



# METODICKÉ UKOTVENÍ VYUŽITÍ UMĚLÉ INTELIGENCE PRO IDENTIFIKACI HETEROGENIT V POSKYTOVÁNÍ ZDRAVOTNÍ PÉČE

Metodický rámec pro analýzu regionálně specifických vzorců  
a jejich využití při plánování zdravotní péče

## Návrh odborného metodického rámce

|                            |                                                                                                                             |
|----------------------------|-----------------------------------------------------------------------------------------------------------------------------|
| <b>Vydavatel</b>           | Ústav zdravotnických informací a statistiky České republiky                                                                 |
| <b>Určeno pro</b>          | odborníky v oblasti analýzy zdravotnických dat, hodnocení kvality vykazování, plánování kapacit a organizace zdravotní péče |
| <b>Charakter dokumentu</b> | návrh odborného metodického rámce                                                                                           |
| <b>Verze</b>               | 1.0                                                                                                                         |
| <b>Datum</b>               | červen 2026                                                                                                                 |
| <b>Rozsah</b>              | identifikace, validace a využití regionálně specifických vzorců ve vykázané zdravotní péči                                  |

*Metodika vychází z postupů vyvinutých a ověřených při analýze dat NRHZS. Vymezuje podmínky transparentní, reprodukovatelné a odborně validované interpretace výsledků.*



## Jak s metodikou pracovat

| Položka     | Vymezení                                                                                                                                                         |
|-------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Účel        | Poskytnout jednotný rámec pro využití metod umělé inteligence při identifikaci heterogenit ve vykázané zdravotní péči a při jejich převodu do plánovací diskuse. |
| Působnost   | Analýzy trajektorií pacientů v datech NRHZS, případně v propojených registrech, od definice kohorty po odbornou validaci a provozní monitoring.                  |
| Charakter   | Návrh metodického postupu a minimálních kontrolních požadavků. Nejde o klinický algoritmus ani o nástroj pro individuální rozhodování o pacientovi.              |
| Použití     | Příprava analytické studie, opakovaný monitoring, ověření regionálních signálů a formulace podkladů pro plánování zdravotní péče.                                |
| Aktualizace | Při změně zdrojových dat, katalogů a klasifikací, architektury modelu, validačního postupu nebo účelu využití výsledků.                                          |

### Způsob výkladu

- formulace „ověřeno v projektu“ označuje postup skutečně použitý při původní analýze;
- formulace „navrhuje se“ nebo „doporučuje se“ označuje rozšíření určené pro budoucí opakované využití;
- výstup modelu je vždy pracovní hypotézou, nikoli přímým důkazem regionální nerovnosti;
- před převodem výsledků do plánování je nutné splnit kontrolní body KB-3 a KB-5.

#### Základní omezení

Metodika analyzuje vykázanou péči, nikoli úplný klinický obsah péče. Model může zachycovat rozdíly v organizaci péče, mobilitu pacientů i odlišnou kódovací a vykazovací praxi. O příčině signálu lze rozhodnout až po analytické a odborné validaci.



# Obsah

## Obsah

|                                                         |    |
|---------------------------------------------------------|----|
| Manažerské shrnutí.....                                 | 4  |
| 1. Účel, předmět a rozsah metodiky .....                | 4  |
| 2. Východiska a ověřené poznatky projektu .....         | 5  |
| 2.1 Co bylo v projektu vybudováno a ověřeno.....        | 5  |
| 2.2 Co projekt ukázal .....                             | 6  |
| 2.3 Co projekt nezahrnoval a co metodika doplňuje ..... | 6  |
| 3. Klíčové pojmy .....                                  | 7  |
| 4. Základní principy použití.....                       | 7  |
| 5. Metodický postup analýzy.....                        | 8  |
| 5.1 Fáze A - Definice analytického kontextu .....       | 8  |
| 5.2 Fáze B - Příprava trajektorií .....                 | 8  |
| 5.3 Fáze C - Modelování .....                           | 8  |
| 5.4 Fáze D - Interpretace a validace signálů .....      | 9  |
| 5.5 Fáze E - Převod do plánování zdravotní péče.....    | 9  |
| 6. Minimální požadavky na dokumentaci analýzy.....      | 10 |
| 7. Omezení a rizika nesprávné interpretace.....         | 11 |
| 8. Kontrolní body před využitím výsledků .....          | 12 |
| 9. Provozní uplatnění metodiky .....                    | 13 |
| 9.1 Role a odpovědnosti.....                            | 13 |
| 10. Možnosti dalšího technologického rozvoje .....      | 14 |
| 11. Závěr .....                                         | 15 |



## Manažerské shrnutí

Metodika převádí zkušenost z jednorázové analýzy dat NRHZZ do opakovaně použitelného procesu. Jádrem je analýza trajektorie pacienta pomocí sekvenčního modelu, měření regionální separability, identifikace kandidátních signálů a jejich vícevrstvá validace.

