

Predikce fluktuace zdravotnických pracovníků

Úvod

Fluktuace zaměstnanců je klíčovým problémem v mnoha organizacích, a především ve zdravotnictví má tento jev závažné dopady. Fluktuaci pracovníků můžeme definovat jako opuštění pracovního trhu v důsledku emigrace, dobrovolného odchodu například do jiného sektoru, nemoci, úmrtí nebo odchodu do důchodu. Jde o faktor, který mohou vlády přímo ovlivnit zaváděním různých strategií zaměřených na motivaci a udržení pracovníků ve zdravotnictví. Odchod zaměstnanců ve zdravotnických institucích může vést k přetížení zbytku personálu, poklesu kvality péče, zvýšeným nákladům na nábor a školení nových pracovníků a k celkové nestabilitě pracovního prostředí (Castro Lopes et al., 2017).

Míra odchodu se liší napříč různými zeměmi podle regionu, polohy městských či venkovských oblastí, typu zdravotnického zařízení, pracovní kategorie nebo dokonce věku pracovníka. Zvláštním problémem je udržení zdravotnických pracovníků v odlehlých nebo venkovských oblastech, což představuje výzvu pro vyspělé země (Schoo et al., 2005).

Existují tři opakující se faktory přispívající k odchodu zdravotníků ze zaměstnání. První jsou **faktory související s profesí**, kterými mohou být například kariérní postup, pracovní spokojenost, podpora a profesní růst. Dále zde hrají roli **systemové faktory**, například odměňování, personální problémy, klinická praxe, péče o pacienty a pracovní zátěž. A jako poslední je důležité zmínit **individuální faktory**, například potřeba uznání, potřeba změny a vyhoření (Yeoh et al., 2024).

Výsledky studie o odchodu pracovníků v podpůrných zdravotnických profesích naznačují vyšší míru odchodu u praktických lékařů, zubařů a zdravotních sester ve srovnání s jinými zdravotnickými povoláními (Pretorius et al., 2016). Studie, která analyzovala 51 akademických studií o mírách odchodu zdravotnických pracovníků, zjistila relativně nízké míry odchodu u porodních asistentek (4,5 % – 16 %) a lékařů (1,7 % – 15 %) ve srovnání se zdravotními sestrami, kde se míra odchodu pohybovala v rozmezí 4,9 % – 44,3 % (Castro Lopes et al., 2017).

Máme k dispozici soubor¹ čítající 796 zdravotnických pracovníků z porodnického oddělení. U těchto pracovníků víme, zda ke fluktuaci došlo (1), či nedošlo (0). Protože tato závislá proměnná je binární, k predikci fluktuace vytvoříme model založený na logistické regresi. Z datového souboru budou pomocí numerických metod získány parametry tohoto modelu.

Popis proměnných datového souboru:

Závislá proměnná:

- **Attrition:** Predikce fluktuace zdravotnického pracovníka
 - **0** = menší šance, že dojde k fluktuaci
 - **1** = větší šance, že dojde k fluktuaci

Nezávislé proměnné:

- **Age:** Věk zaměstnance
- **Gender:** Pohlaví zaměstnance (0 = žena, 1 = muž)
- **DistanceFromHome:** Vzdálenost pracoviště od domova zaměstnance

¹ Data a další informace o této zprávě jsou dostupné na adrese <https://dostal.vyzkum-psychoologie.cz/stat4?i=463>

