

Dopady obmedzenia mobility na šírenie vírusu Covid-19

Aktualizácia č. 2.2 (29.3.2020)

Na základe dostupných dát o incidencii a prevalencii ochorenia COVID-19 v Slovenskej republike a najlepších dostupných modelov predikujeme, že opatreniami zavedenými v SR postupne od 9.3.2020 sme výrazne pomohli spomaliť šírenie ochorenia. Po zohľadnení nových opatrení ohlásených **27.3.2020** očakávame, že bude počet infikovaných na vrchole v 110. deň od 29.3. (s vrcholom na úrovni 3,1 % populácie). Zmiernenie dopadu oproti predikcií zo 17.3.2020 bolo spôsobené zavedením nových prísnejších opatrení a zrealizovaním podkladov na podmienky Slovenska, a to aj po zohľadnení dopadu rozšírenia počtu obchodov, ktoré môžu poskytovať služby občanom.

Očakávame, že náš zdravotný systém bude kapacitne bez obmedzení fungovať 70 dní od 29.3., ak by sa ponechali pôvodné opatrenia, časová rezerva by bola len približne 40 dní. Na základe zavedených opatrení a predikcie sme dospeli k názoru, že sme zaviedli (alebo sme v procese zavedenia) takmer všetky efektívne opatrenia na potlačenie šírenia vírusu. Dnes nevieme presne stanoviť reprodukčnú silu vírusu (R_0), ak by bola nižšia ako modelovaných 1,65, tak je šírenie výrazne nižšie. R_0 pri hodnote napríklad 1,4 dosiahne vrchol šírenia len na úrovni 1,5% populácie. Dosiahnutie týchto a lepších výsledkov bude však vyžadovať udržanie súčasného stavu, opatrení a veľkej miery disciplíny obyvateľstva.

Aj pri aplikovaní pesimistických predpokladov máme stále veľkú časovú rezervu, ktorá sa dá využiť na zastavenie nákazy, budovanie kolektívnej imunity, pretestovanie populácie či aplikáciu cielených opatrení. Naša predikcia je niečo ako záťažový test, čiže pesimistický scenár. Je lepšie byť obozretný, pripravený a zásobený, ako podceňiť situáciu. Bezpečnosť a zdravie občanov sú priority štátu, preto je naša predikcia konzervatívna.

Presnosť analýz sa dá zlepšiť údajmi od mobilných operátorov, ktoré výrazne spresnia migračné pohyby ľudí aj úroveň mobility. Je nevyhnutné spomenúť, že model je predikcia stavu za konštantných podmienok a ovplyvňuje aj mnoho iných premenných, ktoré budú zrejmé v čase, preto Inštitút zdravotnej politiky (IZP) pripraví k 4.4.2020 tretiu verziu modelu s aktualizovanými údajmi a doplnenou metodikou.

Oproti verzii zo 17.3. sme aktualizovali: metodika, kde zahŕňame aj ďalšie interakcie obyvateľov, úprava R_0 na priemernú vstupnú hodnotu 2.0 a 1.65 so zohľadnením existencie superšíriteľov; zohľadnenie socio-ekonomických diferenciačných faktorov pre populáciu; diskusia ohľadne teploty a reinfekcie; úprava OD matice pre lepšie zohľadnenie náhodného pohybu medzi blízkymi obcami; aktualizácia dňa nula na 29.3.2020 a zvýšenie alfa hodnôt.



Úvod

Nakoľko má ochorenie COVID-19 inkubačnú dobu dĺžky 2 – 14 dní, symptómy a nedostatok testovacích kapacít po celom svete limitujú rozoznávajúce reálneho počtu prípadov. Tento model je snahou o predikciu incidencií a prevalencií COVID-19 v SR na základe dostupných dát a pod vplyvom opatrení vlády platných ku 16.3.2020 a následne ku 27.3.2020. Cieľom je simulovať situáciu na základe existujúcich epidemiologických modelov za účelom predpovedania potreby starostlivosti a testovania pre individuálne obce na základe zvolených parametrov. Materiál bol pripravený pre potreby ústredného krízového štábu, nemá teda ambíciu poskytnúť detailný sumár dostupnej literatúry či štúdií, ale prezentovať jeden funkčný model s jeho limitáciami.

Túto metódu sme zvolili, nakoľko sme chceli vytvoriť rámec, kde vieme modelovať šírenie nákazy v geografickom priestore, aby sme vedeli skúmať dopad zníženia mobility alebo úplnej karantény určitého miesta. Model je dostatočne jednoduchý, aby bolo možné pridávať ďalšie scenáre, napríklad absolútne zníženie mobility pre seniorov, vyššia transmisia pre skupiny ohrozené chudobou alebo sociálnym vylúčením alebo postupné zvyšovanie mobility obyvateľstva. Výhodou tiež je, že vidíme ako predikovaná úroveň prevalence stúpa pre každú obec v čase, takže aj bez odhalených prípadov máme odhad, že v nich dochádza k pravdepodobnému nárastu incidencie a je tam treba zakročiť, vrátane širšieho testovania danej populácie. Snahou bolo zohľadniť špecifiká slovenskej situácie, ako aj terajších opatrení na kontrolu rozširovania nákazy. Premenné boli podrobené analýze senzitivity, pričom budeme model a jeho metodiku pravidelne aktualizovať podľa najnovšej akademickej literatúry a pripomienok odbornej verejnosti. Plánujeme zaradiť predpoklady z čerstvo publikovanej štúdie z Imperial College-u (Ferguson et al., 2020) ohľadne dopadov jednotlivých intervencií a tiež aktualizujeme dátové vstupy ohľadne počtu nákaz na Slovensku, dát od mobilných operátorov a ďalších zdrojov. Kompletný zdrojový kód k modelu zverejňujeme na stránke www.izp.sk/covid-19¹.

Tento model je limitovaný predpokladaním incidencie na základe odhadovaných štatistík a zjednodušením pohybu osôb na očakávanú úroveň. Pre detailné predikcie potrebujeme detailné dáta o pohybe osôb na území SR od mobilných operátorov (rokuje s operátormi, zapracované by mali byť vo verzii 30.3.2020), ako aj pre cielenú pomoc najohrozenejším skupinám. Ako ukazujú prípady menších krajín úspešných v reagovaní na pandémiu, cielené kontroly a ohľad na ohrozené skupiny viedlo k zníženiu rastu počtu nákaz aj fatality spojené s ochorením – a to aj bez mimoriadne vysokých úrovní testovania.

Prehľad použitej metodiky

1. Analýza obsahuje simuláciu šírenia koronavírusu na Slovensku na základe migračných tokov medzi všetkými slovenskými obcami, a to podľa modelu na základe článku z časopisu *Nature* (Wesolowski et al, 2017 a Yeghikyan, 2020 a migračného toku od Inštitútu finančnej politiky SR – Havran et al., 2019). V rámci analýz sme vyskúšali viaceré modely, ako napríklad Kucharski et al. (2020), avšak vybraný model bol v rámci dostupných a overených modelov najlepší zohľadňujúci flexibilitu či vzhľadom na obsiahnuté premenné.

