

AMBULANTNÍ PSYCHIATRICKÁ PÉČE POSKYTOVANÁ V ROCE 2024 V ČESKÉ REPUBLICE

Data a další informace o této zprávě jsou dostupné na adrese <https://dostal.vyzkum-psychologie.cz/stat4?i=758>

DATOVÝ SOUBOR

Ministerstvo zdravotnictví zveřejňuje data z Národního registru hrazených zdravotnických služeb (NRHZZ), díky čemuž je možné zkoumat například dostupnost péče v regionech nebo trendy poskytování různých služeb v čase. Výsledky takovýchto analýz jsou následně využitelné v praxi pro plánování a alokaci zdrojů. S tímto účelem vznikla a byla zveřejněna i [datová sada](#), kterou jsem se rozhodla využít v této práci.

Jde o širokou datovou sadu poskytující údaje o počtu pacientů využívajících ambulantní psychiatrickou péči v ČR v letech 2010-2024. Krom roku je evidován také kraj, ve kterém je péče poskytována, a dále pohlaví, věková kategorie a základní diagnóza pacienta. Jde o agregovaná data, což znamená, že vznikla sloučením jednotlivých primárních údajů. Každý jeden záznam („řádek“) sady tak nese údaje o konkrétním jedinci, nýbrž udává celkový počet pacientů v ambulantní psychiatrické péči s danou kombinací výše uvedených proměnných.

Pro účely této práce jsem využila pouze část dané sady. Konkrétně jsem se rozhodla zaměřit na rok 2024. Po očištění dat (odstranění záznamů s chybějícími údaji) čítá má výsledná matice 5768 záznamů.

CÍLE

Cílem prezentované analýzy je prozkoumat využívání ambulantní psychiatrické péče v České republice v roce 2024 a identifikovat případné geografické či demografické rozdíly. Jinými slovy se pokusím zjistit, kde je péče relativně nejvíce či nejméně využívána a zda existují konkrétní skupiny pacientů, které péči využívají častěji či naopak méně často.

METODOLOGIE

Výčet proměnných

Závislou proměnnou v modelu je *počet pacientů*, přičemž detailnější popis této proměnné je k nalezení v další sekci tohoto textu. Model dále pracuje se čtyřmi nezávislými proměnnými neboli faktory, jejichž výčet a popis obsahuje Tabulka 1.

Faktor	Popis	Úrovně faktoru
Kraj	Kraj ČR, ve kterém je poskytována ambulantní psychiatrická péče	14 Hlavní město Praha, Středočeský, Jihočeský, Plzeňský, Karlovarský, Ústecký, Liberecký, Královéhradecký, Pardubický, Vysočina, Jihomoravský, Olomoucký, Zlínský, Moravskoslezský
Pohlaví	Pohlaví pacienta	2 Muž, Žena
Věk	Věková kategorie pacienta	8 (dle číselníku věkových skupin NZIS) 0-19; 20-29; 30-39; 40-49; 50-59; 60-69; 70-79; 80+
Diagnóza	Primární diagnóza, kvůli které je pacient v ambulantní psychiatrické péči	14 (dle MKN 10) F00 a G30, F10, F11-F19, F20-F29, F30-F39 bez F32&F33, F32-F33, F40-F49 bez F42, F42, F50-F59, F60-F61, F62-F69, F70-F79, F80-F99

Tabulka 1: Faktory v modelu

Volba metody analýzy

Při volbě vhodné metody je nutné vzít v potaz, s jakými daty a proměnnými budeme pracovat. Je proto nutné zmínit následující:

V této analýze operuji s jednou závislou proměnnou (počet pacientů), která je početního neboli *count* charakteru. To znamená, že jde o diskrétní proměnnou, která udává, kolikrát specifická událost nastane v určitém fixním časovém intervalu či na daném místě v prostoru. V prezentovaném modelu můžeme za specifickou událost považovat pacienta, který využívá ambulantní psychiatrickou péči.

