

## Umelá inteligencia v onkológii

Martin Demeter, Milan Zatroch

MindIT, s.r.o., Banská Bystrica

Umelá inteligencia (UI) má potenciál transformovať onkológiu tým, že poskytuje nové pohľady na diagnostiku a liečbu rakoviny. Jednou z najvýznamnejších aplikácií UI v onkológii je diagnostický proces. Diagnostické nástroje podporované UI dokážu s vysokou presnosťou analyzovať výstupy zo zobrazovacích zariadení môžu efektívnejšie odhaliť nádorový rast v štádiu, v ktorom môže byť ťažko rozpoznateľný aj skúsenými špecialistami. UI môže tiež predpovedať reakciu na liečbu a prognózu na základe údajov špecifických pre pacienta a jeho chorou, vrátane genomiky nádoru. Tieto a iné použitia UI môžu viesť k personalizovanej liečbe pacientov a zlepšeniu výsledkov v boji proti tejto chorobe.

Napriek potenciálnym výhodám UI v onkológii treba prekonať výzvy spojené s nasadením UI systémov do klinickej praxe. Pozornosť si vyžadujú najmä problémy týkajúce sa kvality údajov, súkromia a súladu s predpismi. Je tiež potrebná lepšia integrácia technológií podporovaných UI do existujúcich klinických pracovných postupov. Napriek tomu má používanie UI v onkológii potenciál výrazne zlepšiť diagnostiku a liečbu rakoviny, čo v konečnom dôsledku povedie k lepším výsledkom u pacientov. Ďalší vývoj a pokroky v UI nám umožnia naďalej posúvať hranice toho, čo je v oblasti onkológie možné.

**Kľúčové slová:** umelá inteligencia, strojové učenie, onkológia, biomarkery

### Artificial Intelligence in Oncology

Artificial intelligence (AI) can transform oncology by providing new cancer diagnosis and treatment perspectives. One of the most significant applications of AI in oncology is the diagnostic process. AI-supported diagnostic tools can accurately analyze outputs from imaging devices, effectively detecting tumour growth at stages that may be difficult to recognize even by experienced specialists. AI can also predict treatment response and prognosis based on patient-specific data, including tumour genomics. These and other uses of AI can lead to personalized patient care and improved outcomes in the fight against this disease.

Despite the potential benefits of AI in oncology, there are challenges to overcome in implementing AI systems into clinical practice. Issues related to data quality, privacy, and regulatory compliance require attention. Better integration of AI-supported technologies into existing clinical workflows is also needed. Nevertheless, the use of AI in oncology has the potential to significantly enhance cancer diagnosis and treatment, ultimately leading to better patient outcomes. Further advancements and progress in AI will continue to push the boundaries of what is possible in oncology.

**Keywords:** Artificial intelligence, Machine learning, Oncology, Biomarkers

**NewsLab, 2023; roč. 14 (3):**

### Úvod

Využitie umelej inteligencie (UI) v oblasti onkológie má potenciál spôsobiť revolúciu v diagnostike, liečbe a výskume rakoviny. Schopnosť algoritmov UI analyzovať veľké množstvo údajov z rôznych zdrojov, ako je genomika, proteomika, či údaje zo zobrazovacích zariadení, môže pomôcť pri identifikácii nových terapeutických cieľov, liečebných postupov a biomarkerov, ktoré môžu zlepšiť výsledky liečby pacientov. Integrácia UI v liečbe rakoviny však prináša súbor nových výziev a obmedzení. V tomto článku sa snažíme poskytnúť prehľad o súčasnom význame UI v diagnostike, liečbe a vo výskume rakoviny. Opíšeme aj výzvy a obmedzenia, ktoré treba riešiť pre úspešnú implementáciu UI do klinickej praxe.

### Stručný prehľad rakoviny ako choroby

Rakovina je ochorenie charakterizované nekontrolovaným rastom a šírením abnormálnych buniek v tele. Je jednou z hlavných príčin úmrtí na celom svete<sup>(1)</sup>.

Vývoj rakoviny je viacstupňový proces. Nádorová transformácia súvisí s vplyvom vrodených a environmentálnych faktorov. Vrodené genetické mutácie v určitých génoch zvyšujú riziko vzniku určitých typov nádorov<sup>(3)</sup>, kým environmentálne faktory zahŕňajú vystavenie organizmu mutagénom fyzikálneho, chemického alebo biologického pôvodu. Úlohu zohrávajú aj faktory životného štýlu, ako je fajčenie a nevhodná strava<sup>(2)</sup>. Nádorové bunky sa líšia od normálnych buniek niekoľkými charakteristikami. Zásadný je ich nadmerný, nekontrolovateľný a nezávislý rast a schopnosť odolávať prirodzeným regulačným procesom organizmu. Malígne nádory môžu invadovať a poškodiť okolité tkanivo<sup>(4)</sup>, môžu sa metastaticky šíriť aj do iných častí tela<sup>(5)</sup>.

