

## SOUBORNÉ SDĚLENÍ

# Pohled na využití umělé inteligence v klinické mikrobiologii

## *Perspectives on artificial intelligence in clinical microbiology*

Jakub Hurych, Pavel Dřevínek

Ústav lékařské mikrobiologie,  
Fakultní nemocnice v Motole,  
2. lékařská fakulta  
Univerzity Karlovy, Praha

## SOUHRN

**Hurych J, Dřevínek P. Pohled na využití umělé inteligence v klinické mikrobiologii**

Umělá inteligence (AI) představuje v posledních letech revoluční nástroj, který má potenciál zásadně proměnit provoz laboratoří klinické mikrobiologie. Díky schopnosti automatizovat rutinní činnosti, analyzovat komplexní datové soubory a rozpoznávat vzorce, které lidskému oku často uniknou, může AI významně přispět k vyšší efektivitě, standardizaci a přesnosti laboratorní diagnostiky.

Jednou z klíčových oblastí je analýza obrazových dat – ať už jde o interpretaci mikroskopických nátěrů (např. Gramovo barvení), nebo digitální čtení kultivačních ploten, kde algoritmy rozpoznávají kolonie, odhadují jejich počet, barvu a morfologii, a tím napomáhají včasné detekci patogenů. Podobně přispívá AI i k zefektivnění práce v molekulární mikrobiologii, např. při hodnocení PCR křivek nebo sekvenčních dat. Stále větší roli hraje také v rámci automatizačních linek, které propojují robotickou manipulaci se vzorky s digitálním obrazovým záznamem a algoritmickým vyhodnocením.

V oblasti antimikrobiální rezistence slouží AI k analýze velkých souborů antibiogramů a genomických dat s cílem odhalovat vzorce rezistence, predikovat klinické dopady a podpořit rozhodování o antibiotické terapii. Systémy klinické podpory rozhodování (CDSS) integrují laboratorní výsledky a klinické informace a přinášejí personalizovanější přístup k antimikrobiální léčbě.

Zavádění AI je však spojeno s řadou výzev – od potřeby standardizace trénovacích dat přes validaci algoritmů až po jejich srozumitelnost pro koncové uživatele. Klíčovým přínosem je ale skutečnost, že umělá inteligence může mikrobiologům „uvolnit ruce“ od rutinní práce a umožnit jim věnovat více času odborné interpretaci a konziliární činnosti – tedy tam, kde jejich odbornost přináší největší přidanou hodnotu.

**Klíčová slova:** mikrobiologie, umělá inteligence, automatizace

## SUMMARY

**Hurych J, Dřevínek P. Perspectives on artificial intelligence in clinical microbiology**

Artificial intelligence (AI) has recently emerged as a revolutionary tool with the potential to fundamentally transform the operation of clinical microbiology laboratories. With its ability to automate routine tasks, analyze complex data sets, and recognize patterns often missed by the human eye, AI can significantly contribute to greater efficiency, standardization, and accuracy in laboratory diagnostics.

One of the key application areas is image data analysis—whether it involves interpreting microscopic smears (e.g., Gram staining) or digital reading of culture plates, where algorithms identify colonies, estimate their number, color, and morphology, thus supporting timely pathogen detection. AI also enhances workflows in molecular microbiology, for example, by evaluating PCR amplification curves or sequencing data. Increasingly, AI is being integrated into automated laboratory systems that combine robotic sample handling with digital imaging and algorithmic interpretation.

In the context of antimicrobial resistance (AMR), AI is used to analyze large datasets of antibiograms and genomic data to identify resistance patterns, predict clinical outcomes, and support decision-making regarding antibiotic therapy. Clinical decision support systems (CDSS) integrate laboratory results with clinical information, offering a more personalized approach to antimicrobial treatment.

However, the implementation of AI comes with several challenges—including the need for standardized training datasets, algorithm validation, and ensuring explainability for end-users. A key benefit remains the ability of AI to relieve microbiologists from repetitive manual work, enabling them to focus more on expert interpretation and consultative activities—precisely where their expertise delivers the highest added value.

