombinacemi preparátů. Složitě a mnohdy zdoluhavé je získávání důkazů pro jednotlivé terapeutické možnosti a jejich zavedení do doporučených postupů urologickými společnostmi. S tímto problémem u KP ale i u jiných nádorů se vypořádávají modely AI automaticky spravující tzv. žijící systematické přehledy (living systematic reviews – LSRs) (42, 43).

Močový měchýř Diagnostika karcinomu močového měchýře

V průběhu posledních desetiletí došlo k vývoji různých způsobů zlepšení detekce tumorů při cystoskopickém vyšetření, jako například fotodynamická metoda (photo-dynamic diagnosis – PDD) s aplikací 5-aminolevulinové kyseliny intravezikálně před vyšetřením či použití úzkopásmového zobrazování (narrow band imaging – NBI). Tyto metody mají svůj význam hlavně ve zvýšené detekci *carcinoma in situ* (CIS) či identifikaci drobných recidiv, ale cystoskopie v bílém světle stále představuje základní metodu, při které dochází k přehlédnutí tumoru až ve 20 % případů (44, 45, 46). Proto se ke zvýšení diagnostické přesnosti testují různé automatizované modely založené na CNN. Příkladem může být CystoNet, pomáhající v identifikaci potenciálních tumorů přímo v průběhu cystoskopie, který byl prospektivně validován na 54 pacientech s výsled-

nou senzitivitou 91 % a specificitou 99 % (47). Konkrétní vizualizace pomocí modelu CystoNet si lze prohlédnout na obrázku 5. Význam takto AI augmentované cystoskopie v klinické praxi je však zatím velmi omezený.


Predikce u karcinomu močového měchýře

Další studie testují hodnocení cytologie či histologického gradingu se snahou vyšetření více objektivizovat a snížit variabilitu mezi jednotlivými lékaři, dále vyhodnocování invaze do svaloviny pomocí CV na MR se zaměřením na močový měchýř (45). U sval neinvadujících nádorů močového měchýře je důležité pacienty stratifikovat do rizikových skupin dle rizika recurence a progresu onemocnění. Doporučovaná jsou rozdělení do rizikových skupin dle EAU či Španělského urologického klubu pro onkologickou léčbu (CUETO) či nomogramu Evropské organizace pro výzkum a léčbu rakoviny (EORCT). Populace, na základě, kterých tyto nomogramy vznikly, jsou rozdílné ve vztahu k adjuvantní terapii. Ve srovnání přesnosti predikce recurence, progresu a času přežití byl z těchto tří metod nomogram EORCT nejlepší, ale v kontextu rozhodování o invazivní léčbě pacienta stále relativně nepřesný (48). Na základě těchto dat Jobczyk et al. v roce 2021 rekalibrovali EORCT a CUETO nomogramy pomocí DL a jejich model dosáhl při porovnání predikce přežití bez progresu (progression-free survival – PFS) větší shody s reálnými výsledky (c-index 0,88) (49). Tento nomogram je volně přístupný na internetu na tomto odkazu: <https://biostat.umed.pl/deepNMIBC/>. Mimo jiné je dalším potenciálním využitím AI odhad odpovědi na neoadjuvantní chemoterapii před radikální cystektomií k identifikaci z ní benefitujících pacientů (45).

Ledviny

V oblasti tumorů ledvin se výzkum umělé inteligence zabývá především zobrazovacími metodami v rozeznávání maligních od benigních lézí, rozlišení subtypů renálních karcinomů a predikci gradingu. Dále je snaha zpřesnit a objektivizovat staging a grading hodnocení patologických preparátů. Mezi další oblasti patří predikce recurence a přežití na základě histologie, zobrazovacích metod, zdravotnických záznamů nebo genetiky a také zjednodušení odhadu perioperačních výsledků (48).

