

KDO SEDÍ V ČEKÁRNĚ? PROMĚNY GENDEROVÉ A VĚKOVÉ STRUKTURY PSYCHIATRICKÝCH PACIENTŮ V ČR

V této práci se podíváme na to, jak se za posledních 18 let proměnilo složení pacientů v českých psychiatrických ambulancích. Pracujeme s daty z Národního zdravotnického informačního systému (NZIS), konkrétně s výkazem A (MZ) 1-01: Psychiatrie (A013), který zpracovává ÚZIS ČR (Večeřová et al., 2025). Jsou to agregované počty pacientů za jednotlivé roky 2007 až 2024, rozdělené podle diagnóz, pohlaví a věku. Důležité je, že jde o kompletní populační data — výkaz povinně vyplňují všichni poskytovatelé ambulantní psychiatrické péče v ČR.

Na tato data aplikujeme binomální logistickou regresi a položíme si dvě výzkumné otázky:

Výzkumná otázka 1: Mění se podíl žen mezi léčenými pacienty v čase a liší se tento trend mezi diagnostickými skupinami?

Výzkumná otázka 2: Mění se podíl dětí a adolescentů (0–19 let) v čase a liší se tento trend mezi diagnostickými skupinami?

Ze spektra dostupných diagnostických kategorií jsme vybrali sedm skupin, které splňují tři kritéria: dostatečně velké počty pacientů pro stabilní odhady proporcí (řádově tisíce ročně), klinickou relevanci jakožto primárně psychiatrické diagnózy a smysluplnou variabilitu v genderové i věkové struktuře. Vyřazeny tak byly kategorie s nízkými počty (F64–F66, F99), nepsihiatrické diagnózy zahrnuté ve výkazu z historických důvodů (N46, N97, Q53–Q55) a kategorie s věkově determinovanou strukturou („dětské“ diagnózy) (F70–F79, F80–F98), u nichž by analýza věkového trendu byla tautologická.

ANALÝZA

K analýze jsme zvolili binomální logistickou regresi. Naše závislá proměnná není klasické ano/ne u jednoho člověka, ale proporce — tedy poměr (kolik žen z celkového počtu

pacientů, kolik mladých z celku). Pro takový typ dat je binomální logistická regrese s logit vazbovou funkcí standardní volba (McCullagh & Nelder, 1989).

Hlavním výstupem, který budeme interpretovat, je poměr šancí (odds ratio, OR). Když má prediktor Rok $OR = 1,05$, znamená to, že s každým dalším rokem se šance, že pacient bude žena (resp. že bude ve věku 0–19 let), zvyšuje 1,05krát — tedy o 5 %. Pokud je OR menší než 1, podíl naopak klesá. U interakcí OR říká, o kolik se roční změna u dané diagnózy liší od referenční skupiny.

Protože každé pozorování v našem modelu zastupuje tisíce až stovky tisíc pacientů, je třeba ověřit, zda binomální model nepodhodnocuje variabilitu v datech — tedy zda se nevyskytuje takzvaná overdispérze. Tu diagnostikujeme pomocí disperzního parametru, který vypočítáme jako podíl Pearsonovy χ^2 statistiky a reziduálních stupňů volnosti. Pokud je disperzní parametr výrazně vyšší než 1, znamená to, že skutečná variabilita dat je větší, než model předpokládá, a standardní chyby je třeba korigovat.

Rok byl centrován na hodnotu 2015, která přibližně odpovídá středu sledovaného období (přesný aritmetický průměr krajních let je 2015,5). Centrování zajišťuje, že intercept má interpretovatelný význam — odpovídá odhadované proporcii v referenční diagnostické skupině přibližně uprostřed sledovaného období.