Jelikož jsou data agregována podle kombinací sledovaných nezávislých proměnných (kraj, pohlaví, věk a diagnóza), vyjadřuje naše závislá proměnná počet událostí, tedy počet ambulantních pacientů v roce 2024, kteří spadají do dané kombinace kategorií. Takovou kombinací by mohlo být například: „žena ve věku 30-39 let využívá ambulantní psychiatrickou péči v pardubickém kraji z důvodu poruchy příjmu potravy“. (Pro zvědavé čtenáře můžu uvést, počet pacientek odpovídajících tomuto konkrétnímu profilu je 35.)

Agregovaná data navíc typicky nemívají normální rozdělení, což je pravdou také pro data užitá v této práci. Nesplnění normality rozdělení, existence jedné závislé proměnné a agregovaná *count* data poukazují na možnost využití metody Poissonovy regrese. Ta je však, jak už název napovídá, zatížena očekáváním Poissonova rozdělení. Jinými slovy očekává, že rozptyl závislé proměnné bude shodný s jejím průměrem, resp. že se tyto dva údaje budou sobě alespoň blížit. Při práci s reálnými daty je však častým jevem tzv. *overdisperze*, tedy situace, kdy rozptyl převyšuje průměr. Jelikož výraznou *overdisperzi* pozoruji i u svého data setu (VAR = 156 585; MEAN = 119,6), Poissonova regrese by neprodukovala spolehlivé výsledky.

Vhodnou alternativou je v tomto případě využití **negativně binomické regrese**, která oproti Poissonově regresi obsahuje dodatečný parametr α , díky kterému je schopná minimalizovat zkreslující vliv *overdisperze* a poskytnout tak robustnější odhady. Výstupem negativně binomického regresního modelu jsou odhady (estimates) také označované jako koeficienty β . Ty bývají pro účely interpretace dále exponencovány, čímž získáme údaj označovaný jako IRR, tedy

incidence rate ratio neboli *relativní míry událostí*. IRR udává poměr očekávaného počtu událostí oproti referenční skupině. Z této hodnoty pak můžeme vypočítat i procentuální rozdíl (relativní nárůst či pokles) mezi sledovanou skupinou a skupinou referenční.

Postup práce s daty

Data jsem prvně očistila o neúplné záznamy a z původního data setu jsem vyselektovala jen zkoumaný rok 2024.

Dalším důležitým krokem bylo vyřešit nerovnoměrnost skupin. Jelikož jednotlivé kraje mají různě velké populace, srovnávat absolutní počty pacientů by nebylo logické. Lze totiž očekávat, že větší kraje budou mít více pacientů čistě z důvodu větší základní populace. Stejně tak genderové rozložení populace není přesně v poměru 1:1. Tento vliv různé velikosti skupin můžeme naštěstí relativně jednoduše kontrolovat pomocí zavedení tzv. *offset* proměnné. Ta zajistí, že nebudeme srovnávat absolutní počty, nýbrž modelovat míru (*rate*) vzhledem k výchozí populaci. V ideálním případě bychom využili údaje o populaci napříč všemi pozorovanými nezávislými proměnnými (tedy např. absolutní počet všech žen ve věku 30-39 let z pardubického kraje trpících poruchou příjmu potravy). Takto detailní data nemám dostupná a jejich získání a následné zapracování do data setu by bylo výrazně nad mé možnosti i nad požadavky této práce. Proto jsem se rozhodla ve svém modelu v rámci *offset* proměnné reflektovat pouze kraj a pohlaví, jelikož tyto údaje jsou snáze dostupné. Údaje o absolutní populaci mužů a žen v jednotlivých krajích k roku 2024 jsem získala z [reportu ČSÚ](#). Prakticky to znamená, že každému záznamu („řádku“ datové tabulky) byla přidělena odpovídající původní populace dle toho, ke kterému kraji a pohlaví se daný záznam vyjadřuje. *Offset* proměnná pak byla jednoduše vypočítána z těchto údajů, jelikož má podobu logaritmické funkce, tedy $\log(\text{populace})$. Tyto úpravy a výpočty byly provedeny v programu MS Excel.

