

# Umelá inteligencia v manažmente kardiovaskulárneho rizika: od digitálnej anamnézy k personalizovanej terapii

Artificial intelligence in cardiovascular risk management: from digital medical history to personalized therapy

Štefan Tóth<sup>1</sup>, Patrik Buček<sup>1</sup>, Adriana Jarolímková<sup>2</sup>, Pavol Fulop<sup>3</sup>, Mariana Dvorožňáková<sup>3</sup>, Tibor Porubán<sup>3</sup>, Marianna Barbierik Vachalcová<sup>3</sup>, Natália Vaňová<sup>4</sup>

<sup>1</sup>Kardiologická ambulancia, Kardiocomp s.r.o., Košice

<sup>2</sup>Klinika všeobecného lekárstva UPJŠ LF a Nemocnice AGEL Košice-Šaca a. s.

<sup>3</sup>Kardiologická klinika UPJŠ LF a VÚSCH, a. s., Košice

<sup>4</sup>Interná klinika UPJŠ LF a Nemocnice AGEL Košice-Šaca a. s.

✉ MUDr. Natália Vaňová, PhD., EMBA | natalia.vanova@upjs.sk | www.upjs.sk

Doručené do redakcie | Doručeno do redakce | Received 30. 12. 2025

Prijaté po recenzii | Přijato po recenzi | Accepted 8. 1. 2026

## Abstrakt

Umelá inteligencia (AI) predstavuje rýchlo sa rozvíjajúci nástroj s významným potenciálom zlepšiť manažment pacientov s kardiovaskulárnym (KV) rizikom. Cieľom tejto prehľadovej práce je zosumarizovať a kriticky zhodnotiť najnovšie poznatky z rokov 2020–2025 o využití AI v starostlivosti o vysokorizikových kardiologických pacientov so zameraním na aterosklerózu, arteriálnu hypertenziu, dyslipidémiu a komplexné hodnotenie KV-rizika. Úvodom poukazujeme na aktuálne systémové výzvy európskeho zdravotníctva, vrátane preťaženia ambulantnej starostlivosti, dlhých čakacích dób, rastúcej administratívnej záťaže a neefektívneho využívania času lekárov. Následne analyzujeme hlavné oblasti aplikácie AI v kardiológii: automatizované získavanie anamnestických a symptomatických údajov prostredníctvom chatbotov a digitálnych asistentov, AI-podporenú rizikovú stratifikáciu a predikciu KV-príhod, personalizovaný manažment hyperlipidémie vrátane identifikácie vysokorizikových jedincov a optimalizácie hypolipidemickej liečby, ako aj využitie AI v manažmente hypertenzie pri meraní krvného tlaku, výbere terapie a podpore adherencie. Osobitná pozornosť je venovaná komplexným AI-systémom pre podporu klinického rozhodovania a vzdialené monitorovanie pacientov. Prehľad dostupných štúdií poukazuje na vyššiu presnosť AI-modelov v porovnaní s tradičnými postupmi pri predikcii KV-rizika, schopnosť AI identifikovať subklinickú aterosklerózu na zobrazovacích vyšetreniach a potenciál strojového učenia pri individualizácii liečby. Na záver konštatujeme, že správne integrovaná AI môže významne prispieť k efektívnejšej prevencii a liečbe kardiovaskulárnych ochorení, zníženiu zaťaženia zdravotníckeho systému a zlepšeniu prognózy pacientov. Kľúčovými výzvami pre jej rutinné klinické využitie však zostávajú kvalitná klinická validácia, ochrana osobných údajov, transparentnosť algoritmov a zabezpečenie etického a vysvetliteľného použitia AI v medicíne.

**Kľúčové slová:** ateroskleróza – dyslipidémia – hypertenzia – kardiovaskulárne riziko – klinická podpora rozhodovania – personalizovaná medicína – umelá inteligencia

## Abstract

Artificial intelligence (AI) is a rapidly developing tool with significant potential to improve the management of patients with cardiovascular (CV) risk. The aim of this review is to summarize and critically evaluate the latest findings from 2020–2025 on the use of AI in the care of high-risk cardiology patients, focusing on atherosclerosis, arterial hypertension, dyslipidemia, and comprehensive CV risk assessment. We begin by pointing out the current systemic challenges facing European health-care, including the overload of outpatient care, long waiting times, growing administrative burdens, and the inefficient use of doctors' time. We then analyze the main areas of AI application in cardiology: automated collection of anamnestic and

symptomatic data through chatbots and digital assistants, AI-supported risk stratification and prediction of CV events, personalized management of hyperlipidemia, including the identification of high-risk individuals and optimization of hypolipidemic treatment, as well as the use of AI in the management of hypertension in blood pressure measurement, therapy selection, and adherence support. Special attention is paid to complex AI systems for clinical decision support and remote patient monitoring. A review of available studies points to the higher accuracy of AI models compared to traditional methods in predicting CV risk, the ability of AI to identify subclinical atherosclerosis in imaging tests, and the potential of machine learning in individualizing treatment. In conclusion, we note that properly integrated AI can significantly contribute to more effective prevention and treatment of CV diseases, reducing the burden on the healthcare system and improving patient prognosis. However, key challenges for its routine clinical use remain high-quality clinical validation, personal data protection, algorithm transparency, and ensuring the ethical and explainable use of AI in medicine.

