

UNIVERZITA PARDUBICE
FAKULTA ZDRAVOTNICKÝCH STUDIÍ

DIPLOMOVÁ PRÁCE

2025

Bc. Petra Slavíková

Univerzita Pardubice
Fakulta zdravotnických studií

Role umělé inteligence při zjišťování pooperačního deliria

Diplomová práce

2025

Bc. Petra Slavíková

Univerzita Pardubice
Fakulta zdravotnických studií
Akademický rok: 2023/2024

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Bc. Petra Slavíková**
Osobní číslo: **Z23228**
Studijní program: **N0913P360006 Specializace v ošetrovatelství – Perioperační péče**
Téma práce: **Role umělé inteligence při zjišťování pooperačního deliria**
Téma práce anglicky: **The Role of Artificial Intelligence in Detecting Postoperative Delirium**
Zadávací katedra: **Katedra porodní asistence, perioperační péče a zdravotně sociální péče**

Zásady pro vypracování

1. Studium literatury, sběr informací a popis současného stavu řešené problematiky.
2. Stanovení cílů a metodiky práce.
3. Příprava a realizace průzkumného šetření dle stanovené metodiky.
4. Analýza a interpretace získaných dat.
5. Zhodnocení výsledků práce.

Rozsah pracovní zprávy: **50 stran**
Rozsah grafických prací: **dle doporučení vedoucího**
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

Literatura dle doporučení vedoucího závěrečné práce.

Vedoucí diplomové práce: **doc. Petra Mandysová, MSN, Ph.D.**
Katedra ošetřovatelství

Datum zadání diplomové práce: **1. prosince 2023**

Termín odevzdání diplomové práce: **16. dubna 2025**

doc. RNDr. ThLic. Karel Sládek, Ph.D., MBA v.r.
děkan

L.S.

Mgr. Helena Poláčková v.r.
vedoucí katedry

V Pardubicích dne 5. března 2025

PROHLÁŠENÍ AUTORA

Prohlašuji:

Práci s názvem Role umělé inteligence při zjišťování pooperačního deliria, jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury. Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše. Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 8. 04. 2025

Bc. Petra Slavíková v. r.

PODĚKOVÁNÍ

Na tomto místě bych ráda poděkovala paní doc. Petře Mandysové, MSN, Ph.D. za cenné rady, ochotu a čas při vedení diplomové práce. Na závěr bych chtěla poděkovat mé rodině, která mě celou dobu podporovala a byla mi oporou.

NÁZEV

Role umělé inteligence při zjišťování pooperačního deliria

ANOTACE

Pooperační delirium (POD) je častou a závažnou komplikací po chirurgické operaci. Díky němu se zvyšuje morbidita, mortalita a délka hospitalizace. Diplomová práce se zaměřuje na přehled odborné literatury a studií na danou problematiku. Je rozdělena na teoretickou část a na systematický přehled. V teoretické části se zaměřuje na důležité pojmy a definice, které navazují a jsou úzce spjaty se systematickým přehledem. Ve druhé části práce je popsána metodika a interpretace dohledaných studií. Hlavním cílem práce bylo zmapování odborné literatury a studií. Dále zjištění jejich relevantnosti a následné zhodnocení užitečnosti dohledaných studií.

KLÍČOVÁ SLOVA

perioperační péče, pooperační delirium, predikce, strojové učení, umělá inteligence

TITLE

The Role of Artificial Intelligence in Detecting Postoperative Delirium

ANNOTATION

Postoperative delirium (POD) is a common and serious complication following surgical operations. It leads to increased morbidity, mortality, and length of hospital stay. This thesis focuses on a review of professional literature and studies related to this issue. It is divided into a theoretical part and a systematic review. The theoretical part addresses key concepts and definitions that are closely linked to the systematic review. The second part of the thesis describes the methodology and interpretation of the retrieved studies. The main objective of the thesis was the mapping of scientific literature and studies. Further assessing of their relevance and subsequent evaluation of the usefulness of the retrieved studies.

KEYWORDS

Artificial Intelligence, Machine Learning, perioperative nursing, postoperative delirium, prediction

OBSAH

Úvod	12
1 Cíle a metody práce	13
1.1 Cíl teoretické části	13
1.2 Hlavní cíl práce	13
1.3 Metody k dosažení cíle	13
Teoretický přehled	14
2 Úvod do problematiky pooperačního deliria	14
2.1 Definice pooperačního deliria	14
2.2 Epidemiologie	15
2.3 Etiologie a patofyziologie	15
2.4 Typy pooperačního deliria	15
2.5 Rizika pro vznik pooperačního deliria	16
2.6 Diagnostika	17
2.6.1 Nástroje pro diagnostiku pooperačního deliria	17
2.7 Léčba deliria	19
2.7.1 Nefarmakologická léčba	19
2.7.2 Kauzální léčba	19
2.7.3 Farmakologická léčba	19
2.8 Dopad pooperačního deliria na pacienta a společnost	20
3 Umělá inteligence obecně	21
3.1 Základní principy AI	21
3.2 Modely strojového učení	21
3.3 Modely hlubokého učení	22
3.4 Umělá inteligence ve zdravotnictví	22

3.4.1	Výhody implementace umělé inteligence ve zdravotnictví.....	23
3.4.2	Bezpečnost využití umělé inteligence ve zdravotnictví.....	23
3.5	Využití umělé inteligence při managementu a v predikci pooperačního deliria	23
3.6	Role sestry při používání umělé inteligence	24
3.7	Využití umělé inteligence v České republice	25
3.7.1	Robotická chirurgie v České republice.....	25
4	Shrnutí teoretické části.....	26
	Systematický přehled.....	27
5	Cíl systematického přehledu	27
5.1	Metodika rešeršní části	27
5.2	Formulace klinické otázky.....	27
5.3	Identifikace relevantních zdrojů	28
5.3.1	Vyhledávací strategie.....	28
5.3.2	Definice klíčových pojmů.....	28
5.4	Posouzení kvality zdrojů.....	30
5.4.1	Validita studie	30
5.4.2	Posouzení výsledků	30
5.4.3	Užitečnost výsledků.....	30
5.4.4	Stanovená kritéria pro zařazení a vyloučení studií	31
5.5	Sumarizace výsledků	34
5.6	Interpretace výsledků.....	35
6	Diskuze	50
6.1	Shrnutí analyzovaných studií.....	50
6.2	Porovnání studií	50
6.3	Limity studií.....	51
6.4	Limity práce.....	52
6.5	Doporučení pro budoucí výzkum (stáhnout pro perioperační péči)	52

Závěr.....	54
7 Použitá literatura.....	56
8 Přílohy.....	62

SEZNAM OBRÁZKŮ A TABULEK

Obrázek 1 – Prisma flow diagram 2020 (adaptováno z PRISMA Statement)

Tabulka 1 – PICO

Tabulka 2 – PICO anglický jazyk

Tabulka 3 – Klíčový pojem v oblasti Patient

Tabulka 4 – Klíčový pojem v oblasti Interest

Tabulka 5 – Klíčový pojem v oblasti Context

Tabulka 6 – Zařazovací kritéria

Tabulka 7 – Vyřazovací kritéria

Tabulka 8 – Vyhledávací strategie na PubMed

Tabulka 9 – Přehled zařazených studií

SEZNAM ZKRATEK A ZNAČEK

AI	Umělá inteligence
AUC	Area Under the ROC Curve
CAM-ICU	Confusion Assessment Method for the ICU
CMP	cévní mozková příhoda
DMS-V	Diagnostic and Statistical Manual of Mental Disorders
EEG	elektroencefalogram
EKG	elektrokardiogram
ICU	Intenzive Care Unit
JIP	jednotka intenzivní péče
ML	machine learning
MMSE	Mini-Mental State Examination
ORL	otorinolaryngologie
POD	pooperační delirium
RAS	roboticky asistovaná operace
RASS	Ritchmond Agitation Sedative Scale
RF	Random Forest
ROC	Receiver Operating Characteristics
RTG	rentgen
SVM	Support Vector Machine
UPV	umělá plicní ventilace
VAS	Visual Analogue Scale
XGBoost	Extreme Gradient Boosting

ÚVOD

Pooperační delirium (POD) představuje častou komplikaci, a to zejména u starších pacientů. Může vést ke vzniku závažných komplikací. Vyznačuje se především akutními změnami kognitivních funkcí a poruchami pozornosti a vědomí. Tyto změny mohou vést k prodloužení doby hospitalizace, vyšším nákladům na zdravotní péči nebo k dlouhodobým kognitivním poruchám. V současnosti existují a stále se vytvářejí nové způsoby, které přispívají k časné diagnostice a prevenci pooperačního deliria, při kterých hraje zásadní roli právě umělá inteligence. Výskyt POD je spojen s vysokou mortalitou a morbiditou (Jin et al., 2020; Yan et al., 2023).

Výskyt pooperačního deliria celosvětově narůstá. V roce 2010 byl počet pacientů, u kterých se delirium projevilo, 524 milionů. Jelikož populace stále nabývá, mohl by počet v roce 2050 činit okolo 1,5 miliardy výskytů POD. (Yan et al., 2023). Výskyt deliria záleží i na typu operačního výkonu. Po srdečních operacích se zvyšuje riziko vzniku POD až o 50 %. To stejné procento nastává i u urgentních operací. Délka operačního výkonu také zvyšuje pravděpodobnost rozvoje POD (Jin et al., 2020).

Používání umělé inteligence (AI) v diagnostice onemocnění a zdravotních stavech, včetně pooperačního deliria, nabízí možnosti rychlejších, efektivnějších a přesnějších rozpoznávání symptomů a predikci rizikových faktorů. Využití AI, v podobě strojového a hluboké učení a analýzy dat, je schopno zpracovávat velké objemy dat, které jsou člověkem snadno přehlédnutelné. Proto jsou tyto technologie přesnější a rychlejší. Zdravotnickému personálu, především sestřám a lékařům, tak umožní lépe identifikovat rizikové faktory a upravit následnou zdravotní péči a její postup (Hess a Mainz., 2023).

Cílem této diplomové práce je prozkoumat roli umělé inteligence při diagnostice a predikci pooperačního deliria. Pomocí analýzy odborných článků se diplomová práce pokusí přispět k lepšímu pochopení potenciálu a důležitosti AI v oblasti predikce a diagnostiky pooperačního deliria, což je krok směrem k efektivnější a bezpečnější zdravotní péči.

1 CÍLE A METODY PRÁCE

1.1 Cíl teoretické části

Teoretickým cílem je shromáždit a zmapovat odbornou literaturu týkající se pooperačního deliria a umělé inteligence, vysvětlit důležité pojmy, které jsou spojené s pooperačním deliriem a umělou inteligencí, shrnout dosavadní provedená výzkumná šetření a identifikovat, jaké aspekty dosud zkoumány nebyly a na co je důležité se zaměřit v budoucích výzkumech. Cílem je také identifikace trendů ve využití umělé inteligence ve zdravotnictví při operační péči a deliriu.

1.2 Hlavní cíl práce

Cílem je zmapovat výzkumnou literaturu týkající se využití umělé inteligence při identifikaci pooperačního deliria a následně učinit doporučení pro budoucí výzkum. Cílem je také zjištění jejich relevantnosti a následné zhodnocení užitečnosti dohledaných studií.

1.3 Metody k dosažení cíle

K dosažení požadovaných cílů byla vytvořena rešerše z dostupných studií, které byly úzce spjaté s tématem diplomové práce. Analýza studií byla provedena na základě shromáždění a vyhodnocení získaných informací a průzkumem odborných článků a studií. Byla provedena akronymem PICO, při čemž byla využita vědecká databáze PubMed a následně byla provedena analýza jednotlivých článků.

TEORETICKÝ PŘEHLED

Teoretický přehled se nejprve zaměřuje na pooperační delirium, jeho definici, epidemiologii, také na důležité body související s pooperačním deliriem, jako jsou typy deliria, rizika vzniku POD, léčbu, diagnostiku a nástroje, které se využívají při diagnostice aktuálně ve světě. Druhá část teoretického přehledu se zaměřuje na umělou inteligenci, na její charakteristiku, základní principy, modely umělé inteligence, její využití ve zdravotnictví, výhody implementace AI do zdravotnictví, bezpečností, jakou hraje roli při managementu a predikci deliria a jaká je role sestry při jejím využívání. Je zde krátce popsána i robotická chirurgie, která souvisí s AI. Cílem je porozumět dané problematice a následně využít znalosti v systematickém přehledu.

2 ÚVOD DO PROBLEMATIKY POOPERAČNÍHO DELIRIA

Pooperační delirium je provázáno chirurgickými výkony. Postihuje přibližně polovinu nově přichozích pacientů starších 65 let. Počet vzniku deliria každým rokem narůstá, jak u nás, tak i ve světě. Jelikož se zvyšuje i populace mohl by se počet pacientů, u kterých se projeví delirium, zvýšit z hodnoty z roku 2010, tedy z počtu 524 milionů na 1,5 miliardy. Tohoto obrovského čísla bychom pravděpodobně dosáhli v roce 2050. Některá rizika je možné předpovídat na základě charakteristiky výkonu. U starších pacientů často dochází k přidruženým onemocněním, jako jsou křehkost nebo multimorbidita. Tyto komplikace nám mohou komplikovat perioperační péči. Především pooperační delirium je závažnou komplikací, kterou před odchodem z nemocnice postihuje až 50 % pacientů. Projevuje se výkyvem kognice, vědomí a pozornosti. Proto je namístě se touto závažnou komplikací, která může následně způsobit různé další komplikace s ním spojené, zabývat (Yan et al., 2023).

2.1 Definice pooperačního deliria

Pooperační delirium je kognitivní porucha, při kterém dochází k akutní mozkové dysfunkci. Často k němu dochází mezi 2.-5. pooperačním dnem. Mezi symptomy deliria patří dezorientace, poruchy vnímání, porucha spánku nebo emoční napětí. Pooperační delirium je úzce spjato s vysokou mortalitou a morbiditou. Co se zvyšuje při výskytu pooperačního deliria jsou náklady na poskytování zdravotní péče (Jin et al., 2020).

2.2 Epidemiologie

Epidemiologické studie jsou důkazem toho, že projev deliria závisí na typu operačního výkonu. Nejvyšší výskyt se objevuje u pacientů po kardiochirurgických výkonech, kde dosahuje až 50 % výskytu. Dalším oborem, kde se delirium vyskytuje hojně, je ortopedie. Zejména vyšší výskyt je po operaci náhrady kyčelního kloubu či zlomenin krčku stehenní kosti a jeho reparaci. Zde se procentuálně výskyt deliria pohybuje okolo 70 %. Rozdíly jsou patrné i u urgentních operací, kdy výskyt deliria dosahuje až o 50 % více než u běžné neurgentní operace. To vše je v závislosti na věku pacienta, typu chirurgického zákroku a celkovém zdravotním stavu pacienta (Jin et al.,2020).

2.3 Etiologie a patofyziologie

Patofyziologie deliria v současnosti vychází z neurozánětlivých hypotéz. Delirium je založeno na podkladě zánětlivého syndromu, který způsobují cytokiny. Po akutních chirurgickém výkonu, převyšuje počet periferních cytokinů, mezi které patří interleukin a tumor nekrotizující faktor. Následně se naruší hematoencefalická bariéra a aktivují se tak mikroglie a astrocyty. Díky aktivaci těchto buněk, které doprovází i uvolňování proteinu B, vzniká neurální poškození. Toto poškození neuronů přispívá k cholinegnímu selhání a také ke ztrátě neurotrofických faktorů. Tím se zhoršuje schopnost neuronů se opravit a přežít. Studie v posledních letech nezkoumaly tyto cytokiny, ale velkou roli hrál předoperační C-reaktivní protein, který se po jeho aktivaci spustí ve formě deliria. Proto studie autorů Khan et al. (2022) se zaměřuje na hodnoty krevních biomarkerů v předoperačním období a cílem je usnadnit strategii perioperační prevence a přispět k personalizaci léčby.