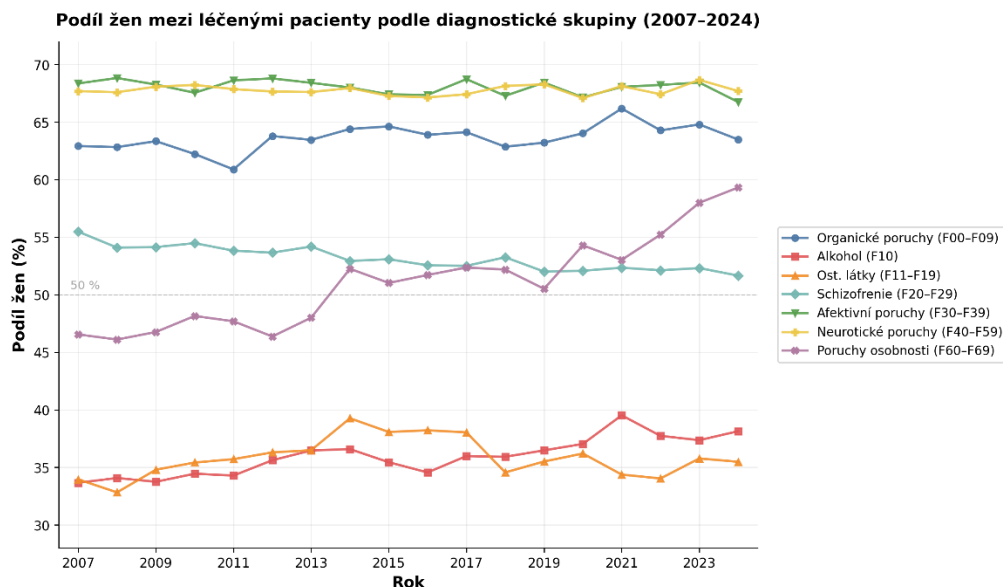
VÝSLEDKY

Než se podíváme na jednotlivé analýzy, je třeba zmínit jednu důležitou věc. V obou modelech se ukázala výrazná overdispérze — skutečná variabilita v datech byla podstatně větší, než kolik binomální model předpokládá. Disperzní parametr činil 17,42 (Analýza 1) a 82,43 (Analýza 2). Co to znamená v praxi? Standardní chyby z původního binomálního modelu byly příliš malé a p -hodnoty příliš optimistické. Proto všechny výsledky níže uvádíme po kvazibinomální korekci — standardní chyby jsou vynásobeny odmocninou disperzního parametru (faktor 4,174 u Analýzy 1 a 9,079 u Analýzy 2), čímž získáváme realističtější intervaly spolehlivosti a p -hodnoty (Agresti, 2013).

ANALÝZA 1: PODÍL ŽEN MEZI LÉČENÝMI PACIENTY

Celkově tvoří ženy kolem 60 % psychiatrických pacientů a tento podíl se za 18 let prakticky nezměnil (59,8 % v roce 2007, 59,2 % v roce 2024). Jenže to je průměr přes velmi odlišné diagnózy — a právě ty rozdíly jsou zajímavé (viz Obrázek 1).

Obrázek 1: Podíl žen mezi léčenými pacienty



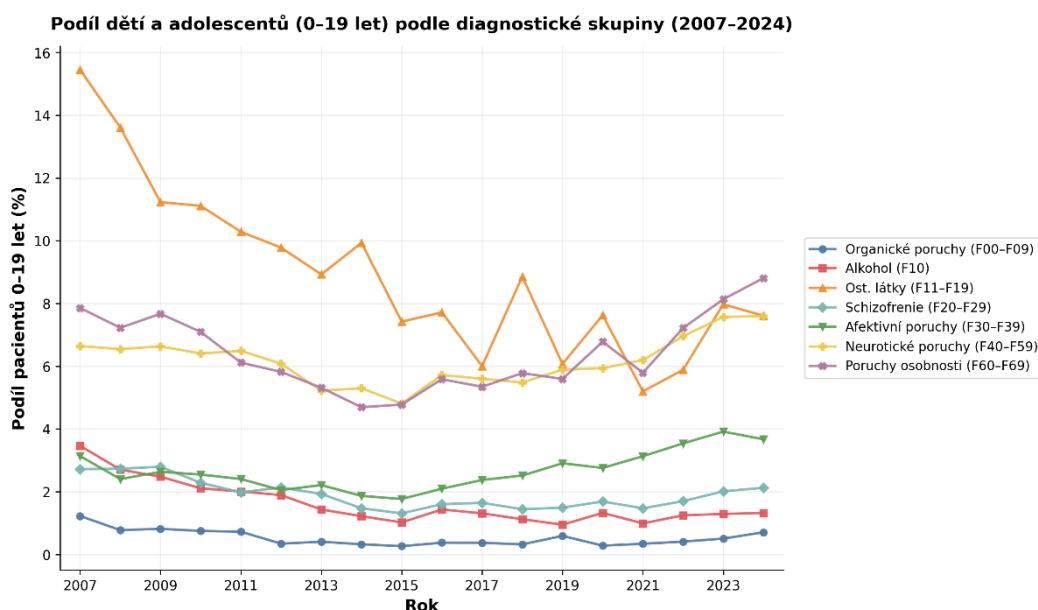
Model ukazuje dvě věci. Za prvé, diagnostické skupiny se ve výchozím podílu žen zásadně liší. Afektivní a neurotické poruchy jsou výrazně „ženské“ diagnózy — ženy tvoří přibližně dvě třetiny pacientů (OR = 1,219 resp. 1,202). Naopak u poruch vyvolaných alkoholem a ostatními látkami tvoří ženy jen třetinu (OR = 0,319 u obou). Schizofrenie a organické poruchy leží někde uprostřed.