Obr. 5. Reprezentativní detekce karcinomu močového měchýře s využitím CystoNetu; zelené kontury představují manuální anotaci tumoru, modré stínování označuje algoritmem řízenou automatickou segmentaci tumoru a červené rámečky indikují výstrahy generované CystoNetem – převzato z Shkolyar et al., 2019 (47)



Diagnostika tumorů ledvin

Zásadní pro rozhodování o radikální léčbě či sledování je znalost, zda je léze benigní či maligní a vzhledem k jejich rozdílné rychlosti růstu i znalost konkrétního histologického subtypu. Pacienti s asymptomatickými malými renálními lézemi (small renal mass = SRM) mnohdy podstupují radikální výkon ve výsledku bez jasného onkologického benefitu (51). Dle systematického přehledu Bhandari et al. z roku 2020 byly v osmi studiích za použití AI a CT snímků provedeny výzkumy s cílem rozlišit světlobuněčný renální karcinom (ccRCC), angiomyolipom s nízkým obsahem tuku, papilární RCC, chromofobní RCC a renální onkocytom s AUC v rozmezí od 0,82 do 0,96 (52). Radiomika využívající CT nálezy spolu s různými AI modely se zdá být velmi slibná především v binárním rozhodování, a to například v odlišení maligních a benigních lézí. Většina studií se soustředila na rozlišení mezi ccRCC a angiomyolipomy s nízkým zastoupením tuku s AUC mezi 0,90 a 0,96 (50). Další studie, analyzující textury z kontrastního CT založená na strojovém učení, zkoumala přesnost odlišení angiomyolipomů s nízkým zastoupením tuku a onkocytomů od všech

ostatních renálních karcinomů s výslednou výkonností AUC 0,91 (53).

Predikce u tumorů ledvin

Z urologického hlediska je zajímavé využití AI algoritmů ve zkrácení a automatizaci jinak náročných a zdoluhavých procesů, jako je výpočet nefrometrických skórovacích systémů, například R.E.N.A.L. skóre, jejichž cílem je odhadnout míru komplexity tumoru a komplikací nefron šetřících operací ledviny na základě anatomických charakteristik léze na CT či MR vyšetření (54, 55). Studie Abdallah et al. z roku 2023 retrospektivně testovala AI model určující R.E.N.A.L. skóre na CT snímcích pomocí mnohorozměrné logistické regrese a v porovnání s experty a jinými podobnými modely byl AI model přesnější v identifikaci malignity, vysokého gradingu, přítomnosti nádorové nekrózy a v predikci bezpečnosti parciální nefrektomie (56).

Varlata, penis a nádory horních močových cest

Aplikace AI v oblasti testikulárních malignit jsou zatím velmi omezené, především kvůli malému množství dat (57). Baessler

et al., v roce 2020 využili radiomiku CT založenou na ML k určení, zda lymfatické uzliny odstraněné u pacientů s metastatickým nebo pokročilým neseminomovým germinálním tumorem varlat byly maligní, nebo benigní. Model dosáhl přesnosti klasifikace AUC 0,81 se senzitivitou 88 % a specificitou 72 % (58). Mezi další výzkumné oblasti patří rozlišení maligních a benigních nálezů na MRI pomocí různých metod DL. Překvapivě zatím nejsou studie zabývající se kombinací ultrasonografie (USG), primární zobrazovací metody u tumorů varlat a AI. Porovnatelná pozice využití USG je například u tumorů štítné žlázy, kde již vznikly některé modely CNN s DL o vysoké přesnosti rozlišení maligní a benigní léze (57, 59).

Z hlediska prognózy je pro pacienty s karcinomem penisu zásadní včasné stanovení diagnózy, avšak mnoho mužů návštěvu urologů, z důvodu sociálního stigma a nedostatečného povědomí o diagnóze, odkládá. Existuje studie o použití CNN nástroje v detekci karcinomu penisu z fotografií, který dokázal odlišit spinocelulární karcinom od benigní léze s přesností AUC 0,94 (60).

Velmi málo prací s AI nalezneme u nádorů horních močových cest (UTUC), příkladem může být nadějně čtení digitalizovaných močových cytologií podpořené ML (zvyšující senzitivitu) v predikci rekurence po radikální nefroureterektomii (61).

Benigní urologická onemocnění

Litiáza

Z benigních urologických onemocnění se testuje využití AI nejvíce v oblasti urolitiázy. Tady se zaměřuje na detekci močových konkrementů na CT, ale také na USG a nativním nefrogramu, dále na predikci efektu terapeutických modalit (spontánní odchod litiázy, extrakorporální litotrypse rázovou vlnou – ESWL, perkutánní extrakce konkrementu – PCNL a jiné endourologické výkony) a na odhad složení konkrementů (62).