**Keywords:** atherosclerosis – artificial intelligence – cardiovascular risk – clinical decision support – dyslipidemia – hypertension – personalized medicine

## Úvod

Kardiovaskulárne ochorenia (KVO) zostávajú jednou z hlavných príčin morbidita a mortality celosvetovo. Napriek pokrokom v prevencii a liečbe je manažment pacientov s vysokým kardiovaskulárnym (KV) rizikom naďalej náročný, najmä v kontexte starnúcej populácie, nedostatku zdravotníckeho personálu a obmedzených zdrojov v európskych zdravotníckych systémoch. Výsledkom sú preťažené ambulancie, dlhé čakacie doby a zhoršený prístup k starostlivosti, čo môže viesť k horším liečebným výsledkom, ak nebudú zavedené účinné riešenia [1]. Súčasne narastá administratívna záťaž lekárov, ktorí v niektorých prípadoch venujú dokumentácii viac času než samotnej starostlivosti o pacientov, čo znižuje kvalitu starostlivosti a prispieva k vyhoreniu zdravotníckeho personálu [2,3]. Na Slovensku je zaznamenaný mimoriadne vysoký počet ambulantných návštev, v priemere 11,0 lekárske konzultácií na obyvateľa ročne, čo patrí k najvyšším hodnotám v EÚ. Napriek častým kontaktom však klinická efektívnosť starostlivosti zostáva nízka – viac ako 90 % pacientov s veľmi vysokým KV-rizikom nedosahuje cieľové hodnoty LDL-cholesterolu (LDL-C) podľa odporúčaní ESC/EAS a nedostatočná je aj kontrola krvného tlaku a ďalších rizikových faktorov. Tieto údaje poukazujú na vysokú záťaž lekárov pri nízkom klinickom prínose návštev a zdôrazňujú potrebu systémových zmien v manažmente chronických pacientov [4]. V reakcii na tieto výzvy rastie záujem o prístupy zvyšujúce efektívnosť zdravotnej starostlivosti, najmä o digitalizáciu a umelú inteligenciu (Artificial Intelligence – AI). Svetová zdravotnícka organizácia (World Health Organization – WHO) aj regulačné authority, vrátane amerického Úradu pre kontrolu potravín a liečiv (Food and Drug Administration – FDA), podporujú implementáciu digitálnych inovácií a AI s cieľom zlepšiť dostupnosť a kvalitu starostlivosti, najmä pri chronických ochoreniach ako KVO. AI, zahŕňajúca techniky od expertných systémov po strojové učenie a hlboké neuronové siete, umožňuje analýzu veľkých dátových súborov a identifikáciu komplexných vzorov. Jej využitie v medicíne rýchlo rastie – do roku 2023 bolo schválených viac než 800 klinických AI-algortimov, pričom kardiológia patrí medzi vedúce odbory v ich počte [3,5].

Cieľom tejto prehľadovej práce je zosumarizovať a kriticky zhodnotiť súčasné dôkazy o využití AI v manažmente pacientov s KV-rizikom a posúdiť jej potenciál zlepšiť efektívnosť starostlivosti a kontrolu rizikových faktorov v klinickej praxi.

## AI pri získavaní anamnestických dát a ťažkosti pacienta za cieľom zefektívnenia manažmentu

Dôkladná anamnéza a kvalitná dokumentácia sú základom správnej diagnostiky a liečby, no v ambulantnej praxi sú často limitované časovým tlakom. Viaceré štúdie ukazujú, že lekári trávia viac času dokumentáciou a administratívou než priamou prácou s pacientmi. Podľa údajov lekári venujú len približne 27 % pracovného času klinickej interakcii, zatiaľ čo až 49 % času zaberá práca s elektronickou zdravotnou dokumentáciou (Electronic Health Record – EHR) a administratíva; priamo počas vyšetrenia môže až 37 % času pripadať na zapisovanie do EHR [2]. Za každú hodinu priamej konzultácie tak často nasledujú takmer 2 hodiny dokumentačných úloh, čo znižuje efektívnosť starostlivosti a významne prispieva k vyhoreniu lekárov a poklesu kvality poskytovanej zdravotnej starostlivosti.

AI môže tento proces zefektívniť viacerými spôsobmi. Jednou z možností je využitie chatbotov a virtuálnych asistentov pre predbežné pýtanie sa u pacienta. AI-chatbot dostupný 24 hodín denne 7 dní v týždni dokáže položiť pacientovi štandardizované otázky na príznaky, ich trvanie, závažnosť, rodinnú a osobnú anamnézu a pod, a získané údaje automatizovane zaznamenať do elektronického zdravotného záznamu. Takýto systém môže pacienta navigovať ešte pred návštevou lekára – napríklad posúdiť, či jeho symptómy vyžadujú neodkladnú starostlivosť alebo mu odporučí vyčkať na bežné vyšetrenie. Tým sa šetrí čas lekára v ambulancii, ktorý už dostane sumarizované anamnestické dáta a môže sa sústrediť na cielenejšie otázky a vyšetrenie (obr) [6].

Sľubným riešením na zníženie administratívnej záťaže a zvýšenie času pre pacienta je využitie AI na automatizáciu zdravotnej dokumentácie prostredníctvom ambientných

AI-záznamov, ktoré pasívne zaznamenávajú rozhovor lekára s pacientom a generujú klinické poznámky. Štúdie preukázali významné úspory času – pilotné nasadenie viedlo k približne 15 % skráteniu času písania poznámok a o 8,5 % nižšiemu času práce s EHR, čo predstavuje výraznú týždennú časovú úsporu [7]. Multicentrické údaje zároveň potvrdzujú redukcii dokumentačnej záťaže a umožnenie väčšieho zamerania lekárov na pacienta počas pracovného dňa [8]. Ďalšie pilotné hodnotenia uvádzajú, že ambientné AI-záznamy môžu znížiť čas strávený písaním poznámok o 15–20 % počas návštevy a znížiť čas po pracovnej dobe až o 30 %, čo poskytuje lekárom viac príležitostí na priame rozhovory s pacientmi [7]. Randomizovaný klinický pokus s využitím komerčných AI-záznamov (napr. Microsoft DAX či Nabla) pri 72 000 vyšetreniach preukázal približne 10 % zníženie času dokumentácie oproti bežnej starostlivosti, s pozitívnym vplyvom na pohodu lekárov [9]. Vo veľkých zdravotníckych systémoch (The Permanente Medical Group či Kaiser Permanente) sa tieto technológie spoločne použili v miliónoch kontaktov a pilotné analýzy naznačujú, že v reálnych podmienkach môže použitie AI-záznamov viesť k tisícim ušetrených hodín dokumentačnej práce ročne. Výsledkom bolo približne 15 791 (resp. > 15 700) hodín ušetreného času dokumentácie za jeden rok, čo zodpovedá ekvivalentu takmer 1 800 plných pracovných dní [10].