2.4 Typy pooperačního deliria

Typy deliria se dělí podle příčin vzniku, symptomů, anebo taky podle závažnosti. Prvním typem je hyperaktivní delirium. Jedná se o formu deliria, která se tak často nevyskytuje na jednotkách intenzivní péče. Doprovází ho agitovanost, neklid, emoční labilita nebo psychotickými stavy, kam patří halucinace a iluze. Tyto stavy často narušují poskytování péče. Vycházíme z toho, že se nejedná o trvalou duševní chorobu, ale o dočasné duševní problémy. Je proto potřeba hledat farmaka, která stav vyvolala nebo fyziologickou příčinu vzniku. Druhým typem je hypoaktivní delirium. Tento typ se až ve 43 % případů vyskytuje na JIP. Je doprovázeno zmateností pacienta, sedací, apatií a sníženou citlivostí. Je zpomalená také motorika, pacient je ospalý a trpí letargií. Hypoaktivní delirium bývá často podceňováno a může způsobit zhoršení prognózy. Je proto spojeno s vyšší mortalitou pacientů. Posledním typem je delirium smíšené. Jedná se o

kombinaci obou zmíněných typů deliria. Tvoří přibližně polovinu všech případů. Pacienti mají stavy obou typů s výrazným kolísáním stavů (Ali & Cascella., 2024).

2.5 Rizika pro vznik pooperačního deliria

Pacienty, kteří jsou v možném riziku vzniku POD, je možné připravit už před plánovaným výkonem a předvídat jeho výskyt. Důležitým krokem je zhodnocení funkční rezervy, křehkosti pacienta a testováním pacienta pomocí orientačních testů. Důležité je se zaměřit na případné komorbidity, jako je věk nad 65 let, cévní mozková příhoda (CMP), a pozitivní anamnézu deliria. Rizikové faktory se obvykle dělí na predisponující a precipitující. Do predisponujících faktorů se řadí ty, se kterými pacient přišel do zdravotnického zařízení. Příkladem je polymorbidita a věk. Nově precipitující typ faktoru zahrnuje i typ operačního výkonu, délku hospitalizace a stav hydratace pacienta (Nekvindová a kol., 2023).

Rizikové faktory se dají dělit i z časového hlediska, a to na předoperační, intraoperační a pooperační. Do předoperačních rizik patří již zmiňovaná křehkost, předchozí výskyt deliria v anamnéze, věk nad 65 let a užívání psychiatrických farmak. U pacientů, kteří trpí demencí, musíme otestovat kognitivní funkce před operačním výkonem. Toto zhodnocení nám pomůže při následném managementu anestezie, kdy zvolíme správný typ anestezie, rozsah monitorace a bilanci tekutin. Intraoperační rizika jsou spojena s urgencí výkonu, výskytem infekce, přítomností šoku, typem hospitalizace a délkou operace. Pooperačního rizikové faktory souvisí s celkovým stavem pacienta po operaci. Zvyšuje je přítomnost umělé plicní ventilace (UPV), jaterní či renální selhání, dále srdeční selhávání, nízká koncentrace hemoglobinu v krvi a bolest. Po nekardiálních operacích do vzniku deliria řadíme i spánkovou a smyslovou deprivaci, imobilitu a stav hydratace. Pro kardiální výkony jsou definovaná kritéria spojená s hypertenzí, diabetem mellitus, dušností a délkou hospitalizace na JIP (Nekvindová a kol., 2023).

Cílem je zredukovat tato rizika, aby se zamezilo vzniku delirantního stavu. Usiluje se o co nejmenší zkrácení doby lačnění před výkonem. U tekutin čas činní z předešlých 6 hodin na 2 hodiny. Dále podání premedikace u starších pacientů. Dle nových pravidel bychom se jí měli co nejvíce vyvarovat. Ovšem tento krok se hodnotí u každého pacienta individuálně. Pokud pacient je psychicky nevyrovnaný před operací, je možné klást větší důraz na strávený čas s pacientem a vše mu vysvětlit. Pokud ovšem tato metoda není účinná, můžeme před výkonem využít podání midazolamu bolusově, jelikož intravenózně podaný midazolam nevykazuje zvýšení rizika vzniku POD. Redukci rizika po operaci označujeme za méně důležitou. Řadí se sem prostředí pacienta, hydrataci, osvětlení místnosti a časnou mobilizaci. Nesmí se opomíjet

ani orientace pacienta, což může přispět až o 40% snížení vzniku POD. Pacient by měl mít výhled na hodiny, kalendář a přítomnost blízkých osob buď formou osobní přítomnosti nebo formou fotografií (Nekvindová a kol., 2023).

2.6 Diagnostika

Odběr anamnézy tvoří vždy základ diagnostiky. Do sběru anamnézy je kromě pacienta zahrnuta i rodina, aby byla co nejpresnější. Zjišťují se především informace o duševním stavu, také farmakologická anamnéza, která se soustřeďuje na léky, které pacient pravidelně užívá. Dle výzkumu se zvyšuje riziko vzniku deliria, pokud pacient užívá více než 3 farmaka. Dalším důležitým bodem při diagnostice je fyzikální vyšetření, které je tvořeno 5P – pohmatem (palpace), pohledem (aspekce), poslechem (auskultace) a poklepem (perkuse). Poslední P je vyšetření per rektum, které se nevyužívá jen při některých diagnostikách. Při těchto vyšetřeních je lékař schopen zhodnotit somatický stav pacienta a následně určit další postup diagnostiky (Rummans et al., 1995).

Nedílnou součástí diagnostiky je i laboratorní vyšetření. Mezi základní laboratorní vyšetření patří biochemické vyšetření moči na močový sediment, test na přítomnost krve v moči, urea, kreatinin, také se vyšetřuje hladina cukru nebo se vzorek odesílá na mikrobiologii pro vyšetření kultivace. Co se týká hematologického vyšetření základ tvoří krevní obraz, jaterní testy, ionty a vyšetření krevních plynů neboli ASTRUP (Green et al., 2018).

K přesnější diagnostice nám mohou přispět i vyšetřovací metody. Do těch nejzákladnějších řadíme elektrokardiografii (EKG), počítačovou tomografii (CT), rentgen (RTG), magnetickou rezonanci (MR) a elektroencefalografii (EEG). EKG a RTG hrudníku je součástí předoperačního vyšetření, zatímco ostatní jsou indikovány, pokud je potřeba pacienta před výkonem do vyšetřit specifitěji (Rummans et al., 1995).

2.6.1 Nástroje pro diagnostiku pooperačního deliria

V klinické praxi se nejčastěji využívají dva nástroje pro zjištění deliria. Prvním typem je DMS-V (pátá verze Diagnostického a statistického manuálu duševních poruch). Jedná se o klíčový dokument, který se nejčastěji využívá na psychiatrii, při diagnostice duševních poruch. Již dříve byl nástroj pro zjištění deliria DSM- IV. Pátá verze je novější a aktualizovaná. Podle tohoto nejnovějšího typu se delirium vyznačuje následujícími charakteristikami. První charakteristikou je porucha pozornosti. Pacient není schopen nasměrovat, zaměřit se a udržet či přesunout pozornost. Druhým jevem je rychlost rozvoje deliria. Rozvíjí se během krátké doby, nejčastěji během jedné hodiny až několika dní a má tendenci v průběhu dne se zhoršovat.

Další závažnou poruchou je porucha kognitivního chování. Pacient je dezorientovaný, má oslabenou paměť a není schopen vnímat prostor, ve kterém se nachází. Dalším kritériem je vyloučení poruchy spojenou s neurokognitivní poruchou, kam se řadí kóma. Posledním kritériem je vyloučit příčinu z fyziologického důsledku. Spojením anamnézy, fyzikálního vyšetření a laboratorních výsledků, musíme vyloučit intoxikaci látkami nebo jiného zdravotního stavu (Meagher et al. 2014).

Zatím co typ CAM-ICU (Metoda hodnocení zmatenosti pro jednotku intenzivní péče) je screeningový nástroj, který je dle dohledaného zdroje (Herold, 2013) nejpoužívanější nástroj v intenzivní medicíně. Test je schopen zhodnotit 4 rysy deliria. První je náhlá přítomnost změny stavu vědomí a kolísající úroveň vědomí. Druhým rysem je porucha pozornosti. Dalším rysem je porucha myšlení a posledním projevem je Průcha vědomí pomocí hodnotící škály RASS (Richmond Agitation Sedative Scale). Tento test je používán buď lékařem či sestrou u pacientů, kteří jsou napojeni na umělou plicní ventilaci. Kroky pro zachycení deliria pomocí CAM-ICU jsou následující. Zachycení změny vědomí či kolísání vědomí během 24 hodin. K hodnocení se využívá škála RASS nebo GCS (Glasgow Coma Scale). Druhým krokem je zhodnocení pozornosti buď pomocí sluchového či zrakového testu. Vizuální test spočívá v 3sekundových intervalech, kdy je pacientovi ukázáno 5 lehkých obrázků. Následně si je pacient musí zapamatovat. Poté je mu ukázáno dalších 10 obrázků z nichž 5 je nových a 5 jich je stejných. Pomocí pohybu hlavy (ano/ne) je vyzván, aby dal najevo zda tyto obrázky předtím viděl. Sluchový test je prováděn za účelem předříkávání 10 hlásek ve vteřinových intervalech. Pacient musí dát najevo stisknutím ruky signál, pokud slyší písmeno A. Třetím krokem je porucha myšlení, kdy se hodnotí odpovědi na 4 jednoduché otázky, jako je např. „Plave kámen ve vodě?“, „Je možné zatlouct hřebík kladivem?“. Posledním krokem je alterace vědomí. Hodnota podle škály RASS musí být jiná než 0 (Herold, 2013).

Dalším podstatným nástrojem pro diagnostiku deliria je Mini-Mental State Examination (MMSE). Jedná se o kognitivní test, který se nejčastěji využívá především u starších osob pro hodnocení demence. (Creavin et al., 2016) Ve studiích byl tento test používán před chirurgickým výkonem k vyřazení pacientů. Existuje i česká verze tohoto testu, který se běžně využívá v zařízeních, které se specializují na pacienty s demencí. Tento test se využívá v České republice již několik desítek let. Zaměřuje se především na kognitivní aspekty. Skládá se celkem z 11 podtestů. Důležitou částí testu je orientace v prostoru i v čase. Pokud pacient získá 24-30 bodů, není u něho přítomna kognitivní porucha. Pokud ovšem získá 0-17 bodů, jedná se o těžký kognitivní deficit. Podle počtu bodů se následně hodnotí míra kognitivní poruchy. Test

pacient musí podstoupit s lékařem či jiným proškoleným pracovníkem (Štěpánková a kol. 2015).

2.7 Léčba deliria

Léčbu pooperačního deliria můžeme rozdělit do tří kategorií, a to do nefarmakologické, kauzální a farmakologické léčby.

2.7.1 Nefarmakologická léčba

Využíváme ji zejména u mírných příznaků zmatenosti a agitace. Zahrnují prostředí, ve kterém je pacient léčen (světlo, hluk), dále interpersonální postupy, kdy se snažíme zamezit stěhování pacienta a omezit použití prostředků, které pacienta omezují. Tyto prostředky by měly být až poslední volbou. Jejich využití zvyšuje pravděpodobnost, že pacienta negativně ovlivní ve funkční výkonnosti po hospitalizaci (Nekvindová a kol., 2023).

2.7.2 Kauzální léčba

Pokud selže nefarmakologická léčba, volíme léčbu kauzální. Mezi kauzálně ovlivněné příčiny řadíme infekci, což může vést k rozvoji sepse, elektrolytovou dysbalanci, dehydrataci, hypoglykémii a orgánové selhání (Nekvindová a kol., 2023).

2.7.3 Farmakologická léčba

Pokud selžou předchozí dva způsoby léčby, volíme právě farmakologickou léčbu. Celosvětově užívaná farmaka pro léčbu POD jsou incizivní antipsychotika, atypická antipsychotika, benzodiazepiny, alfa-2 agonisté a Propofol. Nejvíce doporučovány jsou léky ze skupiny antipsychotik. Jejich použití musí být krátkodobé, pouze pro zvládnutí těch nejhorších symptomů. Antipsychotika se nedoporučují používat u pacientů s demencí, jelikož mohou způsobit CMP a zvýšit tím mortalitu. Do incizivních antipsychotik řadíme haloperidol a levomepromazin. Využívá se při léčbě POD u středních až vážných příznaků. Velkou výhodou je nízké riziko utlumení pacienta. I přesto bychom měli dbát na individualitu pacienta a podávat dávky tak, aby nedošlo k předávkování. Léčba deliria haloperidem není stále stoprocentní. Nebylo prokázáno, že jeho podání ovlivní trvání deliria, délku hospitalizace na JIP a v nemocnici. Quetiapin, tiapridal, melperon a olanzapin spadají pod atypická antipsychotika. Tyto farmaka redukují riziko POD efektivněji než již zmiňovaný haloperidol. Významný efekt se zpozoroval pouze u vysoce rizikových pacientů. Dalšími léky ovlivňující delirium jsou benzodiazepiny. Využívají se i při vzniklé závislosti na opioidech. Podle výzkumu může tato léková skupina zvýšit riziko vzniku hypoaktivního deliria. Do léčby spadá i léčba bolesti, která je často opomíjená. Proto je využívána multimodální analgezie s co nejmenší tolerovanou

dávkou opioidů. Projevu je se akutním respiračním selháním. Pokud projevy deliria zmizí do 48 hodin, můžeme delirium požadovat za vyléčené (Nekvindová a kol., 2023).

2.8 Dopad pooperačního deliria na pacienta a společnost

Pooperační delirium má velký dopad na pacienta, ale i společnost. Jeho výskyt prodlužuje délku hospitalizace. Je také spojeno s délkou potřeby napojení pacienta na UPV. Studie jsou důkazem toho, že po propuštění pacientů, u kterých po chirurgickém výkonu došlo k projevu pooperačního deliria, se zvýšilo riziko vzniku demence až o 10krát. Nicméně přítomnost deliria ovlivňuje i společnost. Jelikož se prodlužuje délka hospitalizace, je potřeba více nákladů, a to až o dvojnásobek. Delirium sebou nese i mnoho pooperačních komplikací, jako je vznik dekubitů, rozvoj infekce, riziko pádu, respirační potíže nebo infarkt myokardu (Whitlock et al., 2011).

3 UMĚLÁ INTELIGENCE OBECNĚ

Umělá inteligence neboli AI, je popisována jako nová elektřina. Jelikož elektřina změnila způsob života všech, umělá inteligence je připravena změnit svět. Výzkumy předpovídají, že globální výdaje na poskytnutí zdravotní péče s využitím AI budou okolo 36,1 miliardy dolarů. AI bude využíváno jak v poskytování zdravotní péče, tak i v domácí péči (Robert, 2019).