Detekce močových konkrementů

Parakh et al. v roce 2019 testovali kaskádový CNN model (nejprve identifikoval močový trakt, poté přítomnost konkrementů) v detekci urolitiázy na nativních CT snímcích, který

identifikoval močové konkrementy s přesností AUC 0,954. Tento model bychom mohli, při tréninku na větším počtu dat a prospektivní validaci, využít například na urgentních případech k zefektivnění práce a triáži snímků nutných ke čtení radiologem (62). Rozlišení distální ureterolitázy (UL) od flebolitů v pánevní určitých situacích bývá mnohdy složitý úkol i pro zkušené radiology. Jendeberg et al. v roce 2021 porovnávali přesnost rozlišení distální UL od flebolitů CNN modelu oproti sedmi zkušeným radiologům s výslednou přesností 92 %, respektive 86 % (medián) a 93 % (při většinovém hlasování) (64).

Predikce v léčbě

V případě předpovídání spontánního odchodu konkrémentu při UL se mimo jiné především řídíme rozměry litiázy. Solakhan et al. v roce 2019 vytvořili a testovali ANN model využívající velikost konkrémentu, hmotnost pacienta, hladinu C-reaktivního proteinu, míru bolestivosti, množství erytrocytů v močovém sedimentu a další parametry a správně odhadli spontánní odchod

v 99,16 % případů (65). Úspěšnost ESWL i PCNL závisí na mnoha faktorech a pro rozhodování o způsobu léčby je důležitý odhad šance, že pacient po výkonu nebude mít reziduální fragmenty nebo konkrementy (stone-free rate – SFR). Několik studií AI modelů na bázi ML či DL testovalo přesnost predikce SFR po ESWL na renální či ureterální konkrementy s různou přesností od 77 do 92 %. Obdobně některé studie testovaly odhad různých výsledků PCNL (potřeba krevní transfuze, zavedení stentu, SFR a infekční komplikace) (62).

Predikce chemického složení konkrémentů

Dalším tématem je analýza chemického složení konkrémentů podle klinických a laboratorních dat nebo pomocí CT, kde nejspěšnější modely odlišily urátovou litiázu od jiných druhů s přesností vyšší než 97 % (62).

Ostatní benigní onemocnění

V případě benigní hyperplazie prostaty je zatím testování velmi limitované, Shah et al.

v roce 2020 ve svém systematickém přehledu zmiňují pouze čtyři studie zabývající se diagnostikou a predikcí odpovědi na medikamentózní terapii (66). V urogynélogii v budoucnu možná nalezne AI využití s nástupem přenosných zařízení monitorujících močovou inkontinenci a z nich získaných dat k vytvoření modelů pro predikci efektivity různých konzervativních či operačních řešení úniků moči (67).

Závěr

Urologie stála vždy v popředí využití moderních technologií a není tomu jinak ani v případě AI. Přestože většina aplikací AI se zatím v klinickém prostředí uplatňuje málo, mnohé studie ukazují velmi slibné výsledky a potenciální zlepšení péče o pacienty. Faktem zůstává, že AI je zde a v medicíně i zůstane a bude se dále rozvíjet. Jako lékaři proto máme vůči našim pacientům zodpovědnost se v této oblasti vzdělávat a již od začátku tuto technologii správně do praxe implementovat. Neměli bychom AI brát jako konkurenta na trhu práce, ale jako kopilota, který nám otevře možnosti, o kterých jsme ani doposud nevěděli.