Okrem samotnej dokumentácie majú AI-chatboty a asistenčné veľké jazykové modely (Large Language Models – LLM) potenciál zefektívniť odpovede na patientske správy a následné administratívne úlohy. To môže znížiť záťaž rutinných úloh približne až o 77 % z hľadiska času potrebného na spracovanie odpovedí alebo správ, aj keď nie všetky odpovede nevyžadujú manuálne úpravy lekárom [11].

Tieto systémy vedú k zníženiu administratívnej záťaže, zlepšujú pohodu lekárov a znižujú mieru vyhorenia, čo potvrdzujú viaceré štúdie vrátane pilotných projektov s ambientnými AI-záznamami [8]. Hoci systematické prehľady upozor-

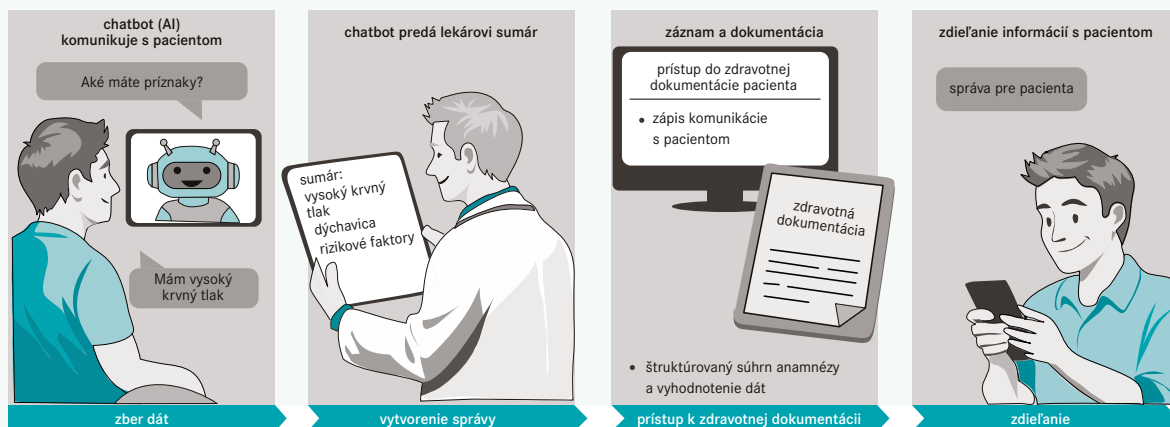
ňujú na heterogenitu dôkazov medzi špecialitami a spôsobi implementácie [3], dostupné údaje poukazujú na výrazný potenciál AI zefektívniť klinickú dokumentáciu a uvoľniť kapacity pre priamu starostlivosť o pacientov a samotnú diagnostiku. Celkovo dôkazy naznačujú, že správne integrované nástroje AI môžu znížiť administratívny čas o desiatky percent, zlepšiť kvalitu interakcií s pacientmi a prispieť k redukcii vyhorenia, pričom kľúčová zostáva dôsledná klinická validácia, tréning používateľov a kontrola kvality, aby sa tieto úspory premietli do reálnych benefitov pre pacientov aj zdravotnícke systémy.

### Využitie AI pri rizikovej stratifikácii pacienta (skórovacie systémy)

Včasná identifikácia vysokorizikového pacienta je kľúčová pre úspešnú prevenciu KV-príhod. Tradičné rizikové skórovacie systémy (napr. SCORE2, Framingham Risk Score, QRISK a pod) využívajú niekoľko klinických parametrov (vek, pohlavie, fajčenie, krvný tlak, hladina cholesterolu) na odhad pravdepodobnosti KV-príhod [12]. Tieto modely však majú obmedzenia – sú založené na populačných priemeroch a môžu prehliadať individuálne rozdiely alebo nedostatočne zohľadniť už preexistujúce subklinické zmeny (napr. začínajúcu aterosklerózu viditeľnú zobrazovacími metódami), ktorá môže kumulatívne výrazne zvýšiť samotné riziko. Umelá inteligencia ponúka možnosť výrazne spresniť rizikovú klasifikáciu integráciou oveľa širšieho spektra údajov s hľadaním komplexných vzorcov spojených s rizikom, ktoré by inak neboli zjavné, a tak môžu zlepšovať odhad KV-rizika [13,14].

