UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



BENCHMARKING NEMOCNÍC POMOCOU DRG

DIPLOMOVÁ PRÁCA

2019 Bc. Dominika IŽDINSKÁ

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

BENCHMARKING NEMOCNÍC POMOCOU DRG

DIPLOMOVÁ PRÁCA

Študijný program:	Ekonomicko-finančná matematika a modelovanie
Študijný odbor:	1114 Aplikovaná matematika
Školiace pracovisko:	Katedra aplikovanej matematiky a štatistiky
Vedúci práce:	Mgr. Henrieta Tulejová, MSc.

Bratislava 2019 **Bc. Dominika IŽDINSKÁ**





Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Dominika Iždinská
Študijný program: ekonomicko-finančná matematika a modelovanie (Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: aplikovaná matematika
Typ záverečnej práce: diplomová
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: Benchmarking nemocníc pomocou DRG
Benchmarking of hospitals with use of DRG data

Anotácia: V posledných rokoch sa zavádza nový spôsob úhrady zdravotnej starostlivosti poskytovanej v nemocniciach – tzv. DRG. Vďaka tomuto platobnému mechanizmu majú zdravotné poisťovne aj nemocnice k dispozícii množstvo nových dát o tom, čo konkrétne sa deje s pacientom v nemocniciach. Pomocou týchto dát je možné porovnávať nemocnice a motivovať ich zvyšovaniu efektívnosti a k odstraňovaniu zbytočných nákladov. Nemocnice môžu pomocou benchmarkingu lepšie riadiť svoje príjmy (pomocou správneho vykazovania) ale aj náklady na jednotlivé hospitalizačné príklady - identifikovať neefektívnosť, nekvalitu a chyby pri poskytovaní starostlivosti a navrhovať opatrenia. Benchmarking tak môže pomôcť k zvýšeniu kvality a organizácie zdravotnej starostlivosti v nemocniciach.

Vedúci: Mgr. Henrieta Tulejová, MSc.
Katedra: FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky
Vedúci katedry: prof. RNDr. Daniel Ševčovič, DrSc.

Dátum zadania: 25.01.2018

Dátum schválenia: 25.01.2018 prof. RNDr. Daniel Ševčovič, DrSc.
garant študijného programu

.....
študent

.....
vedúci práce

Poďakovanie Touto cestou by som rada poďakovala mojej školiteľke Mgr. Henriete Tulejovej, MSc., MUDr. Ing. Danielovi Hodycovi Ph.D. a ďalším kolegom z firmy Advance Hospital Analytics za príležitosť, užitočné materiály, ochotu a cenné rady pri písaní práce. Špeciálne ďakujem MUDr. Petrovi Tůmovi za pomoc s pochopením a interpretáciou klinických súvislostí. V neposlednom rade ďakujem mojej rodine, priateľovi a kamarátom za trpezlivosť a podporu.

Abstrakt v štátnom jazyku

IŽDINSKÁ, Dominika: Benchmarking nemocníc pomocou DRG [Diplomová práca], Univerzita Komenského v Bratislave, Fakulta matematiky, fyziky a informatiky, Katedra aplikovanej matematiky a štatistiky; školiteľ: Mgr. Henrieta Tulejová, MSc., Bratislava, 2019, 73 s.

Práca sa zaoberá tvorbou sady ukazovateľov kvality nemocníc a následnou štandardizáciou vybraného ukazovateľa. V teoretickej časti je čitateľ oboznámený s kontextom merania kvality, sadou ukazovateľov navrhnutou na základe skúseností zo zahraničia a metódou štandardizácie. V praktickej časti sú predstavené testované modely logistickej regresie určené na štandardizáciu ukazovateľa *Úmrtnosť po ischemickej cievnej mozgovej príhode* založené na rôznych kombináciách rizikových faktorov, z ktorých je následne vybraný model s najvyššou diskriminačnou schopnosťou. V závere práce je model aplikovaný na hodnotenie nemocníc v skúmanej vzorke.

Kľúčové slová: kvalita, ukazovatele, štandardizácia, DRG, logistická regresia

Abstract

IŽDINSKÁ, Dominika: Hospital benchmarking with use of DRG [Diploma Thesis], Comenius University in Bratislava, Faculty of Mathematics, Physics and Informatics, Department of Applied Mathematics and Statistics; Supervisor: Mgr. Henrieta Tulejová, MSc., Bratislava, 2019, 73p.

The thesis deals with development of a set of hospital quality indicators and with consecutive risk adjustment of selected indicator. In the theoretical part, the context of quality measurement is provided, as well as a set of indicators based on researched literature and method of risk adjustment. The practical part introduces logistic regression models for risk adjustment of *Acute ischemic stroke mortality rate*, based on different combinations of risk factors. The model with the highest discrimination ability is selected as the final model and applied as a tool for hospital profiling.

Keywords: quality, indicators, risk adjustment, DRG, logistic regression

Obsah

Úvod **8**

1 Úvod do merania kvality nemocníc **10**

1.1 Koncept kvality a ukazovateľov kvality 10

1.2 Počiatky merania kvality vo svete 13

1.3 Má meranie kvality dopad na jej zlepšenie? 14

2 Štandardizácia ukazovateľov **16**

2.1 Prečo štandardizovať výsledkové ukazovatele 16

2.2 Proces štandardizácie 17

2.3 Modelovanie rizikovo štandardizovanej miery 18

2.3.1 Logistická regresia 18

2.3.2 Výpočet variancie a intervalov spoľahlivosti 19

3 Prehľad zahraničných systémov merania kvality **21**

4 Aplikácia na nemocničné dáta v Českej republike **24**

4.1 Klasifikačný systém DRG v ČR 24

4.2 Možnosti a obmedzenia 25

4.3 Výber ukazovateľov 26

4.4 IQI 17C - Miera úmrtnosti po ischemickej cievnej mozgovej príhode 28

5 Spracovanie dát a výber premenných **29**

5.1 Popis dátového súboru 29

5.2 Chýbajúce dáta 30

5.2.1 Spôsob prepustenia 31

5.2.2 Pohlavie 32

5.2.3 Spôsob prijatia 32

5.3 Výber premenných 33

5.3.1 Nemocnica 33

5.3.2 Vek 35

5.3.3 DRG 36

5.3.4 Hlavná diagnóza a vedľajšie diagnózy 39

6 Modelovanie očakávanej úmrtnosti **42**

6.1 Hodnotenie modelu 42

6.1.1 Klasifikačné tabuľky 42

6.1.2 ROC krivka a concordance index 44

6.1.3 Akaikeho infromačné kritérium (AIC) 47

6.2 Predstavenie a porovnanie modelov 48

6.2.1 Demografický model 49

6.2.2 DRG model 49

6.2.3 VDG model 50

6.2.4 Tvorba úsporného modelu 51

6.2.5 Zohľadnenie klinických súvislostí 53

7 Hodnotenie nemocníc **56**

7.1 Zhrnutie 59

Záver **61**

Zoznam použitej literatúry **63**

Úvod

Meranie kvality zdravotnej starostlivosti sa v dnešnej dobe stáva zaužívanou praxou v čoraz väčšom počte krajín a nadnárodných iniciatív. Obzvlášť zaujímavým je meranie kvality nemocníc, ktoré má potenciál poskytnúť užitočné informácie samotným nemocniciam, zdravotným poisťovniam i širokej verejnosti. Konštrukcia zmysluplného rámca pre jej meranie sa však stretá s mnohými problémami na úrovni výberu meraných ukazovateľov ich štandardizácie i spôsobu zverejňovania a interpretácie výsledkov. Správne nastavený systém merania kvality môže dopomôcť k jej zvyšovaniu, ak sa však niektoré z aspektov jeho tvorby podcenia, môže byť neužitočný, prípadne motivovať lekárov k nečestnému konaniu vedúcemu k falošne pozitívnym hodnoteniam.

Česká republika patrí medzi krajiny, v ktorých je meranie kvality zatiaľ iba na začiatku svojej cesty. Hodnotenia českých nemocníc majú poväčšine charakter rebríčkov, založených do veľkej miery na subjektívnom pohľade zamestnancov alebo personálu. Najvýraznejšou iniciatívou bol projekt ministerstva zdravotníctva *Vývoj národní sady ukazatelů zdravotních služeb* z roku 2008 [29], ukazovatele však boli štandardizované iba vzhľadom na vek a pohlavie pacientov, hodnotenie teda nebolo očistené od potenciálnych vplyvov chorobnosti pacientov.

Cieľom našej práce je voľne nadviazať na túto iniciatívu a položiť základ pre meranie s väčšou mierou objektivity. Na základe skúseností zo zahraničia chceme navrhnúť sadu rizikovo štandardizovaných ukazovateľov kvality na hodnotenie českých nemocníc, ktoré by využívali informácie o vedľajších diagnózach prípadu a Diagnoses related group (DRG). V praktickej časti práce chceme následne pre vybraný ukazovateľ vytvoriť model štandardizácie a vyhodnotiť kvalitu poskytovanej starostlivosti 22 českých nemocníc vzhľadom na daný ukazovateľ.

V prvej kapitole uvedieme čitateľa do kontextu merania kvality vo svete, stručne zhrnieme históriu a načrtneme doterajšie skúsenosti s meraním kvality a zverejňovaním výsledkov merania. V druhej kapitole sa venujeme konceptu štandardizácie, vysvetlíme dôvody pre štandardizáciu ukazovateľov a odvodíme použité matematické metódy. V tretej kapitole predstavíme výsledky našej rešerše zahraničných systémov a požitých rizikových faktorov, na základe ktorej potom v štvrtej kapitole navrhneme sadu ukazovateľov použiteľných v prostredí českých nemocničných dát. Vyberieme tiež ukazovateľ, ktorého

štandardizácií sa budeme venovať v praktickej časti práce. V piatej kapitole popíšeme náš dátový súbor, proces čistenia dát, prvotný výber rizikových faktorov a prípadné transformácie. V šiestej kapitole popíšeme proces tvorby modelov a vyberieme finálny model štandardizácie. Nakoniec v siedmej kapitole predstavíme hodnotenie kvality nemocníc vzhľadom na náš ukazovateľ.

1 Úvod do merania kvality nemocníc

1.1 Koncept kvality a ukazovateľov kvality

Rovnako ako všetky ostatné odvetvia, aj zdravotníctvo sa postupne vyvíja a mení. Veda stále prináša nové objavy a moderné technológie sa stávajú dôležitou súčasťou každodennej klinickej praxe, uľahčujúc tak lekárom kedysi náročné a zdĺhavé procedúry. Cieľom všetkých objavov a inovácií je – jednoducho povedané – zvyšovanie kvality zdravotnej starostlivosti. Samotný pojem kvalita má viacero definícií, niektoré kvalitu definujú napríklad ako *mieru dokonalosti* (oxford dictionary) alebo *dosahovanie a poskytovanie zdravia a uspokojenia* (Avedis Donabedian), v našom kontexte by sme ho tiež mohli „voľne preložiť“ ako pozitívny efekt starostlivosti na zdravotný stav pacienta.

Objavy a inovácie pomáhajú zvyšovať kvalitu na celospoločenskej úrovni a podieľajú sa tak na jej raste v čase. Choroby, ktoré boli pred 100 rokmi často príčinou smrti pacientov dnes vieme úspešne liečiť a môžeme predpokladať, že podobne sa v priebehu rokov popasujeme i so závažnými ochoreniami súčasnosti. Okrem tohto globálneho pohľadu na kvalitu je tu však i jej lokálny rozmer, resp. jej variabilita medzi jednotlivými krajinami a zdravotnými zariadeniami v rámci krajiny, na ktorého vysvetlenie nám už nepostačuje súčasná úroveň spoločného poznania a miera technologickej vyspelosti spoločnosti. Samozrejme, poznanie, technologická vyspelosť či schopnosť pružne reagovať na aktuálny pokrok nie sú rovnaké v každej krajine a úzko súvisia s úrovňou ekonomiky krajiny, rozdiely medzi bohatšími a chudobnejšími krajinami sa preto pretavujú i do rozdielov v kvalite zdravotnej starostlivosti. Rozdiely však môžeme pozorovať i medzi podobne ekonomicky vyspelými krajinami, z čoho môžeme usudzovať, že otázka kvality je komplexnejšia a zahŕňa viacero aspektov, ktoré nemusia byť na prvý pohľad zjavnými zdrojmi kvality, alebo jej absencie. Organizácia pre hospodársku spoluprácu a rozvoj (OECD) zverejňuje každoročne štatistiky o úrovni kvality rôznych aspektov zdravotnej starostlivosti členských štátov. Na nasledujúcom grafe môžeme vidieť štandardizovanú mieru úmrtnosti po hospitalizácií na akútny infarkt myokardu v niekoľkých krajinách OECD. (Pozn.: šírka čiary prestavuje relatívny počet nemocníc v danej krajine, v ktorých bola zaznamenaná príslušná miera úmrtnosti).

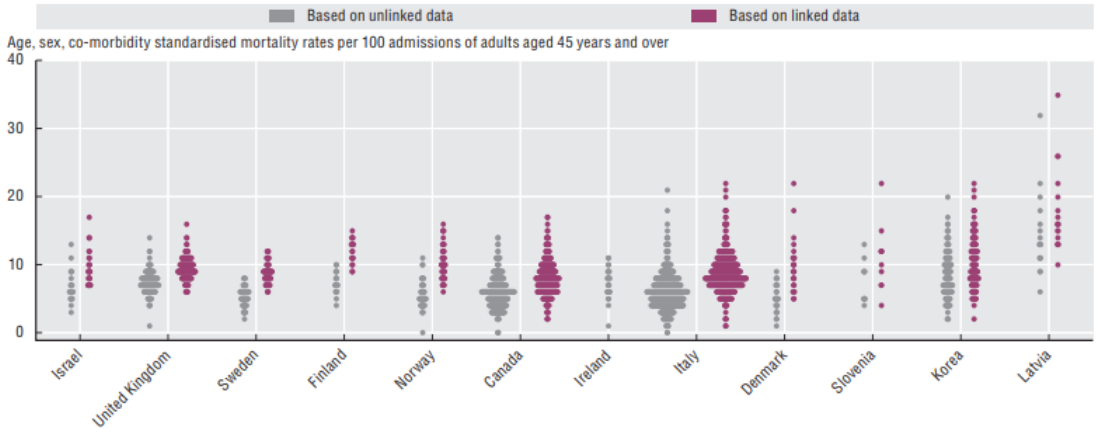

Obr. 1: 30-denná mortalita po prijatí do nemocnice na akútny infarkt myokardu, 2013-2015, [26]

Rovnako ako medzi jednotlivými krajinami, rozdiely môžeme pozorovať i medzi rôznymi zariadeniami, poskytujúcimi zdravotnú starostlivosť v rámci jednej krajiny alebo jej regiónu. Existencia takýchto rozdielov potom už prirodzene nastoľuje otázku, čo je ich príčinou, a či je v možnostiach „menej kvalitných" krajín či zariadení priblížiť sa k tým kvalitnejším a tak zvýšiť spoločné blaho spoločnosti.

Pojem kvality v kontexte zdravotnej starostlivosti, ako sme už naznačili vyššie, má viacero definícií, voľne zhrnuteľných ako pozitívny efekt starostlivosti na zdravotný stav pacienta. Z praktického hľadiska však výber definície nie je natoľko dôležitý ako „rozklad" pojmu kvalita na jednotlivé dimenzie [27]. Tento rozklad nie je jednoznačný a každá krajina či nadnárodná iniciatíva, zaoberajúca sa meraním kvality zdravotnej starostlivosti, má odlišný zoznam dimenzií a často i ich definícií. Pre lepšie pochopenie uvádzame príklad z dokumentu *Zlepšení systému řízení zdravotní péče, technická asistence* [27], , ktorého cieľom je poskytnúť rámec pre prácu s kvalitou zdravotnej starostlivosti v ČR. Autori dokumentu kvalitu a výkonnosť zdravotných služieb navrhujú rozdeliť na 7 atribútov (viď. Tabuľka 1).

Rozklad pomerne abstraktného, ťažko definovateľného pojmu kvalita na konkrétnejšie dimenzie alebo oblasti nám ho umožňuje lepšie uchopiť. Pokiaľ však chceme kvalitu vyhodnocovať, potrebujeme nástroj, ktorý nám umožní rozbiť ju na ešte menšie, kvantitatívne merateľné celky. Medzi takéto nástroje partia tzv. ukazovatele (resp. indikátory) kvality (angl. *Quality indicators*), predstavujúce určité štatistické zistenia založené na

	Atribút	Definícia
1	Prístup	Služby sú pacientovi poskytnuté včas, na správnom mieste a u správneho poskytovateľa
2	Nadväznosť	Služby na seba vhodne nadväzujú, sú poskytované plynule a koordinovane a sú ukončené vo vhodnom čase
3	Primeranosť	Služby sú poskytované v primerane vybavených zariadeniach, primerane erudovanými zdravotníkmi primeranými postupmi, primeranými zdrojmi
4	Účinnosť	(resp. Efektívnosť), Služby sú preukázateľne účinné a vedú k žiaducim výsledkom
5	Hospodárnosť	(resp. Efektivita), služby sú poskytované hospodárne, berúc sa do úvahy spotrebu zdrojov a alokačnú efektivitu
6	Prijateľnosť	Služby sú poskytované spôsobom prijateľným pre pacienta, s ohľadom na interpersonálny aspekt poskytovaných služieb
7	Bezpečnosť	Služby sú poskytované bezpečným spôsobom

Tabuľka 1: Atribúty kvality [27]

číselných faktoch, slúžiace k poznaniu, monitorovaniu alebo vyhodnocovaniu konkrétneho aspektu kvality [27]. Ukazovateľom kvality môže byť napríklad počet prístrojov, množstvo zákrokov vykonaných v danom zariadení či úmrtnosť pacientov po konkrétnom zákroku. Ukazovatele môžeme deliť do skupín viacerými spôsobmi, v literatúre sa však často stretávame so zaužívaným delením na štrukturálne, procesné a výsledkové [12]. Štrukturálne ukazovatele nám podávajú informáciu o vybavení nemocnice, meriame nimi napríklad počet sestier na oddelení, množstvo zákrokov konkrétneho typu priemerne vykonaných doktorom v danej inštitúcií či mieru využitia IT technológie. Procesné ukazovatele nás zase informujú o dodržiavaní definovaných štandardov liečby, napr. o tom, či boli pacientovi podané správne lieky v správnom čase, alebo či podstúpil všetky potrebné predoperačné procedúry. Výsledkové ukazovatele sa už venujú priamo výsledkom liečby, monitorujú

napríklad mieru úmrtnosti alebo komplikácií po konkrétnych zákrokoch.

1.2 Počiatky merania kvality vo svete

Nasledujúci krátky náhľad do histórie merania kvality sme spracovali podľa [10].

Už Florence Nightingale v päťdesiatych rokoch 19. storočia preukázala, že zvýšením hygienických štandardov možno zredukovať mortalitu ranených vojakov a položila tak prvé základy zvyšovania kvality založeného na dôkazoch. Za oficiálneho zakladateľa systematického monitorovania a skúmania medicínskych výstupov je často považovaný Ernest Amory Codman, žijúci na prelome 19. a 20. storočia. Ako prvý uchovával informácie o svojich pacientoch (demografické charakteristiky, diagnóza, liečba a výstupy) na špeciálnych kartách a veril, že pochopenie príčin neúspešnej liečby je základom jej vylepšovania a zvyšovania kvality. Spolu s gynekológom Edwardom Martinom založili v roku 1913 American College of Surgeons (ACS) a spolu s ním i viacero komisií, medzi ktorými bola aj Komisia pre nemocničnú štandardizáciu. Jej zakladatelia verili v systém, v ktorom je povinnosťou každej nemocnice uchovávať informácie o všetkých prípadoch, prístupné pre ďalší výskum a kontrolu. Položili tak základ pre vznik ďalších komisií a asociácií a formovanie minimálnych štandardov, ktoré boli nemocnice povinné spĺňať. Tieto procesy formovania vyústili v osemdesiatych rokoch dvadsiateho storočia do implementácie akreditačných štandardov založených na už spomínanom delení aspektov kvality na štruktúru, proces a výsledky, predstavenom Avedisom Donabedianom v článku *Hodnotenie kvality zdravotnej starostlivosti*. Dlhodobo prevládajúci pohľad na kvalitu ako na prirodzený dôsledok fungujúcej štruktúry a dostatočného vybavenia nemocnice bol významne prehodnotený na základe zverejnených štatistík úmrtnosti. Rozsiahla správa vydaná *Institute of medicine* odhadla počet úmrtí v USA v dôsledku medicínskych pochybení na 44 000 – 98 000 ročne, čím rozpútala intenzívne verejné diskusie a ešte viac motivovala rôzne inštitúcie a orgány k snahe o meranie (a v jeho dôsledku zvyšovanie) kvality zdravotnej starostlivosti.