Následně jsem provedla samotnou NB regresi s využitím tohoto *offsetu*. Model byl vytvořen v programu TIBCO Statistica, který je schopen poskytnout pro jednotlivé úrovně faktorů odhady (koeficienty β), jejich horní a dolní hranici intervalu spolehlivosti, standardní chyby, Waldovy statistiky a p-hodnoty. Neuvádí však hodnoty relativní míry událostí (IRR, viz. výše), které jsou důležité pro interpretaci výsledků, protože jsem tyto hodnoty následně dopočítala opět za využití MS Excel. Jak již zaznělo v předchozí sekci tohoto textu, hodnoty IRR lze z koeficientů β vypočítat za využití exponenciální funkce, tedy platí následující vztah:

$$\text{IRR} = e^{\beta}$$

$$\text{IRR Upper CI} = e^{\text{UpperCI}}$$

$$\text{IRR Lower CI} = e^{\text{LowerCI}}$$

Z takto získané hodnoty IRR jsem následně dopočítala ještě procentuální změnu, tedy relativní nárůst nebo pokles, oproti referenční skupině. K tomu slouží jednoduchý vzorec:

$$\text{procentuální změna} = (\text{IRR} - 1) * 100\%$$

VÝSLEDKY A JEJICH INTERPRETACE

Na začátek je záhodno zmínit výsledek testu fitu. Ten nám říká, jak dobře model „sedí“ na pozorovaná data, tedy jestli jsme schopni s jeho pomocí spolehlivě vysvětlit pozorované počty pacientů. K vyjádření goodness-of-fit můžeme standardně použít *deviance* (odchylku) či *Pearsonův chí-kvadrát*, respektive jejich hodnoty vydělené stupni volnosti (DF). Hodnota pohybující se okolo 1 značí dobrý fit. Hodnoty výrazně vyšší než 1 poukazují na možné zkreslení vlivem overdisperze (viz. výše), zatímco na zkreslení vlivem underdisperze upozorní naopak hodnoty výrazně nižší než 1. Výsledky testu fitu prezentuje Tabulka 2.

Parametr	Hodnota
Deviance/DF	1,18
Pearson χ^2 /DF	2,28

Tabulka 2: Test fitu

První parametr naznačuje dobrý fit, jelikož se jeho hodnota blíží 1, druhý parametr je lehce zvýšený. Tato zvýšená hodnota Pearsonova χ^2 poukazuje na zbytkovou overdisperzi, se kterou však zvolená metoda Negativně binomické regrese počítá a minimalizuje její dopad. Fit proto stále můžeme považovat za přijatelný. Výsledné IRR, tedy odhady relativních mír, tak můžeme považovat za spolehlivé.

Než se podíváme na samotné výsledky analýzy, připomeňme ještě, že NB regresní modely využívají referenční skupiny. Hodnoty IRR udávají relativní míru sledovaných událostí (pacientů) v dané skupině oproti skupině referenční. Nejde tedy o absolutní počty pacientů ale o relativní počet pacientů vztažený k velikosti populace. IRR tak vyjadřuje, o kolik procent je relativní počet pacientů v dané skupině vyšší nebo nižší než v referenční skupině. Řečeno prakticky, IRR nám neprozradí například odpověď na otázku „kolik pacientů pochází z Prahy“, nýbrž „o kolik procent je relativní počet pacientů z Prahy vyšší či nižší než relativní počet pacientů z Olomouckého kraje, při zohlednění rozdílné velikosti populace“. Jelikož výsledky tedy udávají srovnání s referenční skupinou, je logické, že tato referenční skupina samotná není v tabulkách s výsledky uváděna. V mém modelu jsou referenční skupiny pro jednotlivé faktory následující: Karlovarský kraj, Ženy, diagnóza F42 (obsedantně-kompulzivní porucha) a věková kategorie 80+, proto tyto úrovně jednotlivých faktorů nejsou uvedeny v tabulkách výsledků.