Výstupy modelu nejsou samy o sobě podkladem pro rozhodnutí o kapacitách nebo organizaci péče. Teprve po ověření frekvenční opory, klinické a věkové přípustnosti, souladu s odborností poskytovatele a vlivu mobility pacientů mohou být zařazeny do plánovací diskuse. Nízká separabilita je přitom platným výsledkem, který může potvrzovat vysokou míru homogenity vykázané péče.

### Hlavní metodický závěr

Umělá inteligence v tomto rámci slouží k systematickému vyhledávání hypotéz v komplexních datech. Nenahrazuje frekvenční analýzu, odbornou interpretaci ani rozhodnutí plánovací autority.

## 1. Účel, předmět a rozsah metodiky

Dokument vymezuje metodiku využití metod umělé inteligence pro identifikaci heterogenit v poskytování zdravotní péče a pro jejich následné využití při plánování. Metodika vychází z postupů vyvinutých a ověřených při analýze dat Národního registru hrazených zdravotních služeb (NRHZZ) a doplňuje je o kroky nezbytné pro přechod od jednorázové analytické studie k opakovaně využitelnému nástroji.

Dokument je podkladem k diskusi o standardizaci analytického postupu. Konkrétní regionální nálezy nejsou jeho součástí; jsou předmětem samostatných analytických zpráv projektu. Metodika je určena zejména pracovníkům ÚZIS ČR a dalším subjektům podílejícím se na analýze dat zdravotního systému, plánování kapacit a hodnocení kvality vykazování. Nepředstavuje klinický algoritmus ani rozhodovací nástroj pro individuální péči o pacienta.



## 2. Východiska a ověřené poznatky projektu

Výchozím problémem bylo zjistit, zda nám moderní metody hlubokého strojového učení mohou napomoci detekovat heterogenity v poskytování zdravotní péče mezi kraji ve velmi objemných a komplexních datech NRHZS. Tradiční přístupy, jako porovnávání agregovaných ukazatelů napříč kraji nebo analýza frekvencí jednotlivých diagnóz, dobře odpovídají na předem formulované hypotézy, ale nejsou vhodné pro zachycení složitějších vzorců v celé trajektorii péče o pacienta a detekci důležitých faktorů v komplexních datech. Proto byly využity metody hlubokého strojového učení, konkrétně sekvenční modely typu BERT, které z časové posloupnosti vykázaných zdravotních událostí extrahují reprezentaci poskytované péče.

Základní myšlenka postupu je natrénovat model, který se pokusí z trajektorie pacienta odhadnout kraj jeho trvalého bydliště. Pokud takový model dokáže kraje rozlišit lépe než náhoda, znamená to, že v datech našel regionálně specifické vzorce. Kódy péče, které model při rozlišování nejvíce využívá, jsou pak kandidáty na tyto vzorce. Samotná predikce kraje bydliště přitom není cílem — je to nástroj, jak systematicky prohledat komplexní data pro regionální signály.

### 2.1 Co bylo v projektu vybudováno a ověřeno

Pro každého pacienta jsme z dat NRHZS sestavili trajektorii — časově uspořádanou posloupnost tokenů reprezentujících vykázanou péči v průběhu sledovaného období. Pracovali jsme se třemi typy vstupů nezávisle: hlavními diagnózami (tříznaková MKN-10), odbornostmi poskytovatelů a předepsanými léčivými (tříznaková ATC). Každý token jsme doplnili příznakem ambulantního nebo hospitalizačního kontextu, protože stejný kód v různých kontextech může nést odlišný informační obsah.