Za druhé — a to je hlavní výsledek — jednotlivé diagnózy se vyvíjejí opačnými směry. Nejdramatičtější změna nastala u poruch osobnosti (F60–F69): podíl žen vzrostl z 46,5 % na 59,3 %, tedy o téměř 13 procentních bodů za 18 let (OR interakce = 1,024; $p < ,001$). To je s přehledem nejsilnější trend v celém datasetu. Roste i podíl žen u poruch vyvolaných alkoholem — z 33,7 % na 38,1 % (OR = 1,007; $p = ,014$) — což odpovídá mezinárodně popisovanému sblížení alkoholové konzumace mezi pohlavími. Opačným směrem jde schizofrenie, kde podíl žen klesá z 55,5 % na 51,7 % (OR = 0,988; $p < ,001$). U afektivních a neurotických poruch podíl žen sice zůstává vysoký, ale mírně se snižuje — jinými slovy, muži se v těchto diagnózách pozvolna „dohánějí“.

ANALÝZA 2: PODÍL DĚTÍ A ADOLESCENTŮ (0–19 LET)

Děti a dospívající tvoří v psychiatrických ambulancích malý, ale důležitý díl — a právě u nich se ukazuje, jak zásadní je korekce na overdispersi. Disperzní parametr v této analýze dosáhl hodnoty 82,43, což je zhruba pětkrát více než u Analýzy 1. V praxi to znamená, že řada trendů, které nekorigovaný model ukazoval jako vysoce průkazné, po korekci významnost ztrácí (viz Obrázek 2,).

Obrázek 2: Podíl dětí a adolescentů (0–19 let) mezi léčenými pacienty



Diagnózy se v podílu mladých pacientů liší dramaticky — mnohem více než u pohlaví. U organických poruch (F00–F09) tvoří věková skupina 0–19 let jen asi půl procenta, což dává smysl v této věkové kategorii. Naopak u poruch vyvolaných ostatními psychoaktivními látkami (F11–F19) tvořili mladí v roce 2007 přes 15 % pacientů, u poruch osobnosti a neurotických poruch kolem 7–8 %.

Co se děje v čase? Statisticky průkazný nárůst podílu mladých pacientů se po kvazibinomální korekci potvrdil pouze u dvou skupin: u afektivních poruch (OR interakce = 1,070; $p = ,006$) a u neurotických poruch (OR = 1,050; $p = ,035$). U depresí a úzkostí tedy přibývá mladých pacientů rychleji než u ostatních diagnóz — podíl 0–19letých u afektivních poruch vzrostl z 3,1 % na 3,7 %, u neurotických z 6,6 % na 7,6 %. Jsou to malá čísla, ale trend je konzistentní a odpovídá tomu, co se píše v zahraniční literatuře o nárůstu psychických obtíží u mladé generace.

U poruch osobnosti ($OR = 1,047$; $p = ,067$) je trend těsně za hranicí statistické významnosti — podíl mladých sice vzrostl (z 7,9 % na 8,8 %), ale nemůžeme vyloučit, že jde o náhodu.

A pak je tu překvapení: u poruch spojených s alkoholem i ostatními látkami deskriptivní data ukazují výrazný pokles podílu mladých (u F10 z 3,5 % na 1,3 %; u F11–F19 z 15,5 % na 7,6 %) — jenže po korekci na overdisperzi ani jeden z těchto trendů nedosahuje statistické významnosti ($p = ,439$ resp. $p = ,732$). Variabilita mezi roky je tak velká, že model nedokáže spolehlivě odlišit trend od šumu. Tady je tedy potřeba být opatrný: popisně pokles vidíme, ale statisticky ho potvrdit nemůžeme.

KVALITA MODELU

Oba modely jsou jako celek statisticky průkazné. Protože pracujeme s kvazibinomální korekcí, používáme místo klasického χ^2 -testu F -test, který zohledňuje overdisperzi — v obou případech je vysoce signifikantní ($p < ,001$).

U pseudo- R^2 je potřeba být opatrný. Cox & Snell i Nagelkerke dosahují hodnoty 1,000, což je artefakt agregovaných dat s obrovskými jmenovateli — tyto ukazatele v našem případě nemají interpretační hodnotu. McFaddenovo R^2 (McFadden, 1974) je smysluplnější: činí 0,030 (Analýza 1) a 0,048 (Analýza 2). To vypadá nízko, ale u McFaddenova R^2 se i hodnoty kolem 0,2 považují za vynikající fit (McFadden, 1978) — naše nízké hodnoty odrážejí to, že proporce se mezi buňkami liší relativně málo, takže i model zachycující reálné trendy vysvětluje jen malý zlomek celkové variability.