Všechny sledované proměnné (faktory) byly samozřejmě začleněny společně v tomtéž modelu, pro přehlednost je však budu v následujících tabulkách č. 3-6 prezentovat jejich výsledky zvlášť. Faktory, které nevyšly jako statisticky významné, jsou v tabulkách zaznačeny světlejší barvou pro snadnou orientaci.

Kraj	Odhad (ß)	St. chyba	Waldova statistika	P hodnota	IRR	% změna	IRR Lower CI	IRR Upper CI
Královéhradecký	-0,061	0,060	1,036	0,309	0,940	-6	0,836	1,058
Plzeňský	0,075	0,061	1,511	0,219	1,078	8	0,956	1,215
Pardubický	-0,303	0,062	24,327	0,000	0,738	-26	0,654	0,833
Olomoucký	0,273	0,058	21,807	0,000	1,314	31	1,172	1,473
Zlínský	-0,197	0,066	8,953	0,003	0,821	-18	0,722	0,934
Hl. m. Praha	0,780	0,056	196,701	0,000	2,181	118	1,956	2,432
Ústecký	0,059	0,060	0,976	0,323	1,061	6	0,943	1,193
Vysočina	-0,180	0,062	8,470	0,004	0,835	-16	0,740	0,943
Jihomoravský	0,257	0,059	19,223	0,000	1,293	29	1,153	1,450
Středočeský	-0,072	0,060	1,439	0,230	0,930	-7	0,827	1,047
Liberecký	-0,225	0,062	13,246	0,000	0,798	-20	0,707	0,901
Jihočeský	-0,102	0,061	2,781	0,095	0,903	-10	0,802	1,018
Moravskoslezský	0,235	0,058	16,201	0,000	1,265	26	1,128	1,418

Tabulka 3: Výsledky – Kraj

Z Tabulky 3 můžeme vyčíst, že při srovnání jednotlivých krajů můžeme pozorovat statisticky významný rozdíl ($p < 0,05$) u osmi z nich. Nejnižší relativní počet pacientů využívá ambulantní psychiatrickou péči v Pardubickém kraji. IRR pro tento kraj odpovídá hodnotě 0,738 (95% CI [0,654; 0,833]). Mohli bychom tedy říci, že se zde léčí přibližně o 26 % méně lidí než v kraji Karlovarském. Naopak v Praze péči vyhledává přibližně o 118 % více občanů než v Karlovarském kraji, tedy více než dvojnásobek. Náš Olomoucký kraj na tomto žebříčku zaujímá druhé místo, zdejší obyvatelé jsou v ambulantní péči psychiatra o 31 % častěji než jejich karlovarské protějšky. Rozdílné velikosti jednotlivých krajů přitom byly zohledněny tím, že celková populace krajů byla použita jako offset proměnná, jak popisují výše. Data, která máme k dispozici, samozřejmě neumožňují vyvozovat jakékoli závěry o tom, proč se relativní míra vyhledávání psychiatrické péče takto zásadně liší mezi jednotlivými kraji. Můžeme však spekulovat a uvažovat „selským rozumem“. Pravděpodobně zde bude působit celá řada faktorů a jejich kombinací. Mezi nimi může být například sociodemografické složení populace i ekonomická síla regionu, které se mohou mimo jiné promítnout do toho, jak moc je v dané oblasti téma psychického zdraví (de)stigmatizované. Stejně tak určitě zásadní roli hraje hustota a kvalita sítě dostupných zdravotnických služeb, u které můžeme očekávat, že bude větší ve velkých městech a naopak menší v málo obydlených oblastech.