Pro každý typ vstupu jsme vytrénovali vlastní sekvenční model ve dvou krocích. Nejprve jsme model předtrénovali na obecném porozumění trajektoriím pomocí dvou úloh: maskování náhodných tokenů, při němž se model učí, které kódy se v daném kontextu vyskytují, a predikce, zda dvě části sekvence na sebe navazují, čímž model získává povědomí o temporální logice průběhu péče. Poté jsme model doladili pro klasifikaci pacientů do 14 krajů.

Výsledky jsme interpretovali kombinací analýzy SHAP, attention map a frekvenčního ověření v původních datech. Analýzu jsme provedli jak na celé populaci, tak na specifických subpopulacích. Nejlepší výsledky jsme zaznamenali u novorozenců a kojenců ve věku 0–1 rok a u nových onkologických pacientů ve věku 21–44 let. Jako doplněk k modelu diagnóz jsme otestovali i model pracující s trajektoriemi onkologických fází sestavenými z dat NRHZS a NOR, který zachycuje nejen diagnózy, ale i typ aplikované léčby a průběh onkologické péče v rozsahu let 2010–2024.



## 2.2 Co projekt ukázal

Na celé populaci jsou vzorce vykázané péče napříč kraji z pohledu modelu velmi podobné — model dosahoval pouze nízké separability. Toto zjištění považujeme za smysluplný výsledek samo o sobě: indikuje vysokou míru homogenity systému zdravotní péče v ČR. Výraznější regionální signály se projeví teprve u úžeji vymezených subpopulací se specifickým průběhem péče.

Interpretace signálů ukázala, že nezanedbatelná část z nich odráží spíše odlišné vykazovací zvyklosti než reálné rozdíly v poskytované péči. Setkali jsme se například s diagnózami věkově nepřipustnými pro danou kohortu, s kódy vykazovanými pod neobvyklou odborností nebo s různými způsoby kódování screeningových výkonů. Rozlišení klinicky relevantních signálů od těchto artefaktů se ukázalo jako klíčový interpretační krok, bez něž by výsledky modelu mohly vést k zavádějícím závěrům o regionálních nerovnostech.

Jako strukturální limit jsme identifikovali skutečnost, že data obsahují kraj trvalého bydliště, nikoli kraj poskytnuté péče. Model tak může zachycovat spíše mobilitu pacientů za specializovanou péčí než lokální specifika organizace systému — to se projevilo zejména u dospělé populace. Různá informativní hodnota jednotlivých položek se ukázala na příkladu léčiv (ATC), kdy model vykazoval nízkou diskriminační schopnost.

## 2.3 Co projekt nezahrnoval a co metodika doplňuje

Projekt neobsahoval systematickou odbornou validaci identifikovaných signálů s účastí klinických a vykazovacích expertů jako standardní součást procesu před formulací plánovacích závěrů. Vybrané signály jsme v rámci projektu posuzovali analyticky — frekvenční kontrolou a ověřením např. věkové přípustnosti kódů — avšak ne v rámci strukturovaného procesu zahrnujícího doménové experty.

Dále jsme nebudovali rámec pro pravidelný provozní monitoring, tedy opakované spouštění analýzy na aktualizovaných datech, sledování změn separability a signálů v čase a detekci driftu. A konečně, výstupy projektu sloužily primárně analytickému a reportovacímu účelu; formální převod zjištěných informací pro účely plánování zdravotní péče nebyl součástí projektu.

Právě tyto tři oblasti — validace s doménovými experty, provozní monitoring a převod do plánování — tvoří jádro toho, co navrhujeme doplnit.



### 3. Klíčové pojmy

**Trajektorie pacienta** je časově uspořádaná posloupnost tokenů reprezentujících vykázané zdravotní události jednoho pacienta ve sledovaném období.

**Token** je elementární jednotka vstupní sekvence — typický kód z katalogu (MKN-10, odbornost, ATC) doplněný o kontext poskytnutí (ambulantní nebo hospitalizační režim).

Separabilita regionů označuje schopnost modelu rozlišit, z jakého územního celku pacient pochází, na základě jeho trajektorie. Slouží jako indikátor přítomnosti regionálně specifických signálů v datech, nikoli jako cíl klinické predikce.

**Signál klinického charakteru** je token nebo kombinace tokenů, jejichž zvýšená váha v modelu koresponduje s odborně obhajitelným rozdílem v organizaci nebo obsahu péče.

