

UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



BENCHMARKING POSKYTOVATEĽOV ZDRAVOTNEJ  
STAROSTLIVOSTI

DIPLOMOVÁ PRÁCA

UNIVERZITA KOMENSKÉHO V BRATISLAVE  
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY

**BENCHMARKING POSKYTOVATEĽOV ZDRAVOTNEJ  
STAROSTLIVOSTI**

**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



Univerzita Komenského v Bratislave  
Fakulta matematiky, fyziky a informatiky

---

## ZADANIE ZÁVEREČNEJ PRÁCE

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

**Názov:** Benchmarking poskytovateľov zdravotnej starostlivosti  
*Benchmarking of healthcare providers*

**Anotácia:** Identifikácia želaných a neželaných javov v rôznych oblastiach poskytovania zdravotnej starostlivosti pomocou metód data miningu z dát zdravotnej poisťovne. Táto téma je vypisovaná v spolupráci so zdravotnou poisťovňou Dôvera, ktorá má k dispozícii objemné a zaujímavé databázy o poskytnutej zdravotnej starostlivosti. Diplomant sa postupne zoznámi s obsahom a štruktúrou dostupných dát a aktuálnymi témami, na základe ktorých si bude môcť určiť konkrétnejšie zadanie pre svoju prácu.

**Vedúci:** Mgr. Henrieta Tulejová  
**Katedra:** FMFI.KAMŠ - Katedra aplikovanej matematiky a štatistiky  
**Vedúci katedry:** prof. RNDr. Marek Fila, DrSc.  
**Dátum zadania:** 11.01.2022

**Dátum schválenia:** 14.01.2022

prof. RNDr. Daniel Ševčovič, DrSc.  
garant študijného programu

---

študent

---

vedúci práce

**Podakovanie** Touto cestou sa chcem poďakovať mojej školiteľke Mgr. Henriete Tulejovej za jej cenné rady a ochotu vydať sa na tento boj so mnou. Môjmu šéfovi Mgr. Ing. Roman Mužik PhD., MSc. za úžasnú možnosť pracovať v Dôvera z. p. v tak perfektnom kolektíve a mojim kolegom Mgr. Martinovi Selvekovi a Mgr. Beáte Saal za ich nekonečnú trpezlivosť, stále ochotné srdiečko pomôcť úbohej duši a úsmev na ich tvárach, ktorý sa chorobne prenáša na ďalších okolo. V neposlednom rade mojej rodine za ich podporu a premodlené ružence, aby som bola tam, kde som dnes.

## Abstrakt v štátnom jazyku

RUDOLFOVÁ, Karolína: Benchmarking poskytovateľov zdravotnej starostlivosti [Diplo-mová práca], Univerzita Komenského v Bratislave, Fakulta matematiky, fyziky a infor-matiky, Katedra aplikovanej matematiky a štatistiky; školiteľ: Mgr. Henrieta Tulejová, Bratislava, 2023, 67 s.

Práca vyhodnocuje vplyv intervencie za účelom racionalizácie preskripcie antibiotík a to primárne pomocou testovania C-reaktívneho proteínu (CRP). Analýzu vyhodnocujeme nad poistencami zdravotnej poisťovne Dôvera, a.s. v regiónoch, kde funguje program DôveraPomáha, s diagnózou infekcie horných dýchacích ciest. Vplyv CRP na preskripciu antibiotík a ďalšie iné vplyvy sú vyhodnocované pomocou logistického modelu založeného na viacrozmernej lineárnej regresii. Efekt vykazovania CRP za účelom racionalizácie predpisovania antibiotík je vyhodnocovaný počítaním pomeru šancí pre poskytovateľov zdravotnej starostlivosti a tiež pre diagnózy zamerané na infekciu horných dýchacích ciest. Štatistickým testovaním sledujeme rozdiely medzi lekármi, ktorých šance na preskripciu antibiotík po vykonaní CRP sú nižšie s lekármi, ktorí vplyvom vykonania CRP majú vyššie šance na preskripciu antibiotík.

**Kľúčové slová:** Racionalizácia preskripcie antibiotík, C-reaktívny proteín, Logistický model, Pomer šancí, Testovanie hypotéz

# Abstract

RUDOLFOVÁ, Karolína: Benchmarking of health care providers [Master's thesis], Comenius University in Bratislava, Faculty of Mathematics, Physics and Informatics, Department of Applied Mathematics and Statistics; supervisor: Mgr. Henrieta Tulejová, Bratislava, 2023, 67 p.

The thesis evaluates the impact of an intervention to rationalize antibiotic prescription, primarily using C-reactive protein (CRP) testing. The analysis is evaluated on insured patients of the health insurance company Dôvera, a.s. in the regions where the Dôvera-Pomáha programme operates, with a diagnosis of upper respiratory tract infection. The impact of CRP on antibiotic prescription and other effects are evaluated using a logistic model based on multivariate linear regression. The effect of CRP reporting to rationalize antibiotic prescribing is evaluated by calculating odds ratios for healthcare providers and also for diagnoses targeting upper respiratory tract infection. By statistical testing, we observe differences between physicians whose chances of prescribing antibiotics after performing CRP are lower with physicians who, due to the impact of performing CRP, have higher chances of prescribing antibiotics.

**Keywords:** Rationalization of antibiotic prescribing, C-reactive protein, Logistic model, Odds ratio, Hypothesis testing

# Obsah

|                                                                                                                |           |
|----------------------------------------------------------------------------------------------------------------|-----------|
| Úvod                                                                                                           | 8         |
| <b>1 CRP ako nástroj pre zníženie predpisovania antibiotík a tiež rezistencie voči antibiotikám</b>            | <b>10</b> |
| 1.1 Vplyv CRP na zníženie preskripcie antibiotík vo svete . . . . .                                            | 10        |
| 1.2 Intervencia v programe DôveraPomáha . . . . .                                                              | 14        |
| 1.3 Diagnózy horných dýchacích ciest . . . . .                                                                 | 15        |
| <b>2 Matematická analýza</b>                                                                                   | <b>17</b> |
| 2.1 Analyzované dáta . . . . .                                                                                 | 17        |
| 2.2 Exploračná analýza dát . . . . .                                                                           | 18        |
| 2.2.1 Vývoj pravdepodobnosti na predpis ATB pri kontakte . . . . .                                             | 21        |
| 2.2.2 Vývoj pravdepodobnosti na výkon CRP pri kontakte . . . . .                                               | 24        |
| 2.3 Model logistickej regresie . . . . .                                                                       | 27        |
| 2.3.1 Premenné v logistickom modeli . . . . .                                                                  | 29        |
| 2.3.2 Logistická regresia a predpis antibiotík . . . . .                                                       | 31        |
| 2.3.3 VIF a stepAIC . . . . .                                                                                  | 40        |
| 2.3.4 Model pre PLD a PLDD lekárov . . . . .                                                                   | 41        |
| <b>3 Benchmarking poskytovateľov zdravotnej starostlivosti (PZS)</b>                                           | <b>45</b> |
| 3.1 Pomer šancí na predpis antibiotík po vykonaní CRP . . . . .                                                | 45        |
| 3.1.1 Pomer šancí na preskripciu ATB po vykonaní CRP pre lekárov . . .                                         | 45        |
| 3.1.2 Testovanie hypotéz o pravdepodobnostných rozloženiach lekárov pre rôzne kategórie . . . . .              | 47        |
| 3.1.3 Pravdepodobnostné rozdelenie lekárov podľa zapojenia sa do intervencie v programe DôveraPomáha . . . . . | 48        |
| 3.1.4 OR a preskripcia antibiotík pred intervenciou . . . . .                                                  | 49        |
| 3.2 Vplyv CRP na preskripciu ATB pre diagnózy na horné dýchacie cesty . . .                                    | 53        |
| 3.3 Diskusia . . . . .                                                                                         | 56        |
| <b>Záver</b>                                                                                                   | <b>58</b> |

|                                   |           |
|-----------------------------------|-----------|
| <b>Zoznam použitej literatúry</b> | <b>59</b> |
| <b>Príloha A</b>                  | <b>61</b> |
| <b>Príloha B</b>                  | <b>62</b> |
| <b>Príloha C</b>                  | <b>64</b> |
| <b>Príloha D</b>                  | <b>66</b> |

# Úvod

Rezistencia voči antibiotikám (ďalej ATB) je veľmi aktuálny globálny problém. Ide o schopnosť baktérií odolávať látkam, ktoré ich majú primárne ničiť. Rezistencia na antibiotiká vzniká ich užívaním prirodzene vo všetkých sociodemografických skupinách a jedná sa o celosvetový fenomén. Určitému prirodzenému vývoju antibiotickej rezistencie nie je možné zabrániť. Závažnejším problémom však je, že pacienti po celom svete prispievajú k jej rýchlejšiemu rozvoju užívaním antibiotík nesprávne (kratšie ako je predpísaná doba) alebo zbytočne (pri ochoreniach, ktoré antibiotickú liečbu nevyžadujú) [13].

A tak pri liečbe ťažkých infekcií, ako napríklad zápal pľúc, tuberkulóza, salmonelóza a iné, sú antibiotiká stále menej účinné a choroby majú ťažší priebeh. Liečba trvá výrazne dlhšiu dobu. Tak okrem strávených dní v nemocnici stúpajú aj náklady na liečbu, a tiež zbytočná úmrtnosť [13].

Ku antimikrobiálnej rezistencii patrí aj zneužívanie antibiotík pri liečbe akútnych infekcií dýchacích ciest, ktoré sú často vírusového a nie bakteriálneho pôvodu a užívanie antibiotík na nich tak nemá vo väčšine prípadov žiaden významný vplyv [5].

Jednou z metód, ako znížiť túto rezistenciu voči antibiotikám je znížiť nadmerné predpisovanie antibiotík. Existuje viacero postupov, ako nadmernú preskripciu ovplyvniť. Podľa štúdií testovanie C-reaktívneho proteínu (CRP) by mohlo byť účinným nástrojom, ako znížiť zbytočnú preskripciu antibiotík na ochorenia horných dýchacích ciest ako u detí, tak aj u dospelých [1], [2].

V zdravotnej poisťovni Dôvera, a.s. (ďalej Dôvera z. p.) bolo v oblasti nadmerného predpisovania a užívania antibiotík viacero intervencií. Hlavná vlna intervencií bola v prvom kvartáli roku 2017 až do konca roku 2018. Od 1.8.2017 sa postupne pre praktických lekárov pre dospelých (PLD) zazmluvňoval výkon CRP. Praktický lekári pre deti a dorast (PLDD) túto možnosť mali už oveľa skôr, presnejšie od roku 2012.

V tejto práci sme sa pozreli na vyhodnotenie tejto intervencie zameranej na racionalizáciu pridpisovania antibiotík. Vysvetlili sme, prečo sa naša analýza bude zameriavať na diagnózy infekcie horných dýchacích ciest a pri týchto diagnózach sme uviedli aj stručnú charakteristiku, ako by sa malo postupovať pri ich liečbe a v akých prípadoch je vhodné predpísať antibiotiká.

Modelom založeným na logistickej regresii sme vyhodnotili, či využívanie CRP má

vplyv na zníženie šancí predpisovať ATB, a tiež čo iné okrem CRP má signifikantný vplyv na zmenu šancí pri predpisovaní ATB. Ďalej sme sa pozreli, pri akých lekároch sa šance na predpis ATB po vykonaní CRP znižujú, pri ktorých zas zvyšujú. Tiež sme sledovali zmenu šancí na predpis ATB po vykonaní CRP pri konkrétnych ochorení horných dýchacích ciest (HDC).

Nakoniec sme vykonali benchmarking poskytovateľov zdravotnej starostlivosti na základe získaných výsledkov.

Skratky vyskytujúce sa v práci sú vysvetlené v tabuľke 20.

# 1 CRP ako nástroj pre zníženie predpisovania antibiotík a tiež rezistencie voči antibiotikám

V tejto kapitole sme priblížili, prečo sa budeme zaoberať témou znižovania, resp. racionalizácie preskripcie antibiotík. Uviedli sme dôvody a zahraničné štúdie, ktoré hovoria o tom, prečo sa vykonávanie CRP javí ako rozumný nástroj na redukciiu preskripcie antibiotík. Tiež sme priblížili, na ktoré diagnózy by daná metóda mohla fungovať. Na základe odbornej literatúry sme porovnali, v koľkých percentách pri daných vybraných diagnózach ide o ochorenie bakteriálneho pôvodu a v koľkých prípadoch podľa našich dát boli na dané diagnózy predpísané antibiotiká.

Tiež sme uviedli v čom spočívala intervencia v Dôvera z. p., ktorej primárnym cieľom bolo zracionalizovať preskripciu antibiotík a tak znížiť rezistenciu voči antibiotikám u svojich poistencov.

## 1.1 Vplyv CRP na zníženie preskripcie antibiotík vo svete

C-reaktívny proteín je bielkovina v krvi, ktorá sa zvyšuje okrem iného aj pri zápalovej reakcii v tele spôsobenej baktériami. Hladina približne okolo 50 mg/l býva pri mierne zápalovej aktivite. Pri ťažkom zápale sa hodnoty CRP pohybujú v stovkách mg/l [3]. Je ťažké určiť hranicu, ktorá by rozhodovala o vírusovom, alebo bakteriálnom pôvode choroby. Dôležité je tiež v akom štádiu choroby je pacientovi CRP merané. Či ho má hranične zvýšené krátko po vypuknutí príznakov choroby, alebo až po niekoľkých dňoch pretrvávajúcich symptómov. Štúdia [8] poukazuje aj na to, ako sa orientačná CRP hranica líši pri jednotlivých štúdiách a tak nie je konzistentná a jednoznačná.


Štúdia [5] uvádza, že až v 80% prípadov infekcií dýchacích ciest sú predpísané antibiotiká. Podľa tejto meta analýzy nie je vplyv merania CRP na preskripciu antibiotík jednoznačný.

V dánskej štúdii [1] sledovali vplyv CRP po troch mesiacoch od intervencie rozdelenia lekárov na tých, ktorí používali pri diagnostike CRP a tí, ktorí CRP nepoužívali vôbec. Šlo o všeobecných lekárov, ktorí liečili pacientov na sinusitídu, teda zápal prínosových dutín. Lekári, ktorí CRP používali, v 59% prípadov predpísali pacientov antibiotiká. V druhom prípade, lekári, kt. CRP nepoužívali predpísali antibiotiká pacientom v 78% prípadov. Pri

všetkých (365) lekároch sme poznali nasledujúce údaje: vek, pohlavie, počet rokov práce v praxi, typ praxe (skupinová, alebo samostatná), počet pacientov, prístup ku CRP a tiež sebahodnotenie pracovného zaťaženia v praxi.

Podľa výsledkov logistickej regresie v tejto štúdii sa ukázalo, že výkon CRP signifikantne znižuje šance na preskripciu ATB o 57% (OR= 0,43 CI=0,33 – 0,58). Tiež lekári, ktorí mali samostatnú prax majú vyššie šance na preskripciu ATB oproti lekárom so skupinovú praxou (OR= 1,41 CI=1,12 – 1,77).

Samotná hodnota CRP mala silný vplyv na mieru predpisovania antibiotík. Približne polovica pacientov so sinusitídou mala hladinu CRP  $< 10\text{mg/l}$  a z nich menej ako tretina dostala ATB. Na druhej strane, viac ako 80% pacientov s CRP  $> 25\text{mg/l}$  dostali ATB (Obr. 1).