3.1 Základní principy AI

Umělá inteligence představuje široký obor, který je používán pro systémy, které jsou schopny samostatně provádět logické operace, rozhodovat, rozpoznávat věci a příkazy. Je založena na několika základních principech, díky kterým jsou schopny zadávat úkoly pomocí inteligence na úrovni té lidské. Hlavními principy jsou strojové učení (Machine Learning) a hluboké učení (Deep Learning) (Hess a Mainz., 2023).

Strojové učení je definováno jako technika AI, která se využívá převážně k navrhování a trénování softwarových algoritmů. Využívají se algoritmy, které jsou uzamčené nebo adaptivní. Adaptivní algoritmy jsou schopny přizpůsobovat chování, zatím co uzamčené ne. Machine Learning je založený na logickém systému. Je schopen se naučit řešit úlohy, a to podle vzorových dat. Následně je schopen naučit se samostatně řešit další úlohy, které doposud nikdy neřešila (Hess a Mainz., 2023).

Hluboké učení je širší pojem strojovému učení. Tento typ využívá hluboké neuronové sítě, díky kterým je schopen vytvářet složité vztahy mezi vstupy a výstupy (Hess a Mainz., 2023).

3.2 Modely strojového učení

Jeden z typů modelů založeném na strojovém učení je tzv. Random Forest. Jedná se o model, který se využívá k randomizaci prediktorů k dosažení co nejvyšší přesnosti predikce. Nejprve se zkoumají vstupní údaje Random Forest. Výsledkem je spojení všech údajů a zjištění co nejpřesnější odpovědi. (Rigatti, 2017) Ve většině studií, které jsou interpretované v systematickém přehledu, se využívá právě modelu Random Forest. Model Random Forest byl využit například ve studii od autorů Sheng et al. (2024), kdy predikoval riziko POD u starších pacientů společně s kombinací klinickými daty a signálů z elektroencefalogramu (EEG).

Dalším modelem, který využívá strojové učení, je Support Vector Machine (SVM). Jedná se o metodu, která slouží pro vytvoření klasifikátoru. Hlavním cílem tohoto modelu je vytvoření rozhodovací hranice mezi dvěma skupinami (Huang et al. 2018). Tento model byl využitý ve studii od Benovic et al. (2024), také při predikci POD.

Model XGBoost (Extreme Gradient Boosting) je poměrně nový model, založený na algoritmu strojového učení. Primárně je schopen zesilovat gradient, což efektivně nabízí učení a podvědomí o vzácnosti. Jedná se proto o dobrý nástroj pro predikci se schopností trénování velkého obsahu dat. Jeho robustnost má za hlavní využití metod v mnoha aplikacích (Noorunnahar et al. 2023). Využit byl například ve studii od autorů Liu et al. (2023), za účelem predikce pooperačního deliria.

3.3 Modely hlubokého učení

Podstatným modelem hlubokého učení, který je nutno zmínit, je neuronová síť. Je složena z velkého počtu jednoduchých a mezi sebou propojených procesních prvků, které se nazývají neurony. Každý z neuronů je schopen generovat řadu aktivací s reálnou hodnotou, což následně vytvoří hlavní výsledek. Používá se v různých oblastech. Jednou z nich je právě i zdravotnictví. Jedná se o náročný model pro pochopení, proto se nevyužívá tak často jako strojové učení (Sarker, 2021).

3.4 Umělá inteligence ve zdravotnictví

Hlavním potenciálem umělé inteligence ve zdravotnictví je přinést co nejvíce pozitivní změny, a to zejména ve zdravotní péči. Díky AI nám je schopno poskytnout větší kontrolu nad zdravím pacientů. Aktuálně jsme schopni pomocí umělé inteligence poskytovat zdravotní péči několika různými způsoby, a to od poskytnutí personalizovaných zdravotních informací až po virtuální komunikaci s pacienty nebo vzdálené monitorace (Dave & Patel, 2023).

Pomocí analýzy pacientových údajů, kam spadá anamnéza, faktory životního stylu a další, jsou algoritmy schopny poskytnout personalizovanou pomoc pro udržení zdraví. Vzdálená monitorace je díky svým systémům napájených umělou inteligencí schopna monitorace životních funkcí a popřípadě informovat poskytovatele zdravotní péče o možných komplikacích. Díky tomu se zkracuje doba zasažení a následně k lepšímu výsledku. Snižuje se tím také počet návštěv zdravotnických zařízení. Umělá inteligence je schopna umožnit pacientovi přístup o jeho zdraví a léčbě, která jim je poskytována. Tímto způsobem se buduje důvěra mezi pacienty a poskytovateli zdravotní péče. U onkologických pacientů je AI dokonce schopna přizpůsobit léčebný plán na míru (Dave & Patel, 2023).

Kde našla umělá inteligence své uplatnění je zejména i v robotické chirurgii. Důkazem je toho studie od Knudsen, 2024. Studie poukazuje na to, jak má AI dopad na operační výkony s využitím právě chirurgických robotů. V dnešní době se nejvíce uplatňuje metoda „master-slave“. Nejedná se o autonomního robota, který řídí operaci, ale o robota, kterého řídí operatér

během výkonu. Nové pokroky v AI a ML se snaží o to, aby došlo k rozšíření možností chirurgických robotů na operačních sálech. Závěr studie popisuje, že modely AI se využívají zejména k automatizaci chirurgických výkonů, a také jejich použití zvyšuje bezpečnost během operace (Knudsen et al., 2024).

3.4.1 Výhody implementace umělé inteligence ve zdravotnictví

Použití AI ve zdravotnictví přináší řadu výhod. Může se zlepšit kvalita poskytované péče, efektivita a přesnost. Použití umělé inteligence zajišťuje rychlejší, přesnější a podrobnější diagnostiku onemocnění. Využívá se k tomu strojové učení, které se dále rozšiřuje na složitější procesy, a to na neuronovou síť a hluboké učení. Zkracuje se tím doba odhalení nemocí. Umožňuje tak lékařům predikovat jejich rizika, a proto se mohou zajistit preventivní opatření před tím, než dojde ke zhoršení stavu pacienta (Davenport et al., 2019).

AI je přínosná i v administrativě, kdy optimalizuje procesy, automatizuje administrativní úkoly a poskytuje tak zdravotnickým pracovníkům více času, který mohou věnovat péči o pacienta. Podle individuálních dat je umělá inteligence schopna vyhodnocovat zdravotní péči individuálně podle potřeb pacienta, což je efektivnější a přesnější pro minimální vznik vedlejších účinků. Jsou zde i etické rozpory o ochraně osobních dat, kdy pacienti jsou vůči těmto novým technologiím skeptičtí. Buducnost využití AI ve zdravotnictví bude hrát významnou roli. Je ale jasné, že AI nenahradí lidské klinické lékaře, ale spíše jen rozšíří péči o pacienty (Davenport & Kalakota, 2019).

3.4.2 Bezpečnost využití umělé inteligence ve zdravotnictví

Bezpečnost spojená s využitím AI je důležité téma, které se nesmí opomíjet. Jelikož pracujeme s citlivými zdravotnickými daty, musí se data chránit. Data se chrání hlavně před kybernetickými útoky a jejich zneužitím. Poukazuje na to studie od autorů Jalali et al. (2019), kdy byl vytvořen systematický přehled literatury se zaměřením na agregaci strategie. Závěrem studie je, aby zdravotnické instituce investovali co nejvíce financí na kybernetickou bezpečnost, jelikož kybernetických útoků přibývá a mohly by tak ohrozit zdravotnické zařízení, ale i důvěru v ně. Složitější modely umělé inteligence mohou být ze stran lékařů nedůvěřivé, protože jsou těžko neinterpretovatelné. Pro snížení těchto rizik je vhodná regulace a bezpečnostní protokoly.

3.5 Využití umělé inteligence při managementu a v predikci pooperačního deliria

Management deliria je poměrně komplikovaný, jelikož zahrnuje jak prevenci, tak léčbu. Za využití strojového učení jsou zdravotnické systémy schopny určit, jak bude pacient náchylnější

ke vzniku pooperačního deliria. To následně pomůže k včasné predikci a přizpůsobení léčby (Ghazi et al., 2021).

Umělá inteligence se pomalu začíná stávat klíčovým nástrojem při zjišťování pooperačního deliria. Moderní systémy umělé inteligence nám nabízejí rychlejší analýzu klinických dat prostřednictvím elektronických zdravotnických záznamů. Díky tomu je schopna včas zachytit rizikové faktory a včasně detekovat delirium, což následně lékařům umožní personalizovat plány péče o pacienty (Sheng et al., 2024).

Pooperační delirium se nejčastěji vyskytuje u starších pacientů po chirurgických výkonech. Ve studii publikované v BMC Anesthesiology se výzkum zaměřil na vývoj prediktivního modelu, který využíval strojové učení k predikci rizika vzniku POD. Celkem bylo ve studii zahrnuto 878 pacientů ve věku 65 let a více. Pacienti podstoupili různé chirurgické výkony. Sběrání dat zahrnovalo i demografické údaje, intraoperační parametry a klinické charakteristiky. Byly využity 3 různé algoritmy strojového učení. Nejlepšího výsledku dosáhl Support Vector Machine, který identifikoval 3 klíčové prediktory. Délku trvání operace, přítomnost multimorbidity a skóre Americké společnosti anesteziologů. V závěru studie je napsáno, že začlenění strojového učení do predikce POD významně přispívá k včasné identifikaci rizikových pacientů, což následně zajistí lepší zavedení preventivních opatření a zlepšení operačních statistik (Benovic et al., 2024).

Elektroencefalogram (EEG) může sloužit jako nástroj pro predikci pooperačního deliria. Jedná se o levnou neinvazivní metodu, která sleduje mozkovou aktivitu. Průběh deliria se projevuje zpomalením nebo výpadkem rytmu v zadní mozkové části. Je snadno přístupný a málo finančně nákladný. Ve studii od Ning et al. (2024) je dokázáno, že využití EEG je velice účinné. Implementací do klinické praxe by mohla vzniknout personalizovaná péče a následné zlepšení pooperační péče.

3.6 Role sestry při používání umělé inteligence

V dnešní době již vědci zdokonalují roboty, aby byli emočně citliví. Jsou navrženi tak, aby reagovali způsobem, jako reagujeme my na lidské integrace. Jsou už schopni vykonávat některé z ošetrovatelských funkcí, jako je měření fyziologických funkcí, podávat léky a další specifické funkce, které sestry vykonávají. Z výzkumů vyplývá, že 8 % - 16 % ošetrovatelského času je věnováno jiným úkolům než těm ošetrovatelským. Proto s podporou využití robotů bude sestra mít více času se individuálně věnovat pacientům. Sestry se aktuálně podílejí na vývoji aplikací se společností Microsoft. Hlavním cílem je poskytnout přidanou hodnotu zdravotnickému týmu

a pacientům (Robert, 2019). Sestra hraje důležitou roli při různých aspektech implementace AI, včetně monitorace pacientů, sběru a analýzy dat (Jones & Larkin, 2020).

Pro efektivní využití musí být sestra proškolená a musí mít adekvátní vzdělání. Vzhledem k tomu, jak se AI v posledních letech rozvíjí, sestry musejí být schopny pracovat s moderními technologiemi a efektivně je využívat v každodenní praxi. Školení sester musí být zaměřeno i na etické a právní aspekty, které úzce souvisejí s využíváním AI (Smith & Harris, 2020).

3.7 Využití umělé inteligence v České republice

V České republice je využití umělé inteligence teprve v počátcích. Existují již výzkumné projekty, v rámci ICRC (International Clinical Research Center), kteří používají umělou inteligenci k analýze a rozpoznání dat z lékařských záznamů, což vede k rychlejšímu odhalení a diagnostice komplikací, ale i pooperačního deliria (Benda et al., 2020). Kde ale již našla využití je v robotické chirurgii.

3.7.1 Robotická chirurgie v České republice

V České republice se začala robotická chirurgie využívat od roku 2005. V posledních letech v ČR se rozrůstá využití roboticky asistované chirurgie (RAS), díky které jsme schopni provádět miniinvazivní výkony. Role chirurga je nezastupitelná, proto se jedná o jakousi telemanipulaci prostřednictvím konzole. Robotika by se dala označit za vyšší stupeň laparoskopie. Hlavní výhodou při operacích je vymizení třesu rukou, proto dochází k větší preciznosti. Další výhodou je digitalizace, která se promítá do konzole, kterou ovládá chirurg. Nejčastěji se uplatňuje v urologii, gynekologii, ale i v ORL (Schraml, et al., 2019).

Role AI v robotické chirurgii spočívá v predikci a analýze dat. Příkladem je krvácení, které patří mezi komplikace operace. Na první pohled by chirurg mohl přehlédnout krvácení, ovšem pomocí modelu umělé inteligence je schopen rozpoznat krvácení. To stejné i s jinými strukturami. Je například schopen rozeznat žlučník a případné abnormality (Hashimoto et al., 2018).

4 SHRNUTÍ TEORETICKÉ ČÁSTI

Pooperační delirium jednoznačně patří mezi závažné a často podceňované komplikace. Dokáže výrazně ovlivnit prognózu pacientů, a to zejména u starší populace. Vzhledem k vysoké morbiditě a mortalitě je klíčové se zaměřit na jeho včasnou identifikaci, prevenci a léčbu. V posledních letech se ukazuje, že moderní technologie, včetně umělé inteligence, mohou hrát klíčovou roli v predikci a diagnostice deliria.

Delirium vzniká v důsledku multifaktoriálních vlivů, zahrnující strukturální abnormality v mozku. K hlavním rizikovým faktorům patří především věk, kognitivní deficit, polymorbidita a typ anestezie. Diagnostika spočívá pomocí škál, které se přímo zaměřují na pooperační delirium. Prevence zahrnuje jak nefarmakologická opatření, jako je optimalizace farmak, udržení hydratace nebo minimalizace stresu, ale i farmakoterapie. Ta je ovšem omezena na těžké případy deliria s agitací.

Umělá inteligence, především tedy modely založené na strojovém učení, se ukazují jako slibný nástroj v predikci POD. Modely, které jsou založené na analýze elektronických zdravotnických záznamů, EEG dat a klinických faktorů dosahují vysoké přesnosti. Mohou proto pomoci ve včasné identifikaci rizikových pacientů.

Přestože teoretická část práce identifikovala klíčové mechanismy vzniku POD a význam včasné detekce, existují nejasnosti ohledně optimálních metod predikce POD. Nutné je zhodnotit především to, jak efektivně lze využít AI a jeho modely založené na strojovém učení v klinické praxi. Z tohoto důvodu byla provedena systematická rešerše literatury, která se zaměřuje na současné studie predikčních modelů pro POD. Také poskytuje přehled o metodologiích, výsledcích a potencionálních omezeních těchto přístupů. V následující části jsou prezentovány výsledky analýzy, zahrnující hodnocení kvality studií, použité metodologie a hlavní poznatky relevantních výzkumů.

SYSTEMATICKÝ PŘEHLED

Tato kapitola obsahuje zmapování literárního přehledu a aktuálních poznatků z dostupných studií, za účelem získání kompletního přehledu o dosavadní využití umělé inteligence při detekci a predikci pooperačního deliria. Pooperační delirium se vyznačuje jako závažná komplikace u pacientů po chirurgických výkonech, a to zejména u starších pacientů. Umělá inteligence je nová inovativní technologie, která díky velkému množství zpracování dat je schopna rychleji a přesněji diagnostikovat rizikové faktory. Hlavním cílem této kapitoly je shrnout všechny dosavadní poznatky a seskupit je do rešerše odborné literatury.