V dnešnej dobe je už meranie kvality bežnou súčasťou zdravotných systémov krajín. Môže byť iniciatívou ministerstva zdravotníctva, poisťovní, samotných nemocníc alebo spadať pod nezávislé výskumné agentúry.

1.3 Má meranie kvality dopad na jej zlepšenie?

Meranie kvality nie je jednoduché a pokiaľ chceme dosiahnuť komplexné výsledky s adekvátnou výpovednou hodnotou, vyžaduje si veľa času a energie. Je teda na mieste položiť si na začiatku otázku, či a akým spôsobom vie toto meranie a zverejňovanie jeho výsledkov pozitívne ovplyvniť zdravotnú starostlivosť.

Kvalita starostlivosti je prirodzene záujmom všetkých troch zúčastnených strán – pacientov, poskytovateľov a inštitúcií, ktoré za starostlivosť platia – teda zdravotných poisťovní. Pre pacientov môžu byť relevantné informácie o kvalite zdravotníckych zariadení užitočnou pomôckou pri výbere nemocnice, čo pri väčšom množstve informovaných pacientov môže viesť k vytvoreniu tlaku na menej kvalitných poskytovateľov. Ak sa nerozhodnú reagovať na negatívne štatistiky riešením identifikovaných problémov, budú postupne prichádzať o pacientov a teda i zdroj svojho príjmu. I bez tlaku pacientov však môžu mať výsledky meraní kvality vplyv na poskytovateľov, pokiaľ sa úprimne snažia poskytovať čo najlepšiu starostlivosť, ale bez globálneho pohľadu nevedia oblasti nekvality sami spoľahlivo identifikovať. Ďalším kanálom motivácie poskytovateľov môže byť i preventívna obava z tlaku pacientov alebo poisťovní. Pre tie môžu mať výsledky merania užitočný informatívny charakter. Spôsoby, akými môžu poisťovne od nemocníc kvalitu vyžadovať závisia zrejme od konkrétneho zdravotného systému, v niektorých krajinách ako napríklad USA sa však začína rozmáhať trend platobných systémov „platby za výkon“ (angl. *Pay for performance*), ktoré sa snažia odmeňovať lekárov a inštitúcie vzhľadom na kvalitu poskytnutej starostlivosti.

Tieto teoretické argumenty čelia v praxi pomerne rozporuplným výsledkom. Efekt na rozhodovanie pacientov označujú mnohé štúdie za malý až takmer žiadny, prípadne iba krátkodobý. Dôvodov je viacero, Mannion a Goddard v sumarizácií literatúry [21] spomínajú napríklad krátkosť času na rozhodovanie po vypuknutí choroby, problémy s interpretáciou údajov prezentovaných ukazovateľom a s porozumením technickým termínom a kvantitatívnym dátam, ochotu spoliehať sa viac na neformálne informácie poskytnuté rodinou a známymi než na oficiálne dokumenty či neochotu cestovať za kvalitnejším poskytovateľom príliš ďaleko. Niektoré z týchto dôvodov jasne naznačujú, že interpretácia výsledkov merania je dôležitým kľúčom k dosiahnutiu želaného efektu a teda jej spôsob by sa nemal podceňovať. Trochu lepšie je na tom odozva poskytovateľov, u ktorých via-

ceré štúdie ([9],[20]) potvrdili ochotu reagovať na výsledky adaptovaním rôznych programov na zvyšovanie kvality, re-edukáciou personálu či dôkladnejším monitorovaním výkonu lekárov. Dôležitú rolu tu však hrá spôsob, akým sú výsledky prezentované – výrazne vyššiu mieru aktivít zameraných na zvýšenie kvality zaznamenali štúdie (napr. [15]) v prípadoch, kedy boli výsledky prezentované verejne (oproti prípadom, kedy svoje vlastné výsledky obdržala iba daná nemocnica) a teda vplývali na povesť a obraz nemocnice u širokej verejnosti. Nie všetky výsledky štúdií sú však natoľko povzbudivé. Niektoré (napr. [25]) odhaľujú i „temnú stránku“ merania kvality a predovšetkým zverejňovania výsledkov – snahu lekárov docieliť dobré výsledky za každú cenu a akýmkoľvek spôsobom, čo okrem želaného zvyšovania kvality zahŕňa i odmietanie riskantnejších pacientov a manipuláciu vykazovaných dát. Dôležitou otázkou je teda i to, ako nastaviť meranie tak, aby nedávalo priestor na aplikovanie nečestných praktík a aby bolo na zreteli stále dobro pacienta a objektívny progres v kvalite.

2 Štandardizácia ukazovateľov

2.1 Prečo štandardizovať výsledkové ukazovatele

Je zrejmé, že ukazovatele rozdelené na štrukturálne, procesné a výsledkové spolu úzko súvisia a pre kompletný obraz o príčinách nekvality poskytnutej starostlivosti je dôležité venovať sa všetkých trom skupinám zároveň. Na prvý pohľad najväčšiu výpovednú hodnotu však majú jednoznačne výsledkové ukazovatele, ktoré priamo poukazujú na oblasti nekvality a sú dobrým štartovacím bodom ďalšej analýzy. Prirodzene, zlý výsledok má z pravidla korene práve v zlej štruktúre alebo neadekvátnych procesoch. Ak má napríklad nemocnica vysokú úmrtnosť po náročnej operácii srdca, môže to byť dôsledkom malého počtu zákrokov vykonaných na oddelení (a následne nedostatočnej praxe lekárov v danej oblasti) alebo nedostačujúceho technického vybavenia nemocnice. Poukázanie na nepriaznivý výsledok je však oveľa silnejším argumentom na preskúmanie a upravovanie štruktúry, než iba informácie o stave štruktúry samotnej, kde ešte korelácia s výslednou nekvalitou nie je natoľko zrejmá.

Meranie niektorých výsledkových ukazovateľov je však na rozdiel od ďalších 2 skupín problematické. Kým počet meracích prístrojov, lekárov na oddelení alebo zákrokov daného typu vykonaných ročne má sama osebe vzhľadom ku kvalite pomerne jednoznačnú interpretáciu (teda čím viac prístrojov nemocnica má, tým „lepšia“ je v danom ukazovateli kvality), informácia o vyššej úmrtnosti nám už tak jasne „víťaza“ neurčí. Smrť pacienta po danom zákroku totiž nie je determinovaná iba kvalitou starostlivosti, ale aj osobitými charakteristikami pacienta. Po vykonaní rovnakého zákroku môžeme u – inak úplne zdravého - pacienta vo veku 18 rokov očakávať smrť s menšou pravdepodobnosťou ako u 70-ročného pacienta s viacerými vedľajšími diagnózami. Ak je teda rozdiel v celkovej skladbe pacientov nemocníc významný, môže to ovplyvniť i hodnoty skúmaného ukazovateľa a nesprávne označiť nemocnicu s rizikovejšími pacientmi za menej kvalitnú, a to aj v prípade, že by poskytovala porovnateľnú, alebo dokonca lepšiu starostlivosť.

Tento problém je zároveň príčinou ďalšieho problému, ktorý sme spomenuli v 1.3, vznikajúceho pri verejnej prezentácií výsledkov a vyvodzovaní následných konsekvencií. Lekári v snahe dosiahnuť čo najlepšie výsledky sú takto motivovaní neposkytnúť liečbu alebo nevykonať kritický zákrok u pacientov, ktorých pravdepodobnosť prežitia nie je

dostatočne vysoká. Potvrdzuje to napríklad štúdia [25], kde v anonymnom dotazníku 83 percent opýtaných kardiológov štátu New York priznalo, že riskantnejší pacienti, ktorým mohlo pomôcť vykonanie angioplastiky, ju nepodstúpili na základe rozhodnutí lekárov, prihliadajúcich na merané výsledkové štatistiky úmrtnosti.

Takto nastavené merania ukazovateľov nám teda nielenže neposkytujú relevantné informácie o kvalite zdravotnej starostlivosti, ale nepriamo manipulujú zdravotný systém a v konečnom dôsledku smerujú práve k neželanému znižovaniu kvality.

2.2 Proces štandardizácie

Aby hodnota ukazovateľa naozaj zodpovedala kvalite poskytovateľa, musíme ju očistiť od neželaného vplyvu skladby pacientov. Tento proces sa volá štandardizácia a jeho výsledkom sú hodnoty ukazovateľov, ktoré by ukazovateľ dosahoval, ak by skladba pacientov danej nemocnice zodpovedala skladbe pacientov v referenčnej populácií. Referenčnú populáciu spravidla tvoria všetky skúmané prípady všetkých skúmaných nemocníc, môže byť však i širšia a zahŕňať napríklad historické dáta o hospitalizáciách v predchádzajúcich rokoch.

Väčšina výsledkových ukazovateľov vyžadujúcich štandardizáciu má formu miery (pomeru) - napr. miera úmrtnosti alebo vzniku danej komplikácie. Nasledujúci popis metódy štandardizácie sme prevzali z [31].

To, čo nás zaujíma, je rizikovo štandardizovaná miera nemocnice R_h. Počítame ju nasledovne:

$$R_h = \alpha \frac{O_h}{E_h} = \alpha \frac{\frac{1}{n_h} \sum_{j=1}^{n_h} y_j}{\frac{1}{n_h} \sum_{j=1}^{n_h} \hat{y}_j}$$

Pozorovaná miera O_h vyjadruje pomer počtu pacientov danej nemocnice, u ktorých nastal skúmaný jav, k celkovému počtu pacientov danej nemocnice v našej vzorke. Ak napríklad počítame mieru nemocničnej úmrtnosti po resekcii pažeráka, pozorovaná miera predstavuje počet pacientov, ktorí v danej nemocnici po tomto zákroku zomreli v pomere k počtu všetkých pacientov, ktorí zákrok v danej nemocnici podstúpili. Y_j nadobúda hodnotu 1, ak u j-teho pacienta jav nastal a hodnotu 0, ak nenastal.

Očakávaná miera E_h vyjadruje, akú pozorovanú mieru očakávame pri daných charakteristikách pacientov nemocnice. Vzťah medzi jednotlivými charakteristikami a výsledkom modelujeme na základe pozorovaných vzťahov v referenčnej populácii. $\hat{Y}_j$ vyjadruje vypočítanú pravdepodobnosť, že u pacienta j s danými charakteristikami jav nastane. Tomu, ako modelujeme vzťah medzi charakteristikami pacientov a výsledkom sa budeme bližšie venovať v ďalších kapitolách.

Pomer pozorovanej a očakávanej miery násobíme pozorovanou mierou pre referenčnú populáciu α. Vďaka tomu dosiahneme, že naša rizikovo štandardizovaná miera odráža to, ako veľmi sa miera pre danú nemocnicu líši od štandardu.

2.3 Modelovanie rizikovo štandardizovanej miery

2.3.1 Logistická regresia

Celkovú očakávanú mieru pre nemocnicu vypočítame ako súčet očakávaných mier jednotlivých pacientov. Pre každého pacienta teda modelujeme pravdepodobnosť, že uňho nastane na základe jeho charakteristík skúmaný výsledok (napr. smrť po danom zákroku). Na modelovanie binárnej premennej existuje v dnešnej dobe veľa rôznych klasifikačných algoritmov. Pri štandardizácií ukazovateľov kvality patrí k obľúbeným algoritmom logistická regresia. Oproti iným klasifikačným algoritmom má tú výhodu, že jej výstupom je priamo pravdepodobnosť nastania skúmanej udalosti, je teda priamočiaro interpretovateľná a jej výstupy už nepotrebujú ďalšiu transformáciu. Nasledujúce odvodenie sme spracovali na základe [14]. Logistická funkcia má tvar:

$$P\big[Y\big(x\big) = 1\big] = \frac{exp\big(X\beta\big)}{1 + exp\big(X\beta\big)}$$

Logistická regresia je založená na transformácií lineárneho regresného modelu pomocou funkcie logit. Lineárny model má vo všeobecnosti tvar

$$Y = X\beta + \epsilon$$

X predstavuje vektor nezávislých premenných, Y vektor závislých (modelovaných) premenných, β vektor koeficientov modelu vyjadrujúcich vzťah medzi X a Y a ϵ chybový člen. Pri takto definovanej funkcii môže predikovaná premenná Y nadobúdať ľubovoľné

hodnoty a nevieme zabezpečiť, že budú v nami želanom intervale $\big(0,1\big)$. Je teda pre nás výhodné transformovať ju na funkciu, ktorej výstupné hodnoty zaručene do tohto intervalu spadnú. Pri tejto transformácií vychádzame z funkcie logit v tvare

$$logit\big(X\big) = log\bigg(\frac{X}{1-X}\bigg)$$

Vidíme, že definičný obor funkcie je práve interval $\big(0,1\big)$ a obor hodnôt je $\big(\infty,-\infty\big)$.Za premennú dosadíme $P\big[Y\big(X\big)=1\big]$ a modelujeme pomocou $X\beta$:

$$logit\big(P\big[Y\big(x\big)=1\big]\big) = log\bigg(\frac{P\big[Y\big(x\big)=1\big]}{1-P\big[Y\big(x\big)=1\big]}\bigg) = X\beta$$

Použitím inverznej funkcie $logit^{-1}$ ďalej upravíme na

$$P\big[Y\big(x\big)=1\big] = logit^{-1}\big(X\beta\big)$$

z čoho dostávame

$$P\big[Y\big(x\big)=1\big] = \frac{exp\big(X\beta\big)}{1+exp\big(X\beta\big)}$$

Matica X predstavuje v našom prípade charakteristiky pacientov, reprezentované pomocou kategorických premenných, a vektor β príslušné koeficienty, vypočítané na základe údajov o populácií pacientov všetkých nemocníc. Výberu premenných a tvorbe nášho modelu sa budeme podrobnejšie venovať v kapitolách 5 a 6.

2.3.2 Výpočet variancie a intervalov spoľahlivosti

Výpočet variance a intervalov spoľahlivosti sme opäť prevzali z oficiálnej dokumentácie ukazovateľov kvality AHRQ [31] a [2], ktoré slúžili ako inšpirácia pre naše modely.

Pripomeňme si základnú formulu na výpočet rizikovo štandardizovanej miery pre nemocnicu h:

$$R_h = \alpha\frac{O_h}{E_h}$$

Na výpočet variancie použijeme delta metódu pre výpočet variancie funkcie dvoch náhodných premenných. S pomocou Taylorovho rozvoja dostávame pre dve všeobecné (potenciálne korelované) náhodné premenné R a S varianciu

$$var\left(\frac{R}{S}\right) \simeq \frac{E\big[R\big]^2}{E\big[S\big]^2}\left(\frac{var\big(R\big)}{E\big[R\big]^2} - 2\frac{cov\big(R,S\big)}{E\big[R\big]E\big[S\big]} + \frac{var\big(S\big)}{E\big[S\big]^2}\right)$$

Z čoho pre varianciu rizikovo štandardizovanej miery dostávame

$$var\big(R_h\big) \simeq \alpha^2\frac{E\big[O_h\big]^2}{E\big[E_h\big]^2}\left(\frac{var\big(O_h\big)}{E\big[O_h\big]^2} - 2\frac{cov\big(O_h,E_h\big)}{E\big[O_h\big]E\big[E_h\big]} + \frac{var\big(E_h\big)}{E\big[E_h\big]^2}\right)$$

Ďalej môžeme zanedbať varianciu prediktora a predpokladať normalitu rozdelenia rizikovo štandardizovanej miery R_h pre limitu $n_h \to \infty$. V tom prípade sa tvar našej formule zjednoduší na

$$\begin{aligned}
var\big(R_h\big) &\simeq \alpha^2\frac{var\big(O_h\big)}{E_h^2} \\
&\simeq \left(\frac{\alpha}{E_h}\right)^2 var\left[\left(\frac{1}{n_h}\right)\sum_{j=1}^{n_h} y_j\right] \\
&\simeq \left(\frac{\alpha}{E_h}\right)^2\left(\frac{1}{n_h}\right)^2 var\left[\sum_{j=1}^{n_h} y_j\right] \\
&\simeq \left(\frac{\alpha}{E_h}\right)^2\left(\frac{1}{n_h}\right)^2\left[\sum_{j=1}^{n_h} var\big(y_j\big)\right] \\
&\simeq \left(\frac{\alpha}{E_h}\right)^2\left(\frac{1}{n_h}\right)^2\sum_{j=1}^{n_h}\Big[\big(P_{hj}\big)\big(1-P_{hj}\big)\Big]
\end{aligned}$$

S využitím takto odhadnutej variancie potom vypočítame aj 95%-né intervaly spoľahlivosti

$$\begin{aligned}
LB &\simeq R_h - 1.96\sqrt{var\big(R_h\big)} \\
UB &\simeq R_h + 1.96\sqrt{var\big(R_h\big)}
\end{aligned}$$

Táto metóda je pomerne pohodlná a výpočtovo nenáročná, existujú však i argumenty v prospech neaproximovaných metód.

3 Prehľad zahraničných systémov merania kvality

Dôležitým krokom pri tvorbe sady ukazovateľov kvality je správny výber ukazovateľov a rizikových faktorov. Keďže, ako sme spomínali, v mnohých krajinách je meranie kvality bežnou súčasťou zdravotného systému, rozhodli sme sa pri tvorbe nášho modelu inšpirovať zahraničnými sadami ukazovateľov, z ktorých sme následne vybrané ukazovatele prispôsobili našim dátam a podmienkam. Na nasledujúcich stranách stručne zhŕňame výsledky rešerše.

Vo všeobecnosti sa modely štandardizácie môžu opierať o 2 typy dát - administratívne a klinické. Klinické dáta obsahujú podrobnejšie informácie o stave pacienta (ako napríklad výsledky laboratórnych testov), sú teda presnejšie, ich zber je však nákladný a nie je jednoduché sa k nim dostať. My máme k dispozícii iba administratívne dáta, hľadali sme preto spôsoby štandardizácie založené na tomto type dát.

Výstupom našej rešerše je tabuľka vo formáte *.xlsx*, uchovávajúca informácie o nasledovných ucelených systémoch indikátorov kvality:

- AHRQ Inpatient quality indicators
- AHRQ Patient safety indicators
- AHRQ Pediatric quality indicators
- AHRQ Prevention quality indicators
- Canadian institute for health information indicators

Agency for healthcare research and quality (AHRQ) je iniciatíva, dlhoročne sa venujúca meraniu kvality v USA, ktorá každoročne vydáva zoznam ukazovateľov aj s podrobnou metodikou ich výpočtu a štandardizácie a hodnotami príslušných koeficientov.

Inpatient quality indicators (IQI) je sada ukazovateľov kvality zariadení akútnej lôžkovej starostlivosti, rozdelená na ukazovatele určené na meranie kvality na úrovni geografickej oblasti a na úrovni nemocníc. Merajú predovšetkým mieru a objem využívania zdravotnej starostlivosti (oblastné ukazovatele) a výsledky zdravotnej starostlivosti, primárne ako ukazovatele miery úmrtnosti po daných zákrokoch alebo pri daných diagnózach. Ukazovatele, ktoré sú štandardizované, sú predovšetkým práve výsledkové ukazovatele

úmrtnosti. Použité rizikové faktory sú vek, pohlavie, hlavné diagnostické kategórie (angl. *Major diagnostic categories, MDC*) a *All patient refined Diagnostic related groups (APR-DRG)*[1] aj so stupňom rizika úmrtia a informácia o potenciálnom transfere pacienta [4].

Patient safety indicators (PSI) je sada ukazovateľov, poskytujúcich informácie o potenciálnych nemocničných komplikáciách a chybách pri chirurgických výkonoch alebo pôrodoch. Ukazovatele sa opäť delia na oblastné a nemocničné. Pri štandardizácií (opäť iba vybraných ukazovateľov) sa ako rizikové faktory využívajú vek a pohlavie, MDC, modifikované DRG, vybrané vedľajšie diagnózy prítomné pri prijatí pacienta do nemocnice, miesto pôvodu pacienta a informácia o potenciálnom transfere pacienta [7].