Diagnóza	Odhad (ß)	St. chyba	Waldova statistika	P hodnota	IRR	% změna	IRR Lower CI	IRR Upper CI
F80-F99	-0,574	0,035	267,384	0,000	0,563	-44	0,526	0,603
F40-F49 bez F42	2,145	0,067	1032,586	0,000	8,541	754	7,494	9,735
F30-F39 bez F32&F33	-0,603	0,077	61,072	0,000	0,547	-45	0,470	0,636
F20-F29	0,483	0,073	43,785	0,000	1,620	62	1,404	1,869
F32-F33	1,238	0,072	296,257	0,000	3,450	245	2,996	3,972
F00 a G30	1,628	0,074	483,547	0,000	5,093	409	4,405	5,888
F60-F61	-0,128	0,075	2,924	0,087	0,880	-12	0,760	1,019
F50-F59	-0,179	0,069	6,798	0,009	0,836	-16	0,730	0,956
F70-F79	-0,048	0,066	0,519	0,471	0,954	-5	0,838	1,085
F11-F19	-0,776	0,074	108,959	0,000	0,460	-54	0,398	0,532
F10	-0,315	0,078	16,278	0,000	0,730	-27	0,626	0,851
Ostatní	-0,630	0,068	86,178	0,000	0,532	-47	0,466	0,608
F62-F69	-1,282	0,077	277,607	0,000	0,277	-72	0,239	0,323

Tabulka 4: Výsledky – Diagnóza

Obdobně vyčteme z Tabulky 4 výsledky sledovaných parametrů napříč jednotlivými diagnostickými skupinami. Zde se statisticky významný vztah ukázal u všech krom skupin F60-F61 a F70-79. Nalezení výrazných rozdílů je u tohoto faktoru logicky očekávatelné, jelikož různé diagnózy mají ze své podstaty různou incidenci uvnitř populace. Interpretace těchto výsledků proto pravděpodobně nepřinese závratné závěry, nicméně pro úplnost modelu byl tento faktor zohledněn a proto je vhodné jeho výsledky taktéž prezentovat. Poukazují na to, že nejčastější problémy, které pacienti v ambulantní péči v roce 2024 řešili, spadají do diagnostické kategorie F40-F49 bez F42, tedy že se jedná o poruchy neurotické, stresové a somatoformní (mimo OCD). Další výrazně zastoupenou skupinu tvoří demence u Alzheimerovy nemoci (F00 a G30), kterou u sledovaných pacientů zaznamenáváme dokonce pětikrát častěji než obsedantně-kompulzivní poruchu, která je zde referenční skupinou. Naopak nejméně často se sledovaní pacienti potýkali s poruchami z okruhu F62-69 (poruchy osobnosti a chování u dospělých).

Věk	Odhad (β)	St. chyba	Waldova statistika	P hodnota	IRR	% změna	IRR Lower CI	IRR Upper CI
0-19	-0,951	0,032	900,672	0,000	0,386	-61	0,363	0,411
20-29	-0,017	0,050	0,118	0,732	0,983	-2	0,890	1,085
30-39	0,169	0,053	10,335	0,001	1,184	18	1,068	1,313
40-49	0,413	0,054	58,479	0,000	1,511	51	1,359	1,679
50-59	0,354	0,055	41,352	0,000	1,424	42	1,279	1,586
60-69	0,205	0,057	12,991	0,000	1,228	23	1,098	1,373
70-79	0,057	0,059	0,920	0,338	1,058	6	0,943	1,188