5 CÍL SYSTEMATICKÉHO PŘEHLEDU

Hlavním cílem tohoto systematického přehledu je zmapovat dostupné relevantní zdroje, které jsou zaměřené na využití umělé inteligence při diagnostice a predikci pooperačního deliria. Přehled je zaměřen na přesnost, spolehlivost, efektivitu a na praktické využití metod AI v praxi. Při výběru literatury je nezbytné zohlednit výzkumnou otázku. Nejvyšší úroveň vědeckých důkazů poskytují zdroje z primárního výzkumu.

5.1 Metodika rešeršní části

Ke zhotovení diplomové práce byla využita metodika rešerše studií a článků, které jsou publikovány v zahraniční databázi. Tuto metodu můžeme označit za tzv. scoping review, díky kterému jsme schopni zmapovat dostupné výzkumy týkající se daného tématu. Základním pravidlem pro sestavení literárního přehledu je zvolení správné vyhledávací strategie pro dosažení cílů diplomové práce. Klíčové je také určení výzkumného designu. Výzkumný design byl hodnocen podle Mathes & Pieper (2019). Na základě dohledaných výsledků je potřebné studie zařadit či vyloučit, proto musejí být jasně definována jednotlivá kritéria. Na základě studií je dobré graficky znázornit počet studií. Ke znázornění je vhodné využít diagram PRISMA (Prisma, 2021)

5.2 Formulace klinické otázky

K formulaci klinické otázky se řídím podle publikace od Marečkové a kol. (2015). Klinická otázka obsahuje 3 základní prvky podle akronymu PICO.

„Jak efektivní je využití umělé inteligence (Co) při včasném zjišťování a diagnostice pooperačního deliria (I) u pacientů po chirurgických zákrocích (P)

PICo	Kritéria
P – pacient	Pacienti po chirurgických zákrocích
I – předmět zájmu	Pooperační delirium
Co – kontext	Umělá inteligence

Tabulka 1 – PICo

PICo	Criteria
P – patient	Patients after surgical operations
I – interest	Postoperative delirium
Co – Context	Artificial intelligence

Tabulka 2 – PICo anglický jazyk

5.3 Identifikace relevantních zdrojů

5.3.1 Vyhledávací strategie

Pro vyhledávání relevantních studií jsem využila databázi PubMed. Následně byla určena klíčová slova, pro co nejpřesnější vyhledávání. S pomocí tzv. booleovských operátorů jsem následně klíčová slova propojila. Použité operátory byly zejména „OR“ a „AND“. Poté získané studie byly filtrovány, podle názvu studie a jejího abstraktu, dále podle předem stanovených kritérií. Výzkumný design jsem stanovila podle klasifikace, která je detailněji popsána ve zdroji autorů Nowak et al. (2024) a také podle Mathes & Pieper (2019). Znázornění procesu vyhledávání byl použit diagram PRISMA, který přehledně znázorňuje průběh výběru a vyřazování studií. Diagram byl použit pro zajištění transparentnosti a reprodukovatelnosti procesu při výběru dat.

K vyhledávání nemohl být použitý Google Scholar, neboť není schopen efektivně filtrovat recenzované studie a obsahuje i nerecenzované zdroje. Pro výzkum byla původně využita i databáze Medvik, bohužel se na základě definovaných klíčových pojmů nepodařilo vyhledat žádné studie, které by se provedly v České republice.

5.3.2 Definice klíčových pojmů

Pro efektivní vyhledávání relevantních studií, bylo nutné stanovit si co nejlepší strategii a správně definovat klíčové pojmy. Jejich kombinací zároveň s použitím již zmiňovaných

booleovských operátorů, byla vytvořena efektivní strategie. Klíčové pojmy jsou vypsány v následujících tabulkách tak, aby odpovídaly stanovené klinické otázce.

Pořadí	Klíčový pojem
1.	Surgery*
2.	Surgical*
3.	Operation*
4.	#1 OR #2 OR #3

Tabulka 3 – Klíčový pojem v oblasti Patient

Pořadí	Klíčový pojem
1.	Delirium
2.	Delirious
3.	#1 OR #2

Tabulka 4 – Klíčový pojem v oblasti Interest

Pořadí	Klíčový pojem
1.	„artificial intelligence“
2.	„machine learning“
3.	„deep learning“
4.	#1 OR #2 OR #3

Tabulka 5 – Klíčový pojem v oblasti Context

5.4 Posouzení kvality zdrojů

Posuzování kvality zdrojů, které byli zařazeny do diplomové práce, je klíčovým krokem ke kritickému hodnocení vědeckých studií. Musejí být relevantní pro výzkumnou práci. Pomocí nástrojů k určení specifického výzkumného designu jsem použila zdroj od autorů Nowak et al. (2024) a Mathes & Pieper (2019), díky kterým jsem určila, o jaký výzkumný design se jedná. V rámci posouzení kvality je nutné si položit tři základní otázky:

1. Je studie validní?
2. Jaké jsou její výsledky?
3. Jsou výsledky užitečné?

Pomocí těchto otázek bylo provedeno systematické zhodnocení kvality studie z hlediska validity, spolehlivosti výsledků a jejího použití v klinické praxi (Univerzita Pardubice, 2019).

5.4.1 Validita studie

První krok bylo posouzení validity studií, v čemž spočívá jednotlivá analýza metodologie, výběr zkoumaného vzorku a zjištění výzkumného designu. Klíčové požadavky pro posouzení validity zahrnuje velikost vzorku, metodu sběru dat, výzkumný design, vylučovací kritéria a možné zkreslení.

5.4.2 Posouzení výsledků

Druhý krok spočíval ve zjištění spolehlivosti a opakovatelnosti výsledků studií. Studie musela mít výzkum, který se opakoval a výsledky byly téměř totožné, poté jestli byly výsledky statisticky významné a jestli jsou klinicky relevantní.

5.4.3 Užitečnost výsledků

Třetí krok se zaměřoval na hodnocení využitelnosti v praxi, kdy bylo nutné brát v potaz několik faktorů: finanční náročnost, kompetenci zdravotnického personálu a zákonné a etické aspekty.

V rámci této diplomové práce bylo využito systematického přehledu k výběru kvalitních a relevantních studií, což následně umožnilo vytvoření závěrů založených na vědecky podložených důkazech. Závěry v této práci vycházejí z důvěryhodných a klinicky relevantních zdrojů. Přispívají tak k lepšímu pochopení problematiky predikce POD a spojením umělé inteligence v této oblasti.

5.4.4 Stanovená kritéria pro zařazení a vyloučení studií

Nesdílňnou součástí je stanovení kritérií pro zařazení studií do systematického přehledu. Byla proto stanovena kritéria, na základě, kterých bylo provedeno rozhodnutí buď o zařazení či vyloučení studie. Každá studie musela být pečlivě zanalyzována. Díky tomu je možné zajistit co nejpřesnější výběr studií. Zařazovací kritéria by měla být opakem vyřazovacích kritérií.

Okruh	Zařazovací kritéria
Název	Název odpovídá rešeršní otázce
Jazyk	Studie je napsaná v anglickém nebo českém jazyce
Přístupnost	Musí být přístupný plný text studie
Rok publikace	Nesmí být starší 5 let
Pacienti (P)	Pacienti po chirurgických zákrocích
Předmět zájmu (I)	Výskyt pooperačního deliria
Kontext (Co)	Využití umělé inteligence

Tabulka 6 – Zařazovací kritéria

Okruh	Vyřazovací kritéria
Název	Název neodpovídá rešeršní otázce
Jazyk	Studie není napsaná v anglickém nebo českém jazyce
Přístupnost	Studie bez přístupného plného textu
Rok publikace	Studie starší více než 5 let
Pacienti (P)	Pacienti nebyli po chirurgickém zákroku
Předmět zájmu (I)	Absence výskytu pooperačního deliria
Kontext (Co)	Absence použití umělé inteligence

Tabulka 7 – Vyřazovací kritéria

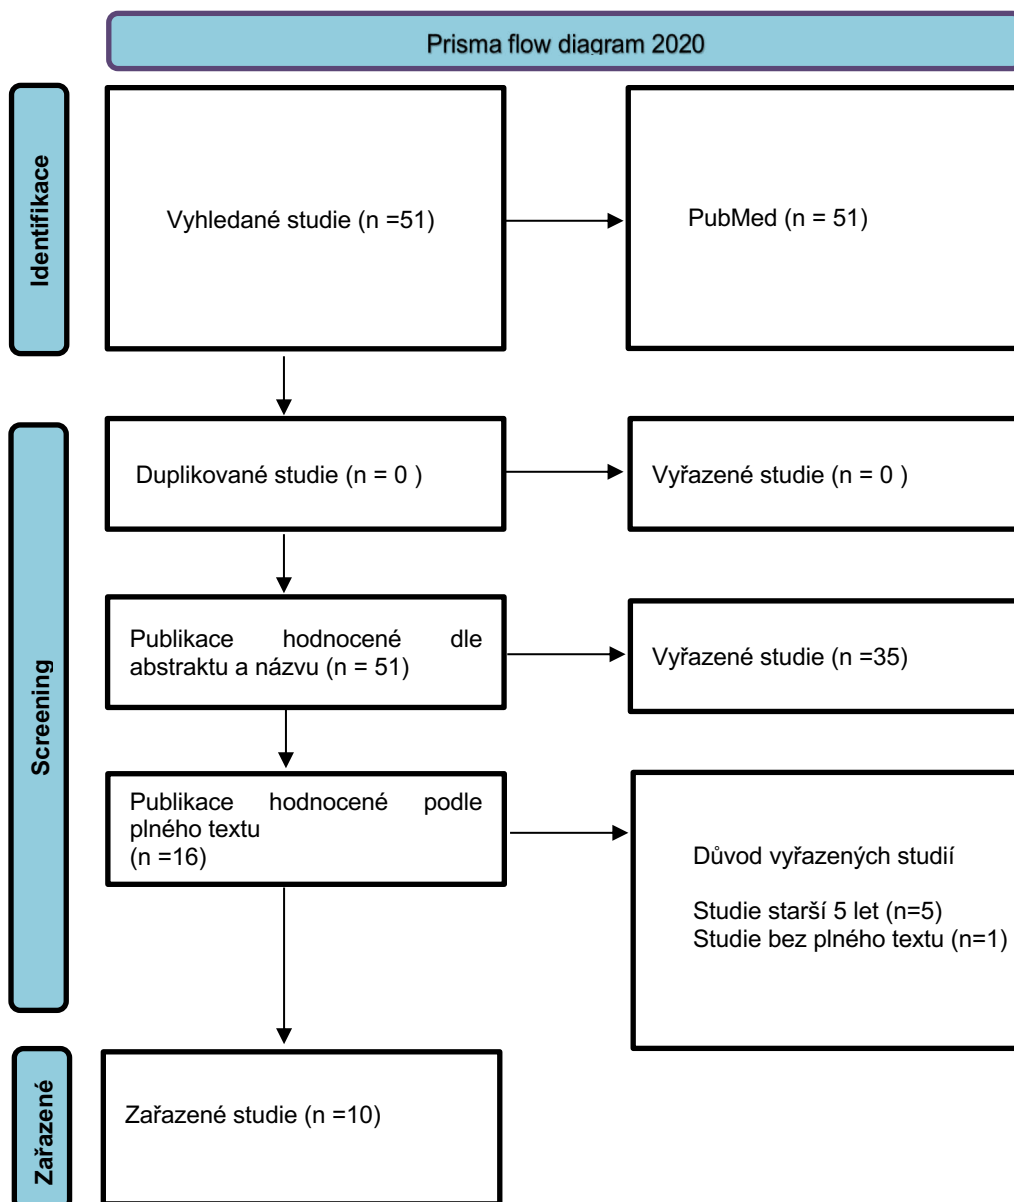
Propojením všech akronymů v databázi PubMed jsem docílila těchto výsledků, které jsem znázornila v tabulce číslo 8.

Pořadí	PICo	Klíčové pojmy	Počet dohledaných studií
1.	Pacienti	Surger*	522 008
2.		Surgery*	509 375
3.		Operation*	199 078
4.		#1 OR #2 OR #3	1 574 269
5.	Předmět zájmu	Delirium	9 205
6.		Delirious	493
7.		#1 OR #2	9 562
8.	Kontext	„artificial intelligence“	40 496
9.		„machine learning“	90 911
10.		„deep learning“	52 266
11.		#1 OR #2 OR #3	174 509
12.		#4 AND #7 AND #11	51

Tabulka 8 – Vyhledávací strategie na PubMed

Výsledky podle vyhledávací strategie jsou znázorněny v tabulce č.8. Výsledky byly dohledány v konkrétní den, tudíž se mohou lišit. V přílohách jsou poté zobrazeny dohledané výsledky v databázi PubMed.

Prisma flow diagram 2020



Obrázek 1 - Prisma flow diagram 2020 (adaptováno z PRISMA Statement)

Prisma flow diagram přehledně zobrazuje počet dohledaných studií v dané databázi. Nebyly zde nalezeny žádné duplikované studie. Vyřazených studií bylo celkem 35, které byly hodnocené na základě názvu a abstraktu. Podle stanovených kritérií byla následně odebrána jedna studie, u které nebyl dostupný plný text. Celkový počet zařazených studií do systematického přehledu činní počtu 10.

5.5 Sumarizace výsledků

Zahrnuté studie byly analyzovány z hlediska jejich přínosu k diagnostice a predikci pooperačního deliria. Níže jsou v tabulce vypsané relevantní studie, které byly zahrnuty do literárního přehledu. Výzkumný design byl určen podle autorů Mathes & Pieper (2019).

Autor	Výzkumný design	Cíl studie	Velikost souboru	Země
Sheng et al. (2024)	Kohortová studie prognostické přesnosti	Identifikace proměnných pomocí algoritmu ML a predikci výskytu POD	1 720 pacientů	Čína
Benovic et al. (2024)	Kohortová studie prognostické přesnosti	Vytvoření modelu ML pro predikci POD u starších pacientů	878 pacientů	Velká Británie
Röhr et al. (2022)	Kohortová studie prognostické přesnosti	Vývoj modelu ML pro predikci POD u starších pacientů ve spolupráci s dříve proběhlé studie	1 067 pacientů	Německo
Liu et al. (2023)	Retrospektivní kohortová studie	Vyvinutí modelu na základě ML pro identifikaci předoperační, intraoperačních a pooperačních faktorů rizikových faktorů.	950 pacientů	Čína
Yu-xiang et al. (2022)	Kohortová studie prognostické přesnosti	Porovnání výkonnosti metod logistické regrese a ML při predikci POD u starších pacientů	29 756 pacientů	Čína
Racine et al. (2020)	Kohortová studie prognostické přesnosti	Posouzení výkonnosti metod ML k predikci POD pomocí prospektivní klinické kohorty	560 pacientů	USA
Oosterhoff et al. (2021)	Kohortová studie prognostické přesnosti	Vyvinutí predikčního modelu využívající ML pro predikci POD u geriatrických pacientů se zlomeninou kyčle	28 207 pacientů	USA
Choi et al. (2022)	Kohortová studie prognostické přesnosti	Vyvinutí prediktivního modelu pooperačních nepříznivých výsledků u starších pacientů po operaci	60 054 pacientů	Jižní Korea
Ning et al. (2024)	Kohortová studie prognostické přesnosti	Identifikace předoperačních prediktorů s cílem snížit výskyt deliria pomocí modelu ML	85 pacientů	USA
Holler et al. (2025)	Kohortová studie prognostické přesnosti	Vyvinutí a externí ověření predikčního modelu pro POD založený na ML pomocí rutinních dat ze zdravotnických záznamů.	14 334 pacientů	USA

Tabulka 9 – Přehled zařazených studií

Zkratky: ML – Machine Learning, POD – pooperační delirium

5.6 Interpretace výsledků

Studie, které byly zařazené do diplomové práce, se věnují propojením pooperačního deliria s umělou inteligencí u starších pacientů po chirurgických výkonech. Popisuje se zde cíl, metodika, výsledky a závěr studie. Výsledky jsou obohaceny o zodpovězení tří otázek podle kroku 3, tedy zda jsou studie validní, jaké jsou jejich výsledky a jestli jsou užitečné. Užitečnost výsledků je zaměřena především na sestry.