¹ <https://dennikn.sk/blog/1812585/co-nam-studia-svetovych-expertov-hovori-o-efektivite-opatreni-voci-ochoreniu-covid-19/>

2. Simulácia berie situáciu ohľadom počtu nakazených z 28.3.2020 za deň nula, po ktorom progres nákazy pokračuje.
3. Yeghikyan (2020) simuluje postup vírusu v rámci jedného mesta, ktoré je rozdelené na políčka o veľkosti 250 x 250 metrov, medzi ktorými sa ľudia presúvajú. Model sme aplikovali na predikciu šírenia koronavírusu na Slovensku na úrovniach jednotlivých obcí.
4. Náš model používa parametre popisujúce rýchlosť šírenia vírusu na základe odhadov z literatúry, je však skôr popisom dynamiky rastu počtu infikovaných než jej presnou predikciou. V súčasnej dobe takmer na dennej báze vychádzajú štúdie predikujúce parameter R_0 (basic reproduction number), neexistuje preto ešte jedna robustná predikcia, resp. model (pozri napr. Liu et al. 2020, 2020a alebo Ferguson et al. 2020).
5. Model na základe cestovania medzi obcami, mestami alebo mestskými časťami (Bratislava, Košice) charakterizuje rýchlosť infikovania populácie. Je možné modelovať vplyv obmedzení v cestovaní a v sociálnom kontakte alebo úplnú karanténu niektorého bodu (napríklad uzatvorenie centra mesta). Model preto možno využiť v kontexte Slovenska na štúdium šírenia vírusu medzi slovenskými obcami.
6. Model zohľadňuje 3 typy interakcií: 1. Interakcia všetkých obyvateľov v rámci jednej obce mimo pracovných hodín, 2. Interakcia obyvateľov, ktorí zostali v domovskej obci s tými, ktorí migrovali do ich obce, 3. Interakcia obyvateľov, ktorí migrovali preč zo svojej obce s domácimi obyvateľmi obce, do ktorej migrujú.
7. Model využíva parameter tau, ktorý hovorí o tom, akú časť dňa prichádzajú obyvatelia v domovskej obci do kontaktu. V súčasnosti má parameter hodnotu 16 hodín z 24, teda $\frac{2}{3}$ a je odhadom, ktorý bude spresnený s použitím dát mobilných operátorov v novej verzii modelu.
8. Intenzita vzťahov medzi obcami je špecifikovaná pohybmi obyvateľstva medzi všetkými kombináciami obcí na Slovensku na základe trvalého a obvyklého pobytu (vypracované v rámci [štúdie IFP](#)).
9. Model analyzuje 4 vybrané scenáre:
 - a. Šírenie nákazy pri 100 % mobilite populácie (štandardný tok obyvateľstva z dát IFP; tzv. „vysoká mobilita“; inak povedané, ľudia migrujú ako keby sa nič výnimočné nedialo);
 - b. Šírenie nákazy pri 70 % mobilite populácie (oproti štandardnému toku obyvateľstva z dát IFP; tzv. „stredná mobilita“, toto číslo je odborný odhad). Berieme tiež do úvahy publikovanú informáciu, že priama mobilita ľudí klesla podľa operátorov o 30 - 50 % po zavedení vládnych opatrení;
 - c. Šírenie nákazy pri 30 % mobilite populácie (oproti štandardnému toku obyvateľstva z dát IFP; tzv. „nízka mobilita“, čiže stav predikovaný po zavedení opatrení ohlásených 16.3.2020, číslo je odborný odhad). Tento model berie tiež do úvahy nižšiu mieru prenosu infekcie formou zníženia parametra R_0 na výšku 2.0.
 - d. Šírenie nákazy pri 35 % mobilite populácie (oproti štandardnému toku obyvateľstva z dát IFP), čiže stav predikovaný po zavedení opatrení ohlásených 27.3.2020, číslo je odborný odhad). Model berie do úvahy zvýšenú mobilitu vplyvom otvorenia nových prevádzok ale nižšiu mieru prenosu infekcie formou zníženia parametra R_0 na výšku 1,65².

² Tento odhad vychádza z metódy, ktorá je momentálne vyvíjaná doc. Radoslavom Harmanom a Dr. Zuzanou Chladnou z FMFI UK, a ktorá berie do úvahy demografické dáta Slovenska ako aj úmrtnosť a smrtnosť z iných krajín zasiahnutých koronou vírusom. Za túto pomoc sme im veľmi vďační. Pre nedostatok času zatiaľ táto metóda neprešla nezávislou odbornou kontrolou, ale na IZP ju berieme ako najrealistickejšiu reflexiu všetkých zavedených opatrení.

10. Momentálne model vychádza zo štandardnej mobility populácie na základe dát Inštitútu finančnej politiky. S presnejšími geolokačnými dátami od mobilných operátorov možno model výrazne spresniť, čiže 100 %, 70 %, 35 % budú nahradené presnými údajmi pohybu obyvateľstva, a tak bude možné modelovať migrácie obyvateľov v rámci miest a obcí a to ako sa menili počas zavedenia vládnych opatrení.
11. Z poznatkov o iných, dobre známych vírusoch a koronavírusoch vyplýva, že aj pri tomto novom type koronavírusu by sa mali u pacienta po prekonaní infekcie vytvoriť minimálne krátkodobé protilátky. Z tohto dôvodu pracujeme s hypotézou, že pacient sa nemôže (v krátko- až strednodobom horizonte) nakaziť vírusom druhý krát. Hypotéza ešte nie je plne potvrdená z dôvodu, že vírusom bol nakazený prvý človek len nedávno (Bao et al., 2020).
12. Vzťah medzi teplotou a intenzitou šírenia koronavírusu je stále nezmapovaný. Zatiaľ jediná štúdia adresovala rozširovanie vírusu naprieč rôznymi teplotami. Wang et al (2020) dokázali v rámci lineárnej regresie pre 100 čínskych miest, že vyššia teplota a vysoká relatívna vlhkosť znižujú prenos vírusu, a to aj pri kontrole hustoty obyvateľstva a HDP na mestá. Táto štúdia je však relatívne nová a nevyšla v akademickom žurnále, iba na portáli SSRN, ktorý má menej striktné pravidlá ako karentované akademické publikácie. Vzťah R_0 ako parametra a teplôt bol preukazovaný v medicínskych štúdiách takmer výlučne len u tropických nákaz, ktoré sú spôsobom rozširovania založené na iných faktoroch než chrípka alebo COVID-19 (napríklad Peña-García a Christofferson (2019)). I napriek indiciám z literatúry nie je dôsledne dokázaný vzťah medzi teplotou a rýchlosťou šírenia koronavírusu – z tohto dôvodu tento parameter nebude zatiaľ vstupovať do hlavného modelu.
13. Viac než environmentálne faktory ovplyvňujú intenzitu šírenia vírusov na báze kvapôčkovej infekcie faktory ako intenzita ľudského kontaktu v komunite, prístup k pitnej vode, vnímanie rizika nákazy, či možnosť zostať v domácej karanténe. Z tohto dôvodu zohľadňujeme tieto socio-ekonomické parametre v rámci indexu rizika, ktorý je vytvorený pre každú obec a je váženým priemerom premenných zohľadňujúcich počet obyvateľov v dome, prístup k pitnej vode a prístup k verejnej kanalizácii – výsledný index v modeli upravuje výšku R_0 na level obce zohľadňujúc pomer populácie, ktorá je sociálne vylúčená v rámci obce.
14. Parameter beta pochádza z dvoch power law distribúcií pre izolovaných a neizolovaných nakazených a umožňuje existenciu „superšíriteľov“ v modeli (viac informácií v Boxe 4). Pre transformáciu parametra R_0 je použité jednoduché násobenie konštantou parametra beta pre zachovanie rovnakých vlastností distribúcie beta pri rôznych priemerných parametroch R_0 .

Použitý model šírenia vírusu má 2 hlavné parametre, *alfa* a R_0 a požaduje maticu mobility medzi obcami.

1. Alfa je premenná ukazujúca úroveň mobility populácie mimo obce (v predošlej verzii modelu alfa popisovala mobilitu aj v rámci obce, v súčasnosti je level interakcie v rámci obce popísaný parametrom pomeru času stráveného v obci). Hodnota jedna pritom reprezentuje úplnú mobilitu (štandardná migračné správanie, množstvo presunov medzi obcami a plný sociálny kontakt) a nízka hodnota reprezentuje úplné zastavenie mobility medzi sídlami (minimálna migrácia medzi obcami, dodržiavanie pravidiel ako nosenie rúšok a umývanie rúk).