Nádory sa v súčasnosti liečia najčastejšie kombináciou chirurgického zákroku, rádioterapie, chemoterapie a cielenej biologickej terapie. Výber liečby závisí od mnohých faktorov, hľadanie nových terapeutických postupov je základnou výzvou pre onkologický výskum súčasnosti<sup>(6)</sup>.

Nedávne pokroky vo výskume, vrátane technológií UI umožňujú onkologickú liečbu vo viac personalizovanej podobe precíznej medicíny<sup>(7,8)</sup>. Je to prístup k lekárskej liečbe, ktorý berie do úvahy genetiku, životný štýl a prostredie jednotlivca s cieľom čo najlepšie prispôbiť lekárske rozhodnutia, postupy a/alebo medikamenty danej osobe. Cieľom je zlepšiť zdravotné výsledky a znížiť riziko vedľajších účinkov.

## Výskum rakoviny

Súčasný stav výskumu nádorových chorôb sa rýchlo vyvíja a je zameraný na vývoj nových a efektívnejších spôsobov liečby<sup>(9)</sup>. Niektoré z hlavných oblastí výskumu zahŕňajú:

- Pochopenie genetických a molekulárnych mechanizmov rakoviny, ktoré vedú k rozvoju a progresii nádorov. Tieto poznatky sa využívajú na vývoj nových liekov a terapeutických postupov, ktoré sa zameriavajú na špecifické molekuly a mechanizmy zapojené v nádorovej premene.
- Vývoj nových a efektívnejších spôsobov liečby so zameraním na ciele liečbu a vývoj nových liečebných postupov, ktoré sú účinnejšie a majú menej vedľajších účinkov ako súčasné spôsoby liečby. Zameriava sa aj na zlepšenie existujúcich liečebných postupov, aby boli presnejšie a menej toxické.
- Zlepšenie včasnej detekcie a diagnostiky, zahŕňajúce vývoj nových a presnejších metód na včasnú detekciu nádorov v štádiu, keď sú lepšie liečiteľné.
- Nádej predstavuje vývoj personalizovaných liečebných plánov pre onkologických pacientov na základe ich individuálnej genetiky, osobnej anamnézy a molekulárneho profilu ich nádorov. Očakáva sa, že tento prístup povedie k efektívnejšej liečbe s menším počtom vedľajších účinkov.
- Vývoj nových kombinovaných terapií, ktoré sa zameriavajú na viaceré dráhy a mechanizmy zapojených v nádorovom procese, s cieľom dosiahnuť účinnejšiu a trvalejšiu odpoveď.
- Vývoj stratégií prevencie a kontroly rakoviny, vrátane identifikácie a riešenia rizikových faktorov rakoviny, ako je fajčenie, strava a vystavenie určitým chemikáliám a toxínom.
- Umelá inteligencia a strojové učenie vo výskume rakoviny s vývojom modelov založených na UI na analýzu veľkého množstva údajov z výskumu, s cieľom identifikovať nové ciele liečby a zlepšiť presnosť diagnostiky.

## Umelá inteligencia

Umelá inteligencia je odvetvie počítačovej vedy. Zahŕňa matematické metódy, ktoré umožňujú rozhodovanie alebo konanie, racionálne a autonómne uvažovanie a efektívne prispôbenie sa zložitým a nevídaným situáciám.

Strojové učenie (ML) je súčasťou umelej inteligencie a hlboké učenie (DL) je súčasťou strojového učenia. Algoritmy strojového učenia vytvárajú matematické modely, ktoré sa učia a prispôbujú na základe skúseností bez toho, aby boli pravidlá rozhodovania ručne naprogramované. Modely umelej inteligencie sú užitočné v tých typoch problémov, kde pravidlá rozhodovania sú príliš komplexné na naprogramovanie. V niektorých typoch úloh, ako je napr. počítačové videnie, je takmer nemožné naprogramovať dostatočné množstvo všeobecných pravidiel na to, aby algoritmus dokázal dostatočne presne rozpoznať zložité a nepravidelné objekty. Modely si

namiesto toho pravidlá vytvoria samé, len na základe tréningových údajov. V mnohých typoch úloh je omnoho efektívnejšie pripraviť tréningové údaje, ako programovať pravidlá, ktoré si často vyžadujú veľkú expertnú znalosť v danej doméne.

Inteligencia modelov vyplýva z množiny parametrov, ktoré spolu vytvárajú pravidlá, na základe ktorých sa model rozhoduje. V závislosti od použitého modelu, napr. v prípade lineárnej logistiky, môže ísť o jednotky parametrov, ale v prípade hlbokých neuronových sietí, môže ísť aj o milióny parametrov.