Pediatric quality indicators (PDI) (opäť rozdelené na oblastné a nemocničné) sa venujú potenciálne predchádzateľným komplikáciám a chybám v pediatrickej nemocničnej starostlivosti. Rizikové faktory pre štandardizované ukazovatele sú vek, pohlavie, pôrodná váha, MDC, modifikované DRG, pôvod pacienta, informácia o potenciálnom transfere pacienta a niektoré špecifické kategórie pre daný ukazovateľ [6].

Prevention quality indicators (PQI) zachytávajú mieru hospitalizácií pacientov s konkrétnymi diagnózami, ktoré sú odvrátiteľné správnou ambulantnou starostlivosťou. Rizikovými faktormi sú v tomto prípade vek a pohlavie [5].

Canadian institute for health information (CIHI) indicators sú ukazovatele vyvíjané každoročne renomovanou kanadskou analytickou inštitúciou. Ukazovateľov je okolo 140 a zachytávajú rôznorodé aspekty zdravotnej starostlivosti. Nájdeme medzi nimi všetky typy ukazovateľov (štrukturálne, procesné aj výsledkové), zachytávajúce všetky dimenzie kvality na rôznych úrovniach (celonárodná, regionálna, poskytovateľská...). Ukazovatele, ktoré sú primárnym objektom nášho záujmu (teda štandardizované, výsledkové ukazovatele na úrovni poskytovateľov) sú tiež pomerne rôznorodé a to sa odráža aj na rizikových faktoroch. Opäť sú prítomné demografické faktory vek a pohlavie, vedľajšie diagnózy (v niektorých prípadoch ako samostatné premenné, v niektorých prostredníctvom Charlsonovho indexu - všeobecne používaného váženého indexu vedľajších diagnóz pacienta). Ďalej sa pri niektorých ukazovateľoch ako rizikové faktory vyskytli nediagnostické premenné ako predchádzajúce hospitalizácie, pobyt na jednotke intenzívnej starostlivosti

[1]DRG je klasifikačný systém, združujúci hospitalizačné prípady podľa diagnostických charakteristík do disjunktných, klinicky a nákladovo homogénnych skupín. APR-DRG je verzia aktuálne využívaná v USA. Fungovanie DRG algoritmu v ČR podrobnejšie popíšeme v 4.1

či urgentný príjem [8].

Zoznam sád ukazovateľov a typov použitých rizikových faktorov uvádzame v tabuľke 2 (nie každý faktor je použitý pri každom ukazovateli).

Sada	**Rizikové faktory**
AHRQ IQI	vek, pohlavie, MDC, APR-DRG a stupeň rizika úmrtia, transfer
AHRQ PSI	vek, pohlavie, MDC, modifikované DRG vybrané vedľajšie diagnózy, miesto pôvodu, transfer
AHRQ PDI	vek, pohlavie, pôrodná váha, modifikované DRG, pôvod pacienta, transfer, špecifické faktory pre niektoré indikátory
AHRQ PQI	vek, pohlavie
CIHI	vek, pohlavie, počet predchádzajúcich hospitalizácií za posledných 6 mesiacov, transfer, prepustenie na vlastné riziko, typ nemocnice (psychiatria/všeobecná), urgentný príjem, Cognitive Performance Score (CPS), Activities of Daily Living (ADL) scale, Personal Severity Index (PSI), vybrané vedľajšie diagnózy, Charlson comorbidity index

Tabuľka 2: Zahraničné sady ukazovateľov kvality a rizikové faktory požité pri štandardizácii

4 Aplikácia na nemocničné dáta v Českej republike

V tejto kapitole popíšeme niektoré špecifiká českého systému vykazovania, dostupných dát a klasifikácie prípadov. V 4.1 najprv stručne vysvetlíme, ako funguje klasifikácia prípadov do DRG, v 4.2 sa budeme venovať možnostiam a obmedzeniam českého systému a v 4.3 predstavíme navrhovanú sadu ukazovateľov, ktorú sme vybrali na základe spomenutých faktorov a konzultácií s odborníkom z klinického prostredia [32]. V 4.4 nakoniec stručne predstavíme ukazovateľ, ktorého štandardizácia bude predmetom praktickej časti našej práce.

4.1 Klasifikačný systém DRG v ČR

Nasledujúcu časť sme spracovali podľa [18]. Klasifikačný systém DRG je v súčasnosti najrozšírenejším klasifikačným systémom hospitalizačných prípadov akútnej lôžkovej starostlivosti. Jeho cieľom je zoskupiť prípady do klinicky podobných a nákladovo homogénnych disjunktných skupín a vďaka tomu uľahčiť mechanizmus hradenia zdravotnej starostlivosti. Umožňuje tiež jednoduchšie monitorovanie poskytovanej starostlivosti, hodnotenie jej vývoja v čase a hodnotenie poskytovateľov. Existuje mnoho rôznych medzinárodných aj národne špecifických úprav DRG systému, všetky však vychádzajú z pôvodného HCFA-DRG vyvinutého v USA.

Ním je inšpirovaný aj systém DRG v ČR, ktorého pilotné implementácie boli spustené pred viac ako 20 rokmi. Každý hospitalizačný prípad je najskôr zaradený na základe hlavnej diagnózy zaznamenanej na príjme do jednej z hlavných diagnostických kategórií (angl. Major Diagnostic Categories - MDC). Tých je 28 (MDC 00 - MDC 25, MDC 88 pre nezaraditeľné prípady a chybová MDC 99). Pokiaľ bol pacientovi počas hospitalizácie vykonaný chirurgický kritický výkon, hospitalizácia je zaradená do chirurgickej skupiny, pokiaľ nie, nechirurgickej. Množiny tzv. báz chirurgického a nechirurgického typu sú disjunktné. V ďalšom kroku je hospitalizácia zaradená do DRG bázy - skupiny konkrétnejšie definovanej hlavnou diagnózou a výkonom. Niektoré bázy sa už ďalej nerozvetvujú, sú to tzv. bázy *bez splitu*. Bázam *so splitom* je v poslednej fáze klasifikácie pridelená jedna z kategórií indikujúcich náročnosť prípadu na základe vykázaných vedľajších diagnóz pacienta - *bez CC* (bez komplikácií a komorbidít), *s CC* (s komplikáciami a komorbiditami)

a *s MCC* (s veľkými komplikáciami a komorbiditami). Schému klasifikácie DRG popisuje nasledujúci diagram:

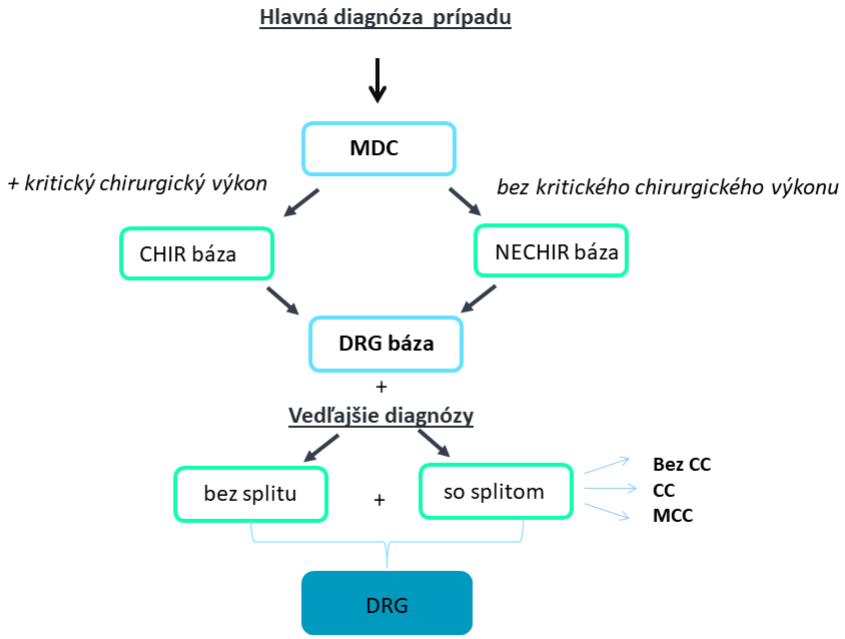

Obr. 2: Schéma algoritmu radenia hospitalizačných prípadov do DRG v ČR

4.2 Možnosti a obmedzenia

V Českej republike sú nemocnice povinné na účely hradenia zdravotnej starostlivosti zbierať administratívne dáta o hospitalizáciách. Tieto dáta obsahujú množstvo informácií o priebehu prípadu z hľadiska administratívy - spôsob a dátum prijatia a prepustenia, prijímajúca odbornosť lekára, počet pobytov na jednotke intenzívnej starostlivosti či ARO. Obsahujú tiež informácie o všetkých stupňoch klasifikácie DRG a zároveň aj „surové"dáta ako hlavnú diagnózu, vedľajšie diagnózy a výkony.

Jedným z hlavných nedostatkov českého dátového rozhrania sú chýbajúce mechanizmy na odlíšenie komorbidít od komplikácií, ktoré sú bežnou súčasťou APR-DRG v USA. Jediná diagnóza, ktorá je určite prítomná na príjme je hlavná diagnóza prípadu, pre všetky ostatné je čas vzniku neznámy. Niektoré ukazovatele tak úplne strácajú zmysel, keďže nevieme povedať, či neželaný výsledok (napr. prítomnosť tlakových vredov) vznikol v nemocnici, alebo nie. Ukazovateľom, ktorých výsledky nevieme jednoznačne zaradiť do epizódy hospitalizácie sme sa teda rozhodli nevenovať. Pri ukazovateľoch, ktorých sa tento

problém netýka (napr. ukazovatele úmrtnosti) však ešte stále hrozí, že pri modelovaní očakávanej miery označíme nesprávne za rizikové faktory pacienta aj dôsledky nekvalitnej starostlivosti, na ktoré sa snažíme poukázať.

S týmto problémom sa, žiaľ, nevieme s aktuálne dostupnými prostriedkami úspešne popasovať. Zo skúseností klinickej praxe však vieme o mnohých diagnózach povedať s pomerne veľkou istotou, že sú komorbiditami (napr. diabetes pri operácií bedrového kĺba) a o iných, že sú to nemocničné komplikácie (napr. cievna komplikácia po infúzii). Po konzultácií [32] sme sa teda rozhodli spomedzi potenciálnych rizikových faktorov vyradiť diagnózy jednoznačných komplikácií T80-T88 a pri vyhodnocovaní modelu dôsledne prihliadať aj na klinický význam jednotlivých prediktorov. Prirodzene, z definície DRG podskupín (*bez CC*,*CC*,*MCC*) je jasné, že ich používanie ako rizikových faktorov nám nedáva možnosť tento problém ošetriť, pri ich použití teda musíme byť zvlášť opatrní.

Pri štandardizácií niektorých ukazovateľov je tiež užitočné vedieť rozlíšiť medzi urgentným a plánovaným príjmom, čo využíva napríklad CIHI sada ukazovateľov, no v ČR tento údaj opäť medzi vykazovanými chýba. Ďalším zdrojom neobjektivity môže byť tendencia nemocníc nevykonávať daný špecifický výkon v takej miere ako iné nemocnice. Napríklad kraniotómia je pomerne náročný zákrok, ktorý niektorí lekári radšej nahradia iným, podobným (ktorého miera úmrtnosti ale už nebude zarátaná v našej definícii miery úmrtnosti po kraniotómií), prípadne pošlú pacientov do inej nemocnice. Tento problém sa však dá jednoducho ošetriť kontrolou početnosti zákrokov v nemocniciach a prioritizáciou ukazovateľov, zameraných na často vykonávané, menej špecifické zákroky.

4.3 Výber ukazovateľov

Ako sme naznačili v predchádzajúcej podkapitole, určité obmedzenia pri výbere ukazovateľov vyplynuli priamo z povahy dostupných dát. Vzhľadom na cieľ našej práce, ktorou je práve štandardizácia ukazovateľov kvality nemocníc sme sa obmedzili na *výsledkové* ukazovatele využívané na hodnotenie *poskytovateľov*. Keďže máme prístup iba k dátam o hospitalizačných prípadoch v danej skupine nemocníc, vylúčili sme ukazovatele, skúmajúce výsledky s *presahom hospitalizačnej epizódy* (napr. nemocničná mortalita do daného času po zákroku, vrátane úmrtia mimo nemocnice).

Zo skúmaných sád sme ako najvhodnejšiu vyhodnotili sadu AHRQ IQI ukazovateľov,

keďže funguje pomerne dlho, prešla viacerými úpravami a k spôsobu výpočtu ukazovateľov je verejne dostupná kvalitná podrobná dokumentácia. Výhodou je aj využitie APR-DRG ako rizikových faktorov (hoci delenie na podskupiny v APR-DRG funguje inak ako v ČR a lepšie reflektuje stav pacienta pri prijatí do nemocnice). Spomedzi IQI ukazovateľov sme vybrali *výsledkové* ukazovatele určené na hodnotenie *poskytovateľov*, čo náš zoznam zúžilo na 21 ukazovateľov. Z nich sme na základe konzultácie [13] vybrali nasledujúcich 7 ukazovateľov, pri ktorých predpokladáme, že ich meranie bude mať význam vzhľadom na frekvenciu zákrokov a možnú variabilitu kvality v českých nemocniciach.

1	IQI 13 Miera úmrtnosti po kraniotómii
2	IQI 14 Miera úmrtnosti po výmene bedrového kĺba
3	IQI 15 Miera úmrtnosti po akútnom infarkte myokardu
4	IQI 16 Miera úmrtnosti po kongestívnom srdečnom zlyhaní
5	IQIB 17B Miera úmrtnosti po cievnej mozgovej príhode - skupina B: Intracelebrálne krvácanie
6	IQIC 17C Miera úmrtnosti po cievnej mozgovej príhode - skupina C: Ischemická cievna mozgová príhoda
7	IQI 19 Miera úmrtnosti po zlomenine bedra

Tabuľka 3: Vybrané IQI indikátory

Na základe [32] sme ďalej porovnaním českého zoznamu výkonov a diagnóz a technických špecifikácií jednotlivých ukazovateľov [30] namapovali české diagnózy a výkony na ich americké ekvivalenty a tak definovali menovatele našich ukazovateľov. Pacienti, ktorým boli prevedené dané výkony alebo hlavná diagnóza spadá medzi definičné diagnózy menovateľa ukazovateľa, budú zaradení do skúmanej vzorky pacientov.

Podotýkame, že úplné prevzatie charakteristík daných indikátorov sa týka iba samotných definícií ukazovateľov, nie však definície rizikových faktorov. V tomto prípade nám AHRQ IQI rizikové faktory budú slúžiť ako inšpirácia, naším cieľom je však nájsť čo najlepšie rizikové faktory pre *naše* dáta, čo pri inom systéme DRG klasifikácie, početnosti prípadov a ďalších špecifikách národného systému vykazovania môžu byť iné premenné.

V praktickej časti sme sa rozhodli proces hľadania vhodných rizikových faktorov a modelu očakávanej miery a tiež porovnávanie nemocníc na základe štandardizovanej miery

demonštrovať na vybranom ukazovateli IQI 17C. Viaceré rozhodnutia a metodické postupy (napríklad predselekcia skupín premenných) sú aplikovateľné i na ostatné ukazovatele, tento text teda môže slúžiť ako inšpirácia pri ďalšej práci a vývoji ukazovateľov kvality.

4.4 IQI 17C - Miera úmrtnosti po ischemickej cievnej mozgovej príhode

Ako modelový ukazovateľ pre proces štandardizácie sme si zvolili ukazovateľ IQI 17C - Miera úmrtnosti po ischemickej cievnej mozgovej príhode. Je podskupinou ukazovateľa IQI 17 - Miera úmrtnosti po cievnej mozgovej príhode. Z jeho podskupín sme do finálneho výberu ukazovateľov zaradili aj IQI 17B, početnosť prípadov v celkovej vzorke aj jednotlivých nemocniciach však bola výrazne nižšia, preto sme sa rozhodli pre IQI 17C.

Cievna mozgová príhoda je druhou najčastejšou príčinou smrti a treťou najčastejšou príčinou invalidity vo svete [28]. Ischemická CMP vzniká vtedy, keď sa v tepnách zhromažďuje tukový povlak, ktorý zužuje tepny zvnútra, čím sa obmedzí prietok krvi. Krv, ktorá nemôže dobre pretiecť tepnou, sa zhlukuje, z čoho začnú vznikať zrazeniny, ktoré následne zablokujú tepnu [33]. Existuje mnoho štúdií, venujúcich sa identifikácií rizikových faktorov na základe klinických i administratívnych dát. My sme sa okrem AHRQ metodiky [4] inšpirovali aj metodikou pre CIHI ukazovatele kvality ([8], 30-denná nemocničná mortalita po cievnej mozgovej príhode). Ako sme však spomínali, vychádzame predovšetkým z našich konkrétnych dát.

Na záver by sme ešte radi podotkli, že problém vzťahu kvality zdravotnej starostlivosti a úmrtnosti je oveľa komplexnejší. Mnoho pacientov zomrie v krátkom čase po prepustení z nemocnice a ďalší majú trvalé následky, na čo tiež do istej miery vplýva aj kvalita poskytnutej starostlivosti. V štúdii [23] sa napríklad uvádza, že iba 65% pacientov po cievnej mozgovej príhode, ktorým lekári predpovedali, že budú po roku schopní nezávisle fungovať, tento stav naozaj dosiahli. Aj napriek týmto obmedzeniam však veríme, že isté príznaky nekvality vieme odhaliť i na základe nášho ukazovateľa.

5 Spracovanie dát a výber premenných

5.1 Popis dátového súboru

Indikátor IQI 17C – Úmrtnosť po ischemickej cievnej mozgovej príhode je v [3] definovaný ako podiel hospitalizácií ukončených úmrtím spomedzi všetkých hospitalizácií pacientov vo veku 18 a viac rokov hospitalizovaných s hlavnou diagnózou Ischemickej cievnej mozgovej príhody. Technická špecifikácia ďalej uvádza kódy prislúchajúce danej diagnóze, na ktoré sme na základe konzultácií [32] namapovali zodpovedajúce ekvivalenty I63.0-I63.9 podľa českého číselníka diagnóz [24].

K dispozícií sme mali databázu všetkých hospitalizácií v 22 českých nemocniciach za obdobie najviac 3 rokov (2015, 2016 a 2017), pričom pre niektoré nemocnice boli dostupné údaje iba za 2 alebo jeden rok. Tieto dáta boli poskytnuté firme Advance Hospital Analytics v rámci projektu nákladového benchmarkingu nemocníc, dostupnosť údajov pre danú nemocnicu teda závisí od jej účasti na projekte v danom roku.

Z tejto databázy sme následne vybrali hospitalizácie, ktorých hlavná diagnóza bola jednou z definičných diagnóz indikátora. Dáta sme dostali vo formáte *.xlsx*, pričom každému hospitalizačnému prípadu zodpovedá jeden riadok súboru. Každý prípad je zároveň popísaný 102 premennými (každej premennej zodpovedá jeden stĺpec súboru), ktoré zaznamenávajú základné demografické (vek, pohlavie) a diagnostické (hlavná, vedľajšia diagnóza) charakteristiky pacienta a tiež priebeh hospitalizácie, popísaný údajmi ako dátum a spôsob prijatia a prepustenia, počet pobytov na jednotke intenzívnej starostlivosti, výkony vykonané pacientovi počas hospitalizácie či zaradenie do DRG skupiny. Súbor ďalej obsahuje 40 stĺpcov zodpovedajúcich nákladovým charakteristikám prípadu, zastúpených predovšetkým nákladmi združenými podľa typu starostlivosti (náklady na výkony podľa typu výkonu, náklady na zvlášť účtovaný materiál, lieky...). Jednotlivým charakteristikám prípadov a ich využitiu v rizikovej štandardizácií sa budeme podrobnejšie venovať v nasledujúcej časti. Všetky analýzy a tiež následná tvorba modelov rizikovej štandardizácie prebiehali v softvéri *RStudio*.