LITERATURA

- Kay M. WHO global survey of telemedicine. *Telemed Telecare* 2010;16:471-472.
- Rodriguez SM, Loeb S, Teoh JY, et al. Telemedicine and Smart Working: Recommendations of the European Association of Urology. *Eur Urol*. 2020;78(6):812-819.
- Ellimootil C, Skolarus T, Gettman M, et al. Telemedicine in Urology: State of the Art. *Urology*. 2016;94:10-16.
- Ohannessian R, Duong T, Odone A. Global Telemedicine Implementation and Integration Within Health Systems to Fight the COVID-19 Pandemic: A Call to Action. *JMIR Public Health Surveill*. 2020;6(2):e18810.
- Novara G, Checcucci E, Crestani A, et al. Telehealth in Urology: A Systematic Review of the Literature. How Much Can Telemedicine Be Useful During and After the COVID-19 Pandemic? *Eur Urol*. 2020;78(6):786-811.
- Symeonidis EN, Veneziano D, Borgmann H, et al. Telemedicine in Urology: Where Have We Been and Where Are We Heading? *Eur Urol Open Sci*. 2023;50:106-112.
- O eReceptu [Internet]. 2024 SÚKL. [cited 2024 Dec 24] Available from: <https://epreskripce.gov.cz/o-ereceptu/>.
- Péče o zdraví online, rychle a s úsměvem [Internet]. uLékaře.cz, s.r.o. [cited 2024 Dec 24]. Available from: <https://www.ulekare.cz/sluzba>.
- Einthoven W. Le télécardiogramme. *Archives Internationales de Physiologie* 1906;4:132-164.
- Wittson CL, Benschoter R. Two-way television: helping the medical center reach out. *American Journal of Psychiatry* 1972;129(5):624-627.
- Foot D, Parker D, Hudson H, et al. Telemedicine in Alaska: The ATS-6 satellite biomedical demonstration. *National Technical Information Service*, 1976.
- Bashshur RL, Shannon GW. History of Telemedicine: Evolution, Context, and Transformation. New Rochelle, NY: Mary Ann Liebert; 2009.
- Mann DM, Chen J, Chunara R, et al. Nov O. COVID-19 transforms health care through telemedicine: Evidence from the field. *J Am Med Inform Assoc*. 2020;27(7):1132-1135.
- Veneziano D, Tafuri A, Rivas JG, et al. Is remote live urologic surgery a reality? Evidences from a systematic review of the literature. *World J Urol*. 2020;38(10):2367-2376.
- Marescaux J, Leroy J, Rubino F, et al. Transcontinental robot-assisted remote telesurgery: feasibility and potential applications. *Ann Surg*. 2002;235(4):487-492.
- 8264km-distance historic first for Prof. Breda and EAU Event. [Internet] eru.uroweb.org, 2024 [cited 2024 Dec 24]. Available from: <https://erus.uroweb.org/>.
- Patel V, Marescaux J, Covas MM. The Humanitarian Impact of Telesurgery and Remote Surgery in Global Medicine. *Eur Urol*. 2024 Aug;86(2):88-89.
- Larcher A, Belladelli F, Capitanio U, et al. Long-distance Robot-assisted Teleoperation: Every Millisecond Counts. *Eur Urol*. 2023;83(1):45-47.
- Shah M, Naik N, Somani BK, et al. Artificial intelligence (AI) in urology-Current use and future directions: An iTRUE study. *Turk J Urol*. 2020;46(Suppl. 1):S27-S39.
- Russell S, Perset K, Grobelenik M. Updates to the OECD's definition of an AI system explained [Internet]. OECD.AI, 2023 [cited 2024 Dec 29]. Available from: <https://oecd.ai/en/work/ai-system-definition-update>.
- Arruda HM, Bavaresco RS, Kunst R, et al. Data Science Methods and Tools for Industry 4.0: A Systematic Literature Review and Taxonomy. *Sensors (Basel)*. 2023;23(11):5010.
- Checcucci E, Autorino R, Cacciamani GE, et al. Artificial intelligence and neural networks in urology: current clinical applications. *Minerva Urol Nefrol*. 2020;72(1):49-57.
- Kolektiv autorů: JEDNODUŠE: Umělá inteligence. Praha, Universum, První vydání, 2023. ISBN 978-80-242-9293-9.
- Hugh LE, James THT. The influence of AI in medicine; *Medicine*. 2024;52(12):811-815.
- Čapoun O. Editorial. *Czech urology*. 2023;27(3):136.
- Zogala D. Využití umělé inteligence v zobrazovacích metodách. *Cas Lek Cesk*. 2024;162(7-8):279-282.
- Choi RY, Coyner AS, Kalpathy-Cramer J, et al. Introduction to Machine Learning, Neural Networks, and Deep Learning. *Transl Vis Sci Technol*. 2020;9(2):14.
- Liu X, Shi J, Li Z, et al. The Present and Future of Artificial Intelligence in Urological Cancer. *J Clin Med*. 2023;12(15):4995.
- Riaz IB, Harmon S, Chen Z, et al. Applications of Artificial Intelligence in Prostate Cancer Care: A Path to Enhanced Efficiency and Outcomes. *Am Soc Clin Oncol Educ Book*. 2024;44(3):e438516.
- Cai JC, Nakai H, Kuanar S, et al. Fully Automated Deep Learning Model to Detect Clinically Significant Prostate Cancer at MRI. *Radiology*. 2024;312(2):e232635.
- Saha A, Bosma JS, Twilt JJ, et al. Artificial intelligence and radiologists in prostate cancer detection on MRI (PI-CAI): an international, paired, non-inferiority, confirmatory study. *Lancet Oncol*. 2024;25(7):879-887.
- Forooghi A, Laschena L, Pecoraro M, et al. Bridging the experience gap in prostate multiparametric magnetic resonance imaging using artificial intelligence: A prospective multi-reader comparison study on inter-reader agreement in PI-RADS v2.1, image quality and reporting time between novice and expert readers. *Eur J Radiol*. 2023;161:110749.
- Eloy C, Marques A, Pinto J, et al. Artificial intelligence-assisted cancer diagnosis improves the efficiency of pathologists in prostatic biopsies. *Virchows Arch*. 2023;482(3):595-604.
- EAU Guidelines. Edn. presented at the EAU Annual Congress Paris 2024. ISBN 978-94-92671-23-3.
- Daskivich TJ, Wood LN, Skarecky D, et al. Limitations of the National Comprehensive Cancer Network® (NCCN®) Guidelines for Prediction of Limited Life Expectancy in Men with Prostate Cancer. *J Urol*. 2017;197(2):356-362.