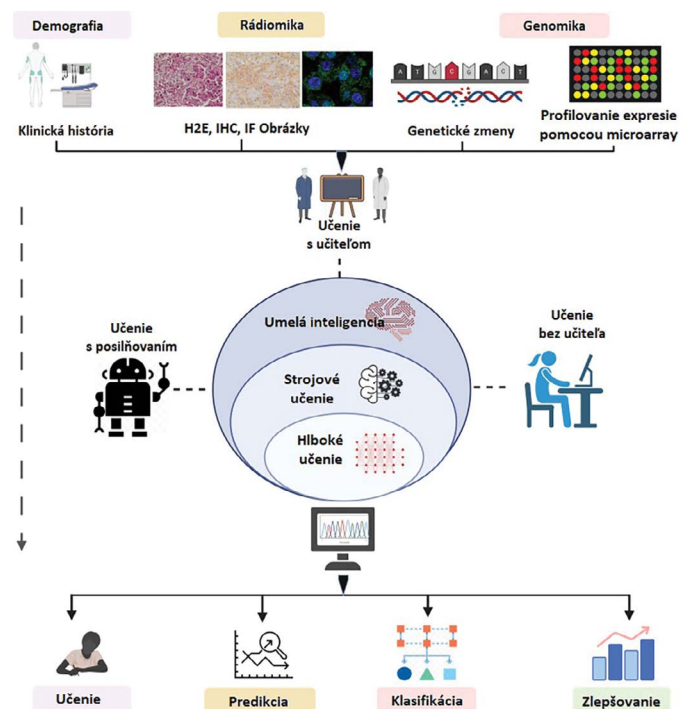
Proces, pri ktorom si modely prispôbujú svoje parametre, sa nazýva tréning. Tréning spočíva v minimalizovaní rozdielu (tzv. tréningovej chyby) medzi výstupom modelu a požadovaným výstupom vo vzorových dátach, tiež známych ako tréningové dáta.

V závislosti od problému, ktorý model napomáhať riešiť, rozdeľujeme algoritmy strojového učenia na 4 základné typy: učenie s učiteľom, učenie bez učiteľa, učenie s čiastočným učiteľom, učenie s posilňovaním.

## Učenie s učiteľom

Algoritmy založené na učení s učiteľom (angl. Supervised learning) sa používajú predovšetkým v prediktívnych úlohách. Typické úlohy, ktoré tu patria, sú klasifikácia (napr. klasifikácia tumorov), objektová detekcia (hľadanie tumoru v CT snímkach) alebo regresia (napr. predikcia rizika úmrtnosti/pravdepodobnosti návratu rakoviny).

V týchto úlohách človek trénuje alebo učí algoritmus, čo má hľadať. Ide o učenie pomocou príkladov – človek dá algoritmu sadu tréningových údajov a algoritmus v nich hľadá vzory, pomocou ktorých sa rozhoduje. Tréningové údaje obsahujú vstupné údaje modelu, ako aj predpokladaný výstup (tzv. učiteľa), teda to, čo očakávame od modelu, aby predikoval. V prípade klasifikácie obrázkov ide o popis toho, čo sa na obrázku nachádza, v prípade objektovej detekcie aj presné súradnice objektov **na obrázku**.



V procese tréningovania, model prispôsobuje svoje parametre tak, aby rozdiel medzi jeho výstupom a predpokladaným výstupom, bol čo najmenší. Po správnom natrénovaní modelu, by mal model predpovedať výstup len na základe vstupných údajov. Pri tomto type úloh je však potrebné zabezpečiť, aby model dostatočne zovšeobecňoval úlohu, na ktorú bol navrhnutý, tzn., že by mal predikovať rozumné výsledky, aj na nových vstupných údajoch, ktoré sa v tréningových údajoch nenachádzali. V opačnom prípade, hovoríme o preučení modelu, čo sa typicky prejavuje vysokou presnosťou predikcie nad tréningovými údajmi, ale nízkou presnosťou nad novými, netrénovanými údajmi. K najčastejšie používaným modelom patria: lineárna/logistická regresia, SVM, rozhodovacie stroje, boosting algoritmy a neurónové siete.

### Učenie bez učiteľa

Algoritmy založené na učení bez učiteľa (angl. Unsupervised learning) sa používajú predovšetkým v deskriptívnych úlohách. Typické úlohy, ktoré sem patria, sú: klastrová analýza, redukcia dimenzionality, kompresia údajov, detekcia anomálií, generovanie dát.

V týchto úlohách sa nepožaduje, aby algoritmus predikoval konkrétnu hodnotu, ktorú človek požaduje. Namiesto toho sa model učí hľadať vzory v zložitých dátach, alebo vracia inak reprezentované vstupné údaje, ktoré v sebe nesú ďalšiu užitočnú informáciu, ktorú by inak človek prehliadol. Napríklad v klastrovej analýze model zoskupuje množinu objektov (ktoré môžu mať aj tisíce atribútov) takým spôsobom, že objekty v tej istej skupine (nazývanej zhluk) sú si navzájom podobnejšie ako s objektami v ostatných skupinách.