5.2 Chýbajúce dáta

Po odstránení evidentne duplicitnej podmnožiny súboru nám ostalo 21 572 hospitalizačných prípadov. Častým problémom pri práci s databázami hospitalizácií sú chýbajúce údaje. S týmto problémom počíta aj technická špecifikácia ukazovateľa [3], ktorá odporúča vyradiť všetky hospitalizácie s chýbajúcou hodnotou spôsobu prepustenia, veku a pohlavia pacienta. Okrem toho tiež odporúča vyradiť zo súboru prípady ukončené transferom do inej nemocnice. Hospitalizácie ukončené transferom sú, pochopiteľne, veľmi problematické, keďže na rozdiel od pacientov prepustených domov (u ktorých predpokladáme, že boli pri odchode „vyliečení“), u pacientov, ktorí ešte potrebovali ďalšiu starostlivosť, môžeme s veľkou pravdepodobnosťou očakávať práve opak. Jednou z možností je, že pacient potrebuje typ starostlivosti nedostupný v danej nemocnici (a transfer bol teda iniciovaný lekárom), mohol sa však i sám rozhodnúť pre zmenu nemocnice, napríklad z dôvodu nespokojnosti s jej starostlivosťou. Nech už sú dôvody na transfer akékoľvek, rozdiel v potenciálnej korelácii s kvalitou nemocnice (v porovnaní s prepustením pacienta domov) je evidentný. Čo je však ešte problematickejšie, o transferovanom pacientovi nemusíme mať k dispozícii informáciu o priebehu nasledujúcej hospitalizácie (pokiaľ sa nenachádza medzi prípadmi v našej databáze) a ak aj áno, nevieme správne identifikovať, ktorej nemocnici priradiť „zodpovednosť“ sa výsledný stav pacienta.

Spôsob prepustenia	Počet
prepustený domov	11 341
preklad na ak. lôžko iného ZZ [2]	3 919
preklad do LDCH [3]	2 691
zomrel (nepitvaný)	1 506
preklad na akútne lôžko inej odb. rovnakého ZZ	1 161
prepustený do zar. soc. starostlivosti	506
zomrel (pitvaný)	365
predčasné ukončneie hospitalizácie	72
N/A	9
prechod k inej poisťovni	2

Tabuľka 4: Počty hospitalizačných prípadov podľa spôsobu prepustenia

5.2.1 Spôsob prepustenia

Pozrime sa teraz na rozdelenie pacientov podľa spôsobu prepustenia v našom dátovom súbore uvedené v tabuľke 4. Ako môžeme vidieť, hoci je *prepustený domov* najčastejším spôsobom prepustenia (11 341 prípadov), druhým najčastejším spôsobom prepustenia je práve *preklad na ak. lôžko iného ZZ* (3 919 prípadov), po ktorom nasleduje *preklad do LDCH* (2 691 prípadov) a *preklad na akútne lôžko inej odb. rovnakého ZZ* (1 161 prípadov). Hoci je počet prípadov ukončených ako *preklad na ak. lôžko iného ZZ* nezanedbateľný, vzhľadom na vyššie spomenuté dôvody a riziká sme sa rozhodli dané prípady do procesu štandardizácie nezaradiť, rovnako ako prípady ukončené ako *preklad na akútne lôžko inej odb. rovnakého ZZ*, keďže zmena oddelenia je častokrát spojená i so zmenou DRG skupiny a spojenie takto rozdelených prípadov by bolo problematické. Vyradili sme tiež 2 prípady hospitalizácie ukončené ako *prechod k inej poisťovni* . Hospitalizácie ukončené ako *preklad do LDCH* a *prepustený do zar. soc. starostlivosti* sme sa po úvahe a konzultácií s lekárom rozhodli v našom súbore ponechať, kdeže vieme s určitosťou povedať, že pacient v nemocnici nezomrel. Analýza dôsledkov mozgovej príhody za hranicami hospitalizačného prípadu (napríklad ukazovateľmi ako miera rehospitalizácií alebo 30-dennej úmrtnosti) už spadá mimo rámca našej práce a vyžaduje ďalšie typy dátových zdrojov. Okrem hospitalizácií ukončených prekladom vidíme v tabuľke aj 9 hospitalizácií s neznámym spôsobom prepustenia. Vzhľadom na nízku početnosť takýchto prípadov v našej vzorke sme sa opäť po vzore [3] rozhodli tieto prípady z dátového súboru vyradiť. Ďalším pozorovaním je rozdelenie spôsobu prepustenia prislúchajúcemu smrti pacienta na 2 podkategórie – *zomrel (pitvaný)* a *zomrel (nepitvaný)*. Hoci nám toto delenie prišlo na prvý pohľad zaujímavé, pri konzultácií s lekárom nám bolo odporúčané nebrať ho do úvahy, keďže rozhodnutia pitvať závisia od interných zvyklostí nemocnice a ďalších faktorov, nezávislých od závažnosti prípadu. V ďalšej analýze budeme operovať iba s dvoma možnými stavmi – smrťou pacienta a iným spôsobom prepustenia. Na tieto účely sme vytvorili binárnu premennú *Zomrel*.

[2]Zdravotnícke zariadenie

[3]Liečebňa dlhodobo chorých

5.2.2 Pohlavie

Po vyradení spomenutých hospitalizácií na základe spôsobu prepustenia nám ostalo 16 481 prípadov, z ktorých 912 nemá priradené pohlavie pacienta. Jednou z možností, ako sa s týmto problémom vysporiadať, je týchto pacientov vyradiť, ako odporúča i [31], prišli by sme však o relatívne veľký objem informácií. Rozhodli sme sa preto pre iné riešenie, spočívajúce vo vytvorení novej kategórie premennej *Pohlavie - U* (Unknown). Do tejto kategórie sme zaradili všetkých pacientov, ktorí nemajú priradenú hodnotu premennej *Pohlavie*. Pohlavie je síce dôležitým faktorom v rizikovej štandardizácií, nepredpokladáme však, že bude úplne kľúčový a teda aj pozorovania s chýbajúcou hodnotou premennej *Pohlavie* nám stále môžu poskytnúť dôležité informácie o vzťahu pravdepodobnosti úmrtia a ďalších charakteristík pacienta.

5.2.3 Spôsob prijatia

Ďalší problém predstavuje premenná *Spôsob prijatia*. 755 hospitalizácií nemá priradený spôsob prijatia, 730 bolo klasifikovaných ako *prevzatý z iného zariadenia* a 383 ako *preložený z iného oddelenia*. Opäť sa stretávame s problémom nekompletných hospitalizácií, kde hrozí nesprávne penalizovanie alebo odmenenie nemocnice za kvalitu starostlivosti v predchádzajúcom zariadení (resp. na predchádzajúcom oddelení). Hoci nevieme vyhodnotiť podiel nemocnice na výsledku v konkrétnych prípadoch, vieme ho aspoň čiastočne zachytiť na globálnej úrovni pridaním kategorickej premennej *Prijatie*, ktorá priraďuje osobitné hodnoty spôsobu prijatia 1) *prevzatý z iného zariadenia* 2) *preložený z iného oddelenia*, 3) *neznámy spôsob prijatia* a 4) *iné*. Do kategórie *neznámy spôsob prijatia* sme zaradili aj 9 hospitalizácií s evidentne nesprávnym kódom spôsobu prijatia *narodený v nemocnici*, keďže išlo o pacientov vo veku nad 60 rokov. Z dátového súboru sme vyradili 2 prípady so spôsobom prepustenia *pokračovanie starostlivosti na rovnakom lôžku po zmene ZP*.

Nakoniec sme z dátového súboru vyradili 1 hospitalizáciu, ktorá nemala uvedenú DRG. Ostalo nám tak 16 478 prípadov, ktorým sa budeme ďalej venovať.

5.3 Výber premenných

Výber vhodných premenných je pri rizikovej štandardizácií kľúčový. Čelíme totiž dvom navzájom konfliktným motiváciám – snahe vytvoriť model, ktorý dokáže čo najlepšie predpovedať výsledný stav pacienta a nutnosti „neospravedlňovať“ modelom riziko spôsobené nekvalitnou starostlivosťou v nemocnici. V prvej fáze sme sa pozreli na dostupné potenciálne premenné a vyradili tie, u ktorých s istotou vieme vylúčiť vplyv na rizikovosť pacienta (napr. Kód poisťovne) a tie, ktoré nám neprinášajú žiadnu alebo iba duplikovanú informáciu (Napr. Dátum prijatia a Dátum prepustenia zároveň s Dĺžkou hospitalizácie...). V druhom kole sme vyradili premenné, ktoré síce na výsledný stav pacienta vplyv mať môžu, zároveň sú však ovplyvnené i rozhodnutiami nemocnice. Sem sme zaradili ekonomické premenné zachytávajúce náklady na danú hospitalizáciu alebo oddelenie prijímajúce pacienta či odbornosť prijímajúceho lekára. Po dlhšej úvahe sme vyradili aj premenné ako Pobyt na jednotke intenzívnej starostlivosti či Dĺžka hospitalizácie. Na účely ďalšej analýzy sme ponechali identifikátor nemocnice, v ktorej hospitalizácia prebehla.

V nasledujúcej sekcii sa bližšie pozrieme na jednotlivé premenné, ich vzťah k úmrtnosti a popíšeme prípadné vykonané transformácie. Závislosť daných premenných a rizika úmrtia sme otestovali Pearsonovým χ^2 testom nezávislosti (resp. homogenity) [22] , pokiaľ boli dodržané jeho predpoklady. Pri niektorých premenných nebola dodržaná požiadavka na *aspoň* 80% *buniek kontingenčnej tabuľky s očakávaným počtom 5 a viac a žiadna bunka s počtom 0*, v týchto prípadoch sme test nepoužili.

5.3.1 Nemocnica

V prvom rade nás zaujímalo, ako sú počty prípadov a úmrtnosť rozdistribuované medzi jednotlivými nemocnicami. Počty prípadov nemocníc rozdelené na *ukončené prepustením* a *ukončené smrťou* zachytáva nasledujúci graf:

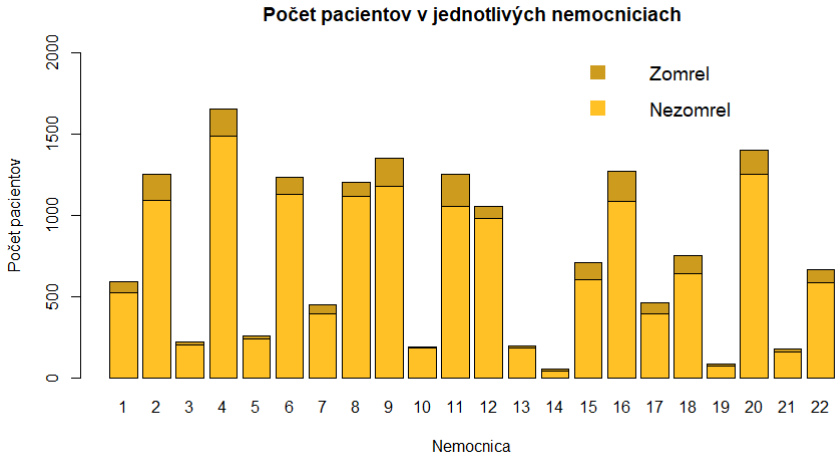

Obr. 3: Počty prípadov hospitalizácií s hlavnou diagnózou *Ischemická cievna mozgová príhoda* v jednotlivých nemocniciach

Ako môžeme vidieť, počty hospitalizácií sú medzi nemocnicami rozdistribuované veľmi nerovnomerne. Kým nemocnica 14 má iba 52 prípadov, nemocnica 4 ich má 1 655. Rovnako vidíme i rozdiely v proporčnom zastúpení hospitalizácií ukončených smrťou, čo ešte lepšie ilustruje nasledujúci graf:

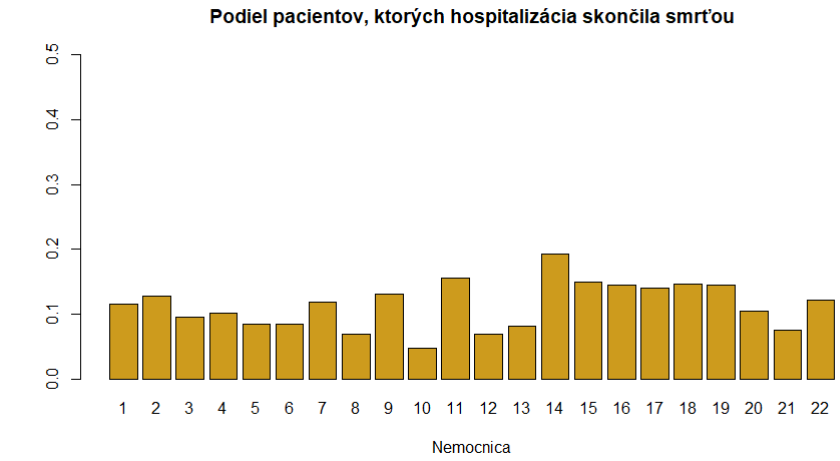

Obr. 4: Podiel hospitalizácií s hlavnou diagnózou *Ischemická cievna mozgová príhoda* ukončených smrťou v jednotlivých nemocniciach

Priemerná úmrtnosť medzi nemocnicami je 11%, čo zodpovedá aj štatistikám uvedeným v štúdii [23], podľa ktorých približne $8\% - 12\%$ cievnych mozgových príhod končí smrťou. Najnižšia úmrtnosť je 5% (nemocnica 10) a najvyššia 19% v nemocnici 14, ktorá je

však zároveň nemocnicou s najnižším počtom prípadov (52). Zaujímalo nás predovšetkým, či je pozorovaná nehomogenita v úmrtnosti medzi nemocnicami signifikantná. Na overenie tejto hypotézy sme použili Pearsonov χ^2 test na hladine významnosti $\alpha = 5\%$, ktorý s p-hodnotou $p < 2,2.10^{-16}$ hypotézu o homogenite úmrtnosti medzi nemocnicami zamietol. Môžeme teda predpokladať, že: a) určité rozdiely v kvalite starostlivosti o pacientov s Ischemickou cievnou mozgovou príhodou existujú, alebo b) medzi nemocnicami sú výrazné rozdiely v skladbe pacientov, alebo c) výsledná nehomogenita je určitou kombináciou oboch faktorov.

5.3.2 Vek

Vek je kľúčovou premennou pri predikcii rizika úmrtnosti. Spojitá premenná *Vek* sa v metodikách štandardizácie ([3], ale tiež napr. [8]) odporúča transformovať na kategorickú premennú vytvorením vekových skupín. Na tento účel sme sa rozhodli vytvoriť 16 vekových skupín po 5 rokov (*VekSkupina* = 1: [18,25) rokov; potom až po *VekSkupina* =15 po 5 rokov; *VekSkupina* =16: [95+)). Distribúciu prípadov a úmrtnosti pacientov podľa veku môžeme vidieť na nasledujúcom grafe:

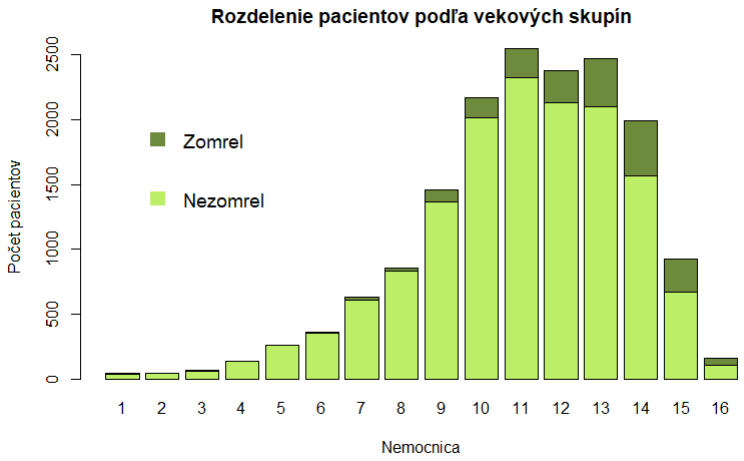

Obr. 5: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa veku

Z grafu je zrejmé, že s rastúcim vekom rastie i riziko Ischemickej cievnej mozgovej príhody a tiež riziko, že príhoda skončí smrťou.

5.3.3 DRG

Jednou z kľúčových premenných v koncepte rizikovej štandardizácie IQI AHRQ je práve zaradenie hospitalizácie do DRG. Ako sme spomínali v 4.2, spôsob radenia v USA a v Českej republike sa líši. Okrem technických rozdielov (v samotnom dizajne DRG aj v počte a dizajne kategórií indikujúcich riziko) je tu i problém s neschopnosťou odfiltrovať vedľajšie diagnózy, ktoré vznikli nekvalitnou nemocničnou starostlivosťou. Predpokladáme však, že väčšina vedľajších diagnóz, ktorá majú globálne signifikantný dopad na úmrtnosť pri Cievnej mozgovej príhode sú diagnózy nezávislé od starostlivosti v nemocnici, ale skôr chronické choroby, a teda DRG môžeme zahrnúť medzi potenciálne rizikové faktory. Vedľajšie diagnózy tiež vstupujú do procesu radenia hospitalizácií do DRG až pri určovaní komplikácií a komorbidít, a teda práca s typom bázy alebo bázou nebude ich potenciálnym vplyvom zasiahnutá. Radeniu hospitalizácií do DRG sme sa podrobnejšie venovali v 4.1. Agregácia hospitalizačných prípadov má 4 stupne – MDC, Typ bázy, Bázu a DRG. Všetky hospitalizácie v našom dátovom súbore spadajú do jednej z troch MDC - *00 - Pre-MDC* , *01 - Onemocnění a poruchy nervového systému* a *88 - Nezařaditelné do DRG*, pričom 16 261 prípadov spadá do MDC 01. Pozrime sa teraz na rozdelenie našich prípadov do jednotlivých kategórií podľa typu bázy:

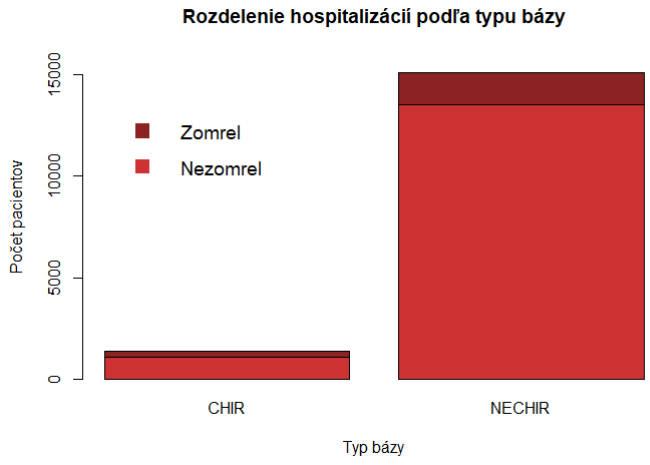

Obr. 6: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa typu bázy

Ako môžeme vidieť, väčšina hospitalizácií spadá pod nechirurgický typ bázy (15 127), medzi chirurgickými bázami je však signifikantne vyššia úmrtnosť (CHIR 20%, NECHIR 11%). Nezávislosť typu bázy a úmrtia opäť zamietol i Perasonov χ^2 test ($p < 2,2.10^{-16}$).

Ďalej sme sa pozreli na rozdelenie prípadov medzi bázami, od ktorého očakávame prirodzene viac informácií, keďže nesie priamo informáciu o hlavnej diagnóze a kritickom výkone pacienta. Problémom je však veľmi nerovnomerné zastúpenie jednotlivých báz v našom dátovom súbore. Kým do bázy *0134 - Cévní mozková příhoda s infarktem* bolo zaradených 14 997 prípadov, v 12 z pätnástich báz je početnosť prípadov nižšia ako 100. Ešte horšie je to, pochopiteľne, s DRG – z 34 DRG sa viac ako 10 prípadov vyskytuje iba v sedemnástich.

Nízka početnosť prípadov môže spôsobiť problémy pri tvorbe modelu, keďže distribúcia úmrtí na veľmi malej vzorke môže byť skôr výsledkom náhodných fluktuácií než skutočnej pravdepodobnosti úmrtia v danej skupine. Tvorcovia AHRQ indikátorov podľa [31] tento problém ošetrili pravidlom združovania menej početných skupín do vyšších kategórií. Všetky DRG s početnosťou menšou ako 30 spojili s najbližšou DRG v danej báze, bázy s početnosťou menšou ako 30 združili do MDC atď. My sme sa rozhodli pre podobný prístup, vzhľadom na veľkosť nášho dátového súboru sme sa však rozhodli znížiť konštantu na 10 prípadov.