**Key words:** microbiology, artificial intelligence, automation

**Korespondující autor:**

MUDr. Jakub Hurych, Ph.D.  
Ústav lékařské mikrobiologie 2. LF UK a FN Motol  
Praha  
jakub.hurych@lfmotol.cuni.cz

**ÚVOD**

Umělá inteligence (AI) se v posledních letech dynamicky rozvíjí napříč medicínskými obory a klinická mikrobiologie není výjimkou. Díky schopnosti analyzovat rozsáhlá a komplexní data, zautomatizovat rutinní činnosti a odhalit skryté vzorce v datech má AI potenciál zásadně proměnit každodenní laboratorní provoz. V situaci, kdy roste počet požadavků na rychlou a přesnou mikrobiologickou diagnostiku, může být AI významným nástrojem k zvýšení efektivity i kvality péče. Tento článek nabízí přehled aktuálních možností využití AI v mikrobiologické laboratoři a výhled na její další uplatnění.

**ANALÝZA OBRAZOVÝCH DAT – CESTA K AUTOMATIZOVANÉ INTERPRETACI**

Jedním z nejpřirozenějších míst, kde může AI v mikrobiologii najít uplatnění, je analýza mikroskopických nebo makroskopických obrazů. V současnosti se výzkumné týmy i výrobci diagnostických systémů snaží využít algoritmy strojového učení pro zjednodušení a urychlení činností, které byly dosud výhradně doménou zkušených odborníků.

**Automatická interpretace mikroskopických náěrů**

Interpretace mikroskopických preparátů, zejména barvených podle Grama, je v mikrobiologii základní, ale stále časově náročnou činností, která většinou stále vyžaduje účast zkušeného mikrobiologického pracovníka. AI se díky hlubokému učení (deep learning) dokáže naučit rozpoznávat jednotlivé buněčné a mikrobiální struktury, jako jsou bakterie, mykotická vlákna, protozoa, vajíčka mnohobuněčných parazitů, leukocyty nebo epitelové buňky, a určit jejich typ nebo množství. Tím pomůže zejména ve „filtrování“ rutinních vzorků, které jsou z mikrobiologického pohledu negativní, ale i v detekci suspektních struktur, na které je ihned upozorněn mikrobiologický pracovník, aniž by sám musel odečítat desítky zorných polí s rizikem přehlédnutí a nevýhodou značné časové ztráty. V budoucnu by taková technologie mohla sloužit nejen jako pomocník pro začínající mikrobiology, ale i jako nástroj pro standardizaci a zrychlení diagnostiky (nejen) v době nedostatku kvalifikovaného personálu.<sup>(1,2)</sup>

**Digitální vyhodnocování kultivačních nálezů**

Denním chlebem pracovníků v mikrobiologii je hodnocení nálezů na pevných kultivačních půdách, které vyžaduje mnoho pozornosti, pečlivosti a také zkušeností a neustálé kontroly. Nové systémy založené na počítačovém vidění a umělé inteligenci již dnes dokážou počítat kolonie, určovat jejich

barvu, tvar a velikost a tím napomoci s identifikací a klasifikací patogenů, například rezistentních kmenů enterokoků či stafylokoků (pokud jsou hodnoceny na selektivních půdách a/nebo chromogenních agarech). Některé algoritmy navíc dokážou s jistotou rozpoznat kompletně negativní kultivační plotny, a tak snížit potřebu manuálního dohledu běžných vzorků, které jsou negativní. Systémy jako DeepColony podle studií dosahují více než 99% shody při hodnocení negativních kultur a více než 95% při hodnocení kultur pozitivních.<sup>(3,4)</sup>