Aktuálne štúdie ukazujú, že modely „strojového učenia“ (Machine Learning – ML) – vedia odhadnúť KV-riziko presnejšie než tradičné skóre. V prehľadovej analýze z roku 2024 autori uvádzajú, že AI-algoritmy dosahujú lepšiu individualizovanú prognózu rizika aterosklerózou podmieneného kardiovaskulárneho ochorenia (ASKVO) v porovnaní s bežnými

Obr | Schéma procesu podporovaného AI pomocou chatbotu



výpočtami [13]. Tieto AI-modely dokážu zohľadniť aj netradičné premenné: genetické markery, výsledky zobrazovacích vyšetrení, biomarkery ako vysoko senzitívne CRP (high-sensitivity CRP – (hsCRP), údaje fyzickej aktivity získané smart zariadeniami a pod, čím vytvoria komplexnejší obraz rizikového profilu pacienta. V priamom porovnaní s tradičnými modelmi (napr. Framingham Risk Score – FRS) dosahujú modely hlbokého učenia (Deep Neural Networks) vyššiu senzitivitu pri identifikácii budúcich príhod a znižujú mieru falošne negatívnych výsledkov [15]. V retrospektívnej kohorte 2 000 pacientov bez predchádzajúcej KV-príhody dosiahli AI-modely, najmä hlboké neuronové siete, výrazne vyššiu presnosť predikcie KV-príhod (Area Under the Curve/AUC, čo je plocha pod Receiver Operating Characteristic/ROC-krivkou: AUC vyjadruje diskriminačnú schopnosť modelu odlíšiť pacientov s budúcou príhodou od pacientov bez príhody; hodnota 0,91 predstavuje vysokú presnosť) v porovnaní s tradičnými skórovacími systémami FRS a ASKVO, ktoré dosiahli AUC len 0,76 a 0,74. Tieto výsledky naznačujú, že AI-prístupy dokážu spoľahlivejšie identifikovať vysokorizikových jedincov a môžu významne zlepšiť včasnú stratifikáciu rizika a preventívne stratégie v klinickej praxi [15].

Nedávna štúdia [16] ukázala, že automatizované strojové učenie (AutoML) dokáže významne zlepšiť stratifikáciu KV-rizika integráciou tradičných rizikových faktorov s biomarkermi, ako sú lipoprotein(a), troponín T a NTproBNP. Modely vyvinuté na kohortách LURIC (prospektívna kohorta pacientov s KV-rizikom) a UMC/M (kohorta pacientov sledovaných v univerzitnom medicínskom centre) dosiahli dobrú až vysokú prediktívnu presnosť pri predikcii jednotlivých KVO ako aj 10-ročnej KV-mortality (AUC 0,74–0,85) [16]. Vysvetliteľné AI-metódy (Shapley Additive Explanations – SHAP) zároveň identifikovali populačne špecifické determinanty rizika, čo podporuje využitie AutoML pre personalizované a lokálne adaptované hodnotenie KV-rizika. Podobne Gonzalez-Franco et al [17] demonštrovali, že pokročilé techniky segmentácie pacientov (k-means, Principal Component Analysis – PCA) umožňujú identifikovať odlišné skupiny pacientov s rozdielnym rizikom infarktu myokardu na základe biomarkerov, čím sa zlepšuje stratifikácia rizika nad rámec tradičných nástrojov.

Ďalšia štúdia [18] sledujúca atlétovej prezentovala hybridný AI-prístup kombinujúci pokročilé jazykové procesy (Natural Language Processing – NLP) a veľké jazykové modely s algoritmom strojového učenia na presnejšiu detekciu arytmií, hypertrofie kardiomyopatie a rizika náhlej srdcovej smrti. Integráciou štruktúrovaných aj neštruktúrovaných klinických dát (EKG, záznamy, genetika, zobrazovacie metódy) dosiahol systém vysokú diagnostickú presnosť (až 92,5 %, F1-skóre 95,6 %), čím prekonal tradičné metódy. Výsledky zdôrazňujú potenciál širokých jazykových modelov (Large Language Models – LLMs) v personalizovanej kardiológii a včasnej stratifikácii KV-rizika [18].

Jednou z najslubnejších oblastí je prepojenie AI s analýzou zobrazovacích dát na odhalenie subklinickej aterosklerózy.

Zobrazovacie metódy ako kalciové skóre koronárnych artérií (Coronary Artery Calcium – CAC) na CT alebo sonografia karotíd dokážu priamo detegovať aterosklerotické pláty ešte pred samotnou symptomatológiou. AI výrazne uľahčuje vyhodnocovanie takýchto vyšetrení – umožňuje automatickú detekciu aterosklerotických zmien a kvantifikáciu nálezu bez nutnosti zdĺhavého hodnotenia rádiológom [19]. Moderné AI-nástroje vedú identifikovať markery rizika ako koronárne kalcium naprieč rôznymi modalitami (špecializované CT s EKG-synchronizáciou, ale aj obyčajné RTG-snímky hrudníka). To znamená, že napríklad z bežného RTG pľúc (ktoré si pacient dá urobiť z iných dôvodov) dokáže AI „vyťažiť“ informáciu o prípadnej prítomnosti kalcifikácií koronárnych ciev a upozorniť na zvýšené KV-riziko. Weiss et al (2024) [20] vyvinuli deep learning model, ktorý z RTG-snímkov hrudníka predpovedal 10-ročné riziko závažných KV-príhod s AUC 0,76, čo je porovnateľné s tradičným klinickým štandardom. U pacientov s vysokým skóre AI-model predikoval významne vyššie riziko (adjusted Hazard Ratio 1,73; 95% CI 1,47–2,03) nezávisle od tradičných faktorov. Podobne Gallone et al (2025) [19] využili AI na odhad CAC-skóre z RTG-snímkov a preukázali schopnosť odhaliť subklinickú koronárnu aterosklerózu neinvazívne, pričom model dosiahol AUC až ~0,9 pre detekciu prítomnosti kalcifikátov.