R_0 (basic reproduction number) reprezentuje priemerný počet ľudí, ktorí sú nakazení jednou infikovanou osobou v infikovateľnej populácii. Podľa doterajších odhadov pre nový koronavírus je to 1.4–3.9 (Li et al., 2020; Riou and Althaus, 2020; Liu et al., 2020), ale v prípade nekontrolovaného rastu dosahujú hodnoty až 14.8 (Rocklov et al., 2020). Simulácia R_0 v rámci uzatvoreného prostredia lode Diamond Princess bola v mediáne 95 % tzv. confidence intervalu podľa Zhang (2020) na úrovni $R_0 = 2.26$. Model IZP pracuje s priemernou hodnotou R_0 na úrovni 2.4 pri pesimistických a 1.65 pri odhadovanom reálnom scenári berúc do úvahy opatrenia ohlásené 27.3.2020.

Box 1: R_0 v simulácii IZP

V simulácii IZP je R_0 skonštruovaná nasledovne: Distribúcia obyvateľov je pomyselné rozdelená medzi „izolovaných“, teda tých, ktorí trávajú svoj čas prevažne doma a riadia sa odporúčaniami hygienikov, vrátane nosenia rúška a obmedzenia sociálnych kontaktov a „neizolovaných“, teda tých, ktorí buď odporúčania nedodržiavajú alebo kvôli svojej práci nemajú možnosť kontakt s ľuďmi obmedziť (patria sem napríklad lekári, predavači alebo šoféri). Parameter beta (R_0 je podielom parametrov beta a gamma) pochádza z Power law distribúcie a je vybraný z rôznych distribúcií pre izolovaných a neizolovaných (kód priložený k štúdii obsahuje kompletný výpočet). Pomer izolovaných osôb je predbežne určený staticky ako 0,7, ale bude upravený v ďalšej verzii modelu na základe údajov od telekomunikačných spoločností.

2. Matica mobility je matica presunov obyvateľstva medzi obcami na základe trvalého a obvyklého pobytu – v ďalšej verzii bude aktualizovaná podľa dát operátorov.

Popis premenných v simulácii:

$N(j)$ – populácia v obci j ,

$S(j, t)$ – počet tých, ktorí sa môžu nakaziť v obci j a čase t (v simulácii všetci v obci j , ktorí nikdy nemali vírus),

$I(j, t)$ – počet infikovaných v obci j v čase t

$R(j, t)$ – počet vyliečených v obci j v čase t (v simulácii sa vyliečení nemôžu nakaziť znovu),

$x(j, t) = I(j, t) / N(j)$ – pomer infikovaných v obci j v čase t

$y(j, t) = S(j, t) / N(j)$ – pomer tých, ktorí sa ešte môžu nakaziť (pomer „susceptible“ alebo náchylných obyvateľov) v obci j v čase t

$m(j, k)$ – mobilita z obce k do obce j , prvok matice na pozícii j, k .

$\beta(j, t)$ – miera infekčnosti v obci j v čase t , reprezentuje ako rýchlo sa vírus dokáže šíriť počas interakcie

gamma – miera vyliečenia, teda pomer všetkých infikovaných, ktorí sa za deň stanú vyliečenými

$R_0(j, t) = \beta(j, t) / \gamma$ – „basic reproduction number“, priemerný počet ľudí, ktorí sú nakazení jednou infikovanou osobou v obci j v čase t

alfa – miera mobility do inej obce, nabera hodnoty medzi 0 a 1

tau - časť dňa, počas ktorej prichádzajú obyvatelia v domovskej obci medzi sebou do kontaktu. V súčasnosti má parameter hodnotu 16 hodín z 24, teda 2/3. Bude aktualizovaný dátami od operátorov.

Iteračné kroky simulácie³:

Počet náchylných na chorobu v čase t+1:

$$\begin{aligned} S_{j,t+1} = & S_{j,t} - \tau \frac{S_{j,t} I_{j,t} \beta_{j,t}}{N_j} \\ & - \alpha(1 - \tau) \frac{\left[S_{j,t} - y_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right] \left[\sum_{k \neq j} m_{j,k} x_{k,t} \beta_{k,t} + \left(I_{j,t} - x_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right) \beta_{j,t} \right]}{N_j - \sum_{\ell \neq j} m_{\ell,j} + \sum_{\ell \neq j} m_{j,\ell}} \\ & - \alpha(1 - \tau) y_{j,t} \sum_{\ell \neq j} \frac{m_{\ell,j} \left[\left(I_{\ell,t} - x_{\ell,t} \sum_{k \neq \ell} m_{k,\ell} \right) \beta_{\ell,t} + \sum_{k \neq \ell} x_{k,t} m_{\ell,k} \beta_{k,t} \right]}{N_\ell - \sum_{k \neq \ell} m_{k,\ell} + \sum_{k \neq \ell} m_{\ell,k}} \end{aligned}$$

Počet infikovaných v čase t+1:

$$\begin{aligned} I_{j,t+1} = & I_{j,t} + \tau \frac{S_{j,t} I_{j,t} \beta_{j,t}}{N_j} - \gamma I_{j,t} \\ & + \alpha(1 - \tau) \frac{\left[S_{j,t} - y_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right] \left[\sum_{k \neq j} m_{j,k} x_{k,t} \beta_{k,t} + \left(I_{j,t} - x_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right) \beta_{j,t} \right]}{N_j - \sum_{\ell \neq j} m_{\ell,j} + \sum_{\ell \neq j} m_{j,\ell}} \\ & + \alpha(1 - \tau) y_{j,t} \sum_{\ell \neq j} \frac{m_{\ell,j} \left[\left(I_{\ell,t} - x_{\ell,t} \sum_{k \neq \ell} m_{k,\ell} \right) \beta_{\ell,t} + \sum_{k \neq \ell} x_{k,t} m_{\ell,k} \beta_{k,t} \right]}{N_\ell - \sum_{k \neq \ell} m_{k,\ell} + \sum_{k \neq \ell} m_{\ell,k}} \end{aligned}$$

Počet vyliečených v čase t+1:

$$R_{j,t+1} = R_{j,t} + \gamma I_{j,t}$$

Popis simulácie:

$\frac{S_{j,t} I_{j,t} \beta_{j,t}}{N_j}$ reprezentuje interakcie všetkých náchylných („susceptible“) obyvateľov v obci j so všetkými infikovanými obyvateľmi v obci j. Sú to teda nákazy, ktoré vzniknú vo vlastnej obci medzi vlastným obyvateľstvom obce.