**AUTOMATIZACE PROCESŮ A OPTIMALIZACE PRACOVNÍCH TOKŮ**

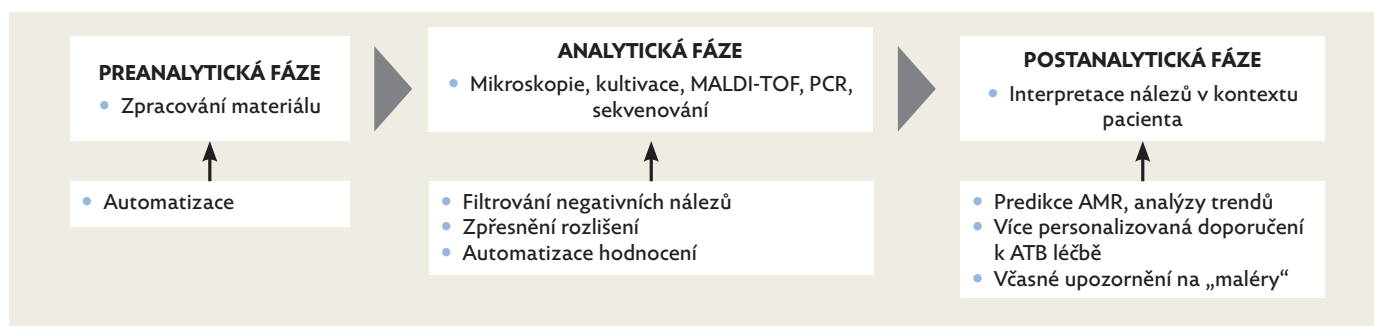
V moderní mikrobiologické laboratoři představují významnou část činností pracovníků jejich rutinní úkoly – od příjmu vzorků přes zadávání údajů, ukládání kultivačních ploten s vyočkováním materiálem do inkubátorů a jejich opakované vyjímání z inkubátorů pro odečet až po uzavření nálezů. Právě zde může umělá inteligence převzít iniciativu a ulevit laboratornímu personálu, který se tak může více soustředit na složitější analýzy, konzultace a interpretace. Skvělým příkladem je připravovaný software automatizačních linek na zpracování materiálu.

**Automatizační linky na zpracování materiálu**

Aby bylo možné reagovat na rostoucí požadavky a výzvy v laboratořích klinické mikrobiologie, zavádějí se automatizované pracovní stanice, jako jsou systémy BD Kiestra™ Total Lab Automation (Beckton Dickinson, NJ, USA) či WASPLab® (Copan Diagnostics, CA, USA), které zefektivňují dosavadní pracovní postupy a zvyšují produktivitu práce v laboratoři. Tyto systémy automatizují různé procesy, včetně označování destiček, očkování materiálu na plotny, inkubace ploten a zobrazování nálezů na plotnách (viz výše), čímž se snižuje čas, který laboratorní personál tráví manuálními úkony. Taková modulární konstrukce systémů umožňuje flexibilní konfiguraci a škálovatelnost, takže se lze přizpůsobit specifickým potřebám různých laboratoří. Automatizací rutinních úkolů umožňují tyto pracovní stanice mikrobiologům soustředit se na složitější analýzy a kritické rozhodování, což v konečném důsledku zlepšuje dobu zpracování a přesnost diagnóz. Sekundárně pak mikrobiologovi „uvolňuje ruce“ ke konziliární činnosti.

**Molekulární mikrobiologie**

V oblasti molekulární mikrobiologie se AI uplatňuje zejména při interpretaci výsledků PCR metod, včetně analýzy amplifikačních křivek nebo hodnocení dat ze sekvenování.



Obr. 1: Shrnutí přínosu AI v klinické mikrobiologii

AMR – antimikrobiální rezistence

V běžném provozu laboratorně vyvíjených testů či komerčních sad je manuální hodnocení často časově náročné a náchylné k chybám. AI nástroje mohou tento proces zrychlit a zpřesnit, čímž nejen šetří čas, ale zároveň zvyšují bezpečnost a kvalitu diagnostiky.<sup>(3)</sup> Konkrétně se může jednat o algoritmy strojového učení, které lze trénovat na historických datech, aby analyzovaly parametry kvality, kontrolovaly křivky PCR a prosazovaly pravidla kontroly kvality.<sup>(3)</sup> Jedním z příkladů je PCR.Ai, automatizovaný nástroj, který využívá strojové učení a logiku „if-then“ k automatizaci procesů po analýze PCR testů.