1) RANDOM FOREST ALGORITHM FOR PREDICTING POSTOPERATIVE DELIRIUM IN OLDER PATIENTS (SHENG ET AL., 2024)

Cíl

Cílem studie bylo zaměřením na identifikaci důležitých proměnných, a to pomocí algoritmů strojového učení a následnou predikci POD u starších pacientů po plánovaných, mimo srdečních, výkonech v oblasti hrudníku nebo břicha. Výzkumníci se nejprve snažili určit klíčové faktory, díky kterým se zvyšuje riziko vzniku POD a na základě faktorů vytvořit model, který by byl schopen lékařům předem identifikovat ohrožené pacienty.

Metodika

Prvním krokem studie byl výběr pacientů, a to ve věkové kategorii od 60 do 90 let. Pacienti podstoupili hrudní nebo abdominální výkon trvajícím minimálně 2 hodiny. Zpracování analýzy proběhlo na základě klinických a laboratorních dat. Jednalo se například o krevní hodnoty a míru pooperační bolesti. Pacienti byli pozorováni opakovaně a delší dobu. Výzkum se prováděl na různých algoritmech strojového učení. Optimalizace modelů byla provedena na základě křížové validace a úpravy parametrů algoritmů. Algoritmy určovaly, které faktory mají největší vliv na výskyt pooperačního deliria.

Výsledky

Studie přinesla několik podstatných výsledků. Nejpřesnější výsledky přinesl model Random Forest, který dosáhl přesnosti 98,78 %. Model Random Forest je založený na strojovém učení, který kombinuje rozhodnutí a analyzuje každý jiný faktor. Výsledkem RF je tak většinové hlasování. Dvěma hlavními faktory, které mají vliv na vznik deliria, se stala hladina kreatininu naměřená před operací a maximální skóre bolesti v průběhu 7 dnů po výkonu. Model byl ověřen na nezávislých datech, což potvrdilo jeho spolehlivost.

Závěr

Tato studie přinesla nový model, který má vysoce výkonný algoritmus a dokáže předpovědět riziko vzniku POD u starších pacientů. Důležitými faktory je hladina kreatininu před výkonem a míra pooperační bolesti. Díky tomu to modelu by lékaři mohli lépe předcházet riziku deliria tím, že by měřili hodnotu těchto rizikových faktorů.

Posouzení validity studie

1. Je studie validní?

Ano, studii můžeme považovat za validní. Byla použita robustní metodika, která zahrnovala pokročilé algoritmy strojového učení a optimalizaci modelů. Model byl navíc testován na nezávislých datech, což snížilo riziko zkreslení výsledků.

2. Jaké jsou její výsledky?

Byly identifikovány dva hlavní faktory, které predikují riziko vzniku POD. Algoritmus Random Forest měl velmi vysokou přesnost, což je důkazem spolehlivosti predikce.

3. Jsou výsledky užitečné?

Ano, výsledky jsou užitečné. Pokud by se tento model aplikoval v praxi, lékaři a sestry by mohli včasněji identifikovat rizikové pacienty a zaměřit se na lepší kontrolu bolesti a optimalizaci předoperačního stavu. To by následně mohlo snížit výskyt POD a zlepšit celkovou péči o starší pacienty. Pro sestry by model umožnil lepší management při kontrole bolesti, dle toho následně zajistit opatření a bezpečí.

2) INTRODUCING A MACHINE LEARNING ALGORITHM FOR DELIRIUM PREDICTION-THE SUPPORTING SURGERY WITH GERIATRIC CO-MANAGEMENT AND AI PROJET (SURGE-AHEAD) (BENOVIC ET AL., 2024)

Cíl

Hlavním cílem byl vývoj modelu, který bude spolehlivý a srozumitelný, na základě strojovém učení pro predikci POD u starších pacientů. Tento model by měl pomoci lékařům identifikovat rizikové pacienty a provést preventivní opatření.

Metodika

Výzkumníci se zabývali daty od 878 pacientů ve věku více než 70 let, kteří podstoupili plánovaný chirurgický výkon. Trénink modelu proběhl na základě datového souboru z již dříve proběhlé studie. V souboru bylo původně 880 pacientů, ale dva účastníci byli vyloučeni, a to

z důvodu odstoupení ze studie před operačním hodnocením. Přítomnost deliria byla posouzena na základě Confusion Assessment Method a analýzy zdravotnické dokumentace. Bylo identifikováno 15 rizikových faktorů (např. skóre Americké společnosti anesteziologů, multimorbidita, doba výkonu, funkce ledvin, počet užitých farmak, využití mimotělního oběhu, výsledky kognitivních testů, přítomnost demence, křehkost pacienta, věk, riziko pádu, pooperační izolace a předoperační užívání benzodiazepinů). Na základě těchto klíčových faktorů byly trénovány dva modely. Jejich účinnost pak byla hodnocena pomocí křivek ROC.

Výsledky

Model SVM dosáhl nejlepšího výkonu s plochou pod křivkou ROC (AUC) 0,82 v tréninkové sadě, 0,81 v testovací sadě a 0,76 při ověřování. To je důkazem vysoké schopnosti modelu správně předpovědět riziko POD. Z celkového počtu pacientů, tedy 878, se POD projevilo pouze u 209 pacientů. Demence, která byla přítomna před operací, byla přítomna u 14 pacientů.

Závěr

Autoři uvedli, že studie je důkazem vzniku klinicky užitečného a srozumitelného modelu strojového učení pro predikci POD u starších pacientů. Tento model bude zařazen do projektu SURGE-Ahead, který podporuje chirurgickou péči s geriatrickou spoluprací a umělou inteligencí.

Posouzení validity

1. Je studie validní?

Ano studie se prokázala jako validní. Byla provedena na základě velkého vzorku pacientů a byly v ní použity bohaté metody pro výběr relevantních faktorů a hodnocení modelu.

2. Jaké jsou její výsledky?

Výsledkem je zjištění, že model SVM přinesl nejsilnější schopnost predikce POD.

3. Jsou výsledky užitečné?

Studie potvrdila, že metody strojového učení, mohou přesněji předpovědět delirium. To by mohlo pomoci zdravotním sestřám při zavádění preventivních opatření před výkonem. Využití modelů v klinických informačních systémech by umožnilo lékařům a sestřám rychleji rozhodovat o změnách v péči (např. úprava medikace, intenzivnější monitorace apod.).

3) MACHINE-LEARNING MODEL PREDICTING POSTOPERATIVE DELIRIUM IN OLDER PATIENTS USING INTRAOPERATIVE FRONTAL ELECTROENCEPHALOGRAPHIC SIGNATURES (RÖHR ET AL., 2022)

Cíl

Cílem studie bylo vyvinout model na základě strojového učení, který by byl schopen předpovědět riziko vzniku POD u starších pacientů s využitím intraoperačních EEG signálů s klinickými parametry, které jsou běžně dostupné na operačním sále. Tento model by měl pomoci lékařům včasné identifikovat rizikové pacienty a zavést tak preventivní opatření.

Metodika

Výzkumníci provedli analýzu dat od 1 277 pacientů ve věku nad 60 let. Pacienti podstoupili plánovaný chirurgický výkon. Před operací proběhlo vyšetření pomocí testu MMSE, aby se odstranili pacienti, kteří měli demenci už v předoperačním období. Během operace se zaznamenávaly EEG signály z čelní oblasti mozku. Kromě záznamů z EEG byla shromážděna i klinická data, jako je věk, skóre Americké společnosti anesteziologů a délky operačního výkonu. Pro analýzu dat byly následně využity různé metody. Následně byly vytvořeny modely na základě strojového učení, které pomocí kombinace EEG signálů a klinických dat určovali účinnost modelu pomocí křivky ROC.

Výsledky

Z celkového počtu 1 277 pacientů, bylo 210 z nich vyloučeno, kvůli nedostatku dat nebo soubory EEG byly kratší dvaceti minut. Celkem proto bylo zahrnuto 1 067 pacientů. Modely, které zahrnovaly kombinaci dat, přinesly rozsáhlé a spolehlivé výsledky v hodnocení rizika POD. Pacienti byli rozděleni podle typu použitých anestetik a byli hodnoceni samostatně pro každou skupinu. Nejlepší výkon byl dosažen kombinací EEG signatur a klinických dat. Celkově bylo skóre AUC-ROC 0,78.

Závěr

Studie ukázala, že přístup strojového učení, který kombinoval intraoperační EEG signály s klinickými parametry, by se mohl snadno využívat v klinické praxi a časné tak identifikovat riziko vzniku POD.

Posouzení validity

1. Je studie validní?

Ano, studie byla označena za validní. Byla provedena na velkém vzorku dat a její metodika byla rozsáhlá. Využity byly zajímavé metody pro analýzu EEG dat a vývoj predikčních modelů.

2. Jaké jsou její výsledky?

Výsledkem je, že kombinací EEG signálů s propojením klinických dat, se zlepšila schopnost predikce POD se srovnáním s využitím pouze klinických dat.

3. Jsou výsledky užitečné?

Výsledky studie naznačují, že spojení laboratorních hodnot s algoritmy umělé inteligence poskytuje spolehlivý prediktivní nástroj. Pokud by nemocnice začaly automaticky analyzovat laboratorní výsledky v souvislosti s deliriem, mohl by tento systém upozorňovat zdravotníky na pacienty s vysokým rizikem. To by usnadnilo zavedení cílených preventivních opatření a snížilo počet výskytu pacientů s POD.

4) USING MACHINE LEARNING ALGORITHMS TO PREDICT HIGH-RISK FACTORS FOR POSTOPERATIVE DELIRIUM IN ELDERLY PATIENTS (LIU ET AL., 2023)

Cíl

Hlavním cílem studie bylo vyvinutí modelu založeného na strojovém učení, který by identifikoval předoperační, intraoperační a pooperační rizikové faktory a byl díky nim schopen předpovědět výskyt deliria po operacích u starších pacientů, bez zahrnutí operace mozku.

Metodika

Celkový soubor pacientů tvořil 950 starších pacientů. Pooperační delirium bylo zjištěno u 132 pacientů. Seskupeno bylo celkem 30 charakteristických proměnných, do kterých spadalo odebrání základní anamnézy, charakteristika předoperačního vyšetření, typ operačního výkonu, intraoperační informace a demografické charakteristiky pacienta. Celkem se využily 3 algoritmy strojového učení. K závěrečnému vyhodnocení byla použita k-násobná křížová validace, ROC křivka, kalibrační křivka, analýza rozhodovacích křivek a externí validace.

Výsledky

Model XGBoost vykázal nejlepší výkon mezi třemi predikčními modely. Výsledky křivky ROC ukázaly, že model XGBoost měl vysokou plochu pod křivkou AUC 0,982 v tréninkové sadě, zatím co ve validační sadě byla křivka AUC 0,924, což výrazně značí vysokou přesnost predikčního modelu. K-násobná křížová validace potvrdila stabilitu modelu XGBoost. Kalibrační křivka projevila svou vysokou predikční schopnost na tomto modelu. DCA křivka měla vyšší míru prospěchu pro pacienty, kteří obdrželi intervenční léčbu na základě modelu XGBoost. AUC pro externí validační sadu činila 0,88, což jasně dokazuje dobrou přenositelnost predikčního modelu.

Závěr

Predikční model, který byl tvořen na základě strojového učení, měl vysokou přesnost predikce, což by bylo velice přínosné pro lékaře k včasné diagnostice a léčbě pacientů. Ukázalo se, že delirium je jedním z hlavních problémů, které ovlivňují prognózu pacientů a jsou neprodleně spojeny s věkem, kouřením, abúzem alkoholu, chronickou obstrukční plicní nemocí (CHOPN), hypertenzí, délkou operace a délkou pobytu na JIP.

Posouzení validity

1. Je studie validní?

Ano, studie je validní. Byla provedena na základě velkého vzorku pacientů a použila více metod pro analýzu dat a vývoj predikčních modelů.

2. Jaké jsou její výsledky?

Kombinací předoperačních, intraoperačních a pooperačních údajů s algoritmy strojového učení, zejména XGBoost, umožnila přesnou predikci rizika POD.

3. Jsou výsledky užitečné?

Výsledky můžeme považovat za užitečné, jelikož by mohly pomoci jak lékařům, tak i sestřám snadněji identifikovat pacienty s vysokým rizikem POD a zavést preventivní opatření. Studie představuje významný krok k integraci moderních technologií, jako je strojové učení, do klinické praxe, pro zlepšení péče o starší pacienty podstupující chirurgické zákroky.

5) COMPARISON OF LOGISTIC REGRESSION AND MACHINE LEARNING METHODS FOR PREDICTING POSTOPERATIVE DELIRIUM IN ELDERLY PATIENTS: A RETROSPECTIVE STUDY (YU-XIANG ET AL., 2022)

Cíl

Cílem studie bylo porovnání výkonnosti logistické regrese a metod strojového učení při predikci POD u starších pacientů. Výzkumní pracovníci se snažili zjistit přístup, který bude poskytovat co nejpřesnější predikci a identifikaci klíčových rizikových faktorů spojené s pooperačním delíriem.

Metodika

Výzkum se provedl jako retrospektivní analýza dat u starších pacientů, kteří podstoupili chirurgický výkon. Byla shromážděna různá klinická a demografická data, včetně věku, pohlaví, anamnézy a laboratorních výsledků. Do studie bylo zařazeno celkem 31 363 pacientů nad 65 let, kteří podstoupili operační výkon, kromě srdečních a neurologických výkonů. Byli vyřazeni pacienti o počtu 1 241 a dalších 491 kvůli nedostatku potřebných dat a podstoupení endoskopie. Pro predikci se využily tyto metody strojového učení a logistická regrese. Výkonnost těchto modelů byla hodnocena pomocí metrik, jako je přesnost, citlivost, specifita a plocha pod křivkou ROC (AUC).

Výsledky

Studie zjistila, že některé metody strojového učení jsou schopny překonat logistickou regresi v predikci POD. Logistická regrese dosáhla přesnosti přibližně 70 %, zatímco modely strojového učení 85-90 %. Modely strojového učení nejenže dosahovaly lepších výsledků než tradiční metody, ale také umožnily hlubší analýzu mezi jednotlivými faktory.

Závěr

Závěry studie naznačují, že metody strojového učení mohou poskytnout přesnější predikci POD ve srovnání s tradiční logistickou regresí. Pokud by byly modely zařazeny do klinické praxe, mohly by pomoci zdravotnickému personálu při rozhodování o prevenci a léčbě deliria.

Posouzení validity

1. Je studie validní?

Studie je validní, jelikož byl výzkum proveden na velkém souboru vzorků, dále byla přesně popsána metodika studie, také proběhlo porovnání dvou přístupů, což umožnilo objektivně vyhodnotit výhody AI oproti tradičním metodám.