**Obr. 1:** Počet pacientov s ATB a bez ATB podľa nameraných hladín CRP, zdroj: [1]

V tejto štúdii bol uvedený medián veku praktických lekárov približne 50 rokov. Pri našich analyzovaných dátach bol medián veku lekárov 61 rokov. Tiež pozorujeme veľký rozdiel v zastúpení žien ako praktických lekároch. Pokiaľ je to v dánskej štúdii približne 37%, na Slovensku je trend skôr opačný. Celkový podiel žien pri praktických lekároch je 71% (PLDD 87% a PLD 62%).

| CRP                     | ATB                    |
|-------------------------|------------------------|
| $CRP \leq 20mg/l$       | bez predpisu ATB       |
| $20mg/l < CRP < 99mg/l$ | odložený recept na ATB |
| $CRP \geq 100mg/l$      | okamžitý predpis ATB   |

**Tabuľka 1:** Rozhodovanie sa pri rôznych hladinách CRP

V holandskej štúdii [2] šlo o podobný prípad, ako v prvom prípade v štúdii [8]. Išlo o 107 pacientov s ochorením dolných dýchacích ciest a 151 pacientov s rinosinuitídou. Títo pacienti boli vyšetrení u 32 praktických lekárov. Jedna skupina pacientov bola liečená použitím CRP a druhá skupina bola kontrolná, čiže diagnostikovaná bez CRP vyšetrenia. Lekár mal na výber, či pacientovi podá ATB okamžite, alebo mu dá odložený recept, vďaka ktorému si pacient môže vybrať ATB ak sa mu zhorší stav. Všetci pacienti mali 18 a viac rokov a išlo o polročné sledovanie.

Primárnym výsledkom bolo užitie ATB po odbornej konzultácii s lekárom. Sekundárnym výstupom bolo sledovanie spokojnosti pacienta a tiež klinické zotavovanie pacientov.

Pacienti, ktorým bolo merané CRP, v 43% prípadov mali predpísané ATB po konzultácii s lekárom. Pri pacientoch bez CRP vyšetrenia šlo o 56% prípadov. V CRP skupine bol vydaný recept s odkladom pri 23% prípadov z celkového množstva predpísaných antibiotík. Pri kontrolnej skupine šlo o 72% prípadov. Oba rozdiely sa ukázali ako štatisticky významné. Spokojnosť pacientov bola významne vyššia u pacientov z CRP skupiny.

Pri jednotlivých pacientoch sa skúmali príznaky ako vek, pohlavie, vzdelanie, komorbidita (astma, diabetes, a iné), či ide o fajčiara, ale tiež aj klinické údaje ako dýchavičnosť, horúčka, potenie, bolesť hlavy, svalov a iné. Podľa týchto príznakov lekári vedeli pacientov zaradiť, či ide o ochorenie dolných dýchacích ciest prípadne rinosinuitídu.

Aj v tejto štúdii bola dôležitá nameraná hladina CRP. Ako sa lekári rozhodovali je znázornené v tabuľke 1.

Na slovenských dátach by sme nevedeli do takejto hĺbky sledovať rozhodovanie lekára. Nakoľko máme prístup len ku vykázananej zdravotnej starostlivosti, nedisponujeme klinickými údajmi pacienta ako napríklad informáciami o subjektívnom zhodnotení stavu pacienta, resp. aké mal pacient bolesti. Tiež nevieme detaily o rozhodovaní lekára, teda napríklad presne namerané hodnoty CRP. Vieme sledovať len skutočnosť že lekár vyšet-

| Intervencia                | ATB po 3 mes. | ATB po 12 mes. | P-value, RR               |
|----------------------------|---------------|----------------|---------------------------|
| CRP školenie               | 35%           | 43%            | $P = 0,052$ , $RR = 0,75$ |
| Komunikácia                | 41%           | 40%            | $P = 0,02$ , $RR = 0,7$   |
| CRP školenie + komunikácia | 32%           | 45%            | $P = 0,01$ , $RR = 0,75$  |
| kontrolná skupina          | 58%           | 51%            | ref                       |

**Tabuľka 2:** Preskripcia ATB po 3 mesiacoch, po roku a signifikantnosť zmeny po roku v porovnaní s kontrolnou skupinou

ril CRP a vykázal to poisťovní. Samozrejme je tu ešte iná možnosť výkonu CRP, a to ak lekár vykoná CRP ale poisťovní to nevykáže. Takýto scenár tiež nevieme podchytiť. Poznamenajme tiež, že v štúdií Calsa et. al išlo o pomerne malú vzorku pacientov a tiež lekárov.

Štúdia [7] riešila efekt CRP na zníženie preskripcie antibiotík z dlhodobého hľadiska. Podľa Littla et. al je C-reaktívny proteín užitočný najmä pri identifikovaní ochorenia dolných dýchacích ciest. Existujú mnohé štúdie, ktoré potvrdili vplyv CRP na zníženie preskripcie ATB z krátkodobého hľadiska (niektoré sme uviedli vyššie). Štúdia však sleduje vplyv po 12 mesiacoch od intervencie na dospelých pacientoch s ochorením horných a tiež dolných dýchacích ciest.

Hlavnou výskumnou otázkou bolo sledovanie preskripcie ATB po troch mesiacoch, po jednom roku od intervencie a vzájomné porovnanie. V štúdií bolo zapojených 246 praktických lekárov zo 6 rôznych krajín. Sledovali sa štyri druhy skupín lekárov. Lekári s CRP školením, lekári s dôrazom na zvýšenie komunikáciu s pacientom (letáky, vysvetlenie priebehu a liečby choroby, antibiotiká v daných prípadoch nie sú nápomocné a iné), kombinácia CRP školenia a komunikácie a základná kontrolná skupina lekárov bez žiadnej intervencie. V tabuľke 2 je znázornené, koľkým pacientom boli predpísané antibiotiká do troch a následne do dvanástich mesiacov.

Posledný stĺpec v tabuľke 2 hovorí o signifikantnosti relatívneho rizika ku kontrolnej skupine po roku. V porovnaní s kontrolnou skupinou bez intervencie, signifikantne najnižšie riziko na preskripciu ATB majú lekári zo skupiny s dôrazom na zvýšenie komunikáciu. Nižšie riziko má aj skupina lekárov s CRP školením a komunikáciou, ale nie tak výraznú,

ako lekári zo skupiny len s dôrazom na zvýšenie komunikáciu. V tejto „komunikačnej“ skupine ide o lekárov, ktorí aktívne konzultovali s pacientami metódy liečby danej choroby bez antibiotík, vysvetľovali im zbytočnosť predpisania antibiotík pri daných ochoreniach pomocou rôznych brožúr, letákov, prezentácií a pod.

Zo štúdie vyplýva, že z dlhodobého hľadiska má na zníženie preskripcie ATB efekt skôr aktívna komunikácia lekára s pacientmi ako vykonávanie CRP.

## 1.2 Intervencia v programe DôveraPomáha

Uvedené štúdie preukázali, že minimálne z krátkodobého hľadiska má význam vykonávať CRP, ktoré signifikantne znižuje preskripciu ATB pri ochoreniach horných a dolných dýchacích ciest.

V programe DôveraPomáha bola zavedená intervencia na povedomie o tom, že preskripcia antibiotík na ochorenie horných dýchacích ciest je častokrát bezvýznamná, a tak sa len zvyšuje rezistencia baktérií voči antibiotikám.

Hlavná doba intervencie bola v rokoch 2017 – 2018, kedy boli pre lekárov z programu DôveraPomáha organizované schôdzky 9–krát do roka pre edukáciu lekárov v tejto oblasti. Všetkým lekárom bola posielaná spätná väzba, kde bolo zhrnuté, ako sú na tom v predpisovaní ATB v porovnaní s referenčnou skupinou lekárov, ktorí nepodliehali žiadnej intervencii v tejto oblasti, ale aj detailné porovnanie predpisovania ATB medzi lekármi v programe. Spätná väzba bola odosielaná kvartálne. Lekári dostali taktiež klinické protokoly o tom, kedy a ako predpisovať antibiotiká.

Jednou z častí intervencie bolo aj postupné zazmluvňovanie CRP výkonu pre PLD.

Súčasťou intervencie boli rôzne plagáty a brožúry o tom, čo sú antibiotiká, prečo by sa nemali užívať vo väčšine prípadov pri ochoreniach na horné dýchacie cesty, aké sú vedľajšie účinky nesprávneho užívania antibiotík atď.

V tejto práci sme vyhodnotili túto intervenciu použitím viacerých matematických metód. Vyhodnotili sme posledný rok pred intervenciou (2016) a pozreli sme sa až do aktuálneho obdobia, presnejšie po máj roku 2022.

### 1.3 Diagnózy horných dýchacích ciest

V tejto časti si v skratke priblížime niektoré hlavné ochorenia HDC. Uvedieme základné charakteristiky a symptómy pri daných ochoreniach. Čo nás bude primárne zaujímať je, pri koľkých % ide o ochorenie bakteriálneho pôvodu. Budeme vychádzať primárne z [9], [4].

#### Akútna nádcha

Len v zopár prípadoch ide o ochorenie bakteriálneho pôvodu. Líši sa to tiež podľa toho, či ide o dospelých pacientov, alebo deti:

- 0,5 – 2% bakteriálneho pôvodu u dospelých
- 5 – 13% bakteriálneho pôvodu u detí

O bakteriálny pôvod ide prevažne ak symptómy pretrvávajú aspoň 10 dní, alebo sa zhoršujú po 5 dňoch.

Pri liečbe nádchy sa odporúčajú kortikosteroidy, ktoré majú zmiernené vedľajšie účinky.

Antibiotiká sa odporúčajú len v ťažkých prípadoch a ak je to možné, tak s odloženým receptom.

#### Akútna infekcia hltana a mandlí

Približne v 70% ochorenie vírusového pôvodu, ak ide o bakteriálny pôvod, pri pacientoch pozorujeme závažnú bolesť pri prehĺtaní, teplota  $\geq 38,5^{\circ}\text{C}$ , zväčšené lymfatické uzliny a iné závažnejšie symptómy popísané v článku [9]. Antibiotiká je vhodné podať, ak má pacient riziko reumatickej horúčky.

Platí tiež to, čo pri ARS. Teda ak symptómy neustupujú ani po 10 dňoch, alebo sa zhoršujú po 5 dňoch, môže ísť o bakteriálny pôvod ochorenia. Vtedy je dobré zvážiť liečbu použitím antibiotík, alebo aspoň odložený recept, ktorý si pacient vyberie pri zhoršenom stave.

#### Chrípka

Chrípku ako aj iné už uvedené choroby horných dýchacích ciest spôsobujú prevažne vírusy. Avšak približne v 10 – 20% prípadov môže dôjsť ku vzniku sekundárnych infekcií

bakteriálneho pôvodu najmä v dýchacích cestách. Tento odhad nie je jednoznačný a môže sa líšiť od veku pacienta, fyzickej kondície, základného zdravotného stavu a iných faktorov pri sledovanom pacientovi.

Pri chrípke sa vo väčšej miere odporúča odpočinok, zvýšený príjem tekutín pre uvoľnenie hlienov na pľúcach, prípadne antivirotiká.

Antibiotiká lekár môže zvážiť pri zhoršení, alebo pretrvávajúcich nasledujúcich symptómov:

- Pretrvávajúca horúčka
- Ťažkosti s dýchaním, dýchavičnosť
- Bolesť na hrudníku
- Zvýšený tep srdca
- Silný, alebo pretrvávajúci kašeľ s hustým, zafarbeným hlienom

V tabuľke 3 uvádzame zhrnutie, v koľkých prípadoch pri vybraných diagnózach ide o ochorenie bakteriálneho pôvodu podľa uvedených štúdií vyššie a v koľkých prípadoch podľa dát Dôvera z.p. boli pri týchto ochoreniach vydané antibiotiká. Dáta boli analyzované na základe vykázananej zdravotnej starostlivosti PZS od roku 2016 po rok 2022 pre všetky vekové kategórie spolu. Diagnózy sú klasifikované podľa Medzinárodnej klasifikácie chorôb 10. revízie (MKCH 10). Medzi zahrnuté diagnózy patrili J00 - J01.9, J11.0 - J11.9, J03.0 - J03.9 (nádcha, zápal prínosových dutín, chrípka, zápal mandlí). Ich bližšia charakteristika v tabuľke 18

| Kód diagnózy | Názov diagnózy                                | % kontaktov s ATB podľa dát Dôvery | % kontaktov s bakteriálnym pôvodom podľa štúdií |
|--------------|-----------------------------------------------|------------------------------------|-------------------------------------------------|
| J00          | Akútny zápal nosohltana (nádcha)              | 5,3 %                              | 0,5 - 2 %                                       |
| J01          | Akútny zápal prínosových dutín                | 40,3 %                             | 0,5 - 2 % (dospelí),<br>5 - 13 % (deti)         |
| J03          | Akútny zápal mandlí                           | 51,6 %                             | 30 %                                            |
| J11          | Chríпка zapríčinená neidentifikovaným vírusom | 5,4 %                              | 10%                                             |

**Tabuľka 3:** Percentuálny podiel kontaktov s diagnózou na horné dýchacie cesty

## 2 Matematická analýza

### 2.1 Analyzované dáta

V tejto analýze sme pracovali s databázou vykazanej zdravotnej starostlivosti, ktorá hovorí o kontakte pacienta s ochorením horných dýchacích ciest (J00 - J01.9, J11.0 - J11.9, J03.0 - J03.9), zjednodušene ide o nádchu, zápal mandlí a chrípku v regiónoch, kde funguje DôveraPomáha (DP), čiže v Košickom kraji, Nitrianskom kraji a Prešovskom kraji. Diagnózy sú definované podľa medzinárodnej klasifikácie chorôb 10. revízie. Názvy diagnóz sú uvedené v tabuľke 18.

Databáza bola postavená nad kapitujúcimi lekármi z regiónu programu DôveraPomáha. Kapitujúci lekári sú takí, ktorí za pacienta dostávajú paušálne (kapitačné) platby od poisťovne. Poisťovňa uhradza kapitačnú platbu za poistenca maximálne jednému kapitujúcemu lekárovi.

Z databázy boli vylúčení pacienti, u ktorých je preskripcia ATB opodstatnená z dôvodu chronického ochorenia, ktorých identifikujeme podľa zaradenia pacienta do PCG skupiny (Pharmacy-based cost group, nástroj oceňovania rizika podľa nákladových skupín založených na predpísaných liekoch) - pacienti s ochorením mozgu a miechy, pacienti s cistickou fibrózou, pacienti liečení inhibítormi TNF, pacienti po transplantáciách, onko-

logický pacienti, HIV pozit. pacienti.

V databáze sa nachádzajú kontakty od roku 2013 po máj roku 2022. Kontakt predstavuje návštevu pacienta u lekára s ochorením na horné dýchacie cesty, ktorú si lekár vykáže ako vykázanú zdravotnú starostlivosť. Pri jednom kontakte disponujeme informáciou o jeho začiatku a tiež jeho konci. To znamená, že nemusí ísť nutne o jednorazovú návštevu u lekára. Pre jeden kontakt uvažujeme maximálne 3 dni. Ak pacient príde s ochorením HDC po troch dňoch od začiatku kontaktu, tento kontakt uvažujeme ako nový. Pri každom zázname, ktorý predstavuje kontakt pacienta s ochorením horných dýchacích ciest sledujeme vlastnosti, ktoré prislúchajú pacientom a tiež kapitujúcim lekárom. Konkrétne atribúty alebo premenné, ktoré sme v analýze používali popisujeme v časti 2.3.1.

## 2.2 Exploračná analýza dát

V hlavnej časti analýzy sme počítali s obdobím od roku 2016 po máj roku 2022, keďže prvá intervencia týkajúca sa nášho výskumu prišla v prvom kvartáli roku 2017.

V našej analýze sme analyzovali 772 jedinečných lekárov za celé obdobie s tým, že ak jeden lekár mal ordináciu vo viacerých krajoch, alebo na jednej bol odbornosťou PLD a na inej PLDD, analyzovali sme ho násobne.