**Signál administrativního charakteru** je token nebo kombinace tokenů, jejichž regionální specifika lze přisoudit odlišné vykazovací praxi, kódovací chybě nebo odlišnému využití administrativních kódů, aniž by šlo o prokazatelný rozdíl ve zdravotním stavu populace.

**Analytický kontext** je vymezení populace (věk, diagnóza, typ péče), časového období, typu vstupní sekvence a územního členění, v němž se analýza provádí.

### 4. Základní principy použití

Na základě zkušeností z projektu navrhujeme, aby další analýzy v tomto rámci vycházely z následujících principů.

Výstupy modelů UI jsou třeba chápat jako pracovní hypotézy k ověření, nikoli jako přímý důkaz regionální nerovnosti. Samotná predikce modelu říká, že v datech existuje zachytitelná odlišnost — neříká ale nic o její příčině ani klinickém nebo organizačním dopadu.

Klíčová hodnota přístupu spočívá v tom, že analytickou jednotkou je trajektorie pacienta, nikoliv izolovaný kód. Přístup tak umožňuje zachytit kombinace a pořadí událostí, které agregátní statistiky přehlíží — například specifický průběh onkologické léčby nebo vzorec novorozenecké péče typický pro dané pracoviště.

Každý identifikovaný signál by pak měl projít posouzením, zda odráží obsah péče, organizaci systému, mobilitu pacientů nebo odlišnou vykazovací praxi. Oddělení obsahu od formy vykazování je při interpretaci výsledků nezbytné a nelze ho přeskočit.

Výsledky získané pro jednu populaci, časové období nebo typ sekvence nelze přenášet na jiný analytický kontext bez opakování analýzy. A každá analýza by měla být dokumentována včetně verze dat, parametrů modelu a definice kohorty, aby bylo možné výsledky srovnávat napříč cykly.



## 5. Metodický postup analýzy

Postup je členěn do pěti navazujících fází. Každá fáze má samostatný minimální výstup, který musí být dohledatelný v dokumentaci analýzy.

| Fáze | Hlavní úkol                    | Minimální výstup                                                       |
|------|--------------------------------|------------------------------------------------------------------------|
| A    | Definice analytického kontextu | jednoznačně vymezená otázka, kohorta, období a vstupní sekvence        |
| B    | Příprava trajektorií           | reprodukovatelný datový soubor, tokenizer a slovní zásoba              |
| C    | Modelování                     | metriky separability a seznam tokenů významných pro rozlišení regionů  |
| D    | Interpretace a validace        | odborně posouzené a klasifikované kandidátní signály                   |
| E    | Převod do plánování            | schválené podněty pro plánování, kvalitu vykazování nebo další analýzu |

Postup, který navrhujeme, vychází z toho, co jsme v projektu ověřili, a doplňuje ho o kroky nezbytné pro přechod od jednorázové studie k opakovaně využitelnému nástroji.

### 5.1 Fáze A - Definice analytického kontextu

Před zahájením analýzy je třeba explicitně formulovat analytickou otázku a stanovit sledované období, cílovou populaci a typ vstupní sekvence. Výběr populace má zásadní vliv na výslednou separabilitu modelu — zkušenost z projektu ukazuje, že obecná populace poskytuje nízkou separabilitu, zatímco úžeji vymezené kohorty se specifickým průběhem péče poskytují lépe interpretovatelné výsledky. Doporučujeme proto nejprve analyzovat obecnou populaci za účelem posouzení celkové míry homogenity a teprve při nízké separabilitě přejít k cíleným subpopulacím. Výsledky pro různé typy vstupních sekvencí je vhodné vždy porovnat, protože každý typ zachycuje jinou dimenzi péče.

### 5.2 Fáze B - Příprava trajektorií

Sestavení trajektorií jsme prováděli tak, že jsme nejprve filtrovali záznamy podle definovaného kontextu, seřadili události chronologicky a každou událost transformovali na token kombinující kód s kontextem poskytnutí. Pacienty s neúplnou nebo nekonzistentní územní identifikací jsme vyloučili. Maximální délku sekvence jsme stanovili na základě distribuce délek trajektorií v dané kohortě — pro předtrénování jsme používali zhruba 50. percentil délky, pro doladění zhruba 90. percentil. Pro každý typ vstupu je třeba vytvořit samostatný tokenizer a slovní zásobu.