³ Za návrh pre kroky simulácie sa chceme poďakovať doc. Mgr. Richardovi Kollárovi, PhD., Mgr. Kataríne Boďovej, PhD. z FMFI UK v Bratislave a Dr. Zuzane Chladnej z FMPH UK v Bratislave.

$$\frac{\left[S_{j,t} - y_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right] \left[\sum_{k \neq j} m_{j,k} x_{k,t} \beta_{k,t} + \left(I_{j,t} - x_{j,t} \sum_{\ell \neq j} m_{\ell,j} \right) \beta_{j,t} \right]}{N_j - \sum_{\ell \neq j} m_{\ell,j} + \sum_{\ell \neq j} m_{j,\ell}}$$

reprezentuje interakcie náchylných obyvateľov, ktorí zostali v obci j s infikovanými obyvateľmi v obci j. Infikovaní v obci j sa skladajú zo všetkých infikovaných, ktorí sú z obce j a neopustili ju a infikovaných, ktorí prišli do obce j zo všetkých ostatných obcí. Sú to teda nákazy, ktoré sú prinesené infikovanými obyvateľmi ostatných obcí.

$$y_{j,t} \sum_{\ell \neq j} \frac{m_{\ell,j} \left[\left(I_{\ell,t} - x_{\ell,t} \sum_{k \neq \ell} m_{k,\ell} \right) \beta_{\ell,t} + \sum_{k \neq \ell} x_{k,t} m_{\ell,k} \beta_{k,t} \right]}{N_{\ell} - \sum_{k \neq \ell} m_{k,\ell} + \sum_{k \neq \ell} m_{\ell,k}}$$

reprezentuje interakcie medzi náchylnými obyvateľmi z obce j, ktorí cestovali do všetkých ostatných obcí a tam mali kontakt s infikovaným obyvateľstvom. Infikované obyvateľstvo v danej obci sa skladá z infikovaných, ktorí zostali v danej domovskej obci a infikovaných, ktorí migrovali do tejto obce. Sú to teda nákazy, ktoré vzniknú mimo vlastnej obce počas pracovných hodín a osoba sa s nimi vracia do domovskej obce.

Výhody modelu:


- Komplexný model, ktorý berie do úvahy geografické parametre šírenia vírusu, socio-ekonomické charakteristiky obce, mobilitu obyvateľstva, čas strávený mimo obce, obsahuje superširiteľov, a ktorý je predikovateľný na deň pre každú obec;
- Je možné ďalej zakomponovať migračné vzorce v rámci SR;
- Parameter mobility umožňuje simulovať scenáre obmedzenia cestovaní a sociálneho kontaktu; rôzne typy populácie; upravením migračnej matice možno simulovať dopad uzavretia obce;
- Jednoduchosť modelu umožňuje testovať ďalšie hypotézy, ako napríklad postupné zvyšovanie mobility v čase, vyšší čas strávený vo vlastnej obci alebo dopady iného konkrétneho opatrenia na počet infikovaných.
- Model dokáže predikovať približnú potrebu kapacity lôžok a pľúcnych ventilátorov na infekčných oddeleniach a na jednotke intenzívnej starostlivosti, ktorá bude potrebná pre každý región.

Limitácie súčasného modelu:

- Matica pohybu osôb nezahŕňa pohyb zo zahraničia (je ho možné pridať, pričom zahraničné mestá alebo krajiny budú predstavovať ďalšie lokality);
- Mobilitu predikujeme na základe odborných (a agregovaných) odhadov; bez informácií od mobilných operátorov nevieme presne určiť migračné toky;
- Model SIR (Susceptible – Náchylný, Infected – Infikovaný, Recovered - Vyliečený) ráta s exponenciálnym správaním šírenia vírusu.

Výsledky simulácie


Tento model je výsledkom 10 simulácií a je iniciovaný podľa momentálneho stavu nákazy v SR (prípady, ktoré boli odhalené k 28.3.2020 – spolu 295, dáta boli vyžiadané od NCZI – Národné centrum zdravotníckych informácií).



Graf 1: Všetky verzus odhalené prípady nákazy

Box 2: Iniciačný počet v simulácii IZP

Kedže počet identifikovaných prípadov pravdepodobne výrazne podhodnocuje reálny počet prípadov nakazených osôb, iniciačný počet vyplýva z identifikovaných prípadov vynásobených odhadovaným nárastom počtu týchto prípadov počas inkubačnej doby, ktorá bol odhadnutá na úrovni 6 dní (pri 95 % intervale spoľahlivosti – 4,5 až 5,8 dní podľa Lauer et al, 2020). Ako možno vidieť na grafe nižšie, na základe aktuálnych údajov je tento koeficient na úrovni 6.




Graf 2: Nárast identifikovaných prípadov COVID-19 v SR

Variácia mobility obyvateľstva a dopadu opatrení

Cieľom modelovania bolo zobraziť vrcholy, čiže body s najvyšším počtom infikovaných v jeden deň, aby sa tieto hodnoty dali porovnať s existujúcou kapacitou invazívnej ventilačnej techniky, resp. JIS/ARO kapacít. Grafy preto nezobrazujú celkový počet infikovaných, ale aktuálne hodnoty prevalencie daných dní.

- **Pri vysokej mobilite obyvateľstva** (žiadne alebo takmer žiadne obmedzenia) nastáva vrchol infekcie už 55 dní od začiatku simulácie. Pri vrchole infekcie je nakazených až 18,2 % populácie. Po 80 dňoch od začiatku nákazy pomer infikovaných osôb klesá pod 10 % populácie. Podobný priebeh v pravdepodobne prebiehal v Taliansku a Španielsku pred zavedením prísnych opatrení, o čom svedčí extrémny nárast pacientov na dennej báze, ako aj spojená vysoká úroveň mortality (ECDC, 2020).

- **Pri strednej mobilite obyvateľstva** (stredne prísne obmedzenia) je vrchol infekcie nižší (14,7 % populácie) a nastáva neskôr (63. deň), keďže nákaza je viac rozložená v čase. Choroba má v tomto prípade dlhší celkový priebeh, a tak pomer infikovaných osôb klesá pod 10 % až v 88. deň. Na základe odborného odhadu a aproximácie štúdie Ferguson et al. (2020) sa jednalo o opatrenia, ktoré boli platné na Slovensku pred 16.3.2020.
- **Pri vládnych opatreniach ohlásených 16.3.2020** pracuje model s rovnakou úrovňou mobility medzi obcami ako prvá verzia modelu, čiže 0.3, ale s nižšou rýchlosťou prenosu - použité R_0 je v priemere 2.0. Zníženie R_0 došlo kvôli zrealizovaniu predpokladov, diferenciácie MRK komunity a zapracovania odborných pripomienok. V tomto prípade nastáva vrchol v počte infikovaných až 101. deň na úrovni 5,6 %.
- **Pri obmedzeniach mobility a opatreniach ohlásených 24.3. a 27.3.2020** (povinné nosenie rúšok, minimálne rozstupy v obchodoch, separátne otváracie hodiny, povinné karantény pri vstupe či otvorenie niektorých obchodov za prísnych podmienok a ďalšie) je efekt nižšieho vrcholu a pomalšieho nástupu choroby výraznejší, keďže model uvažuje aj o nižšej rýchlosti prenosu na úrovni R_0 1.65. Vyššia alfa reflektuje otvorenie nových prevádzok. Tento scenár, ako všetky ostatné, pracuje s hypotézou, že opatrenia zostanú po celú dobu simulácie rovnaké, čo však budeme variovať v ďalšej verzii modelu. Aj keď celkový pomer nakazených je stále v maxime 3,1 % (takmer 170 000 osôb), táto situácia nastáva až po 110 dňoch od začiatku simulácie, a tak predstavuje výrazne nižšiu záťaž pre zdravotnícky systém.




Graf 3: Priebeh infekcie podľa mobility obyvateľstva

Variácia rýchlosti šírenia vírusu (R_0)

Nie všetky vládne opatrenia je možné modelovať znížením parametra mobility medzi obcami alfa. Napríklad povinné nosenie rúšok vonku a dôsledné umývanie rúk priamo znižujú schopnosť vírusu prenášať sa z jednej osoby na druhú, a preto je ich možné modelovať pomocou zníženia parametra R_0 (priemerný počet osôb, ktoré sú infikované jedným chorým). V nasledujúcich scenároch sme preto zadefinovali variabilitu parametra R_0 medzi 1.65 (stredný odhad súčasného modelu pri dnešných opatreniach) a 1.20. Pri hodnote R_0 nižšej ako 1 vírus postupne vymizne, keďže každý nakazený infikuje v priemere menej ako jednu osobu.