Začali sme spájaním DRG. Každú DRG s početnosťou prípadov nižšou ako 10 sme spojili s „najbližšou“ DRG v rámci danej bázy, teda pokiaľ išlo o okrajový prípad (*bez CC* alebo *s MCC*), spojili sme ho DRG *s CC*, pokiaľ išlo o DRG *s CC*, spojili sme ho s tou zo zvyšných DRG, ktorá mala nižší počet prípadov. Pokiaľ „spojená“ DRG alebo „zostávajúca“ DRG v rámci danej bázy nemala aspoň 10 prípadov, opäť sme ich spojili. Takto nám v každej báze ostali najviac 3 a najmenej jedna DRG. Bázy, ktoré nemali aspoň 10 prípadov sme ďalej spojili do „zbernej“ bázy pod príslušnú MDC. Ak v „zbernej“ báze nebolo aspoň 10 prípadov, spojili sme ju s ďalšími zbernými bázami s menším počtom prípadov ako 10 do hlavnej zbernej bázy. Tieto zberné MDC sme potom rozdelili na *bez CC*, *s CC* a s *s MCC* tak, aby v každej báze bolo aspoň 10 prípadov. (Pokiaľ tak po rozdelení nebolo, spojili sme ich podľa kľúča aplikovaného pri spájaní DRG). V našom prípade však počet prípadov vo všetkých zberných bázach dokopy bol iba 4, preto sme tento stupeň agregácie vôbec nevyužili a všetky bázy s nízkou početnosťou združili do jednej spoločnej zbernej bázy.

Takto sme dostali nové rozdelenie do *pseudoDRG*, ktoré ilustruje nasledujúci obrázok 7:

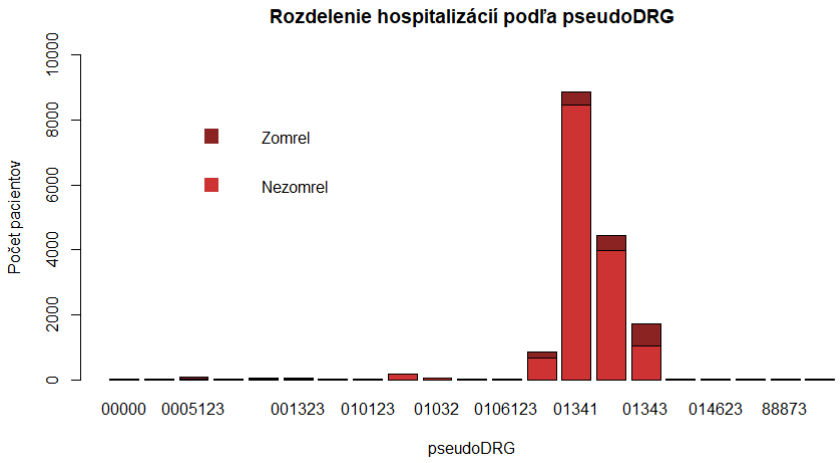

Obr. 7: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa pseudoDRG

Pre detailnejšiu predstavu o distribúcií prípadov medzi jednotlivými *pseudoDRG* uvádzame ich počty v tabuľke 12. Prvé 4 cifry reprezentujú bázu, zvyšné 1-3 cifry príslušné úrovne komplikácií zahrnuté v danej *pseudoDRG* (1 - *bez CC*, 2 - *s CC*, 3 - *s MCC*). Slovné názvy príslušných báz uvádzame v tabuľke 10 v Prílohe.

pseudoDRG	**0000_0**	**0004_13**	**0005_123**	**0010_0**	**0012_13**	**0013_23**	**0101_1**
Počet prípadov	4	14	85	13	48	60	19
pseudoDRG	**0101_23**	**0103_1**	**0103_2**	**0103_3**	**0106_123**	**0107_0**	**0134_1**
Počet prípadov	27	172	57	25	27	861	8848
pseudoDRG	**0134_2**	**0134_3**	**0146_1**	**0146_23**	**8887_12**	**8887_3**	**8889_123**
Počet prípadov	4426	1723	15	12	14	18	10

Tabuľka 5: Počty hospitalizačných prípadov podľa pseudoDRG

Z grafu je však zrejmé, že rozdelenie medzi pseudoDRG je stále veľmi nerovnomerné. Keďže nechceme prirodzenú štruktúru DRG viac narúšať umelými snahami o ďalšiu agregáciu, rozhodli sme sa ponechať ho v tejto forme a otestovať jeho výpovednú predikčnú hodnotu v našom modeli. Nakoniec sa ešte pozrime na distribúciu prípadov medzi samotnými kategóriami indikujúcimi závažnosť prípadu:

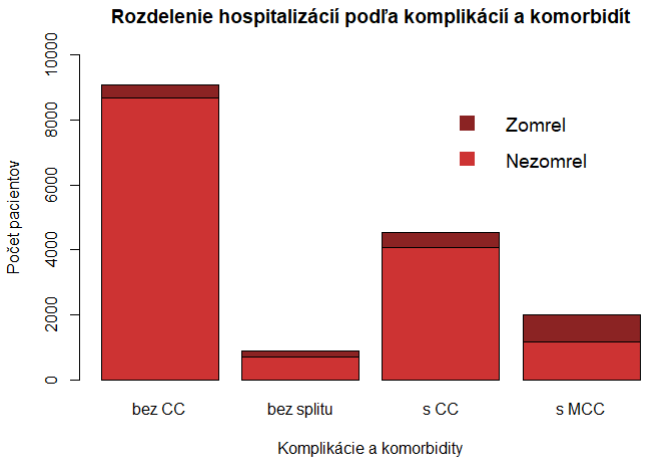

Obr. 8: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa komplikácií a komorbidít

Graf potvrdzuje to, čo sme i intuitívne očakávali - percentuálne zastúpenie úmrtí je najvyššie medzi pacientami s MCC. Očividnú závislosť medzi komplikáciami a komorbiditami a smrťou pacienta potvrdil aj Pearsonov χ^2 test ($p < 2,2.10^{-16}$). Takéto rozdelenie nám umožňuje pracovať s Komplikáciami a komorbiditami ako so samostatnou premennou (mimo DRG), nesmieme však zabúdať, že práve komplikácie môžu byť výsledkom nekvalitnej starostlivosti.

5.3.4 Hlavná diagnóza a vedľajšie diagnózy

Výhodou nášho dátového súboru je, že okrem agregovaných dát (DRG) obsahuje aj „surové“ dáta v podobe diagnóz pacienta a výkonov. V rámci našej práce teda chceme okrem iného i porovnať využitie týchto dvoch zdrojov informácií a ich vplyv na úspešnosť predikcie.

Hoci náš ukazovateľ je obmedzený už z definície konkrétnou úzkou skupinou diagnóz, i medzi nimi môžeme pozorovať určité rozdiely:

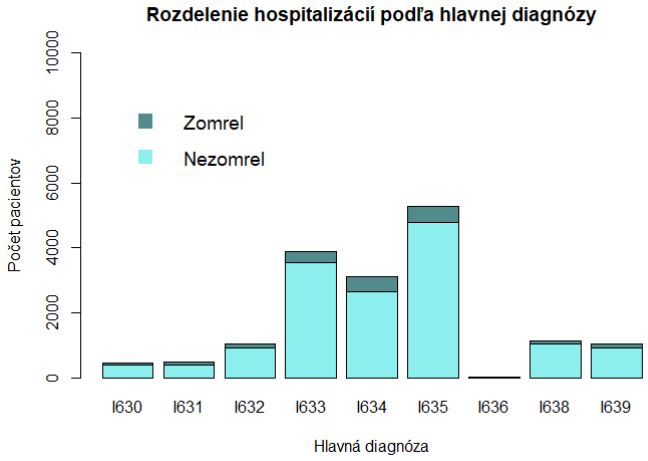

Obr. 9: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa hlavnej diagnózy

Nezávislosť medzi úmrtnosťou a hlavnou diagnózou zamietol i Pearsonov χ^2 test ($p < 2,2.10^{-16}$).

Ešte zaujímavejšie sú pre nás vedľajšie diagnózy, ktoré sú v iných systémoch ukazovateľov kvality často kľúčovými prediktormi rizika. Štúdia [13] napríklad označila za významné rizikové faktory úmrtnosti pri cievnej mozgovej príhode počet vedľajších diagnóz, rakovinu, vrodenú srdcovú chorobu, diabetes a chronickú obštrukčnú chorobu pľúc. Kanadský CIHI indikátor *30-denná miera nemocničnej úmrtnosti po cievnej mozgovej príhode* zase využíva ako rizikové faktory zlyhanie srdca alebo pľúcny edém, rakovinu, zlyhanie obličiek a ischemickú srdcovú chorobu.

Ako sme spomínali v 4.2, na základe konzultácií [32] s lekárom sme vyradili spomedzi kandidátov na rizikové faktory diagnózy T80-T88, popísané ako *Komplikácie zdravotnej starostlivosti nezaradené inde*, ktoré priamo popisujú časté nemocničné komplikácie. Pri ostatných diagnózach predpokladáme ich prítomnosť na príjme a teda s nimi budeme ďalej pracovať.

Každý pacient v našom dátovom súbore mal zaznamenaných od 0 po 15 vedľajších diagnóz. Pozrime sa najprv na rozdelenie počtu diagnóz a úmrtnosť v daných skupinách:

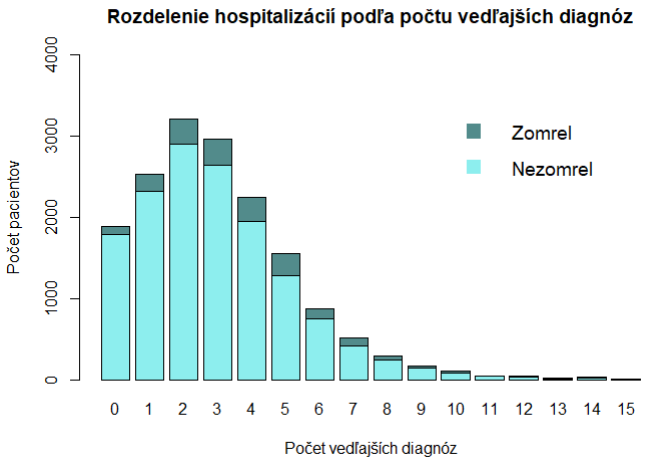

Obr. 10: Distribúcia hospitalizačných prípadov a úmrtí pacientov podľa počtu vedľaších diagnóz

Každá z diagnóz je zaznamenaná 5-miestnym kódom, pričom posledné 2 znaky kódu predstavujú užšiu špecifikáciu v rámci danej diagnózy, definovanej prvými troma znakmi. Diagnózy sú pri tom združené v 22 kapitolách, ďalej rozdelených na podkapitoly. Pri hospitalizáciách v našom dátovom súbore bolo spolu zaznamenaných 2118 unikátnych diagnóz, pričom mnohé z nich boli prítomné iba u veľmi úzkej skupiny pacientov, častokrát iba u jednotlivca. Ak teda chceme vedľajšie diagnózy použiť ako samostatné rizikové faktory, narážame na podobný problém s malými kategóriami ako pri DRG. Okrem toho tu narážame i na ďalší problém vysokého počtu prediktorov. Zaužívané odporúčané pravidlo na určenie maximálneho počtu prediktorov v logistickej regresii spomenuté napr. Agrestim [1] je *aspoň 10 výstupov oboch typov na každý prediktor*. To v našom prípade pri 1871 smrtiach znamená najviac 187 prediktorov.

Rozhodli sme sa preto opäť logicky združiť diagnózy do väčších celkov. Najprv sme združili 5-miestne kódy diagnóz do menej špecifických 3-miestnych kategórií. Dostali sme tak 810 diagnóz, stále však mnoho z nich malo veľmi nízku početnosť prípadov. Rozhodli sme sa preto všetky diagnózy s početnosťou nižšou ako 100 spojiť v rámci príslušnej kapitoly. Z každej diagnózy, ktorá sa vyskytla aspoň 100 krát a každej kapitoly, do ktorej bola priradená aspoň 1 diagnóza sme následne vytvorili binárnu premennú, ktorá nadobúda hodnotu 1 pre danú hospitalizáciu, pokiaľ bola diagnóza (diagnóza z danej kapitoly) u pacienta evidovaná a 0, pokiaľ nebola. Takto sme dostali 62 premenných zodpovedajúcich konkrétnej diagnóze a 21 premenných zodpovedajúcich kapitole.

6 Modelovanie očakávanej úmrtnosti

Na modelovanie očakávanej úmrtnosti sme využili logistickú regresiu, ktorej teoretické základy sme čitateľovi priblížili v 2.3.1. Bežnou praxou pri tvorbe klasifikačných modelov je rozdelenie dátového súboru na trénovací, validačný a testovací súbor. Trénovanie modelu - teda v našom prípade hľadanie optimálnych parametrov logistickej regresie - prebieha na trénovacom súbore, vyhodnocovanie modelu však prebieha na inom, validačnom súbore, ktorý spravidla tvorí okolo $10\% - 15\%$ celkového súboru. Validačný súbor slúži k objektívnejšiemu vyhodnoteniu kvality modelu, keďže eliminuje pravdepodobnosť pretrénovania - teda prispôsobeniu modelu v príliš veľkej miere konkrétnym trénovacím dátam. Používame ho na vyhodnocovanie kvality každého testovaného modelu. Testovací súbor slúži už na kontrolu užšej skupiny finálnych modelov a ako „poistka" proti potenciálnemu prispôsobeniu modelu validačným dátam.

Náš dátový súbor sme rozdelili v pomere 70% (trénovací súbor), 15% (validačný súbor) a 15% (testovací súbor). Keďže nechceme, aby bol náš model vychýlený z dôvodu silnejšieho vplyvu pozorovaní niektorých nemocníc, v danom pomere sme medzi všetky 3 súbory rozdelili aj pozorovania každej nemocnice zvlášť (teda trénovací súbor obsahuje 70% pozorovaní každej nemocnice). Na záver sme otestovali, ako sú medzi súbormi rozdistribuované prípady ukončené smrťou. Rozdelenie bolo 1293/287/291 (69%/15%/16%), čo považujeme za uspokojivý pomer a s takto rozdelenými súbormi budeme ďalej pracovať.

V nasledujúcej časti najprv stručne popíšeme kritériá, na základe ktorých sme vyhodnocovali kvalitu modelu (voľne spracované podľa [1]), spôsob výberu a kombinovania premenných a porovnáme predikčnú schopnosť testovaných modelov. Na záver vyberieme na základe našich kritérií model, ktorý využijeme na modelovanie očakávanej úmrtnosti vo finálnom hodnotení nemocníc.

6.1 Hodnotenie modelu

6.1.1 Klasifikačné tabuľky

Častým nástrojom hodnotenia klasifikačných modelov sú tzv. klasifikačné tabuľky. Klasifikačná tabuľka je tabuľka veľkosti 2x2, obsahujúca počty správne a nesprávne klasifikovaných pozorovaní pri danej hranici pravdepodobnosti π_0, pričom pre predikovanú

pravdepodobnosť $\hat{\pi}_i$ pre i-te pozorovanie platí: ak $\hat{\pi}_i > \pi_0$, potom $\hat{y}_i = 1$, ak $\hat{\pi}_i \leq \pi_0$, potom $\hat{y}_i = 0$.

		y	
		0	1
$\hat{y}$	0	a	b
	1	c	d

Tabuľka 6: Príklad všeobecnej klasifikačnej tabuľky

Klasifikačné tabuľky nám poskytujú viacero pohľadov na predikčnú úspešnosť modelu. Najintuitívnejším je celkový podiel správne klasifikovaných pozorovaní, alebo tiež **presnosť**:

$$Accuracy = P(y = 1 \wedge \hat{y} = 1) + P(y = 0 \wedge \hat{y} = 0)$$

$$= P(\hat{y} = 1|y = 1)P(y = 1) + P(\hat{y} = 0|y = 0)P(y = 0)$$

Presnosť využijeme v našom hodnotení ako kontrolnú metriku, jej výpovedná hodnota v našom prípade však nebude veľká. Keďže náš dátový súbor je z hľadiska výstupov rozdelený veľmi nerovnomerne (iba 1 871 prípadov, v ktorých $\hat{y} = 1$ z celkového počtu 16 478 prípadov), vysokú presnosť vieme dosiahnuť už aj pri modeli obsahujúcom iba intercept. Dôležitejšia je pre nás schopnosť modelu správne predikovať $\hat{y} = 1$ v prípadoch, kedy $y = 1$. To zachytáva **senzitivita** modelu, definovaná ako:

$$Sensitivity = P(\hat{y} = 1|y = 1)$$

Z klasifikačnej tabuľky tento údaj dostaneme jednoducho ako podiel $\frac{d}{d+b}$. Podobne definujeme aj **špecifickosť** modelu, teda:

$$Specificity = P(\hat{y} = 0|y = 0)$$

V tabuľke je špecifickosť modelu zachytená ako $\frac{a}{a+c}$.

Prirodzene, počty správne klasifikovaných pozorovaní nie sú v našom prípade ideálnou metrikou. Viac ako zaradenie do skupiny na základe určenej π_0 nás totiž zaujímajú pred-

ikované pravdepodobnosti úmrtia. Viacero kritérií nám však pomôže utvoriť si komplexnejší obraz o modeli, preto pri našich modeloch uvádzame aj ich presnosť, senzitivitu a špecifickosť. Tieto charakteristiky klasifikačných tabuliek nám zároveň slúžia aj pre lepšie pochopenie všeobecnejšej metriky, ktorú predstavíme v nasledujúcej podkapitole.

6.1.2 ROC krivka a concordance index

Senzitivita i špecifickosť modelu závisia od hodnoty konštanty π_0, predstavujúcej „deliacu čiaru" medzi pozorovaniami vyhodnotenými ako $\hat{y} = 1$ a $\hat{y} = 0$. Touto konštantou môžeme hýbať a nastaviť ju tak, aby model dosahoval čo najlepšie výsledky, pri posúvaní však vždy strácame časť senzitivity na úkor špecifickosti alebo naopak. Problém nastáva vtedy, ak model nie je schopný správne rozlišovať medzi „lepšími" a „horšími" pozorovaniami a teda nie je možné nájsť hranicu, ktorá by ich realisticky od seba oddelila. Túto vlastnosť modelu testuje tzv. **ROC krivka** (angl. *receiving operating characteristic curve).*

ROC krivka popisuje závislosť senzitivity modelu od jeho chyby 1. druhu, teda doplnkovej pravdepodobnosti k špecifickosti modelu, pre všetky možné hodnoty π_0. Chyba 1. druhu je definovaná ako:

$$1 - specificity = P(\hat{y} = 1|y = 0)$$

ROC krivka je obyčajne konkávna, spájajúca body (0,0) a (1,1). Pre danú špecifickosť predstavuje vyššia senzitivita lepšiu predikčnú schopnosť modelu a teda i vyššiu ROC krivku. Príklad ROC krivky zostrojenej podľa skutočného modelu uvádza napr. Agresti v [1]:

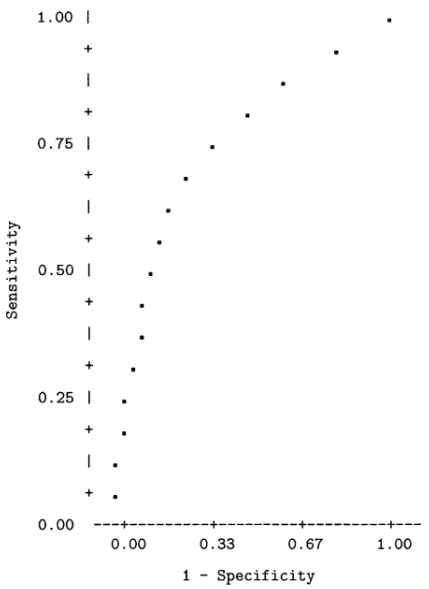

Obr. 11: ROC krivka modelu logistickej regresie pre dáta Kraby,[1]

Plocha pod ROC krivkou je tiež interpretovateľná ako pravdepodobnosť, že náhodne zvolené pozorovanie v našej vzorke so skutočnou hodnotou $y = 1$ bude mať modelom predpovedanú pravdepodobnosť $\hat{y}$ vyššiu ako náhodne zvolené pozorovanie so skutočnou hodnotou $y = 0$. Pri dôkaze tohto tvrdenia sme vychádzali z [16]. Dôkaz uvádzame v pôvodnej forme, zovšeobecnenej aj na klasifikačné algoritmy, ktoré nemusia predikovať priamo pravdepodobnosť, ale iba určité skóre s, pričom $s \in (-\infty, \infty)$.