Algoritmy AI stále častěji používají k analýze různého typu sekvenčních dat pro účely charakterizace kmenů či molekulární epidemiologie. Nástroje založené na AI zefektivňují různé aspekty zpracování dat NGS (next generation sequencing), včetně kontroly kvality, taxonomického zařazení a detekce genů antimikrobiální rezistence.<sup>(5)</sup> Tato integrace snižuje složitost a čas potřebný pro analýzu.<sup>(4)</sup>

### MALDI-TOF MS – ještě přesnější spektrální analýza

Hmotnostní spektrometrie MALDI-TOF je již dnes zlatým standardem v identifikaci bakterií a většiny klinicky

významných mikromycét. Umělá inteligence zde může pomoci s jemnější analýzou spektrálních dat, zejména při rozlišení příbuzných druhů či v případech smíšených infekcí, kdy klasické softwarové algoritmy často selhávají.<sup>(4)</sup> Mohla by pomoci pro epidemiologickou surveillance, tj. porovnávání spekter a příbuznosti izolátů.

### UMĚLÁ INTELIGENCE V BOJI PROTI ANTIMIKROBIÁLNÍ REZISTENCI

Globální nárůst rezistence na antibiotika kladé vysoké nároky na sledování trendů, identifikaci rezistentních kmenů a predikci šíření rezistence i volbu vhodných terapeutických postupů, zahrnujících účinná antibiotika s co nejužším spektrem. AI může díky schopnosti pracovat s daty z nemocničního a laboratorního informačního systému a s obrovským množstvím dat z antibiogramů, sekvenčních analýz a klinických záznamů odhalovat vzorce a vztahy, které by jinak zůstaly skryté. Využívají se i pokročilé přístupy, jako je učení v grafech (graph-based machine learning), které dokážou propojovat informace o patogenu, genetických determinantech a klinických projevech.<sup>(2,3,6)</sup>

Tab. 1: Shrnutí přínosu AI v klinické mikrobiologii

| Oblast využití                        | Přínos AI                                                                                    | Výzvy spojené s využitím AI                                                |
|---------------------------------------|----------------------------------------------------------------------------------------------|----------------------------------------------------------------------------|
| Automatizace laboratorních procesů    | Zefektivnění práce pomocí automatizačních linek a jejich softwaru, snížení manuální zátěže   | Nutnost podpory 24/7 vzhledem k závislosti provozu na technologii          |
| Světelná mikroskopie                  | Rychlé filtrování negativních vzorků, detekce suspektních struktur, standardizace odečtu     | Falešně negativní/pozitivní odečty, nutnost trénovaných dat                |
| Kultivace                             | Rychlé filtrování negativních kultur, automatické počítání kolonií, detekce běžných patogenů | Falešně negativní/pozitivní odečty, nutnost trénovaných dat                |
| Hmotnostní spektrometrie (MALDI-TOF)  | Přesnější rozlišení příbuzných druhů, podpora detekce smíšených infekcí                      | Interpretace nejednoznačných výsledků – stále potřeba posouzení odborníkem |
| PCR a sekvenování                     | Automatizace hodnocení křivek, kontrola kvality, zrychlení analýz                            | Interpretace nejednoznačných výsledků – stále potřeba posouzení odborníkem |
| Monitoring antimikrobiální rezistence | Predikce rezistence, analýza trendů a vzorců na základě antibiogramů a genotypů              | Vysoké nároky na validaci a klinickou interpretaci                         |
| Klinická rozhodovací podpora (CDSS)   | Personalizovaná doporučení léčby, upozornění na nevhodné požadavky, podpora stewardshipu     | Vysoké nároky na validaci                                                  |

Využití AI sahá až k předpovídání výsledků léčby konkrétních pacientů a optimalizaci léčebných strategií prostřednictvím systémů klinické podpory rozhodování (clinical decision support systems, CDSS). Tyto systémy analyzují zdravotní záznamy pacientů, aby posoudily adekvátnost léčby a předpověděly potenciální problémy, jako jsou například neracionální požadavky na antibiotickou terapii. Díky integraci anamnézy pacienta, laboratorních výsledků a aktuálních klinických pokynů mohou CDSS pomáhat lékařům při informovaném rozhodování, podporovat správné používání antimikrobiálních látek a zlepšovat výsledky léčby pacientů. Komerční systémy jako LUMED (Biomérieux, Francie) jsou příkladem takových nástrojů, které využívají AI k poskytování informací v reálném čase založených na datech pro identifikaci patogenů a účinnost antibiotik.