Celkový počet kontaktov (návštev pacientov) s ochorením HDC bol 916 073. Môže sa javiť, že časť množiny môže byť závislá, keďže sa opakujú lekári s rovnakými pacientmi. Pracujeme však s predpokladom, že jednotlivé infekcie horných dýchacích ciest sú dostatočne jedinečné javy s jedinečnými príznakmi, ku ktorým by sa malo pristupovať individuálne a samotná osoba lekára by nemala mať žiaden vplyv na preskripciu a pacient by mal dostať rovnakú starostlivosť podľa najaktuálnejších usmernení v každej ambulancii. Možnú variabilitu medzi lekármi (napr. kraj, veková kat. a podobne) sa neskôr snažíme zachytiť v logistickom modeli.

Počet kontaktov v ukončených celých rokoch kolísal medzi 104 633 pacientami v roku 2021 a 161 965 v roku 2018. Takýto diametrálny rozdiel môže byť kvôli vplyvom pandémie COVID-19. Obdobie jej trvania (od marca 2020) budeme ďalej v práci označovať ako kovidové obdobie.

Pre účely analýzy sme brali do úvahy len kontakty, kedy lekár pacientovi už mohol vyšetriť CRP. To znamená, dátum kontaktu bol väčší nanajvýš rovný ako dátum prvého

vyšetrenia CRP pre kapitujúceho lekára. V 25 prípadoch kontaktov lekár vykonal CRP, aj keď dátum prvého CRP bol neskôr, ako dátum konca kontaktu s pacientom. Preto sme zahrnuli aj takéto prípady. Celkový analyzovaný počet takýchto kontaktov u lekára s ochorením HDC v našej analýze pre sledované obdobie bol 881 707.

Pre ďalšie potreby sme lekárov kategorizovali do skupín podľa toho, aký vzťah mali s programom DôveraPomáha (DP). Vytvorili sme tak štyri skupiny lekárov. Referenčná skupina (tí lekári, ktorí nemali s programom DP žiaden vzťah počas hlavnej intervencie medzi 1.1.2017 a 1.1.2019), vždy boli v DP, odišli skôr z DP, alebo prišli neskôr do DP. Nasledujúci obrázok 2 vysvetľuje tieto stavy v DP graficky a tiež tabuľkovo.



**Obr. 2:** Grafické znázornenie stavov účasti lekára v DP, zdroj: vlastné spracovanie

Lekárov, ktorí ordinovali na viacerých ambulanciách pod rôznymi stavmi v DP bolo potrebné zjednotiť. Pri lekároch, ktorí na jednej ambulancii ordinovali ako referenční a na inej boli zapojení do DP, takáto referenčná ordinácia z celej analýzy bola vyradená, pretože nie je možné objektívne posúdiť, či sa na takejto ambulancii lekár naozaj správal ako referencia. Ak nastal prípad, že na jednej ambulancii lekár bol zaradený do DP len čiastočne (prišiel neskôr, odišiel skôr) a na inej bol vždy v DP, na všetkých ambulanciách bol kategorizovaný ako vždy v DP. Ak nastala situácia, že lekár menil ordinácie tak, že na jednej bol kategorizovaný ako odišiel skôr a na inej hneď na to prišiel neskôr, lekár bol finálne zaradený do kategórie vždy v DP.

V tabuľke 4 uvádzame počty jedinečných lekárov podľa odbornosti v jednotlivých

| Kategória                              | Podkategória    | PLD       | PLDD      | PLD+PLDD  |
|----------------------------------------|-----------------|-----------|-----------|-----------|
| Stav v DôveraPomáha                    | Referencia      | 267       | 177       | 444       |
|                                        | Vždy v DP       | 87        | 35        | 122       |
|                                        | Prišiel neskôr  | 3         |           | 3         |
|                                        | Odišiel skôr    | 20        | 4         | 24        |
| Kraj ambulancie kapitujúceho lekára    | Košický kraj    | 202       | 110       | 312       |
|                                        | Nitriansky kraj | 141       | 71        | 212       |
|                                        | Prešovský kraj  | 34        | 35        | 69        |
| Veková kategória lekára                | do 40 rokov     | 29        | 4         | 33        |
|                                        | 41-50 rokov     | 86        | 38        | 124       |
|                                        | 51-60 rokov     | 106       | 70        | 176       |
|                                        | 61-70 rokov     | 125       | 88        | 213       |
|                                        | 71+ rokov       | 31        | 16        | 47        |
| Kapitačný kmeň lekára ku decembru 2016 |                 | 624 ± 329 | 486 ± 225 | 573 ± 303 |
| Priemerný vek lekára                   |                 | 56 ± 11   | 58 ± 8    | 57 ± 10   |

**Tabuľka 4:** Počty jedinečných lekárov, kapitačný kmeň a priemerný vek lekára ku decembru roka 2016 (stav pred intervenciou), zdroj: vlastné spracovanie z dát Dôvera z. p.

kategóriách, ako je stav v DP, kraj ambulancie kapitujúceho lekára, alebo veková kategória lekára. Tiež popisujeme priemerný kapitačný kmeň lekára a priemerný vek lekárov so štandardnou odchýlkou v daných odbornostiach. Tieto údaje sú počítané ku dátumu pred prvou intervenciou, teda ku decembru roka 2016.

Pozorujeme, že čo sa týka kategórie stavu v DP, najpočetnejšie sú kategórie referencia a lekári, ktorí boli vždy v programe DôveraPomáha. Čo sa týka kategórie kraja, najmenej lekárov prislúcha Prešovskému kraju a naopak najviac lekárov je v Košickom kraji. Podľa vekovej kategórie je najviac lekárov v kategórii 61 – 70 rokov, čo sú v podstate už lekári v dôchodkovom veku.

### 2.2.1 Vývoj pravdepodobnosti na predpis ATB pri kontakte

Pravdepodobnosť na predpis ATB pri kontakte v čase budeme počítat ako podiel kontaktov s predpisom na ATB ku všetkým kontaktom s ochorením HDC. Uvedieme dva pohľady

- Rozdelenie lekárov podľa stavu v DP - najpočetnejšie stavy (referencia, vždy v DP)
- Rozdelenie lekárov podľa krajov - porovnáme tri kraje DP

Uvedieme ešte deskriptívne tabuľky, ktoré udú vyjadrovať počty lekárov kategorizovaných podľa sledovaných kategórií. Teda podľa kraju a podľa stavu v DP. Hodnoty sú vyjadrené ku roku 2016.

|                 | Referencia | Vždy v DP |
|-----------------|------------|-----------|
| Košický kraj    | 143        | 48        |
| Nitriansky kraj | 107        | 39        |
| Prešovský kraj  | 34         | 9         |

**Tabuľka 5:** Počet lekárov podľa kraju a stavu v DP v roku 2016 pre PLD lekárov


|                 | Referencia | Vždy v DP |
|-----------------|------------|-----------|
| Košický kraj    | 93         | 14        |
| Nitriansky kraj | 56         | 14        |
| Prešovský kraj  | 31         | 7         |

**Tabuľka 6:** Počet lekárov podľa kraju a stavu v DP v roku 2016 pre PLDD lekárov


Tabuľka 5 a tabuľka 6 ilustrujú počty jedinečných lekárov vo vzťahu medzi stavom v DP a krajmi. Vo všetkých krajoch prevládala referenčná skupina lekárov nad lekármi, ktorí boli celý čas v DP.

Kvartálne sme porovnávali sledované obdobie, t.j. od roku 2016 s príslušným kvartálom v roku 2016. Keďže prvá intervencia bola v prvom kvartáli roku 2017, takto sme zistili, ako sa vývoj v porovnaní s pred intervenčným obdobím menil.


Pravdepodobnosť na preskripciu antibiotík v roku 2016 sa pohybovala priemerne v 30% na kontakt pri PLDD lekároch a v 45% pri PLD lekároch.




**Obr. 3:** Percentuálna zmena pravdepodobnosti preskripcie antibiotík na 1 kontakt v porovnaní s rokom 2016 pre PLD podľa stavu v DP, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 4:** Percentuálna zmena pravdepodobnosti preskripcie antibiotík na 1 kontakt v porovnaní s rokom 2016 pre PLDD podľa stavu v DP, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 5:** Percentuálna zmena pravdepodobnosti preskripcie antibiotík na 1 kontakt v porovnaní s rokom 2016 pre PLD podľa krajov, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 6:** Percentuálna zmena pravdepodobnosti preskripcie antibiotík na 1 kontakt v porovnaní s rokom 2016 pre PLDD podľa krajov, zdroj: vlastné spracovanie z dát Dôvera z. p.


Podľa grafov na obrázkoch 3, 4, pri referenčnej skupine lekárov neklesá pravdepodobnosť na predpis ATB v porovnaní s rokom 2016 tak výrazne, ako pri lekároch z DP. V porovnaní s rokom 2016 pravdepodobnosť na ATB v roku 2020 klesá predovšetkým pri PLDD lekároch z programu DP (až 45%). Aj pri PLD lekároch pozorujeme pokles pravdepodobnosti preskripcie ATB v porovnaní s rokom 2016. Najväčší pokles sledujeme v roku 2018 a to až 33%. Pravdepodobnosť narastá v porovnaní s rokom 2016 o 12% na prelome rokov 2021 a 2022 u lekárov z DP. Rozdiely medzi lekármi z referenčnej skupiny a z programu DP sú jednoznačné hlavne počas rokov intervencie. Neskôr sa jednoznačnosť pri PLD lekároch stráca.

Podľa obrázkov 5, 6 pravdepodobnosť na predpis ATB v krajoch DP sa po intervencii, ktorá začala v prvom kvartáli roku 2017 v porovnaní s rokom 2016 mierne znižovala hlavne v Prešovskom a Nitrianskom kraji. Pokles predpisu ATB v porovnaní s rokom 2016 sledujeme počas celého obdobia u PLDD lekárov hlavne v Nitrianskom kraji, kedy preskripcia ATB v roku 2020 klesla o 49%. Pri PLD na prelome roka 2021 a následne v roku 2022 dochádza ku nárastu pravdepodobnosti preskripcie ATB oproti roku 2016 v Prešovskom kraji (o 20%) a Košickom kraji (o 15%).


### **2.2.2 Vývoj pravdepodobnosti na výkon CRP pri kontakte**

V tomto prípade pravdepodobnosť počítame ako podiel počtu kontaktov, ktorým bolo vykonané CRP, ku celkovému počtu kontaktov. Tento podiel vyjadruje počet CRP na jeden kontakt s ochorením HDC, alebo aj pravdepodobnosť, že pri ochorení HDC pacientovi bude vyšetrené CRP.


Taktiež porovnávame s rokom pred intervenciou, teda s rokom 2016. V tomto roku priemerná pravdepodobnosť na vykonanie CRP predstavovala 8% pri PLDD lekároch a 3,5% pri PLD lekároch.




**Obr. 7:** Percentuálna zmena pravdepodobnosti výkonu CRP na 1 kontakt v porovnaní s rokom 2016 pre PLD podľa stavu v DP, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 8:** Percentuálna zmena pravdepodobnosti výkonu CRP na 1 kontakt v porovnaní s rokom 2016 pre PLDD podľa stavu v DP, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 9:** Percentuálna zmena pravdepodobnosti výkonu CRP na 1 kontakt v porovnaní s rokom 2016 pre PLD podľa kraja, zdroj: vlastné spracovanie z dát Dôvera z. p.



**Obr. 10:** Percentuálna zmena pravdepodobnosti výkonu CRP na 1 kontakt v porovnaní s rokom 2016 pre PLDD podľa kraja, zdroj: vlastné spracovanie z dát Dôvera z. p.

Grafy na obrázkoch 7, 8 predstavujú vývoj pravdepodobnosti výkonu CRP podľa stavov v DP. Na týchto grafoch je vidieť, že počas intervencie hlavne lekári, ktorí boli celý čas zapojení do programu DP začali viac využívať vyšetrenie CRP v porovnaní s rokom 2016, ktoré im mohlo pomôcť pri rozhodovaní na racionálne predpisovanie ATB pri ochorení HDC. Najvýraznejší nárast v porovnaní s rokom 2016 pozorujeme u PLD, keď v roku 2019 v druhom kvartáli došlo k 11%-násobnému nárastu. Pozorujeme mierny úpadok počas konca roka 2020, čo z veľkej časti môžeme pripísať kovidovému obdobiu. Počas tohto obdobia bolo pre lekárov náročné vyšetrovať CRP, keďže značná časť pacientov do ambulancii nechodila. Lekári v tomto období využívali často telemedicínu na vyšetrovanie pacientov (vyšetrenie prostredníctvom telefonického kontaktu). Stále však pozorujeme vyšší nárast používania CRP u lekárov z programu DôveraPomáha, ako u lekárov z referenčnej skupiny.

Pri PLDD v roku 2020 dochádza k poklesu vyšetrovaných CRP. Koncom tohto roka klesla pravdepodobnosť výkonu CRP na jeden kontakt až o 20% v porovnaní s rokom 2016.

Na obrázkoch 9, 10 sledujeme vývoj pravdepodobnosti z pohľadu krajov a odbornosti lekárov. Pri PLD v Prešovskom kraji sledujeme najvyššiu zmenu pravdepodobnosti na výkon CRP v porovnaní s ostatnými kraji. V poslednom kvartáli v roku 2019 šlo o nárast o viac ako 900% v porovnaní s rokom 2016.

Pri PLDD výrazne vzrástlo vykazovanie CRP v Nitrianskom a tiež v Prešovskom kraji oproti roku 2016. V Košickom kraji sa postupne vykazovalo menej CRP v porovnaní s rokom 2016. Pravdepodobnosť v tomto kraji na konci roka 2021 bola nižšia o 40% v porovnaní s rokom 2016.

## 2.3 Model logistickej regresie

Logistickú regresiu používame, ak premenná, ktorú chceme modelovať má binárny charakter. Inak môžeme povedať, že nadobúda len hodnoty 1/0 resp. Áno/Nie. Vysvetľovanú premennú označíme ako  $y$ , ktoré má binomické rozdelenie. Nasledujúce vyjadrenie označuje, že naša premenná  $y$  nadobúda hodnotu 1 s pravdepodobnosťou  $p_y$  a tiež aká je jej

stredná hodnota [6].

$$y \sim \text{Bin}(1, p_y)$$

$$E(y) = 1 \cdot p_y = p_y$$

Ak by sme použili lineárny model, dostali by sme predpis:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \rightarrow E(\dots)$$

$$p_y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

Pokiaľ na ľavej strane rovnice modelujeme pravdepodobnosť  $p_y \in (0, 1)$ , na pravej strane ( $PS$ ) nemáme obmedzenie na premenné a teda  $(PS) \in (-\infty, \infty)$ . Preto použijeme GLM (Generalized linear model), kde transformujeme  $E(y)$  *logit* funkciou a dostaneme predpis pre **Logistickú regresiu** [6]:

$$\text{logit}(p_y) = \ln \frac{p_y}{1 - p_y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1)$$

$$p_y = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}}. \quad (2)$$

Takto obe strany patria do intervalu  $(-\infty, \infty)$ . Tento vzťah ale vieme zapísať aj v podobe šancí:

$$ODDS = \frac{p_y}{1 - p_y} = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n) \quad (3)$$

$$OD\tilde{D}S = \frac{\tilde{p}_y}{1 - p_y} = \exp(\beta_0 + \beta_1(x_1 + 1) + \beta_2 x_2 + \dots + \beta_n x_n). \quad (4)$$

Uvažujme príklad, kde  $p_y$  predstavuje pravdepodobnosť úmrtia pacienta na chorobu. Predpokladajme, že vysvetľujúca premenná  $x_1$  predstavuje, či je pacient fajčiar. Teda  $ODDS$  predstavujú šance, že pacient zomrie na danú chorobu, ak nefajčí.  $OD\tilde{D}S$  predstavujú šance pre pacienta ktorý fajčí. Podelme tieto dva výrazy:

$$or = \frac{OD\tilde{D}S}{ODDS} = e^{\beta_1}$$

Takto dostaneme zmenu šancí (odds ratio). Odds ratio hovorí o tom, ako sa zmenia šance, že pacient zomrie na nejakú chorobu ak začne fajčiť. Samozrejme, skutočné hodnoty  $\beta$  nikdy nepoznáme, avšak logistickým modelom, hľadaním argumentu maxima pri maximalizovaní funkcie vierohodnosti (Likelihood function), ich vieme odhadnúť. Tak dostaneme aj odhadnutú zmenu šancí, čo už vieme ďalej testovať [6].

$$\hat{or} = \frac{\hat{OD\tilde{D}S}}{\hat{ODDS}} = e^{\hat{\beta}_1}$$

Pri kategorických dátach,  $\hat{or}$  hovorí o zmene šancí pri prechode z jednej kategórie do druhej. Ak kategorické dáta nemáme,  $\hat{or}$  hovorí v našom príklade o zmene šancí pri náraste počtu cigariet. Ako sa zmenia šance pre úmrtie pacienta, ak bude o fajčiť o 1 cigaretu viac.