V scenároch nižšie model pracuje s hodnotami nízkej mobility medzi obcami (alfa je na úrovni 35 %), ale R_0 nabera hodnoty 1.65, 1.4 a 1.2. Z úrovne vrcholov je zrejmé, že hodnota R_0 je kľúčovým parametrom, ktorý zásadne ovplyvňuje priebeh ochorenia. V scenári s R_0 1.65 vrchol nákazy nastáva na úrovni 3,1 %, pri hodnote R_0 1.4 je úroveň 1,5 % a pri R_0 1.2 len 0,7 % celkovej populácie. Nižšie R_0 korešponduje tiež s pomalším priebehom nákazy a vrchol je posunutý na 110., 150., respektíve 175. deň od začiatku simulácie (28.3.2020).



Graf 4: Priebeh infekcie podľa mobility obyvateľstva, nižšia rýchlosť šírenia

Ktorá hodnota je najbližšia k realite dnes konzultujeme s epidemiológmi, prikláňame sa k verzii blízkej 1.65. V budúcej verzii modelu zohľadníme tiež zmenu R_0 a alfa v čase, keďže tieto hodnoty sa menili s vládnymi opatreniami, aj zmenami v správaní obyvateľstva, podobne ako to zobrazuje Box 3.

Nasledujúci graf ukazuje počet nových nákaz v čase v závislosti od mobility obyvateľstva. Vrcholy nákaz sú tu zreteľnejšie – napríklad pri plnej mobilite sa väčšina obyvateľov nakazí do 40 dní od začiatku simulácie a počet následne klesá, keďže v simulácii tí, ktorí už vírus mali, nemôžu byť nakazení znovu. Pri najvyššej mobilite už krátko po 60. dni počet nových infikovaných, v dôsledku vytvorenia kolektívnej imunity, klesá na nulu (pri scenári strednej mobility je to okolo 70. dňa). Pri nízkej mobilite počet nakazených výraznejšie osciluje, keďže nákaza sa šíri znovu v prípade vzniku superšíriteľa v obci a jeho následnej migrácie do ďalších obcí. Nákaza však plne nezaniká ani po 100 dňoch a ďalej sa šíri pomalým tempom.




Graf 5: Nárast infekcie podľa mobility obyvateľstva, absolútny počet


(červená – vysoká mobilita; oranžová – stredná mobilita; zelená – nízka mobilita predpokladaná po 16.3.2020; modrá – nízka mobilita predpokladaná po 27.3.2020)

Box 3: Ako stanoviť hodnotu R_0

Hodnota R_0 nie je statická a závisí od mnohých faktorov. Jeden z najlepších príkladov je samotný Wuhan, kde Lin (2020) rozdelil hodnoty R_0 do troch fáz. Nástupná s R_0 vo výške 3.88 (prvých 20 dní od prvého prípadu), 1.25 počas zavádzania opatrení a 0.32 po zavedení karantén a najstriktnějších opatrení. Podobnú fluktuáciu majú aj v Japonsku, kde však už posledné 3 týždne držia hodnotu R_0 pod 1.0 (druhý obrázok nižšie). Model IZP ráta so statickou priemernou hladinou R_0 vo výške 1.65 od 27.3.2020 a 2.0 ak by platili opatrenia spustené 16.3.2020. Jedná sa o odhad, konzultovaný s odborníkmi, presne spočítať sa bude dať, podobne ako v prípade Wuhanu, až po ukončení epidémie.



Lin (2020)



Katsunobu (2020)

Celkový počet nakazených ako výstup z modelu (mobilita po 24.3) je zobrazený v Tabuľke 1 nižšie, v časovej postupnosti pre vybrané dni.

Počet dní	Vysoká mobilita, Počet infikovaných	Stredná mobilita, Počet infikovaných	Nízka mobilita, Počet infikovaných	Opatrenia 27.3.2020, Počet infikovaných
10	8,666	6,340	3,482	2,789
20	45,189	27,885	7,626	4,546
30	218,998	115,846	16,512	7,520
40	626,274	326,041	38,375	14,740
50	953,653	635,506	78,298	27,200
60	970,865	780,440	132,395	46,082
80	556,845	679,410	257,438	103,105
100	177,499	338,341	300,151	154,462
150	6,024	20,149	205,600	138,242
200	244	1,037	81,838	91,312

Tabuľka 1: Počet infikovaných (celkový) v čase podľa troch scenárov mobility

Box 4: „Superširitel“

Ako ukazujú prípady z Južnej Kórey, niektoré osoby šíria koronavírus výrazne rýchlejším tempom ako je priemer. Túto dynamiku sme zohľadnili v modeli tým, že aj keď je reprodukčné číslo R_0 v priemere 2.4, spôsob jeho distribúcie v modeli umožňuje každý deň simulácie prideliť niektorým z obcí superširiteľov, čím je R_0 týchto obcí v deň simulácie výrazne vyššia. Superšírenie možno zohľadniť aj ako dôsledok takej udalosti v obci, ktorá umožnila vírusu rozšíriť sa rýchlo – napríklad športová udalosť s vysokou účasťou osôb (Frieden, Lee 2020). Táto zmena v modeli pomáha tiež lepšie zachytiť nezodpovedné správanie jednotlivcov s veľkým dosahom na ľudí, ako bol príklad gynekológa v Ružinove s cestovateľskou anamnézou a pozitívnymi výsledkami na koronavírus (TASR, 2020).

Prečo model predikuje tak vysoké úrovne infikovaných a diagnostikovaných pacientov?

Ako ukazujú mnohé štúdie, napríklad Verity et al (2020), Ferguson et al (2020) alebo Niehus et al (2020), reálny počet nakazených je násobne vyšší než množstvo diagnostikovaných pacientov v akoľvek systéme. Podľa dát z Číny takmer **40 – 50% infekcií nebolo identifikovaných ako prípady nakazenia práve preto, že nevykazovali symptómy** (Niehus et al, 2020). Tento rozdiel vzniká z troch hlavných dôvodov:

1. limitovaná kapacita zdravotníckych systémov testovať celú populáciu,
2. dlhá inkubačná doba,
3. asymptomatický priebeh ochorenia - v štyroch z piatich prípadov sú buď slabé alebo aj neprejavéne symptómy.

Je však potrebné zohľadňovať týchto „nediagnostikovaných-infikovaných,“ nakoľko môže ísť o tichých šíriteľov vírusu v rámci rizikovej populácie. Inak povedané, model IZP predikuje očakávanú reálnu

prevalenciu ochorenia, pričom podobne ako iné krajiny popísané v štúdiách, v realite identifikujeme testami len časť z množiny všetkých chorých.