### 5.3 Fáze C - Modelování

Trénink probíhal ve dvou krocích. Nejprve jsme model předtrénovali pro obecné porozumění trajektoriím, a to pomocí dvou úloh: maskovaného jazykového modelování, při němž model predikuje





zakryté tokeny v sekvenci, a predikce návaznosti sekvencí, díky níž model rozumí časové struktuře průběhu péče. Předtrénování probíhalo na celé populaci bez cílové proměnné (kraj). V druhém kroku jsme model doladili pro klasifikaci pacientů do 14 krajů. Výstupem není predikce určená k praktickému nasazení — predikce kraje bydliště nemá přímou klinickou ani administrativní hodnotu. Cílem je měřit míru separability a identifikovat tokeny, které model k rozlišování nejvíce využívá. Referenční konfigurace modelu použitá v projektu je dokumentována v technickém repozitáři.

## 5.4 Fáze D - Interpretace a validace signálů

Interpretace je nejdůležitějším krokem celého postupu a přesahuje standardní hodnocení výkonnosti modelu. Strukturujeme ji do tří vrstev.

Výkonnostní vrstva slouží k základnímu hodnocení separability: sledujeme přesnost a F1 skóre po regionech, matici záměn, entropii predikce a asymetrii záměn mezi regiony. Nízká separabilita je platným výsledkem indikujícím homogenitu; neinterpretujeme ji nutně jako selhání modelu.

Vysvětlující vrstva identifikuje tokeny přispívající k predikci konkrétního regionu pomocí hodnot SHAP, attention map a analýzy vlivu tokenů na logity modelu. Výstupem je seznam kandidátních signálů pro každý kraj.

Validační vrstva je krokem, který jsme v rámci projektu otestovali a který navrhujeme pro budoucí využití a aplikaci výsledků formalizovat. U kandidátních signálů z předchozí vrstvy doporučujeme ověřit jejich frekvenci výskytu v původních datech — vysoká hodnota SHAP nestačí, signál musí mít oporu v datech. Dále je třeba posoudit klinickou a věkovou přípustnost kódu v analyzované kohortě a soulad s odborností poskytovatele, protože kód vykázaný pod neočekávanou odborností indikuje spíše specifickou vykazovací praxi než klinický obsah. Systematické záměny mezi sousedními nebo funkčně propojenými regiony pak mohou signalizovat mobilitu pacientů spíše než heterogenitu systému. Považujeme za klíčové, aby závěrečné posouzení provedl doménový expert.

Na základě validace se signály zařadí do kategorií: klinický, organizační, mobilita pacientů, vykazovací/administrativní, nebo nejednoznačný (vyžaduje další šetření).

## 5.5 Fáze E - Převod do plánování zdravotní péče

Tato fáze v projektu nebyla realizována jako samostatný proces; výstupy sloužily analytickému a reportovacímu účelu. Navrhujeme, aby validované signály byly systematicky převáděny do plánovací diskuse podle svého charakteru. Signály klinického nebo organizačního charakteru slouží k posouzení dostupnosti specializované péče, kapacit center nebo regionálních standardů. Signály indikující mobilitu pacientů jsou podkladem pro analýzu mezikrajových toků a návaznosti na síť poskytovatelů. Signály vykazovacího charakteru by měly být předány ke kontrole kvality vykazování a metodické podpoře poskytovatelů. A konečně, nízká separabilita v dané oblasti je sama o sobě hodnotným výsledkem potvrzujícím srovnatelnost péče — taková oblast nevyžaduje prioritizaci intervence. Plánovací závěry by měla vždy formulovat odborná skupina na základě validovaných zjištění, nikoli přímo z výstupů modelu.



## 6. Minimální požadavky na dokumentaci analýzy

Pro zajištění reprodukovatelnosti a srovnatelnosti v čase navrhuje, aby každá analýza v tomto rámci obsahovala:

1. popis analytického kontextu včetně zdůvodnění volby populace a období;
2. charakteristiku dat — rozsah, filtry, počty pacientů po regionech;
3. dokumentaci modelu — architektura, postup tréninku, metriky na validační a testovací množině;
4. přehled identifikovaných signálů včetně klasifikace dle fáze D;
5. posouzení limitů — zejména vztah mezi krajem bydliště a krajem poskytnutí péče;
6. návrh dalších kroků — včetně doporučení, zda signál vyžaduje odborné ověření nebo opakování analýzy.



