

Regionální anestezie je oblastí, kde již existují komerčně dostupné AI nástroje pro ultrazvukovou asistenci: software může v reálném čase zvýraznit předpokládané sonoanatomické struktury a podpořit orientaci uživatele [33]. Dosavadní evidence podporuje zejména získání kvalitního ultrazvukového obrazu a jeho interpretaci, dále výuku a podporu méně zkušených uživatelů, zatímco dopad na klinické výsledky, bezpečnost blokad, úspěšnost výkonu nebo četnost komplikací zůstává zatím nedostatečně doložený [33]. Samostatně je třeba odlišit AI-asistovanou neuroaxiální ultrasonografii, například automatizovanou identifikaci spinálních orientačních bodů a odhad hloubky vpichu, která odpovídá spíše fázi časného klinického hodnocení [34]. Technologie navázané na sledování jehly, predikci úspěchu blokady nebo poloautomatizované vedení výkonu zůstávají převážně vývojovými koncepty a neměly by být prezentovány jako klinicky ověřené nástroje [33]. Některé komerční nástroje jsou již dostupné pro klinické použití, jejich dostupnost však nelze zaměňovat za běžnou auditovanou praxi s prokázaným dopadem na klinický výsledek [33].

3. Pooperační fáze: časné varování, bolest a předání péče

Pooperační fáze představuje období, ve kterém může AI propojit předoperační riziko, intraoperační průběh a časná data z jednotky poanestetické péče, standardního oddělení nebo intenzivní péče. Prakticky lze predikční nástroje v této fázi chápat především jako systémy časného varování, které sledují vitální funkce, laboratorní hodnoty a klinické události a upozorňují na pacienta, jehož trajektorie se odchyluje od očekávaného průběhu. Dalšími oblastmi vývoje jsou objektivizace pooperační bolesti nebo standardizace pooperačního předání péče.

V pooperační péči, zejména u pacientů sledovaných na jednotce intenzivní péče, se využití umělé inteligence překrývá s širší oblastí intenzivní medicíny. AI nástroje jsou zde zkoumány především jako podpora prognostiky, analýzy kontinuálních dat a časného rozpoznání klinické deteriorace, například při sepsi, akutním poškození ledvin nebo rozvoji respirační insuficience [2, 35, 36]. Jejich přenos do specificky pooperačního kontextu však nelze považovat za samozřejmý, protože mnohé dostupné příklady vycházejí z obecné perioperační nebo ICU populace a pooperačně specifická validační data zůstávají omezená [36]. Podmínky bezpečného použití predikčních modelů, zejména vztah k cílové populaci, lokální validaci, kalibraci, začlenění do pracovního postupu a návaznosti na konkrétní klinickou reakci, byly rozvedeny výše a platí i pro níže uvedené pooperační příklady.

Časná predikce sepse patří k nejvíce zkoumaným oblastem ICU AI. Některé modely dosahují v retrospektivních validacích slibné diskriminační schopnosti. Například Artificial Intelligence Sepsis Expert v retrospektivní kohortě ICU pacientů predikoval rozvoj sepse 4–12 hodin před definovaným nástupem sepse podle Sepsis-3 s AUC přibližně 0,83–0,85. Klinická užitečnost modelu však vyžaduje prospektivní ověření [37]. Externí validace široce implementovaného modelu Epic Sepsis Model u hospitalizovaných pacientů v jednom akademickém centru ukázala podstatně nižší výkon, než byl uváděn v původních vývojových údajích, s hospitalizační AUC 0,63 [38]. Tento rozdíl dobře ilustruje obecný problém AI nástrojů: vysoký výkon v původní

validační kohortě nemusí být reprodukován v odlišném klinickém prostředí.

Podobně jsou rozvíjeny modely pro časnou predikci akutního poškození ledvin u kriticky nemocných. Retrospektivní multicentrická a multinacionální validace modelu využívajícího rutinně dostupná data ukázala AUC přibližně 0,88–0,91 pro predikci středně těžkého až těžkého akutního poškození ledvin stadia 2/3 podle KDIGO během pobytu na jednotce intenzivní péče. Klinický přínos takového modelu však vyžaduje prospektivní ověření [39].

Pooperačně specifictějším příkladem je predikce pooperační nauzey a zvracení (PONV). Monocentrická retrospektivní studie vývoje a interní validace modelu na souboru 35 003 pacientů dosáhla AUC 0,872 pro časnou PONV během pobytu v PACU a 0,708 pro opožděnou PONV během prvních 24 pooperačních hodin a v uváděných metrikách překonala Apfelovo a Koivurantovo rizikové skóre. Externí validace a dopad na klinické výsledky však zatím doloženy nejsou [40].

Výzkumně zajímavou oblastí je také objektivizace pooperační bolesti. Prospektivní observační studie ukázala, že model hlubokého učení založený na analýze obličejové mimiky může rozpoznávat zejména těžkou pooperační bolest. V klinickém datovém souboru 3 411 obrazů od 503 pooperačních pacientů dosáhl AUC 0,898 pro klasifikaci těžké bolesti [41]. Tento přístup může být užitečný jako doplňkový signál u pacientů, u nichž je sebehodnocení bolesti obtížné, nelze jej však chápat jako náhradu pacientova vlastního hodnocení bolesti ani klinického vyšetření. Dopad podobných nástrojů na kvalitu analgetického managementu nebo patientské výsledky zatím nebyl prokázán [41].

Další perspektivní oblastí je standardizace pooperačního předání péče. Velké jazykové modely by mohly být využity k přípravě návrhu souhrnu pro předání péče (hand-off souhrn), průběhu anestezie, rizikových událostí, doporučené monitorace a analgetického plánu [8, 9]. Hodnota takového nástroje by však vznikala pouze tehdy, pokud by výstup odpovídal skutečnému průběhu výkonu, byl ověřen lékařem a byl začleněn do lokálního způsobu předávání péče. Přehled literatury k LLM v perioperační medicíně podporuje jejich potenciál pro vybrané edukační, dokumentační a klasifikační úlohy, nikoli však dostatečně prospektivně validované použití jako specifického pooperačního hand-off nástroje [8]. Finální předání musí zůstat schopné auditu a odpovědnost za jeho obsah zůstává na lékaři [9].

Implementace, regulace a klinická odpovědnost

Z výše uvedeného přehledu je patrné, že vzniká zřetelná mezera mezi vývojem a klinickou implementací AI nástrojů („development-to-implementation gap“) [5]. Hlavní implementační bariéry, které mohou bránit přenosu AI nástrojů z fáze vývoje, validace nebo časné implementace do bezpečného klinického provozu, shrnuje **tabulka 1**.

Detailní rozbor všech oblastí implementačních bariér přesahuje možný rozsah tohoto článku. Proto budou dále podrobněji rozvedeny dvě vybrané oblasti: lidské a edukační faktory, které jsou v současnosti intenzivně diskutovány v odborné komunitě, a regulační oblast, která je zcela zásadní pro odpovědnou implementaci AI nástrojů do klinické praxe.