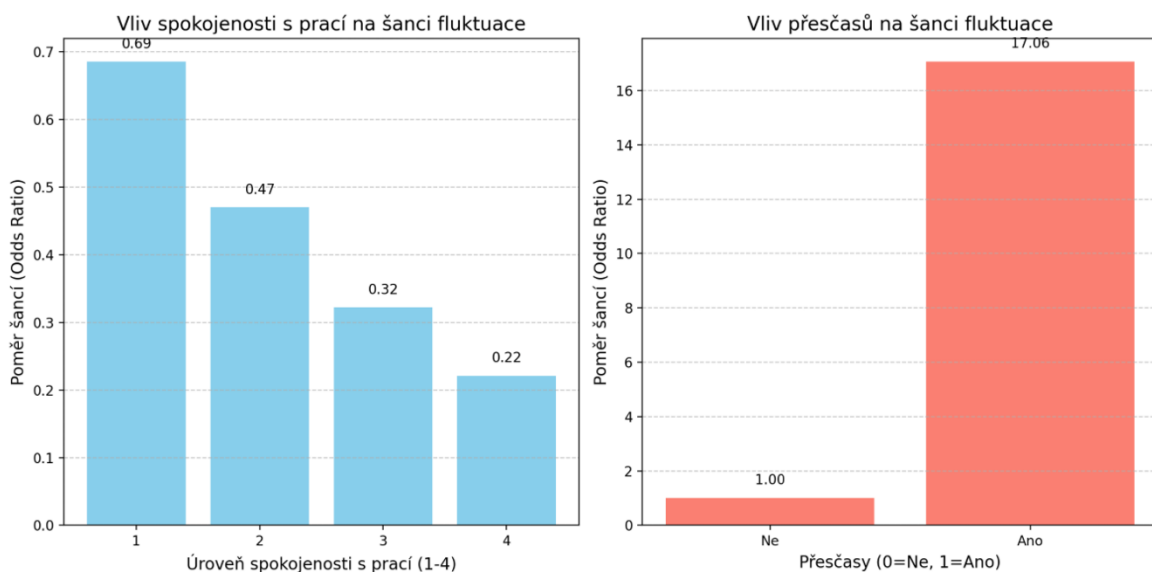
- **JobSatisfaction:** Hodnocení spokojenosti se zaměstnáním
 - 1 = Velmi nespokojený
 - 2 = Spíše nespokojený
 - 3 = Spíše spokojený
 - 4 = Spokojený
- **MonthlyIncome:** Měsíční příjem zaměstnance
- **TotalWorkingYears:** Počet let strávených v zaměstnání
- **OverTime:** Zda zaměstnanec pracuje přesčasy
 - 0 = Nepracuje přesčasy
 - 1 = Ano, pracuje přesčasy

Výsledky binární logistické regrese

Binární logistická regrese byla vypočítána v programu Jamovi (verze 2.6.24). Výsledky jsou uvedeny v tabulce 1. V logistické regresi se odhadnuté parametry modelu (tzv. β koeficienty) neinterpretují přímo, protože se vyskytují jako exponenty v logistické funkci. Místo toho se často používá poměr šancí (odds ratio, OR), který se vypočítá jako e^β , kde e je Eulerovo číslo (přibližně 2,71). Poměr šancí nám ukazuje, jak změna dané nezávislé proměnné ovlivňuje pravděpodobnost výskytu zkoumaného jevu – v našem případě fluktuace zaměstnanců.

Aplikujeme-li to na náš model, můžeme vypočítat poměr šancí pro jednotlivé významné proměnné. Čím vyšší je spokojenost zaměstnance, tím nižší je pravděpodobnost fluktuace. Zvýšení spokojenosti o jednu úroveň snižuje šanci na odchod přibližně 1,46krát (neboli o 31,5 %). Zaměstnanci, kteří pracují přesčas, mají přibližně 17krát vyšší šanci, že odejdou. Graficky je to znázorněno na obrázku 1.

Obrázek 1: Grafy vlivu spokojenosti s prací a práce s přesčasy na šanci fluktuace



Tabulka 1: Odhad parametrů modelu

Prediktor	Odhad parametru	St. Chyba	Z	p
Intercept	2.2000	0.7704	2.856	0.004
Age	-0.0864	0.0226	-3.830	<.001
DistanceFromHome	0.0230	0.0169	1.365	0.172
JobSatisfaction	-0.3775	0.1188	-3.178	0.001
MonthlyIncome	-3.88e-4	1.01e-4	-3.853	<.001
TotalWorkingYears	-0.0375	0.0397	-0.945	0.344
Gender	-0.1536	0.2771	-0.554	0.579
OverTime	2.8368	0.2923	9.705	<.001

Nyní se podíváme, které proměnné jsou statisticky významné, tedy u kterých lze zamítnout nulovou hypotézu parametru $\beta_i = 0$. **Věk, spokojenost v práci, měsíční příjem a práce s přesčasy mají statisticky významný vliv na fluktuaci zaměstnanců**, protože u těchto proměnných je p-hodnota nižší než 0,005 viz. tabulka 1. Zatímco vzdálenost od domova, celkový počet pracovních let a pohlaví se jako významné faktory neprojevíly.