## 7. Omezení a rizika nesprávné interpretace

Tak jako každá analytická metoda má i tento postup svůj přirozený rozsah, v rámci kterého je potřeba výsledky interpretovat, aby nedocházelo k chybným závěrům. Použitá metodika analyzuje vykázanou péči jako posloupnost kódů — zachycuje tedy to, co bylo pojišťovně vykázáno, nikoliv plný klinický obsah péče. Vykázaný kód odráží kombinaci klinické reality, kódovací praxe a vykazovacích zvyklostí daného pracoviště, a tomu odpovídá i to, co model dokáže rozlišit. Výsledky proto primárně vypovídají o vzorcích ve vykazování péče, a teprve skrze validační vrstvu je možné posoudit, do jaké míry tyto vzorce odrážejí organizaci nebo obsah péče jako takové.

Model pracuje s krajem trvalého bydliště pacienta, což je pro účely analýzy heterogenit přirozená volba — ale znamená to, že model může zachycovat i mobilitu pacientů za specializovanou péčí, nikoli jen lokální specifika systému. U dospělé populace je tento efekt výraznější, u novorozenců naopak kraj bydliště a kraj poskytnuté péče bývají častěji v souladu, což mohlo přispět k vyšší separabilitě v této skupině.

Analýza agregovaná za sledované období nepracuje s intervaly mezi událostmi ani s dlouhodobými trendy — to je vědomé zjednodušení, které umožňuje efektivní zpracování velkého objemu dat. Výsledek je proto vhodné číst jako zachycení vzorců platných pro dané období, nikoli jako popis dynamiky v čase. Podobně platí, že různé typy vstupní sekvence zachycují různé dimenze péče: data léčiv vykazovala nízkou schopnost rozlišit regiony, což poukazuje na relativní homogenitu preskripce v ČR napříč kraji — to samo o sobě je hodnotné zjištění, nikoli selhání přístupu.

Metody vysvětlení jako SHAP nebo attention mapy označují tokeny, které model při své predikci využívá nejvíce. U modelů tohoto typu — hluboké neuronové sítě s miliony parametrů a nelineárními interakcemi mezi vrstvami — deterministické vysvětlení ve smyslu „tento token způsobil tuto predikci“ není ani teoreticky možné, ani výpočetně realizovatelné. SHAP a podobné metody proto nejsou zkrácenou verzí takového vysvětlení; jsou to nástroje pro aproximaci příspěvku jednotlivých vstupů k výstupu modelu, a jako takové jsou transparentní ohledně své povahy.

Jednodušší metody — například logistická regrese nebo rozhodovací stromy — deterministickou interpretovatelnost nabízejí, ale za cenu toho, že zachycují pouze lineární nebo mělce větvené vztahy mezi proměnnými. V případě trajektorií pacientů, kde záleží na pořadí událostí, jejich kombinacích a kontextu, by takové modely velkou část relevantní informace ztratily už při formulaci úlohy. Hodnota sekvenčních modelů hlubokého učení spočívá právě v tom, že dokáží zachytit vzorce v komplexních datech, které jednoduché metody přehlédnou — a SHAP umožňuje tyto vzorce alespoň částečně nahlédnout a formulovat jako hypotézy k odbornému ověření. Výstupy je proto vhodné chápat jako vodítko k dalšímu šetření, nikoliv jako samovyvětlující závěr.



## 8. Kontrolní body před využitím výsledků

Pro předávání výsledků plánovacím orgánům navrhujeme následující kontrolní seznam. V projektu nebyl uplatněn jako formální součást procesu; považujeme ho za vhodný rámec pro budoucí cykly.