### Učenie s čiastočným učiteľom

Algoritmy založené na tomto princípe (angl. Semi-Supervised learning) kombinujú učenie s učiteľom aj učenie bez učiteľa.

Anotácia a príprava tréningových dát je spravidla časovo najnáročnejšia úloha pri vývoji modelov. V prípade, ak je k dispozícii veľa tréningových údajov, ale len malá časť z nich je anotovaná, možno postupovať pri vývoji modelu iteratívne, a to tak, že sa prvý model natrénuje len na malej, anotovanej vzorke. Následne sa model využíva na pred-anotovanie ostatných dát. Pred-anotované dáta sú však človekom skontrolované, opravené, analyzované a následne použité na rozšírenie tréningovej vzorky. Väčšia tréningová vzorka je využitá na natréningovanie novšieho modelu.

Takýmto spôsobom možno urýchliť proces anotácie a aj zvýšiť presnosť modelu. Vďaka analýze predikcií pri každej iterácii sa totiž získavajú užitočné informácie, ktoré napomáhajú k pochopeniu toho, ako model funguje. Pri analýze možno zistiť, pri akých vstupoch robí model chyby, čo môžeme využiť v ďalšej iterácii na zlepšenie predspracovania dát, výberu dôležitejších tréningových údajov, vylepšenie modelu a iných techník, ktoré vedú k natréningovanie ešte lepšieho modelu.

### Učenie s posilňovaním

Algoritmy založené na učení s posilňovaním (angl. Reinforcement learning) sa využívajú predovšetkým v robotike, optimalizovaním procesov, hernom priemysle.

Algoritmy založené na tomto princípe, sa neučia na základe tréningových príkladov, ktoré pripravil človek (ako v uče-

ní s učiteľom), ale na základe skúseností, ktoré získava tzv. agent v prostredí, v ktorom sa nachádza. Pod agentom je možné si predstaviť robota, alebo postavu v hre. Učenie spočíva v spočiatku náhodnom konaní agenta v prostredí, pričom za vykonanie istých akcií získava spätnú väzbu v podobe odmeny. Táto spätná väzba slúži na posilnenie tých akcií, ktoré viedli k jej získaniu.

### UI ako nástroj na zlepšenie liečby a výskumu rakoviny

Umelá inteligencia má potenciál výrazne zlepšiť liečbu a výskum rakoviny. UI sa môže použiť na analýzu veľkého množstva údajov z výskumu rakoviny, ako sú genetické dáta a obrazové údaje z medicínskych zariadení, na identifikáciu nových cieľov liečby a zlepšenie presnosti diagnózy.

Jedným z príkladov toho, ako sa UI používa vo výskume rakoviny, je vývoj počítačom podporovaných diagnostických systémov. Tieto systémy využívajú algoritmy strojového učenia na analýzu lekárskeho obrazov, ako sú CT a MRI skeny, na identifikáciu a klasifikáciu nádorov. Štúdie ukázali, že tieto systémy môžu zlepšiť presnosť diagnostiky rakoviny a znížiť potrebu invazívnych postupov<sup>(9,10)</sup>.

UI sa tiež používa na analýzu veľkého množstva genetických údajov. Algoritmy UI možno trénovať na identifikáciu špecifických mutácií, ktoré sú spojené s rôznymi typmi rakoviny<sup>(11)</sup>. Tiež možno použiť modely hlbokého učenia na klasifikáciu typov rakoviny z genetického profilu pacientov<sup>(12)</sup>.

Ďalšou aplikáciou UI pri výskume rakoviny je objavovanie nových liekov. Modely UI sa používajú na analýzu chemických vlastností liekov a ich potenciálnych interakciách s rakovinovými bunkami<sup>(11)</sup>. Výstupy z týchto modelov môžu pomôcť identifikovať nové zlúčeniny, ktoré môžu byť účinné proti rakovine alebo znížiť riziko nepriaznivých účinkov liekov.

### Použitie UI pri diagnostike rakoviny

Umelá inteligencia sa čoraz viac využíva v oblasti diagnostiky rakoviny ako nástroj na zlepšenie presnosti a účinnosti procesu. UI sa môže tiež použiť na analýzu genetických údajov a na predpovedanie, ktorí pacienti budú reagovať na určité liečebné postupy. Umelá inteligencia sa môže použiť aj na vývoj počítačom podporovaných diagnostických systémov, ktoré môžu zlepšiť presnosť diagnostiky rakoviny a znížiť potrebu invazívnych postupov.

UI sa môže použiť na analýzu veľkého množstva údajov, ako sú genomické, proteomické a zobrazovacie údaje, na identifikáciu nových, ale aj známych biomarkerov, ktoré môžu naznačovať prítomnosť nádoru. To môže pomôcť pri vývoji nových diagnostických testov a zlepšiť presnosť diagnostiky rakoviny.