Kombinácia klinických údajov s genomikou je ďalším prístupom, v ktorom AI preukazuje prínos. Príkladom je model NeuralCVD-DSM od Steinfeldta et al (2022) [21], ktorý integroval polygénne skóre (informácie o rizikových génových variantoch) s tradičnými rizikovými faktormi v neuronovej sieti. Výsledný model mal síce len o niečo vyšší C-index než štandardný (zlepšenie ~0,006), no významne zlepšil reklasifikáciu pacientov. Mnoho jedincov s pôvodne nízkym až stredným rizikom bolo správne prekategORIZOVANÝCH DO VYŠŠIEHO RIZIKA (alebo naopak) podľa skutočného výskytu príhod. Čiastočne tak AI pomohla odhaliť „skrytých“ vysokorizikových pacientov, ktorých by tradičný skórovací systém podcenil. Súčasné dôkazy naznačujú, že polygénové rizikové skóre (PRS) a AI významne zlepšujú stratifikáciu rizika aj u pacientov s familiárnou hypercholesterolémiou (FH). Veľká kohortová štúdia z roku 2025 ukázala, že osoby v najvyššom kvartile PRS pre koronárnu chorobu mali takmer 2-násobne vyššie riziko príhod (HR 1,92) nezávisle od tradičných faktorov [22]. AI-modely strojového učenia v tejto populácii prekonal konvenčné skórovacie systémy, keď dosiahli AUC približne 0,88 (ML model Survival RF) pre predikciu 10-ročných KV-príhod, oproti AUC 0,79 (SAFEHEART) pri tradičných skóre [23]. Navyše, AI-nástroj FIND-FH aplikovaný na elektronické zdravotné záznamy dokázal identifikovať skrytých pacientov s FH s vysokou presnosťou, pričom zachytil aj tých, ktorí nespĺňali klasické LDL-kritériá (> 4,9 mmol/l), čím sa screening stal efektívnejším [24].

Výsledky systematických prehľadov a metaanalýz z posledných rokov teda konsenzuálne naznačujú, že zapojením AI možno dosiahnuť presnejšie odhady KV-rizika, a tým cieľenejšie usmerniť preventívne stratégie. AI umožňuje tzv.

precision medicine prístup – riziková prognóza je „šitá na mieru“ konkrétnemu pacientovi na základe tisícok premenných, nie len zopár tradičných faktorov. V praxi to znamená, že lekári môžu lepšie rozhodnúť, ktorí pacienti profitujú z intenzívnej intervencie (napr. skoré nasadenie vysokých dávok statínov, agresívna liečba hypertenzie), a naopak ktorí majú riziko nízke a stačí im menej intenzívne sledovanie [13].

## Využitie AI v manažmente pacientov s lipitenziou

Dyslipidémia (predovšetkým zvýšené hladiny LDL-C) je jedným z hlavných faktorov rozvoja aterosklerózy. Napriek existencii medzinárodných odporúčaní však v populácii ostáva významná časť pacientov s nedostatočne kontrolovanými lipidmi alebo nediagnostikovanými poruchami (napr. familiárna hypercholesterolémia). AI môže pomôcť zlepšiť každý krok manažmentu hyperlipidémie – od identifikácie ohrozených osôb, cez presnejšiu diagnostiku a stratifikáciu, až po personalizovanú liečbu. V oblasti screeningu a diagnostiky dokáže strojové učenie vyhľadávať v databázach pacientov vzorce typické pre neliečenú alebo familiárnu hypercholesterolémiu (FH). Keďže FH má nízky záchyt (diagnostikovaných < 1 % nositeľov v populácii), algoritmy prečesávajúce milióny elektronických záznamov vedia označiť podozrivých jedincov pre cieleňé dovyšetrovanie. Luo et al [25] preukázali viacero inovatívnych prístupov v tejto oblasti, a to hlavne ML-modely založené nielen na laboratórnych profiloch pacientov, ale aj na analýze klinických dát. Napríklad algoritmus FAMCAT 2 (Familial Hypercholesterolaemia Case Ascertainment Tool, verzia 2), ktorý využíva údaje z primárnej starostlivosti, dosiahol výrazne vyššiu senzitivitu v porovnaní s Dutch Lipid Clinic Network a vyššiu špecificitu ako Simon Broome kritériá [26,27]. Pri odhade KV-rizika u pacientov s dyslipidémiou AI dokáže zlepšiť presnosť stanovenia kľúčových parametrov. Napríklad presný odhad hladín LDL-C je kritický pre stratifikáciu – bežne sa LDL-C počíta z Friedewaldovho vzorca, ktorý však zlyháva pri zvýšených hladinách triglyceridov. Nová štúdia publikovaná v roku 2025 preukázala, že ML-algoritmy vedú predpovedať LDL-C z lipidového profilu omnoho presnejšie než tradičné vzorce. V analýze dát od vyše 120 000 pacientov dosiahli modely Random Forest a XGBoost takmer dokonalú zhodu s priamym meraním LDL-C ( $R^2 = 0,94$ ; MSE = 89,25), čím prekonalí Friedewaldov vzorec ( $R^2 = 0,85$ ) aj novší Sampsonov vzorec, a to najmä u pacientov s hypertriglyceridémiou (> 3,4 mmol/l), kde presnosť tradičných vzorcov dramaticky klesala [28]. Presnejšie stanovenie LDL-C pomocou AI umožňuje lepšie rozhodnutia o liečbe – napr. identifikovať pacientov, ktorí už skutočne dosiahli cieľovú hodnotu, oproti tým, u ktorých je výsledok skreslený vysokými hladinami triglyceridov.

Najďalej sa však pokročilo v aplikácii AI pri personalizácii liečby hyperlipidémie, konkrétne terapie statínmi. Hoci existujú medzinárodné odporúčania, odpoveď na statíny sa individuálne líši. AI dokáže túto variabilitu riešiť analyzova-

ním obrovských súborov reálnych dát. Napríklad Xiong et al (2024) vyvinuli ML-model (Random Forest) na základe klinických dát, ktorý predpovedal účinnosť a bezpečnosť statínov. Model dosiahol vynikajúcu diskriminačnú schopnosť s AUC 0,883 pre predikciu dosiahnutia cieľovej hladiny LDL-C a ešte vyššou presnosťou pre predikciu nežiaducich účinkov – AUC 0,964 pre abnormality pečeneých enzýmov a AUC 0,981 pre svalové symptómy (abnormality kreatínkinázy). Zavedením takéhoto modelu do praxe by lekár mohol vopred identifikovať pacientov s vysokým rizikom nežiaducich účinkov alebo zlyhania liečby a zvoliť iný preparát či dávku [29].