Splnění bodů KB-3 a KB-5 považujeme za nezbytné před využitím výsledků pro plánování zdravotní péče.

| Bod  | Kontrolní otázka                                             |
|------|--------------------------------------------------------------|
| KB-1 | Je analytický kontext jednoznačně definován a zdůvodněn?     |
| KB-2 | Byly identifikované signály klasifikovány dle charakteru?    |
| KB-3 | Prošly klíčové signály frekvenční a odbornou kontrolou?      |
| KB-4 | Jsou explicitně uvedena omezení včetně územní identifikace?  |
| KB-5 | Jsou formulovány závěry odděleně od surových výstupů modelu? |
| KB-6 | Je postup reprodukovatelný (verze dat, kód, parametry)?      |



## 9. Provozní uplatnění metodiky

Projekt byl koncipován jako jednorázová analytická studie. Pro dlouhodobé využití navrhujeme přechod k pravidelně opakovanému procesu. Roční cyklus aktualizace na nových datech NRHZS odpovídá granularitě dat a umožňuje sledovat trendy v datech. Porovnání separability a složení signálů oproti předchozímu cyklu slouží jako indikátor driftu — výrazná změna může signalizovat buď skutečnou proměnu vzorců péče, nebo změnu v kódovacích praktikách. Navrhujeme průběžně vést katalog kódů, které se v předchozích analýzách opakovaně ukázaly jako vykazovací artefakty; takový katalog by urychlil validační vrstvu v následujících cyklech. Agregované výstupy by měly být předávány pracovní skupině pro plánování a kontrolu kvality jako podněty k odbornému posouzení, nikoliv jako hotové závěry. Výstupy určené k externí publikaci nebo přímému využití v plánovacích dokumentech by měly procházet schvalovacím procesem.

### 9.1 Role a odpovědnosti

Pro pravidelné využití metodiky musí být oddělena odpovědnost za data, model, odbornou interpretaci a plánovací rozhodnutí. Jedna osoba může zastávat více rolí, odpovědnosti však musí být v každém analytickém cyklu výslovně určeny.

| Role                             | Minimální odpovědnost                                                          |
|----------------------------------|--------------------------------------------------------------------------------|
| Odborný garant                   | schvaluje analytickou otázku, interpretační rámec a závěry určené k využití    |
| Datový analytik / datový správce | připravuje data, dokumentuje filtry a ověřuje frekvenční oporu signálů         |
| Vývojář modelu                   | spravuje kód, parametry, verze modelu a reprodukovatelnost tréninku            |
| Doménový expert                  | posuzuje klinickou, organizační a vykazovací interpretaci kandidátních signálů |
| Pracovní skupina pro plánování   | formuluje a schvaluje plánovací podněty na základě validovaných zjištění       |



## 10. Možnosti dalšího technologického rozvoje

Současný postup, jehož jádro jsme v projektu ověřili a který popisujeme v předchozích kapitolách, považujeme za funkční základ pro analýzu heterogenit na datech NRHZS. Níže uvádíme přístupy, které by bylo možné v budoucnu zkoumat jako jeho rozšíření nebo alternativy — ne proto, že by stávající postup tyto dimenze postrádal, ale proto, že rychlý technologický vývoj v oblasti hlubokého strojového učení otevírá nové možnosti, jejichž přínos v tomto specifickém kontextu zatím nebyl vyhodnocen. Základní analytický princip — trajektorie → model → interpretace → validace → plánování — by přitom zůstal zachován.

Embeddingové a kontrastivní metody. Současný postup vychází z klasifikace pacienta do jednoho ze 14 krajů — náročná úloha s nízkou absolutní přesností na celé populaci. V projektu jsme na embeddingách z předtrénovaného modelu otestovali různé shlukovací metody včetně hodnocení kvality shluků pomocí silhouette analýzy, avšak shluky identifikované na různé úrovni granularity se s regionálním členěním nepřekrývaly: pacienti ze stejného kraje se v embeddingovém prostoru předtrénovaného modelu neshluovali odděleně od ostatních. To je konzistentní se zjištěním o celkové homogenitě vykazované péče. Přesto považujeme embeddingový přístup za perspektivní pro jiné formulace úlohy. Pokud by se model učil reprezentaci přímo s ohledem na podobnost vzorů péče — například metodami kontrastivního učení jako SimCLR nebo triplet loss — nikoli pomocí úlohy maskování tokenů, mohl by latentní prostor lépe odrážet klinicky relevantní skupiny. Regionální heterogenitu by pak bylo možné posuzovat jako vzdálenost mezi distribucemi embeddingů jednotlivých krajů nebo jako postupnou změnu těchto vzdáleností v čase, což by mohl být dobrý rámec pro pravidelný monitoring.