Prípád Južnej Kórey s veľmi vysokým množstvom testovaných (ale aj pokročilého zdravotníckeho systému) ukazuje, že smrtnosť (pomer úmrtí na detegovaných nákazu) môže byť len na úrovni 0,8 %. V tomto prípade je počet reálnych a detegovaných nákaz oveľa bližšie ako vo väčšine krajín. Takáto konštelácia sa však nevyskytuje takmer v žiadnej inej krajine; krajiny s podobne nízkou fatalitou ako Južná Kórea majú skôr menší počet detegovaných nákaz. Štúdiá publikovaná len pred niekoľkými dňami (Ferguson et al., 2020) okrem spomínaných 40 – 50 % detegovaných pacientov sumarizuje nasledovné hodnoty dopytu po ústavnej starostlivosti:

Veková skupina	% symptomatických prípadov vyžadujúcich hospitalizáciu	% hospitalizovaných vyžadujúcich akútnu starostlivosť	IFR (infection fatality ratio)
0 - 9	0,10%	5%	0,00%
10 - 19	0,30%	5%	0,01%
20 - 29	1,20%	5%	0,03%
30 - 39	3,20%	5%	0,08%
40 - 49	4,90%	6,30%	0,15%
50 - 59	10,20%	12,20%	0,60%
60 - 69	16,60%	27,40%	2,20%
70 - 79	24,30%	43,20%	5,10%
80+	27,30%	70,90%	9,30%

Tabuľka 2: Publikované pomery pacientov vyžadujúcich hospitalizáciu, akútnu starostlivosť a IFR

Zdroj: Ferguson et al (2020) a Verity et al (2020)

Tieto hodnoty vychádzajú z regionálnych špecifik, prístupu k testovaniu či organizácie zdravotnej starostlivosti. Ich aplikácia na systém v SR je preto len hrubý odhad. Na Slovensku ešte totiž nemáme dostatočný počet pacientov, aby sme vedeli modelovať aj presnú vekovú štruktúru, a tým lepšie asimilovať model. Ak však rátame súčasnú vekovú distribúciu, tak očakávame, že 7,43 % symptomatických pacientov bude vyžadovať hospitalizáciu a 13,75 % z nich bude vyžadovať akútnu starostlivosť. Nakoľko máme na Slovensku momentálne nízky počet pacientov, ktorí vyžadujú akútnu starostlivosť, tak sa jedná o pesimistický – konzervatívny odhad. Na základe R03 výkazu NCZI (Ročný výkaz o zdravotníckej technike) máme k dispozícii takmer 450 ventilátorov, ktoré sa dajú použiť na invazívnu ventiláciu pacientov. Za posledné dve týždne sa cez súkromné dary a iniciatívy doplnilo ďalších 20 prístrojov (alebo ECMO). Štátne hmotné rezervy v súčasnej dobe navyšujú tento stav o minimálne 130 kusov⁴ (od 19.3.2020 prebralo MZ SR proces). Kapacitne preto rátame, že bez obmedzení⁵ bude náš systém schopný zvládnuť 600 ventilovaných pacientov s COVID-19. Je preto zrejmé, že obmedzenia výrazne prispeli k vyrovnaní dopytu po starostlivosti.

⁴ <https://rokovania.gov.sk/RVL/Material/24587/1>

⁵ abstrahujeme od iných limitácií, karantén personálu a pod. Ide len o priame porovnanie technického maxima kapacít invazívnej ventilácie.

K naplneniu týchto kapacít dôjde za 70 dní⁶. Jedná sa teda stále o veľkú rezervu, ktorá sa dá využiť na zastavenie nákazy, budovanie kolektívnej imunity či aplikáciu cielených opatrení. Ak by sa ponechali platné opatrenia pred 26.3.2020, tak by táto rezerva bola len necelých 40 dní.

Nemecké zdravotníctvo preto zvolilo ako jedno z predbežných opatrení zabezpečiť viac prístrojovej techniky a objednalo do rezervy 10 000 prístrojov; Taliansko prikázalo lokálnemu výrobcovi presmerovať celú produkciu (500 kusov prístrojov mesačne) pre účely talianskych nemocníc (Buck and Ghighlione, 2020).

Počet dní	Počet infikovaných	Symptomatickí pacienti	Hospitalizácie	Vyžadujúci intenzívnu starostlivosť
10	2,789	1,674	124	17
20	4,546	2,728	203	28
30	7,520	4,512	335	46
40	14,740	8,844	657	90
50	27,200	16,320	1,213	167
60	46,082	27,649	2,054	282
80	103,105	61,863	4,597	632
100	154,462	92,677	6,886	947
150	138,242	82,945	6,163	847
200	91,312	54,787	4,071	560

Tabuľka 3: Očakávaný dopyt po ústavnej starostlivosti v SR v prípade nízkej mobility

Vyššiu transmisiu ako u majoritného obyvateľstva, sme predpokladali u marginalizovaných rómskych komunit (MRK), ale aj u ostatných skupín ohrozených chudobou a sociálnym vylúčením. Na jednej strane sú síce tieto komunity čiastočne chránené nižším priemerným vekom a čiastočnou izoláciou od majority, no rizikové faktory to prevyšujú. Sociálne vylúčené komunity majú horší zdravotný stav (vrátane neliečených a chronických chorôb), nedostatočné hygienické podmienky a zhoršený prístup k pitnej vode, zhoršený prístup k zdravotným službám, nižšie povedomie o správnej hygiene a vyššiu hustotu obyvateľstva. Takisto značná časť komunity migruje za prácou do zahraničia.

Úrad splnomocnenca vlády pre rómske komunity považuje za najdôležitejšie kroky zabezpečenie dostatočných ochranných pomôcok pre terénnych pracovníkov (terénni pracovníci sú pre MRK bod prvého kontaktu a ich úloha je kľúčová pri prevencii), poskytnutie materiálnej pomoci pre MRK (prístup k pitnej vode tam, kde nie je zabezpečený, k mydlu a k antibakteriálnym gélom), prípravu krízových plánov v obciach s MRK (vrátane vytvorenia jednoduchého postupu pre starostov pre uplatnenie prípadných

⁶ Za predpokladu, že sú všetky prístroje využité pre COVID-19 pozitívnych pacientov. Vrchol potreby sa dosiahne v 110. deň na počte približne 1 030 ventilovaných pacientov.

karanténnych opatrení) a prípravu na dopady epidémie na MRK (s dôrazom na výpadok detí zo vzdelávacieho systému, zvýšenie nezamestnanosti a nárast spoločenského napätia).⁷

Komentár

Základným výstupom tejto analýzy je porovnanie vplyvu opatrení a obmedzenia mobility populácie na celkový priebeh a vývoj epidémie koronavírusu. Môžeme potvrdiť, že opatrenia po 16.3.2020 a 27.3.2020 znížia celkový očakávaný počet infikovaných koronavírusom. Podľa simulácie nepresiahne najvyšší počet nakazených 3,1 % populácie. Po prerátaní na potrebu hospitalizácií je to zvládnuiteľná hodnota (pri postupnom doplnení kapacít). K tejto situácii by však došlo v prípade, že zavedené opatrenia zostanú v platnosti najbližšie 3 až 4 mesiace, keďže vrchol v počte infikovaných je dosiahnutý až po 110 dňoch. Scenár prísnych opatrení limitujúcich mobilitu v krajine je kvôli silnému vplyvu na bežný život a ekonomiku krajiny nepravdepodobný, a preto je potrebné zabezpečiť aj iné formy opatrení, ktoré budú minimalizovať vážne negatívne ekonomické efekty, spojené s touto situáciou.

Náš scenár aktualizovanej verzie vládnych opatrení k 28.3.2020 ráta so strednou alebo mierne nižšou hodnotou R_0 podľa literatúry a podľa odhadov vedcov z FMPH UK v priemernej výške 1.6 v hlavnom scenári⁸, avšak zahŕňa prítomnosť superšíriteľov, ktorí môžu infikovať výrazne vyšší počet osôb ako priemerný chorý. Model predpokladá pomerne mierne dopady opatrení na mobilitu populácie medzi obcami (porovnávajúc mieru mobility v hodnotách 100 %, 70 % a 35 % pre jednotlivé scenáre). Je vysoko pravdepodobné, že silnejšie opatrenia by viedli k ešte väčšiemu splošteniu epidemiologickej krivky. Kvôli potrebnému trvaniu týchto opatrení pred dosiahnutím vrcholu distribúcie preto považujeme cielené opatrenia za efektívnejšie riešenie. V modeli zohľadňujeme tiež socio-ekonomické faktory na level obce, ktoré je možné využiť na cielenú pomoc najviac ohrozeným obciam alebo skupín občanov. Model taktiež predikuje vyššie hodnoty pre skupiny so slabším socio-ekonomickým statusom, čím sa kompenzuje pravdepodobnosť rýchlejšieho šírenia v týchto oblastiach.