36. Esteva A, Feng J, van der Wal D, et al. Prostate cancer therapy personalization via multi-modal deep learning on randomized phase III clinical trials. *NPJ Digit Med.* 2022;5(1):71.
37. Spratt DE, Tang S, Sun Y, et al. Artificial Intelligence Predictive Model for Hormone Therapy Use in Prostate Cancer. *NEJM Evid.* 2023;2(8):EVIDo2300023.
38. Hung AJ, Chen J, Che Z, et al. Utilizing Machine Learning and Automated Performance Metrics to Evaluate Robot-Assisted Radical Prostatectomy Performance and Predict Outcomes. *J Endourol.* 2018;32(5):438-444.
39. Hung AJ, Chen J, Ghodoussipour S, et al. A deep-learning model using automated performance metrics and clinical features to predict urinary continence recovery after robot-assisted radical prostatectomy. *BJU Int.* 2019;124(3):487-495.
40. Sabbagh A, Tilki D, Feng J, et al. Multi-institutional Development and External Validation of a Machine Learning Model for the Prediction of Distant Metastasis in Patients Treated by Salvage Radiotherapy for Biochemical Failure After Radical Prostatectomy. *Eur Urol Focus.* 2024;10(1):66-74.
41. LEOPARD Challenge. [Internet] Grand-Challenge.org. [cited 2024 Jan 15]. Available from: <https://leopard.grand-challenge.org/leopard/>.
42. Riaz IB, Naqvi SAA, He H, et al. First-line Systemic Treatment Options for Metastatic Castration-Sensitive Prostate Cancer: A Living Systematic Review and Network Meta-analysis. *JAMA Oncol.* 2023;9(5):635-645.
43. Riaz IB, He H, Ryu AJ, et al. A Living, Interactive Systematic Review and Network Meta-analysis of First-line Treatment of Metastatic Renal Cell Carcinoma. *Eur Urol.* 2021;80(6):712-723.
44. Brisuda A, Hrbáček J, Babjuk M. Využití fotodynamické diagnostiky a úzkopásmového zobrazení v diagnostice a léčbě svalovinu neinvazivních nádorů močového měchýře. *Czech urology.* 2023;17(2):79-87.
45. Borhani S, Borhani R, Kajdacsy-Balla A. Artificial intelligence: A promising frontier in bladder cancer diagnosis and outcome prediction. *Crit Rev Oncol Hematol.* 2022;171:103601.
46. Kausch I, Sommerauer M, Montorsi F, et al. Photodynamic diagnosis in non-muscle-invasive bladder cancer: a systematic review and cumulative analysis of prospective studies. *Eur Urol.* 2010;57(4):595-606.
47. Shkolyar E, Jia X, Chang TC, et al. Augmented Bladder Tumor Detection Using Deep Learning. *Eur Urol.* 2019;76(6):714-718.
48. Jobczyk M, Stawiski K, Fendler W, et al. Validation of EORTC, CUETO, and EAU risk stratification in prediction of recurrence, progression, and death of patients with initially non-muscle-invasive bladder cancer (NMIBC): A cohort analysis. *Cancer Med.* 2020;9(11):4014-4025.
49. Jobczyk M, Stawiski K, Kaszkowiak M, et al. Deep Learning-based Recalibration of the CUETO and EORTC Prediction Tools for Recurrence and Progression of Non-muscle-invasive Bladder Cancer. *Eur Urol Oncol.* 2022;5(1):109-112.
50. Rasmussen R, Sanford T, Parwani AV, et al. Artificial Intelligence in Kidney Cancer. *Am Soc Clin Oncol Educ Book.* 2022;42:1-11.