Temporální modelování. V projektu jsme události seřadili chronologicky, avšak interval mezi nimi se do modelu nepromítal — trajektorie byly z pohledu modelu posloupností bez časové vzdálenosti. Explicitní zařazení časových intervalů by umožnilo rozlišit akutní epizodu péče od dlouhodobé linie, což může být pro regionální srovnání obsahově významné. Pro delší trajektorie, typické pro onkologickou péči nebo chronická onemocnění, lze zvážit stavové modely s nižší výpočetní náročností (Mamba, S4) nebo grafové reprezentace, v nichž uzly odpovídají událostem a hrany jejich časové či klinické vazbě. Pilotní ověření by mělo posoudit, zda temporální obohacení přináší interpretovatelně odlišné výsledky oproti současné sekvenční reprezentaci.

Multimodální vstupy. V projektu jsme pracovali se třemi typy tokenů odděleně a pro interpretaci zvolili diagnózy jako nejvýkonnější vstup. Reálná trajektorie pacienta však zahrnuje všechny tyto dimenze současně, spolu s demografickým a organizačním kontextem — věkem, pohlavím, typem poskytovatele nebo délkou hospitalizace. Multimodální model propojující více kanálů v jedné reprezentaci by mohl lépe zachytit situace, kdy regionální specifika nejsou patrná v žádné doméně samostatně, ale projevují se např. jako odlišná kombinace diagnózy, odbornosti a preskripce.

Lokálně provozované jazykové modely. Velké jazykové modely umožňují efektivní převod kódů MKN-10, odborností a ATC kódů do srozumitelného klinického jazyka, seskupování příbuzných kódů do interpretovatelných témat jako screening, následná péče nebo perinatologie, a formulaci hypotéz k ověření. V prostředí ÚZIS je jejich využití možné pouze za podmínky, že citlivá data neopouštějí zabezpečenou infrastrukturu — tedy formou lokálně hostovaných open-source modelů pracujících nad agregovanými nebo anonymizovanými výstupy. Navrhujeme je chápat jako podpůrný nástroj pro analytika



a pro validační vrstvu, nikoli jako náhradu SHAP, frekvenční analýzy ani odborného posouzení. Každý výstup takového modelu by musel být verifikovatelný proti registrům a katalogům.

Kauzální a kontrafaktuální analýza. Detekce regionálního rozdílu modelem odráží korelaci, nikoli příčinný vztah: odlišnost může být důsledkem demografie, mobility, struktury sítě poskytovatelů nebo vykazovací praxe. Doplnkové kauzální postupy, jako např. stratifikace nebo propensity score matching, by umožnily posoudit, zda signál přetrvává po adjustaci na věk, pohlaví a další známé charakteristiky kohorty. Kontrafaktuální vysvětlení by doplňovalo analýzu SHAP otázkou, jak by se musela trajektorie změnit, aby pacient spadl do predikce jiného regionu. K tomu existují specializované nástroje jako DiCE (Diverse Counterfactual Explanations), které generují minimální změny vstupní sekvence vedoucí k jiné predikci třídy — takový výstup může být pro odbornou diskusi srozumitelnější než surové váhy tokenů. Navrhujeme tyto metody jako nástroj hlubšího ověření až po identifikaci signálu v rámci stávajícího postupu, před zařazením nálezu mezi kandidáty pro plánovací závěry.

Každou technologickou změnu navrhujeme nejprve pilotně ověřit a na základě výsledků tento dokument aktualizovat.

## 11. Závěr

Projekt ukázal, že metody umělé inteligence aplikované na trajektorie pacientů z NRHZS dokáží identifikovat regionální signály ve vykázané zdravotní péči. Po navržené validaci lze tyto signály rozlišovat na projevy odlišné vykazovací praxe, mobility pacientů a potenciálně klinicky nebo organizačně relevantní rozdíly. Pro využití těchto postupů nad rámec explorativní analýzy navrhujeme metodický rámec, který staví na ověřeném jádru projektu a doplňuje ho zejména o systematickou validační vrstvu s doménovými experty a formální převod zjištění do plánování.

Tento dokument předkládáme jako podklad k další diskusi. Jeho cílem není stanovit závazná pravidla, ale navrhnout postup, který by umožnil využívat metody umělé inteligence pro definici heterogenit transparentně, reprodukovatelně a s patřičnou opatrností při interpretaci výsledků.