Ešte uvedieme vzťah medzi šancami a pravdepodobnosťou:

$$ODDS = \frac{\hat{p}_x}{1 - \hat{p}_x} \quad (5)$$

$$\hat{p}_x = \frac{ODDS}{1 + ODDS} \quad (6)$$

### 2.3.1 Premenné v logistickom modeli

V tejto časti predstavíme všetky premenné, ktoré sme použili vo finálnom logistickom modeli v časti 2.3.2. Uvedieme, ako sme postupovali pri výbere referenčných kategórií. Uvedieme premenné z pohľadu pacientov a tiež lekárov.

#### Pacient

- CRP 3 dni okolo návštevy - či bolo pacientovi v čase kontaktu alebo v jeho okolí spravené vyšetrenie CRP
- Vydaný recept na ATB - či bol pacientovi vydaný recept na ATB, ktorý si následne v lekárni vybral
- Veková kategória pacienta - keďže sme disponovali len údajmi o veku pacienta ku júlu 2022, vek sme aktualizovali pre každého pacienta v čase kontaktu na základe dátumu narodenia a dátumu kontaktu. Vekové kategórie sme volili podľa toho, ako sa u lekárov mení kapitačná platba podľa veku pacienta. Ak sa kapitačná platba už nemení, volili sme 10 ročné vekové kategórie. Referenčnú kategóriu sme zvolili najpočetnejšiu skupinu pacientov (1 – 5 rokov)
- Pohlavie pacienta
- Diagnóza pri kontakte - diagnózy sme v modeli zgrupili (J00 - nádcha, J01 - zápal prínosových dutín, J03 - zápal mandlí, J11 - chrípka), referenčnú kategóriu sme vybrali diagnózu, ktorá by inak mala vysoký pomer šancí na preskripciu ATB a iné zmeny by boli nečítateľné (J03).

- Kontakt na LSPP - Lekárska starostlivosť prvej pomoci (pohotovosť). Analyzovali sme aj prípady, ktoré s ochorením HDC boli vyšetrené na pohotovosti. Aj pri takýchto prípadoch sme neuvádzali ošetrojúceho lekára, ale kapitujúceho, pretože kapitujúci lekár má vplyv na to, či pacientovi budú predpísané ATB
- Predošlý recept - či mal pacient pri predchádzajúcom kontakte predpísané ATB. Chceme totižto zistiť, či sa lekár pri aktuálnom kontakte rozhoduje aj na základe toho, či mu bol predpísaný recept na ATB pri poslednom kontakte. Problém je ale v tom, že posledný kontakt mohol byť pred mesiacom, pred rokom, dvomi a podobne. Preto sme vytvorili ešte jeden atribút, ktorý sa pozeral na posledný kontakt pacienta za posledný rok. Tento atribút bol však prirodzene závislý s prvým a zhoršoval informačné kritérium modelu. Preto sme sa rozhodli zostať pri zjednodušenej verzii tohto atribútu a pozrieť sa, či mal pacient jednoducho pri poslednom kontakte u lekára predpísané antibiotiká, nezávisiac na tom, kedy posledný kontakt bol.
- Komorbidity - hypertenzia, astma, kardiovaskulárne ochorenia (spojili sme srdcové zlyhávanie, ischemickú chorobu srdca, fibriláciu sieni, infarkt myokardu), diabetes, chronické zlyhávanie obličiek, hypercholesterolemia. Komorbidity boli párované ku príslušnému polroku, kedy bol pacient vyšetrený na ochorenie HDC.
- Kovidové obdobie - kontakty boli rozdelené na tie, ktoré boli ešte pred pandémiou *COVID* – 19, a tie, ktoré boli vyšetrené od pandémie (začiatok 1.3.2020).

## Lekár

- Stav v DP - Podľa dátumov zapojenia lekára v programe DôveraPomáha sme ich rozdelili do skupín referencia, vždy v DP, odišiel skôr z DP, prišiel neskôr do DP (viac v časti 2.2) . Ako referenčnú kategóriu sme zvolili referenčnú skupinu lekárov, pretože primárne chceme zistiť, ako sa správali lekári z programu DP v porovnaní s referenčnou skupinou.
- Veková kategória lekárov - Lekárov sme členili po 10 ročných rozdieloch. Lekárov mladších ako 40 rokov sme zlúčili, keďže táto kategória bola málo početná. Ako referenčnú kategóriu sme zvolili najpočetnejšiu skupinu 61 – 70 ročných.

- Kraj ambulancie kapitujúceho lekára - kraj, v ktorom sa nachádza ambulancia lekára. Opäť sme zvolili ako referenčnú kategóriu kraj, kde bolo najviac kontaktov s ochorením HDC (Košický kraj)
- Odbornosť - PLD, resp. PLDD

### 2.3.2 Logistická regresia a predpis antibiotík

V 1.1 sme v dánskej štúdii videli, že vyšetovanie CRP z krátkodobého hľadiska znížilo preskripciu ATB pri sinusitíde (J01) medzi pozorovanými lekármi. Šance boli dokonca nižšie o viac ako 50% [1]. Naopak, iná štúdia, ktorá sledovala dlhodobější vplyv CRP na preskripciu antibiotík (1 rok) došla k záveru, že vyšetovanie CRP nie je spoľahlivým indikátorom nízkeho predpisu ATB z dlhodobého hľadiska [7].

Keďže hlavná intervencia v Dôvere trvala 2 roky, pozrieme sa na vplyv tejto intervencie z dlhodobého hľadiska.

V tejto časti práce sa pozrieme, aký vplyv na predpisovanie ATB malo vykonanie CRP. Našou vysvetľovanou premennou bude  $p_y$ , ktorá hovorí o pravdepodobnosti predpisu ATB, ktoré si pacient v lekárni aj vybral. Okrem toho chceme zistiť vplyvy aj iných atribútov na vysvetľovanú premennú ako napríklad vplyv vekovej kategórie lekára, vekovej kategórie pacienta, odbornosti lekára a ďalšie iné popísané v tabuľkách 7, 9.

Existujú dve úrovne sledovania predpisu ATB. Buď sledujeme či lekár predpísal ATB, alebo prípad, že si pacient aj ATB v lekárni vybral. My sme analyzovali len tú možnosť, kedy si pacient predpísané ATB aj vybral v lekárni.

Náš model bude vyzeráť nasledovne:

$$\ln \frac{p_y}{1 - p_y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{33} x_{33}$$

$$p_y = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{33} x_{33})}}$$

Zvolili sme referenčnú kategóriu, resp. kategórie, s ktorými budeme ostatné atribúty porovnávať:

- Stav v DP **referencia**
- Veková kategória lekára **61-70 rokov**

- Kontakt na Lekársku službu prvej pomoci LSPP (Pohotovosť) **Nie**
- Predošlý recept - či mal pacient pri poslednom kontakte na ochorenie HDC predpísané ATB **Nie**
- Veková kategória poistenca **1-5 rokov**
- Pohlavie poistenca **Muž**
- Kraj ambulancie kapitulujúceho lekára **Košický kraj**
- Diagnóza pri kontakte **J03** (*akútny zápal mandlí*)
- Bez ďalších komorbidít
- Odbornosť lekára **PLD** (*všeobecný lekár pre dospelých*)
- Nekovidové obdobie

Vysvetľovaná premenná:

- $p_y$  - pravdepodobnosť predpisu receptu u lekára ktorý si pacient aj vybral

Vysvetľujúce premenné:

- $X_1$  - výkon CRP  $\pm 3$  dni okolo kontaktu (*Yes*)
- $X_2 - X_4$  - Stav v programe DôveraPomáha (*Prišiel neskôr, Vždy v DôveraPomáha, Odišiel skôr*)
- $X_5 - X_8$  - Veková kategória lekára (*do 40 rokov, 41 – 50 rokov, 51 – 60 rokov, 71+ rokov*)
- $X_9$  - Kontakt na LSPP (*Yes*)
- $X_{10}$  - Predošlý recept (*Yes*)
- $X_{11} - X_{19}$  - Veková kategória poistenca (*do 1 roka, 6 – 14 rokov, 15 – 18 rokov, 19 – 26 rokov, 27 – 40 rokov, 41 – 50 rokov, 51 – 60 rokov, 61 – 70 rokov, 71+ rokov*)
- $X_{20}$  - Pohlavie poistenca (*Žena*)

- $X_{21} - X_{22}$  - Kraj ambulancie kapitujúceho lekára (*Prešovský, Nitriansky*)
- $X_{23} - x_{25}$  - Diagnóza pri kontakte zlúčená do skupín (*J00, J01, J11*)
- $X_{26}$  - Príznak hypertenzia
- $X_{27}$  - Príznak kardiovaskulárne ochorenie
- $X_{28}$  - Príznak chronické zlyhávajúce obličky
- $X_{29}$  - Príznak astma
- $X_{30}$  - Príznak diabetes
- $X_{31}$  - Príznak hypercholesterolemia
- $X_{32}$  - Odbornosť kapitujúceho lekára *PLDD* (*všeobecný lekár pre deti a dospelých*)
- $X_{33}$  - Kovidové obdobie

V tabuľkách 7 a 9 popisujeme analyzované počty kontaktov podľa pozorovaných atribútov v sledovaných rokoch.

| Atribút                   | Možnosti    | 2016, n(%)   | 2017, n(%)    | 2018, n(%)    | 2019, n(%)    | 2020, n(%)   | 2021, n(%)   | 2022*, n(%)  |
|---------------------------|-------------|--------------|---------------|---------------|---------------|--------------|--------------|--------------|
| Recept na ATB             | Áno         | 47 154 (33%) | 44 821 (31%)  | 46 090 (28%)  | 45 842 (28%)  | 27 392 (26%) | 28 285 (27%) | 16 772 (29%) |
| Výkon CRP                 | S CRP       | 9 511 (7%)   | 10 622 (7%)   | 13 911 (9%)   | 16 595 (10%)  | 9 356 (9%)   | 8 001 (8%)   | 4 371 (8%)   |
| Veková kategória pacienta | Do 1 roka   | 9 309 (6%)   | 10 402 (7%)   | 11 203 (7%)   | 11 169 (7%)   | 8 396 (8%)   | 8 733 (8%)   | 3 775 (7%)   |
|                           | 1-5 rokov   | 34 519 (24%) | 35 047 (24%)  | 40 003 (25%)  | 41 366 (26%)  | 27 015 (26%) | 32 620 (31%) | 16 195 (28%) |
|                           | 6-14 rokov  | 42 351 (29%) | 42 587 (29%)  | 46 855 (29%)  | 46 323 (29%)  | 29 430 (26%) | 27 453 (28%) | 16 530 (29%) |
|                           | 15-18 rokov | 17 069 (12%) | 116 244 (11%) | 116 516 (10%) | 116 485 (11%) | 18 620 (8%)  | 18 051 (8%)  | 14 940 (9%)  |
|                           | 19-26 rokov | 12 413 (9%)  | 11 947 (8%)   | 12 286 (8%)   | 12 209 (8%)   | 7 907 (8%)   | 6 708 (6%)   | 3 684 (6%)   |
|                           | 27-40 rokov | 11 867 (8%)  | 12 692 (9%)   | 14 255 (9%)   | 14 147 (9%)   | 9 312 (9%)   | 8 085 (8%)   | 4 890 (8%)   |
|                           | 41-50 rokov | 6 640 (5%)   | 7 262 (5%)    | 8 244 (5%)    | 7 942 (5%)    | 5 761 (5%)   | 5 143 (5%)   | 3 118 (5%)   |
|                           | 51-60 rokov | 5 158 (4%)   | 5 560 (4%)    | 6 842 (4%)    | 6 338 (4%)    | 4 507 (4%)   | 3 774 (4%)   | 2 253 (4%)   |
| Pohlavie pac.             | 61-70 rokov | 3 102 (2%)   | 3 420 (2%)    | 3 944 (2%)    | 4 016 (2%)    | 2 925 (3%)   | 2 647 (3%)   | 1 510 (3%)   |
|                           | 71+ rokov   | 1 300 (1%)   | 1 613 (1%)    | 1 769 (1%)    | 1 769 (1%)    | 1 432 (1%)   | 1 405 (1%)   | 705 (1%)     |
|                           | Muž         | 69 028 (48%) | 70 446 (48%)  | 76 867 (47%)  | 76 816 (47%)  | 49 643 (47%) | 49 147 (47%) | 27 397 (48%) |
| Diagnóza pri kontakte     | J00         | 31 776 (22%) | 35 729 (24%)  | 39 905 (25%)  | 41 664 (26%)  | 31 840 (30%) | 36 976 (35%) | 19 823 (34%) |
|                           | J01         | 30 588 (21%) | 31 176 (21%)  | 33 591 (21%)  | 35 892 (22%)  | 21 946 (21%) | 25 363 (24%) | 15 428 (27%) |
|                           | J03         | 59 215 (41%) | 55 043 (38%)  | 57 159 (35%)  | 55 402 (34%)  | 33 240 (32%) | 30 151 (29%) | 15 898 (28%) |
|                           | J11         | 22 149 (15%) | 24 826 (17%)  | 31 262 (19%)  | 28 806 (18%)  | 18 279 (17%) | 12 129 (12%) | 6 451 (11%)  |
| Kontakt LSPP              | Áno         | 4 252 (3%)   | 4 597 (3%)    | 4 906 (3%)    | 4 481 (3%)    | 2 929 (3%)   | 2 577 (2%)   | 1 275 (2%)   |
| Predošlý recept           | Áno         | 24 463 (17%) | 33 361 (23%)  | 37 235 (23%)  | 38 885 (24%)  | 24 124 (23%) | 23 642 (23%) | 13 623 (24%) |

| Atribút       | Možnosti | 2016, n(%) | 2017, n(%) | 2018, n(%) | 2019, n(%) | 2020, n(%)  | 2021, n(%)   | 2022*, n(%)  |
|---------------|----------|------------|------------|------------|------------|-------------|--------------|--------------|
| HYP           | Áno      | 10 435(7%) | 11 094(8%) | 12 861(8%) | 12 333(8%) | 9 174(9%)   | 8 315(8%)    | 4 710(8%)    |
| KVO           | Áno      | 3 101(2%)  | 3 207(2%)  | 3 551(2%)  | 3 663(2%)  | 2 890(3%)   | 2 750(3%)    | 1 546(3%)    |
| CHZO          | Áno      | 1 391(1%)  | 1 402(1%)  | 1 400(1%)  | 1 341(1%)  | 739(1%)     | 671(1%)      | 427(1%)      |
| AST           | Áno      | 11 239(8%) | 10 406(7%) | 10 757(7%) | 10 564(7%) | 6 531(6%)   | 5 377(5%)    | 3 095(5%)    |
| DIA           | Áno      | 2 313(2%)  | 2 509(2%)  | 2 891(2%)  | 2 752(2%)  | 1 980(2%)   | 1 853(2%)    | 1 051(2%)    |
| CHO           | Áno      | 5 735(4%)  | 5 874(4%)  | 6 052(4%)  | 5 751(4%)  | 4 192(4%)   | 3 767(4%)    | 2 303(4%)    |
| Kovidové obd. | Áno      | (0%)       | (0%)       | (0%)       | (0%)       | 69 184(66%) | 104633(100%) | 57 607(100%) |