Reziduální deviance (1 950,7 resp. 9 174,4 při $df = 112$) výrazně převyšuje stupně volnosti, což znovu potvrzuje overdisperzi.

ZÁVĚR

Na těchto datech je zajímavé hlavně to, jak moc se liší příběh, který vidíme na první pohled, od toho, co nám řekne statistický model. Když se podíváme na celkový podíl žen v psychiatrické péči, vypadá to stabilně — kolem 60 % po celých 18 let. Jenže pod tímto průměrem se skrývají protichůdné trendy: u poruch osobnosti podíl žen raketově roste (o téměř 13 procentních bodů), zatímco u schizofrenie naopak klesá.

Ještě poučnější je srovnání obou analýz. U genderových trendů (Analýza 1) většina efektů přežila kvazibinomální korekci — overdisperze tam byla sice přítomná, ale trendy byly dostatečně silné. U věkových trendů (Analýza 2) korekce smetla ze stolu víc než polovinu interakcí, které nekorigovaný model ukazoval jako vysoce signifikantní. To je dobrá připomínka toho, proč je kontrola overdisperze u agregovaných dat naprosto zásadní. Kdybychom ji neprovedli, tvrdili bychom například, že podíl mladých u látkových závislostí statisticky významně klesá — přitom po korekci to říct nemůžeme.

Metodicky stojí za zmínku i volba binomální logistické regrese na agregovaných počtech. Zároveň ale ukazuje svá omezení — s rostoucí velikostí čitatele i jmenovatele (tisíce až statisíce pacientů na buňku) se jakýkoliv, byť nepatrný odklon od binomálního rozložení projeví jako masivní overdisperze. Disperzní parametr 82 u Analýzy 2 znamená, že skutečná variabilita dat je přibližně 80krát větší, než model očekává. V praxi by proto stálo za úvahu použít přímo kvazibinomální rodinu v GLM nebo betabinomální model, případně pracovat s GEE, které by explicitně modelovaly korelační strukturu v čase.

Data samotná mají rovněž své zvláštnosti. Roky 2011 a 2014 vykazují u některých diagnóz (zejména F00–F09) nápadné skoky, které pravděpodobně souvisejí se změnami v metodice sběru výkazů, nikoli s reálnou změnou v počtu pacientů. Tyto body model nijak neošetřuje — nepoužili jsme ani dummy proměnné pro tyto roky, ani robustní odhady. V budoucí analýze by stálo za to tyto roky buď vyloučit, nebo explicitně modelovat jako strukturální zlomy. Rovněž by bylo přínosné doplnit regionální rozměr — data za kraje jsou k dispozici alespoň za rok 2024 a umožnila by testovat, zda jsou pozorované trendy konzistentní napříč regiony, nebo zda je celostátní průměr tažen jedním či dvěma kraji.

Na závěr ještě osobní poznámka k tomu, jaké to je s těmito daty prakticky pracovat. Na první pohled vypadá soubor od ÚZIS lákavě — máte k dispozici 18 let dat za celou republiku, stovky řádků, všechno pěkně v Excelu. Jenže jakmile si sednete k analýze, zjistíte, že je to úplně jiný svět než klasický dotazníkový výzkum. Nemáte jednotlivce, nemáte raw data, nemáte žádný codebook s popisem proměnných. Učebnice logistické regrese přitom v drtivé většině ukazují příklady na individuálních datech (pacient měl infarkt ano/ne), takže než člověk vůbec přijde na to, jak správně zadat model na proporcích a co je to offset nebo disperzní parametr, stráví dost času googlováním a zkoušením. Další nepříjemností je formát samotného Excelu. Než se dostanete k samotné analýze, musíte data ručně přestrukturovat, což je pracné a náchylné k chybám. A konečně — u některých let a proměnných jsou záhadné skoky nebo chybějící hodnoty (podkategorie demencí, sebepoškození, poruchy příjmu potravy začínají až od

pozdějších let), aniž by metodický popis jednoznačně říkal, kdy a proč se struktura výkazu změnila. Pracujete tedy s daty, u kterých si nemůžete být stoprocentně jistí, že změna v čísle odráží změnu v realitě, a ne změnu ve formuláři.

ZDROJE

Agresti, A. (2013). *Categorical data analysis* (3rd ed.). Wiley.

McFadden, D. (1974). Conditional logit analysis of qualitative choice behavior. In P. Zarembka (Ed.), *Frontiers in econometrics* (pp. 105–142). Academic Press.

McFadden, D. (1978). Quantitative methods for analyzing travel behaviour of individuals. In D. A. Hensher & P. R. Stopher (Eds.), *Behavioural travel modelling* (pp. 279–318). Croom Helm.