UI možno použiť na vytvorenie prediktívnych modelov, ktoré dokážu predpovedať pravdepodobnosť určitých typov nádorov.

### Zobrazovacie prístroje

Algoritmy UI možno použiť na analýzu výstupov z lekárskeho zobrazovacích zariadení, ako sú CT, MRI, röntgeny alebo USG. Algoritmy dokážu analyzovať obrazovú informáciu a nájsť v nej rôzne vzory, ktoré môžu napomôcť v lepšej diagnostike.



Jeden z príkladov, kde sa UI používa, je analýza výstupov z mamografie pri diagnostike nádorov prsníka. Výskumníci vytvorili UI algoritmus, ktorý predpovedá riziko rakoviny prsníka analýzou mamografických snímok. Ukazuje sa, že algoritmus je presnejší ako niektoré existujúce metódy na predpovedanie rizika rakoviny prsníka<sup>(13)</sup>.

V prípade rakoviny pľúc bolo vyvinutých niekoľko modelov umelej inteligencie s hlbokým učením, ktoré pomáhajú lekárom nájsť rakovinu pľúc na CT vyšetreniach<sup>(14-17)</sup>. Výskum naznačuje, že UI môže lepšie odlíšiť nádorové zmeny pľúc od nenádorových, čo môže potenciálne znížiť počet falošne pozitívnych výsledkov a ušetriť niektorých pacientov od zbytočného stresu a ďalších vyšetrení<sup>(18)</sup>.

Používanie nástrojov UI na detekciu nádorov z medicínskych obrazov je stále v počiatočnom štádiu, pričom existuje mnoho nevyriešených otázok spojených s jeho nasadením do praxe. Hoci mnohé algoritmy boli úspešne testované, väčšina z nich zatiaľ neprešla externým validačným testovaním, čo je dôležité na zabezpečenie ich presnosti na rôznych skupinách pacientov a v rôznych lekárskejších inštitúciách. Klinické štúdie musia tiež ukázať, že nástroje UI zlepšujú výsledky diagnostiky a liečby pacientov.

### Biopsia/histológia/patológia

Biopsia je postup, pri ktorom sa z tela odoberie vzorka tkaniva a následne sa mikroskopicky vyšetrí patológom za účelom potvrdenia diagnózy a určenia typu, ako aj relevantných prognostických a terapeutických znakov.

Umelá inteligencia môže byť použitá v histológii na zlepšenie presnosti, rýchlosti a efektívnosti v rôznych úlohách.

Histologické obrázky možno analyzovať pomocou algoritmov UI na detekciu a klasifikáciu rôznych typov buniek, tkanív a štruktúr. To môže pomôcť patológom identifikovať abnormality a urobiť presnejšie diagnózy. UI môže tiež pomôcť s kvantifikáciou rôznych zmien v histologických prípravkoch.

Známe sú algoritmy založené na hlbokoj neurónovej sieti na kategorizáciu snímok. Natrénovaný model dokáže odfiltrovať 65–75 % obrazovej informácie, ktorá v sebe neobsahuje dôležitú informáciu na stanovenie diagnózy a upriamiť pozornosť patológa na relevantné časti. To v praxi môže ušetriť čas patológom<sup>(19)</sup>.

V štúdií Korbar a spol. porovnávali viacero architektúr modelov hlbokého učenia na klasifikáciu kolorektálnych polypov na Whole slide obrazov. Najlepší model hlbokého učenia dosiahol mieru presnosti 93 %. Hoci model nie je dostatočne presný na to, aby nahradil lekárov a patológov, môže byť užitočný na redukovanie manuálnej záťaži a zvýšenie efektivity diagnostického procesu<sup>(20)</sup>.

Štúdia Bychkov a kol. mala za cieľ pomocou modelov hlbokého učenia trénovaných na obrazoch nádorového tkaniva získaných pomocou metódy tkanivových mikroarray (TMA) predikovať stratifikáciu pacientov s nízkym a vysokým rizikom kolorektálneho karcinómu (CRC). Výsledky ukázali, že predikcia založená na hlbokom učení (AUC 0,69) prekonal klasifikáciu troch nezávislých odborníkov na úrovni TMA spot (AUC 0,58), ako aj na úrovni celého prípravku (AUC 0,57). Ďalšie výskumy sú potrebné na zhodnotenie účinnosti tejto metódy na väčších vzorkách tkaniva a v rôznych skupinách pacientov<sup>(21)</sup>.