**Tabuľka 7:** Počty analyzovaných kontaktov týkajúce sa pacientov vzhľadom na atribúty

| Skratka | Názov chronického ochorenia   |
|---------|-------------------------------|
| HYP     | Hypertenzia                   |
| KVO     | Kardiovaskulárne ochorenie    |
| CHZO    | Chronické zlyhávanie obličiek |
| AST     | Astma                         |
| DIA     | Diabetes                      |
| CHO     | Hypercholesterolemia          |

**Tabuľka 8:** Chronické ochorenia v modeli

| Atribút                               | Možnosti       | 2016, n(%)   | 2017, n(%)   | 2018, n(%)   | 2019, n(%)   | 2020, n(%)  | 2021, n(%)  | 2022*, n(%) |
|---------------------------------------|----------------|--------------|--------------|--------------|--------------|-------------|-------------|-------------|
| Stav v<br>DôveraPomáha                | Referencia     | 106 863(74%) | 104 917(71%) | 109 942(68%) | 109 722(68%) | 72 709(69%) | 74 170(71%) | 40 653(71%) |
|                                       | Vždy v DP      | 33 098(23%)  | 35 405(24%)  | 38 811(24%)  | 37 420(23%)  | 22 068(21%) | 19 685(19%) | 11 201(19%) |
|                                       | Prišiel neskôr | 204(0%)      | 3 717(3%)    | 12 254(8%)   | 14 534(9%)   | 10 497(10%) | 10 728(10%) | 5 731(10%)  |
|                                       | Odišiel skôr   | 3 563(2%)    | 2 735(2%)    | 910(1%)      | 88(0%)       | 31(0%)      | 36(0%)      | 15(0%)      |
| Veková<br>kategória<br>lekára         | do40 rokov     | 3 853(3%)    | 4 100(3%)    | 5 552(3%)    | 5 395(3%)    | 4 243(4%)   | 5 136(5%)   | 3 316(6%)   |
|                                       | 41-50 rokov    | 28 464(20%)  | 32 158(22%)  | 37 118(23%)  | 37 268(23%)  | 23 445(22%) | 21 042(20%) | 10 501(18%) |
|                                       | 51-60 rokov    | 46 879(33%)  | 40 349(27%)  | 42 438(26%)  | 42 022(26%)  | 25 787(24%) | 26 281(25%) | 14 239(25%) |
|                                       | 61-70 rokov    | 56 140(39%)  | 58 594(40%)  | 64 397(40%)  | 64 454(40%)  | 42 600(40%) | 42 327(40%) | 24 121(42%) |
|                                       | 71+ rokov      | 8 392(6%)    | 11 573(8%)   | 12 412(8%)   | 12 625(8%)   | 9 230(9%)   | 9 833(9%)   | 5 423(9%)   |
| Kraj ambulan-<br>cie kapit.<br>lekára | Košický        | 74 150(52%)  | 73 619(50%)  | 75 771(47%)  | 76 280(47%)  | 51 273(49%) | 51 549(49%) | 29 499(51%) |
|                                       | Nitriansky     | 48 768(34%)  | 49 373(34%)  | 55 702(34%)  | 53 263(33%)  | 31 470(30%) | 29 130(28%) | 15 676(27%) |
|                                       | Prešovský      | 20 810(14%)  | 23 782(16%)  | 30 444(19%)  | 32 221(20%)  | 22 562(21%) | 23 940(23%) | 12 425(22%) |
| Odbornosť<br>lekára                   | PLD            | 32 202(22%)  | 34 842(24%)  | 39 262(24%)  | 38 064(24%)  | 26 149(25%) | 22 841(22%) | 13 445(23%) |
|                                       | PLDD           | 111 526(78%) | 111 932(76%) | 122 655(76%) | 123 700(76%) | 79 156(75%) | 81 778(78%) | 44 155(77%) |

**Tabuľka 9:** Počty analyzovaných kontaktov týkajúce sa kapitujúcich lekárov vzhľadom na atribúty


V týchto tabuľkách môžeme hneď pozorovať pár zaujímavostí. Preskribované antibiotiká percentuálne od roka intervencie klesali. Tiež mierne stúpali počty kontaktov, ktorým bolo vykonané CRP. K lekárovi s ochorením HDC chodili prevažne deti do 18 rokov. Starší menej chodia k lekárovi s ochorením HDC. Dôvod môže byť taký, že sú menej infekční kvôli vybudovanej imunite, alebo v ľahkých prípadoch nie je potrebná návšteva lekára a tak ostávajú na domácej liečbe. Častejšie medzi kontaktami šlo o ženy a z vybraných komorbidít u pacientov šlo najčastejšie o pacientov s hypertenziou, alebo astmou.

Počet kontaktov, ktorým boli predpísané antibiotiká sa pohyboval okolo 30%. Ak sme zobrali do úvahy len kontakty, ktorým bolo vykonané CRP, 26,6% kontaktov dostalo antibiotiká. Pri kontaktoch, kde nebolo vykonané CRP boli antibiotiká predpísané v 29,3% prípadov. V porovnaní so štúdiou [7], ktorú sme spomínali v úvode, je to značný rozdiel. V tejto štúdii lekári, ktorí používali CRP pri liečbe ochorení horných a dolných dýchacích ciest, po roku sledovania v 43% prípadov predpísali ATB. Lekári, ktorí nepoužívali CRP predpísali antibiotiká v 51% prípadov. Poznamenajme však, že my nemáme lekárov rozdelených na skupiny, ktorí používajú, a ktorí nepoužívajú CRP. Všetci lekári z nášho datasetu majú možnosť CRP použiť. Berieme tiež do úvahy len diagnózy na horné dýchacie cesty.

Výsledky modelu reprezentujeme forest plotom, ktorý znázorňuje zmenu šancí na predpis ATB aj s intervalmi spoľahlivosti, alebo v matematickej formulácii  $e^{\hat{\beta}}$  s intervalmi spoľahlivosti, kde  $\hat{\beta}$  je vektor odhadnutých parametrov nášho modelu.

O odhadnutých šanciach na preskripciu ATB pri referenčnom kontakte nám hovorí intercept ( $ODDS = e^{\hat{\beta}_0}$ ). V našom prípade ( $ODDS = 1,21$ ;  $CI = (1,16; 1,26)$ ). Využitím 5 zistíme, že referenčný kontakt má 55% pravdepodobnosť na preskripciu ATB.

Obrázok 11 ilustruje, že výkon CRP naozaj znižuje šance na predpis ATB signifikantne nadol a to o 27% ( $OR = 0,73$ ;  $CI = (0,72; 0,75)$ ). Šance na predpis ATB stúpajú s rastúcim vekom pacientov oproti referenčnej kategórii 1 – 5 rokov. Čo sa týka vekovej kategórie lekárov, oproti referenčnej skupine 61 – 70 rokov, ostatní lekári majú vyššie šance na preskripciu ATB, alebo nesignifikantne nižšiu (lekári mladší ako 40 rokov), pretože zloženie lekárov mladších ako 40 rokov predstavovalo nie viac ako 5% spomedzi ostatných kategórií. Teda v znižovaní preskripcií ATB boli najúspešnejší lekári z vekovej kategórie



**Obr. 11:** Forest plot pomeru šancí s intervalmi spoľahlivosti pre celý model, zdroj: vlastné spracovanie z dát Dôvera z. p.

61 – 70 rokov.

Šance na predpis antibiotík sú oproti všeobecným lekárom pre dospelých nižšie u praktických lekárov pre deti a dorast (PLDD) o 22% ( $OR = 0,78$ ;  $CI = (0,75; 0,8)$ ).

Naopak, šance na preskripciu antibiotík sú vyššie u pacientov, ktorým boli pri poslednom kontakte podané antibiotiká ( $OR = 1,48$ ;  $CI = (1,47; 1,5)$ ). Tiež sú šance vyššie, ak ide o pacientov ženského pohlavia ( $OR = 1,05$ ;  $CI = (1,04; 1,06)$ ).

Čo sa týka komorbidít, šance na preskripciu antibiotík sú vyššie u pacientov s kardiovaskulárnym ochorením (srdcové zlyhávajúce, ischemická choroba srdca, fibrilácia sieni, infarkt myokardu) ( $OR = 1,31$ ;  $CI = (1,26; 1,36)$ ), chronickým zlyhávajúcimi obličkami ( $OR = 1,09$ ;  $CI = (1,03; 1,16)$ ) a u pacientov s diabetom ( $OR = 1,07$ ;  $CI = (1,03; 1,12)$ ). Je pravdepodobnejšie, že v týchto prípadoch sú lekári opatrnejší a preto vo väčšej miere predpisujú antibiotiká. Signifikantne nižšie sú len u pacientov s astmou ( $OR = 0,94$ ;  $CI = (0,93; 0,97)$ ).

Tiež sú šance vyššie pre pacientov v Prešovskom kraji ( $OR = 1,28$ ;  $CI = (1,26; 1,3)$ ),

naopak nižšie sú pre pacientov v Nitrianskom kraji ( $OR = 0,86; CI = (0,85; 0,88)$ ) oproti referenčnému Košickému kraju.

Vyššia šanca na predpis ATB je na kontakte u lekára, ktorí odišli skôr z DP ( $OR = 1,2; CI = (1,13; 1,26)$ ). Naopak, pri lekároch, ktorí prišli neskôr do DP, šance pri kontakte sú nižšie oproti referenčnej skupine lekárov ( $OR = 0,69; CI = (0,67; 0,71)$ ).

Obdobie pandémie COVID 19, teda pacienti, ktorí prišli na vyšetrenie po 1.3.2020, tiež signifikantne znižuje šance na predpis ATB pri kontakte. Dôvodom mohol byť všeobecný pokles infekčných chorôb kvôli prísny opatreniam nosenia rúšok a izolácie či už študentov (domáca výučba), alebo pracujúcich (home office). Signifikantný pokles kontaktov kvôli infekčným chorobám horných a tiež dolných dýchacích ciest prezentuje článok [10]. Najvýraznejší pokles podľa článku bol zaznamenaný najmä pri chrípke (o 90%). Pri nádche išlo o pokles o 66%. Dôvodom môže byť tiež dôraz na telemedicínu, ktorá bola lekármi počas kovidového obdobia preferovaná.

Šance na predpis ATB znižuje kontakt na pohotovosti ( $OR = 0,12; CI = (0,11; 0,12)$ ). To znamená, že ak pacient príde na LSPP s ochorením HDC, jeho šance na predpis ATB budú pomerne nízke. Na LSPP celkovo dostalo ATB na ochorenie HDC len 8,2% pacientov. Tabuľka 10 prezentuje, ako je to s pravdepodobnosťou na ATB pri kontakte na LSPP s pacientami podľa vekovej kategórie v čase kontaktu.

Podľa 10 vidíme, že pravdepodobnosť na antibiotiká pri kontakte na LSPP je vyššia skôr u dospelých, ako pri deťoch.

Podrobné výsledky z logistického modelu sú uvedené v tabuľkách 21, 22.

| Veková kategória pacienta | Počet kontaktov s ATB na LSPP | Celkový počet kontaktov na LSPP | % kontaktov s ATB |
|---------------------------|-------------------------------|---------------------------------|-------------------|
| do 1                      | 104                           | 3810                            | 2,7%              |
| 1-5                       | 529                           | 10533                           | 5,0%              |
| 6-14                      | 324                           | 5348                            | 6,1%              |
| 15-18                     | 106                           | 1099                            | 9,6%              |
| 19-26                     | 277                           | 1064                            | 26,0%             |
| 27-40                     | 400                           | 1596                            | 25,1%             |
| 41-50                     | 142                           | 706                             | 20,1%             |
| 51-60                     | 107                           | 465                             | 23,0%             |
| 61-70                     | 64                            | 260                             | 24,6%             |
| 71+                       | 10                            | 144                             | 6,9%              |

**Tabuľka 10:** Percentuálny podiel kontaktov na LSPP s vybraným receptom na antibiotiká, zdroj: vlastné spracovanie z dát Dôvera z. p.

### 2.3.3 VIF a stepAIC

Správnosť modelu overíme pomocou **Variance inflation factor** (VIF), alebo faktor inflácie rozptylu.

**VIF** predstavuje mieru multikolinearity medzi nezávislými premennými vo viacnásobnom regresnom modeli. Zisťovanie multikolinearity je dôležité, pretože multikolinearita medzi nezávislými premennými znižuje ich štatistickú významnosť. Veľmi vysoký VIF často naznačuje kolineárny vzťah sledovanej premennej ku ostatným premenným. Táto premenná by sa následne mala zohľadniť a model podľa toho upraviť [11].

Pri multikolinearite vstupy v modeli viacnásobnej regresie sa navzájom ovplyvňujú. Tak nie sú v skutočnosti nezávislé a je ťažké testovať, do akej miery kombinácia nezávislých premenných ovplyvňuje závislú premennú alebo výsledok v rámci regresného modelu.

Vzorec pre výpočet VIF:

$$VIF_i = \frac{1}{1 - R_i^2}$$

$R_i^2$  predstavuje neupravený koeficient determinácie pre  $i$ -tú nezávislú premennú od

ostatných premenných v našom modeli. Inak povedané, ako koreluje  $i$ -tá nezávislá premenná v modeli s ostatnými.

Teda, ak  $R_i^2 = 0$  a  $VIF = 1$ ,  $i$ -tá nezávislá premenná nekoreluje s ostatnými premennými v modeli.

Čím vyššie je VIF pre sledovanú premennú, tým vyššia je možnosť, že existuje multikolinearita. Ak je VIF vyššia ako 10, existuje významná multikolinearita, ktorú je potrebné korigovať [11].

Pre správny výber parametrov do nášho modelu nám vie byť nápomocná aj funkcia **stepAIC** zabudovaná v Rku. Naším cieľom pri výbere parametrov v modeli je minimalizovať AIC (Akaikeho informačné kritérium) tak, aby sme čo najlepšie popisovali vysvetľovanú premennú nezávislými vysvetľujúcimi premennými. StepAIC sa tak používa na zjednodušenie modelu bez vplyvu na výkonnosť [12].

Absolútna hodnota AIC nemá praktický význam v porovnávaní modeloch, ktoré modelujú inú vysvetľovanú premennú. Porovnávame len to, či sa hodnota AIC pridaním ďalších premenných zvyšuje alebo znižuje. Preto v prípade viacerých modelov tej istej modelovanej premennej sa uprednostňuje ten, ktorý má nižšiu hodnotu AIC.

Čo sa týka nášho modelu, funkciou *vif* sme zistili, že v našom modeli existuje silná multikolinearita pre odbornosť lekára ( $GVIF = 8,7$ ) a tiež pre vekovú kategóriu pacientov ( $GVIF = 15,3$ ). Pre ostatné premenné neboli hodnoty  $GVIF$  nijako kriticky vysoké. Dáva však aj dobrý zmysel, že odbornosť lekárov je silne korelovaná s vekom pacientov, keďže vek pacientov je primárne to, čo odlišuje kmeň pacientov pri odbornosti lekárov.

GVIF (Generalized variance inflation factor) predstavuje druhú odmocninu z VIF. Preto sa dá použiť ako ekvivalent ku VIF.