Jednou z kľúčových oblastí aplikácie AI je presné a kontinuálne meranie krvného tlaku (TK). Tradičné meranie auskultačnou metódou je náchylné na chyby obsluhy a poskytuje len sporadické údaje. Moderné automatické tlakomery síce uľahčili meranie, no stále ide zväčša o prístroje s manžetou, ktoré nie sú ľahko prenosné a flexibilné na meranie [30]. AI umožnila vývoj bezmanžetových neinvazívnych meračov TK, ktoré využívajú signály ako pulzná tranzitná doba (Pulse Transit Time – PTT) z fotopletyzomografie. Tieto zariadenia kontinuálne odhadujú krvný tlak pomocou ML-algoritmov. Elgendí et al [31] vo svojej práci zdôrazňujú, že pre klinickú akceptáciu musia tieto AI-modely spĺňať prísne validačné štandardy American Association of Medical Instrumentation – AAMI/European Society of Hypertension – ESH (napr. 95 % meraní v tolerancii  $\pm 10$  mm Hg) a odporúčajú štandardizované postupy na vyhodnocovanie ich presnosti.

Ďalšou oblasťou je self-monitoring a podpora pacienta. Randomizované štúdie skúmajúce vplyv AI-driven aplikácií priniesli povzbudivé výsledky. V štúdií Leitnera et al (2024) [32] použitie plne digitálneho, autonómneho AI-koučingu viedlo k významnému zníženiu systolického TK o 8,1 mm Hg a diastolického o 5,1 mm Hg po 24 týždňoch. U pacientov s hypertenziou 2. stupňa bol pokles ešte výraznejší (systolický TK -14,2 mm Hg). Podiel pacientov s kontrolovaným tlakom sa zvýšil o 26,5 %, pričom systém vyžadoval len minimálny zásah lekára (5,9 % prípadov). Tieto výsledky naznačujú, že digitálne intervencie poháňané AI môžu byť rovnako účinné ako lieky v monoterapii [32]. Kľúčovou otázkou ostáva, ktorí pacienti potrebujú agresívnejšiu liečbu (cieľový systolický TK < 120 mm Hg). Štúdia ESPRIT (2024) potvrdila benefity intenzívnej liečby aj u starších pacientov, pričom dosiahla redukciu rizika KV-príhod o 12 % (HR 0,88; 95 % CI 0,78–0,99) v porovnaní so štandardnou liečbou (< 140 mm Hg) [33]. Hoci tieto výsledky podporujú prísnejšie ciele, ich bezpečná implementácia v klinickej praxi si vyžaduje precízny monitoring a personalizáciu, kde práve technológie umelej inteligencie – od presného merania až po podporu adhenencie – zohrávajú kľúčovú úlohu.

Okrem intenzity liečby stojí lekár pred voľbou konkrétneho antihypertenzíva. Štandardne sa postupuje metódou pokus-omyl, no AI dokáže tento proces zefektívniť. Ye et al (2020) [34] využili hlboké neurónové siete (Long Short-Term Memory – LSTM) na analýzu dát z elektronických záznamov 245 499 pacientov. Ich model dokázal predpovedať pravde-

podobnosť dosiahnutia cieľového tlaku pri rôznych liečebných režimoch s vysokou presnosťou (AUC > 0,85). Model identifikoval optimálne liečebné cesty pre jednotlivcov, ktoré sa často líšili od všeobecných odporúčaní, najmä u pacientov s komorbiditami, kde štandardné postupy zlyhávali. Takýto nástroj môže slúžiť ako „GPS navigácia“ pre lekára pri výbere lieku [34].

Napokon, AI našla uplatnenie aj v riešení adhirencie. Li et al [35] využili ML-segmentačnú analýzu (Chi-square Automatic Interaction Detection) na dátach z New York City Community Health Survey. Identifikovali, že medzi mladými dospelými (18–44 rokov) boli najväčším rizikom neadherencie belosi, Ázijci a Hispánci bez diabetu (pravdepodobne pre podceňovanie asymptomatického ochorenia). Naopak, u starších pacientov (45–65 rokov) hrali rolu socio-ekonomické faktory (poistenie a bydlisko).

Umělá inteligencia prináša do manažmentu hypertenzie hmatateľné inovácie: od presnejších bezmanžetových meraní, cez autonómny digitálny koučing s preukázaným účinkom na zníženie TK, až po personalizované predikčné modely pre výber liečby. Klinické dôkazy naznačujú, že AI sa stáva nevyhnutným nástrojom pre modernú kardiológiu.

## Záver

Umělá inteligencia sa v posledných rokoch etablovala ako významný nástroj v manažmente KV-rizika, keď zlepšuje stratifikáciu rizika a identifikáciu vysokorizikových pacientov prostredníctvom integrácie komplexných klinických, genetických a zobrazovacích dát. V oblasti personalizovanej liečby dyslipidemií a hypertenzie AI preukázateľne prekonáva tradičné prístupy, či už ide o presnejší výpočet LDL-C, optimalizáciu statínovej terapie alebo predikciu individuálnej odpovede na antihypertenzíva.