2. Jaké jsou její výsledky?

Autoři na závěr uvedli, že přístup strojového učení by se mohl prokázat přesněji než tradiční logistická regrese. Přesnost modelů strojového učení byla až o 20% vyšší než při klasické metodě.

3. Jsou její výsledky užitečné?

Výsledky studie jsou přínosem pro budoucnost. Aplikací modelu logistické regrese, by se mohlo včasné identifikovat riziko POD a mohl by se tím zlepšit perioperační management.

6) MACHINE LEARNING TO DEVELOP AND INTERNALLY VALIDATE A PREDICTIVE MODEL FOR POST-OPERATIVE DELIRIUM IN PROSPECTIVE, OBSERVATIONAL CLINICAL COHORT STUDY OF OLDER SURGICAL PATIENTS (RACINE ET AL., 2020)

Cíl

Hlavním cílem této studie bylo vyvinout a interně validovat prediktivní model pro pooperační delirium u starších pacientů pomocí metod strojového učení. Autoři se snažili zjistit, zda by tyto moderní techniky mohly poskytnout přesnější predikci ve srovnání s tradičními metodami.

Metodika

Do studie bylo zařazeno celkem 560 starších pacientů ve věku 70let a více, u kterých nebyla přítomna předoperační demence a podstoupili velké plánované nesrdeční operace. Pomocí metody hodnocení zmatenosti (Confusion Assessment Method) bylo zjištěno, že delirium se z původních 560 pacientů rozvinulo pouze u 134. Predikční modely byly vytvořeny na základě strojového učení a krokové logistické regrese. V modelu strojového učení bylo vyvinuto 5 algoritmů, zatím co kroková logistická regrese sloužila jako tradiční metoda pro srovnávací model. Byly hodnoceny tři překrývající se sady proměnných, omezené na proměnné, které jsou snadno dostupné nebo alespoň méně náročné na sběr v klinických podmínkách. Jednalo se o údaje z rozhovorů a lékařské záznamy. Velká sada obsahovala 71 potenciálních prediktorů.

Menší sada obsahovala pouze 18 proměnných. Sada byla zaměřena na předoperační mentální stav.

Výsledky

Plocha pod křivkou ROC ve velké sadě proměnných činila (AUC) 0,62-0,71. Vybraná sada proměnných se pohybovala v rozsahu AUC 0,53-0,57 a omezená sada s mentálním statusem v rozsahu 0,53-0,68. Pro srovnání modelů můžeme říct, že výsledky byly srovnatelné s modelem vyvinutým pomocí tradiční krokové logistické regrese. Kalibrace modelů pro všechny modely a sady proměnných byla velmi špatná.

Závěr

Autoři vyvinuli predikční modely pro pooperační delirium pomocí strojového učení, které dokazovaly lepší výkon než náhoda a byly srovnatelné s tradiční krokovou logistickou regresí. Avšak POD se ukázalo jako obtížně predikovatelné s významnou přesností.

Posouzení validity

1. Je studie validní?

Studie byla provedena na dobrém podkladě charakterizované jako prospektivní observační kohorta s použitím standardizovaných metod pro sběr dat a hodnocení deliria, proto ji můžeme považovat za validní.

2. Jaké jsou její výsledky?

Modely strojového učení dosáhly AUC v rozmezí 0,62-0,71, což naznačuje to, že schopnost predikce POD je na mírné až střední úrovni. Tradiční logistická regrese dosáhla AUC 0,69, což je v podstatě srovnatelné s modely strojového učení.

3. Jsou výsledky užitečné?

Výsledky poukazují na to, že predikce deliria je náročná i při použití pokročilých metod strojového učení. Přesto mohou tyto modely poskytnout užitečné informace pro identifikaci pacientů s vyšším rizikem POD.

7) PREDICTION OF POSTOPERATIVE DELIRIUM IN GERIATRIC HIP FRACTURE PATIENTS: A CLINICAL PREDICTION MODEL USING MACHINE LEARNING ALGORITHMS (OOSTERHOFF ET AL., 2021)

Cíl

Cílem studie bylo vyvinutí klinicky predikčního modelu na podkladě využití algoritmů strojového učení pro předoperační predikci POD u geriatrických pacientů s frakturou kyčle.

Metodika

Celkem do studie bylo zahrnuto 28 207 pacientů, kteří podstoupili operativní fixaci fraktury kyčle. Pouze u 8 030 pacientů se pooperační delirium projevilo. Shromážděna byla demografická data, anamnéza, laboratorní výsledky a informace z průběhu operace. Primárně byl sledován výskyt POD do 30 dnů po výkonu. Nejprve výzkum probíhal na trénovacích modelech a následně byl využit model Random Forest, který měl identifikovat proměnné pro POD v rámci predikce. Celkový výkon byl zhodnocen pomocí metrik, jako je přesnost, citlivost, specificita a plocha pod křivkou ROC.

Výsledky

Faktory, které přinesly nejvyšší pravděpodobnost vzniku POD, byla předoperační demence, věk, potřeba podpory mobility před výkonem, závislý funkční stav a třída ASA. Výsledkem byla téměř dokonalá kalibrace s interceptem -0,01 a sklonem 1,02, což znamená velmi dobře predikované riziko. Hodnota dosáhla výsledku AUC 0,79, což je jasným důkazem vysoké schopnosti predikce.

Závěr

Díky této studii byl vyvinut model pro predikci POD u geriatrických pacientů po fraktuře kyčle. Model může hrát v budoucnosti zásadní roli při managementu preventivních opatření s rizikem vzniku deliria. Pokud bude uznána za externě validní, lékaři budou moci využívat dostupnou webovou aplikaci do klinické praxe, což usnadní jejich rozhodování a optimalizuje úsilí předoperační prevence.

Posouzení validity

1. Je studie validní

Studie byla publikována v recenzovaném časopise, což značí vysokou úroveň validity. Také byl použit velký vzorek pacientů a použity byly obsáhlé metody strojového učení.

2. Jaké jsou její výsledky?

Hlavním výsledkem studie je dosažení dobré diskriminace a téměř perfektní kalibrace POD u geriatrických pacientů.

3. Jsou výsledky užitečné?

Výsledky studie jsou jednoznačně užitečné pro klinickou praxi. Zdůrazňuje potenciál algoritmů strojového učení při predikci POD a její přínos pro zlepšení péče o tuto zranitelnou populaci. Pokud by byl tento přístup implementován do klinické praxe, zdravotníci by měli k dispozici nástroj, který by umožnil personalizovanou anesteziologickou péči s cílem snížit riziko deliria. Ovšem studie má svá omezení a tím je hlavně zaměření na konkrétní skupinu pacientů. Pro lepší výsledky by bylo dobré výzkum rozvést na širší populační skupinu.

8) DEVELOPMENT AND VALIDATION OF A PROGNOSTIC CLASSIFICATION MODEL PREDICTING POSTOPERATIVE ADVERSE OUTCOMES IN OLDER SURGICAL PATIENTS USING A MACHINE LEARNING ALGORITHM: RETROSPECTIVE OBSERVATIONAL NETWORK STUDY (CHOI ET AL., 2022)

Cíl

Hlavním cílem studie bylo vyvinutí prediktivního modelu pooperačních nežádoucích událostí se zaměřením na starší pacienty po všeobecném operačním výkonu.

Metodika

Studie zahrnovala pacienty ve věku 65 let a starší, kteří podstoupili obecné chirurgické výkony v období od ledna 2011 do prosince roku 2020 ve dvou velkých nemocnicích. Celkem bylo zanalyzováno 27 197 pacientů z jedné nemocnice a 32 857 pacientů z druhé nemocnice. Data byla získána z elektronických zdravotnických záznamů a byly převedeny do společného datového modelu. Informace o pacientech zahrnovaly demografické údaje, anamnézu, laboratorní výsledky a informace o průběhu operace. Primárním výstupem byla kombinace devítidenní pooperační mortality a návštěv pohotovosti. Druhý výstup byl definován na základě prodlouženého pooperačního pobytu a prodlouženému pobytu v nemocnici. Ve studii byly využity různé algoritmy, včetně logistické regrese a Random Forest. Výkon modelů byl hodnocen pomocí plochy pod křivkou ROC s 95% intervalem spolehlivosti.

Výsledky

Primární výstup na základě logistické regrese dosáhl interní validace AUC 0,723 a externí validace AUC 0,703. Je zřejmé, že logistická regrese překonala ostatní modely jako je Random Forest a další, v predikci primárního výstupu. Sekundární výstup měl velmi vysoké jak interní, tak externí validace. Hodnoty AUC se pohybovaly okolo 0,7 a více AUC, což je jasným důkazem vysoké přesnosti predikce.

Závěr

Výzkumníci úspěšně vyvinuli a validovali prediktivní model, který využívá algoritmy strojového učení a efektivně předpovídá riziko vzniku předoperačních nežádoucích událostí. Tento model může pomoci lékařům a pacientům lépe porozumět individuálním rizikům a přínosem operace, což následně umožní informovanější rozhodování a potenciálně lepší pooperační výsledky.

Posouzení validity

1. Je studie validní?

Jelikož byla studie provedena na velkém vzorku pacientů z více nemocnic s celkovým vzorkem 60 054 pacientů, zvyšuje se tím její zobecnitelnost. Použitím širších metod strojového učení, spolu s interní a externí validací, podporuje její věrohodnost. Převodem dat do jednotného datového modelu se zajistila správná konzistence dat a jejich správné zpracování. Studie byla publikována v recenzovaném časopise, což svědčí o jejím odborném přezkoumání, proto ji můžeme označit za validní.

2. Jaké jsou její výsledky?

Studie ukázala, že modely strojového učení, zejména logistická regrese, byly schopné predikovat s vysokou přesností jak primární, tak i sekundární výstupy. Výsledky predikčního modelu ukázaly dobrý výkon při odhadu pooperační mortality, POD a prodlouženého pobytu v nemocnici. Vysoká hodnota AUC je důkazem toho, že modely dokázaly dobře rozlišit pacienty s vysokým rizikem komplikací.

3. Jsou výsledky užitečné?

Predikční model může zlepšit rozhodovací procesy nejen v oblasti chirurgické péče, ale i v širším kontextu perioperačního managementu. Může se stát užitečným nástrojem pro zlepšení péče a snížení pooperačních komplikací, proto si na otázku, zda jsou výsledky užitečné, můžeme odpovědět ano.

9) PREDICTION OF POSTOPERATIVE DELIRIUM IN OLDER ADULTS FROM PREOPERATIVE COGNITION AND OCCIPITAL ALPHA POWER FROM RESTING-STATE ELECTROENCEPHALOGRAPH (NING ET AL., 2024)

Cíl

Cílem studie je identifikace předoperačních prediktorů, které by mohly odhalit pacienty, u kterých je vysoká pravděpodobnost vzniku POD a umožnit tak cílenou intervenci se zaměřením snížením počtu výskytu deliria a jeho komplikací.

Metodika

Do studie bylo zařazeno 85 pacientů ve věku nad 60 let, kteří podstoupili plánovaný operační výkon. Během výkonu se zaznamenávaly EEG signály z čelní oblasti mozku. Kromě těchto signálů byly shromážděny i základní klinické údaje, jako je věk, skóre Americké společnosti anesteziologů a délka operace. Pro analýzu signálů z EEG se využily metody jako je analýza vlastní a identifikace vzorců burst-suprese (náhlé poklesy mozkové aktivity). Následně pak byly vytvořeny modely strojového učení, které kombinovaly EEG signály s klinickými parametry. Jejich účinnost byla vyhodnocena pomocí křivek ROC.

Výsledky

Nejpestřejší výsledky dosáhly modely založené na kombinaci EEG dat a klinických parametrů. Samotné klinické údaje dosáhly AUC-ROC skóre 0,75. Přidáním signálů z EEG zlepšilo klasifikaci, zejména když byli pacienti rozděleni podle typu použitých anestetik a hodnoceni samostatně pro každou skupinu. Aplikace tohoto predikčního modelu na nezávislý datový soubor z jiné klinické studie potvrdila tyto výsledky pro kombinovanou klasifikaci, zatímco klasifikátor založený pouze na klinických parametrech nebyl obecně použitelný.

Závěr

Závěr studie poukazuje na silnou predikci POD u kombinace intraoperačních čelních EEG signálů s klinickými parametry. Mohl by být snadno použitelným nástrojem pro včasnou identifikaci pacientů s rizikem rozvoje POD.

Posouzení validity

1. Je studie validní?

Studie byla provedena na velkém vzorku pacientů s použitím obsáhlých metod pro analýzu EEG dat a vývoj predikčního modelu, proto ji můžeme označit za validní.

2. Jaké jsou její výsledky?

Kombinací intraoperačních EEG signatur s klinickými parametry se zlepšila přesnost predikce POD ve srovnání s použitím pouze klinických parametrů.

3. Jsou výsledky užitečné?

Výsledky by mohly umožnit lékařům lepší identifikaci pacientů s rizikem POD, můžeme je považovat za velmi užitečné. Tato studie představila významný pokrok v integraci moderních technologií, jako je strojové učení a EEG monitorace, do klinické praxe pro zlepšení péče o starší pacienty po chirurgických výkonech.

10) DEVELOPMENT AND VALIDATION OF A ROUTINE ELECTRONIC HEALTH RECORD-BASED DELIRIUM PREDICTION MODEL FOR SURGICAL PATIENTS WITHOUT DEMENTIA: RETROSPECTIVE CASE-CONTROL STUDY (HOLLER ET AL., 2025)

Cíl

Cílem bylo vyvinout a validovat predikční model pro pooperační delirium, který byl založený na modelu strojového učení pomocí rutinních dat ze zdravotních záznamů.

Metodika

Identifikovány byly všechny operační výkony od roku 2014 do roku 2021 pouze u pacientů starších 50 let. Podmínkou bylo podstoupení operačního výkonu provedený v celkové anestezii s délkou hospitalizace minimálně jednoho dne. U pacientů, kteří v předoperačním období jeví známky demence či vykazovali známky jiných kognitivních poruch, byli ze studie vyloučeni. Delirium bylo identifikováno pomocí Confusion Assessment Method a deliriových kódů z Mezinárodních klasifikací nemocí.

Výsledky

Studie zahrnovala 7 167 případů, kdy se vyskytlo delirium. Nejlepší výsledek měl klasifikátor XGBoost, který dosáhl průměrné hodnoty AUC 0,79. Modely, které byly založené na elektronických zdravotních datech, prokázaly ty nejlepší výsledky.

Závěr

Závěr studie zmiňuje, že rutinní data jsou přínosná pro včasnou predikci POD u různorodé kohorty pacientů po chirurgickém výkonu, u kterých nebyla v preperioperační době zjištěna demence. Modely sice nedosahovaly takové výkonnosti v porovnání s jinými studiemi, ale umožňují předvídat delirium už v době příjmu pacienta. Použití modelu je omezené na použití pouze pro určitý počet proměnných před přijetím a operací s distribucí, která je mezi institucemi rozdílná. V klinické praxi by se mohly využít pro před screeningové vyšetření, které odhalí rizikové pacienty pro vznik POD a umožní tak lékařům upravit následnou strategii v péči a zahájit preventivní opatření. Pro použití modelu je potřeba vytvořit další výzkum a upravit model pro širší aplikaci.

Posouzení validity

1. Je studie validní?

Studie byla provedena na velkém vzorku pacientů, bylo využito dostatečné množství metod strojového učení a analýzy dat z elektronických zdravotních záznamů. Byla publikována v recenzovaném časopise, což dokazuje její odbornost.