V medzinárodnej súťaži zameranej na detekciu metastatického karcinómu prsníka na Whole Slide obrazoch biopsií sentinelových lymfatických uzlín sa Wang a kol. stali víťazmi, pričom ich model založený na neurónových sieťach dosiahol presnosť 0,925 AUC pre úlohu klasifikácie Whole slide obrazov a 0,7051 AUC pre úlohu lokalizácie nádoru. Obrazy boli nezávisle posúdené patológom, pričom dosiahli 0,966 AUC pre klasifikáciu Whole slide obrazov a 0,733 AUC pre lokalizáciu nádoru. Kombináciou výstupu modelu s výstupmi patológa sa zvýšila presnosť AUC na 0,995, čo predstavuje približne 85-percentné zníženie ľudskej chybovosti. Aj tieto výsledky ukazujú význam použitia hlbokého učenia pri významnom zlepšení presnosti patologických diagnóz<sup>(22,23)</sup>.

Celkovo má UI potenciál spôsobiť revolúciu v histológii tým, že poskytne rýchlejšiu a presnejšiu diagnostiku, prognózu a kontrolu kvality.

### Tekutá biopsia

Tekutá biopsia sa ukazuje ako sľubný neinvazívny prístup k diagnostike a monitorovaniu rakoviny. Ponúka jednoduchosť odberu vzoriek, nepretržité monitorovanie opakovaným odberom vzoriek, navrhovanie personalizovaných terapeutických režimov a skrining terapeutické rezistencie. Tekutá biopsia pozostáva z izolácie entít odvodených z nádoru, ako sú cirkulujúce nádorové bunky, cirkulujúca nádorová DNA, nádorové extracelulárne vezikuly a iné, ktoré sú prítomné v telesných tekutinách pacientov. Po odobratí vzorky nasleduje analýza genetických a proteomických markerov. Hoci vo všetkých prípadoch nemusí úplne nahradiť invazívne metódy, ako je tkanivová biopsia, tekutá biopsia má potenciál spôsobiť revolúciu v boji proti rakovine tým, že poskytuje komplexnejší a pre pacienta priateľský diagnostický prístup. Pred zavedením do praxe je však potrebné realizovať ďalšie výskumy, rozsiahle klinické štúdie, štandardizáciu protokolov a iné<sup>(24,25,27)</sup>.

Metódy analýzy tekutej biopsie sa za posledných niekoľko rokov rýchlo vyvinuli. Algoritmy strojového učenia môžu napomôcť v identifikácii nádorových zmien, čím sa otvára možnosť menej invazívneho a presnejšieho testovania.

Napríklad výskumníci z Johns Hopkins University School of Medicine vyvinuli CancerSEEK, ktorý dokáže odhaliť prípady ôsmich rôznych druhov nádorov, vrátane nádorov ovárií, pečene, žalúdka, pankreasu, pažeráka, hrubého čreva, pľúc a prsníka. V štúdiu s 1 005 pacientmi bol test CancerSEEK schopný identifikovať nádorovú chorobu v krvi približne 70 % prípadov, čo patrí medzi doteraz najlepšie výsledky krvného testu. Falošne pozitívny nález bol zistený u menej ako 1 % zdravých probandov<sup>(26)</sup>.

### Genetické testovanie a poradenstvo

Genetické testovanie možno použiť na identifikáciu dedičných genetických mutácií, ktoré môžu zvýšiť riziko určitých typov nádorov. UI možno použiť na analýzu veľkého množstva genetických údajov, vrátane údajov zo sekvenovania celého genómu. Analýzou možno identifikovať vzorce a korelácie, ktoré môžu naznačovať prítomnosť nádoru, ale aj nájsť nové genetické biomarkery, ktoré možno použiť na diagnostiku a monitorovanie onkologickej choroby. UI sa môže použiť na identifikáciu potenciálnych cieľov pre liečbu rakoviny, čo umožňuje vytvorenie personalizovaných liečebných plá-

nov pre pacientov. Taktiež tvorbou prediktívnych modelov nad genetickými údajmi možno s určitou pravdepodobnosťou určiť riziko vzniku rakoviny a zvoliť vhodnú prevenciu ešte pred prepuknutím choroby<sup>(28,29)</sup>.

## Výzvy a obmedzenia

Použitie umelej inteligencie (UI) pri liečbe, diagnostike a výskume onkologických chorôb má niekoľko výziev<sup>(9,12,24,29)</sup>:

- Kvalita a dostupnosť údajov: Algoritmy UI vyžadujú veľké množstvo vysokokvalitných údajov na tréning a testovanie modelov. Pri výskume nádorov môže byť ťažké získať údaje a tie, ktoré sú k dispozícii, môžu byť neúplné alebo nekonzistentné. To môže sťažiť tréning presných modelov a aj obmedziť použiteľnosť UI vo výskume.
- Skreslenie údajov: Modely umelej inteligencie sú len také dobré, ako dobré sú údaje, na ktorých sú tréňované. Ak údaje použité na tréning modelu obsahujú odchýlky, skreslenia, zaujatost, model bude negatívne ovplyvnený. To môže viesť k nepresným výsledkom a môže to sťažiť zovšeobecnenie modelu na nové populácie pacientov.
- Nedostatočná interpretovateľnosť: Niektoré modely UI, najmä modely hlbokého učenia, môžu byť ťažko interpretovateľné. To môže sťažiť pochopenie toho, ako model robí rozhodnutia a obmedziť schopnosť identifikovať a opraviť chyby v modeli.
- Obmedzené chápanie biológie rakoviny: Na vývoj účinných modelov UI na liečbu a výskum rakoviny treba pochopenie biológie nádorových zmien. Naše chápanie je však obmedzené, čo môže sťažiť vývoj presných modelov UI.
- Právne a etické obavy: Používanie UI v zdravotníctve vyvoláva množstvo právnych a etických problémov, ako sú súkromie údajov, autonómia pacienta a zodpovednosť za diagnostiku a liečbu choroby. Taktiež použitie UI pri liečbe a výskume si vyžaduje regulačné schválenie, čo môže byť zdĺhavý a nákladný proces.
- Technické výzvy: Vývoj modelov UI na liečbu a výskum rakoviny môže byť technicky náročný. Vyžaduje si to odborné znalosti v oblasti UI, ako aj medicíny. Okrem toho treba mať prístup k výkonným výpočtovým zdrojom a príslušným softvérovým nástrojom.
- Nedostatočná štandardizácia: V súčasnosti chýba štandardizácia vo vývoji a overovaní modelov UI na liečbu

a výskum nádorových chorôb. To môže sťažiť porovnávanie výkonnosti rôznych modelov a môže obmedziť schopnosť replikovať výsledky.

- Vysoké náklady a nedostatočná dostupnosť: Vývoj a implementácia riešení založených na UI na liečbu a výskum rakoviny môže byť nákladný proces a nemusí byť dostupný pre všetkých pacientov. To môže obmedziť dostupnosť liečby a diagnostických nástrojov založených na UI pre pacientov v krajinách s nízkymi príjmami alebo pre tých, ktorí nemajú prístup k špecializovaným zdravotníckym zariadeniam.

## Záver

Umelá inteligencia má potenciál zmeny v liečbe, diagnostike a výskume onkologických chorôb analýzou veľkého množstva údajov z rôznych zdrojov. UI môže pomôcť identifikovať nové terapeutické ciele, nové kombinácie liekov a nové biomarkery. Použitie UI pri liečbe, diagnostike a výskume však musí zdolať niekoľko výziev. Medzi takéto výzvy patrí obmedzená dostupnosť a kvalita údajov, skreslenie údajov, nedostatočná interpretovateľnosť výsledkov, obmedzené chápanie biológie nádorových zmien, právne a etické problémy, technické problémy, nedostatočné zovšeobecňovanie predikcii modelov, nedostatok štandardizácie, schválenia regulačnými orgánmi, a aj vysoké náklady. Napriek týmto výzvam sa dosiahol významný pokrok vo vývoji a implementácii riešení založených na UI. S pokračujúcim výskumom a vývojom je pravdepodobné, že UI bude v budúcnosti hrať čoraz dôležitejšiu úlohu v boji proti rakovine. Je však dôležité poznamenať, že UI by sa mala používať ako nástroj, ktorý pomáha ľudskému rozhodovaniu, a nie ju nahrádzať. Okrem toho je dôležité zabezpečiť, aby boli modely UI overené a testované a aby neboli zaujaté pre určité skupiny pacientov.

### Podakovanie

„Táto publikácia vznikla vďaka podpore v rámci Operačného programu Integrovaná infraštruktúra pre projekt: Centrum pre biomedicínsky výskum – BIOMEDIRES - II. etapa, kód ITMS: 313011W428, spolufinancovaný zo zdrojov Európskeho fondu regionálneho rozvoja.“

## LITERATÚRA

1. National cancer institute - <https://www.cancer.gov/about-cancer/understanding/what-is-cancer>
2. National cancer institute - <https://www.cancer.gov/about-cancer/causes-prevention/risk>
3. National cancer institute - <https://www.cancer.gov/about-cancer/causes-prevention/genetics>
4. Hanahan, D., & Weinberg, R. A. (2011). Hallmarks of cancer: the next generation. *Cell*, 144(5), 646–674. <https://doi.org/10.1016/j.cell.2011.02.013>
5. National cancer institute - <https://www.cancer.gov/types/metastatic-cancer>
6. National cancer institute - <https://www.cancer.gov/about-cancer/treatment/types>
7. National cancer institute - <https://www.cancer.gov/research/areas>
8. National cancer institute - <https://www.cancer.org/treatment/treatments-and-side-effects/treatment-types/precision-medicine.html>