Popri klinických prínosoch má AI potenciál zmierniť aj systémové zaťaženie zdravotníctva. Automatizácia zberu anamnézy a využitie ambientných AI-záznamov významne redukuje administratívnu záťaž, šetria čas lekárov a umožňujú väčší dôraz na priamu interakciu s pacientom, čo môže prispieť k zníženiu profesionálneho vyhorenia. Inovatívne preventívne prístupy, ako kontinuálny monitoring krvného tlaku či digitálny koučing, zároveň zlepšujú kontrolu rizikových faktorov a adhirenciu k liečbe. Napriek týmto prínosom zostáva nevyhnutná dôsledná klinická validácia a citlivá integrácia AI do praxe, s dôrazom na personalizáciu a zachovanie kľúčovej úlohy lekára pri interpretácii dát.

Záverom možno konštatovať, že pri správnej implementácii predstavuje AI-transformačný prvok modernej kardiológie – od včasného záchytu subklinickej aterosklerózy až po precíznu, preventívne orientovanú starostlivosť, z ktorej profitujú predovšetkým pacienti.

## Literatúra

1. OECD/European Commission. Health at a Glance: Europe 2024. State of Health in the EU Cycle. OECD Publishing. Paris. Dostupné z DOI: <https://doi.org/10.1787/b3704e14-en>.

2. Sinsky C, Colligan L, Li L et al. Allocation of physician time in ambulatory practice: A time and motion study in 4 specialties. *Ann Intern Med* 2016; 165(11): 753–760. Dostupné z DOI: <https://doi.org/10.7326/M16-0961>.

3. Sasseville M, Yousefi F, Ouellet S et al. The impact of AI scribes on streamlining clinical documentation: A systematic review. *Healthcare (Basel)* 2025; 13(12): 1447. Dostupné z DOI: <https://doi.org/10.3390/healthcare13121447>.

4. Toth S, Turek M, Pella D. Success in achieving LDL-C target values in a high-risk population in Slovakia: the SlovakLipid retrospective study. *Arch Med Sci* 2023; 21(3): 738–746. Dostupné z DOI: <https://doi.org/10.5114/aoms/170961>.

5. Mathur P, Srivastava S, Xu X et al. Artificial Intelligence, Machine Learning, and Cardiovascular Disease. *Clin Med Insights Cardiol* 2020; 14: 1179546820927404. Dostupné z DOI: <https://doi.org/10.1177/1179546820927404>.

6. Hindelang M, Zink A, Egeberg A. Transforming health care through chatbots for medical history-taking and future directions: Comprehensive systematic review. *JMIR Med Inform* 2024; 12: e56628. Dostupné z DOI: <https://doi.org/10.2196/56628>.

7. Pearlman K, Wan W, Shah SD et al. Use of an AI scribe and electronic health record efficiency. *JAMA Network Open* 2025; 8(10): e2537000. Dostupné z DOI: <https://doi.org/10.1001/jamanetworkopen.2025.37000>.

8. Olson KD, Patel SV, Ryu S. Use of ambient AI scribes to reduce administrative burden and professional burnout. *JAMA Network Open* 2025; 8(10): e2534976. Dostupné z DOI: <https://doi.org/10.1001/jamanetworkopen.2025.34976>.

9. UCLA Health. UCLA study finds AI scribes may reduce documentation time and improve physician well-being. *UCLA Health Newsroom* 2025. Dostupné z WWW: <https://www.uclahealth.org/news/release/ucla-study-finds-ai-scribes-may-reduce-documentation-time>.

10. American Medical Association. 2025. AI scribes save 15,000 hours—and restore the human side of medicine. Dostupné z WWW: <https://www.ama-assn.org/practice-management/digital-health/ai-scribes-save-15000-hours-and-restore-human-side-medicine>.

11. Chen S, Eagan B, Chen M. The impact of responding to patient messages with large language models. *arXiv preprint arXiv* 2023; 2310.17703. Dostupné z DOI: <https://doi.org/10.48550/arXiv.2310.17703>.

12. Ridker PM, Bhatt DL, Pradhan AD et al. Inflammation and cholesterol as predictors of cardiovascular events among patients receiving statin therapy: A collaborative analysis of three randomized trials. *The Lancet* 2023; 401(10384): 1293–1301. Dostupné z DOI: <https://doi.org/10.1016/S0140-6736(23)00215-5>.

13. Cai Y, Cai YO, Tang LY et al. Artificial intelligence in the risk prediction models of cardiovascular disease and development of an independent validation screening tool: a systematic review. *BMC Med* 2024; 22(1): 56. Dostupné z DOI: <https://doi.org/10.1186/s12916-024-03273-7>.

14. Nogimori Y, Sato K, Takamizawa K et al. Prediction of adverse cardiovascular events in children using artificial intelligence-based electrocardiogram. *Int J Cardiol* 2024; 406: 132019. Dostupné z DOI: <https://doi.org/10.1016/j.ijcard.2024.132019>.

15. Agarbattiwala MM, Iqbalbhai SA, Patel P. Comparative study of artificial intelligence-driven diagnostic models and traditional risk scores in predicting cardiovascular events. *Eur J Cardiovasc Med* 2025; 15(4): 323–326. Dostupné z DOI: <http://dx.doi.org/10.61336/ejcm/25-04-60>.

16. Bibi I, Schaffert D, Blanke P et al. Cardiovascular risk assessment enhanced by automated machine learning in a multi-phase study. *Sci Rep* 2025; 15(1): 36474. Dostupné z DOI: <https://doi.org/10.1038/s41598-025-24189-z>.

17. Gonzalez-Franco JD, Galaviz-Mosqueda A, Villarreal-Reyes S et al. Revolutionizing cardiac risk assessment: AI-powered patient segmentation using advanced machine learning techniques. *Mach Learn Knowl Extr* 2025; 7(2): 46. Dostupné z DOI: <https://doi.org/10.3390/make7020046>.