Tabulka 2: Ukazatelé kvality modelu

Model	Deviance	AIC	R ² _{McF}	R ² _{CS}	R ² _N	χ^2	df	p
1	383	399	0.355	0.233	0.443	211	7	<.001

Statistiku kvality modelu nám ukazuje tabulka 2. P-hodnota je velmi nízká ($p < 0,001$), což znamená, že náš model je statisticky významný a dobře predikuje fluktuaci zdravotnických pracovníků. Ukazatelé R² jsou analogií koeficientu determinace známého z lineárních modelů. McFaddenovo R² dosahuje hodnoty 0,355, což naznačuje středně silnou vysvětlovací schopnost modelu. Koeficient R² podle Coxe a Snella je 0,233, přičemž tento ukazatel nemůže nabývat hodnoty 1, což koriguje Nagelkerkeho R², které v tomto případě dosahuje 0,443. Na základě tohoto ukazatele můžeme říci, že model vysvětluje přibližně 44 % rozptylu závislé proměnné.

Tabulka 3: Ukazatel kvality predikce modelu

Přesnost	Specifická	Sensitivita
0.915	0.977	0.469

Prediktivní schopnosti modelu ukazuje tabulka 3. Celková přesnost modelu dosahuje 91,5 %, což znamená, že model správně klasifikuje většinu případů. Specificita, tedy schopnost správně identifikovat pracovníky, u kterých k fluktuaci nedojde, je velmi vysoká (97,7 %). Naopak senzitivita, tedy schopnost modelu správně identifikovat pracovníky, kteří skutečně odejdou, je nižší (46,9 %). To znamená, že model velmi dobře rozpoznává zaměstnance, kteří zůstávají, ale méně přesně identifikuje ty, kteří odejdou. Cut-off hodnota pro klasifikaci byla nastavena na 0,5.

Tabulka 4: Klasifikační tabulka

Observed	Predicted		% Correct
	0	1	
0	682	16	97.7
1	52	46	46.9

To potvrzuje i klasifikační tabulka, která ukazuje, že model správně identifikoval 682 zaměstnanců, kteří v zaměstnání zůstali, a pouze u 16 případů chybně předpověděl fluktuaci. Naopak z 98 skutečně odcházejících zaměstnanců model správně identifikoval pouze 46, zatímco 52 bylo nesprávně klasifikováno jako setrvávající. To odpovídá vysoké specificitě modelu (97,7 %) a nižší senzitivitě (46,9 %), což naznačuje, že model je spolehlivější při identifikaci zaměstnanců, kteří neodejdou než při predikci těch, kteří skutečně opustí své zaměstnání.

Závěrečné zhodnocení

Pomocí binomické logistické regrese se podařilo vytvořit model predikce fluktuace zdravotnických pracovníků na porodnických odděleních. Za statisticky významné prediktory fluktuace lze považovat věk zaměstnance, spokojenost se zaměstnáním, měsíční příjem a práci s přesčasy, viz tabulka 1. Naopak proměnné vzdálenost od domova, celkový počet odpracovaných let a pohlaví se neukázaly jako statisticky významné. Tabulky 2 a 3 ukazují, že model má vysokou celkovou přesnost (91,5 %) a velmi dobře identifikuje zaměstnance, kteří ve zdravotnickém zařízení zůstanou (specificita 97,7 %). Predikce fluktuace je však méně přesná, protože senzitivita modelu dosahuje pouze 46,9 %. To znamená, že model správně předpovídá odchod přibližně u poloviny zaměstnanců, kteří skutečně odejdou.

Zdroje

- Castro Lopes, S., Guerra-Arias, M., Buchan, J., Pozo-Martin, F., & Nove, A. (2017). A rapid review of the rate of attrition from the health workforce. *Human Resources for Health*, 15(1). <https://doi.org/10.1186/s12960-017-0195-2>
- Schoo, A. M., Stagnitti, K. E., Mercer, C., & Dunbar, J. (2005). A conceptual model for recruitment and retention: Allied health workforce enhancement in Western Victoria, Australia. *Rural and Remote Health*, 5(4), 1-18. <https://doi.org/10.3316/informit.611403704521769>

Miller, J. P. (2023). *Employee Attrition for Healthcare*. Kaggle. Retrieved March 4, 2025, from <https://www.kaggle.com/datasets/jpmiller/employee-attrition-for-healthcare>

Yeoh, S. A., Kumar, S., Phillips, A., Li, L. S. K., & Wilkinson, J. (2024). Unveiling the Exodus: A scoping review of attrition in allied health: A scoping review of attrition in allied health. *PLOS ONE*, *19*(9). <https://doi.org/10.1371/journal.pone.0308302>