Funkcia *stepAIC* nám v tomto prípade povedala, že ak by sme vyhodili parameter týkajúci sa komorbidít na hypertenziu, znížili by sme tak AIC.

Po zvážení týchto výsledkov sme sa rozhodli, že spravíme separátne dva modely pre PLD a PLDD lekárov.

### 2.3.4 Model pre PLD a PLDD lekárov

Pri týchto modeloch budeme uvažovať rovnaké referenčné kategórie. Zmeníme ale vekovú kategóriu pacienta kvôli odbornosti lekárov. Pri PLD na 61 – 70 rokov a pri PLDD na

1 – 5 rokov.

Referenčné kategórie:


- Stav v DP *referencia*
- Veková kategória lekára 61 – 70 *rokov*
- Kontakt na LSPP *No*
- Predošlý recept *No*
- Veková kategória poistenca 61 – 70 *rokov pre PLD* a 1 – 5 rokov pre PLDD
- Pohlavie poistenca *Muž*
- Kraj ambulancie kapitujúceho lekára *Košický kraj*
- Diagnóza pri kontakte *J03 (akútny zápal mandlí)*
- Bez ďalších komorbidít
- Nekovidové obdobie

Pre PLD model ( $OD\hat{D}S = e^{\hat{\beta}_0}$ ). V našom prípade ( $OD\hat{D}S = 1,39$ ;  $CI = (1,32; 1,45)$ ). Referenčný kontakt má 58% pravdepodobnosť na preskripciu ATB.

Pre PLDD model ( $OD\hat{D}S = e^{\hat{\beta}_0}$ ). V našom prípade ( $OD\hat{D}S = 1,02$ ;  $CI = (1; 1,04)$ ). Referenčný kontakt má 50% pravdepodobnosť na preskripciu ATB.

Čo je kľúčové, podľa 12 a 13, v oboch prípadoch výkon CRP a tiež kontakt na LSPP znižujú šance na predpísanie antibiotík. Pri PLD lekároch vyšetrenie CRP znižuje šance o 46% ( $OR = 0,54$ ;  $CI = (0,52; 0,57)$ ), kým pri PLDD lekároch sú šance nižšie o 20% ( $OR = 0,8$ ;  $CI = (0,78; 0,82)$ ). Na opačnej strane, šance na predpis antibiotík sú v oboch prípadoch vyššie u žien. Ako to bolo aj v predchádzajúcom prípade, šance sú vyššie v prípade, ak pacient pri poslednom kontakte u lekára s ochorením HDC odišiel s antibiotikami - PLD ( $OR = 1,71$ ;  $CI = (1,68; 1,75)$ ), PLDD ( $OR = 1,38$ ;  $CI = (1,36; 1,4)$ ).

Hlavný rozdiel vidíme pri správaní lekárov podľa vekovej kategórie. Pri PLDD kontakty s lekármi všetkých vekových skupín majú vyššie šance na predpísanie ATB oproti referenčnej skupine 61 – 70 ročných lekárov, kým pri PLD lekároch je efekt rôznorodejší. Pri lekároch, ktorí sú mladší ako 40 rokov ( $OR = 0,91$ ;  $CI = (0,87; 0,94)$ ), alebo starší




**Obr. 12:** Forest plot pomeru šancí s intervalmi spoľahlivosti pre PLDD, zdroj: vlastné spracovanie z dát Dôvera z. p.

ako 70 rokov ( $OR = 0,83; CI = (0,8; 0,86)$ ) sú šance nižšie, kým u lekárov vo vekovej kategórii 51 – 60 sú šance naopak vyššie ( $OR = 1,12; CI = (1,09; 1,15)$ ).

Čo sa týka správania lekárov z pohľadu fungovania v programe DP, kontakt u PLDD majú nižšie šance na predpis ATB oproti referencii, ak sa zapojili do programu DP. Pre kontakt u lekárov, ktorí odišli z programu skôr, sú však šance vyššie ( $OR = 1,3; CI = (1,2; 1,4)$ ). Pri kontakte PLD sú šance oproti referencii vyššie v prípade, ak lekár bol počas celej intervenčnej doby zapojený do programu DP ( $OR = 1,11; CI = (1,09; 1,14)$ ) a tiež ak odišiel skôr ( $OR = 1,2; CI = (1,1; 1,3)$ ).

Chronické ochorenia sme uvažovali len u pacientov pri PLD lekároch, keďže pri det-ských pacientoch sa pohybovali maximálne v 0,2% prípadov.

Pacienti, ktorí trpeli chronickými ochoreniami ako kardiovaskulárne ochorenie ( $OR = 1,2; CI = (1,15; 1,25)$ ), chronické ochorenie obličiek ( $OR = 1,1; CI = (1,01; 1,2)$ ) alebo diabetes ( $OR = 1,07; CI = (1,03; 1,12)$ ), majú štatisticky významne vyššie šance, že dostanú antibiotiká. Pacientom s astmou naopak šance na antibiotiká klesajú ( $OR = 0,88; CI = (0,85; 0,91)$ ).



**Obr. 13:** Forest plot pomeru šanci s intervalmi spoľahlivosti pre PLD, zdroj: vlastné spracovanie z dát Dôvera z. p.

Pri PLD majú nižšie šance na predpis všetky vekové kategórie pacientov v porovnaní s referenčnou kategóriou 61 – 70 ročných pacientov.

Pri pacientoch, ktorých kapituujúci lekár je PLDD majú oproti referenčnej skupine 1 – 5 ročných pacientov nižšiu šancu na predpis ATB väčšina vekových kategórií až na 19 – 26 ročných ( $OR = 1,08; CI = (1,06; 1,11)$ ) a nesignifikantnú skupinu pacientov 27 – 40 ročných ( $OR = 1,07; CI = (0,97; 1,18)$ ). Pravdepodobne nesignifikantná preto, lebo v tejto kategórii pri PLDD bolo málo kontaktov. Pokiaľ pri referenčnej skupine pacientov 1 – 5 ročných šlo priemerne ročne o 35095 kontaktov, pri vekovej skupine 27 – 40 ročných šlo priemerne o 344 kontaktov.

Podrobné výsledky z PLD modelu sú uvedené v tabuľkách 23 a 24. Výsledky z PLDD modelu sú uvedené v tabuľkách 25 a 26.

Poznamenajme, že sú to však šance na predpis antibiotík bez akéhokoľvek iného vplyvu, ktorý sme pomenovali.

Pozorujeme, že hlavné atribúty sa v jednotlivých skupinách lekárov vyvíjali rovnako.

### **3 Benchmarking poskytovateľov zdravotnej starostlivosti (PZS)**

V predchádzajúcej časti sme ukázali, že výkon CRP znižuje preskripciu ATB. V tejto časti nás zaujímalo, v akých prípadoch tomu tak je. Naším cieľom bolo nájsť skupiny lekárov, ktorým CRP pomáha v rozhodovaní či predpísať ATB pacientovi. Pri akých lekároch výkon CRP pomáha v znížení preskripcie ATB, v akých zas nie a čo tieto skupiny lekárov od seba odlišuje.

#### **3.1 Pomer šancí na predpis antibiotík po vykonaní CRP**

Lekárov sme rozdelili do skupín podľa toho, aký vplyv na nich malo vykonávanie CRP v súvislosti s preskripciou ATB. Či výkon CRP zvyšoval ich šance na preskripciu ATB, alebo naopak znižoval. Lekárov sme kategorizovali do skupín pomocou vypočítaného pomeru šancí pre každého lekára. Testovaním kontingenčných tabuliek sme hľadali rozdiely medzi týmito skupinami lekárov.

Pomer šancí budeme počítat pre lekárov a následne aj pre ochorenia HDC.

##### **3.1.1 Pomer šancí na preskripciu ATB po vykonaní CRP pre lekárov**

Pre túto časť analýzy sme pracovali s jedinečnými kódmi lekárov, a týmito údajmi:

- počet kontaktov, pri ktorých bolo vykonané CRP a následne bol vydaný recept na ATB
- počet kontaktov, pri ktorých bolo vykonané CRP a následne nebol vydaný recept na ATB
- počet kontaktov, pri ktorých nebolo vykonané CRP a následne bol vydaný recept na ATB
- počet kontaktov, pri ktorých nebolo vykonané CRP a následne nebol vydaný recept na ATB

V skratke 11.

Pri každom lekárovi sme vypočítali OR pre kontakty nad jeho kapitovanými poisten-  
cami. Postupovali sme nasledovne:

|     | ATB | Áno | Nie |
|-----|-----|-----|-----|
| CRP |     |     |     |
| Áno |     | a   | b   |
| Nie |     | c   | d   |

**Tabuľka 11:** Pomocná tabuľka na výpočet pomeru šancí (OR)

Pomer šancí definujeme:

$$OR = \frac{\frac{a}{b}}{\frac{c}{d}}$$

- Vrchný podiel v zlomku hovorí o šanciach na predpis ATB po vykonaní CRP
- Spodný podiel hovorí o šanciach na predpis ATB, ak sa CRP nevykoná
- Celkový zlomok hovorí o pomere šancí na predpis ATB vykonaním CRP

Podľa OR môžeme PZS rozdeliť hneď do niekoľkých skupín:

- $OR < 1$ , vykonaním CRP sa šance na predpis ATB znižujú
- $OR > 1$ , vykonaním CRP sa šance na predpis ATB zvyšujú
- $OR$  nesignifikantné, tj.  $OR < 1$ , alebo  $OR > 1$ , pričom pomocou intervalu spoľah-  
livosti sme zistili, že pomer šancí nebol signifikantný
- $OR = 0$ , lekár ani v jednom prípade nevykázal CRP a zároveň nepredpísal ATB
- $OR = 0 \setminus 0$ , OR nevieme určiť, pretože v hrubej väčšine takýchto prípadov lekári ani  
raz CRP neurobili
- $OR = \infty$ , lekári urobil CRP len v zopár prípadoch a aj tam sa rozhodli, že ATB  
predpíšu.

| $OR$      | $OR < 1$ | $OR > 1$ | $OR$ nesig-<br>nifikantné | $OR = 0$ | $OR = 0 \setminus 0$ | $OR = \infty$ |
|-----------|----------|----------|---------------------------|----------|----------------------|---------------|
| Počet PZS | 94       | 99       | 348                       | 102      | 100                  | 28            |

**Tabuľka 12:** Počet lekárov podľa tried OR

V tabuľke 12 znázorňujeme počty lekárov v jednotlivých kategóriách OR.


Pre nás sú zaujímavé boli len skupiny, kde  $OR < 1$ ,  $OR > 1$  a  $OR$  je nesignifikantné. Chceli sme zistiť, aké zloženie lekárov je v týchto skupinách, a zároveň, či sa zloženie medzi jednotlivými skupinami výrazne líši.

### 3.1.2 Testovanie hypotéz o pravdepodobnostných rozloženiach lekárov pre rôzne kategórie

V prvej časti testujeme nasledujúcu hypotézu:

$H_0$  : Pravdepodobnosť, že lekár bol vždy v DP, odišiel skôr z DP, prišiel neskôr do DP, alebo bol referenčný **je rovnaká** pre lekárov, ktorých  $OR$  je  $OR < 1$ ,  $OR > 1$  a  $OR$  nesignifikantné

$H_0$  : Pravdepodobnostné rozdelenie lekárov v jednotlivých triedach DP **je rovnaké** pre  $OR < 1$ ,  $OR > 1$  a tiež pre  $OR$  nesignifikantné



**Obr. 14:** Rozloženie lekárov v skupinách OR podľa stavu v DP, zdroj: vlastné spracovanie z dát Dôvera z. p.

|                      | $OR$ nesig-<br>nifikantné | $OR < 1$ | $OR > 1$ |
|----------------------|---------------------------|----------|----------|
| Odišiel skôr z DP    | 10                        | 2        | 1        |
| Prišiel neskôr do DP | 29                        | 7        | 8        |
| Referencia           | 247                       | 63       | 68       |
| Vždy v DP            | 62                        | 22       | 22       |

**Tabuľka 13:** Rozloženie počtu lekárov v skupinách OR podľa stavu v DP

Testujeme kontingenčnú tabuľku 13:

Keďže v tabuľke máme hodnoty, kde počet lekárov je  $< 5$ , na vyhodnotenie tohto testu použijeme Fisherov test.  $P - value = 84\%$ ,  $H_0$  nezamietame. Nepozorujeme signifikantný rozdiel pravdepodobnostného rozdelenia lekárov v jednotlivých stavoch DP pre  $OR < 1$ ,  $OR > 1$  a tiež pre  $OR$  nesignifikantné.

Takisto sme nezamietli hypotézu  $H_0$  v prípade pravdepodobnostného rozloženia u lekárov v jednotlivých kategóriách OR podľa kraja ambulancie kapitujúceho lekára ( $p - value = 56\%$ ) a vekovej kategórie lekára ( $p - value = 39\%$ ).


Naopak, signifikantne sa ukázali prípady, keď sme testovali hypotézy týkajúce sa pravdepodobnostného rozloženia u lekárov v jednotlivých kategóriách OR podľa odbornosti ( $p - value < 0,001\%$ ) a tiež podľa pohlavia kapitujúcich lekárov ( $p - value = 3,1\%$ ).

### 3.1.3 Pravdepodobnostné rozdelenie lekárov podľa zapojenia sa do intervencie v programe DôveraPomáha

Ako sme v úvode spomínali, v rámci intervencie všetci lekári zapojení do programu DP dostávali pravidelnú spätnú väzbu, ktorá porovnávala zloženie jeho preskripcie a zmenu v čase s referenčnými lekármi ako aj s inými lekármi v DP. V rámci intervencie mali lekári tiež možnosť zúčastňovať sa schôdzok zameraných okrem iného aj na racionalizáciu preskripcie ATB. Vplyv týchto faktorov na správanie lekárov sme následne vyhodnotili.

$H_0$  : Pravdepodobnostné rozdelenie kapitujúcich lekárov podľa zapojenia sa do intervencie **je rovnaké** pre  $OR < 1$ ,  $OR > 1$  a tiež pre  $OR$  nesignifikantné

Hypotézu sme otestovali pomocou Chí-kvadrát testu dobrej zhody, kde  $p - value = 5\%$ .



**Obr. 15:** Rozloženie lekárov v skupinách OR podľa iniciatívnosti počas intervencie, zdroj: vlastné spracovanie z dát Dôvera z. p.

|                           | <i>OR</i> nesig-<br>nifikantné | <i>OR</i> < 1 | <i>OR</i> > 1 |
|---------------------------|--------------------------------|---------------|---------------|
| Bez intervencie           | 247                            | 63            | 68            |
| Len písomná spätná väzba  | 27                             | 2             | 3             |
| Písomná sp. v. + schôdzky | 74                             | 29            | 28            |

**Tabuľka 14:** Rozloženie počtu lekárov v skupinách OR podľa angažovanosti počas intervencie, zdroj: vlastné spracovanie z dát Dôvera z. p.


Aj keď hranične, ale zdá sa, že u lekárov, ktorí sa zúčastňovali schôdzok, CRP signifikantnejšie ovplyvnilo ich správanie.

### 3.1.4 OR a preskripcia antibiotík pred intervenciou

Možno sa na prvý pohľad zdá, že lekári, ktorých  $OR < 1$  sú lepší v porovnaní s lekármi s  $OR > 1$ . Dôležité sú však obe skupiny, pretože takto objavujeme skupiny, kde výkon CRP pomohol v racionalizácii preskribovania ATB.

Chceli sme zistiť, ako sa správali lekári pred intervenciou. Pozreli sme sa na celkovú preskripciu ATB u lekárov pred časom intervencie aby sme zistili, ako sa celková preskripcia ATB líši u signifikantných skupín.