Dôkaz:

Označme skóre pridelené klasifikačným algoritmom i-temu pozorovaniu ako $s_i \in (-\infty, \infty)$. Pre jednoznačnosť ďalej označme $\tilde{s}_i, \tilde{s}_i \in \{0, 1\}$ skutočnú triedu, do ktorej patrí i-te pozorovanie, $\hat{s}_i, \hat{s}_i \in \{0, 1\}$ triedu, do ktorej i-te pozorovanie zaradil algoritmus. Nech τ predstavuje *threshold*, oddeľujúci pozorovania zaradené algoritmom do triedy 1 od pozorovaní zaradených do triedy 0, teda ak $s_i > \tau$, potom $\hat{s}_i = 1$, ak $s_i \leq \tau$, potom $\hat{s}_i = 0$. Nech $f_0(s)$ je hustota pravdepodobnostného rozdelenia s pre pozorovania patriace do triedy 0 a $f_1(s)$ pre pozorovania patriace do triedy 1. Analogicky, nech $F_0(s)$ je distribučná funkcia pre pozorovania patriace do triedy 0 a $F_1(s)$ pre pozorovania patriace do triedy 1. Krivka ROC je funkciou senzitivity modelu (y) od (1-špecifickosti) modelu (x), označme ju $G(x) = y$. X a y sú zároveň obe funkciami τ, platí $x = a(\tau)$, $y = b(\tau)$. Ďalej platí:

$$X = P(\hat{s} = 1|s = 0) = a(\tau) = 1 - F_0(\tau)$$

$$Y = P(\hat{s} = 1|s = 1) = y = b(\tau) = 1 - F_1(\tau)$$

Označme plochu pod ROC krivkou AUC *(area under curve)*. Keďže x aj y sú pravdepodobnosti, platí $x \in [0, 1]$ a tiež $y \in [0, 1]$. Potom AUC vypočítame ako:

$$AUC = \int_0^1 G(x)dx$$

Dosaďme teraz $x = a(\tau)$. Potom platí:

$$x = a(\tau)$$

$$dx = a'(\tau)d\tau$$

$$x = 1 \implies \tau = -\infty$$

$$x = 0 \implies \tau = \infty$$

Všimnime si, že x (a rovnako aj y) nadobúda hodnotu 1 pre $\tau = -\infty$ a hodnotu 0 pre $\tau = \infty$. Práve ak je τ nekonečne malé totiž spadnú všetky pozorovania do triedy 1, a teda senzitivita aj (1-špecifickosť) modelu majú hodnotu 1. Analogicky, pre $\tau = \infty$ žiadne s_i nemá hodnotu väčšiu ako τ, preto všetky pozorovania spadnú do triedy 0 a senzitivita a (1-špecifickosť) modelu majú hodnotu 0.

AUC má potom tvar:

$$AUC = \int_\infty^{-\infty} G(a(\tau))a'(\tau)d\tau$$

Keďže $y = G(x) = G(a(\tau)) = b(\tau)$, platí:

$$\begin{aligned} AUC &= \int_\infty^{-\infty} b(\tau)a'(\tau)d\tau \\ &= \int_\infty^{-\infty} (1 - F_1(\tau))(-f_0(\tau))d\tau \\ &= \int_{-\infty}^{\infty} (1 - F_1(\tau))(f_0(\tau))d\tau \end{aligned}$$

Tento integrál už vyjadruje priamo našu hľadanú pravdepodobnosť, že pre náhodne zvolenú dvojicu pozorovaní patriacich do rozdielnych tried bude skóre s_i u pozorovania z triedy 1 vyššie.

Hodnote AUC sa tiež hovorí **concordance index** (alebo **c-štatistika**) a na rozdiel od presnosti, senzitivity a špecifickosti modelu vyhodnocuje schopnosť modelu diskriminovať medzi dobrými a zlými pozorovaniami bez ohľadu na hodnotu *thresholdu*. Pokiaľ je diskriminačná schopnosť modelu dobrá, vieme nájsť hranicu, pri ktorej budú aj ďalšie metriky modelu poskytovať uspokojivé výsledky. C-štatistika spravidla nadobúda hodnoty od 0,5 po 1, pričom hodnota 0,5 zodpovedá diskriminácií na úrovni hádzania mincou, hodnota 1 zodpovedá dokonalej diskriminácií. Hosmer and Lemeshow [17] zaviedli pre vyhodnocovanie diskriminačnej schopnosti modelu nasledovnú metriku:

- 0,70 $\leq$ c-štatistika $<$ 0,80 - akceptovateľná diskriminácia
- 0,80 $\leq$ c-štatistika $<$ 0,90 - excelentná diskriminácia
- 0,90 $\leq$ c-štatistika - výnimočná diskriminácia

6.1.3 Akaikeho infromačné kritérium (AIC)

Ďalšou metrikou kvality modelu je tzv. Akaikeho informačné kritérium (AIC). AIC hodnotí model podľa toho, ako veľmi sa predikované hodnoty $\hat{y}_i$ líšia od skutočných hodnôt y_i na základe funkcie maximálnej vierohodnosti. Okrem toho však berie do úvahy aj úspornosť modelu z hľadiska počtu parametrov, „penalizuje“ modely s príliš veľkým počtom parametrov a tak upozorňuje na riziko prípadného pretrénovania modelu. Ideálny model podľa AIC je taký, ktorý minimalizuje

$$AIC = -2(loglikelihood - k)$$

kde k je počet parametrov v modeli. AIC nie je absolútnou metrikou, môže však poslúžiť na relatívne porovnanie viacerých modelov. Hodnota AIC nebude pre nás pri výbere modelu rozhodujúca, v prípade modelov s podobnou predikčnou schopnosťou však môže poslúžiť ako vodítko k úspornejšiemu modelu a upozorniť na prípadné nebezpečenstvo pretrénovania.

6.2 Predstavenie a porovnanie modelov

V 5.3.1 sme predstavili prvotnú predselekciu premenných a základné transformácie, ktoré sme s nimi vykonali. Na základe tejto predselekcie sme vytvorili viacero kombinácií premenných, slúžiacich ako vstupy do modelov, ktorých predikčnú schopnosť ďalej porovnávame. Vychádzame pri tom z faktu, že niektoré premenné sú od seba silno závislé už z podstaty ich konštrukcie (Napr. DRG a vedľajšie diagnózy), a teda ich nebudeme využívať v spoločnom modeli. Na základe tejto úvahy sme vytvorili 3 typy modelov - čisto **demografický model** (vek a pohlavie) - slúži na porovnanie prínosu nových premenných oproti doterajšiemu spôsobu štandardizácie v ČR, **DRG model** využívajúci agregované informácie o pacientoch v podobe DRG a **VDG model**, využívajúci „surové“ dáta v podobe diagnóz. V každom modeli máme kontrolnú premennú *Prijatie* predstavujúcu spôsob prijatia pacienta. V nasledujúcej tabuľke uvádzame modely a využité kombinácie typov premenných.

Typ	Model	Premenné
Demografický	M1	Vek, Pohlavie, Prijatie
	M2	Vek, Pohlavie, Vek:Pohlavie, Prijatie
DRG	M3	Vek, Pohlavie, pseudoBáza, CC, Prijatie
	M4	Vek, Pohlavie, pseudoDRG, Prijatie
	M5	Vek, Pohlavie, pseudoBáza, CC, pseudobáza:CC, Prijatie
VDG	M6	Vek, Pohlavie, Typ Bázy, Hlavná diagnóza, Počet vedľajších diagnóz Prijatie
	M7	Vek, Pohlavie, Typ Bázy, Hlavná diagnóza, Vedľajšie diagnózy, Prijatie
	M8	Vek, Pohlavie, psuedoBáza, Vedľajšie diagnózy, Prijatie

Tabuľka 7: Modely pre pravdepodobnosť úmrtia pacienta po ischemickej cievnej mozgovej príhode, kombinácie premenných

Pre každý model sme vypočítali priamo na trénovacom dátovom súbore jeho AIC a hodnotu c-štatistiky. AIC je jedným z automatických výstupov funkcie *summary* v softvéri *RStudio*, c-štatistika vypočítaná na trénovacom súbore slúži predovšetkým na porovnanie s hodnotou pre validačný dátový súbor a vyhodnotenie prípadného pretrénovania modelu.

Hlavnou metrikou je pre nás c-štatistika vypočítaná na validačnom súbore, pre každý model tiež uvádzame presnosť, senzitivitu a špecifickosť pri hodnote *tresholdu* 0.5 pre validačný dátový súbor.

	AIC	C-train	C-val	Presnosť	Senzitivita	Špecifickosť
M1	7565	0.7012	0.7064	0.8839	0	1
M2	7594	0.7040	0.709	0.8839	0	1
M3	6303	0.8391	0.8145	0.8831	0.1882	0.9744
M4	6303	0.8419	0.8144	0.8831	0.1951	0.9735
M5	95 261	0.9042	0.5923	0.8706	0.23	0.9547
M6	7356	0.7298	0.705	0.8835	0.0105	0.9982
M7	5458	0.8888	0.8533	0.8952	0.2718	0.9771
M8	5432	0.8912	0.8537	0.8932	0.2753	0.9744

Tabuľka 8: Modely pre pravdepodobnosť úmrtia pacienta po ischemickej cievnej mozgovej príhode, vyhodnotenie

6.2.1 Demografický model

Ako prvý sme otestovali model založený iba na pohlaví pacienta a vekových kategóriách po 5 rokov. Ako vidíme v tabuľke, aj napriek 88%-nej presnosti model nebol schopný správne klasifikovať ani jedno úmrtie pacienta vo validačnom dátovom súbore, teda všetkých zaradil do kategórie živých. C-štatistika na validačnom súbore dosiahla hodnotu 0.7064, čo takmer nezmenilo ani pridanie interakčného člena pre interakciu vekových skupín a pohlavia. Pomocou *ANOVA* testu sme otestovali hypotézu o nesignifikantnosti vplyvu interakčného člena, test však hypotézu pomerne sebavedomo nezamietol (p-hodnota = 48%) . Rozhodli sme sa preto pre jednoduchší model, obsahujúci iba vekové skupiny a pohlavie bez interakcií.

6.2.2 DRG model

Pri DRG modeli sme najprv modelovali úmrtnosť iba pomocou pseudoBázy a CC. Diskriminačná schopnosť modelu vzrástla oproti demografickému modelu na 0.81, model bol pri hodnote *tresholdu* 0.5 schopný správne klasifikovať 19% smrtí. Takmer totožné

výsledky dostávame aj v prípade, že miesto pseudoBázy a CC používame ako rizikové faktory pseudoDRG. Je to pravdepodobne spôsobené veľmi podobnou štruktúrou väčšiny pseudoDRG a pseudoBáz. Nakoniec sme otestovali aj vplyv „pôvodných"DRG - do modelu sme pridali popri pseudoBázach a CC aj ich interakčný člen. Tento model dosiahol na pôvodnom trénovacom súbore doteraz najvyššiu hodnotu c-štatistiky 0.9, pri pohľade na c-štatistiku validačného súboru 0.59 je však jasné, že ide o pretrénovanie modelu a pri kontakte s novými pozorovaniami bude s veľkou pravdepodobnosťou neúspešný. Alarmujúca je i výška AIC 95 261, ktorá je rádovo vyššia ako pri ostatných modeloch. V prípade DRG modelu teda ostávame pri modeli založenom na našom agregovanom delení.

6.2.3 VDG model

Nakoniec sme otestovali 3 modely využívajúce miesto agregovaných DRG samotné diagnózy pacientov. Vyskúšali sme pri tom modely využívajúce hlavnú diagnózu ako rizikový faktor (M6, M7) a alternatívny model využívajúci pseudoBázu (M8). Model M6 pritom využíval ako rizikový faktor počet vedľajších diagnóz ako spojitú premennú, M7 a M8 používali prítomnosť konkrétnych vedľajších diagnóz ako kategorické premenné. Model M6 bol iba mierne lepší ako demografický model (c-štatistika 0.74). Oba modely založené na jednotlivých vedľajších diagnózach preukázali zatiaľ najvyššiu diskriminačnú schopnosť s c-štatistikou 0.85. Tieto modely nám umožnili priradiť každému pacientovi namiesto 1 levelu DRG viacero vedľajších diagnóz, vďaka agregácií však nevznikli natoľko nerovnomerné skupiny ako pri DRG. Tento postup očividne vedie pri skladbe pacientov českých nemocníc k výrazne lepším výsledkom ako model založený na DRG, rozhodli sme sa preto pre model založený na vedľajších diagnózach.

Nakoniec sme 2 finálne modely použili na predikciu pravdepodobnosti úmrtia pacientov v testovacom súbore. Dostali sme nasledovné výsledky:

Model	C-štatistika	Presnosť	Senzitivita	Špecifickosť
M7	0.8736	0.9099	0.3505	0.9844
M8	0.8747	0.9115	0.3746	0.9831

Tabuľka 9: Modely pre pravdepodobnosť úmrtia pacienta po ischemickej cievnej mozgovej príhode, vyhodnotenie na testovacom súbore

Oba modely dosiahli diskriminačnú schopnosť okolo 0,87, čo sa blíži k hodnote c-štatistiky AHRQ modelu 0,886 uvedenej v [4]. Keďže rozdiely v diskriminačnej schopnosti modelov sú zanedbateľné, rozhodli sme sa pre model M7, keďže využíva viac informácií o stave pacienta (hlavná diagnóza) a menej o rozhodnutiach nemocnice. Jeho ďalšou výhodou je, že hlavná diagnóza s najnižším výskytom sa objavila až u 30 prípadov, kým medzi pseudoBázami sa vyskytuje 6 skupín s nižším počtom prípadov ako 30. Pri využití hlavnej diagnózy teda môžeme očakávať väčšiu istotou správneho zachytenia vzťahov premenných i pre skupiny s nižšou početnosťou prípadov. Jedinou premennou odrážajúcou DRG delenie teda ostáva Typ Bázy.

6.2.4 Tvorba úsporného modelu

Finálny model využíva ako rizikové faktory vekové skupiny po 5 rokov, pohlavie pacienta, typ bázy, hlavnú diagnózu, vybrané vedľajšie diagnózy a diagnostické kapitoly podľa čísleníka [24] a tiež kontrolnú premennú indikujúcu spôsob prijatia. Aj keď má model relatívne vysokú diskriminačnú schopnosť, nepodieľajú sa na nej všetky využité premenné rovnako. V ďalšom kroku sme sa teda rozhodli pozrieť na význam a prínos jednotlivých premenných a vytvoriť pri zachovaní predikčnej schopnosti čo najúspornejší model, vhodný pre praktické použitie a interpretáciu. Štandardným testom signifkantnosti premenných je Waldov test [1], ktorý je aj automatickým výstupom funkcie *summary* v softvéri *RStudio*. Tento test využíva fakt, že rozdiel parametra odhadnutého metódou maximálnej vierohodnosti, v našom prípade teda koeficientu $\hat{\beta}_i$ a skutočnej hodnoty parametra β_i má približne normálne rozdelenie s priemerom 0 a so štandardnou odchýlkou rovnou štandardnej odchýlke odhadnutého parametra. Potom pre Waldovu štatistiku platí:

$$W = \frac{(\hat{\beta}_i - \beta_i)}{\hat{se}(\hat{\beta}_i)} \sim N(0,1)$$

Zaujíma nás, či je skutočná hodnota parametra β_i nulová - v tom prípade totiž daný faktor na úmrtnosť pacienta nevplýva a teda by nemal byť zahrnutý v modeli štandardizácie. Hodnota β_i je teda v našom prípade 0 a pre Waldovu štatistiku platí:

$$W = \frac{\hat{\beta}_i}{\hat{se}(\hat{\beta}_i)} \sim N(0,1)$$

Hodnotu Waldovej štatistiky pre každý parameter porovnáme s normálnym rozdelením $\sim N(0,1)$ a hypotézu $\beta_i = 0$ pre i-ty parameter zamietame, pokiaľ je p-hodnota dostatočne malá, štandardnou hranicou je 5%.

Hodnoty Waldovej štatistiky sú vypočítané zvlášť pre jednotlivé kategórie každej kategorickej premennej a sú závislé aj od nastavenia referenčnej kategórie. Pre ľahšiu interpretovateľnosť koeficientov sme nastavili za referenčné kategórie tie kategórie, do ktorých spadá najviac prípadov (Hlavná diagnóza, Vekové kategórie) a pre pohlavie kategóriu U (Unknown).

Pri pohľade na p-hodnoty Waldovho testu jednotlivých premenných nás prekvapila veľmi výrazná nesignifikantnosť niektorých vekových skupín. Ako sme však videli i na grafe 5, pri mladých pacientoch je riziko ischemickej cievnej mozgovej príhody veľmi nízke a rovnako i riziko úmrtnosti (vo vekových skupinách [25,30) a [35,40) napríklad nezomrel ani jeden pacient). Metodika AHRQ odporúča v takýchto prípadoch spojiť nesignifikantné kategórie do väčších celkov [31]. Rozhodli sme sa teda pripojiť všetky nesignifikantné vekové skupiny k najbližšej signifikantnej skupine s vyšším vekom, čím sme dostali miesto skupín 1,2 a 3 spojenú skupinu 123 (pacienti vo veku [18,35) rokov), miesto skupín 4 a 5 spojenú skupinu 45 (pacienti o veku [35,45) rokov) a spojením skupín 10 a 11 skupinu 1011 (pacienti vo veku [65,75) rokov). Na základe tohto delenia sme už dostali signifikané kategórie.

Signifikantný vplyv nepotvrdil Waldov test ani pri niektorých kategóriách premennej *hlavná diagnóza*, v tomto prípade však už nechceme diagnózy združovať, keďže neexistuje poradie ani vyšší level hierarchie, pod ktorý spadajú (resp. je to priamo už definičná diagnóza indikátora). Otestovali sme teda prínos celej premennej hlavná diagnóza pomocou ANOVA testu, porovnávajúceho mieru deviancie modelu s premennou hlavná diagnóza a bez nej. Test hypotézu o rovnakej deviancii modelov zamietol (p-hodnota = 0.01833), rozhodli sme sa teda premennú hlavná diagnóza v modeli ponechať.

Veľa nesignifikantných premenných sa objavilo aj medzi vedľajšími diagnózami a kapitolami, čo je pochopiteľné, keďže nie každá vedľajšia diagnóza musí vplývať na riziko úmrtia pri cievnej mozgovej príhode. Keďže nejde o komplementárne kategórie, ale samostatné premenné, rozhodli sme sa vedľajšie diagnózy s nesignifikantným efektom z modelu vyradiť. Alternatívnym riešením by mohlo byť združenie do kapitol, avšak hranicu

výskytu aspoň 100 prípadov považujeme za dostatočne vysokú na to, aby sa potenciálny efekt diagnózy prejavil. Ak diagnóza na úmrtnosť vplyv naozaj nemá, zrejme združením do kapitoly môže nanajvýš znížiť efekt signifikantnosti samotnej kapitoly. Rozhodli sme sa preto ďalšiemu spájaniu v tomto prípade vyvarovať a premenné pre jednotlivé kapitoly ponechať v (trochu nepraktickej) forme zahŕňajúcej *všetky diagnózy danej kapitoly okrem tých, ktoré boli použité v pôvodnom modeli samostatne*. Uvedomujeme si však, že p-hodnota v teste signifikantnosti je spojitým ukazovateľom pravdepodobnosti a nie jednoznačným rozhodcom medzi „dobrými“ a „zlými“ premennými. Vzhľadom na potenciálne veľkú stratu informácie (pozostávajúcu z väčšieho množstva malých strát) sme sa preto rozhodli za hranicu p-hodnoty pre vyradenie premenných z modelu určiť $p = 10\%$.

C-štatistika úspornej varianty modelu M7 vypočítaná na validačnom súbore je 0.859, čo je porovnateľné, dokonca mierne lepšie ako c-štatistika pôvodného modelu (0.8533).

6.2.5 Zohľadnenie klinických súvislostí

Prekvapením sú pre nás i hodnoty tzv. *odds ratio* (pomeru šancí) prislúchajúce k niektorým vedľajším diagnózam. *Odds ratio* reprezentované $e^{\hat{\beta}_i}$ predstavuje v našom prípade pomer šancí na úmrtie po CMP pre pacienta v prislúchajúcej kategórii k šanciam pacienta v referenčnej kategórií, pokiaľ sú ostatné charakteristiky pacientov rovnaké. Intuitívne by sme očakávali, že všetky ďalšie diagnózy budú riziko úmrtia zvyšovať, až polovica signifikantných diagnóz a kapitol má však *odds ratio* nižšie ako 1, teda šance na úmrtie pacienta s ich prítomnosťou klesajú.