Nakoľko používame pri simuláciách maticu pohybu osôb medzi obcami a každý deň je prepočítaný na všetky obce, disponujeme po ukončení simulácie údajmi o šírení vírusu v čase pre každú z nich. To nám umožňuje modelovať dopady na jednotlivé regióny a prijať optimálne cielené opatrenia za účelom manažovania kapacít zdravotníctva. Budúca verzia modelu bude zohľadňovať aj dáta od mobilných operátorov, ktoré pomôžu spresniť pohyb populácie medzi obcami a zaradiť návraty zo zahraničia do modelu. Tieto údaje boli vyžiadané výborom MZ SR a prisľúbené ústredným krízovým štábom v pondelok 16.3.2020. Po obdržaní dát dokážeme navrhnúť opatrenia cielené na najviac ohrozené regióny, obce či skupiny obyvateľstva, podobne ako to je v Nemecku či v iných krajinách.

Najlepší predikčný model sa ukáže až empiricky, po prekonaní tejto pandémie. Odhadujeme, že ideálnou cestou môže byť kombinácia viacerých opatrení, napr. cielená karanténa pre rizikovú populáciu a rizikové lokality, zabezpečenie domácej starostlivosti pre väčšinu pacientov s ľahkým a miernym priebehom, testovanie aj na všetky rizikové skupiny. Štúdia Imperial College-u (Ferguson et al., 2020) sa pokúsila empiricky dopočítať dopady jednotlivých opatrení, ako zobrazuje nasledovný graf, avšak ich efektivita bude závisieť od disciplíny obyvateľstva, pokročilosti zdravotníckeho systému a ďalších faktorov. Z tejto

⁷ Vychádzame z listu splnomocnenia vlády pre rómske komunity premiérovi z dňa 22.3.2020

⁸ To znamená, že pacient je schopný počas svojho ochorenia nakaziť v priemere 1,6 ďalších pacientov.

analýzy je však zrejmé, že Slovensko zaviedlo takmer všetky mitigačné či supresívne opatrenia, ktoré sú k dispozícii, čo malo pozitívny vplyv na spomalenie šírenia vírusu. Na základe opravených dát sme názoru, že Slovenský vývoj je aj pri pesimistickom pohľade stabilný a postupné zavádzanie cielených opatrení je nevyhnutné.



Graf 6: Dopady zavedenie rozličných opatrení na NHS (Britský národný systém zdravotníctva) kapacity kritickej starostlivosti (Ferguson et al., 2020)

Vysvetlenie scenárov: Červená – Maximálna kapacita lôžok pre intenzívnu starostlivosť, Tmavomodrá – Žiadna akcia, Oranžová – Izolácia detekovaných prípadov, Žltá – Izolácia detekovaných prípadov a domáca karanténa, Zelená – Zatvorenie škôl a univerzít, Modrá – Izolácia detekovaných prípadov, domáca karanténa, minimalizácia sociálnych interakcií

Modely úspešnej reakcie

Úspešné reakcie globálnych vlád by sa dali rozdeliť do troch skupín resp. modelov: Čína, Južná Kórea a Taiwan.

Čínska voľba bola minimalizácia rozširovania nákazy od istého bodu absolútnym odstihnutím mesta a provincie od zvyšku sveta (model IZP dokáže takúto situáciu simulovať „vypnutím“ migrácie medzi touto lokalitou a zvyškom). Táto forma môže byť inšpiráciou z hľadiska výrazného zníženia pokračujúcej nákazy, no má značný vplyv na bežný život aj level ekonomickej aktivity v štáte. O podobnú úroveň oddelenia od zvyšku sveta sa v súčasnosti pokúša severné Taliansko.

Juhokórejský model bol založený na výrazne vyššej kapacite pre testovanie než sme schopní dosiahnuť v tejto dobe. Dodnes tam bolo uskutočnených viac než štvrt milióna testov v rámci celej krajiny, čo je druhý najvyšší počet po čínskom Wuhane. Kórejský model bol tiež výnimočný výskytom viacerých pacientov, takzvaných „super-šíriteľov,“ ktorí rozšírili infekciu výrazne nad priemerom v populácii.

V Taiwane boli schopní zachovať mimoriadne nízky počet nakazených ľudí i napriek blízkosti k Číne. Krajina neblokuje pohyb v rámci vlastného územia do takej miery ako Čína, ani nedisponuje takým počtom testovaných ako Južná Kórea. Taiwanský úspech vychádza z dobrého manažmentu potenciálnych a nakazených pacientov. Tri kľúčové body sú:

- Samo-ohlasovanie histórie cestovania a symptómov cez automatizovanú elektronickú aplikáciu, ktoré je povinné u všetkých prichádzajúcich zo zahraničia;
- Detailné sledovanie prípadov nakazených (geograficky aj historicky) – vďaka špecifickej aplikácii sledujúcej pohyb;
- Dobrý manažment osvetu a informovania verejnosti –, komunikácia o príznakoch a prevencii cez vyhradené sloty v televízii,
- Dostupnosť rúšok pre exponované profesie aj verejnosť.

Práve na základe skúseností z Taiwanu chceme využiť detailné dáta od mobilných operátorov na špecifické monitorovanie, ako aj oslovenie rizikových skupín obyvateľstva. Prípad Taiwanu ukazuje, že situáciu možno dostať pod kontrolu v prípade komplexného manažmentu pacienta (Wang et al., 2020).

Záver

Pre efektívnu schopnosť reakcie na COVID-19 je potrebné predikovať potrebu starostlivosti v jednotlivých geografických oblastiach a čo najviac minimalizovať mobilitu v krajine. Ďalšie možné opatrenia do budúcnosti budú musieť byť analyzované z pohľadu možných benefitov a rizík. Presnosť modelov a analýz, ako aj schopnosť štátu reagovať, možno zlepšiť presnými údajmi od mobilných operátorov, na základe ktorých budeme schopní exaktne dopočítať predikcie nových nákaz, ako aj rizikové oblasti v krajine. Analýza zachytáva možnú prítomnosť superširiteľov, socio-ekonomické charakteristiky obce a vhodnejšiu voľbu parametrov modelu.

Potlačenie epidémie prostredníctvom minimalizácie sociálneho kontaktu (tzv. „social distancing“) je najlepšou možnou formou reakcie na túto krízu a ako ukazuje náš model, znižovanie mobility osôb a šírenia nákazy bude kľúčové pre limitovanie jeho rozsahu pre najrizikovejšie skupiny. Tento prístup poskytne dost času zdravotníckemu systému reagovať na ochorenia najkritickejších skupín do času, keď sa u populácie vytvorí kolektívnu imunitu a zdravotnícky systém bude na nápor lepšie pripravený. Na druhej strane je nevyhnutné postupne opúšťať od celoplošných opatrení a zavádzať cieľené opatrenia zamerané na rizikové skupiny.

IZP pripraví tretiu verziu modelu do piatka 3.4.2020 a zapracuje údaje o presnom pohybe obyvateľstva, aby sa cieľené politiky a akcie dokázali čím skôr a adresne aplikovať. Kompletný model zverejníme na webe IZP pre ďalšiu replikáciu, pripomienky a vylepšenie.