51. Finelli A, Cheung DC, Al-Matar A, et al. Small Renal Mass Surveillance: Histology-specific Growth Rates in a Biopsy-characterized Cohort. *Eur Urol.* 2020;78(3):460-467.
52. Bhandari A, Ibrahim M, Sharma C, et al. CT-based radiomics for differentiating renal tumours: a systematic review. *Abdom Radiol (NY).* 2021;46(5):2052-2063.
53. Erdim C, Yardimci AH, Bektas CT, et al. Prediction of Benign and Malignant Solid Renal Masses: Machine Learning-Based CT Texture Analysis. *Acad Radiol.* 2020;27(10):1422-1429.
54. Kutikov A, Uzzo RG. The R.E.N.A.L. nephrometry score: a comprehensive standardized system for quantitating renal tumor size, location and depth. *J Urol.* 2009;182(3):844-853.
55. Kutikov A, Saldone MC, Egleston BL, et al. Anatomic features of enhancing renal masses predict malignant and high-grade pathology: a preoperative nomogram using the RENAL Nephrometry score. *Eur Urol.* 2011;60(2):241-248.
56. Abdallah N, Wood A, Benidir T, et al. AI-generated R.E.N.A.L.+ Score Surpasses Human-generated Score in Predicting Renal Oncologic Outcomes. *Urology.* 2023;180:160-167.
57. Chuluunbaatar Y, Bansal S, Brodie A, et al. The current use of artificial intelligence in testicular cancer: a systematic review. *Art Int Surg.* 2023;3:195-206.
58. Baessler B, Nestler T, Pinto Dos Santos D, et al. Radiomics allows for detection of benign and malignant histopathology in patients with metastatic testicular germ cell tumors prior to post-chemotherapy retroperitoneal lymph node dissection. *Eur Radiol.* 2020;30(4):2334-2345.
59. Bini F, Pica A, Azzimonti L, et al. Artificial Intelligence in Thyroid Field-A Comprehensive Review. *Cancers (Basel).* 2021;13(19):4740.
60. Liu J, O'Brien JS, Nandakishor K, et al. Snap Diagnosis: Developing an Artificial Intelligence Algorithm for Penile Cancer Detection from Photographs. *Cancers (Basel).* 2024;16(23):3971.
61. Chen CC, Yen TH, Li JR, et al. Artificial intelligence algorithms enhance urine cytology reporting confidence in postoperative follow-up for upper urinary tract urothelial carcinoma. *Int Urol Nephrol.* 2024 Nov 7 – ahead of print.
62. Anastasiadis A, Koudonas A, Langas G, et al. Transforming urinary stone disease management by artificial intelligence-based methods: A comprehensive review. *Asian J Urol.* 2023;10(3):258-274.
63. Parakh A, Lee H, Lee JH, et al. Urinary Stone Detection on CT Images Using Deep Convolutional Neural Networks: Evaluation of Model Performance and Generalization. *Radiol Artif Intell.* 2019;1(4):e180066.
64. Jendeborg J, Thunberg P, Lidén M. Differentiation of distal ureteral stones and pelvic phleboliths using a convolutional neural network. *Urolithiasis.* 2021;49(1):41-49.
65. Solakhan M, Seckiner SU, Seckiner I. A neural network-based algorithm for predicting the spontaneous passage of ureteral stones. *Urolithiasis.* 2020;48(6):527-532.
66. Shah M, Naik N, Hameed BZ, et al. Current Applications of Artificial Intelligence in Benign Prostatic Hyperplasia. *Turk J Urol.* 2022;48(4):262-267.
67. Bentalab J, Larouche M. Innovative use of artificial intelligence in urogynecology. *Int Urogynecol J.* 2020;31(7):1287-1288.