Jedným z dôvodov by mohla byť práve opačná kauzalita. Pokiaľ ide o diagnózy, ktoré sú častým dôsledkom CMP a boli kódované neskôr počas hospitalizácie alebo pri prepustení z nemocnice, u pacientov, ktorí rýchlo zomreli, sa možno iba nestihli prejaviť. Rozhodli sme sa preto jednotlivé diagnózy skonzultovať s odborníkom [32] a na základe úvahy a dostupných štúdií sme pre každú diagnózu zvlášť posúdili jej zaradenie alebo nezaradenie do modelu.

Niektoré diagnózy sme z modelu vylúčili na základe silného predpokladu, že ide o diagnózy bežne kódované pri prepustení, resp. neskôr počas hospitalizácie a sú častými nemocničnými komplikáciami alebo priamo častými následkami CMP (*B96 - Jiná určená bakteriální agens jako příčina nemoci zařazené do jiných kapitol; N30 - Zánět močového*

měchýře (cystitida); F01 - Vaskulární demence; F05 - Delirium , které není vyvolané alkoholem nebo jinými psychoaktivními látkami; I65 - Uzávěr (okluze) a zúžení (stenóza) přívodných mozkových tepen nekončící; I67 - Jiná cévní onemocnění mozku; M54 -Dorzalgie). Pri týchto diagnózach sme taktiež nenašli žiadne štúdie, podporujúce hypotézu, že by mohli zlepšovať šance na prežitie u pacientov s CMP. Z podobných dôvodov sme po dlhšej úvahe vylúčili aj diagnózu *F32 - Depresivní fáze* (názory a výsledky štúdií sa pri tejto diagnóze líšia), *D68 - Jiné poruchy koagulace* a tiež kapitoly *V. - Poruchy duševní a poruchy chování* a *VIII. - Nemoci ucha a bradavkového výběžku*. V modeli sme sa rozhodli ponechať diagnózy *E03 - Jiná hypotyreóza* a *E78 - Poruchy metabolismu lipoproteinů a jiné lipidemie*, keďže ide o diagnózy kódované primárne na vstupe a existujú štúdie potvrdzujúce pozitívny vplyv E03 [11] aj E78 [19] na šance pacienta na prežitie po CMP. Pre diagnózu *Z92 - Lékařská léčba v osobní anamnéze* sme ponechali jej podskupinu *792.1 - Dlouhodobé (průběžné) užívání antikoagulancií v osobní anamnéze*. Prítomnosť tejto diagnózy znamená, že pacient bol liečený a teda i dôslednejšie monitorovaný lekárom. Taktiež sme ponechali v modeli diagnózu *R47 - Poruchy řeči nezařazené jinde*. Táto diagnóza býva často prítomná u pacientov s CMP už na vstupe a svedčí o tom, že pacient nie je v kóme, čo indikuje miernejšiu formu CMP.

Pozreli sme sa tiež na klinický význam faktorov, ktorých *odds ratio* bolo vyššie ako 1. Z tejto skupiny sme sa rozhodli vylúčiť diagnózu *L89 - Dekubitální vřed a proleženina*, ktorý je diagnózou vznikajúcou v nemocnici a je často spojený s výsledkom nekvalitnej starostlivosti. Používa sa tiež ako samostatný ukazovateľ kvality, napr. v [7].

Diskriminačnú schopnosť finálneho modelu sme otestovali na validačnom dátovom súbore, kde dosiahol hodnotu c-štatistiky 0.8563. Nakoniec sme ho teda otestovali aj na testovacom dátovom súbore. Model dosiahol veľmi slušnú diskriminačnú schopnosť 0.8745, čo je hodnota blížiaca sa k hodnote 0.886 uvedenej v dokumentácií AHRQ modelu pre IQI 17C [3] . Finálny model s parametrami a prislúchajúcimi štatistikami uvádzame v Prílohe A.

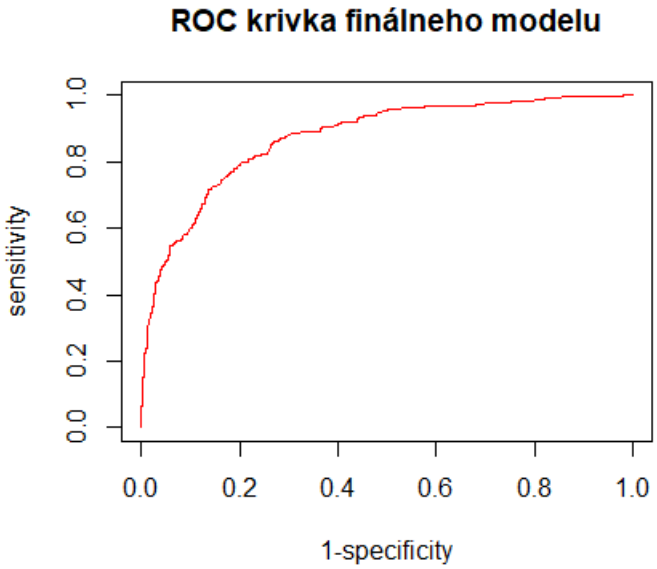

Obr. 12: ROC krivka pre diskrimináciu na testovacom súbore, finálny model, c-štatistika 0.8745

7 Hodnotenie nemocníc

V tejto kapitole predstavíme hodnotenie nemocníc na základe nášho ukazovateľa kvality. Pre každú nemocnicu sme vypočítali pozorovanú, očakávanú a štandardizovanú mieru úmrtnosti po ischemickej cievnej mozgovej príhode, varianciu rizikovo štandardizovanej miery a prislúchajúce intervaly spoľahlivosti. Teoretický koncept výpočtov sme popísali v časti 2.3.2.

Za účelom zmysluplnejšieho porovnania sme rozdelili nemocnice v našom súbore na *malé* (6), *stredne veľké* (8) a *veľké* (8). Za *veľké* nemocnice budeme považovať fakultné nemocnice, ktoré majú spravidla (ale nie nutne) najviac prípadov a od väčšiny z nich máme k dispozícií dáta za všetky 3 roky. *Stredne veľké* sú ostatné väčšie nemocnice, dáta máme u niektorých za všetky 3 roky, u niektorých za 1 alebo 2. *Malé* nemocnice je nová skupina menších nemocníc, pre ktoré máme dáta iba za rok 2017 a početnosť prípadov sa pohybuje spravila okolo 100 až 200.

Rozhodli sme sa využiť náš ukazovateľ kvality na porovnanie kvality nemocníc v rámci časovo homogénnej vzorky. Za túto vzorku sme zvolili rok 2017, keďže zaň máme dáta pre najvyšší počet nemocníc. Jediná nemocnica, ktorej dáta pre tento rok nemáme, je nemocnica 3, tá sa teda nevyskytne vo finálnom hodnotení.

Ako sa uvádza v [31], štandardizované miera úmrtnosti nemocnice je signifikantne nižšia ako referenčná hodnota, ak je horná hranica intervalu spoľahlivosti nižšie ako bodový odhad referenčnej hodnoty. Podobne, štandardizovaná miera je signifikantne vyššia ako referenčná hodnota, ak je dolná hranica intervalu spoľahlivosti vyššie ako bodový odhad referenčnej hodnoty.

Pre hodnotenie všetkých nemocníc sme použili ten istý model štandardizácie aj tú istú referenčnú hodnotu (priemerná pozorovaná úmrtnosť celej populácie), pre lepšiu ilustráciu však hodnotenie nemocníc uvádzame zvlášť pre *malé*, *stredné* a *veľké* nemocnice.

Na nasledujúcich grafoch vidíme štandardizované miery úmrtnosti pre jednotlivé nemocnice aj s intervalmi spoľahlivosti. Zelenou farbou sú vyznačené nemocnice signifikantne lepšie ako priemer, červenou signifikantne horšie, čiernou priemerné. Číslené hodnoty jednotlivých údajov sa nachádzajú v tabuľkách 13, 14 a 15 v Prílohe.

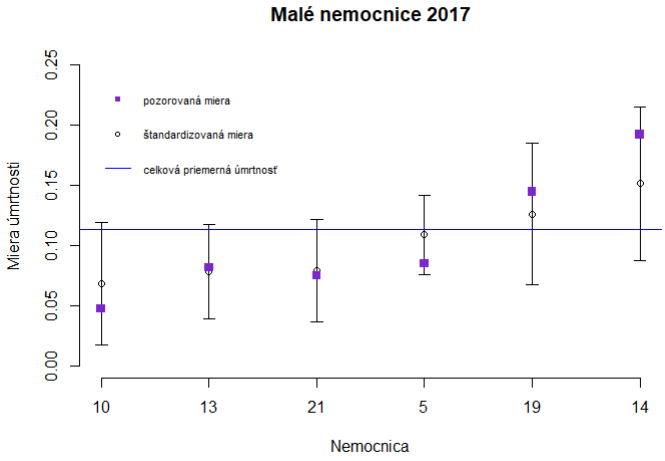

Obr. 13: Porovnanie pozorovanej a štandardizovanej miery úmrtnosti po ischemickej CMP pre malé nemocnice v roku 2017

Ako môžeme vidieť, intervaly spoľahlivosti pre malé nemocnice sú veľmi široké a žiadna z nich sa neukázala ako signifikantne horšia alebo signifikantne lepšia ako priemer. Nemocnice 10 a 5 si štandardizáciou „pohoršili", naopak nemocnice 19 a 14 sú na tom po štandardizácii lepšie. Štandardizácia nespôsobila ani výrazné zmeny v poradí nemocníc, na oboch stranách sa však nemocnice priblížili k priemeru.

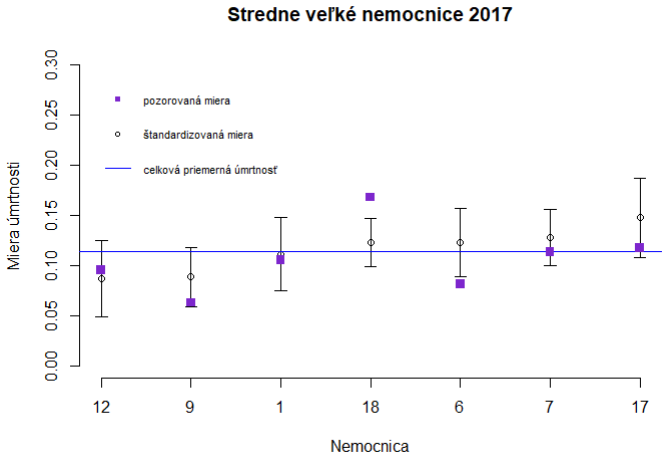

Obr. 14: Porovnanie pozorovanej a štandardizovanej miery úmrtnosti po ischemickej CMP pre stredne veľké nemocnice v roku 2017

Pre stredne veľké nemocnice štandardizácia priniesla zaujímavejšie výsledky. U nemocníc 6 a 18 pozorovaná miera úmrtnosti vôbec nespadá do intervalu spoľahlivosti pre

štandardizovanú mieru, čo svedčí o veľkých rozdieloch v skladbe pacientov daných nemocníc v porovnaní s priemerom. Poradie nemocníc na základe štandardizovanej a pozorovanej miery sa tiež v tomto prípade líši. Stále žiadna z nemocníc nejaví známky signifikantne horšieho alebo signifikantne lepšieho správania ako priemer, intervaly spoľahlivosti sú však už výrazne užšie ako v prípade malých nemocníc.

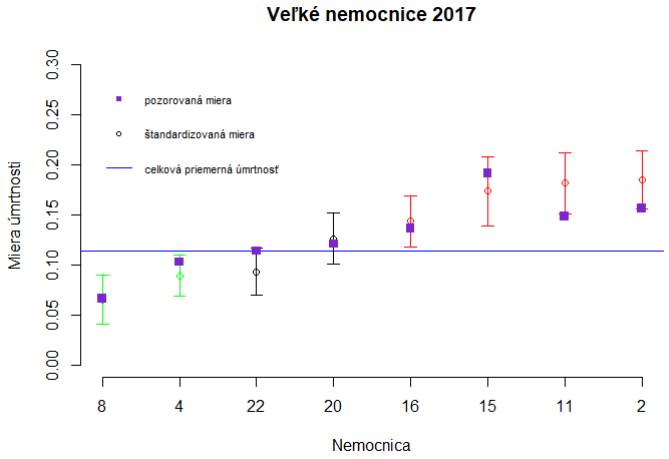

Obr. 15: Porovnanie pozorovanej a štandardizovanej miery úmrtnosti po ischemickej CMP pre stredne veľké nemocnice v roku 2017

Nakoniec sme sa pozreli na veľké nemocnice, u ktorých prvýkrát pozorujeme nemocnice vybočujúce z pásma signifikantnosti. 2 nemocnice sa javia ako výrazne lepšie, 2 ako priemerné a 4 ako výrazne horšie ako priemer. Najhoršie nemocnice 11 a 2 si štandardizáciou najvýraznejšie pohoršili oproti pozorovanej miere úmrtnosti.

Keďže pre stredné a veľké nemocnice máme k dispozícií väčšiu dátovú vzorku, rozhodli sme sa pre porovnanie vyhodnotiť aj ich miery úmrtnosti na všetkých dostupných dátach. Zaujímalo nás predovšetkým, či pridaním ďalších dát (a následným zúžením intervalov) dostaneme viac nemocníc vybočujúcich z priemeru.

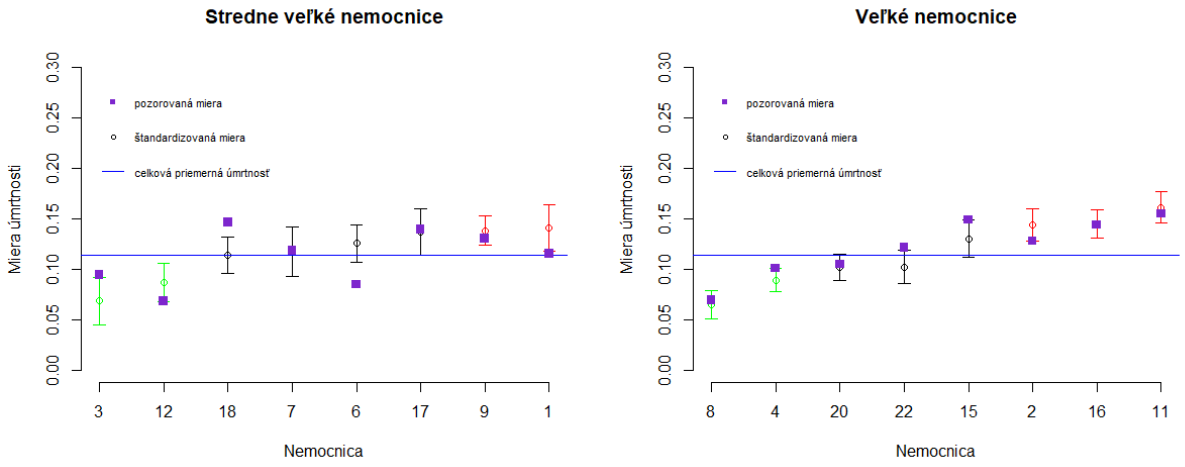

(a) Stredne veľké nemocnice

(b) Veľké nemocnice

Obr. 16: Porovnanie pozorovanej a štandardizovanej miery úmrtnosti po ischemickej cievnej mozgovej príhode, 2015-2017

U veľkých nemocníc pozorujeme na väčšom dátovom súbore miernu zmenu poradia, okrem (pôvodne signifikantne horšej) nemocnice 15 však nemocnice ostávajú v pôvodnom pásme. Pri stredne veľkých nemocniciach sa tentoraz objavujú aj výrazne horšie a výrazne lepšie nemocnice. Prekvapením je predovšetkým posun nemocníc 9 a 1 do výrazne horšieho pásma, keďže v hodnotení 2017 patrili medzi najlepšie.

7.1 Zhrnutie

V tejto kapitole sme predstavili hodnotenie nemocníc v našom dátovom súbore na základe ukazovateľa kvality IQI 17C - Úmrtnosť po ischemickej cievnej mozgovej príhode za rok 2017. Nemocnice sme pritom rozdelili na veľké (fakultné), stredné (ostatné väčšie) a malé nemocnice.

Malé nemocnice mali pôvodnú pozorovanú mieru úmrtnosti veľmi variablinú, na základe nášho hodnotenia však žiadna výrazne nevybočuje z priemeru. Štandardizácia poukázala na vysokú rizikovosť niektorých malých nemocníc, čo by mohlo vysvetľovať nehomogenitu v miere úmrtnosti. Intervaly spoľahlivosti sú však veľmi široké (maximálna šírka 0.13), pre malé nemocnice pri danom počte prípadov teda IQI17 nemôžeme považovať za spoľahlivý ukazovateľ kvality.

U stredných nemocníc rovnako nepozorujeme výrazne horšie ani výrazne lepšie ne-

mocnice, dĺžka intervalu spoľahlivosti však už nepresahuje hodnotu 0,079 a môžeme teda hovoriť o väčšej miere presnosti. Pri rozšírení dátovej vzorky na roky 2015 a 2016 však pozorujeme výrazné zmeny statusu niektorých nemocníc, čo by mohlo znamenať výrazné medziročné fluktuácie, ale tiež nedostatočnú spoľahlivosť nášho ukazovateľa.

Najlepšie sa ukazovateľ osvedčil pri hodnotení veľkých nemocníc. Už pri hodnotení v roku 2017 pozorujeme výrazne lepšie i výrazne horšie nemocnice, s rozšírením vzorky sa výstup výrazne nemení. Najdlhší interval spoľahlivosti má dĺžku 0.069.

Početnosť prípadov v malých českých nemocniciach je zrejme príliš nízka na to, aby ukazovateľ IQI 17C priniesol relevantné výsledky. Možným riešením je obohatiť meranie o dáta zozbierané počas viacerých rokov, pre zmysluplné každoročné meranie však skôr odporúčame rozšíriť definíciu ukazovateľa o podobné diagnózy (napríklad iné typy CMP) a tak zabezpečiť väčšiu robustnosť hodnotenia.

Záver

V teoretickej časti práce sme sa pozreli na problematiku merania kvality a sád ukazovateľov kvality v širšom kontexte a tak položili základ pre ďalšiu iniciatívu. Výhodou sád ukazovateľov oproti globálnym metrikám (ako napríklad celonemocničná úmrtnosť) je možnosť prispôsobiť model konkrétnejšie rizikám danej diagnózy a tiež väčšia miera detailu v pomenovaní zdrojov nekvality. Ako hlavný prínos práce vnímame model pre výpočet pravdepodobnosti úmrtia pacienta s ischemickou CMP, ktorý sme oproti doterajším spôsobom štandardizácie využívaným v ČR (iba demografické charakteristiky) obohatili o faktory popisujúce zdravotný stav pacienta. Z pôvodných 0,701 pre demografický model sme zvýšili diskriminačnú schopnosť reprezentovanú hodnotu c-štatistiky na 0,872. Pri tvorbe modelu sme dôkladne zvážili klinické súvislosti vyplývajúce z výberu premenných tak, aby model čo najlepšie odrážal stav pacienta na príjme. Otestovali sme tiež model založený na zaradení pacientov do DRG, diskriminačná schopnosť modelu založeného na vedľajších diagnózach však bola v prípade nášho ukazovateľa vyššia. Na základe štandardizovanej miery úmrtnosti sa nám podarilo následne identifikovať signifikantne lepšie a signifikantne horšie nemocnice medzi veľkými nemocnicami v našom dátovom súbore. Všetky malé a stredné nemocnice boli zaradené do stredného pásma. To s veľkou pravdepodobnosťou svedčí o tom, že počet prípadov je príliš nízky na to, aby sme o týchto nemocniciach vedeli na základe nášho ukazovateľa vyvodzovať objektívne závery. V prípade malých nemocníc s veľkými rozdielmi v pozorovanej miere úmrtnosti poukázal na to, že bez štandardizácie by sme ľahko urobili mylné závery. Pre objektívnejšie využitie ukazovateľa v prípade menších nemocníc odporúčame porovnávať mieru úmrtnosti za dlhšie časové obdobie alebo rozšíriť množinu prípadov ukazovateľa o ďalšie typy CMP.