Podakovanie

Radi by sme sa poďakovali všetkým osobám a inštitúciám, ktoré si našli priestor a pripomienkovali náš model, poskytli údaje alebo poskytli svoj odborný názor. Osobitne ďakujeme expertom: Robert Mistrík a Juraj Lutšan (HighChem), Pavol Čekan (MultiplexDX), Richard Kollár a Katarína Boďová (FMFI UK, Bratislava), Radoslav Harman a Zuzana Chladná (FMPH UK), Vladimír Krčméry (FMUK), Urban Kováč a Peter Pšenák (KKM FMUK), Jozef Šuvada, Tomáš Kúdela a jeho tím (MZ SR), Soňa Slobodníková, Matúš Lupták (a jeho tím), kolegom z IFP (Eduard Hagara, Branislav Žúdel, Daniel Dujava, Tomáš Meszároš), UHP (Štefan-

Zdeno Kišš, Adam Marek a Tomáš Hellebrandt), Daniel Reitzner, Ján Šimon, Pedro Degiovanni, Micole De Vera a všetkým odborne diskutujúcim na FB, či našej web-stránke www.izp.sk.

Teší nás a ďakujeme, že máme možnosť spolupracovať okrem iných aj s členmi platformy Slovak.AI pod vedením Márie Bielikovej.

Zoznam použitých zdrojov

Bao L., et al. (2020). Reinfection could not occur in SARS-CoV-2 infected rhesus macaques. *bioRxiv*. Published online March 14, 2020. doi: 10.1101/2020.03.13.990226.

Buck, T. a Ghighlione, D. (2020). European countries search for ventilators as virus cases surge. *Financial Times*. Dostupné online: <https://www.ft.com/content/5a2ffc78-6550-11ea-b3f3-fe4680ea68b5>

ECDC (2020) European Centre for Disease Prevention and Control: Dataset. Dostupné online: <https://www.ecdc.europa.eu/en/publications-data/download-todays-data-geographic-distribution-covid-19-cases-worldwide>

Ferguson, N., Laydon, D., Nedjati-Gilani, G. Imai, N. et al. (2020). Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand. Imperial College COVID-19 Response Team. Dostupné online: <https://www.imperial.ac.uk/media/imperial-college/medicine/sph/ide/gida-fellowships/Imperial-College-COVID19-NPI-modelling-16-03-2020.pdf>

Frieden TR, Lee CT. Identifying and interrupting superspreading events—implications for control of severe acute respiratory syndrome coronavirus 2. *Emerg Infect Dis*. 2020 Jun [21.3.2020]. <https://doi.org/10.3201/eid2606.200495>

Havran, P., Mesároš, T., Paur, D., 2019 Koľko je na Slovensku cépečkárov? Dostupné online: https://www.mfsr.sk/files/archiv/42/2019_X_Obvyklpobyt20190404_final.pdf

Katsunobu, K. (2020) Experiences of Japan to respond to COVID-19. Memo a webex, Ministerstvo zdravotníctva Japonsko. Dostupné na vyžiadanie.

Kucharski, A. J., Russel, T. W., Diamond, CH. et al. (2020) Early dynamics of transmission and control of COVID-19: a mathematical modelling study. *The Lancet Infectious Diseases*, March 11, 2020. Dostupné online: [https://www.thelancet.com/journals/laninf/article/PIIS1473-3099\(20\)30144-4/fulltext](https://www.thelancet.com/journals/laninf/article/PIIS1473-3099(20)30144-4/fulltext)

Li Q, Guan X, Wu P, Wang X, Zhou L, Tong Y, et al. (2020). Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus-Infected Pneumonia. *The New England Journal of Medicine*. Dostupné online DOI:10.1056/NEJMoa2001316

Lin, X. (2020) Special Webinar by Xihong Lin on Analysis of 25, 000+ COVID-19 cases in Wuhan: Epidemiological characteristics and effects of non-pharmaceutical interventions. Dostupné online: <https://www.hsph.harvard.edu/biostatistics/covid-19-webinar/>

Liu T., Gayle, A.A., Wilder-Smith, A a Rocklov, J. (2020) The reproductive number of COVID-19 is higher compared to SARS coronavirus. *Journal of Travel Medicine*. Dostupné online DOI: <https://doi.org/10.1093/jtm/taaa021>

Liu T, Hu J, Kang M, Lin L (2020a). Time-varying transmission dynamics of Novel Coronavirus Pneumonia in China. *bioRxiv*. Dostupné online DOI:10.1101/2020.01.25.919787.

Niehus, R., De Salazar, P. M., Taylor, A., & Lipsitch, M. (2020). Quantifying bias of COVID-19 prevalence and severity estimates in Wuhan, China that depend on reported cases in international travelers. *medRxiv*.: 10.1101/2020.02.13.20022707

Peña-García, V. H., & Christofferson, R. C. (2019). Correlation of the basic reproduction number (R0) and eco-environmental variables in Colombian municipalities with chikungunya outbreaks during 2014-2016. *PLoS neglected tropical diseases*, 13(11), e0007878. <https://doi.org/10.1371/journal.pntd.0007878>

Read, J. M., Bridgen, J. R., Cummings, D. A., Ho, A., & Jewell, C. P. (2020). Novel coronavirus 2019-nCoV: early estimation of epidemiological parameters and epidemic predictions. *medRxiv*. doi: 10.1101/2020.01.23.20018549.

Rocklov, J., Sjoding, H a Wilder-Smith, A. (2020) COVID-19 outbreak on the Diamond Princess cruise ship: estimating the epidemic potential and effectiveness of public health countermeasures. *Journal of Travel Medicine*, <https://doi.org/10.1093/jtm/taaa030>

Riou, J. and Althaus, Ch. L. (2020). "Pattern of early human-to-human transmission of Wuhan 2019 novel coronavirus (2019-nCoV), December 2019 to January 2020". *Eurosurveillance*. **25** (4). doi:10.2807/1560-7917.ES.2020.25.4.2000058

Stephen A. Lauer, Kyra H. Grantz, Qifang Bi, Forrest K. Jones, Qulu Zheng, Hannah R. Meredith, Andrew S. Azman, Nicholas G. Reich, Justin Lessler. *The Incubation Period of Coronavirus Disease 2019 (COVID-19) From Publicly Reported Confirmed Cases: Estimation and Application*. *Annals of Internal Medicine*, 2020. Dostupné online DOI: 10.7326/M20-0504

TASR (2020) Lekárovi z kliniky gynekológie ružinovskej nemocnice potvrdili koronavírus. TREND.sk Dostupné online: <https://www.etrend.sk/ekonomika/krajci-lekarovi-z-kliniky-gynekologie-ruzinovskej-nemocnice-potvrdili-koronavirus.html>

Verity R, Okell LC, Dorigatti I, et al. (2020) Estimates of the severity of COVID-19 disease. *medRxiv*; doi:10.1101/2020.03.09.20033357v1.

Wang, C. J., Ng, C. Y., & Brook, R. H. (2020). Response to COVID-19 in Taiwan: Big Data Analytics, New Technology, and Proactive Testing. *JAMA journal*, doi:10.1001/jama.2020.3151

Wang, J., Tang, K., Feng, K., & Lv, W. (2020). High Temperature and High Humidity Reduce the Transmission of COVID-19. Available at *SSRN 3551767*.

Wesolowski, A., zu Erbach-Schoenberg, E., Tatem, A.J. et al. (2017) Multinational patterns of seasonal asymmetry in human movement influence infectious disease dynamics. *Nature Communications* **8**(2069) <https://doi.org/10.1038/s41467-017-02064-4>

Yeghikyan, G (2020) Modelling the coronavirus epidemic in a city with Python. *Towards data science*, February 4, 2020 Dostupné online: <https://towardsdatascience.com/modelling-the-coronavirus-epidemic-spreading-in-a-city-with-python-babd14d82fa2>

Zhang, S., Diao, M., Yu, W., Pei, L., Lin, Z., & Chen, D. (2020). Estimation of the reproductive number of Novel Coronavirus (COVID-19) and the probable outbreak size on the Diamond Princess cruise ship: A data-driven analysis. *International Journal of Infectious Diseases*, 93, April 2020 Dostupné online: 10.1016/j.ijid.2020.02.033