2. Jaké jsou její výsledky?

Model dosáhl vysoké přesnosti predikce POD. Identifikoval klíčové faktory a poskytl nástroj, který lze využít v praxi. Model se ukázal účinný zejména se spojením dostupných elektronických zdravotních záznamů, což usnadňuje implementaci v nemocničním prostředí.

3. Jsou výsledky užitečné?

Výsledky jsou užitečné, zejména pro zdravotní sestry, které pomocí studie mohou včasně předcházet komplikacím. Jsou schopny zajistit cílený monitoring, zlepšit spolupráci s lékaři, zvýšit bezpečnost pacientů a zefektivnit organizaci péče.

6 DISKUZE

Hlavním cílem diplomové práce bylo zmapovat odbornou literaturu, kdy byla použita umělá inteligence při identifikaci pooperačního deliria. V rámci systematického přehledu bylo analyzováno celkem deset studií, které se zabývaly predikcí pooperačního deliria pomocí metod umělé inteligence. Každá z analyzovaných studií přinesla unikátní přístup k predikci POD. Ať už z hlediska použitých modelů, vstupních dat nebo délky trvání výzkumu.

6.1 Shrnutí analyzovaných studií

V oblasti predikce pooperačního deliria bylo zanalyzováno více metod přístupu, které byly převážně založeny na strojovém učení. Mezi nejčastější modely patřil model Random Forest, logistická regrese, neuronové sítě a model XGBoost. Autoři studie Benovic et al. (2024) provedli analýzu klinických a laboratorních dat, což jim zajistilo vyšší predikční přesnost. Často se také predikovalo delirium pomocí využití EEG signálů. (Sheng et al, 2024; Röhr et al., 2022; Ning et al., 2024). EEG se projevilo jako efektivní způsob predikce s vysokou přesností. Využívala se i klinická data společně se spojením umělé inteligence (Sheng et al., 2024; Benovic et al.2024) Pouze dvě studie využily logistickou regresi (Racine et al., 2020; Yu-Xiang et al., 2022). Holler et al. (2025) a Choi et al. (2022) provedli studii na základě využití elektronických zdravotnických dat. Specifickou studií se zaměřením na konkrétní skupinu pacientů po fraktuře kyčle byla studie od autorů Oosterhoff et al. (2021). Studie od autorů Liu et al. (2023) se jako jediní zaměřili na výsledky z laboratorních výsledků, což se projevilo jako efektivní způsob v predikci POD. Celkově lze konstatovat, že nejpřesnější modely kombinují více typů dat a že díky nim dokáže AI výrazně zlepšit včasnou detekci a prevenci pooperačního deliria.

6.2 Porovnání studií

Pro rozšíření pohledu na predikci POD pomocí umělé inteligence je užitečné porovnat dříve interpretované studie s dalšími relevantními výzkumy v oblasti predikce deliria. Pro porovnání byla vybrána studie, která byla publikovaná v časopise od autorů Song et al. (2023). Zaměřila se na vývoj a validaci modelu pro predikci deliria, a to u pacientů s rozsáhlými popáleninami. Model byl založen na principu strojového učení. Studie byla velkým přínosem z důvodu specifity na daný vzorek pacientů, tedy na pacienty s rozsáhlými popáleninami. Tato studie využila pro výzkum data z elektronických zdravotnických záznamů, a to standardních klinických a laboratorních výsledků. Tím se podobá předem interpretované studii od Holler et al. (2025). Byl zde použit model Random Forest, který z dalších osmi modelů měl nejvyšší

míru predikce. Tudíž můžeme říct, že dohledané studie, ve kterých se používal algoritmus Random Forest, se často využívá a patří do jednoho z nejlepších prediktorů v současnosti. Jak již bylo zmíněno, bylo by potřeba zaměřit se na širší populaci, aby došlo k co nejvyšší přesnosti výsledků, ale můžeme konstatovat, že využití algoritmu Random Forest bude v budoucnu velký přínosem pro zdravotnictví.

Pro srovnání byla vybrána další studie, která se zabývala výzkumem na deseti modelech strojového učení pro predikci předoperační a pooperační koagulopatie. Výzkum byl zaměřen na pacienty, kteří prošli traumatem. Celkem bylo zanalyzováno přes 13 tisíc pacientů, tudíž studii považujeme za validní, jelikož byl zkoumaný velký vzorek pacientů. Co můžeme považovat za velký přínos je, že výzkum byl prováděn ve čtyřech zdravotnických centrech. I když se nejedná o výzkum, kde se zkoumala predikce deliria, studie byla vybrána právě za účelem porovnání s jinou komplikací. Výsledkem studie byla nejpřesnější míra predikce pomocí modelu Random Forest (Xiong et al., 2025).

6.3 Limity studií

Přestože systematický přehled těchto deseti studií poskytl cenné poznatky o využití umělé inteligence v predikci pooperačního deliria, je nutné vzít v úvahu několik omezení, které mohou ovlivnit zobecnitelnost a praktickou aplikaci výsledků. Jedním z hlavních limitů byla různorodost metodologií a vstupních dat. Některé studie se zaměřovaly primárně na klinická data a laboratorní testy (Benovic et al. 2024; Liu et al. 2023). Jiné zapojily do výzkumu například EEG pro přesnější predikci POD (Sheng et al. 2024; Ning et al. 2024). Tato variabilita znemožňuje přímé srovnání přesnosti jednotlivých modelů a komplikuje jejich implementaci v klinické praxi. Pro budoucí výzkum by bylo žádoucí sjednotit metodologii a definovat kritéria pro posouzení efektivity modelů.

Většina studií validovala modely na historických datech, což znamená, že nebyly testovány v reálném čase na současných pacientech. Pouze Choi et al. (2022) se zaměřil na implementaci AI modelu do nemocničního informačního systému. Bylo zde nutno provést dlouhodobé testování pro ověření spolehlivosti modelu a jeho účinnosti. Aby bylo možné modely skutečně aplikovat v praxi. Je nutné provést prospektivní klinické studie. Ty by poté testovaly modely na aktuálních pacientech.

Jeden ze zásadních limitů je nízká interpretovatelnost některých modelů. Mezi relativně dobře interpretovatelné modely patří Random Forest a logistická regrese. Oproti tomu model XGBoost, který byl testován například ve studii Liu et al. (2023), poskytuje vynikající predikční

výkon, ale rozhodovací procesy mohou být pro lékaře hůře pochopitelné. Tento zásadní problém by mohl vést k nízké důvěře zdravotníků.

Dalším limitem bylo zaměření na různé populační skupiny. Některé studie se zaměřovaly pouze na specifické skupiny pacientů (např. s frakturou kyčle), což omezuje zobecnitelnost výsledků. Proto by bylo potřeba modely testovat na širší populaci.

Zásadním limitem je technická a ekonomická náročnost pro použití modelů. Potřebné jsou výkonné nemocniční informační systémy, které by umožňovaly integraci prediktivních modelů a automatickou analýzu dat. Z finančního hlediska se jedná o vysoce nákladnou záležitost, a to zejména v menších nemocnicích. Budoucí studie by se měly zaměřit na nalezení způsobu, jak snížit náklady na implementaci těchto modelů do praxe.

6.4 Limity práce

Tato práce je založená na systematickém přehledu, proto je nutné brát ohled na určitá omezení. Hlavním limitem práce byl omezený počet zahrnutých studií podle požadovaných kritérií. Druhým limitem bylo omezení na anglický a český jazyk. Studie musely mít přístupný plný text, musely být z relevantních zdrojů a z konkrétní databáze.

Teoretický přehled práce byl také velmi omezen. Počet zdrojů ohledně pooperačního deliria a umělé inteligence byl velmi omezený. Proto se v práci vyskytují zdroje stejné nebo zdroje z roku 2011 nebo zdroj z roku 1995, kdy se pooperační delirium diagnostikuje stále pomocí stejných metod. U pooperačního deliria se jedná o jasně dané charakteristiky, proto počet dohledaných relevantních článků a studií není příliš velký. To stejné u umělé inteligence. Zde je podstatné zmínit, že se jedná o poměrně novou problematiku a jelikož se jedná o tak široké téma, není zatím vše ohledně AI specificky upřesněno.

6.5 Doporučení pro budoucí výzkum

Je zřejmé, že pooperační delirium zůstává zásadním klinickým problémem, který negativně ovlivňuje zdravotní stav pacientů, zvyšuje tím délku hospitalizace a souvisejí náklady na poskytovanou zdravotní péči. I přes významný pokrok v této oblasti díky predikčním modelům založených na umělé inteligenci existují stále zásadní body, které je nutné vyřešit a překonat. Výzkum by se měl zaměřit na širší populaci a zohlednit různé chirurgické výkony.

Dalším důležitým aspektem budoucích studií by mohlo být porovnání prediktivních modelů v různých nemocničních zařízeních. Mohla by se podrobněji sledovat jejich přesnost a použitelnost v různých podmínkách. Rozdíl by mohl nastat třeba mezi soukromými

zdravotnickými zařízeními a fakultními nemocnicemi či dalšími veřejnými instituty. Modely by mohly ovlivnit výkonnost strojového učení a jejich přizpůsobení na konkrétní podmínky.

Mohly by se také zaměřit podstatným směrem, a to na začlenění jednoduchých a finančně nenáročných systémů, založených na umělé inteligenci. Byly by tak snadno přístupné a přívětivé pro široké spektrum zdravotnického personálu. Například kognitivní testy, které využívají digitální platformy. Ty by mohly být automatizovány a využívány i nelékařským zdravotnickým personálem. Usnadnily by tak časnou identifikaci pacientů s vysokým rizikem vzniku POD. Nástroje by měly být navrženy tak, aby nevyžadovaly složité technické znalosti a byly by tak snadno aplikovány do klinické praxe.

Pro budoucí výzkum by bylo dobré se zaměřit i na faktory, které jsou úzce spjaty s operačním výkonem. Mezi klíčové proměnné by mohly patřit například typ anestezie, délka operačního výkonu anebo podaná farmaka nejen během operace, ale i užívaná farmaka před výkonem. Také by se mohly zkoumat životně podstatné faktory během operace, jako jsou výkyvy krevního tlaku, hypoxie, změny hladiny glykémie. Tyto faktory významně ovlivňují neurologický stav pacienta. Zároveň by bylo vhodné se zaměřit na kombinaci klinických skórovacích systémů a modelů strojového učení, což by vedlo k přesnější predikci deliria pomocí hybridního přístupu.

Zkoumání dlouhodobého vlivu pooperačního deliria na pacienty, včetně dopadu na kognitivní funkce, kvalitu života a mortalitu by mohlo vést také k zajímavým výsledkům budoucího výzkumu. Většina studií v současnosti se zaměřuje na bezprostřední pooperační období, ale je stále více potřebné zaměřit se na dlouhodobé sledování, které by hodnotilo faktory vedoucí k trvalému kognitivnímu poklesu nebo až k demenci po operačním výkonu.

Přestože výsledky studií ukazují velký potenciál, je zřejmé, že pro plnohodnotnou implementaci AI do praxe bude nutné překonat řadu výzev. Pokud se podaří překážky odstranit, může umělá inteligence významně přispět ke snížení incidence deliria a ke zkvalitnění perioperační péče.

ZÁVĚR

Diplomová práce se zabývala problematikou pooperačního deliria s využitím predikce pomocí umělé inteligence. Práce byla rozdělena na teoretickou část a na systematický přehled. Teoretická část se soustředovala na odborné pojmy v oblasti umělé inteligence, zahrnovala také definici pooperačního deliria, diagnostiku, léčbu a další souvislosti s deliriem. Systematický přehled byl rozdělen do pěti hlavních kroků. Nejprve byl popsán cíl systematického přehledu a následně byla popsána metodika. Následně proběhla formulace klinické otázky pomocí akronymu PICO, posouzení validity zdrojů, stanovení vyřazovacích a zařazovacích kritérií, sumarizace výsledků a interpretace výsledků. Pomocí diagramu PRISMA byly dohledané studie graficky znázorněny. Dohledané studie byly následně porovnány s podobnými studiemi a byly zde popsány i limity studií, limity práce a doporučení pro budoucí výzkum.

V diplomové práci byly určeny cíle, a to teoretický cíl a hlavní cíl. Hlavním cílem bylo zmapování odborných studií, které úzce souvisejí s tématem diplomové práce a následné doporučení pro budoucí výzkum. Cílem bylo také zjištění relevantnosti studií a zhodnocení jejich užitečnosti.

Pooperační delirium představuje závažnou komplikaci, která může výrazně ovlivnit zotavení pacientů po operacích. Včasná identifikace rizikových pacientů je proto klíčovým krokem k zajištění kvalitní péče a snížení negativních dopadů tohoto stavu. Tradiční metody diagnostiky a predikce se často spoléhají na klinická hodnocení a zkušenosti zdravotnického personálu, avšak s rozvojem moderních technologií se objevují nové možnosti, jak tento problém efektivně řešit.

Umělá inteligence se ukazuje jako významný nástroj v oblasti predikce pooperačního deliria. Modely strojového učení mají schopnost analyzovat rozsáhlé množství dat a identifikovat vzory, které by mohly uniknout lidské pozornosti. Díky tomu mohou tyto technologie pomoci nejen včas detekovat rizikové pacienty, ale také optimalizovat preventivní opatření.

Navzdory slibným výsledkům existuje několik výzev, které je nutné překonat před plošným zavedením těchto metod do klinické praxe. Mezi hlavní problémy patří interpretace výsledků modelů, která musí být vždy srozumitelná pro zdravotnický personál. Také je potřeba mít dostatek rozsáhlých a kvalitních dat, na nichž jsou tyto modely trénovány. Důležité je zajistit standardizaci a validaci těchto metod v různých nemocničních zařízeních, aby bylo možné jejich výsledky spolehlivě aplikovat v reálném prostředí.

Pro úspěšnou implementaci umělé inteligence do klinické praxe je klíčové propojit tyto systémy s nemocničními informačními systémy, které by umožnilo jejich snadné a rychlé použití zdravotnickým personálem. Současně je nutné zajistit dostatečné vzdělávání zdravotnického personálu v oblasti umělé inteligence, aby se mohly efektivněji interpretovat výstupy a využívat je při rozhodování o péči.

Do budoucna by se měl výzkum v této oblasti zaměřit na zdokonalování predikčních modelů, vylepšit jejich interpretovatelnost a ověřování v praxi. Pokud se podaří překonat současné výzvy, může umělá inteligence výrazně přispět ke zlepšení péče o pacienty, snížit tak komplikace a optimalizovat zdravotnické zdroje. Celkově lze konstatovat, že technologie umělé inteligence představují slibný přístup k predikci pooperačního deliria. Budoucí vývoj bude zásadní pro rozšíření metod do běžné klinické praxe a jejich efektivní využití ve prospěch pacientů i zdravotnického personálu.

Hlavní cíl diplomové práce byl splněn. Z interpretace výsledků plyne, že pomocí umělé inteligence se dá poměrně snadno predikovat pooperační delirium. Je jen otázkou času, kdy se umělá inteligence stane běžnou součástí v klinické praxi.

7 POUŽITÁ LITERATURA

ALI, M. a CASCELLA, M. ICU Delirium. In: StatPearls [online]. Treasure Island (FL): StatPearls Publishing, 2025 Jan–. [cit. 11. 2. 2025]. PMID: 32644706.