V návaznosti na předchozí odstavec o MALDI-TOF jsou ve vývoji i nástroje AI schopné rozlišit producenty enzymů rezistentních k antibiotikům, jako třeba nebezpečných karbapenemáz, ze snadno dostupných spektrálních dat.<sup>(7)</sup>

## VÝZVY A PERSPEKTIVY DALŠÍHO VÝVOJE

Přestože AI nabízí mnoho slibných možností, její zavádění do běžného provozu naráží na řadu překážek. Jednou z hlavních je absence standardizovaných trénovacích dat a validačních metod, které by umožnily objektivní porovnání různých algoritmů. Dále je třeba, aby vývojáři lépe porozuměli potřebám klinických mikrobiologů a přizpůsobili nástroje reálným podmínkám laboratorní praxe. Klíčovou roli zde hraje tzv. vysvětlitelná AI (**explainable AI**), která umožňuje uživatelům pochopit, na základě jakých vstupů a mechanismů dochází k výstupům algoritmu.<sup>(8)</sup>

Do budoucna se očekává rozšíření AI do dalších oblastí mikrobiologie – od rychlejší detekce infekcí přes predikci klinických komplikací až po kontrolu nozokomiálních nákaz. AI nástroje mohou být rovněž propojeny s telemedicínou – díky digitalizaci obrazů umožní vzdálené konzultace a posudky i pro menší nebo komunitní laboratoře. Umělá inteligence nebude mikrobiology nahrazovat, ale doplňovat – například tím, že předzpracuje a předtřídí obrazová data a mikrobiologovi se pak „uvolní ruce“ a bude moci zaměřit svou pozornost na složitější či hraniční případy jak v diagnostické, tak konziliární činnosti.<sup>(3,4)</sup> |

### LITERATURA

1. **Smith KP, Kirby JE.** Image analysis and artificial intelligence in infectious disease diagnostics. *Clin Microbiol Infect* 2020; 26: 1318–1323.
2. **Tsitou VM, Rallis D, Tsekova M, Yanev N.** Microbiology in the era of artificial intelligence: transforming medical and pharmaceutical microbiology. *Biotechnology Biotechnological Equipment* 2024; 38.
3. **Dien Bard J, Prinzi AM, Larkin PM, et al.** Proceedings of the Clinical Microbiology Open 2024: artificial intelligence applications in clinical microbiology. *J Clin Microbiol* 2025; 63: e0180424.
4. **Smith KP, Wang H, Durant TJS, et al.** Applications of artificial intelligence in clinical microbiology diagnostic testing. *Clin Microbiol Newsletter* 2020; 42: 61.
5. **Wensel CR, Pluznick JL, Salzberg SL, et al.** Next-generation sequencing: insights to advance clinical investigations of the microbiome. *J Clin Invest* 2022; 132.
6. **Alsulmani A, Akhter N, Jameela F, et al.** The impact of artificial intelligence on microbial diagnosis. *Microorganisms* 2024; 12.
7. **Hamprecht A, Muhsal L, van Dijk CC, et al.** CarbaDetector: a machine learning model for detecting carbapenemase-producing enterobacterales from disk diffusion tests. *Research Square* (preprint platform): Carl von Ossietzky University Oldenburg 2025.
8. **Peiffer-Smadja N, Delliere S, Rodriguez C, et al.** Machine learning in the clinical microbiology laboratory: has the time come for routine practice? *Clin Microbiol Infect* 2020; 26: 1300–1309.