18. Li A, Wang Y, Chen H. AI driven cardiovascular risk prediction using NLP and Large Language Models for personalized medicine in athletes. *SLAS Technol* 2025; 32: 100286. Dostupné z DOI: <https://doi.org/10.1016/j.slast.2025.100286>.

19. Gallone G, Belmonte M, Conte E. Detection of subclinical atherosclerosis by image-based deep learning on chest radiographs. *Eur Heart J Digit*

- Health 2025; 6(4): 567–576. Dostupné z DOI: <<https://doi.org/10.1093/ehjdh/ztaf033>>.
20. Weiss J, Raghu VK, Bontempi D et al. Deep learning to estimate cardiovascular risk from chest radiographs: A risk prediction study. *Ann Intern Med* 2024; 177(4): 409–417. Dostupné z DOI: <<https://doi.org/10.7326/M23-1898>>.
21. Steinfeldt J, Buerger T, Look L et al. Neural network-based integration of polygenic and clinical information: development and validation of a prediction model for 10-year risk of major adverse cardiac events in the UK Biobank cohort. *Lancet Digit Health* 2022; 4(2): e84–e94. Dostupné z DOI: <[https://doi.org/10.1016/S2589-7500\(21\)00249-1](https://doi.org/10.1016/S2589-7500(21)00249-1)>.
22. Paquette M, Trinder M, Ruel I et al. Polygenic risk score for coronary artery disease predicts atherosclerotic cardiovascular disease in familial hypercholesterolemia. *J Clin Lipidol* 2025; 19(3): 595–604. Dostupné z DOI: <<https://doi.org/10.1016/j.jacl.2025.01.004>>.
23. Zamora A, Masana L, Civeira F et al. Prognostic stratification of familial hypercholesterolaemia patients using AI algorithms: a gender-specific approach. *Eur Heart J Digit Health* 2025; 6(6): 1113–1123. Dostupné z DOI: <<https://doi.org/10.1093/ehjdh/ztaf092>>.
24. Carter SV, Triana T, Basit M et al. Performance of the FIND-FH machine learning algorithm for the identification of individuals with suspected familial hypercholesterolemia. *J Clin Lipidol* 2025; 19(4):1037–1043. Dostupné z DOI: <<https://doi.org/10.1016/j.jacl.2025.06.009>>.
25. Luo RF, Wang JH, Hu LJ et al. Applications of machine learning in familial hypercholesterolemia. *Front Cardiovasc Med* 2023; 10: 1237258. Dostupné z DOI: <<https://doi.org/10.3389/fcvm.2023.1237258>>.
26. Mohammadnia N, Akyea RK, Qureshi N et al. Electronic health record-based facilitation of familial hypercholesterolaemia detection sensitivity of different algorithms in genetically confirmed patients. *Eur Heart J Digit Health* 2022; 3(4): 578–586. Dostupné z DOI: <<https://doi.org/10.1093/ehjdh/ztaf059>>.
27. Osei J, Razavi AC, Otchere B et al. A Scoping Review of Electronic Health Records-Based Screening Algorithms for Familial Hypercholesterolemia. *JACC Adv* 2024; 3(12): 101297. Dostupné z DOI: <<https://doi.org/10.1016/j.jacadv.2024.101297>>.
28. Meng JB, An ZJ, Jiang CS. Machine learning-based prediction of LDL cholesterol: Performance evaluation and validation. *PeerJ* 2025; 13: e19248. Dostupné z DOI: <<https://doi.org/10.7717/peerj.19248>>.
29. Xiong Y, Liu X, Wang Q et al. Machine learning-based prediction model for the efficacy and safety of statins. *Front Pharmacol* 2024; 15: 1334929. Dostupné z DOI: <<https://doi.org/10.3389/fphar.2024.1334929>>.
30. Stergiou GS, Mukkamala R, Avolio A et al. Cuffless blood pressure measuring devices: Review and statement by the European Society of Hypertension Working Group on Blood Pressure Monitoring and Cardiovascular Variability. *J Hypertens* 2022; 40(8): 1449–1460. Dostupné z DOI: <<https://doi.org/10.1097/HJH.0000000000003224>>.
31. Elgendi M, Fletcher R, Ward R. Recommendations for evaluating photoplethysmography-based algorithms for blood pressure assessment. *Commun Med (Lond)* 2024; 4(1): 555. Dostupné z DOI: <<https://doi.org/10.1038/s43856-024-00555-2>>.
32. Leitner J, Chiang PH, Agnihotri P et al. The effect of an AI-based, autonomous, digital health intervention using precise lifestyle guidance on blood pressure in adults with hypertension: Single-arm nonrandomized trial. *JMIR Cardio* 2024; 8: e51916. Dostupné z DOI: <<https://doi.org/10.2196/51916>>.
33. Liu J, Li Y, Ge J et al. Lowering systolic blood pressure to less than 120 mm Hg versus less than 140 mm Hg in patients with high cardiovascular risk with and without diabetes or previous stroke: an open-label, blinded-outcome, randomised trial. *Lancet* 2024; 404(10449): 245–255. Dostupné z DOI: <[https://doi.org/10.1016/S0140-6736\(24\)01028-6](https://doi.org/10.1016/S0140-6736(24)01028-6)>.
34. Ye X, Zeng QT, Facelli JC et al. Predicting Optimal Hypertension Treatment Pathways Using Recurrent Neural Networks. *Int J Med Inform* 2020; 139: 104122. Dostupné z DOI: <<https://doi.org/10.1016/j.ijmedinf.2020.104122>>.
35. Li Y, Jasani F, Su D et al. Decoding Nonadherence to Hypertensive Medication in New York City: A Population Segmentation Approach. *J Prim Care Community Health* 2019; 10: 2150132719829311. Dostupné z DOI: <<https://doi.org/10.1177/2150132719829311>>.