BENDA, A., NOVÁK, P., ŠTĚPÁNEK, M. a HRUŠKA, M. Advances in AI-based predictive models for postoperative complications in clinical settings: Czech case studies. *Journal of Medical Systems* [online]. 2020, 44(3), 49. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1007/s10916-020-1531-6>

BENOVIC, S., MEIER, T., SCHMIDT, H., SCHNEIDER, R., FUCHS, M. a KELLER, A. Introducing a machine learning algorithm for delirium prediction—the Supporting SURgery with GERiatric Co-Management and AI project (SURGE-Ahead). *Age and Ageing* [online]. 2024, 53(5), afae101. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1093/ageing/afae101>

CREAVIN, S. T., WISNIEWSKI, S., NOEL-STORR, A. H., TREVELYAN, C. M., HAMPTON, T., RAYMENT, D., THOM, V. M., NASH, K. J., ELHAMOUI, H., MILLIGAN, R., PATEL, A. S., TSIVOS, D. V., WING, T., PHILLIPS, E., KELLMAN, S. M., SHACKLETON, H. L., SINGLETON, G. F., NEALE, B. E., WATTON, M. E. a CULLUM, S. Mini-Mental State Examination (MMSE) for the detection of dementia in clinically unevaluated people aged 65 and over in community and primary care populations. *Cochrane Database of Systematic Reviews*. 2016, 2016(1), CD011145. DOI: 10.1002/14651858.CD011145.pub2.

DAVE, M. a PATEL, N. Umělá inteligence ve zdravotnictví a školství. *British Dental Journal* [online]. 2023, 234, s. 761–764. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1038/s41415-023-5845-2>

DAVENPORT, T. a KALAKOTA, R. The potential for artificial intelligence in healthcare. *Future Healthcare Journal*[online]. 2019, 6(2), s. 94–98. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.7861/futurehosp.6-2-94>

GHAZI, S., PETRÁŠEK, P., KUBALOVÁ, J., MATOUŠEK, T. a ZEMAN, P. Předoperační management geriatrického pacienta. *EC Microbiology* [online]. 2021, 17, s. 109–115. [cit. 11. 2. 2025].

GREEN, S., JONES, R., WILLIAMS, P. a ROBINSON, T. Investigating speech and language impairments in delirium: A preliminary case-control study. *PLoS One* [online]. 2018, 13(11), e0207527. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1371/journal.pone.0207527>

HASHIMOTO, D.A., ROSMAN, G., RUS, D. & MEIRELES, O.R., 2018. Artificial Intelligence in Surgery: Promises and Perils. *Annals of Surgery*, 268(1), s. 70–76. Dostupné z: <https://doi.org/10.1097/SLA.0000000000002693> [cit. 1. 4. 2025].

HEROLD, I. Skórovací schémata hodnocení sedace a výskytu deliria. *Anesteziologie a intenzivní medicína* [online]. 2013, 2013(5), s. 363–366. [cit. 11. 2. 2025]. Dostupné z: <https://www.aimjournal.cz>

HESS, Z. a MAINZ, D. Současná úroveň implementace prvků umělé inteligence do medicíny. Společnost všeobecného lékařství ČLS JEP [online]. ISSN 1213-8711. [cit. 11. 2. 2025]. Dostupné z: <http://hdl.handle.net/11025/52996>

HOLLER, E., SCHNEIDER, J., KÖHLER, F., WAGNER, M., FISCHER, A., MÜLLER, T. a BRAUN, S. Development and Validation of a Routine Electronic Health Record-Based Delirium Prediction Model for Surgical Patients Without Dementia: Retrospective Case-Control Study. *JMIR Perioperative Medicine* [online]. 2025, 8, e59422. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.2196/59422>

HUANG, S., CAI, N., PACHECO, P. P., NARRANDES, S., WANG, Y. a XU, W. Applications of Support Vector Machine (SVM) Learning in Cancer Genomics. *Cancer Genomics & Proteomics*. 2018, 15(1), s. 41–51. DOI: 10.21873/cgp.20063.

CHOI, J. Y., PARK, H. S., LEE, K. W., KIM, J. S. a HWANG, S. H. Development and Validation of a Prognostic Classification Model Predicting Postoperative Adverse Outcomes in Older Surgical Patients Using a Machine Learning Algorithm: Retrospective Observational Network Study. *Journal of Medical Internet Research* [online]. 2023, 25, e42259. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.2196/42259>

JIN, Z., HU, J. a MA, D. Postoperative delirium: perioperative assessment, risk reduction, and management. *British Journal of Anaesthesia* [online]. 2020, 125(4), s. 492–504. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1016/j.bja.2020.06.063>

JONES, R. a LARKIN, P. AI-Assisted Nursing: Emerging Technologies and Their Role in Patient Care. *Journal of Nursing Informatics* [online]. 2020, 25(3), s. 47–55. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1016/j.jni.2020.06.003>

KHAN, S. H., LINDROTH, H., JAWED, Y., WANG, S., NASSER, J., SEYFFERT, S., NAQVI, K., PERKINS, A. J., GAO, S., KESLER, K. a KHAN, B. Serum Biomarkers in Postoperative Delirium After Esophagectomy. *Annals of Thoracic Surgery* [online]. 2022, 113(3), s. 1000–1007. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1016/j.athoracsur.2021.03.035>

KNUDSEN, J. E., PETERSEN, J. H., OLSEN, T. R. a ANDERSEN, P. H. Clinical applications of artificial intelligence in robotic surgery. *Journal of Robotic Surgery* [online]. 2024, 18(1), 102. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1007/s11701-024-01867-0>

KONG, Y. a CAO, Y. Machine learning-based prediction of postoperative delirium in elderly patients: A review of recent developments. *Frontiers in Medicine* [online]. 2021, 8, 748. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.3389/fmed.2021.690518>

LEE, D. Y., KIM, S. J., PARK, J. H., CHOI, W. S. a LEE, S. H. Machine learning-based prediction model for postoperative delirium in non-cardiac surgery. *BMC Psychiatry* [online]. 2023, 23(1), 317. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1186/s12888-023-04768-y>

LIU, Y., SHEN, W. a TIAN, Z. Using Machine Learning Algorithms to Predict High-Risk Factors for Postoperative Delirium in Elderly Patients. *Clinical Interventions in Aging* [online]. 2023, 18, s. 157–168. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.2147/CIA.S398314>

MAREČKOVÁ, J. a KLUGAROVÁ, J. Evidence-based health care: zdravotnictví založené na vědeckých důkazech. Olomouc: Univerzita Palackého v Olomouci, 2015. ISBN 978-80-244-4784-1.

MATHES, T. a PIEPER, D. Algorithm for classifying study proposals for assessing the accuracy of diagnostic, prognostic, and predictive tests in systematic reviews. *Systematic Reviews*. 2019, 8, 226. DOI: 10.1186/s13643-019-1131-4.

MEAGHER, D. J., MORRISON, C., COONEY, M., KENNEDY, P., O'REILLY, L., O'HANLON, D., TULLY, A., DUFFY, L., KANE, R., COONEY, T., O'CONNOR, M.,

KEARNS, P., O'GRADY, J., SHARKEY, E., O'DONOVAN, A., WHELAN, S., MULCAHY, R., KEHOE, M., SCANLON, L., MURPHY, D. a MACLULLOCH, G. Concordance between DSM-IV and DSM-5 criteria for delirium diagnosis in a pooled database of 768 prospectively evaluated patients assessed with the Delirium Rating Scale-Revised-98. *BMC Medicine* [online]. 2014, 12, 164. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1186/s12916-014-0164-8>

NEKVINDOVÁ, K., GABRHELÍK, T. a MACHÁT, L. Pooperační delirium up-to-date. *Anesteziologie a intenzivní medicína*. 2023, 34, s. 69–75.

NING, M., WU, L., CHEN, Y., ZHANG, H., LI, J., XU, Q., HUANG, Y., LIU, C., WANG, P. a ZHOU, H. Prediction of Postoperative Delirium in Older Adults from Preoperative Cognition and Occipital Alpha Power from Resting-State Electroencephalogram. *medRxiv* [Preprint]. 1. listopadu 2024. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1101/2024.08.15.24312053>

NOORUNNAHAR, M., CHOWDHURY, A. H., a MILA, F. A. A tree based eXtreme Gradient Boosting (XGBoost) machine learning model to forecast the annual rice production in Bangladesh. *PLoS One*. 2023, 18(3), e0283452. DOI: 10.1371/journal.pone.0283452.

NOWAK, J. K. a WALKOWIAK, J. Study designs in medical research and their key characteristics. *JMS* [online]. 2024, 92(4), e928. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.20883/medical.e928>

OOSTERHOFF, J. H. F., VAN BODEGOM-VOS, L., DE JONGE, R., ZEGERS, M., ARENTZ, S., VERDUYN-LUNEL, A., VERMEER, M. a JOLING, K. Prediction of Postoperative Delirium in Geriatric Hip Fracture Patients: A Clinical Prediction Model Using Machine Learning Algorithms. *Geriatric Orthopaedic Surgery & Rehabilitation* [online]. 2021, 12, p. 21514593211062277. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1177/21514593211062277>

PRISMA, 2021. PRISMA 2020 flow diagram. PRISMA Statement. Dostupné z: <https://www.prisma-statement.org/prisma-2020-flow-diagram> [cit. 1–4–2025].

RACINE, A. M., ALEXANDER, T. C., CHAMBERS, A. N., BERNSTEIN, J. D., WILSON, E. M., O'CONNOR, M. F., TESSMER, A. M., MARCOUX, A. J. a LUTZ, M. W. Machine Learning to Develop and Internally Validate a Predictive Model for Post-operative Delirium in

a Prospective, Observational Clinical Cohort Study of Older Surgical Patients. *Journal of General Internal Medicine* [online]. 2021, 36(2), s. 265–273. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1007/s11606-020-06238-7>

RIGATTI, S. J. Random Forest. *Journal of Insurance Medicine*. 2017, 47(1), s. 31–39. DOI: 10.17849/in-sm-47-01-31-39.1.

ROBERT, N. How artificial intelligence is changing nursing. *Nursing Management* [online]. 2019, 50(9), s. 30–39. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1097/01.NUMA.0000578988.56622.21>

RÖHR, V., SCHMIDT, C., FISCHER, T., WAGNER, S., MÜLLER, J., SCHNEIDER, R., HOFFMANN, L. a KELLER, A. Machine-learning model predicting postoperative delirium in older patients using intraoperative frontal electroencephalographic signatures. *Frontiers in Aging Neuroscience* [online]. 2022, 14, p. 911088. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.3389/fnagi.2022.911088>

RUMMANS, T. A., BASSO, R. A., KIRKLAND, K. S., MATTHEWS, M. S., RYAN, D. W., SHARP, L. K., LINDEN, S. M., O'NEILL, S. a MCCARTHY, T. D. Delirium in elderly patients: evaluation and management. *Mayo Clinic Proceedings* [online]. 1995, 70(10), s. 989–998. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.4065/70.10.989>

SARKER, I. H. Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*. 2021, 2(6), 420. DOI: 10.1007/s42979-021-00815-1.

SHENG, W., LIU, H., CHEN, Y., ZHANG, P., ZHAO, X., WANG, J. a SUN, R. Random forest algorithm for predicting postoperative delirium in older patients. *Frontiers in Neurology* [online]. 2024, 14, p. 1325941. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.3389/fneur.2023.1325941>

SCHRAML, J., NOVÁK, T., PETRÁŠEK, P., KUBÍČEK, R. a VRÁNA, M. Rok v přehledu - roboticky asistovaná chirurgie v ČR. *Anesteziologie a intenzivní medicína*. 2019, 30, s. 288–295.

SMITH, P. a HARRIS, M. Nursing education for Artificial Intelligence: Bridging the gap between technology and practice. *Nursing Education Perspectives* [online]. 2020, 41(1), s. 15–20. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1097/01.NEP.0000000000000600>

SONG, Y. X., WANG, H., CHEN, L., ZHANG, J., LI, X., GAO, P., LIU, M. a DENG, Y. Comparison of logistic regression and machine learning methods for predicting postoperative delirium in elderly patients: A retrospective study. *CNS Neuroscience & Therapeutics* [online]. 2023, 29(1), s. 158–167. [cit. 11. 2. 2025]. Dostupné z: <https://doi.org/10.1111/cns.13991>

ŠTĚPÁNKOVÁ, H., NIKOLAI, T., LUKAVSKÝ, J., BEZDÍČEK, O., VRAJOVÁ, M. a KOPEČEK, M., 2015. Mini-Mental State Examination – česká normativní studie. *Česká a slovenská neurologie a neurochirurgie*, 78(1), s. 57–63. Dostupné z: <https://www.csmn.eu/casopisy/ceska-slovenska-neurologie/2015-1/mini-mental-state-examination-ceska-normativni-studie-50969>

UNIVERZITA PARDUBICE, 2019. Obecná doporučení pro psaní DP. [interní dokument]. Pardubice: Fakulta zdravotnických studií Univerzity Pardubice. Dostupné u studijní oddělení fakulty.

WHITLOCK, E. L., VANNUCCI, A. a AVIDAN, M. S. Postoperative delirium. *Minerva Anestesiologica*. 2011, 77(4), s. 448–456.

XIONG, X., FU, H., XU, B., WEI, W., ZHOU, M., HU, P., REN, Y. a MAO, Q., 2025. Ten Machine Learning Models for Predicting Preoperative and Postoperative Coagulopathy in Patients With Trauma: Multicenter Cohort Study. *Journal of Medical Internet Research*, [online]. 27, e66612. DOI: 10.2196/66612. PMID: 39841523.

YAN, E., VEITCH, M., SARIPELLA, A., ALHAMDAH, Y., BUTRIS, N., TANG-WAI, D. F., TARTAGLIA, M. C., NAGAPPA, M., ENGLISAKIS, M., HE, D., a CHUNG, F. Association between postoperative delirium and adverse outcomes in older surgical patients: A systematic review and meta-analysis. *Journal of Clinical Anesthesia*. 2023, 90, 111221. DOI: 10.1016/j.jclinane.2023.111221.

8 PŘÍLOHY

Příloha A – Dohledané výsledky podle klíčových slov v databázi PubMed

Dotazový box

Zde zadejte / upravte svůj vyhledávací dotaz

Zobrazit
Vyhledává

Historie a podrobnosti vyhledávání Stáhnout Vymazat

Vyhledávání	Akce	Podrobnosti	Dotaz	Výsledky	Čas
#6	...	>	Hledat: ((#1 AND (#2) AND (#3) Filtry: za posledních 5 let, bezplatný celý text	46	04:28:35
#5	...	>	Hledat: ((#1 AND (#2) AND (#3) Filtry: Volný plný text	51	04:28:31
#4	...	>	Hledat: ((#1 AND (#2) AND (#3) Filtry: Abstrakt, Volný plný text	51	04:28:20
#3	...	>	Hledat: (("umělá inteligence"[Název/Soubor]) NEBO ("strojové učení"[Název/Soubor])) NEBO ("hluboké učení"[Název/Soubor]) Filtry: Abstrakt, Volný plný text	154,753	04:27:43
#2	...	>	Hledat: (delirium[Titul/Abstrakt]) NEBO (delirious[Titul/Abstrakt]) Filtry: Abstrakt, Volný plný text	9,359	04:26:53
#1	...	>	Hledat: ((chirurgie*[nadpis/soubor]) NEBO (chirurgický*[nadpis/soubor])) OR (operace*[nadpis/abstrakt]) Filtry: Abstrakt, Volný celý text	888,799	04:26:31

Zobrazeno 1 až 6 z 6 záznamů

Literární zdroje NCBI [Pletivo](#) [PMC](#) [Regál](#) [Zřeknutí se odpovědnosti](#)