Náš ukazovateľ samozrejme nie je absolútne objektívnou metrikou kvality a má veľa nedostatkov. Dôsledkom nekvalitnej starostlivosti nemusí byť vždy smrť pacienta v nemocnici. Mnohí pacienti po CMP zomrú neskôr, alebo majú trvalé následky, to už však naším ukazovateľom nevieme zachytiť. O časť informácie sme prišli i vyradením pacientov prevezených do iných zariadení a v prípade pacientov privezených z iných zariadení sme mohli neprávom penalizovať druhú nemocnicu za chyby prvej, ak neboli odhalené v podobe diagnóz na príjme. Vedľajšie a hlavné diagnózy taktiež závisia od schopností lekára a bolo by naivné predpokladať, že pri diagnostike a kódovaní nevznikajú pochybenia a

informačné straty. Vzhľadom na zdroj a formu našich dát sme neboli schopní spoľahlivo identifikovať predchádzajúcu zdravotnú starostlivosť hospitalizovaných pacientov. Zaradenie takejto premennej by tiež zrejme pomohlo vylepšiť predikčnú schopnosť modelu. Za najnepriaznivejší aspekt dátového rozhrania v ČR však považujeme neschopnosť rozlíšiť medzi diagnózami kódovanými na príjme a pri prepustení. Pridanie takéhoto dátového elementu pomohlo posunúť štandardizáciu ukazovateľov v USA na vyššiu úroveň a určite by pomohlo aj pri meraní kvality v ČR.

Meranie kvality je rozsiahla téma a existuje mnoho spôsobov, ako rozvinúť výsledky našej práce do hĺbky i do šírky. Okrem eliminácie spomenutých nedostatkov napríklad otestovaním iných modelov štandardizácie s prihliadnutím na potenciálnu koreláciu prípadov v rámci nemocnice. Modely zohľadňujúce tento faktor sú napríklad *generalized estimating equations* alebo zovšeobecnené zmiešané lineárne modely. Využitím simulačných metód by tiež bolo možné vytvoriť rovnomernejšiu vzorku pozorovaní, v ktorej by natoľko nedominovali nemocnice s veľkým počtom prípadov. Z hľadiska šírky je prirodzeným pokračovaním našej práce tvorba modelov štandardizácie pre ďalšie ukazovatele kvality. Tie potom možno spojiť do váženého ukazovateľa, ktorý by umožnil zostavenie rebríčka nemocníc alebo ich zaradenie do pásiem kvality. Hoci faktory štandardizácie sa pri jednotlivých ukazovateľoch líšia, niektoré metodické úvahy a kroky sú veľmi podobné. Závery našej práce teda môžu byť aj užitočnou inšpiráciou pri ďalšej práci v oblasti štandardizácie ukazovateľov kvality.

Zoznam použitej literatúry

[1] Agresti, A.: *An introduction to categorical data analysis*, John Wiley & sons inc. publication, Hoboken, New Jersey, 2007

[2] Agency for healthcare research and quality, *Calculating Standard Errors and Confidence Intervals for the AHRQ Quality Indicators*, dostupné na internete (12.5.2019): `https://www.qualityindicators.ahrq.gov/Modules/default.aspx`

[3] AHRQ Quality Indicators™ (AHRQ QI™) ICD-9-CM Specification Version 6.0, *Inpatient Quality Indicator 17 (IQI 17) Acute Stroke Mortality Rate*, 2017, dostupné na internete (10. 5. 2019): `https://www.qualityindicators.ahrq.gov/Downloads/Modules/IQI/V60/TechSpecs/IQI_17_Acute_Stroke_Mortality_Rate.pdf`

[4] Agency for healthcare research and quality, *Inpatient quality indicators (IQI) parameter estimates ICD-9-CM Version 6.0*, 2017, dostupné na internete (10. 5. 2019): `https://www.qualityindicators.ahrq.gov/Downloads/Modules/IQI/V60/Parameter_Estimates_IQI_6.0_ICD-9-CM.pdf`

[5] Agency for healthcare research and quality, *Prevention quality indicators (PQI) parameter estimates ICD-9-CM Version 6.0*, 2016, dostupné na internete (10. 5. 2019): `https://www.qualityindicators.ahrq.gov/Downloads/Modules/PQI/V60-ICD09/Parameter_Estimates_PQI_60.pdf`

[6] Agency for healthcare research and quality, *Pediatric quality indicators (PDI) parameter estimates ICD-9-CM Version 6.0*,2017, dostupné na internete (10. 5. 2019): `https://www.qualityindicators.ahrq.gov/Downloads/Modules/PDI/V60/Parameter_Estimates_PQI_60.pdf`

[7] Agency for healthcare research and quality, *Patient safety indicators parameter estimates ICD-9-CM Version 6.0*,2016, dostupné na internete (10. 5. 2019): `https://www.qualityindicators.ahrq.gov/Downloads/Modules/PQI/V60-ICD09/Parameter_Estimates_PQI_60.pdf`

[8] Canadian institute for health information, *Model specifications - Clinical indicators*, 2018, dostupné na internete (10.5. 2019): `https://www.cihi.ca/en/search?query-all=model+specifications&Search+Submit=`

[9] Chassin, M.R.: *Achieving and Sustaining Improved Quality: Lessons From New York State and Cardiac Surgery.*, Health Affairs (Millwood), 2002, Vol. 21, No. 4, pp. 40-51.

[10] Chun, J.; Bafford, A. C.:*History and background of quality measurement*, Clinics in colon and rectal surgery, 2014, Vol. 27(1), 5-9

[11] Dhital, R. et al., *Ischemic Stroke and Impact of Thyroid Profile at Presentation: A Systematic Review and Meta-analysis of Observational Studies*, Journal of Stroke and Cerebrovascular Diseases , 2017 Volume 26 , Issue 12 , 2926 - 2934

[12] Donabedian, A.:*The Quality of Care. How Can it be Assessed?*, The Journal of the American Medical Association, 1988, Vol. 260, No. 12, pp. 1743-1748

[13] Gallacher, K. I. et al: *Risk factors and mortality associated with multimorbidity in people with stroke or transient ischaemic attack: a study of 8,751 UK Biobank participants.*, Journal of Comorbidity, 2018, Volume 8(1), 1–8.

[14] Gelman, A., Hill, J.: Data Analysis Using Regression and Multilevel/Hierarchical Models, Cambridge University Press, New York, 1st printing, 2007.

[15] Hibbard, J., Stockard, J., Tusler, M.: *Does Publicizing Hospital Performance Stimulate Quality Improvement Efforts?*, Health Affairs (Millwood), 2003, Vol. 22, No. 2, pp. 84-94.

[16] Hand, J. D.: *Measuring classifier performance: a coherent alternative to the area under the ROC curve*, Machine Learning, 2009, Volume 77, Issue 1, pp 103–123

[17] Hosmer, D. W., Lemeshow S: *Applied logistic regression, 2. ed*, Wiley, Inc.,New York

[18] Hodyc, D.: *DRG systém v ČR.* Diplomová práca, Vysoká škola ekonomická v Praze, Praha, 2007

[19] Jimenez-Conde, J. et al: *Hyperlipidemia and reduced white matter hyperintensity volume in patients with ischemic stroke.*, Stroke, 2010, Vol. 41, No. 3, 437-442.

[20] Longo, D. R. et al: *Consumer Reports in Health Care. Do They Make a Difference in Patient Care?*, Journal of the American Medical Association, 1997, Vol. 278, pp. 1579-1584.

[21] Mannion, R. – Goddard, M.: *Public disclosure of comparative clinical performance data: lessons from the Scottish experience*, Journal of Evaluation in Clinical Practice, 2003, Vol. 9, No. 2, pp. 277-286.

[22] McHugh, M. L.: *The chi-square test of independence*, Biochemia medica, 2013,Vol. 23(2), 143–149.

[23] Mittal, S.H.; Goel, D.; *Mortality in ischemic stroke score: A predictive score of mortality for acute ischemic stroke.* Brain Circulation, 2017, Volume 3(1), 29–34

[24] Mezinárodní statistická klasifikace nemocí a přidružených zdravotních problémů, 2018, dostupné na internete (10. 5. 2019): `http://www.uzis.cz/cz/mkn/index.html`

[25] Narrins, C.R. et al: *The influence of public reporting of outcome data on medical decision making by physicians*, Archives of Internal Medicine, 2005, Vol. 165, pp. 83-87.

[26] OEDC hospital performance, dostupné na internete (10. 5. 2019): `https://www.oecd.org/health/health-systems/hospital-performance.htm`

[27] Prášil, M. et al: *Zlepšení systému řízení zdravotní péče, technická asistence - Indikátory kvality zdravotních služeb, díl 1 - Úvod do problematiky a návrh základní metodiky*

[28] Shah, B.; Bartaula, B.; Adhikari, J.; Neupane, HS.; Shah, B.P., Poudel, G.: *Predictors of In-hospital Mortality of Acute Ischemic Stroke in Adult Population.*, J Neurosci Rural Pract. 2017;8(4):591–594.

[29] Suchý, M. et al: *Vývoj národní sady ukazatelů zdravotních služeb*, 2008, dostupné na internete (14.1.2019): http://www.mzcr.cz/dokumenty/vyvoj-narodni-sady-ukazatelu-zdravotnich-sluzeb_3783_1841_15.html

[30] Technické špecifikácie AHRQ IQI indikátorov, dostupné na internete (14. 1. 2019) https://www.qualityindicators.ahrq.gov/Modules/IQI_TechSpec_ICD9_V60.aspx

[31] Truven health analytics (Stanford university), *AHRQ Quality indicators empirical methods*, 2014, dostupné na internete (10. 5. 2019): https://www.qualityindicators.ahrq.gov/Downloads/Resources/Publications/2015/Empirical_Methods_2015.pdf

[32] Tůma P., osobná komunikácia, Praha, 2019

[33] Zavarská S., *Ischemická CMP: Cievna mozgová príhoda spôsobená zrazeninou*, 2018, dostupné na internete https://www.slovenskypacient.sk/ischemicka-cmp-cievna-mozgova-prihoda-sposobena-zrazeninou/

Príloha

Kód bázy	Názov
0000	Zberná báza
0004	Dlhodobá mechanická ventilácia > 240 hodín (11-21 dní)
0005	Dlhodobá mechanická ventilácia > 96 hodín (5-10 dní)
0010	Dlhodobá mechanická ventilácia > 504 hodín (22-42 dní) s ekonomicky náročným výkonom
0012	Dlhodobá mechanická ventilácia > 240 hodín (11-21 dní) s ekonomicky náročným výkonom
0013	Dlhodobá mechanická ventilácia > 96 hodín (5-10 dní) s ekonomicky náročným výkonom
0101	Kraniotómia
0103	Výkony na extrakraniálnych cievach
0106	Iné výkony pri chorobách a poruchách nervového systému
0107	Endovaskulárne výkony pri mozgovom infarkte
0134	Cievna mozgová príhoda s infarktom
0146	Iné poruchy nervového systému
8887	Rozsiahle výkony, ktoré sa netýkajú hlavnej diagnózy
8889	Výkony obmedzeného rozsahu, ktoré sa netýkajú hlavnej diagnózy

Tabuľka 10: Názvy pseudoDRG báz zobrazených v tabuľke 12

Hodnoty premenných pre referenčnú kategóriu sú: `Prijatie_4` *(iný spôsob prijatia)*, `Vek_1011` *(Vek [65,75) rokov)*, `Pohlavie_U` *(Pohlavie: neznáme)*, `TypBázy_CHIR` *(Chirurgický typ bázy)*, `Dg_I635` *(Mozgový infarkt spôs.neurč.oklúziou alebo stenózou mozgových tepien)*. Pre všetky vedľajšie diganózy a kapitoly je referenčná hodnota *0 - diagnóza neprítomná*.

Parameter	$\hat{\boldsymbol{\beta}}$	$e^{\hat{\beta}}$	**Std. error**	$\boldsymbol{W}$	$\boldsymbol{p(>W)}$
Intercept	-2.32539	0.09774490	0.20389	-11.405	$< 2.10^{-16}$
Prijatie_1	0.06269	1.06469444	0.18007	0.348	0.727736
Prijatie_2	0.27763	1.31999666	0.23914	1.161	0.245668
Prijatie_3	0.51341	1.67098208	0.14657	3.503	0.000460
Vek_123	-2.44307	0.08689391	0.91305	-2.676	0.007457
Vek_45	-3.85619	0.02114849	1.08488	-3.554	0.000379
Vek_6	-1.53232	0.21603442	0.56717	-2.702	0.006899
Vek_7	-1.32185	0.26664034	0.40101	-3.296	0.000980
Vek_8	-1.12782	0.32373764	0.30631	-3.682	0.000231
Vek_9	-0.35961	0.69794796	0.17985	-1.999	0.045559
Vek_12	0.40939	1.50589313	0.12124	3.377	0.000733
Vek_13	0.62745	1.87282691	0.11402	5.503	$3.73.10^{-08}$
Vek_14	1.00635	2.73558486	0.11593	8.681	$< 2.10^{16}$
Vek_15	1.40750	4.08572942	0.13648	10.313	$< 2.10^{-16}$
Vek_16	1.59321	4.91951707	0.25131	6.340	2.30^{-10}
Pohlavie_M	-0.47916	0.61930121	0.14741	-3.251	0.001152
Pohlavie_Z	-0.34749	0.70646016	0.14411	-2.411	0.015896
TypBázy_NECHIR	-0.27406	0.76028990	0.12955	-2.116	0.034386
Dg_I631	0.38090	1.46359881	0.18311	2.080	0.037511
Dg_I632	-0.02133	0.97889614	0.15740	-0.136	0.892207

Tabuľka 11: Model pre výpočet pravdepodobnosti úmrtia po ischemickej cievnej mozgovej príhode

Parameter	$\hat{\beta}$	$e^{\hat{\beta}}$	**Std. error**	W	$p(>W)$
Dg_I630	0.23270	1.26200614	0.21447	1.085	0.277925
Dg_I633	-0.19712	0.82109467	0.10613	-1.857	0.063276
Dg_I634	-0.02475	0.97555004	0.10296	-0.240	0.810007
Dg_I636	0.46448	1.59118338	0.93255	0.498	0.618434
Dg_I638	-0.59053	0.55403155	0.17899	-3.299	0.000970
Dg_I639	0.18709	1.20573808	0.14930	1.253	0.210150
A41	1.34304	3.83067980	0.28659	4.686	$2.78.10^{-06}$
E03	-0.53232	0.58724359	0.23153	-2.299	0.021500
E10	0.63982	1.89614182	0.22272	2.873	0.004069
E78	-1.01343	0.36297270	0.11349	-8.929	$< 2.10^{-16}$
G40	0.50474	1.65655043	0.20792	2.428	0.015200
G93	3.22227	25.08490132	0.15834	20.350	$< 2.10^{-16}$
I25	0.38665	1.47204540	0.10482	3.689	0.000225
I50	1.25889	3.52152099	0.13721	9.175	$< 2.10^{-16}$
I61	1.67734	5.35132711	0.23839	7.036	$1.98.10^{-12}$
I70	0.33297	1.39510938	0.18974	1.755	0.079272
J15	0.74850	2.11383151	0.25052	2.988	0.002810
J18	1.87235	6.50355160	0.11772	15.905	$< 2.10^{-16}$
J20	0.48422	1.62290888	0.22157	2.185	0.028856
J96	2.16571	8.72075580	0.17251	12.554	$< 2.10^{-16}$
R40	1.99256	7.33426561	0.26338	7.565	$3.87.10^{-14}$
R47	-1.51316	0.22021240	0.26177	-5.781	$7.45.10^{-09}$
Z92.1	-0.82687	0.43741610	0.35488	-2.330	0.019807
II.	0.60013	1.82235815	0.16942	3.542	0.000397
IX.	0.36848	1.44554086	0.12299	2.996	0.002735

Tabuľka 11: Model pre výpočet pravdepodobnosti úmrtia po ischemickej cievnej mozgovej príhode

Parameter	Popis
Intercept	
Prijatie_1	Spôsob prijatia: transfer z iného zariadenia
Prijatie_2	Spôsob prijatia: transfer z iného oddelenia
Prijatie_3	Spôsob prijatia neznámy
Vek_123	Vek [18,35) rokov
Vek_45	Vek [35,45) rokov
Vek_6	Vek [45,50) rokov
Vek_7	Vek [50,55) rokov
Vek_8	Vek [55,60) rokov
Vek_9	Vek [60,65) rokov
Vek_12	Vek [75,80) rokov
Vek_13	Vek [80,85) rokov
Vek_14	Vek [85,90) rokov
Vek_15	Vek [90,95) rokov
Vek_16	Vek 95+ rokov
Pohlavie_M	Pohlavie: muž
Pohlavie_Z	Pohlavie: žena
TypBázy_NECHIR	Nechirurgický typ bázy
Dg_I630	Mozgový infarkt spôs.trombózou prívodných mozgových tepien
Dg_I631	Mozgový infarkt spôs.embóliou prívodných mozgových tepien
Dg_I632	Mozgový infarkt spôs.neurč.oklúziou alebo stenózou prívod.mozg. tepien
Dg_I633	Mozgový infarkt spôs.trombózou mozgových tepien
Dg_I634	Mozgový infarkt spôs.embóliou mozgových tepien
Dg_I636	Mozgový infarkt spôs.mozgovou žilnou trombózou, nehnisavou
Dg_I638	Iný mozgový infarkt
Dg_I639	Mozgový infarkt NS
A41	Iná sepsa
E03	Iná hypotyreóza
E10	Diabetes mellitus 1. typu

Tabuľka 12: Model pre výpočet pravdepodobnosti úmrtia po ischemickej cievnej mozgovej príhode: popis parametrov

Parameter	Popis
E78	Poruchy metabolizmu lipoproteínov a iné lipidémie
G40	Epilepsie – padúcnica
G93	Iné poruchy mozgu
I25	Chronciká ischmická srdečná choroba
I50	Zlyhanie srdca
I61	Intracerebrálne (vnútromozgové) krvácanie
I70	Ateroskleróza
J15	Bakteriálny zápal pľúc (pneumónia) nezaradený inde
J18	Pneumónia, pôvodca NS
J20	Akútny zápal priedušiek [bronchitis acuta]
J96	Respiračné zlyhanie nezarazené inde
R40	Spavosť (somnolencia), strnulosť (stupor) a bezvedomie (kóma)
R47	Poruchy reči nezaradené inde
Z92	Lekárska liečba v osobnej anamnéze
II.	Novotvary
IX.	Choroby obehovej sústavy (okrem diagnóz I10, I25, I48, I50, I61, I63, I65, I66, I67, I69)

Tabuľka 12: Model pre výpočet pravdepodobnosti úmrtia po ischemickej cievnej mozgovej príhode: popis parametrov

Malé nemocnice 2017					
Číslo	**LB**	**Štand. miera**	**UB**	**Poz. miera**	**Pásmo**
10	0.0175	0.0684	0.1192	0.0471	Priemer
13	0.039	0.078	0.1170	0.0816	Priemer
21	0.0367	0.0790	0.1213	0.0747	Priemer
5	0.0758	0.1088	0.1417	0.0849	Priemer
19	0.0672	0.1260	0.1848	0.1446	Priemer
14	0.0874	0.1512	0.2151	0.1923	Priemer

Tabuľka 13: Hodnotenie malých nemocníc na základe úmrtnosti po ischemickej cievnej mozgovej príhode za rok 2017

Stredne veľké nemocnice 2017					
Číslo	**LB**	**Štand. miera**	**UB**	**Poz. miera**	**Pásmo**
12	0.049	0.0867	0.1244	0.0955	Priemer
9	0.059	0.0883	0.1178	0.0629	Priemer
1	0.0743	0.1109	0.1474	0.1050	Priemer
18	0.0985	0.1225	0.1465	0.168	Priemer
6	0.0885	0.1228	0.157	0.0815	Priemer
7	0.0998	0.1281	0.1563	0.1134	Priemer
17	0.1083	0.1479	0.1874	0.1176	Priemer

Tabuľka 14: Hodnotenie stredne veľkých nemocníc na základe úmrtnosti po ischemickej cievnej mozgovej príhode za rok 2017

Veľké nemocnice 2017					
Číslo	**LB**	**Štand. miera**	**UB**	**Poz. miera**	**Pásmo**
8	0.0407	0.0652	0.0897	0.0665	Lepšia
4	0.0688	0.0892	0.1095	0.1027	Lepšia
22	0.0701	0.0933	0.1165	0.1137	Priemer
20	0.1004	0.1261	0.1517	0.1208	Priemer
16	0.1182	0.1437	0.1692	0.1367	Horšia
15	0.1392	0.1739	0.2085	0.1916	Horšia
11	0.1519	0.1817	0.212	0.1486	Horšia
2	0.1556	0.1848	0.2139	0.1561	Horšia

Tabuľka 15: Hodnotenie veľkých nemocníc na základe úmrtnosti po ischemickej cievnej mozgovej príhode za rok 2017