9. Farina E, Nabhen JJ, Dacoregio MI, Batalini F, Moraes FY. An overview of artificial intelligence in oncology. *Future Sci OA*. 2022; 8(4): FSO787. Published 2022 Feb 10. doi: 10.2144/fsoa-2021-0074.
10. Hu L, Bell D, Antani S, et al. An Observational Study of Deep Learning and Automated Evaluation of Cervical Images for Cancer Screening. *J Natl Cancer Inst*. 2019; 111(9): 923-932. doi: 10.1093/jnci/djy225
11. You, Y., Lai, X., Pan, Y. et al. Artificial intelligence in cancer target identification and drug discovery. *Sig Transduct Target Ther* 7, 156 (2022). <https://doi.org/10.1038/s41392-022-00994-0>
12. Dwivedi, A.K. Artificial neural network model for effective cancer classification using microarray gene expression data. *Neural Comput & Applic* 29, 1545–1554 (2018). <https://doi.org/10.1007/s00521-016-2701-1>
13. Yala A, Mikhael PG, Strand F, et al. Toward robust mammography-based models for breast cancer risk. *Sci Transl Med*. 2021; 13(578): eaba4373. doi: 10.1126/scitranslmed.aba4373

14. Ardila D, Kiraly AP, Bharadwaj S, et al. End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography [published correction appears in Nat Med. 2019 Aug; 25(8): 1319]. *Nat Med*. 2019; 25(6): 954-961. doi: 10.1038/s41591-019-0447-x
15. Lakshmanaprabu, S. K., Mohanty, S. N., Shankar, K., Arunkumar, N., & Ramirez, G. (2019). Optimal deep learning model for classification of lung cancer on CT images. *Future Generation Computer Systems*, 92, 374-382.
16. Riquelme, D., & Akhloufi, M. A. (2020). Deep learning for lung cancer nodules detection and classification in CT scans. *Ai*, 1(1), 28-67.
17. Zhang S, Sun F, Wang N, et al. Computer-Aided Diagnosis (CAD) of Pulmonary Nodule of Thoracic CT Image Using Transfer Learning. *J Digit Imaging*. 2019; 32(6): 995-1007. doi: 10.1007/s10278-019-00204-4
18. El-Regaily, S. A., Salem, M. A. M., Aziz, M. H. A., & Roushdy, M. I. (2020). Multi-view Convolutional Neural Network for lung nodule false positive reduction. *Expert systems with applications*, 162, 113017.
19. Campanella G, Hanna MG, Geneslaw L, et al. Clinical-grade computational pathology using weakly supervised deep learning on whole slide images. *Nat Med*. 2019; 25(8): 1301-1309. doi: 10.1038/s41591-019-0508-1
20. Korbar B, Olofson AM, Miraflor AP, et al. Deep Learning for Classification of Colorectal Polyps on Whole-slide Images. *J Pathol Inform*. 2017; 8: 30. Published 2017 Jul 25. doi: 10.4103/jpi.jpi\_34\_17
21. Bychkov D, Linder N, Turkki R, et al. Deep learning based tissue analysis predicts outcome in colorectal cancer. *Sci Rep*. 2018; 8(1): 3395. Published 2018 Feb 21. doi: 10.1038/s41598-018-21758-3
22. Wang, Dayong & Khosla, Aditya & Gargeya, Rishab & Irshad, Humayun & Beck, Andrew. (2016). Deep Learning for Identifying Metastatic Breast Cancer.
23. Litjens G, Bandi P, Ehteshami Bejnordi B, et al. 1399 H&E-stained sentinel lymph node sections of breast cancer patients: the CAMELYON dataset. *Gigascience*. 2018; 7(6): giy065. doi: 10.1093/gigascience/giy065
24. <https://directorsblog.nih.gov/2018/01/30/new-liquid-biopsy-shows-early-promise-in-detecting-cancer>
25. National Cancer Institute - Biomarker Testing for Cancer Treatment <https://www.cancer.gov/about-cancer/treatment/types/biomarker-testing-cancer-treatment>
26. Joshua D. Cohen et al. ,Detection and localization of surgically resectable cancers with a multi-analyte blood test. *Science* 359, 926-930(2018). DOI: 10.1126/science.aar3247
27. Lone, S.N., Nisar, S., Masoodi, T. et al. Liquid biopsy: a step closer to transform diagnosis, prognosis and future of cancer treatments. *Mol Cancer* 21, 79 (2022). <https://doi.org/10.1186/s12943-022-01543-7>
28. Dias, R., Torkamani, A. Artificial intelligence in clinical and genomic diagnostics. *Genome Med* 11, 70 (2019). <https://doi.org/10.1186/s13073-019-0689-8>
29. Xu, J., Yang, P., Xue, S. et al. Translating cancer genomics into precision medicine with artificial intelligence: applications, challenges and future perspectives. *Hum Genet* 138, 109–124 (2019). <https://doi.org/10.1007/s00439-019-01970-5>

---

**Mgr. Martin Demeter, RNDr. Milan Zatroch, CSc.**

MindIT, s.r.o.

Sládkovičova 23, 974 01 Banská Bystrica

e-mail: martin.demeter@alanata.sk