Sledovali sme, v koľkých percentách kontaktov lekári predpísali ATB pred intervenciou.



**Obr. 16:** Rozloženie lekárov v skupinách OR podľa preskripcie antibiotík do roku 2017, zdroj: vlastné spracovanie z dát Dôvera z. p.

|         | <i>OR</i> nesig-<br>nifikantné | <i>OR</i> < 1 | <i>OR</i> > 1 |
|---------|--------------------------------|---------------|---------------|
| do 20%  | 41                             | 3             | 27            |
| 21-40%  | 111                            | 27            | 42            |
| 41-60%  | 94                             | 42            | 12            |
| 61-80%  | 26                             | 12            |               |
| 81-100% | 2                              |               |               |
| neviem  | 74                             | 10            | 18            |


**Tabuľka 15:** Rozloženie počtu lekárov v skupinách OR podľa vekovej kategórie kapitulujúceho lekára, zdroj: vlastné spracovanie z dát Dôvera z. p.

$H_0$  : Pravdepodobnostné rozdelenie kapitulujúcich lekárov podľa preskripcie antibiotík do roku 2017 **je rovnaké** pre  $OR < 1$ ,  $OR > 1$  a tiež pre  $OR$  nesignifikantné

Kvôli obmedzeniam použitia Pearsonovho Chí-kvadrát testu dobrej zhody v programovacom jazyku R používanom na štatistické výpočty sme vylúčili kategóriu 80 – 100%.  $P - value < 0,001\%$  a tak hypotézu  $H_0$  zamietame.


Ak CRP v nejakých prípadoch zvyšuje šance na preskripciu ATB, môže to znamenať, že lekár skôr než začal využívať CRP, nepredpisoval ATB v opodstatnených prípadoch a tak podliečovali svojich pacientov. Preto budú jeho šance na preskripciu ATB vyššie po vyšetrení CRP. V prípadoch, kedy lekár predpisoval ATB vo veľa prípadoch, vykonávanie CRP mu pomohlo určiť, že to nie je potrebné v tak veľa prípadoch a preto vykonávaním CRP jeho šance na preskripciu ATB sa budú znižovať. V takýchto prípadoch lekár nadliečoval svojich pacientov. Tieto rozdiely v preskripcii ATB sledujeme na grafe na obrázku 16

Pozrieme sa, ako sa zmenila celková preskripcia antibiotík u lekárov zo signifikantných skupín. Budeme sledovať pravdepodobnosť na predpis antibiotík na jeden kontakt z pohľadu dvoch období. Do intervencie (do roku 2017) a následne od intervencie (od roku 2017).



**Obr. 17:** Preskripcia antibiotík u lekárov, kde  $OR < 1$  do roku 2017 a od roku 2017, zdroj: vlastné spracovanie z dát Dôvera z. p.

Obr. 17, 18 ukazujú pravdepodobnosť na predpis ATB pri jednom kontakte s ochorením HDC. Vyznačujeme tiež priemer týchto pravdepodobností z času pred intervenciou a tiež z obdobia od intervencie. Pokles v priemere sme v prípade lekárov, ktorých



**Obr. 18:** Preskripcia antibiotík u lekárov, kde  $OR > 1$  do roku 2017 a od roku 2017, zdroj: vlastné spracovanie z dát Dôvera z. p.

$OR > 1$  a  $OR < 1$  otestovali. Rozdiely v oboch prípadoch sú signifikantné (pre oba prípady  $p - value < 0,001$ ).

Dáta (pravdepodobnosti), ktoré sa týkali lekárov, ktorých vyšetovanie CRP znižuje šance na preskripciu ATB ( $OR < 1$ ), pochádzali z normálneho rozdelenia. Nezamietli sme ani hypotézu o rovnakej disperzii. Preto sme na vyhodnotenie poklesu priemeru preskripcie na ATB pre túto sadu dát použili Studentov t-test. Priemer pravdepodobnosti vydania ATB do roku 2017 bol 45%. Vplyvom intervencie a po nej klesol na 40%. Tento rozdiel sa ukázal ako signifikantný.

Pri dátach týkajúcich sa lekárov z kategórie, kde  $OR > 1$  sme hypotézu o normalite dát zamietli a použili sme Wilcoxonov test. Priemer pravdepodobnosti na predpis ATB do roku 2017 bol 26%. Vplyvom intervencie a po nej klesol na 22%. Aj tento rozdiel sa ukázal ako signifikantný.

V oboch prípadoch tak klesla celková pravdepodobnosť na predpis ATB čo len hovorí o tom, že výkon CRP dopomohol lekárom k racionálnej preskripcii ATB.

Nevýhodou takéhoto prístupu môže byť skutočnosť, že neberieme ohľad na počet pa-

cientov pri jednotlivých lekároch. (Ak má lekár pravdepodobnosť na predpis ATB 25%, mohol predpísať ATB v 2 prípadoch, kde celkový počet návštev predstavoval 8 pacientov, alebo mohol predpísať ATB u 200 pacientov z 800 pacientov). Preto sme zvolili ešte jeden pohľad vyhodnotenia tejto zmeny pomocou Chí-kvadrát testu dobrej zhody. Pozrieme sa na celkový počet pacientov v sledovanej skupine lekárov, ktorým boli/neboli v obdobiach do roku 2017 a od roku 2017 predpísané ATB. Testovali sme nasledujúcu hypotézu:

$H_0$  : Pravdepodobnosť predpísania, resp. nepredpísania ATB je rovnaká v období do roku 2017 a od roku 2017

| Obdobie | s ATB  | bez ATB |
|---------|--------|---------|
| do 2017 | 44 258 | 62 242  |
| od 2017 | 50 049 | 85 405  |

**Tabuľka 16:** Počty pacientov s predpísanými a s nepredpísanými ATB pre lekárov, ktorých  $OR < 1$

| Obdobie | s ATB  | bez ATB |
|---------|--------|---------|
| do 2017 | 33 639 | 103 974 |
| od 2017 | 41 786 | 159 361 |

**Tabuľka 17:** Počty pacientov s predpísanými a s nepredpísanými ATB pre lekárov, ktorých  $OR > 1$


Túto hypotézu zamietam v prípade lekárov, ktorých je  $OR > 1$  a tiež  $OR < 1$  ( $p - value < 0,001$ ).

### 3.2 Vplyv CRP na preskripciu ATB pre diagnózy na horné dýchacie cesty

Aj v tejto časti výpočet pre OR ostáva ako pre lekárov. Interpretácia výsledku sa však zmení.

V tomto prípade hovoríme o zmene šancí na predpis antibiotík po vykonaní CRP pri jednotlivých diagnózach na HDC.

Ani v tejto časti sme neuvažovali kontakty na ambulanciách, kde sa lekár správal ako referencia, a zároveň na inej bol v nejakom vzťahu s DP tak, ako sme to uvádzali v úvodnej analýze. Tiež sme uvažovali len kontakty, ktoré boli vykonané neskôr, ako lekár prvý krát vykázal CRP.



**Obr. 19:** Forest plot pomeru šancí na predpis ATB po vykonaní CRP pri diagnózach na HDC, zdroj: vlastné spracovanie z dát Dôvera z. p.

Na 19 vidíme, že výkon CRP znižuje šance na predpis ATB pri veľkej väčšine diagnóz na HDC. Preto z tohto hľadiska má naozaj zmysel vykonávať CRP, keďže väčšina z týchto chorôb je prevažne vírusového pôvodu.

Sú však diagnózy, pri ktorých sú šance na predpis ATB po vykonaní CRP vyššie. Medzi takéto diagnózy patria *J00*, *J01.2*, *J11.1* (pozri 18).

*Pozn.* V tomto forest plote sú vylúčené diagnózy, ktorých OR nevieme určiť, pretože pri týchto diagnózach nebolo vykonané CRP ani v jednom prípade. (*J11*, *J03*) a kde  $OR = \infty$  (*J01*) (pozri 18).

Tak, ako sme diagnózy spájali do celých kategórii pri logistickom modeli, spravíme aj teraz.

Výkon CRP, ako ilustruje Obr. 20, naozaj znižuje šance na predpis ATB pri všetkých skupinách diagnóz na HDC až na nádchu, kde sa šance na predpis ATB zvyšujú. Je


| Kód diagnózy | Názov diagnózy                                                               |
|--------------|------------------------------------------------------------------------------|
| J00          | Akútny zápal nosohltana (nádcha)                                             |
| J01.0        | Akútny zápal čelustnej dutiny                                                |
| J01.1        | Akútny zápal čelovej dutiny                                                  |
| J01.2        | Akútny zápal čuchovej dutiny                                                 |
| J01.3        | Akútny zápal klinovitej dutiny                                               |
| J01.4        | Akútna pansinusitída                                                         |
| J01.8        | Iný akútny zápal prínosových dutín                                           |
| J01.9        | Zápal prínosových dutín, bližšie neurčený                                    |
| J03.0        | Streptokokový zápal mandlí                                                   |
| J03.8        | Akútny zápal mandlí, zapríčinený iným bližšie určeným organizmom             |
| J03.9        | Akútny zápal mandlí, bližšie neurčený                                        |
| J11.0        | Chrípka zapríčinená neidentifikovaným vírusom, so zápalom pľúc               |
| J11.1        | Chrípka zapríčinená neidentifikovaným vírusom, s inými respiračnými prejavmi |
| J11.8        | Chrípka zapríčinená neidentifikovaným vírusom, s inými prejavmi              |

**Tabuľka 18:** Kódy diagnóz na HDC s ich celými názvami

| Kód diagnózy | Názov diagnózy                                |
|--------------|-----------------------------------------------|
| J00          | Akútny zápal nosohltana (nádcha)              |
| J01          | Akútny zápal prínosových dutín                |
| J03          | Akútny zápal mandlí                           |
| J11          | Chrípka zapríčinená neidentifikovaným vírusom |

**Tabuľka 19:** Kódy tried diagnóz na HDC s ich celými názvami

naozaj pozoruhodné, že pri nádche výkon CRP výrazne zvyšuje šance na ATB, aj keď sme v úvodnej časti práce ukázali, že len približne v 2% pacientov dochádza ku nádche s bakteriálnym pôvodom. Niečo podobné sa dalo skôr očakávať pri diagnóze J03, teda akútnom zápale mandlí, keďže v tomto prípade môže ísť až o 30% pacientov, ktorí by reálne aj ATB potrebovali.



**Obr. 20:** Forest plot pomeru šanci na predpis ATB po vykonaní CRP pri zoskupených diagnózach na HDC, zdroj: vlastné spracovanie z dát Dôvera z. p.

### 3.3 Diskusia

V tejto práci sme skúmali vplyv CRP a tiež iných premenných v racionalizácii preskripcie ATB. Hľadali sme rozdielnosti medzi skupinami lekárov, ktorých vykonávanie CRP ovplyvňuje v predpisovaní ATB. Štatistickým vyhodnocovaním kontingenčných tabuliek sme brali do úvahy rôzne premenné. Takto sme našli rozdiely medzi lekármi, ktorých vyšetrením CRP sa zvyšujú šance na preskripciu ATB, a ktorým sa naopak znižujú. Lekári, ktorých  $OR > 1$  sú prevažne taký, ktorý celkovo predpisujú málo ATB a tak podliečujú svojich pacientov. Preto takýchto lekárov vyšetrenie CRP smeruje ku vyššej preskripcii ATB. Naopak, lekári s  $OR < 1$  majú tendenciu často predpisovať ATB, preto vykonaním CRP sú smerovaní k tomu, že to nie je potrebné v takej veľkej miere. Dôležité je ale preskribovať ATB racionálne. O tom že k tomu CRP napomohlo svedčí zníženie celkovej priemernej preskripcie ATB u oboch signifikantných skupinách lekárov.

V tejto časti sme tiež pracovali s celou skupinou lekárov a nedelili sme ich na PLD a PLDD. Urobili sme tak, pretože ak by sme ich rozdelili a tieto dve skupiny, ktoré by sme následne delili ešte na menšie kategórie, v jednotlivých kategóriách by sme mali veľmi

nízky počet jednotlivých lekárov.

Je však dôležité povedať, že takýmto vyhodnocovaním sme brali ohľad len na dané premenné osamote a zanedbávali sme prípadný vzťah s ostatnými premennými. Ak by sme chceli vyhodnocovať pravdepodobnostné rozdelenie lekárov vo viacerých premenných naraz, museli by sme použiť napríklad Poissonov log-lineárny model.

Tiež sme predpokladali, že lekári sa správajú racionálne v tom zmysle, že ak urobia CRP a predpíšu ATB, pacient v tej chvíli aj ATB potrebuje. Ak ich po vykonaní CRP nepredpíšu, nie sú potrebné. Ak by sme tento predpoklad nebrali do úvahy, interpretácia pomeru šancí na preskripciu ATB po vykonaní CRP by vo viacerých prípadoch nedávala zmysel.

Tiež sme ukázali, že intervencia v programe DP bola dôležitá a lekári, ktorí sa aktívne do tejto intervencie zapájali patria so skupiny lekárov, ktorým vyšetrenie CRP pomáha ku racionálnej preskripcii ATB.

Modelom založeným na logistickej regresii sme ukázali, že CRP signifikantne znižuje šance na preskripciu ATB ako pri PLD, tak aj pri PLDD.

Výhoda použitia modelu založeného na logistickej regresii je tá, že jednotlivé efekty medzi atribútmi očistí. To znamená, že eliminujeme efekt, že napríklad v Košickom kraji je viac starších lekárov v porovnaní s Prešovským krajom. Alebo, že na LSPP chodí viac starších ľudí s ochorením HDC a pod.

Nevýhodou môže byť to, že vypočítané šance môžeme brať ako výstup len v kompletnom chápaní. To znamená, že vypočítané šance fungujú len na takom zložení vstupných atribútov, ako sme si ich vybrali. Ak by sme uvažovali atribúty povedzme týkajúce sa len toho, či lekár spravil CRP, z ktorého kraja pochádzal a jeho vekovú kategóriu, odhad šancí by bol iný.

Medzi limity patrí aj to, že sme nevzali do úvahy určité ambulancie, pri ktorých sme nevedeli zhodnotiť, ako sa tam lekári podľa vzťahu v DP budú správať.

## Záver

Naším cieľom práce bolo ukázať, či vyšetrenie CRP pomáha racionalizovať preskripciu antibiotík, ktorá je pri ochoreniach na HDC častokrát zbytočná a nadužívaná. Logistickým modelom sme ukázali, že vyšetrenie CRP signifikantne znižuje šance na predpis antibiotík a to ako pri praktických lekároch pre dospelých ( $OR = 0,54; CI = (0,52; 0,57)$ ), tak aj pri praktických lekároch pre deti a dorast ( $OR = 0,8; CI = (0,78; 0,82)$ ). Zo spoločného modelu pre PLD a tiež pre PLDD lekárov sme ukázali, že šance na predpis antibiotík sú všeobecne nižšie pre PLDD lekárov v porovnaní s PLD lekármi ( $OR = 0,78; CI = (0,75; 0,8)$ ).

Z celkového počtu 771 jedinečných lekárov, z nich 94 lekárom vykonanie CRP signifikantne znižuje šance na predpis antibiotík. Pri 99 lekároch sa tieto šance vykonaním CRP signifikantne zvyšujú. Pri 348 zmeny šanci na preskripciu ATB nie sú signifikantné. Prevažne ide o také prípady lekárov, ktorí majú nízky počet kontaktov, alebo všeobecne veľmi zriedkavo vykazujú CRP a tak nevieme určiť ich správanie ako signifikantné.

Pozorovali sme signifikantný rozdiel v pravdepodobnostnom rozložení lekárov, podľa toho, ako preskribovali ATB pred intervenciou. Lekári s  $OR > 1$  mali tendenciu podliečať pacientov a naopak lekári s  $OR < 1$  zas nadliečovali a predpisovali ATB častejšie, ako bolo treba ( $p - value < 0,001$ ). Pri oboch skupinách sledujeme signifikantný pokles v celkovej priemernej preskripcii ( $p - value < 0,001$ ).