Tabulka 5: Výsledky – Věk

Rozdíly napříč věkovými kategoriemi, prezentované v Tabulce 5, jsou taktéž do jisté míry očekávatelné. Obecně ve zdravotnictví sledujeme trend nárustu potřeby odborné péče s přibývajícím věkem, jelikož úbytek sil, zhoršení tělesných funkcí a nárůst chorobnosti je přirozeným doprovodem stárnutí. Považuji taktéž za záhodné zde připomenout, že data nemají reflektovat prevalenci duševních nemocí v jednotlivých věkových skupinách, nýbrž počet (resp. míru) pacientů daného věku, kteří se dostanou do odborné ambulantní péče. Taktéž zde může působit celá řada faktorů, které nemáme možnost sledovat, jako například to, že děti či senioři mohou mít apriorně ztížený přístup k odborné péči, jelikož mnohdy bývají závislí na pečující osobě a nemusí proto mít možnost odbornou péči vyhledat sami ze své iniciativy. Stejně tak nutno upozornit na fakt, že věk nebyl zohledněn v offset proměnné (viz. výše), což znamená, že model nebere v úvahu různé velikosti jednotlivých věkových kategorií uvnitř populace, což může vést ke zkreslení výsledků. S jejich interpretací by se proto mělo zacházet spíše opatrně. Nicméně pro didaktické účely můžeme i zde uvést možný výklad některých hodnot z tabulky. Naše výsledky by naznačovaly, že relativně nejméně často se do ambulantní péče dostávají děti a dospívající ve věku do 19 let, kteří tyto služby využívají přibližně o 61 % méně než senioři ve věku 80+ let, kteří slouží jako referenční skupina. Jinými slovy senioři jsou v ambulantní péči psychiatra přibližně 2,6 krát častěji lidé mladší 19 let. Zato mezi čtyřicátníky pozorujeme zhruba padesátiprocentní nárůst ve srovnání se zmíněnými seniory a mohli bychom tedy říct, že jsou pacienty psychiatrických ambulancí zhruba 1,5 krát častěji.

Pohlaví	Odhad (β)	St. chyba	Waldova statistika	P hodnota	IRR	% změna	IRR Lower CI	IRR Upper CI
Muž	0,075	0,017	20,164	0,000	1,078	8	1,043	1,114

Tabulka 6: Výsledky – Pohlaví

Poslední sledovanou proměnnou v modelu je pohlaví, výsledky analýzy pro tento faktor naleznete v Tabulce 6. Jak čísla napovídají, pohlaví představuje statisticky významný prediktor v našem

modelu ($p < 0,001$). Hodnota relativní míry událostí se rovná 1,078 (95% CI [1,043;1,114]), tedy mezi muži pozorujeme vyšší relativní míru pacientů než mezi ženami. To znamená, že dle našich dat muži využívali v roce 2024 ambulantní psychiatrickou péči 1,078 krát častěji než ženy, jinými slovy byl počet mužských pacientů přibližně o 8 % vyšší. Nevyrovnané zastoupení jednotlivých pohlaví v populaci bylo zohledněno použitím offsetu.

MOŽNÁ DOPORUČENÍ PRO DALŠÍ PRÁCI

Ve své práci jsem se zaměřila na rok 2024 a sledovala hlavní efekty vybraných faktorů. To však není jediný způsob, jak k analýze přistoupit. Na tuto zprávu by mohli další spolužáci potenciálně navázat a zkusit například sledovat trend využívání ambulantní psychiatrické péče v České republice v čase. Další informace by mohlo přinést také přidání interakcí mezi faktory. Zajímavé by mohlo být například sledovat interakce mezi kraji a diagnózami a popsat tak, zda jsou některé druhy psychických potíží relativně častěji řešeny v konkrétních oblastech naší země než v jiných. Stejně tak diagnóza a rok nebo věk a rok mají potenciál tvořit zajímavé interakce. Kdyby někdo ze spolužáků byl inspirován touto zprávou a chtěl v modelování pokračovat, mohu tento datový set NRHZS plně doporučit, jelikož je opravdu bohatý na informace a jistě poskytne mnoho dalších možných cest pro analýzu.

Závěrečná poznámka autorky

V úvodu této práce nezmiňuji teoretické zakotvení tématu, jelikož jsem se rozhodla prozkoumat reálná data o využívání / poskytování ambulantní psychiatrické péče v České republice. Nešlo o ověřování hypotéz, mé závěry se nevyjadřují k žádné psychologické teorii. Stejně tak v práci neoperuji s žádným specifickým fenoménem, který by dle mého názoru bylo nutné definovat a představit čtenářům za účelem pochopení konceptu. Vzhledem k délce finální zprávy jsem se proto rozhodla teoretický úvod vypustit a věnovat raději více prostoru vysvětlení metody Negativně binomické regrese, se kterou nemusí být čtenáři seznámeni a jejíž pochopení pro ně může být, doufám, přínosné.