Cieľom vykonávania CRP nie je, aby lekári prestali úplne predpisovať antibiotiká. CRP má lekárov usmerniť v racionálnom preskribovaní ATB. Touto prácou sme našli skupiny lekárov, ktorých správanie v preskripcii antibiotík CRP výkon signifikantne ovplyvnil a ukázali sme, v čom sa tieto skupiny líšia.

Tiež sme ukázali, že výkon CRP usmernil v správnej preskripcii antibiotík hlavne lekárov, ktorí sa zúčastňovali počas intervencie aj schôdzok, ktoré iniciovala Dôvera z.p. ( $p - value = 5\%$ ). Okrem spätnej väzby to bol tak dôležitý element intervencie.

Pri hrubej väčšine diagnóz na HDC vykonanie CRP signifikantne znižuje šance na predpis ATB. Preto má význam pri týchto diagnózach aj CRP naďalej vykonávať.

## Zoznam použitej literatúry

- [1] Bjerrum, Lars, Bente Gahrn-Hansen, and Anders P. Munck: *C-reactive protein measurement in general practice may lead to lower antibiotic prescribing for sinusitis*, British Journal of General Practice 54, no. 506, 2004, str. 659-662
- [2] Cals, Jochen WL, Marjolein JC Schot, Sanne AM de Jong, Geert-Jan Dinant, and Rogier M. Hopstaken: *Point-of-care C-reactive protein testing and antibiotic prescribing for respiratory tract infections: a randomized controlled trial*, The Annals of Family Medicine 8, no. 2, 2010, str. 124-133
- [3] C-reaktívny proteín, dostupné na internete (18.10.2022), [https://sk.wikipedia.org/wiki/C-reakt%C3%ADvny\\_prote%C3%ADn](https://sk.wikipedia.org/wiki/C-reakt%C3%ADvny_prote%C3%ADn)
- [4] HSU, Jonathan, et al: *Antivirals for treatment of influenza: a systematic review and meta-analysis of observational studies*, Annals of internal medicine 156.7, 2012, str. 512-524.
- [5] Huang, Yafang, Rui Chen, Tao Wu, Xiaoming Wei, Aimin Guo: *Association between point-of-care CRP testing and antibiotic prescribing in respiratory tract infections: a systematic review and meta-analysis of primary care studies*, British Journal of General Practice 63, no. 616, 2013
- [6] Kleinbaum, Dietz, Gail: *Logistic regression*, New York, Springer-Verlag, 2002
- [7] Little, Paul, Beth Stuart, Nick Francis, Elaine Douglas, Sarah Tonkin-Crine, Sibyl Anthierens, Jochen WL Cals: *Antibiotic prescribing for acute respiratory tract infections 12 months after communication and CRP training: a randomized trial*, The Annals of Family Medicine 17, no. 2, 2019, str. 125-132
- [8] Martínez-González, Nahara Anani, Ellen Keizer, Andreas Plate, Samuel Coenen, Fabio Valeri, Jan Yvan Jos Verbakel, Thomas Rosemann, Stefan Neuner-Jehle: *Point-of-care c-reactive protein testing to reduce antibiotic prescribing for respiratory tract infections in primary care: Systematic review and meta-analysis of randomised controlled trials*, Antibiotics 9, no. 9, 2020, str. 610

- [9] Piltcher, Otávio Bejzman, et al. : *How to avoid the inappropriate use of antibiotics in upper respiratory tract infections? A position statement from an expert panel*, Brazilian journal of otorhinolaryngology 84, 2018, str. 265-279.
- [10] Tanislav, Christian, and Karel Kostev: *Fewer non-COVID-19 respiratory tract infections and gastrointestinal infections during the COVID-19 pandemic*, Journal of medical virology, vol. 94,1, 2022, str. 298-302
- [11] Thompson, Christopher Glen: *Extracting the variance inflation factor and other multicollinearity diagnostics from typical regression results*, Basic and Applied Social Psychology 39.2, 2017, str.81-90.
- [12] Venables, W. N. and Ripley, B. D.: (2002) *Modern Applied Statistics with S*, Springer, Fourth edition, 2002
- [13] WHO Regional Office for Europe/European Centre for Disease Prevention and Control: *Antimicrobial resistance surveillance in Europe 2022 - 2020 data*, WHO Regional Office for Europe, Copenhagen, 2022

## Príloha A

| Skratka | Vysvetlenie                            |
|---------|----------------------------------------|
| ATB     | Antibiotiká                            |
| CRP     | C-reaktívny proteín                    |
| HDC     | Horné dýchacie cesty                   |
| PZS     | Poskytovateľ zdravotnej starostlivosti |
| NZ      | Nížšia zložka (ordinácia)              |
| PLD     | Praktický lekár pre dospelých          |
| PLDD    | Praktický lekár pre deti a dorast      |
| LSP     | Lekárska služba prvej pomoci           |
| DP      | program DôveraPomáha                   |
| OR      | Pomer šancí (Odds ratio)               |

**Tabuľka 20:** Vysvetlenia používaných skratiek

## Príloha B

| Názov premennej                 | OR   | 2,5% | 97,5% |
|---------------------------------|------|------|-------|
| Intercept                       | 1,21 | 1,16 | 1,26  |
| CRP 3 dni okolo návštevy        | 0,73 | 0,72 | 0,75  |
| Stav v DP - Referencia          | 1,00 | 1,00 | 1,00  |
| Stav v DP - Odišiel skôr        | 1,20 | 1,13 | 1,26  |
| Stav v DP - Prišiel neskôr      | 0,69 | 0,67 | 0,71  |
| Stav v DP - Vždy v DP           | 1,01 | 0,99 | 1,02  |
| Veková kategória lekára do 40   | 0,98 | 0,95 | 1,01  |
| Veková kategória lekára 41-50   | 1,15 | 1,13 | 1,16  |
| Veková kategória lekára 51-60   | 1,10 | 1,09 | 1,11  |
| Veková kategória lekára 61-70   | 1,00 | 1,00 | 1,00  |
| Veková kategória lekára 71+     | 1,18 | 1,16 | 1,21  |
| Kontakt na LSPP Y               | 0,12 | 0,11 | 0,12  |
| Predošlý recept Y               | 1,48 | 1,47 | 1,50  |
| Veková kategória pacienta do 1  | 0,80 | 0,78 | 0,83  |
| Veková kategória pacienta 1-5   | 1,00 | 1,00 | 1,00  |
| Veková kategória pacienta 6-14  | 0,89 | 0,88 | 0,91  |
| Veková kategória pacienta 15-18 | 0,92 | 0,90 | 0,93  |
| Veková kategória pacienta 19-26 | 1,08 | 1,05 | 1,11  |
| Veková kategória pacienta 27-40 | 1,26 | 1,21 | 1,31  |
| Veková kategória pacienta 41-50 | 1,35 | 1,29 | 1,41  |
| Veková kategória pacienta 51-60 | 1,35 | 1,29 | 1,41  |
| Veková kategória pacienta 61-70 | 1,52 | 1,45 | 1,61  |
| Veková kategória pacienta 71+   | 1,29 | 1,21 | 1,38  |

**Tabuľka 21:** Výsledky logistického modelu pre zmiešané odbornosti 1. časť

| Názov premennej                    | OR   | 2,5% | 97,5% |
|------------------------------------|------|------|-------|
| Pohlavie poistenca - Žena          | 1,05 | 1,04 | 1,06  |
| Kraj ambulancie - Košický kraj     | 1,00 | 1,00 | 1,00  |
| Kraj ambulancie - Nitriansky kraj  | 0,86 | 0,85 | 0,88  |
| Kraj ambulancie - Prešovský kraj   | 1,28 | 1,26 | 1,30  |
| Diagnóza pri kontakte J00          | 0,06 | 0,05 | 0,06  |
| Diagnóza pri kontakte J01          | 0,51 | 0,50 | 0,51  |
| Diagnóza pri kontakte J03          | 1,00 | 1,00 | 1,00  |
| Diagnóza pri kontakte J11          | 0,05 | 0,05 | 0,05  |
| Príznak HYP                        | 1,00 | 0,97 | 1,02  |
| Kardiovaskulárne ochorenie         | 1,31 | 1,26 | 1,36  |
| Príznak CHZO                       | 1,09 | 1,03 | 1,16  |
| Príznak AST                        | 0,94 | 0,93 | 0,97  |
| Príznak DIA                        | 1,07 | 1,03 | 1,12  |
| Príznak CHO                        | 0,99 | 0,96 | 1,02  |
| Odbornosť kapitujúceho lekára PLDD | 0,78 | 0,75 | 0,80  |
| Kovidové obdobie Y                 | 0,95 | 0,94 | 0,97  |

**Tabuľka 22:** Výsledky logistického modelu pre zmiešané odbornosti 2. časť

## Príloha C

| Názov premennej                       | OR   | 2,5% | 97,5% |
|---------------------------------------|------|------|-------|
| Intercept                             | 1,39 | 1,32 | 1,45  |
| PLD - CRP 3 dni okolo návštevy        | 0,54 | 0,52 | 0,57  |
| PLD - Stav v DP - Referencia          | 1,00 | 1,00 | 1,00  |
| PLD - Stav v DP - Odišiel skôr        | 1,20 | 1,10 | 1,30  |
| PLD - Stav v DP - Prišiel neskôr      | 0,90 | 0,86 | 0,94  |
| PLD - Stav v DP - Vždy v DP           | 1,11 | 1,09 | 1,14  |
| PLD - Veková kategória lekára do 40   | 0,91 | 0,87 | 0,94  |
| PLD - Veková kategória lekára 41-50   | 1,00 | 0,97 | 1,02  |
| PLD - Veková kategória lekára 51-60   | 1,12 | 1,09 | 1,15  |
| PLD - Veková kategória lekára 61-70   | 1,00 | 1,00 | 1,00  |
| PLD - Veková kategória lekára 71+     | 0,83 | 0,80 | 0,86  |
| PLD - Kontakt na LSPP Y               | 0,29 | 0,27 | 0,32  |
| PLD - Predošlý recept Y               | 1,71 | 1,68 | 1,75  |
| PLD - Veková kategória pacienta 15-18 | 0,57 | 0,46 | 0,71  |
| PLD - Veková kategória pacienta 19-26 | 0,70 | 0,67 | 0,74  |
| PLD - Veková kategória pacienta 27-40 | 0,84 | 0,80 | 0,87  |
| PLD - Veková kategória pacienta 41-50 | 0,88 | 0,85 | 0,92  |
| PLD - Veková kategória pacienta 51-60 | 0,88 | 0,85 | 0,92  |
| PLD - Veková kategória pacienta 61-70 | 1,00 | 1,00 | 1,00  |
| PLD - Veková kategória pacienta 71+   | 0,87 | 0,82 | 0,92  |

**Tabuľka 23:** Výsledky logistického modelu pre PLD 2. časť

| Názov premennej                         | OR   | 2,5% | 97,5% |
|-----------------------------------------|------|------|-------|
| PLD - Pohlavie poistenca - Žena         | 1,11 | 1,09 | 1,14  |
| PLD - Kraj ambulancie - Košický kraj    | 1,00 | 1,00 | 1,00  |
| PLD - Kraj ambulancie - Nitriansky kraj | 1,07 | 1,04 | 1,09  |
| PLD - Kraj ambulancie - Prešovský kraj  | 1,41 | 1,36 | 1,46  |
| PLD - Diagnóza pri kontakte J00         | 0,07 | 0,07 | 0,08  |
| PLD - Diagnóza pri kontakte J01         | 0,59 | 0,58 | 0,61  |
| PLD - Diagnóza pri kontakte J03         | 1,00 | 1,00 | 1,00  |
| PLD - Diagnóza pri kontakte J11         | 0,10 | 0,09 | 0,10  |
| PLD - Príznak HYP                       | 1,00 | 0,97 | 1,03  |
| PLD - Kardiovaskulárne ochorenie        | 1,20 | 1,15 | 1,25  |
| PLD - Príznak CHZO                      | 1,10 | 1,01 | 1,20  |
| PLD - Príznak AST                       | 0,88 | 0,85 | 0,91  |
| PLD - Príznak DIA                       | 1,07 | 1,03 | 1,12  |
| PLD - Príznak CHO                       | 1,01 | 0,98 | 1,04  |
| PLD - Kovidové obdobie Y                | 0,93 | 0,91 | 0,95  |

**Tabuľka 24:** Výsledky logistického modelu pre PLD 2. časť

## Príloha D

| Názov premennej                        | OR   | 2,5% | 97,5% |
|----------------------------------------|------|------|-------|
| Intercept                              | 1,02 | 1,00 | 1,04  |
| PLDD - CRP 3 dni okolo návštevy        | 0,80 | 0,78 | 0,82  |
| PLDD - Stav v DP - Referencia          | 1,00 | 1,00 | 1,00  |
| PLDD - Stav v DP - Odišiel skôr        | 1,30 | 1,20 | 1,40  |
| PLDD - Stav v DP - Prišiel neskôr      | 0,63 | 0,61 | 0,65  |
| PLDD - Stav v DP - Vždy v DP           | 0,96 | 0,94 | 0,97  |
| PLDD - Veková kategória lekára do 40   | 1,12 | 1,08 | 1,16  |
| PLDD - Veková kategória lekára 41-50   | 1,23 | 1,21 | 1,25  |
| PLDD - Veková kategória lekára 51-60   | 1,12 | 1,10 | 1,14  |
| PLDD - Veková kategória lekára 61-70   | 1,00 | 1,00 | 1,00  |
| PLDD - Veková kategória lekára 71+     | 1,40 | 1,36 | 1,43  |
| PLDD - Kontakt na LSPP Y               | 0,08 | 0,08 | 0,08  |
| PLDD - Predošlý recept Y               | 1,38 | 1,36 | 1,40  |
| PLDD - Veková kategória pacienta do 1  | 0,80 | 0,77 | 0,82  |
| PLDD - Veková kategória pacienta 1-5   | 1,00 | 1,00 | 1,00  |
| PLDD - Veková kategória pacienta 6-14  | 0,89 | 0,88 | 0,91  |
| PLDD - Veková kategória pacienta 15-18 | 0,92 | 0,90 | 0,94  |
| PLDD - Veková kategória pacienta 19-26 | 1,08 | 1,06 | 1,11  |
| PLDD - Veková kategória pacienta 27-40 | 1,07 | 0,97 | 1,18  |

**Tabuľka 25:** Výsledky logistického modelu pre PLDD 1. časť

| Názov premennej                          | OR   | 2,5% | 97,5% |
|------------------------------------------|------|------|-------|
| PLDD - Pohlavie poistenca - Žena         | 1,03 | 1,01 | 1,04  |
| PLDD - Kraj ambulancie - Košický kraj    | 1,00 | 1,00 | 1,00  |
| PLDD - Kraj ambulancie - Nitriansky kraj | 0,77 | 0,76 | 0,79  |
| PLDD - Kraj ambulancie - Prešovský kraj  | 1,23 | 1,21 | 1,25  |
| PLDD - Diagnóza pri kontakte J00         | 0,05 | 0,05 | 0,05  |
| PLDD - Diagnóza pri kontakte J01         | 0,48 | 0,47 | 0,49  |
| PLDD - Diagnóza pri kontakte J03         | 1,00 | 1,00 | 1,00  |
| PLDD - Diagnóza pri kontakte J11         | 0,03 | 0,02 | 0,03  |
| PLDD - Kovidové obdobie                  | 0,97 | 0,95 | 0,98  |

**Tabuľka 26:** Výsledky logistického modelu pre PLDD 2. časť